Didaktičko-metodičke kompetencije nastavnika matematike

Horvat, Zoran

Doctoral thesis / Disertacija

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, University of Zagreb, Faculty of Humanities and Social Sciences / Sveučilište u Zagrebu, Filozofski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:131:336514

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Filozofski fakultet
Sveučilišta u Zagrebu

Repository / Repozitorij:

ODRAZ - open repository of the University of Zagreb
Faculty of Humanities and Social Sciences

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište u Zagrebu

FILOZOFSKI FAKULTET

Zoran Horvat

DIDAKTIČKO-METODIČKE KOMPETENCIJE NASTAVNIKA MATEMATIKE

DOKTORSKI RAD

Zagreb, 2019.

Sveučilište u Zagrebu

FILOZOFSKI FAKULTET

Zoran Horvat

DIDAKTIČKO-METODIČKE KOMPETENCIJE NASTAVNIKA MATEMATIKE

DOKTORSKI RAD

Mentor: prof. dr. sc. Ante Kolak

Zagreb, 2019.

University of Zagreb

FACULTY OF HUMANITIES AND SOCIAL SCIENCES

Zoran Horvat

Didactic-methodical competencies of mathematics teachers

DOCTORAL THESIS

Supervisor:

PhD Ante Kolak

Zagreb, 2019.

Mentor: prof. dr. sc. Ante Kolak

Životopis:

Ante Kolak rođen je 1972. u Slavonskom Brodu gdje je završio osnovnu i srednju školu. Na Učiteljskoj akademiji u Zagrebu 2004. stječe zvanje nastavnika razredne nastave. Studij pedagogije na Filozofskom fakultetu u Zagrebu završio je 1998. Magistrirao je 2004. s radnjom „Stavovi roditelja prema suradnji sa školom". Doktorski rad „Modeli upravljanja nastavnim procesom" obranio je 2008. pod vodstvom mentora prof. dr. sc. Vladimira Jurića. Radio kao učitelj razredne nastave u osnovnoj školi te kao pedagog u srednjoj školi. Bio je stručni suradnik na Učiteljskoj akademiji u Zagrebu u području metodika nastave. Godine 2013. izabran je za suradničko zvanje i radno mjesto docenta na Katedri za didaktiku na Odsjeku za pedagogiju. Od 2002. godine član je znanstveno-istraživačkih projekata Odsjeka za pedagogiju Filozofskog fakulteta u Zagrebu (Metodologija i struktura nacionalnog kurikuluma; Kurikulum socijalnih kompetencija i odnosa u školi, voditelj prof. dr. sc. Vlatko Previšić). Od 2004. godine bio je član uredništva za izdavanje udžbenika kao i autor priručnika za učitelje i učenike. Trenutno na preddiplomskom i diplomskom studiju sudjeluje u realizaciji kolegija Teorije i metodike nastave, Didaktika, Školski podsustavi, Upravljanje i autonomija škole te Obrazovanje darovitih. Autor je znanstvenih i stručnih radova iz područja didaktike, školske pedagogije i obrazovanja darovitih te je mentor studentima diplomskog i poslijediplomskog studija pedagogije. Za uredništvo udžbenika Priroda i društvo na svjetskom sajmu knjiga u Frankfurtu 2010. osvojio je srebrnu medalju za najbolji europski udžbenik u kategoriji udžbenika za niže razrede osnovne škole.

Zahvale

Sve što je vrijedno u životu postiže se ustrajnim radom i upornošću prema ostvarivanju postavljenih ciljeva. Međutim, bez utjecaja bližnjih nam ljudi, koji nas vole i podupiru, to nije moguće. Prije svega od srca zahvaljujem svojem profesoru, mentoru i kolegi dr. Anti Kolaku na pruženoj prilici te posebice na svim vidljivim i nevidljivim oblicima potpore koju mi je pružio na životnoj dionici mojeg profesionalnog razvoja.

Hvala mojim roditeljima koji su, pored neopisive potpore i ljubavi, omogućili da se na osobnoj i profesionalnoj razini razvijem u osobu koja može postići sve što poželi u životu. Za kraj, hvala Nini koja je sa mnom prošla najteže trenutke u procesu pisanja ove doktorske radnje.

Sažetak

Raširenost izazova i zahtjeva nastave matematike u obrazovnim sustavima diljem svijeta dovela je do afirmacije novog interdisciplinarnog znanstvenog područja koje se u široj znanstvenoj zajednici navodi kao „Matematičko obrazovanje“ (eng. *Mathematics Education*). Pored sadržaja supstratne znanosti, izazovi suvremene nastave matematike predmet su interesa stručnjaka različitih profila (pedagoga, psihologa, sociologa, antropologa, komunikologa i sl.) što implicira kompleksnost zahtjeva koji predstoje predmetnim metodikama i didaktikama čiji položaj i klasifikacija u sustavno-znanstvenom sistematskom poretku nisu razjašnjeni u znanstvenoj zajednici. Specifičnost zahtjeva nastave matematike pokazuje se kao izazov visokog prioriteta suvremenih obrazovnih sustava.

Glavni ciljevi tog područja su obrazovanje nastavnika matematike, unapređenje kvalitete nastave matematike te jačanje znanstveno-istraživačkog potencijala u području matematičkog obrazovanja. U nastojanjima da se učenicima pruži suvremena i kvalitetna nastava matematike, nužno je razmatrati zastupljenost pedagoških i didaktičko-metodičkih sadržaja u obrazovanju nastavnika te usklađenost obrazovnih standarda s nastavnim planovima i programima.

U suvremenom društvu mnogobrojnih trendova kompetencije nastavnika matematike moraju se sagledavati u okviru šireg društvenog i obrazovno-političkog konteksta unutar kojeg promatramo i cjelokupno matematičko obrazovanje, a polazište u nastavi mora biti usmjereno na učenike, ali i čimbenike koji utječu na razvoj njihovih vještina i sposobnosti te odgojnih vrijednosti koje pritom stječu.

Pritom treba koristiti suvremene didaktičke pristupe te ih prilagođavati s obzirom na specifičnosti učenja i poučavanja matematike te s obzirom na znanja, umijeća i sposobnosti nastavnika koja su u najiziravnijoj vezi s učenjem učenika. Razumijevanje pojedinačnih uvjerenja, stavova i postupaka nastavnika, koje čine učinkovitu nastavu matematike, suštinski su izazov i prioritet matematičkog obrazovanja te su stoga osnova istraživačkih interesa, kao i refleksije osobnih praktičnih iskustava i djelovanja nastavnika usmjerenih na unaprjeđivanje odgojno-obrazovne prakse.

Ključne riječi: matematičko obrazovanje, kompetencije nastavnika, uvjerenja i samoprocjene nastavnika

Structured abstract

A quality upbringing and education can be attainable only with quality elementary and high school teachers, requiring the quality of their initial education and their ongoing training. Teachers' competence is one of the key issues in the quality of educational system with a constant effort being made to determine a set of competencies of a successful teacher and the characteristics which distinguish them from the less successful ones. Even though recent research has indicated the need for a higher standard in the pedagogical knowledge of teachers, there are still disagreements on the competencies of math teachers, namely in the competence hierarchy relatable to the requirements of modern math teaching. The objective of this research is to analyse the beliefs, self-assessments, teaching practices and extra curricular activities of teachers that affect their performance. In order to conduct the research on the competence profile of math teachers and present the findings, an instrument was devised based on relevant research in the field of math education as well as pedagogy and psychology. The work is organized in five main chapters: introduction, theoretical segment, methodology of the empirical segment, findings, final deliberations and comments on research findings.

In *Introduction* the author starts with the assumption that in theoretical and practical considerations on mathematical education social and affective aspects of recent challenges in teaching mathematics are often undermined, as well as the need for interdisciplinary approach in didactics and methodics of math teaching in order to offer solutions to a number of problems facing teaching in practice. The author asserts a critial approach in analysing the field of mathematical education, displaying how comprehensive and multilayered the challenges of modern math teaching and the suitable math teacher competence profile are. He describes the epistemology of mathematics and its relation to epistemological status of maths in schools, emphasizing social context as key distinction, presenting both a challenge as well as the potential for creating the requirements for a better quality math teaching.

As essential factors in mathematical education he mentions stereotypes that have accompanied maths and science throughout history, along with educational policies and international research on education that have become a standard for successful education. The author concludes the introductory part with a reference to the current state of the educational system, taking into account teachers' position and competencies along with the quality of the teaching and learning process in relation to the contemporary educational policies.

The following part, *Theoretical segment* comprises five sub-chapters introducing a more comprehensive outline of relevant aspects in mathematical education: competence approach to education; didactic and curricular approach to math education; students with special needs in math teaching; social and affective aspects of mathematical education; teachers' competencies.

In the segment *Competence approach to education* the author displays a historical outline of the recent educational policies and the development of the concept of lifelong learning, along with competence approach to education. In doing so, he points out the discrepancies between economic trends and pedagogical aspects of education as one of the most significant challenges of modern education. He also illustrates the position of mathematical competence within the contemporary education and upbringing as well as the features and nature of mathematical language, script and thinking, linking them to the main objectives of mathematics in schools.

In the following sub-chapter *Didactic and curricular approach to mathematical education* the author presents an outline of theories in didactics, analyses them and relates to the specifics of math teaching. In doing so, he describes fundamental didactic models, placing them in the context of math teaching and analysing them from the scientific pedagogical aspect. He states the existence of a discontinuity between the initial education of teachers and the requirements posed by practice and points to the predominance of core science in the methodics of math teaching. In the segment entitled *Educational and upbringing standards in math teaching* the author asserts a critical standpoint against the aim-oriented contemporary curricula and highlights numerous challenges from practice which thus remain unaddressed, together with problems on a theoretical and content level of the curriculum which have not even been taken into consideration within math teaching. Furthermore, he presents conceptual and organizational components in teaching along with the general didactic principles, focusing on specific usage in math teaching. In practical examples, he illustrates the potential usage of certain methods in math teaching. He views evaluation as one of the crucial elements and points out that evaluation of educational aims within the existing currricula and lesson plans and programs should consider the position of students and their educational and upbringing needs.

In the sub-chapter *Students with special needs in math teaching* he addresses students with dyscalculia and the gifted ones. In that sense, he especially emphasizes insufficient representation of dyscalculia in theoretical, research as well as practical terms in comparison to other learning disorders and the need for a pedagogical approach and counseling of both children and their parents. This is followed by a concise outline of dominant theoretical

approaches to studying giftedness. As a significant challenge to teaching and learning mathematics he presents the problem of recognizing the gifted students, where the concept of giftedness is not seen in binary terms following the concept of creativity, but instead considers the (mathematical) development of an individual as a process subjected to change and direction by well-trained experts. Along with the issue of giftedness he indicates the presence of stereotypes and the perception of mathematical education forced upon by society and individuals, emphasizing the necessity for math teacher training in theoretical aspects of stereotyping related to math teaching, as well as the practical competence in a form of pedagogical counselling and development of students' educational aspirations.

In sub-chapter *Social and affective aspects of mathematical education* he presents the notion that math teaching is constructed within certain social frames and that subsequent success in teaching and learning math is under a significant influence of social and affective factors, which, therefore, have to be incorporated into subject curriculum planning as its integral part. As one of the crucial moments in math teaching the author claims that students have positive or neutral attitude and emotional reactions towards math in the beginning of their education, whereas, with years they become more negative. He presents a comprehensive outline of scientific research related to sudent beliefs and emotional reactions, by which he implies a critical attitude towards outcomes-set priorities in math teaching. He refers to one of the most significant challenges in considerations on teachers' competencies: the relationship between a teacher's competence and student achievement, and claims that studying teachers' competencies has to encompass a wide spectrum of their beliefs and attitudes in order to gain a perspective on their approach to students and teaching. This claim is supported with research showing that the role and actions of teachers, perception of the importance of mathematics, the ability to grasp it, perception of math as a social activity and as the field of success shape the beliefs and students' attitudes towards mathematics (Eynde and De Corte, 2003). He is guided by the notion that teachers have an influence on educational aspirations and academic success of their students (Marsh,1987; Cambria et al., 2017), emphasizing the complexity of each class dynamics, which, using the average student achievement variable determines the relationship between students in the context of the perception of their academic self-efficiency (Marsh, 1987).

Theoretical segment concludes with an outline of relevant literature on teachers' competencies, their beliefs and self-assessment on the quality of performance and teaching patterns as well as expert training (sub-chapter *Teachers' competencies*). Within various fields of teacher competence, the author highlights didactic and methodical competence as the

operative aspect of the superimposed pedagogical one.

In third chapter *Methodology of empirical research* he highlights the emphasis the traditional pedagogy attributes to the styles of learning (Marsh, 1994), and not so much the content of learning. In doing so, he views the concept of didactic and methodical competence of math teacher as operative teacher competence, i.e. as a form of manifestation of overall teacher competence profile.

As the main objective of the research the author sets determining predictive value of individual teacher characteristics, deriving from their attitudes, beliefs, self-assessment and teaching practice and the amount in which they contribute to the quality of teaching, starting with the assumption that the perception of academic self-efficiency, teacher system of values and beliefs reflect teacher competence profile, determine their teaching and upbringing role and are the foundation for acquiring values and achieving educational outcomes of students. A research tool was devised on that premises comprising four parts: 1. Socio-demographic data; 2. Scale of teacher beliefs about teaching and education in general, including specific and problematic areas of math education; 3. Scale of teacher self-efficiency; 4. Scale of occurence of teaching practices, including participation in profesional training and enhancement. Based on the analysis of the research on teacher competence, the author claims that the research where the given aspects (beliefs, sels-assessment and teaching practice) are mainly observed separately outnumber the ones that incorporate them and studies their inter-relationship. He thus claims that beliefs, self-assessment and teaching practice of the participants in the research were firstly analysed as separate, and subsequently in their inter-relationship, which provides a framework in methodological approach to the empirical segment of this study.

Participants in the research were elementary and high school math teachers. Total of 348 teachers from all Croatian counties took part, making up a representative sample according to Cohran formula for assessing sample size (1963).

Fourth part *Research findings* encompasses the majority of the paper and is organized according to the sequence of data analysis and research phases. This refers to as follows: descriptive analysis, factor analysis and co-relation analysis of three research scales. Among a number of specific data included, also taken into account in direct or indirect manner of questioning were teachers' beliefs and attitudes on: the quality of teaching, their expectations, pedagogical optimism, class environment, education and various forms of teacher training, curriculum, insight into student's individuality, perception of giftedness, competence to identify disabilities such as dyscalculia, etc. Taken into account was also teacher self-assesment in the field of: social competence, professional competence, emotional competence and insight into

curricular documents and specific teaching practice with students with math learning disabilities. Related to classroom and outside of classroom activities taken into account were: student-oriented teaching activities, methods and actions of the participants in the research, involvement in mobility projects and action research, reflective aspects of teaching practice, following innovations in science, and command of ICT.

Following the descriptive analysis and assessing differences among the participants considering socio-demographic factors and professional teacher profile, the author confirms the existence of various methodological restrictions in determining potential predictive aspects of certain variables, which leads to a conclusion of correlation analysis with a number of regression analyses. This is clear from the existing redundancies in results where for a number of variables it is dificult to determine whether they indicate or even explain the potential latent constructs in specific test conclusions in descriptive and inferential methods and actions. In regression analysis models are therefore included among the primary independent variables (gender, work experience, position, initial education, further education and training) also beliefs and participant self-assessment, which are separated by factor analyses of specific scales, and are as such included into predictive variables in the process of synthesis and filtrating of the results obtained by previous analyses.

Regarding the insight into the specific needs of math students, the only significant predictor was proven to be the gender of the teacher, where female teachers showed a much higher level of self-assessment than their male colleagues. When considering professional competence, significant predictors were work experience and further education and training, where the more experienced teachers assessed their expertise on a much higher level compared to their colleagues with 5 years of work experience or less. In self-assessing social competence, two significant predictors were present, out of which a more relevant variable is workplace, whereas gender plays a less relevant role. In working with students with certain disabilities teacher's workplace has proven to be the single and fairly significant predictor, which was confirmed in previous analyses, indicating the higher level of competence self-assessment among elementary school teachers, compared to the high school ones. The same has been established for adjusting to and helping students with learning disabilities that have negative attitude towards learning math, to whom elementary school teachers dedicated a substantially more amount of time. Regarding recognizing students with dyscalculia, elementary school teachers also assess their competence to detect children having this disability much higher than those working in high schools, however more thorough analyses have proven self-assessment in recognizing dyscalculia not to be consistent in any of the groups according to workplace with

contemporary definition of dyscalculia. Teaching directed towards the student has three substantial predictors: workplace, gender and the acquired additional education.

Teacher workplace has proven to be the best predictor for student-oriented teaching, demonstrating high level of adjustment to students among elementary school teachers, compared to high school teachers. Regarding the metacognitive aspect, it has been determined that gender and further education equally contribute to the metacognitive aspect of teacher performance. Female teachers have demonstrated a higher level of student support and the accompanying regressive model has established gender as the single statistically relevant factor in this dependant variable. Professional development is also influenced by gender, showing female teachers as more prone to professional training. However, further acquired education based on this aspect of teaching has turned out to be a better predictor. Fermale teachers also more frequently evaluate their work performance by taking into account student feedback on their teaching and are more prone to expert training through mobility projects, peer evaluation and action research.

In the factor analysis of the teacher self-assessment scale it has been determined that the differences in the self-assessment of the professional competence are most prominent considering teacher work experience, where the more experienced ones consider themselves significantly more competent than the younger ones with up to five years work experience. Beliefs on student mathematical capabilities are a negative predictor, meaning that the teachers displaying a more optimistic attitude towards students and their capabilities have a slightly lower assessment of their professional competence, in connection to the group of elementary school teachers who graduated from the Faculty of Teacher Education. As the most prominent predictor of teachers' professional competence have proven to be beliefs about curriculum, showing higher level of math competence assessment among teachers who consider curriculum aspects of modern education relevant. Workplace is the best predictor for self-assessment of social competence, demonstrating the connection between elementary school workplace and teacher self-assessment in working with children with specific disabilities in learning math and the notion of student-oriented teaching in general. These analyses have shown that elementary school teachers tend to offer help to students with learning difficulties more often than high school teachers, link tasks with everyday situations, help students that have negative attitude towards learning maths. In the frequency of certain actions and practice in the metacognitive aspect of teacher performance, the greatest connection is with beliefs about teacher social skills and self-assessment of awareness of student individuality in math teaching, which are strongly connected with elements of teaching oriented towards supporting students.

Work experience is negatively connected with teaching methods related to student support, meaning that younger teachers are more inclined to emphasize the importance of persistence and work habits in learning maths and more frequently encourage attitudes towards learning among less successful students and believe and advocate in their teaching that every student can be successful at maths. Teachers with 30 years of work experience and more feel most competent in working with gifted students. Significant differences have been established among the most experienced teachers and both groups with up to 15 years work experience, showing teachers to be gradually more prone to working with gifted students with increasing work experience. Predictors of professional development and teacher training through professional meetings are attitudes and beliefs on curriculum and, to a lesser extent self-assessment of professional competence. Reflexive aspect of teacher performance is mostly determined by awareness on student individuality in math teaching, showing female teachers as more successful. Teachers that consider themselves more competent in the field of expertise more often participate in professional training through mobility projects, peer evaluation and action research. Male teachers consider themselves more competent in the field of expertise, whereas in the assessment of the methodical aspect of teaching, they consider themselves less successful than female teachers. The results show that female teachers follow guidelines from documents encompassed by National Frame Curriculum in preparation, performance and teaching evaluation significantly more frequently than male teachers.

In the final combined regression analyses the author determines the relationship between socio-demographic factors and professional profile of teachers and their attitudes, beliefs and self-assessment, including which of the factors or characteristics can serve as the best predictors of their teaching and out of classroom practice relevant to the quality of the teaching process. It has been determined that teacher beliefs correspond with their self-evaluation in the sense of efficiency in teaching practice, which affects their approach to teaching and students, highlighting workplace, gender and teaching experience as variables that shape their performance the most.

Related to socio-demographic and professional characteristics of the participants in the research, the most significant are gender differences. Indicative results related to working with gifted students and recognizing students with dyscalculia point to potential directions for development of math teacher training, as well as the need for a more detailed research. The results synthesis demonstrates the way in which performance and work experience self-assessment, taking into consideration the specifications of workplace (elementary, high school, student age etc.) affect the beliefs and teaching patterns of the participants more significantly

than Teaching Faculties programs, whose differences are primarily determined by self-assessment of the professional competence, also influenced by workplace variable as well as distinctiveness of working with younger schoolchildren.

The fifth part *Final deliberations and comments on the results of the research* serves to verify the research hypothesis and review the theoretical outline of literature and the accompanying research results. The author emphasizes the need for a research into math education from an aspect of math as pedagogical science, especially in the context of more specific areas of math teaching, whose problems dominantly fall into the category of pedagogical research. The author thereby claims that the initial education of teachers would be more efficient in terms of teaching practice if more oriented towards learning and teaching process, academic achievements and students' educational prospects. He concludes with the need for a change in acquiring teaching competence in the context of considering the structure and amount of expert, pedagogical and didactic and methodical contents in teacher training, which implies a necessary correlation and assessment of challenges from the teaching practice and the domain of research in didactics and methodics of math teaching.

SADRŽAJ

1. UVOD 1

2. TEORIJSKI DIO 13

2.1 Kompetencijski pristup obrazovanju 13

2.1.1. Matematička kompetencija u suvremenom odgoju i obrazovanju 17

2.2. Didaktički i kurikularni pristup matematičkom obrazovanju 27

2.2.1. Nastava i didaktičke teorije 27

2.2.1.1 Didaktika i metodika nastave matematike 36

2.2.2. Odgojno-obrazovni standardi nastave matematike 39

2.2.2.1. Ciljevi i sadržaji nastave matematike 46

2.2.3. Struktura i organizacija nastave matematike 52

2.2.3.1 Strukturni model metodičkog djelovanja i odnosi učenika u nastavi 56

2.2.4. Didaktička načela nastave matematike 60

2.2.5. Metode u nastavi matematike 64

2.2.6. Didaktički sustavi u nastave matematike 75

2.2.6.1 Problemska nastava 78

2.2.7. Vrednovanje u nastavi matematike 82

2.3. Učenici s posebnim potrebama u nastavi matematike 85

2.3.1. Učenici s teškoćama u nastavi matematike 87

2.3.2 Učenici s diskalkulijom 88

2.3.2.1 Pojavnost i detekcija diskalkulije 90

2.3.2.2 Komorbiditet diskalkulije 93

2.3.2.3 Diskalkulija u praksi 94

2.3.3. Matematički daroviti učenici 96

2.3.3.1 Identifikacija darovitih učenika 99

2.3.3.2 Rad s darovitim učenicima i pozicioniranje konstrukta darovitosti u nastavnom procesu 102

2.4. Socijalne i afektivne dimenzije matematičkog obrazovanja 110

2.4.1 Emocionalne reakcije učenika u nastavi matematike 112

2.4.1.1 Strah od matematike i matematička anksioznost 115

2.4.1.2 Odnosi među učenicima i percepcija akademske samoefikasnosti 119

2.5. Kompetencije nastavnika 121

2.5.1 Kompetencije nastavnika matematike 129
2.5.1.1 Uvjerenja nastavnika matematike 132
2.5.1.2 Samoefikasnost nastavnika matematike 136
3. METODOLOGIJA ISTRAŽIVANJA 139
3.1 Polazne vrijednosti i problem istraživanja 140
3.2 Kontekst i sudionici istraživanja 142
3.3 Konceptualni okvir istraživanja 144
3.3.1 Ciljevi istraživanja 145
3.3.2 Hipoteze istraživanja 146
3.3.3 Varijable istraživanja 149
3.3.4 Obrada podataka i etape istraživanja 150
4. REZULTATI ISTRAŽIVANJA 152
4.1 Uzorak ispitanika i osnovna sociodemografska obilježja 152
4.2 Deskriptivna analiza 158
4.2.1. Deskriptivna analiza ljestvice uvjerenja i stavova nastavnika 158
4.2.1.1 Razlike s obzirom na spol 166
4.2.1.2 Razlike s obzirom na inicijalno obrazovanje 171
4.2.1.3 Razlike s obzirom na radni staž 179
4.2.1.4 Razlike s obzirom na stečenu dodatnu naobrazbu 186
4.2.1.5 Razlike s obzirom na radno mjesto 186
4.2.1.6 Deskriptivni pokazatelji nastavničkih uvjerenja i stavova o stereotipima karakterističnim za nastavu matematike 191
4.2.1.6.1 Percepcija problema nadarenosti i obrazovanosti 191
4.2.1.6.2 Osposobljenost i samoprocjena nastavnika za prepoznavanje diskalkulije 194
4.2.1.6.3 Uvjerenja o radnim navikama i motivaciji darovitih učenika 197
4.2.1.6.4 Percepcija rodnih stereotipa 199
4.2.2 Deskriptivna analiza ljestvice percipirane kompetentnosti i samoefikasnosti 200
4.2.2.1 Razlike u percipiranoj kompetentnosti i samoefikasnosti s obzirom na spol 202
4.2.2.2 Razlike u percipiranoj kompetentnosti i samoefikasnosti s obzirom na inicijalno obrazovanje 206
4.2.2.3 Razlike u percipiranoj kompetentnosti i samoefikasnosti s obzirom na radni staž 208
4.2.2.4 Razlike u percipiranoj kompetentnosti i samoefikasnosti s obzirom na stečenu dodatnu naobrazbu 210
4.2.2.5 Razlike u percipiranoj kompetentnosti i samoefikasnosti s obzirom na radno mjesto 216

4.2.3 Deskriptivna analiza ljestvice učestalosti nastavnih i izvannastavnih praksi 219
4.2.3.2 Razlike s obzirom na inicijalno obrazovanje 225
4.2.3.3 Razlike s obzirom na radni staž 227
4.2.3.4 Razlike s obzirom na stečenu dodatnu naobrazbu 229
4.2.3.5 Razlike s obzirom na radno mjesto 233
4.3 Faktorska analiza istraživačkog instrumenta 236
4.3.1 Faktorska analiza ljestvice uvjerenja nastavnika 238
4.3.1.1 Razlike u uvjerenjima nastavnika s obzirom na spol 243
4.3.1.2 Razlike u uvjerenjima i stavovima nastavnika s obzirom na inicijalno obrazovanje ... 244
4.3.1.3 Razlike u uvjerenjima i stavovima nastavnika s obzirom na radni staž 245
4.3.1.4 Razlike u uvjerenjima i stavovima nastavnika s obzirom na stečenu dodatnu naobrazbu 246
4.3.1.5 Razlike u uvjerenjima nastavnika s obzirom na radno mjesto 247
4.3.2 Faktorska analiza ljestvice percipirane kompetentnosti i samoefikasnosti 247
4.3.2.1 Razlike u percipiranoj kompetentnosti i samoefikasnosti nastavnika s obzirom na spol 252
4.3.2.2 Razlike u percipiranoj kompetentnosti i samoefikasnosti nastavnika s obzirom na inicijalno obrazovanje 253
4.3.2.3 Razlike u percipiranoj kompetentnosti i samoefikasnosti nastavnika s obzirom na radni staž 254
4.3.2.4 Razlike u percipiranoj kompetentnosti i samoefikasnosti nastavnika s obzirom na stečenu dodatnu naobrazbu 255
4.3.2.5 Razlike u percipiranoj kompetentnosti i samoefikasnosti nastavnika s obzirom na radno mjesto 256
4.3.3 Faktorska analiza ljestvice učestalosti nastavnih i izvannastavnih praksi 257
4.3.3.1 Razlike u učestalosti nastavnih i izvannastavnih praksi s obzirom na spol 262
4.3.3.2 Razlike u učestalosti nastavnih i izvannastavnih praksi s obzirom na inicijalno obrazovanje 263
4.3.3.3 Razlike u učestalosti nastavnih i izvannastavnih praksi s obzirom na radni staž 264
4.3.3.4 Razlike u učestalosti nastavnih i izvannastavnih praksi s obzirom na stečenu dodatnu naobrazbu 265
4.3.3.5 Razlike u učestalosti nastavnih i izvannastavnih praksi s obzirom na radno mjesto .. 266
4.4 Korelacijska analiza istraživačkog instrumenta 267
4.4.1 Korelacije između faktorskih struktura 270
4.4.1.1 Povezanost stavova i uvjerenja nastavnika s percepcijom kompetentnosti i samoefikasnosti 270

4.4.1.2 Povezanost stavova i uvjerenja nastavnika s učestalošću nastavnih i izvannastavnih praksi ... 272

4.4.1.3 Povezanost percepcije kompetentnosti i samoefikasnosti s učestalošću nastavnih i izvannastavnih praksi ... 274

4.4.2 Regresijska analiza ... 275

4.4.2.1 Regresijska analiza sociodemografskih obilježja i profesionalnog profila nastavnika kao prediktorima stavova i uvjerenja nastavnika kao zavisnom varijablom ... 278

4.4.2.2 Regresijska analiza sociodemografskih obilježja i profesionalnog profila nastavnika kao prediktorima samoprocjena nastavnika kao zavisnom varijablom ... 280

4.4.2.3 Regresijska analiza sociodemografskih obilježja i profesionalnog profila nastavnika kao prediktora učestalosti nastavnih i izvannastavnih aktivnosti nastavnika kao zavisnom varijablom ... 283

4.4.2.4 Kombinirane regresijske analize sociodemografskih obilježja i profesionalnog profila nastavnika s dominantnim uvjerenjima kao prediktorskim varijablama ... 285

4.4.2.5 Kombinirane regresijske analize sociodemografskih obilježja i profesionalnog profila nastavnika s dominantnim uvjerenjima i samoprocjenama kao prediktorskim varijablama odgojno-obrazovnih dimenzija rada nastavnika ... 290

5. ZAVRŠNA RAZMATRANJA I OSVRT NA REZULTATE ISTRAŽIVANJA ... 295

5.1 Verifikacija istraživačkih hipoteza ... 295

5.2 Sinteza rezultata i zaključci provedenog istraživanja ... 309

6. LITERATURA ... 314

7. POPIS TABLICA ... 334

8. PRILOZI ... 340

9. ŽIVOTOPIS ... 346

1. UVOD

Nastava matematike i cjelokupno matematičko obrazovanje poprište je mnogih rasprava i diskusija odgojno-obrazovnih stručnjaka svih profila, ali i svakog pojedinca koji je kroz vlastita iskustva na jedinstven način doživio matematiku. Naime, matematika kao znanstvena disciplina i nastavni predmet sadrži brojne posebnosti te je zbog toga na uvijek istaknutom mjestu među odgojno-obrazovnim temama. Malo tko je prošao kroz školske klupe, a da nema određena iskustva i sjećanja vezana uz nastavu i/ili nastavnika/učitelja matematike. Matematika je mnogim učenicima najteži predmet, zbog čega i značajan broj učenika s vremenom razvije negativne emocije i uvjerenja prema istoj. Naime, iskustva učenika u nastavi matematike ozbiljno se odražavaju na njihovo opće samopouzdanje i percepciju samoefikasnosti. U praksi se to očituje kroz njihova negativna uvjerenja prema sebi i vlastitim sposobnostima što u međudjelovanju s različitim nepovoljnim čimbenicima iz obiteljske i odgojno-obrazovne okoline često dovodi do potpune nesposobnosti u svladavanju matematičkih sadržaja ili pak do uvjerenja o istom. Ta uvjerenja imaju temeljno polazište u percepciji matematike kao teškom predmetu koji ne može svatko svladati. Matematika i nastavnici matematike zato se često spominju i percipiraju u negativnom kontekstu ili pak s određenim strahopoštovanjem. Pored ostalih čimbenika, nastala situacija uvjetovana je i percepcijom nastave matematike kroz prizmu struke koja se smatra zahtjevnom zbog tradicijom zastupljenih problema nastave matematike, a to je, među ostalim, uvjetovano i povlaštenim položajem matematike prema ostalim znanostima kroz povijest i danas.

Matematika se razvila iz potrebe za mjerenjem, računanjem te proučavanjem oblika i objekata iz svakodnevice, a navedeno argumentira analitičkim pristupom i logičkim zaključivanjem. Suvremena matematika afirmirala se u znanstvenu disciplinu koja proučava koncepte količine, strukture, prostora i promjene. Iz navedenih koncepata razvile su se i različite matematičke discipline. Tako se iz koncepta *količine* primarno razvila aritmetika, počevši od prirodnih brojeva, koji su temelj osnovnoškolske matematike, pa do teorije grafova, kombinatorike i dokaza posljednjeg Fermatova teorema kao jednog od najkompleksnijih postignuća suvremene matematike.

Pod konceptom „struktura“ razvila se apstraktna algebra u kojoj se pručavaju grupe, prsteni, vektorski prostori i druge apstraktne strukture koje na svojevrstan način prožimaju ostala područja i matematičke discipline. Koncept „prostor“ odnosi se na geometriju koja se svojim razvojem raščlanila na euklidsku geometriju i neeuklidske geometrije, trigonometriju, analitičku geometriju, diferencijalnu geometriju, algebarsku geometriju, topologiju itd. Na

kraju, koncept „promjena“ odnosi se na područje matematičke analize čiji su začetnici Newton i Leibnitz koji su krajem 17. stoljeća, neovisno jedan o drugome, otkrili diferencijalni i integralni račun jedne i više varijabli što je rezultiralo ubrzanim razvojem matematike i velikom ekspanzijom, primjenom, ali i sintezom dotadašnjih matematičkih spoznaja iz čega su se razvile još mnoge poddiscipline poput diferencijalnih jednadžbi, dinamičkih sustava, teorije kaosa itd. Pored navedenih koncepata i disciplina, ima još nekoliko značajnih područja matematike koja imaju iznimne primjene u suvremenom svijetu: diskretna matematika kao matematika najzastupljenija u digitalnim tehnologijama čije su poddiscipline kombinatorika, teorija izračunljivosti, teorija grafova, kriptografija itd.; osnove matematike i filozofija unutar kojih se razvila matematička logika i teorija skupova; primijenjena matematika kao matematička fizika, mehanika fluida, optimizacija, numerička analiza, teorija vjerojatnosti, statistika, financijska matematika, teorija igara itd.

Matematika se stoga u najopćenitijem obliku određuje kao znanost o obrascima (Devlin, 2008). Pod obrascem se pritom smatraju pravilnosti ili uzorci u najopćenitijem obliku, a iste nalazimo u brojevima, prostoru, prirodi, računalima, imaginarnim apstrakcijama, kao i u svim objektima čija svojstva možemo na neki način kvantificirati i/ili analizirati prema nekim logičkim principima. Matematika se stoga može percipirati kao skup alata za analiziranje i opisivanje obrazaca, rješavanje problema oslanjajući se na činjenicu kako se različiti strukturalni koncepti i procesi iz različitih područja ljudske djelatnosti mogu istraživati proučavajući njihova zajednička svojstva u različitim situacijama koje se svojim specifičnostima mogu svesti na matematiku kao temeljni jezik prirodnih znanosti. Tako da korištenje matematičkih znanja, koncepata, principa i teorija podrazumijeva manipuliranje informacijama, stvaranje pretpostavki, predviđanje situacija i ishoda, rješavanje postavljenih problema, izvođenje analogija i apstrakcija te niza logikom utemeljenih misaonih operacija vodeći se induktivnim i deduktivnim zaključivanjem.

Zbog toga korpus znanja matematike i matematički način razmišljanja ima primjene u: prirodnim znanostima, tehničkim znanostima, medicini, tehnologiji, ekonomiji te društvenim, humanističkim znanostima itd. Područje, odnosno predmet proučavanja i poučavanja matematike iznimnog je opsega koji se ubrzano širi prelaskom na više stepenice obrazovanja te je stoga važno razumjeti polazišta i koncepte koji su u središtu matematike kao znanosti te samim time obrazovne vrijednosti koje učenici stječu učenjem matematike. Iako se vode istim principima i načelima, Romano (2013) tvrdi kako treba razlikovati školsku matematiku od znanstvene zato što su zbog socijalnog konteksta te dvije domene utemeljene na znanjima koja su epistemološki različita. Fey (2006) ističe kako se u pristupu kreiranja kurikuluma nastave

matematike uvijek propituje u kojoj bi mjeri školska matematika trebala odražavati znanstvenu matematiku, a koliko bi trebala slijediti različite načine na koje se matematika koristi i primjenjuje u svakodnevnom životu, različitim djelatnostima i profesijama. Posljednjih desetljeća elektronički kalkulatori i računala postali su standardni alat u učenju matematike što je dovelo do toga da mali broj ljudi računa aritmetičke zadatke na tradicionalan način, a to je rezultiralo značajnim promjenama u načinu poučavanja mnogih sadržaja (npr. eksponencijalna i logaritamska funkcija, trigonometrija i sl.). Fey stoga (2006) navodi kako se pri izboru sadržaja trebaju razmatrati kontekst suvremenoga društva i promjenjivosti zanimanja budućnosti te načini na koje će učenici primjenjivati stečeno znanje. Epistemološki status znanja školske matematike ne smije se u potpunosti izvoditi iz znanstvenog znanja, već treba biti povezan s društvenim kontekstom nastave i procesom učenja (Romano, 2013) te sa širim trendovima u društvu, obrazovanju, znanosti i tehnologiji.

Na neki se način to pokazuje kao dodatni izazov nastave matematike koja na određeni način treba dokazati društvu kako ima mnoštvo primjena u svakodnevnom životu i brojnim područjima ljudske djelatnosti. Društvo pritom ima predrasude i specifične stereotipe spram matematike što, među ostalim, potvrđuju i brojna međunarodna istraživanja poput PISA projekta i TIMSS istraživanja koja pokazuju kako je uspješnost učenika u nastavi matematike pored mnogih drugih čimbenika i kulturno uvjetovana. U drugoj polovici dvadesetog stoljeća sve se više istraživača počelo baviti razlikama u uspjehu učenja matematike koje učenici Sjedinjenih Američkih Država postižu u odnosu na učenike iz Japana, Kine, Tajvana, Koreje i Singapura. Naime, već prvi dostupni podatci o usporedbama rezultata učenika navedenih zemalja upućuju na značajno bolje uspjehe učenika azijskih zemalja (Hess i sur., 1987; Stevenson i sur., 1990). Isto potvrđuju i recentna međunarodna istraživanja TIMSS i PISA prema kojima samo neke europske zemlje uspijevaju držati korak s Kinom, Singapurom, Korejom i Tajvanom. S obzirom na to da su te razlike značajne već od prvog razreda osnovne škole (Geary i sur., 1993), pokazuje se kako kulturni i obiteljski čimbenici daju značajan doprinos razlikama u postignućima (Huntsinger i sur., 1997). To ukazuje kako se u teorijskim i praktičnim razmatranjima mora ozbiljnije pristupiti društvenim i kulturološkim dimenzijama matematičkog obrazovanja i njihovim implikacijama u nastavi matematike. Opće poznato je kako je u Kini, Japanu, Tajvanu i Singapuru tradicionalno prisutna predanost marljivu radu i upornosti, a na obrazovanje se gleda kao na put prema zaposlenju i boljem statusu u društvu. Predanost i upornost glavna su obilježja radne etike koja se smatra ključnim čimbenikom uspjeha (Chang, 1985) te se potpomaže snažno vidljivoj vezi obrazovanja i karijere. Jedan od

razloga visoko je postignuće razine učenja japanskih učenika njihova snažna predanost marljivu radu i perfekcionizmu što prihvaćaju učenici i njihove obitelji (Devide, 2000).

U izvješću OECD-a o rezultatima PISA istraživanja s povijesnog i socijalnog stajališta ističu se tri bitna momenta koji značajno utječu na obrazovanje u spomenutim zemljama Dalekog istoka (OECD, 2010):

- prijamni ispiti za upis u srednju školu i fakultet smatraju se „ulaznicom“ u viši sloj društva
- u društvu vlada uvjerenje kako uspjeh na tim ispitima više ovisi o količini uloženog truda nego o inteligenciji
- uspjeh na prijamnim i selekcijskim ispitima nije odraz samog učenika i nastavnika, već je refleksija roditelja i drugih članova obitelji (na taj se način dijeli odgovornost za neuspjeh, ali se i povećava pritisak što boljem uspjehu).

Gore navedeni rezultati istraživanja upravo zbog kulturološke različitosti nemaju značenje i svojevrsnu primjenu u našim kurikularnim reformama i/ili odgojno-obrazovnim diskusijama. No, osvijestimo li kako su sve gore istaknute razlike one u uvjerenjima društva, obitelji i svih aktera odgojno-obrazovnog sustava, pitanje je možemo li, i kako, promijeniti svekolika uvjerenja i stavove našeg društva, obitelji i djece. Također, pri usporedbi rezultata međunarodnih istraživanja obrazovanja potrebno je promotriti tendenciju smanjivanja satnice nastave matematike u Republici Hrvatskoj u nastavnim planovima (Matijević i Rajić, 2015) te dinamiku istih uzduž osnovnoškolskog i srednjoškolskog obrazovanja. Pored različitih kurikularnih i kulturoloških aspekata, nastava matematike, kroz ne tako davnu povijest, obilježena je rodnim stereotipima gdje je dugo vremena vladalo uvriježeno mišljenje kako su dječaci predodređeni za uspjeh u matematici i prirodnim znanostima, a djevojčice u društvenim znanostima. Za matematička i znanstvena usmjerenja nekad se odlučivao značajno manji broj žena od muškaraca. Benbow i Stanley (1980), temeljem svojih istraživanja, zaključili su kako je matematička sposobnost (koju razlikuju od uspjeha u matematici) više vezana uz dječake te kako mora postojati i biološka osnova za takve spolne razlike. Kasnija istraživanja nisu potvrdila navedena stajališta, a razlike u matematičkom dostignuću između muških i ženskih osoba danas se više pripisuju uvjerenju u vlastite sposobnosti i atribucijama (ne)uspjeha u matematici nego biološkim razlikama, tj. razlikama u sposobnostima (npr. Wigfield i sur., 1997; Sigel i Lisi, 2002). Premda recentna istraživanja to nisu potvrdila, i dalje vlada uvjerenje kako je matematika teža djevojkama nego dječacima (Smith i White, 2002). Arambašić i suradnici (2005) utvrdili su razlike vezane uz spol učenika gdje se pozitivniji stav prema nastavi

matematike pokazao kod učenika, a kod učenica je vidljivi strah prema matematici. Unatoč tome, iz različitih izvora očigledno je kako danas na matematičkim odjelima prirodoslovno-matematičkih fakulteta i ostalih studija na kojima se obrazuju budući nastavnici matematike u Republici Hrvatskoj studira 60 % i više žena, a omjer i dalje raste u korist žena (Godišnje izvješće PMF-a, 2018; Statističko izvješće o visokom obrazovanju, 2017, 2018; Statistički ljetopis, 2018). Konkretnije, prema statističkom izvješću o visokom obrazovanju (2017, 2018) na odjelu za matematiku Sveučilišta u Splitu, 2016. i 2017. godine matematiku upisuje oko 70 % studentica što se gotovo identično pokazalo na istom odjelu u Rijeci. Prema istom izvoru na matematičkom odjelu Prirodoslovno-matematičkog fakulteta u Zagrebu studira 66 % studentica, a na istom odjelu Prirodoslovno-matematičkog fakulteta u Splitu studira 70 % studentica (Statističko izvješće o visokom obrazovanju, 2018). Unatoč većoj dominaciji ženskog spola na nastavničkim studijima, pokazuje se kako je na preddiplomskom studiju matematike u akademskoj godini 2016./2017. studiralo 74 % studentica na nastavničkom studiju te 58 % studentica na inženjerskom smjeru Odjela za matematiku što ukupno daje 65 % studentica na preddiplomskom studiju matematike (Godišnje izvješće PMF-a, 2018). Što se tiče istraživanja kojima su se ispitivale razlike po spolu u razini matematičke anksioznosti i vezi s postignućima u matematici, većina studija utvrdila je kako nema značajnih razlika među spolovima (Fennema i Sherman, 1977; Fox, 1977; Richardson i Suinn, 1972; Resnick, Viehe i Segal, 1982; Tocci i Engelhard, 1991). Sintezom navedenoga može se pretpostaviti kako su razlike među spolovima dijelom uvjetovane i kulturološkim okruženjem te da razlike u matematičkom znanju ovise o društvenim čimbenicima poput rodne jednakosti i društvenog položaja žena. S druge strane, stereotipi vezani uz matematiku, prirodne i tehničke znanosti dio su duge „tradicije“ u kojoj žene nisu bile u ravnopravnom odnosu u obrazovanju, a naročito u znanosti. Stoga se treba razmatrati utjecaj socijalizacije spolnih uloga i očekivanih zahtjeva što ih zanimanje i spolna uloga postavljaju pred pojedinca. Matematika se tradicionalno prikazivala kao muško područje što ima za posljedicu očekivanje uspjeha i razvoj za to karakterističnih stavova i uvjerenja o matematici.

Naposljetku, neovisno o razmatranju razlika u sposobnostima i kapacitetima između učenika i učenica koje se nisu pokazale utemeljenima, za nastavu je matematike svrsishodnije razmišljati zašto postoje i koje su razlike u postignućima između učenika i učenica u matematici. Uzmemo li pritom u obzir kako učenici na početku školovanja imaju pozitivne ili neutralne stavove i emocije prema matematici, a s godinama školovanja oni postaju sve negativniji (McLeod i Ortega, 1993), moramo preispitati prioritete u nastavi matematike i kurikulumu matematičkog područja, a naročito u kontekstu kompetencija koje želimo da

nastavnici matematike posjeduju. Uvažavajući niz specifičnosti matematičkog obrazovanja uzduž predtercijarnog sustava odgoja i obrazovanja, uslijed kojih mnogi učenici na određeni način odustaju od matematike i srodnih predmeta i struka iz spektra prirodnih i tehničkih znanosti, nužno je promisliti o tome koliko recentni kurikulumi nastave matematike mogu ponuditi „prosječnom“ učeniku ukoliko su mu uskraćene obrazovne perspektive i aspiracije prije negoli se suoče s matematikom, njenim sadržajima i konceptima u nešto širem opsegu od onog osnovnoškolskog koji se isključivo vezuje uz aritmetiku i uže područje početne matematike koja na svojevrstan način diskriminira svakoga koji ne može brzo računati.

Mnogi istraživači tvrde kako većina učenika nikada ni nije „upoznala“ matematiku i vlastite mogućnosti unutar iste (npr. Devlin, 2000) zato što pored društvenih i afektivnih dimenzija nastave, kao što su primjerice interes, motivacija, emocije i samopouzdanje učenika, nastava matematike u vidu često isticanih kognitivnih kapaciteta iziskuje raznovrsne sposobnosti i vještine koje će kod nekih učenika možda tek u srednjoj školi iznjedriti neke neslućene potencijale. Razmotrimo li pritom socioekonomske uvjete te individualnost učenika u kontekstu njihova emocionalnog i kognitivnog razvoja, može se reći kako je površno očekivati i/ili čak predviđati koliko će pojedinac biti uspješan u matematici usko svodeći njegove ocjene na kognitivne sposobnosti što je od svih školskih predmeta vjerojatno najzastupljenije u kontekstu učenja matematike.

Međutim, „klasična“ nastava kroz ocjenjivanje i evaluaciju učenika, najčešće neovisno o nastavniku, indirektno unutar razrednog odjela nosi i tu prediktivnu komponentu koja se reflektira na učenika dominantno u njegovom obiteljskom i školskom okruženju pa se stoga kao veliki izazov nastave matematike nameće pitanje pedagoškog savjetovanja i profesionalne orijentacije koja u školskoj praksi egzistira uglavnom na deklarativnoj razini. Izuzetak su entuzijastični nastavnici koji posjeduju istinski pedagoški takt i percipiraju više od samih ocjena i trenutnog stanja učenika zato što vide, otkrivaju i/ili potiču posebnost i perspektivu svojih učenika. Tu se, pored ostalih, posebno ističu učenici koji posjeduju nesrazmjer u intelektualnim sposobnostima što se najčešće očituje u slabijim aritmetičkim vještinama i prosječnim ili iznadprosječnim općim intelektualnim sposobnostima. U toj su kategoriji i učenici koji imaju diskalkuliju, ali i oni koje suvremenim testovima ne bismo svrstali u kategoriju istih te imaju potencijal za matematiku koja se bavi složenim konceptima i strukturama za koje nije bitno koliko brzo i vješto računaju. Kod mnogih učenika početni se neuspjesi u razumijevanju matematičkih pojmova pokazuju kao snažan prediktor daljnjih uspjeha što se po redoslijedu sadržaja osnovne škole primarno odnosi na vještinu računanja. S druge strane, učenici solidnog i/ili iznadprosječnog znanja matematike i ostalih predmeta iz STEM područja često ne žele

upisivati fakultete kojima su navedena predmetna područja dominantna u nastavnom planu i programu. To se nerijetko događa i u elitnim gimnazijama gdje se zbog nekolicine izuzetno darovitih učenika ostali ne osjećaju kompetentni za studij STEM područja unutar kojih dotični učenici tradicionalno dominiraju na natjecanjima, ali i u nastavi (više u poglavlju 2.4.1.2). Očito je kako se unatoč brojnim spoznajama iz pedagogije i psihologije relevantnim po pitanju stereotipa u nastavi matematike navedeno pokazuje kao sveprisutni izazov u praksi. Izazovi nastave matematike, kao i specifičnosti matematičkog područja, globalni su fenomen prisutan po cijelom svijetu te se prema tome mogu uspoređivati različiti načini kako se obrazovni sustavi diljem svijeta nose s time. To se primarno uspoređuje kroz rezultate međunarodnih istraživanja (npr. TIMSS i PISA). Prema rezultatima PISA istraživanja naši su petnaestogodišnjaci znatno ispod prosjeka zemalja OECD-a (na 40. mjestu od 64 zemalja) gdje njih 30 % nije steklo osnovna znanja matematike (OECD, 2013), a isto se potvrđuje i u ostalim ciklusima dotičnog istraživanja (OECD, 2017). Rezultati državne mature također ukazuju na nedovoljno razvijene matematičke kompetencije naših učenika te kako značajan broj učenika ne razumije osnovne koncepte matematike. Te rezultate najčešće pripisujemo nastavnicima i učiteljima, odnosno kvaliteti nastavnog procesa. U suvremenom društvu brzorastućih i promjenjivih trendova ne smije se podcijeniti činjenica razvoja i procesa socijalizacije mladih unutar društvenih i institucionalnih uvjeta, kao ni mnogostrukost čimbenika i pretpostavki u sustavu odgoja i obrazovanja zbog čega se uspjeh u matematici mora razmatrati sa šireg socijalnog i kulturnog konteksta. Kvalitetna nastava svakako je temeljna pretpostavka realizacije zadanih obrazovnih ishoda, ali nije jedini ni nužno presudni čimbenik općeg školskog uspjeha (pa tako i uspjeha u matematici).

Očito je kako zahtjevi suvremene škole upućuju na nužne promjene uloga i zadaća nastavnika (Previšić, 2003) što se u slučaju nastavnika matematike pokazuje imperativom za pronalazak nekih novih metoda i pristupa učenju i poučavanju. Brojna istraživanja matematičkog obrazovanja i relevantna istraživanja odgoja i obrazovanja upućuju na porast teorijskih spoznaja o kvalitetnom poučavanju matematike i problematičnim područjima nastave matematike. Uz to, nastavnička usmjerenja na prirodoslovno-matematičkim fakultetima imaju sve zastupljenije kolegije iz pedagoško-psiholoških i didaktičko-metodičkih područja te im je dostupno više znanja o nastavi i učenicima. Također, unatoč rastućem broju istraživanja u području matematičkog obrazovanja aktualne su mnoge teorije o učenju i poučavanju matematike, ali se zbog različitog epistemološkog viđenja matematičkog znanja razvijaju različite teorije matematičkog obrazovanja (Milovanović, Romano i Todić, 2012). Pored toga, specifičnosti strukovnih didaktika i njihove klasifikacije u korpusu znanja pedagogije nisu

razrađene u obrazovnim sustavima s puno naprednijim istraživačima nastave (Lenzen, 2002), no u kontekstu našeg obrazovnog sustava ključno je pitanje imamo li uopće dostatan broj istraživača-didaktičara koji bi unaprijedili sustav obrazovanja nastavnika i pratili korak s recentnim međunarodnim istraživanjima, kao i unapređenjem kvalitete nastave matematike.

Većina recentnih istraživanja matematičkog obrazovanja usmjerena je na socijalne i afektivne dimenzije nastave zbog čega su sve češće u istraživačkom fokusu stavovi i emocije učenika u nastavi. Među recentnim razmatranjima u pedagogiji, upravo se afektivna strana odgojno-obrazovnog procesa pokazuje kao jedna od najaktualnijih tema (Kolak i Majcen, 2011). Učenici se svakodnevno susreću s mnogim izazovnim i stresnim situacijama u školi i izvan nje, što je naročito istaknuto u nastavi matematike.

Većina istraživača suglasna je kako su za uspjeh u matematici značajni njihovi stavovi prema matematici, razina samopouzdanja u učenju matematike i radne navike (npr. Sherman i Christian, 1999; Vizek-Vidović i sur., 1996). No, s druge strane, nastavi matematike i matematici općenito pristupa se kao znanstvenoj disciplini u kojoj su stručne kompetencije nastavnika i (urođene) sposobnosti učenika najvažnije za realizaciju zadanih ciljeva (Horvat, 2015). Zbog prisutnih nesuglasja oko preduvjeta razvoja matematičkih vještina svaki se uspjeh u matematici često stavlja u istu rečenicu s pojmom darovitost, a nedovoljno se pridaje značaj postupnoj izgradnji matematičkih znanja i vještina te društvenom kontekstu unutar kojeg se sve odvija. U nastavi matematike zato je uvijek aktualan i značajno zastupljen središnji pedagoški problem - *problem nadarenosti i obrazovanosti* (Giesecke, 1993).

Brojne specifičnosti nastave matematike i matematičkog obrazovanja impliciraju na podzastupljenost uloge društvenih dimenzija nastave matematike te okolinskih čimbenika društva i škole na kvalitetu učenja i poučavanja matematike. To je razvidno iz izazova s kojima se nastavnici matematike susreću u sferi didaktičkih i pedagoških dimenzija nastave koji kod učenika imaju značajne implikacije na odgojne i općeobrazovne vrijednosti njihova (daljnja) školovanja. Područje matematičkog obrazovanja stoga se sve više promatra kao svojevrsni društveni konstrukt umjesto tradicionalnog određenja (nastave) matematike kao isključivo znanstvene discipline. Međutim, nedostaje istraživanja, teorija, akcijskih i preventivnih programa te općih didaktičko-metodičkih smjernica za poboljšanje kvalitete nastave. U skladu s time, prirodno je pitati se koje kompetencije trebaju posjedovati nastavnici matematike te trebaju li, zbog zastupljenosti pedagogijskog problematiziranja, biti pedagoški kompetentniji.

Većina istraživača suglasna je kako za kvalitetno poučavanje nije dovoljno posjedovati duboko, konceptualno razumijevanje i poznavanje matematike, već se isto smatra nužnim, ali ne i dostatnim za suočavanje s različitim didaktičkim izazovima nastave matematike. To je i

zadnjih desetljeća iniciralo znatan broj istraživanja koja su uglavnom ukazala na potrebu za raznovrsnim kompetencijama koje bismo mogli svrstati u kategoriju pedagoških kompetencija. S ciljem sustavnog pristupa kompetencijama nastavnika, potrebno je odrediti sveukupnost čimbenika koji određuju i utječu na nastavu matematike uvažavajući svekolike aspekte utjecaja društva, odgoja i obrazovanja na razvoj matematičkih kompetencija učenika. Naime, tek poznavanjem cjelokupne razvojne crte matematičkog obrazovanja možemo konstruktivno rezonirati, misliti i zaključivati o bilo kojim problemima tog područja, pa tako i o kompetencijama nastavnika.

Stoga se kompetencije nastavnika matematike moraju sagledavati u okviru šireg društvenog i obrazovno-političkog konteksta unutar kojeg promatramo i cjelokupno matematičko obrazovanje, a primarni dio mora biti usmjeren na učenike i svekolike čimbenike koji određuju, odnosno utječu na razvoj njihovih vještina i sposobnosti te vrijednosti koje pritom stječu. Tu je, među ostalim, potrebno razmatrati status matematike u društvu i znanosti te kakav je odnos između matematike i društva. Uz to, bitno je odrediti nastavničku percepciju njihovog položaja i uloge koju imaju u odgoju i obrazovanju te društvu u cijelosti.

Prema smjernicama suvremene pedagogije, kompetentan nastavnik treba uvažavati individualnost djeteta, njegove potrebe i njegovo socijalno biće čime se polazi od škole kao društvenog bića (Previšić, 1999). To upućuje na potrebu istraživanja kompetencija nastavnika u kontekstu suvremene škole koja polazi od učenika i njegovih posebnosti s naglaskom na izazove u nastavi matematike. Kompetencije nastavnika pritom se određuju u okviru pojedinog predmetnog područja pa stoga one trebaju biti adekvatne zahtjevima i posebnostima dotičnog predmeta. Tražeći nove praktične i teorijske spoznaje o odgojno-obrazovnom procesu u okvirima nastave matematike, težimo prema razumijevanju istih i pronalaženju optimalnih rješenja unutar zadanih okvira. U nastojanjima da nastavni plan i program svlada većina učenika, nužno je didaktički pristupiti predmetnom kurikulumu, a ne samo određenju idealnog kompetencijskog profila nastavnika. Naime, ako se zadani ciljevi ne mogu realizirati kroz aktualne nastavne planove i programe, tada se mora analizirati usklađenost obrazovnih standarda s nastavnim planom i programom te s odgovarajućim osposobljavanjem nastavnika. Također, treba proučiti suvremene didaktičke pristupe u nastavi općenito te ih na praktičnoj razini utemeljiti u kontekstu nastave matematike kako bismo mogli odrediti koje vještine i znanja nastavnici trebaju posjedovati.

Uz to, problemi s kojima se susreće nastava matematike dio su šire problematike suvremenog društva s kojima se suočavaju odgojno-obrazovni sustavi diljem svijeta. Naime, suvremena pedagogijska znanost mora se kontinuirano prilagođavati tendencijama u društveno-

kulturnim, gospodarsko-ekonomskim i obrazovno-političkim trendovima i tradicijama kako bi ispunila ciljeve za koje se (trenutno) smatra da ih treba realizirati. Tako je i poučavanje matematike pod utjecajem kulturnih, društvenih i političkih okruženja unutar kojih se realizira nastava matematike (English i Sriraman, 2005). Premda je matematika oduvijek na vrhu hijerarhije među znanostima te se nalazi među temeljnim kompetencijama za cjeloživotno obrazovanje, ista se kao nastavni predmet i znanstvena disciplina suočava sa svojevrsnim nerazumijevanjem njezine funkcije u društvu, znanosti i obrazovanju, s njezinim određenjem i svrhom, kao i pitanjem primjenjivosti u svakodnevnom životu. Navedeno nastavnik mora artikulirati kroz svoj odgojno-obrazovni rad za što je nužno njegovo razumijevanje uloge i općih vrijednosti obrazovanja, a ne samo vrijednosti matematičkog obrazovanja. Pritom je potrebno kroz odgojno-obrazovni rad dosljedno njegovati i razvijati određene vrijednosti matematičkih znanja i vještina kako bi bile u funkciji općeg obrazovanja koje će djeci omogućiti stjecanje osnovnih znanja iz područja temeljenih kompetencija.

Nastavnici se danas sučeljavaju s društvom koje propituje i kritizira obrazovanje i školu te naročito nastavnike i učitelje čiji je profesionalni autoritet i status u društvu ionako već suviše podcijenjen. Iako se težište metodike nastave premješta s nastavnika na učenika, odgovornost za uspjeh mijenja se u suprotnom smjeru pa se svakom objavom rezultata naših učenika prozivaju isključivo nastavnici. Također se pokazuje kako je temeljno polazište teorijskih promišljanja i odgojno-obrazovnih reformi prožeto generalizacijama kako nastavnici ne rade dobro te tipičnim frazama kako samo „predaju“ umjesto da poučavaju. Status nastavničke struke takvim se pristupom dodatno narušava po cijeni opravdanja istih reformi te odgojno-obrazovnih i političkih interesnih skupina koje su njima na čelu. S obzirom na to da je broj empirijsko provjerljivih (Palekčić, 2014) istraživanja o kompetencijama nastavnika nedovoljan, jedini su standard kvalitete obrazovnog sustava međunarodna istraživanja obrazovanja temeljem kojih mnogi prozivaju nastavnike, iako se ne uzimaju u obzir društveni, kulturalni, socioekonomski i obrazovno-politički čimbenici. Naime, po pitanju kompetencija nastavnika općenito nedostaje objektivnih kriterija i/ili validnih istraživanja na temelju kojih možemo te iste tvrdnje potkrijepiti.

Uspješnost nastave ponajprije je određena jednom općom kompetencijom nastavnika čija se kvaliteta, unatoč mnogim naporima svakojakih evaluacija, ne može kvantificirati jednostavnom metodologijom, a naročito ne onom koja vrednuje samo rezultate učenika u rješavanju „mjerodavnih“ zadataka zadanih od strane krovnih obrazovnih institucija u svijetu, a potom izvodi cijeli niz zaključaka o nekim aspektima nastave i kompetencijama nastavnika koji ponekad nisu ni implicitno obuhvaćeni istim vrednovanjem. Cjelokupna nastavnička

profesija po svojoj prirodi osuđena je na svojevrsnu asimpotičnost u realizaciji ciljeva i standarda kvalitetne nastave što zajedno s metodološkim ograničenjima u istraživanjima odgoja i obrazovanja ostavlja mnoga otvorena pitanja i mogućnost različitih tumačenja određenih pojava i fenomena. Tako se sustavi vanjskog vrednovanja (državna matura i međunarodna istraživanja) usredotočuju na učenička postignuća koja je lakše kvantificirati, a zanemaruju se odgojni zadatci nastave te slojevitost i kompleksnost rada nastavnika koji svojim radom i djelovanjem djeluju na učenike u cijelom spektru njihova razvoja i odrastanja. Naime, usporedno s promjenama u društvu, učenici su izloženi sve većem broju okolinskih faktora koji, među ostalim, utječu na učenička postignuća koja se sustavima vanjskog vrednovanja evaluiraju neovisno o ostalim aspektima matematičkih kompetencija što nije pedagoški opravdano te je u proturječju sa standardima suvremene nastave koju nastavnici nastoje realizirati.

S druge strane, poznato je kako nikakav kurikulum ni njegove reforme ne mogu uspjeti ukoliko podcjenjujemo učitelje i nastavnike zato što ih neće cijeniti ni učenici. Autoritet nastavnika temelji se na ugledu, znanju, karijeri, iskustvu, kompetencijama. No, nastavnici danas grade autoritet isključivo na vlastitim komptencijama te ga ostvaruju u okvirima društva koje ga ne podupire, već ga propituje i kritizira. Unutar takvih ograničenja moramo se pitati kako će nastavnici motivirati učenike (i njihove roditelje) ako ih ne poštuju već kroz samu ulogu koju imaju.

Unatoč tome, suvremena nastava mora učeniku pružiti odgojne i obrazovne vrijednosti ne samo zbog onoga što škola jest, odnosno čemu teži svojim djelovanjem, već zato što se ni obrazovni ciljevi ne mogu realizirati ukoliko ih ne sjedinimo s odgovarajućim postupcima tako da nastava ima i odgojnu dimenziju. Herbart, koji je teorijski utemeljio „odgojnu nastavu“, istu je povezao sa svrhom odgoja prema kojoj navodi kako je moralnost najviša svrha odgoja (prema Palekčić, 2014). Roth (1971) tvrdi kako na određenje čovjeka odlučujuće utječu sloboda, samoodređenje i samoodgovornost te je moralna sposobnost za djelovanje ključno pitanje za pedagogiju. S druge strane, u vremenu brzih promjena društvo se sve više usmjerava prema znanstveno-tehničkom aspektu svojeg razvoja. U praksi zanemaruje, a u teoriji istovremeno promovira odgoj i razvoj moralnog pojedinca spremnog za izazove suvremenog društva. Ta se proturječnost negativno odražava na obrazovanje koje gubi svoju odgojnu komponentu zbog čega su i opravdane sumnje kako bi koncept cjeloživotnog učenja mogao imati negativne posljedice za društvo i obrazovanje te cjelovitost ljudske osobe.

Razvojem industrijskog društva, ekspanzijom proizvodnje i velikom potrebom za radnicima, javlja se potreba za „učinkovitijim“ obrazovanjem, to jest kako u što kraćem

vremenskom roku osposobiti radnika za njegovu funkciju. John Franklin Bobbit svojevrsni je začetnik takvog kurikuluma s naglaskom na efikasnost te prilagođavanje obrazovanja industriji, a nešto kasnije razradio ga je Ralph W. Tyler. U svom djelu *Basic principles of curriculum and instruction* Tyler (1949) navodi kako se pri izradi kurikuluma mora objasniti svrha koju želimo postići obrazovanjem, iskustva kojima to možemo postići, efikasna organizacija tih iskustava i u to sve uključiti specifičnosti učenika, vrijednosti i potrebe društva te sadržaj predmeta. Već iz ovih temeljnih postavki možemo zaključiti kako navedeni pristup nema ništa zajedničko s Herbartovim pojmom obrazovanja. Nastavnik u ovakvom školstvu ima zadatak pobrinuti se da učenici usvoje potrebnu količinu informacija za funkciju za koju se pripremaju te u konačnici evaluirati isto prema kriterijima karakterističnim za ekonomiju (Ćatić, 2012).

Sukladno tome, kurikulumi diljem svijeta zadnjih nekoliko desetljeća sve se više okreću standardizaciji što je već svojevrstan trend u pedagogiji i obrazovanju. Slijedom toga, u recentnim kurikulumima prisutna je sve izraženija disonanca između suvremenih trendova u obrazovanju i pedagoško-psiholoških spoznaja o nastavi i obrazovanju općenito. Naime, današnji kurikulumi usmjereni su na usvojenost znanja i realizaciju zadanih obrazovnih standarda (ishoda) do te mjere da se onaj najbitniji dio nastave gotovo zanemaruje - *kako nastavnici poučavaju i kako učenici uče* (Bruner, 2000). Isti je autor za reforme školstva koje su se zadnja dva desetljeća dvadesetog stoljeća provela u Sjedinjenim Američkim Državama istaknuo kako začuđuje koliko su u zadnjih nekoliko desetljeća naučili o učenju i poučavanju u školama te kako je intimnija perspektiva učenja i poučavanja bila isključena iz nacionalnih rasprava. Isto je razvidno u obrazovnim sustavima diljem Europe, kao i u Hrvatskoj, gdje se o kvaliteti nastave i kompetencijama nastavnika priča samo na deklarativnoj razini te je u recentnim kurikularnim dokumentima isto prisutno samo formalno, kao i u javnim raspravama u kontekstu nastave matematike gdje su ključni elementi kvalitetne nastave bili u sporednom planu. Tako se kroz nedavne reforme uložio ogroman napor u precizno definiranje obrazovnih ishoda uzduž cijelog sustava predtercijarnog obrazovanja po svim predmetnim područjima, a specifičnosti nastave zbog kojih su dotična područja problematična nisu dobile posebnu pozornost. Međutim, intencija cjelokupne reforme jest podizanje kvalitete nastave, a obrazovni ishodi omogućuju primarno standardizaciju, ali ne nužno i kvalitetniju nastavu i cijeli niz relevantnih čimbenika odgojno-obrazovnog procesa što su u konačnici ciljevi svake reforme. Stoga nam tek predstoji vidjeti hoće li se buduće kurikularne reforme i promjene u sustavu odgoja i obrazovanja više usmjeriti na problematična područja nastave matematike i na kompetencije koje bi suvremeni nastavnik matematike trebao posjedovati te koliko će dugo težište obrazovnog sustava biti usmjereno na obrazovne ishode.

2. TEORIJSKI DIO

2.1 Kompetencijski pristup obrazovanju

Razvoj društva znanja, koji se temelji na kompetencijama, među najaktualnijim je temama u obrazovanju te se smatra imperativom za život i rad u suvremenom društvu. Europsko vijeće 2000. godine u Lisabonu postavilo je novi strateški cilj Europskoj uniji - postati najkompetentnije gospodarstvo svijeta utemeljeno na znanju, vještinama i sposobnostima. Kako bi došlo do ostvarenja tog cilja, Europsko vijeće pozvalo je države članice, Vijeće i Komisiju da donesu Europski okvir i definiraju „nove osnovne vještine“ koje je potrebno steći tijekom cjeloživotnog učenja.

Sljedeće godine Europsko vijeće u Stockholmu usvojilo je dokument „Konkretni budući ciljevi sustava obrazovanja i izobrazbe“ koji se sastoji od trinaest ciljnih područja. U želji da se ostvare ciljevi svih područja, Komisija formira stručne skupine koje sačinjavaju stručnjaci iz država članica, zemalja EFTE/EEA, pridruženih zemalja i udruga na europskoj razini. Osnovni ciljevi radne skupine zadužene za ključne kompetencije bili su prepoznati i definirati nove vještine, a poseban naglasak stavljen je na skupine s posebnim potrebama, one koji ne uspijevaju završiti školu i starije. Radna skupina za ključne kompetencije završila je 2004. godine Europski referentni okvir ključnih kompetencija za cjeloživotno učenje.

Zbog prenosivosti kvalifikacija i cjeloživotnog učenja, Europska komisija, uz pomoć stručne skupine za Europski kvalifikacijski okvir, napravila je prijedlog Okvira s osam razina temeljenih na ishodima učenja. Koristeći ishode učenja kao zajedničku referentnu točku, Okvir će omogućiti prenosivost kvalifikacija između zemalja te na taj način koristiti najširem krugu korisnika na europskoj i nacionalnoj razini. Tijekom druge polovice 2005. godine, Europska komisija dala je prijedlog za proces konzultacija diljem Europe, a pristigli su odgovori potvrdili prihvaćenost prijedloga. Predloženo je da se Okvir ključnih kompetencija primijeni u kontekstu svakodnevnih obrazovnih situacija tijekom cjeloživotnog učenja u skladu s nacionalnim programima:

- opće obvezno obrazovanje više nije usmjereno na „eksplicitno„ znanje, već je naglasak na „nesvjesnom“ stjecanju znanja koje je ugrađeno u osobne i socijalne kompetencije svakog pojedinog učenika
- obrazovanje i izobrazba odraslih – od kompenzacijskog obrazovanja do trajnog profesionalnog usavršavanja

- jasni obrazovni programi za skupine kojima prijeti društveno isključenje (nacionalne manjine, migranti, osobe koje žive u udaljenim i izoliranim područjima)
- obrazovni programi za osobe s posebnim obrazovnim potrebama – s obzirom na razne teškoće učenika u odgojno-obrazovnom sustavu, potrebno je osigurati odgovarajuće, prilagođene i individualizirane obrazovne programe.

(Memorandum o cjeloživotnom učenju)

Stručna skupina zadužena za ključne kompetencije prihvatila je definiciju:

Ključne kompetencije su prenosivi multifunkcionalni sklop znanja, vještina i stavova koji su potrebni svim pojedincima za njihovu osobnu realizaciju i razvitak, uključivanje u društvo i zapošljavanje. Treba ih razviti do kraja obveznog obrazovanja ili izobrazbe i predstavljaju temelj za daljnje učenje kao dio cjeloživotnog učenja.

(Memorandum o cjeloživotnom učenju, str.7)

Koncept cjeloživotnog učenja odgovor je krizi obrazovanja koja je nastala uslijed velikih društvenih promjena, naročito zbog razvoja novih tehnologija koje stvaraju nova zanimanja, koje utječu na radno aktivno stanovništvo koje mora nadopuniti i/ili steći neka nova znanja i vještine. Time se, među ostalim, stvorila potreba proširivanja obrazovanja izvan okvira formalnog školstva u namjeri da se svima, bez obzira na dob, spol i stečenu naobrazbu, omogući stjecanje znanja i razvijanje kompetencija potrebnih za život i rad u suvremenom društvu.

Unatoč prvotnim intencijama usmjerenim prema obrazovanju odraslih, koncept cjeloživotnog učenja odnosi se na „formalni, neformalni i informalni oblik obrazovanja te pokušava integrirati i artikulirati sve strukture i faze obrazovanja duž vertikalne i horizontalne dimenzije sustava odgoja i obrazovanja. Ono je također karakteristično po svojoj fleksibilnosti što se tiče vremena, prostora, sadržaja i načina učenja te stoga zahtijeva samoupravljivo učenje, dijeleći nečije prosvjetljenje s drugima i prihvaćajući različite stilove i strategije učenja“ (Dave, 1976; prema Pastuović, 2008). Sintagmom „cjeloživotno učenje“ riješila su se prethodna neslaganja i neodređenost pojma cjeloživotnog obrazovanja zato što je pojam učenja obuhvatniji i širi koncept od obrazovanja, može se provoditi/realizirati i nenamjernim, neorganiziranim, pa i spontanim stjecanjem znanja kroz vlastita iskustva tijekom cijelog života. Temeljne pretpostavke ostvarenja cjeloživotnog učenja čine četiri stupa uspjeha obrazovanja redom formulirana kao: *učiti znati, učiti činiti, učiti živjeti zajedno* (Delors i sur., 1998). *Učiti znati* osnova je cjeloživotnog obrazovanja, a odnosi se na stjecanje i primjenu općih znanja kako bi isto bilo u funkciji nadogradnje novim znanjima nastalim razvojem znanosti i društva

te u mogućnosti specijalizacije u pojedinim predmetima. Za koncept *učiti činiti* potrebno je stjecanje stručnih kompetencija koje će nam olakšati snalaženje u nepredvidivim situacijama, pripremiti za rad u timu te omogućiti aktivan i kritičan odnos prema problemima iz društva i radnog okruženja. *Učiti živjeti zajedno* sastavni je dio života i osnovna značajka čovjeka kao društvenog i humanog bića koji se trudi razumjeti druge ljude, tolerantan je, uvažava druge kulture i tradicije te cijeni bogatstvo različitosti ne samo zbog nametnutih društvenih normi, već zato što nam to omogućuje vlastiti razvoj, kao i razvoj društva u cijelosti. Posljednji stup cjeloživotnog obrazovanja *učiti biti* odnosi se na razvoj samostalnog i odgovornog pojedinca.

Za realizaciju Temeljnog okvira cjeloživotnog učenja kojeg čine četiri stupa, predstavljene su ključne kompetencije koje svaki građanin Europske unije treba steći kako bi punopravno sudjelovao u suvremenom društvu (Europsko vijeće, 2006):

- komunikacija na materinskom jeziku
- komunikacija na stranom jeziku
- matematička kompetencija i temeljne kompetencije u prirodnim znanostima i tehnologiji
- digitalna kompetencija
- učiti kako učiti (kompetencija učenja)
- društvena i građanska kompetencija
- inicijativa i poduzetništvo
- kulturna svijest i izražavanje.

Cilj Referentnog okvira temeljnih kompetencija omogućiti je pojedincu osobni razvoj i samoostvarenje te mu omogućiti da se kao aktivan građanin Europske unije zaposli temeljem stečenih znanja i vještina. Navedeni je Referentni okvir osnova za svako daljnje poduzimanje zajedničkih mjera pri svladavanju izazova s kojima se suočava europska zajednica (Europsko vijeće, 2006). Temeljna pretpostavka ostvarenja sveobuhvatnih ciljeva cjeloživotnog učenja jest sustav formalnog obrazovanja na čelu s nastavnicima čije kompetencije određuju kvalitetu nastave. Upravo je zato jedan od predstojećih izazova osiguravanje kvalitetnog obrazovanja za učitelje i nastavnike kako bi koncept cjeloživotnog učenja realizirali u što većoj mjeri. Posebice bi velik dio sredstava trebalo uložiti u poboljšanje statusa nastavnika, njihovog ekonomskog statusa te u njihovo školovanje i kontinuirano usavršavanje. Delors i suradnici (1998) u tom smislu naglašavaju važnost poboljšanja selekcije, radnih uvjeta nastavnika, izgradnju odgovarajućih znanja i sposobnosti, pozitivnu osobnost te profesionalne izglede i motivaciju

kao potrebne uvjete kako bi nastavnik ostvario očekivanja koja se postavljaju pred njega. Novi zahtjevi obrazovne politike maksimalno su proširili područje nastavničkih kompetencija koje su nužne za rad nastavnika u društvu znanja.

No, prvo je potrebno poboljšati kvalitetu obrazovanja nastavnika i obrazovanja općenito kako bi se kompetencije stjecale kao dio visokoprofesionalnog sustava. U zadnje vrijeme koristi se pojam „profesionalizacija nastavničke djelatnosti“ koja u sebi sadrži pojam „pedagoške profesionalnosti“. Stoga, nastavnici kao profesionalci, bez obzira na ustanovu u kojoj rade, u svojem poslu vode se širokom bazom znanja utemeljenog na istraživanju, koristeći pritom metode provjerene u praksi. Delors i suradnici (1998) ističu kako je funkcija nastavnika širiti upravo ljudske kvalitete i biti uzor u pogledu radoznalosti, otvorenosti duha, spremnosti preispitivanja vlastitih pogrešaka te poticati ljubav prema učenju i vrline poput empatije, skrušenosti i strpljivosti. Zbog toga je neizbježno osmisliti školovanje nastavnika koje će stremiti k razvoju intelektualnih i ljudskih kvaliteta te podržati nove pristupe poučavanja utemeljene na olakšavanju izgradnje znanja (Delors i sur., 1998).

S druge strane, *nastava orijentirana prema kompetencijama nije teorijski utemeljen ni empirijski provjeren model nastave* (Palekčić, 2014, str.8). „Kompetencijski standardi služe za permanentno vrednovanje odgoja i obrazovanja, kao djelatnosti i kao procesa, a vrednovanje omogućuje i potiče stalno poboljšanje i usavršavanje poučavanja i učenja, to jest stalnu povezanost znanstvenog pristupa s odgojno-obrazovnom praksom (Vican, Bognar, Previšić, 2007, 163). Problem se javlja u nedostatku kritičkog preispitivanja koncepta cjeloživotnog učenja čime se na svojevrstan način stvara jednostrana pozitivna slika cjeloživotnog učenja i društva znanja, a to otvara prostor manipulaciji različitih interesnih skupina od strane politike, tržišta i samog obrazovanja. Svrha ovakvog obrazovanja osposobljavanje je pojedinca za rad uz što manju potrošnju resursa i vremena. Unatoč toj kritici, to su elementi i današnjeg obrazovanja.

Aktualna strategija Europske komisije *Europa 2020* stupila je na snagu 2010. godine te se tiče zapošljavanja, inovacija, obrazovanja, socijalne uključenosti te energetskih izazova i klimatskih problema. Ona donosi nekoliko ciljeva koje bi države članice Europske unije trebale ispuniti do 2020. godine:

- smanjiti stopu prekida školovanja na manje od 10 % te osigurati da najmanje 40 % osoba između 30. i 34. godine završi tercijarno obrazovanje

- cilj je povećati učinkovitost obrazovnih sustava i olakšati ulazak mladih na tržište rada što se, među ostalim, postiže programima studiranja, učenja i izobrazbe koje financira EU te platformama kojima se mladima pomaže pronaći zaposlenje diljem EU-a
- poboljšati uvjete i pristup financijskim sredstvima za istraživanje i inovacije kako bi se inovativne ideje u konačnici mogle pretvoriti u proizvode i usluge te tako potaknuti rast i otvoriti nova radna mjesta
- modernizirati tržišta rada i poboljšati ulogu i položaj ljudi razvijanjem njihovih vještina i poboljšanjem fleksibilnosti i sigurnosti u radnom okruženju
- cilj je i pomoći radnicima u lakšem traženju zaposlenje diljem EU-a kako bi se bolje uskladile ponuda i potražnja na tržištu rada

Što se tiče obrazovanja, ključni je pojam „učinkovitost“, a to znači da se kao svrha obrazovanja primarno ističe osposobljavanje mladih za rad. Iz navedenih ciljeva također je razvidno kako se istraživanja stavljaju u funkciju trgovine, odnosno kako će začetnici ove inicijative novčano potpomoći istraživanja, ali s očekivanjem kako će se proizvodi tih istraživanja moći prodati, a dane investicije povratiti uz očekivani dodatni profit. Što se tiče programa za nove vještine i radna mjesta, ističe se cilj poboljšanja kvalitete života razvijanjem vještina koje su potrebne današnjem gospodarstvu kako bi se pojedinci lakše prilagodili tržištu rada i potrebama potencijalnih poslodavaca u funkciju gospodarstva.

Naposljetku, obrazovna je politika pod utjecajem globalnih društvenih trendova te se kao takva nalazi u nezavidnom položaju s obzirom na polazišta koja su opravdana i uvjetovana gospodarsko-ekonomskim trendovima, umjesto pedagoških vrijednosti i polazišta koje su temelj (suvremene) škole. U tim okvirima škola i odgojno-obrazovni djelatnici moraju ispuniti višestruke ciljeve i kriterije unutar kojih ostaje diskutabilno jesu li zadani kriteriji pedagoški opravdani te je li ih moguće optimalno realizirati kako bi učenici bili spremni na izazove koji ih čekaju u budućnosti. S druge strane, ne može se reći kako su pedagoški ciljevi zanemareni te kako nisu među prioritetima, ali ostaje sporno jesu li svrha i cilj obrazovanja ispunjeni prema njenom tradicionalnom i znanstveno-teorijskom određenju ili prema nekim novim određenjima koje postavlja suvremeno društvo, odnosno kapitalizam.

2.1.1. Matematička kompetencija u suvremenom odgoju i obrazovanju

Matematika se, svojim područjem djelovanja i različitim primjenama u svakodnevici, konstituirala kao znanost koja zahtjeva i koristi složeni i apstraktni jezik kojim opisuje različite

procese, pojave i odnose među njima. Taj jezik iskazuje se matematičkom terminologijom kroz apstraktne znakove kojima se opisuju matematički koncepti i procesi koji su međusobno usko povezani tako da svako usvajanje novih sadržaja često podrazumijeva i logičko-deduktivno povezivanje novih sadržaja te proširivanje matematičkog pisma što pak implicira kontinuitet i kumulativnost znanja kao osnovne karakteristike školske i istraživačke matematike.

Matematika je, kao znanstvena disciplina i nastavni predmet, po prirodi deduktivna znanost, a u težnjama je unapređenja znanosti induktivna. Induktivan i deduktivan način razmišljanja temeljna su obilježja matematičkog načina razmišljanja te ih je važno isticati i njegovati u njihovoj općenitosti kako bi iste imale univerzalnu vrijednost koja nije ograničena samo na matematiku. Zbog univerzalnosti i apstraktne razine matematičkog jezika, korpus znanja matematike i matematički način razmišljanja ima primjene u: prirodnim znanostima, tehničkim znanostima, medicini, tehnologiji, ekonomiji te društvenim, humanističkim znanostima itd. Sukladno tome, učenici kroz nastavu matematike moraju steći osnove matematičke pismenosti i osvijestiti značajne uloge i primjene matematike te matematičkog jezika u društvu, raznim djelatnostima i znanostima kroz povijest i danas.

Nastava matematike i visokoškolska matematika po svojoj su tradiciji poučavanja te programskom i sadržajnom usmjerenju dominantno deduktivnog karaktera što za praksu podrazumijeva postupnu nadogradnju znanja kojom se nova znanja izvode iz prethodnih, kumulativnim stjecanjem, znanja i vještina. Za nastavu matematike ovo je ključni moment zato što nam implicite ukazuje kako su školska matematika i ona koja se uči na najvišim razinama studija iz STEM područja iste po načinu rada, razmišljanja i cjelokupnoj izgradnji znanja, a to samo potvrđuje kako je kontinuitet u radu najbitnija pretpostavka uspješnosti i izvrsnosti.

Naime, iako se smatra da je za dostizanje visokih znanja ili za ostvarivanje karijere u matematici potrebno kreativno razmišljanje, pokazuje se kako je ustrojstvo kombinacije znanja, vještina i osobnih značajki potrebnih za uspješno studiranje matematike jako slično onome u školskoj matematici, samo što je na višim razinama apstrakcija matematičkih znanja. Teorije se grade na isti način na svim razinama matematičkog obrazovanja, zadatci su konvencionalni i predvidivi ukoliko se vodimo matematičkim načelima i načinom razmišljanja koje se izgrađuje u osnovnoj i srednjoj školi. Također, složenost matematike općenito se odnosi na razumijevanje i uporabu matematičkih koncepata, akumuliranju mnogih pravila, činjenica i umijeća njihove primjene što je i optimalan način za razvoj daljnjih teorija i stjecanje odgovarajućih znanja. S druge strane, motivacija, prisustvo radnih navika i kontinuitet uspjeha duž matematičkog obrazovanja prioritet su svakog uspjeha u školskoj i znanstvenoj matematici. Kreativnost se pokazuje ili se može pokazati značajnom tek kod onih rijetkih matematičara koji su uspjeli

ostvariti karijeru vrhunskih znanstvenika, koji su usvojili kritičnu količinu znanja i vještina kako bi mogli raditi na otvorenim problemima unutar kojih sami ostvaruju doprinos znanosti. Naime, matematika i matematičke spoznaje napredovale su u tolikoj mjeri da samo manji broj studenata matematike uspije doći do razina znanja unutar nekog užeg područja matematike u kojem je spoznao/la dovoljno znanja kako bi mogao stvarati nove ideje. Tako da aspekt kreativnosti ne dolazi do izražaja, barem ne u onom kontekstu u kojem se ista najčešće spominje.

U intencijama ostvarivanja kreativnosti i primjenjivosti znanja učenika pri planiranju nastave od neizmjerne je važnosti odrediti razinu znanja učenika, odnosno kvalitetu usvojenosti prethodnih nastavnih sadržaja. Znanje kao logički pregled činjenica i generalizacija o objektivnoj stvarnosti (Poljak, 1991) u matematici se odnosi na usvojene pojmove, pravila, definicije, modele i zaključke koje učenik usvaja te primjenjuje u svojem radu. U nastavi matematike pritom se isprepliću deklarativna (konceptualna) i proceduralna znanja koja se komplementarno razvijaju i nadograđuju (Anderson, 1982).

Deklarativna znanja odnose se na usvajanje činjenica i generalizacija, a proceduralna se odnose na način izvođenja pojedinih operacija što u matematici često opisujemo algoritamskim rješavanjem zadataka. Proceduralna znanja odnose se na poznavanje niza radnji ili koraka u rješavanju matematičkih zadataka te se vježbaju rješavanjem većeg broja sličnih zadataka. Iako učenici vježbanjem tih zadataka zapamte proceduru, ponekad ne razumiju njezinu pozadinu pa se ne mogu snaći kada izmjene u zadatku odstupaju od onih na koje su navikli. Ono što nedostaje jesu konceptualna znanja koja se ponajprije očituju u razumijevanju provođenja postupaka rješavanja zadataka kojima učenici razumiju zašto se nešto radi te kako je isto povezano s prethodnim sadržajima. Međutim, kako bi uspješno razumjeli i rješavali matematičke zadatke, uz konceptualno znanje potrebno je razumijevanje matematičkog jezika koji je zbog svoje apstraktnosti često neprimjeren, odnosno nije prilagođen učenicima na njima razumljiv način. Naime, matematički jezik je koncizan, zbijen i jezgrovit te ne trpi suvišnost, ali ni enigmatsku kratkoću *(Kadum i sur., 2007).* Autori stoga navode tri komponente svakog matematičkog koncepta: lingvistička komponenta, konceptualna komponenta i proceduralna komponenta. Lingvistička komponenta odnosi se na matematički vokabular, sintaksu i pravila prevođenja matematičkog jezika u smislene tvrdnje. Konceptualna komponenta jest razumijevanje matematičkih ideja te razvijanje njima svojstvenih misaonih koncepata. Proceduralna komponenta odnosi se na računske postupke i algoritme koji se primjenjuju u odnosu na koncept. Te komponente odražavaju kompleksnost i apstraktnost matematike koja nije zahtjevna samo zbog složenosti sadržaja koji se rade u nastavi, već je riječ o usvojenosti

matematičkog pisma i proceduralnih znanja. Također, svaki zadatak iz nastave matematike u sebi sadrži jedinstvo navedenih komponenti zbog čega je nastavnicima ponekad teško detektirati izvor problema, odnosno komponentu/e koja/e učenicima čine problem pri razumijevanju zadatka i uspješnosti njegova rješavanja.

Istu misao svakako treba promisliti u kontekstu uobičajenih stavova prema kojima se školska matematika smatra znatno težom nego što objektivno doista jest, a primarna je distinkcija matematike od ostalih školskih predmeta da već vrlo rano postaje predmet u kojem se učenici susreću s određenim kognitivnim pa i emocionalnim preprekama. Matematička kompetencija, među temeljnim kompetencijama, možda je i najviše izložena kvantifikaciji i raznim evaluacijama kroz međunarodna istraživanja obrazovanja (npr. TIMSS i PISA), kao i kroz domaći projekt državne mature. U PISA međunarodnom istraživanju obrazovanja temeljno je polazište organizacije OECD kako je matematičko obrazovanje jedan od instrumenata razvoja ljudskog kapitala. PISA je akronim od *Programme for International Student Assessment*, odnosno program međunarodnog ispitivanja znanja i vještina petnaestogodišnjih učenika. U nastojanjima da raspolaže međunarodno usporedivim podatcima o kvaliteti obrazovnih sustava i postignućima učenika, projekt PISA pokrenula je *Organizacija za ekonomsku suradnju i razvoj* (OECD) 1997. godine. Međunarodna istraživanja obrazovnih postignuća učenika provode se na dovoljno velikim i reprezentativnim uzorcima testova koji mjere ostvarivanje kognitivnih ciljeva obrazovanja koja su zajednička različitim zemljama. Sudjelovanjem u PISA-i zemlje članice OECD-a obvezale su se redovito pratiti ishode svojih obrazovnih sustava ispitivanjem učeničkih postignuća prema međunarodno usuglašenom konceptualnom okviru. Provodi se u zemljama članicama Organizacije za ekonomsku suradnju i razvoj (OECD) i partnerskim zemljama u trogodišnjim ciklusima (2000., 2003., 2006., 2009., 2012., 2015.). Ovo istraživanje ispituje znanja i sposobnosti iz triju područja: matematičke, prirodoslovne i čitalačke pismenosti.

U domeni matematičke pismenosti prema rezultatima PISA istraživanja naši učenici znatno su ispod prosjeka zemalja OECD-a (na 40. mjestu od 64 zemalja), a njih 30 % nije steklo osnovna znanja matematike (OECD, 2013). Pritom ne postoji statistički značajna razlika između rezultata ciklusa PISA 2015. i prijašnjih ciklusa, ali zato postoji razlika s obzirom na spol pa su tako dječaci postigli značajno bolji rezultat od djevojčica što je karakteristično u većini zemalja OECD-a (NCVVO, 2017). Hrvatski učenici na PISA testu postigli su sljedeće rezultate: u prirodoslovnoj pismenosti smjestili su se na 36. mjesto od ukupno 72 države, na području matematičke pismenosti postigli su 41. mjesto, a u čitalačkoj su pismenosti na 31. mjestu (OECD, 2017). Prikupljeni komparativni podatci omogućuju obrazovnim sustavima i

školama preispitivanje svojeg funkcioniranja uspoređujući se s drugima .

Dodatni značaj navedenome očituje se u neupitnoj vezi uspjeha u matematici i izboru fakulteta i budućih zanimanja naših učenika. Tako naši maturanti već tradicionalno biraju studijske programe izbjegavajući fakultete iz područja matematike, prirodoslovlja i tehnologije. S obzirom na to da su ta područja na razini Europe prepoznata kao ključne sastavnice obrazovne politike za razvoj gospodarstva (Eurydice Report, 2012), prosvjetne vlasti brojnih europskih zemalja pokušavaju raznim mjerama povećati udio diplomiranih studenata iz tih područja. Prema istom izvješću, komparativnom analizom Europske unije o razvijanju ključnih kompetencija utvrđeno je kako trećina europskih zemalja nije razvila nacionalnu strategiju za materinji jezik, matematiku i prirodoslovlje.

Kako je svako predmetno područje unutar odgojno-obrazovnog sustava koncipirano tako da sustavno priprema i osposobljava učenike na način kako bi oni uspješniji upisali određene studijske programe, važno je već u kurikularnom pristupu matematičkog obrazovanja razumjeti koje su to kompetencije diplomiranih matematičara i koji se profil učenika po završetku srednjoškolskog obrazovanje odlučuje za studijske programe releventne za neko predmetno područje. Međutim, možda je najizazovnije i najrelevantnije za istraživače, didaktičare i praktičare u nastavi matematike razumjeti zašto određeni profil učenika upisuje dotične studijske programe te može li odgojno-obrazovni sustav s praktičarima na čelu nešto promijeniti i dati perspektivu širem krugu naših učenika. Stoga je potrebno razumijeti vertikalu matematičkog obrazovanja od osnovne škole do fakulteta i opći pregled matematičkih znanja, sposobnosti i vještina.

Prema nastavnom planu i programu za osnovnu školu ciljevi nastave matematike su (MZOŠ, 2006): stjecanje temeljnih matematičkih znanja potrebnih za razumijevanje pojava i zakonitosti u prirodi i društvu, stjecanje osnovne matematičke pismenosti i razvijanje sposobnosti i umijeća rješavanja matematičkih problema. U tim okvirima učenici u osnovnoj školi trebaju: osposobljavati se za apstraktno mišljenje, logičko zaključivanje i precizno formuliranje pojmova; razvijati osjećaj odgovornosti i kritičnosti prema svojem i tuđem radu; razvijati sposobnost i odgovornost za samostalni rad, točnost, urednost, sustavnost, preciznost i konciznost u pismenom i usmenom izražavanju.

Ciljevi nastave matematike u gimnaziji i srednjim strukovnim školama su:

- stjecanje temeljnih matematičkih znanja nužnih za nastavak daljnje izobrazbe, praćenje suvremenog društveno-gospodarskog i znanstveno-tehnološkog razvoja i buduće djelatnosti

- razvijanje logičkog mišljenja i zaključivanja, matematičke intuicije, mašte i stvaralaštva
- stjecanje navika i umijeća kao što su sistematičnost, ustrajnost, preciznost i postupnost
- usvajanje metoda matematičkog mišljenja koje se očituje u preciznom formuliranju pojmova i algoritamskom rješavanju problema
- stjecanje znanja potrebnih za razumijevanje kvantitativnih odnosa i zakonitosti u raznim pojavama u prirodi, društvu i praktičnom životu
- razvijanje preciznosti i konciznosti u izražavanju te urednosti, ustrajnosti i sistematičnosti u radu.

Općenito se smatra kako su time postavljeni preduvjeti za razvoj kompetencija potrebnih za studij matematike. Kompetencije diplomiranih matematičara pritom dijelimo na opće kompetencije, a to su rješavanje problema, argumentiranje, komuniciranje, modeliranje i matematičko reprezentiranje matematičkih sadržaja i koncepata te na specifične kompetencije koje se odnose na niz vještina i znanja u područjima koje čine jezgru matematičkih sadržaja:

- brojevi i aritmetika
- algebra i funkcije
- geometrija (oblici i prostor)
- veličine i mjerenje
- podatci, vjerojatnost i statistika.

Na matematiku se stoga ne gleda samo kao na korpus znanja, već kroz vještine i način razmišljanja što se može primjeniti u mnogim situacijama iz života te raznim profesijama i strukama. Stoga se i vrijednost matematike ponajprije očituje u shvaćanju i usvajanju njezinih načela i zakonitosti te u logičkom načinu mišjenja i zaključivanja koje nije ograničeno samo na matematičke i matematici srodne sadržaje, već ima univerzalnu vrijednost pa samim time i primjenjivost u različitim situacijama iz života. To čini i suštinu matematičke kompetencije u konceptu cjeloživotnog učenja zato što se ne temelji samo na primjenjivosti sadržaja, već je integralni dio odgoja i obrazovanja u perspektivi cjeloživotnog učenja. Sukladno tome, u *Nacionalnom okvirnom kurikulumu* (2010) matematička kompetencija određuje se kao osposobljenost učenika za razvijanje i primjenu matematičkog mišljenja u rješavanju problema u različitim svakodnevnim situacijama. Temeljni okvir kroz koji se razrađuju učenička postignuća matematičke kompetencije su matematički koncepti i matematički procesi. Matematički koncepti u *Nacionalnom okvirnom kurikulumu* određeni su domenama matematičke znanosti: brojevi, algebra i funkcije, oblik i prostor, mjerenje i podatci. To se već uvelike preklapa s područjima koja čine jezgru studija matematike što je upravo određeno sa

svrhom pripreme učenika za studij matematike i ostalih studija STEM područja. Matematičkim konceptima određuju se i razrađuju temeljna znanja u pojedinim obrazovnim sadržajima. S druge strane, matematički procesi odnose se na: prikazivanje i komunikaciju, povezivanje, logičko mišljenje, argumentiranje i zaključivanje, rješavanje problema i matematičko modeliranje, primjena tehnologije. Matematički procesi opisuju opće matematičke kompetencije koje se očituju u usvojenim/razvijenim kognitivnim sposobnostima i vještinama.

Iako matematika ima konceptualnih i sadržajnih primjena praktički u svim znanostima, prisutna su uvjerenja kako se matematička znanost razvija zbog vlastitih interesa te kako je ona zatvoren sustav u kojem se nema više što otkrivati pa čak ni da isto nema opravdanu svrhu. Ta uvjerenja često se reflektiraju i na stavove o nastavi matematike u smislu da se njezini sadržaji kritički gledaju kroz primjenjivost svakog sadržaja na mikrorazini te se korisnost matematike pokušava opravdati, a ponekad i kritizirati, u vidu rješavanja i primjenjivosti zadataka iz nastave, a ne na načinu razmišljanja i odgojnim aspektima matematičke kompetencije.

Uz to, značajno su zastupljena uvjerenja kako potrebu za matematikom i matematičkim vještinama možemo nadomjestiti strojevima i računalima zbog čega se ponekad jednostrano pristupa problemima matematičkog obrazovanja bez uvažavanja odgojnih i općeobrazovnih vrijednosti matematičkih kompetencija. Osobit problem je osnovnoškolska i srednjoškolska matematika koja je prema kurikulumu matematičkog područja primarno usmjerena na stjecanje osnova matematičke pismenosti i razvijanje matematičkog načina razmišljanja. Naime, dimenzija primjenjivosti znanja u školskoj matematici jednim se dijelom ostvaruje artificijelnim primjerima koji su krajnje hipotetski te kao takvi više služe funkciji zanimljivijeg konteksta zadavanja zadataka, ali ne nužno i u osvješćivanju ili pružanju uvida u stvarne primjene koje su aktualne danas ili su bile kroz povijest. Međutim, ne postoji svako znanje kako bi bilo primjenjivo, već je ono ponekad samo stepenica za nešto što će tek imati taj karakter. Većina je matematičkih sadržaja kroz osnovno i srednjoškolsko matematičko obrazovanje usmjerena na postizanje opće matematičke pismenosti te na razvijanje logičkog i općeg znanstvenog načina razmišljanja koji ima primjene u svim aspektima života. Za nastavu matematike potrebno je razlučiti je li uopće cilj i svrha samog predmeta matematike primjenjivost inih sadržaja? Izuzev učenika koji će studirati na tehničkim ili prirodoslovno-matematičkim usmjerenjima, mnogi matematički sadržaji mogu se pokazati vrijednim jedino u vidu razumijevanja složenih matematičkih koncepata i struktura te u razvoju apstraktnog mišljenja i svekolikih vještina koje imaju jednu univerzalnu i općeobrazovnu vrijednost.

Nastavnik, prema tome, uz stečena stručna i pedagoška znanja mora imati određeno razumijevanje prirode svakog znanja i vještina kako bi se usmjerio na njihovu opću odgojnu i

obrazovnu ulogu u razvoju učenika. Time se i pitanje kompetencija u smislu sredstvo-cilj može dvojako tumačiti. Na primjer, matematička kompetencija kao kombinacija znanja, sposobnosti i vještina koje su preduvjet daljnjem obrazovanju na tehničkim i prirodoslovno-matematičkim fakultetima. Ili pak s druge strane, kompetencija kojom se razvija logički, analitički i znanstveni način razmišljanja koje uključuje niz sposobnosti, vještina i vrlina izvan okvira nastave matematike, a koje su potrebne u svakodnevnom životu. Prvo tumačenje lakše je mjeriti te je stoga i dominantno u odgojno-obrazovnom radu u nastavi kao i u svakom ispitu formalnog ili neformalnog obrazovanja kojim želimo stupnjevito ocijeniti stečena znanja i vještine. Smisleno je zaključiti da ako se učenje i poučavanje matematike odvija u idealnim uvjetima uz posredstvo kvalitetnog nastavnika i motivirane učenike, kako će se tada oba tumačenja sjediniti te se neće međusobno isključivati. Relevantna istraživanja unutar razvojne crte matematičkog obrazovanja pokazuju kako učenici s godinama postupno gube interes (npr. Ma i Kishor, 1997) i na određeni način uopće ne participiraju u nastavi matematike svojim kapacitetima, a logiku i analitički način razmišljanja više koriste na upamćivanje procedura negoli na razumijevanje istih.

Pored toga, osvrnemo li se na područja koja čine jezgru matematike kao znanosti te na kompetencije koje se „propisuju“ uzduž prilično opširnog kurikuluma matematičkog područja, potrebno je kritički preispitati kakve kompetencije naši učenici stječu nastavom matematike te koja je funkcija matematičke kompetencije u cjelovitom kontekstu stečenih odgojnih i obrazovnih vrijednosti. Naime, operacionalizacija kompetencija u suvremenim obrazovnim sustavima svojevrsna je manipulacija kojom svodimo uspjeh i kvalitete učenika na zasebne vještine i sposobnosti u kontekstu sadržaja nastave matematike.

Tako na primjer, učenik četvrtog razreda srednje škole odličnog uspjeha iz matematike posjeduje sve bitne tehničke elemente, znanja i vještine iz školske matematike, no sve one bitne značajke matematičke kompetencije posjeduje samo u kontekstu predmeta matematike i srodnih struka i predmeta, ali iste kvalitete ne posjeduje u ostalim aspektima svog života. To se odnosi na karakteristike koje bismo najpreciznije mogli odrediti kao one dimenzije ličnosti koje pripadaju pedagoškim aspektima matematičke kompetencije:

- pedantnost i osjećaj za detalje
- sustavnost i organiziranost
- strpljivost i disciplina
- konvergentno i divergentno mišljenje
- različiti oblici logičkog rezoniranja koji su okosnica pristupa životnim situacijama i izazovima.

Dakle, jednodimenzionalna percepcija matematičkih znanja i vještina kroz prizmu direktnih primjena usvojenih sadržaja zbog nerazumijevanja problematike često je predmet mnogih kritika. Stvarna primjenjivost kojoj moramo težiti postiže se u odgojnim aspektima matematičkih kompetencija, odnosno u općeobrazovnim i odgojnim vrijednostima koje su produkt stjecanja matematičkih znanja i vještina. One se očituju u logičkom načinu zaključivanja te složenom i apstraktnom razmišljanju koje je svojstveno mnogim znanostima te je potrebno za život u suvremenom društvu. Ukoliko percipiramo ideju temeljnih kompetencija izvan okvira sustava obrazovanja i struka za koje ih „pripremamo“, izostavljamo činjenicu kako škola nema samo obrazovnu funkciju kao obrazovanje budućih radnika, već odgoj i obrazovanje ljudi koji će prije svega živjeti u suvremenom društvu, umjesto nametnute perspektive „gdje će“ i „što će“ raditi.

Sadržajno gledano, matematička kompetencija koju evaluiramo standardiziranim ispitima zbog strukture matematičkih sadržaja podrazumijeva usvojenost znanja i određenu razinu logičkog mišljenja kojom isto znanje povezujemo i nadograđujemo. Tako i rješavanje zadataka ima za pretpostavku usvojena znanja i vještine rješavanja mnogih zadataka i sadržaja koje su ranije obrađivali pa nerijetko i nekoliko godina unazad. Pritom se smatra kako su svi prethodni sadržaji svladani te kako će učenici biti u stanju pravovremeno prizvati neke od njih ili ih automatski reproducirati. Rješavanje zadataka nije samo po sebi cilj, već su to implicitna znanja i vještine koja se očituju u usvajanju činjenica, zakonitostima te njihovoj primjeni u proceduralnim znanjima pri rješavanju istih. Za razliku od nekih sadržaja čija je struktura takva da učenje novih sadržaja nije uvjetovano svladavanjem prethodnih znanja ni njihovom primjenom, u matematici predznanje značajno određuje uspješnost svladavanja novih sadržaja.

Dakle, kumulativnost matematičkih sadržaja svojevrsni je indikator kvalitete stečenih znanja i vještina što se očituju u primjeni pravila i zakonitostima u pristupu i rješavanju problema te u kvaliteti izgradnje novih znanja. Vratimo li se na temeljni problem nastave matematike, odnosno nedostatne kvalitete učeničkih znanja, najčešće se vodimo pretpostavkama kako nastavnici nisu kompetentni ili kako nastavni plan i program nije usklađen s optimalnim tempom učenja i poučavanja. Pri tim opažanjima ne smijemo izostaviti mnogostrukost čimbenika uspjeha učenika u matematici, a znanstveno i teorijsko polazište mora biti u našoj primarnoj domeni koja se u praksi ostvaruje s institucionalnog konteksta u smislu obrazovanja i usavršavanja nastavnika te relevantnih smjernica odgojno-obrazovne politike. Što se tiče rada nastavnika, često se ističe kako zapravo rade šablonske nesvrsishodne zadatke umjesto onih u kojima se vidi primjena u svakodnevici. Međutim, uzmemo li u obzir

kumulativnu prirodu matematičkih sadržaja i teškoće učenika u matematici, pokazuje se kako nije problem u nedostatku vježbanja zadataka iz svakodnevice zato što velik dio učenika ne usvaja ni ona temeljna znanja koja su svojom razinom znatno ispod one razine na kojoj bi ih mogli primijeniti. Također, potrebno je razmatrati opširnost nastavnog plana i programa koja očito daje prioritet kvantiteti, a ne kvaliteti što onemogućuje nastavnike u težnji ostvarivanja dublje razine znanja i prijeko potrebnog ponavljanja i vježbanja za koje se prema dinamici nastavnog plana i programa nema dovoljno vremena. Problem je u kvaliteti koja izostaje u fundamentalnim znanjima na razini minimalnih kriterija koji su nužni kako bi određena znanja dovela do viših razina znanja, a kamoli do primjenjivosti istih.

Te bi razine znanja trebao usvojiti svaki učenik prosječnih sposobnosti pa je pretpostavka kako su metodički postupci nastavnika nedovoljno prilagođeni znanjima, sposobnostima, motivaciji i uvjerenjima učenika u kontekstu nastave matematike. Jedna od glavnih zadaća metodike nastave matematike pokazuje se u umijeću poučavanja koje osposobljava učenika za ispravan način učenja matematike. Matematički sadržaji po svojoj prirodi logički su strukturirani te je jedino pitanje koliko se nastavnici razlikuju u načinima da iste prezentiraju na što zorniji i svrsishodniji način koji je prilagođen učenicima. S obzirom na to da matematika podrazumijeva logičko mišljenje, očekuje se da će učenici učiti na odgovarajući način, vodeći se logičkim načinom razmišljanja. Međutim, nedostatan broj učenika usvaja sadržaje na satu zbog čega je ključni izazov utvrditi koje su pretpostavke pri ostvarivanju dubinskog stjecanja znanja svih ili barem većine učenika. Učenici koji ne usvajaju temeljna znanja uglavnom imaju probleme u predznanju, negativna uvjerenja i stavove o matematici, podcjenjuju svoje sposobnosti te doživljavaju niz izazovnih emocionalnih stanja karakterističnih za navedene probleme uslijed čega stječu svojevrsnu odbojnost prema matematici. Zato se motivacija u nastavi matematike treba percipirati i tretirati kao složen i dugotrajan proces te se treba planirati već u izradi predmetnog kurikuluma za pojedini razredni odjel. Stoga možemo reći kako je najbitniji aspekt pedagoških kompetencija u radu nastavnika usmjerenom na jačanje individualnih snaga i samopouzdanja učenika na način da s godinama školovanja zadrže ili povećaju razinu motivacije prema nastavi matematike kako bi imali pozitivnu sliku vlastitih sposobnosti u učenju matematike.

S takvim pristupom učenici mogu stjecati znanja i vještine koje imaju pretpostavku dubinskog učenja i razvoj odgovarajućih znanja koje, ukoliko se ne usvoje i razviju do određene razine, neće biti u funkciji primjenjivosti. Kako bismo nadišli postojeće prepreke u težnjama suvremene nastave matematike, moramo razmatrati sve pretpostavke u odnosu zahtjeva društva i odgojno-obrazovnog sustava, počevši od obrazovne politike koja mora osigurati status i

kvalitetu osposobljavanja nastavnika i učitelja te osigurati uvjete kako bi predmetni kurikulumi bili fleksibilniji s obzirom na specifičnosti učenika. To bi se trebalo ostvariti povezivanjem predmetnih kurikuluma s temeljnim odgojnim i obrazovnim znanostima kako bi metodika nastave matematike imala uporište u bogatom interdisciplinarnom znanju (pedagogija, psihologija, sociologija, antropologija, komunikologija i sl.).

Naime, interdisciplinarnost u didaktici, odnosno metodici predmetnih područja trenutno je možda i najveći potencijal koji recentne odgojno-obrazovne znanosti ne umiju aktualizirati zbog svekolikih interesa i odnosa snaga pojedinačnih znanosti koje djeluju u sustavu znanosti i obrazovanja i nejasne klasifikacije strukovnih didaktika. Zaključno, problemi matematičkog obrazovanja ukazuju na višeslojnost procesa razvoja matematičke kompetencije zbog čega je za svako teorijsko i praktično djelovanje u poučavanju matematike potrebno jedno široko interdisciplinarno znanje te bogatstvo iskustava kojim bi iste dobile funkcionalnu uporabljivost u vidu kompetencija za koje želimo da ih posjeduju suvremeni nastavnici.

2.2. Didaktički i kurikularni pristup matematičkom obrazovanju

2.2.1. Nastava i didaktičke teorije

Didaktiku su, kao pojam, u pedagogiju uveli Ratke i Komensky u 17. stoljeću. Riječ didaktika grčkog je porijekla i izvorno znači poučavanje (*didasko* - poučavam, *didaskein* - poučavati). Didaktika je grana pedagogije koja proučava opće zakonitosti obrazovanja (Poljak, 1991). Obrazovanje kao pojam ima višestruko značenje. Pod obrazovanjem se podrazumijeva institucija, proces, sadržaj i rezultat organiziranog i/ili slučajnog učenja u funkciji razvoja različitih kognitivnih sposobnosti, kao i stjecanja raznovrsnih znanja, vještina i navika. Meyer (2002) definira didaktiku kao teoriju i praksu učenja i poučavanja. Didaktika pokušava pružiti okvir za razmišljanje nastavnika o temeljnim pitanjima njegova rada: kako, što i zašto (Palekčić, 2007). Palekčić pritom ističe kako se didaktika odnosi na transformaciju sadržaja iz nastavnog plana i programa u obrazovne sadržaje što je i okvir rada nastavnika. Stoga se pod didaktikom dugo podrazumijevalo „umijeće poučavanja“ (Kiper, Mischke, 2008) ili pak teorija i praksa učenja i poučavanja (Meyer, 2002). Međutim, od različitih definicija najčešće se navodi kako je didaktika grana pedagogije koja proučava opće zakonitosti obrazovanja (Poljak, 1991). Središnji pojam didaktike jest nastava koja je planski organizirani, svrhoviti sustavni proces usmjeren na stjecanje znanja i usvajanje vještina učenika. Didaktika se pita što treba znati i umjeti te *zašto* i *čemu* to treba naučiti. Time otvara pitanja o nadređenim idejama kao što su

obrazovanje, kvalifikacija, kompetencija, profesionalno osposobljavanje, osposobljavanje za studij (Kiper, Mischke, 2008). Slijedom toga, didaktika se bavi nastavnim planovima i programima ili kurikulumima koji podrazumijevaju ključne odluke za kvalitetu obrazovanja i nastave. Didaktika jest analiza i planiranje procesa učenja i poučavanja putem nastave te stoga nije neposredno djelovanje, već teorija (Klafki, 1992; str. 8). Isti autori također ističu kako je didaktika uvijek i kritika određene prakse što znači da se uvijek odnosi na neku postojeću i intendiranu praksu te stoga nije samo teorija, već i promišljanje o toj praksi i odgovornost za nju.

S druge strane, pojam „metodika“ (grč. *methodos* - postupak) u našem govornom području izvorno je definiran kao „svi načini svrsishodnog provođenja nekog posla“ (Klaić, 1982) ili u nešto užem značenju kao „način svrsishodnog rješavanja praktičnih problema“ (Anić i Goldstein, 2000). Konkretnije, u odgojno-obrazovnom kontekstu Klaić (1982) određuje metodiku kao dio pedagogije koji govori o pravilima i metodama predavanja, a Anić i Goldstein (2000) kao dio pedagogije koji se bavi metodama poučavanja i predavanja u sustavu obrazovanja. Prema tim određenjima, metodika se često smatra kao područje unutar didaktike (Mijatović, 2000). Međutim, Mužić (2005) ističe kako potpunog suglasja nema te da dio znanstvene zajednice percipira metodike kao zasebne istraživačke discipline koje u kontekstu pojedinačnih predmetnih područja predstavljaju supstratnu znanost koja nije pozicionirana untar didaktike i/ili pedagogije.

Kako je na našim prostorima, povijesno gledano, u pedagogiji najveći utjecaj njemačke pedagogije, potrebno je prikazati u kakvom su odnosu određenja didaktike i metodike od strane njemačkih i naših didaktičara. Schleple (1974) definira didaktiku kao znanost o poučavanju i učenju koja obuhvaća sve teorije i metode nastave (što obuhvaća i medije) te ističe didaktiku u užem određenju kao područje izbora, izgradnje i određivanja redoslijeda znanstvenih sadržaja u nastavi. Metodiku navodi kao postupak prenošenja nastavnih sadržaja, odnosno kao dio didaktike.

Tako i Klafki (1976) određuje didaktiku (njem: Fachdidaktik) kao teoriju nastave što također implicira na metodiku kao dio didaktike u kontekstu istraživanja različitih oblika poučavanja i učenja. Mužić (2005) pritom tvrdi kako pojam i naziv metodike u našoj suvremenoj strukovnoj i znanstvenoj literaturi s područja odgoja i obrazovanja nije upitan zbog čega je i prihvaćeno određenje metodike kao interdisciplinarne znanosti u kojoj su osnovne (premda ne jedine) polazne discipline supstratne znanosti, odnosno njihova područja s jedne te područja odgoja i obrazovanja s druge strane. Međutim, položaj strukovnih didaktika nije jednoznačno određen u znanstvenim i teorijskim promišljanjima (Gudjons, 1994), a što je

ponajviše razvidno iz različitosti didaktika i metodika na našim učiteljskim i nastavničkim fakultetima koje su se na mnogim fakultetima afirmirale kao neovisne discipline primarno utemeljene na supstratnoj znanosti, a to je naročito karakteristično za studije iz spektra prirodnih i tehničkih znanosti. (*U kontekstu nastave matematike problem klasifikacije strukovnih didaktika i metodika detaljnije će se prikazati u poglavlju 2.2.1.1.*)

Kako je područje matematičkog obrazovanja (eng. *Mathematics Education*) dominantno pokriveno istraživačkim i teorijskim radovima u engleskom govornom području, pripadna terminološka određenja didaktike i metodike imaju slične specifičnosti neovisno o govornim područjima. Dakle, u engleskom govornom području didaktika je konzistentna s njemačkim određenjem i određenjem unutar naših teorijskih razmatranja (eng. *didactics*), a terminološko određenje metodike opet je specifično te se uglavnom navodi kao *instructional methods* ili još češće kao *instructional design* (Seels i Glasgow, 1998; Branch i Kopcha, 2010; Khalil i Elkhider, 2016).

Primarni interes metodike jest oblikovanje konkretnih nastavnih sadržaja na način da ih učenici mogu usvojiti stjecanjem odgovarajućih znanja i razvijanjem za to potrebnih vještina. *Pod metodikom nastave podrazumijeva se cjelokupnost pojedinačnih metoda za postizanje cilja učenja. Svaka pojedinačna metoda trebala bi učeniku omogućiti da brzo, bez okolišanja i u potpunosti ostvari cilj učenja. Pri tome se proces učenja u pravilu razlaže u pojedine korake, a svakom se koraku pridružuje određena metodička mjera. Pojedinačna nastavna metoda za učenika pomoć je u učenju i obuhvaća sve aspekte koji se odnose na optimalni postupak za postizanje cilja učenja* (Aschersleben, 1986, str.18;). *Metodičko djelovanje podrazumijeva cjelokupnost svih aktivnosti koje se neposredno odnose na oblikovanje i prilagođavanje određenih situacija učenja ili pak na njihove posljedice, odnosno područja učenja* (Schulze, 1978, str.34; prema Terhart, 2001).

Barth (2004) metodičku pripremu budućih nastavnika (učitelja) temelji na upoznavanju širokih didaktičkih modela koji bi se primjenjivali i provjeravali u stvarnom kontekstu i kasnije procjenjivali s obzirom na uspjeh njihove primjene. Didaktički modeli vezani su uz pothvate i oblikovanja u praksi, uz djelovanje, neposredno planiranje te uz procjenu odgovornosti u nastavi (Gudjons, 1994).

Temelj suvremene didaktike čine sljedeće teorije, odnosno didaktički modeli:

1. Didaktika kao teorija obrazovanja u okviru kritičko-konstruktivne znanosti u odgoju. (Wolfgang Klafki)
2. Didaktika kao teorija kurikuluma. (Christina Moller)
3. Didaktika kao teorija učenja. (Wolfgang Schulz)
4. Didaktika kao kibernetičko-informacijska teorija. (Felix von Cube)
5. Didaktika kao kritička teorija nastavne komunikacije. (Rainer Winkel)

U didaktici kao *teoriji obrazovanja* Klafki (1969) propituje opću smislenu ili predmetnu povezanost predmetnih sadržaja, značenje određenih sadržaja za spoznaje koje se iz njega izvode te o njegovoj relevantnosti za budućnost učenika (prema Kiper i Mischke, 2008). U fokusu ovog modela jest obrazovanje u širem smislu te riječi. Pod *kritičkim* se misli na osposobljavanje učenika za rastuće sposobnosti samoodređenja, suodređenja i solidarnosti, uključujući smanjenje ometajućih čimbenika. *Konstruktivno* ukazuje na praktični aspekt koncepta, na njegove interese djelovanja, oblikovanja i promjene. Svojim pojmom obrazovanja, Klafki dotiče pitanja poput mira, pitanja okoliša, zemalja u razvoju, političkih i društvenih nejednakosti te informacijsko-tehnologijskih opasnosti i mogućnosti na koje se može osloniti današnje obrazovanje. Prema Klafkiju, sveza učenja i poučavanja interakcijski je proces u kojem onaj tko uči samostalno usvaja spoznaje i stječe sposobnosti uz potporu učitelja (Gudjons, 1994). Klafki smatra kako učenje mora biti smisleno, razumijevajuće te kako u proces učenja trebaju biti umetnuti oblici vježbanja, ponavljanja i sl. Što se tiče nastave, Klafki smatra kako nastava mora biti diskurzivno pripravljena i planirana, odnosno mora doći do suplaniranja nastave s učenicima, do zajedničke kritike nastave, do nastave orijentirane na učenika. Za njega je didaktička analiza osnova didaktičke pripreme koja pomaže u donošenju odluka o pitanju izbora nastavnih sadržaja, ali je neznatna pomoć u organizaciji procesa učenja.

U nastavi matematike ovaj model ima velik potencijal za unapređenje kvalitete procesa učenja i poučavanja. Koristeći svoje komunikacijske vještine, nastavnik može potaknuti buđenje interesa učenika čime ih osposobljava za samostalno učenje. To primarno ovisi o percepciji matematike od strane nastavnika te od osobnih karakteristika koje utječu na stil vođenja razreda i na odnos nastavnika s učenicima. Stoga se u didaktici kao teoriji obrazovanja utjecaj nastavnika može sagledavati u kontekstu njegove osobne biografije koju unosi u proces učenja i poučavanja. Naime, iskustva koje je nastavnik imao kada je i sam bio učenik te sklop svih iskustava i uvjerenja koje je izgradio kroz studij i rad u nastavi oblikovala su njegovu percepciju matematike. To se odnosi na procjenu važnosti matematike kao znanosti u svijetu

kroz prošlost, kakva je ta uloga u sadašnjosti te kakva će biti u budućnosti. Kroz taj aspekt može se učiniti značajan iskorak u isticanju primjenjivosti matematike što može imati značajan motivacijski učinak na učenike koji, ukoliko su upoznati sa svekolikim područjima života, djelatnosti i znanosti u kojima se matematike primjenjuje, mogu biti pozitivno potkrepljeni za učenje matematike. S time njihov trud i rad na određeni način dobivaju „viši“ smisao, a za učenike boljeg uspjeha osnovnoškolskog uzrasta to može rezultirati i nekim novim ili pojačanim obrazovnim aspiracijama koje su ponekad obilježene i pozitivnijom percepcijom vlastitih kvaliteta nastalih uslijed svojevrsnog poistovjećivanja s matematikom ili s postignućima kojima je matematika doprinijela društvu.

U užem smislu realizacije ovog didaktičkog modela Klafki (1969) smatra kako nastavnici u svojoj pripremi trebaju promišljati o različitim načinima kako učenicima posredovati obrazovne sadržaje te se pitati o općoj smisaonoj ili predmetnoj povezanosti odabranih sadržaja, o značenju odabranih sadržaja za spoznaje koje se izvode iz njih i o njihovoj ulozi u budućnosti učenika. U skladu s time tvrdi: *Što je neki obrazovni sadržaj i u čemu leži njegova obrazovna vrijednost ili značenje, moguće je, prvo, reći samo s obzirom na određenu djecu i mlade koje treba obrazovati i, drugo, samo s obzirom na određenu povijesno-duhovnu situaciju, […]*. (Klafki, 1969, str. 11; prema Kiper i Mischke, 2008). U ovakvom pristupu prema nastavnom procesu te pored obrazovnih sadržaja i kritičnosti prema istima, nastavnici mogu ponuditi intimniji dio sebe, otvoriti se vlastitim iskustvima u školovanju i, među ostalim, ostvariti pedagoški odnos s učenicima koji je pretpostavka realizaciji obrazovnih ishoda.

Nastavnici, koji ostvaruju ovaj aspekt svojega rada, na raznovrsnim sadržajima imaju *mogućnost* otvoreno pričati s učenicima o nekim sadržajima, komentirati je li nešto teško i dosadno i/ili naizgled nesvrhovito, ali i istaknuti zašto je bitno i vrijedno te kako nemaju svi sadržaji isti karakter i ulogu, no ipak su podjednako bitni dijelovi šire cjeline. Tako, na primjer, nastavnici u srednjim školama u kontekstu svoje profesionalne autonomije mogu zajedno s učenicima komentirati i kritički se osvrnuti na pojedine sadržaje predviđene nastavnim planom i programom te donositi odluke o odabiru i/ili pristupu ponekim sadržajima ovisno o karakteristikama razrednog odjela i specifičnostima odgojno-obrazovnih programa koje ti učenici pohađaju. Pretpostavka jest kako su učenici srednjih škola zbog već relativno visoke razine emocionalnog i kognitivnog funkcioniranja, s obzirom na učenike osnovnih škola, u stanju i vlastoručno davati konstruktivne kritičke osvrte te naposljetku cijeniti takav pristup nastavnika što može rezultirati povećanim poštovanjem prema nastavniku, pa i motivacijom za učenje. Na konkretnom primjeru, uvođenje algebarskih razlomaka u prvom razredu srednje škole uglavnom počinju značajnije teškoće u učenju matematike kod učenika srednjoškolske

dobi. U motivacijskom pristupu sadržajima iz tog poglavlja nastavnik može (prema prethodnim iskustvima) unaprijed izraziti kritičko stajalište te najaviti kako naredno poglavlje ima specifičan karakter zato što je u središtu vježbanje određenih pravila i procedura te kako isto nema konkretnih primjena u svakodnevici, ali je neizostavan dio u mnogim bitnim sadržajima koji možda imaju nešto zanimljiviji karakter ili je često primjenjivano u drugim predmetima i znanostima (fizika, kemija, biologija, tehnički predmeti i sl.). Pritom je potrebno istaknuti prirodu matematike kao struke i znanosti koja je dominantno obilježena deklarativnim konceptualnim te proceduralnim znanjima koja često zajedno čine neodvojiv dio ishoda učenja u nastavi matematike te kako je za uspjeh u matematici potrebno njegovati i razvijati oba vida matematičkih znanja i vještina

S druge strane, neki nastavnici taj didaktički model često svode na ciljeve učenja te tako vrijednost obrazovnih sadržaja svode, a ponekad i autoritarno opravdaju kumulativnošću znanja. Iako je kumulativnost znanja neizostavan i veoma bitan aspekt nastave matematike, u kontekstu motivacije većeg broja učenika to nije dostatno zato što se kao dominantna karakteristika matematičkih sadržaja s vremenom razvija u jedan od momenata nastave koji više doprinose izostanku interesa, nego poticanju motivacije za učenje. Razlog tome primarno je u opsežnim nastavnim planovima i programima koji određuju dinamiku rada nastavnika na način da se većina nastavnika opterećuje s realizacijom istih, a usmjerenost na ciljeve i obrazovne ishode učenika pozicionirali su na sporedno mjesto u nastavnom procesu. Neki su od tih nastavnika stoga više usmjereni na ciljeve učenja što je temeljno obilježje sljedećeg didaktičkog modela.

Didaktika kao *teorija kurikuluma* didaktički je model orijentiran na odgojno-obrazovne ciljeve. Ovaj model često se navodi i kao didaktika usmjerena na ciljeve učenja (Kiper i Mischke, 2008). Prema ovom modelu, didaktika je teorija o postizanju određenih kvalifikacija putem kvalitetnog i ciljno usmjerenog nastavnog procesa. Pod pojmom *kurikuluma* podrazumijeva se i sustav postupaka učenja u vezi s definiranim i operacionaliziranim ciljevima učenja, a tu spadaju: ciljevi učenja kojima treba težiti, sadržaji, metode, situacije (kao što su grupiranje sadržaja i metoda), strategije i vrednovanje. Razvoj kurikuluma (odnosno nastavnih jedinica) odvija se u tri dijela, a to su planiranje nastave, organizacija nastave i kontrola nastave. Kod nastavnog planiranja od brojnih izvora sabire se što je moguće obuhvatnije mnoštvo nastavnih ciljeva za nastavnu jedinicu, a ciljevi se zatim razvrstavaju hijerarhijski. Doprinos didaktike usmjerene na ciljeve učenja jest u isticanju važnosti formuliranja ciljeva nastave, u određivanju kriterija na kognitivnom, afektivnom i motoričkom području te o uvođenju stupnja intenziteta kojim treba ovladati učenjem (Keck, 1975). Najpoznatija taksonomija potječe od

Benjamina S. Blooma koji je nastavne ciljeve razvrstao na kognitivno, afektivno i psihomotorno područje ponašanja. Taj model obrazovanja osnova je većine obrazovnih sustava i politika diljem svijeta, pa i u našem odgojno-obrazovnom sustavu. U nastavi matematike, kao i u ostalim predmetnim područjima, takav pristup obrazovanju ponajprije je postavio okvire, ali kako je razvidno iz osvrta na model didaktike kao teorije obrazovanja, ovaj model ne može se pokazati optimalnim za opći razvoj učenika ukoliko u tim okvirima učenik nije razmatran sa stajališta suvremenih spoznaja didaktike i pedagogije. Temeljna obilježja ovog modela su normiranost i standardiziranost u gotovo svim segmentima kurikuluma kojem je primarni cilj propisati, evaluirati i procjenjivati učenička postignuća, a samim time i kvalitetu nastave te kompetencije nastavnika. Mnogi autori (npr. Bašić, 2007, Palekčić, 2007) iz područja pedagogije ukazuju na nedostatke ovakvog pristupa obrazovanju, a detaljniji osvrt prikazat će se u poglavlju 2.2.2 pod naslovom *Odgojno-obrazovni standardi nastave matematike*.

Didaktika kao *teorija učenja*, poznata i kao *berlinska didaktika*, usmjerena je na spoznaju nastavnog procesa unutar kojeg se didaktika shvaća kao teorija nastave, a nastava kao mjesto gdje se neriješena pitanja ukupne didaktičke situacije pojavljuju kao konkretni problemi učenja i poučavanja koje valja riješiti (Kiper i Mischke, 2008). Isti autori ističu kako su Heinman i Schulz u ovom konceptu postavili didaktiku kao teoriju nastave te stoga nastavu nastoje pozicionirati na način koji će omogućuiti vrijednosno neutralno teorijsko razmatranje nastave na kategorijalno-analitičkoj osnovi. Pritom se navodi šest strukturnih momenata nastave koji u svom uzajamnom djelovanju konstituiraju nastavu kao svrsishodno pedagoško zbivanje: pedagoške intencije (namjere), teme nastave (sadržaji, predmeti), namjere i metode (postupci) koje trebaju služiti svladavanju tema i realizaciji intencija te mediji (sredstva) sporazumijevanja između sudionika nastave o namjerama, predmetima i postupcima (Schulz, 1994). Predstavnici berlinske didaktike predložili su strukturno planiranje nastave u sljedećim koracima:

- antropogene pretpostavke kao činjenice o stupnju informiranosti i mišljenju određene skupine učenika o nastavnoj jedinici
- socijalno-kulturne pretpostavke
- intencije
- tematski slijed
- preferirani mediji.

(Kipper i Mischke, 2008; prema Schulz, 1994).

Prema navedenom teorijskom modelu didaktičko djelovanje ima cilj uspješno sporazumijevanje učitelja i nastavnika s učenicima o: nastavnim ciljevima, polazišnim situacijama u nastavnom procesu, čimbenicima posredovanja znanja pomoću kojih se ostvaruju nastavni ciljevi te o kontrolama uspješnosti nastavnog procesa koje učenicima i učiteljima omogućuju samoregulaciju u nastavnoj komunikaciji. U takvim postavkama odgoj se smatra dijalogom između djelujuće sposobnih subjekata, a ne kao podvrgavanje nekog nastavnog i odgojnog objekta namjerama učitelja ili odgajatelja (Gudjons, 1994). Didaktika kao teorija učenja nastala je u trenutku kada u psihologiji još nije bilo riješeno sporno pitanje između biheviorističkih teorija učenja i kognitivnih teorija pa je Gagne (1971) predložio da se iste uvedu kao kontinuum što je rezultiralo time da se u takvoj didaktici govori o učenju bez da se pokazuje kako se stvarno uči (Kipper i Mischke, 2008). Nastava se u takvoj kategorijalnoj analizi pokazuje kao posebno strukturirano (inter)akcijsko polje unutar kojeg treba donijeti jednoznačne odluke za određene nastavne ciljeve, sadržaje, postupke i medije, a uloga teorije jest samo u pojašnjavanju nastavnih odluka o utvrđivanju realnih i optimalnih čimbenika koji u njima sudjeluju (Heinmann, 1968; prema Kipper i Mischke, 2008). To na svojevrstan način ponovno dovodi do propisivosti i standardizacije u kojoj se nastavni proces smatra statičnim sustavom, a učenici kao subjekti u nastavi koje se tretira provođenjem unaprijed zacrtanih metoda i odluka u nastavi. U okvirima didaktike kao *kibernetičko-informacijske teorije* učenje i poučavanje događa se vođenjem, stalnim usmjeravanjem uz neprestano ispravljanje. Prema ovom je modelu didaktika znanost i tehnika optimalnog ostvarenja programiranih, unaprijed postavljenih ciljeva nastave na temelju poznavanja polazišne situacije učenika.

U ovom modelu nastava i obrazovanje mogu se shvatiti kao upravljani sustav u kojem nastava, učenje i samo obrazovanje podliježu određenim zakonitostima sustava. Prema ovom modelu, proces obrazovanja u osnovi je proces vođenja učenika i postizanje određenog cilja učenja. Intencija je pritom da se proces učenja i nastava pojednostavne u procedure od nekoliko etapa kojima bi postigli zadane ciljeve. Pobornici ovog modela (Cube, Frank i Mayer) smatrali su kako se procesi učenja mogu pojednostaviti, tj. svesti pod forme ulaza, prerade i kontrole prerade informacija. Gudjons (1994) je analizom nastave prema kibernetičkom modelu opisao regulacijski krug u nastavi u kojem se prvo određuje nastavni cilj, a nastavnik slijedi određenu nastavnu strategiju kako bi postigao nastavni cilj. Međutim, isti autor ističe kako se pri razvijanju obrazovnih strategija javlja više problema kao što su specifična karakteristična djelovanja i poremećajne veličine koje se stalno mijenjaju i sastavni su dio nastavnog procesa. Kibernetički model svodi se na učitelja kao voditelja sustava, učenika kao objekt upravljanja te uređaj kao tehničko sredstvo. U kontekstu nastave matematike ovaj model odnosio bi se na niz

propisanih obrazaca nastavne prakse koji bi uključivali različite načine ponašanja i snalaženja nastavnika u predvidivim nastavnim situacijama, odnosno algoritmizaciju nastavnih metoda. Nastavni proces tako je sveden prema paradigmi pozitivizma na nekoliko poznatih varijabli (što isključuje sve one poremećajne veličine nepredvidivosti nastave i specifičnosti svakog razrednog odjela) na temelju kojih se funkcionalno mogu propisati optimalni obrasci nastavnog djelovanja što reducira dimenzionalnost i kompleksnost nastavnog procesa. Ovaj model, kao i model didaktike kao teorije učenja, može imati značajan doprinos ukoliko se za pojedine metode, refleksije i evaluacije nastavne prakse u brojnim specifičnim situacijama provedu istraživanja koja bi unaprijedila spoznaje i/ili potvrdila valjanost određenih metoda. Međutim, iste opet mogu poslužiti samo kao okvir ili dio repertoara (ovisno o njihovoj praktičnoj i teorijskoj utemeljenosti) koji će biti na raspolaganju nastavnicima kako bi bili što fleksibilniji u brojnim situacijama koje će ih snaći u praksi.

Na osnovi različitih prednosti i nedostataka navedenih didaktičkih modela, proizašao je model didaktike kao *kritičke teorije nastavne komunikacije* (Gudjons i sur., 1992). Kritičko-komunikativna didaktika nastoji pomoću analiza zahvatiti složenost nastave te jasno odrediti faktore i sastavne dijelove nastave. Nastoji ustanoviti zakone i planove nastavnih procesa te ih kritički upotrijebiti u svrhu stalnog poboljšavanja nastave. Školski sat shvaća se kao komunikacijski proces u kojem istu ulogu i važnost imaju sadržaj i odnos učenik-učenik te učenik-nastavnik. Nastavna jedinica oblikovana je komunikacijskim djelovanjem što uključuje: razgovor, govorno izražavanje, dijalog, pitanja, interakciju. Kritičko-komunikativna didaktika, kao analiza i planiranje nastavnih procesa učenja i podučavanja, ne suprotstavlja se polemički ostalim četirima teorijama/modelima, već njihove jednostranosti i ograničenja uzima kao poticaj svojim nastojanjima u svrhu kako bi se bolje shvatila praksa školskog djelovanja. Ovaj didaktički model/teorija jedini je model koji problem analize i planiranja isprepliće tako da norme postaju suvišne te da se umjesto njih planiranje odvija iz analize. Kritičko-komunikativna didaktika usmjerena je na učenike te oni nastupaju kao ravnopravni sudionici u procesu nastavne komunikacije. Jedna je od središnjih stavki analize i planiranja i podložnost smetnjama koja je karakteristična za svaku nastavu. Ovaj model shvaća poučavanje i učenje kao solidarni način ljudske emancipacije te se oslanja na kritičku teoriju škole i odgoja (Gudjons i sur., 1992).

Prema navedenim modelima mogu se izdvojiti pedagoška težišta općeg didaktičkog nastojanja, a to su: koncepcija i smisaona struktura nastavnog sata, ciljevi i sadržaji koji su u međusobnoj ovisnosti, učenicima i sadržaju prikladne metode, mogućnosti didaktičke analize, teorija didaktičkih medija te mjere kontrole učenja (Garmaz, 2005). Međutim, nerijetko postoji

preveliki stupanj dihotomije između konkretne odgojno-obrazovne prakse i načina njezinog istraživanja (Šagud, 2006), a to se naročito tiče didaktičkih teorija i njihovog suvremenog tumačenja i primjene u suvremenom obrazovanju. To je još izraženije u slučaju predmetnih metodika unutar kojih nedostaju istraživanja koja imaju u središtu različite izazove iz prakse kojima bi dali odgovore ili potencijalna rješenja u teorijskim i praktičnim aspektima učenja i poučavanja razumljivima i upotrebljivima za praktičare. U užim područjima obrazovanja, odnosno u pojedinim predmetnim područjima, iskorak od navedenih modela stoji na predmetnim didaktikama i metodikama koje se tek trebaju afirmirati kao znanstvene discipline koje istražuju i unaprjeđuju odgojno-obrazovnu praksu te proširuju teorijske spoznaje o nastavi.

2.2.1.1 Didaktika i metodika nastave matematike

Metodika nastave matematike predstavlja znanstvenoistraživačku i razvojnu disciplinu čiji je cilj identificirati, okarakterizirati i razumjeti pojave i procese koji se javljaju ili bi se mogli javiti u učenju i poučavanju matematike na bilo kojem stupnju obrazovanja. S obzirom na to da se didaktika bavi učinkovitošću nastavnog procesa te traga za uspješnim metodama poučavanja, često je se naziva „opća metodika“ pa stoga metodika nastave matematike u tom kontekstu ima funkciju primijenjene didaktike (matematike). Didaktika nastave matematike pritom ujedinjuje pitanja opće didaktike sa specifičnostima nastave matematike i aspektima učenja i poučavanja matematike. Prema tome, metodika nastave matematike disciplina je koja primjenjuje didaktička načela, zakonitosti i metode svojstvene nastavi matematike i matematici kao znanosti te pritom razmatra pretpostavke važne za poučavanje i učenje matematike, učenikov razvoj i utjecaj nastavnika na učenje matematike.

Glavna područja istraživanja su razvoj i implementacija kurikuluma, metode poučavanja i učenja matematike te vrednovanje postignuća, odnosno rezultata učenja. Didaktika i metodika nastave matematike zahtijevaju visok stupanj interdisciplinarnosti, no unatoč tome prisutna je dominantna utemeljenost u supstratnoj znanosti (matematici) te se ista nedostatno povezuje sa znanstvenicima iz društvenog i humanističkog područja (pedagozi, psiholozi, sociolozi, antropolozi i dr.) koji pored općeg teorijskog i istraživačkog rada u vlastitim disciplinama često istražuju specifične fenomene iz područja matematičkog obrazovanja.

Didaktika i metodika osnova su inicijalnog obrazovanja nastavnika na sveučilištima te su ishodište profesionalnog razvoja koje treba biti komplementarno s napredovanjem

nastavnika sukladno aktualnim obrazovnim društvenim, političkim, socijalnim, ekonomskim i drugim čimbenicima koji impliciraju profesionalne i osobne kompetencije praktičara. Obrazovanje nastavnika temeljna je pretpostavka kvalitetnog odgojno-obrazovno sustava te je podizanje kvalitete njihova obrazovanja imperativ u procesu cjeloživotnog učenja. Nastavnici stječu znanja i vještine u predtercijarnom sustavu obrazovanja te su istovremeno okosnica kvalitete istog tog sustava. Obrazovanje nastavnika u složenom je međuodnosu sa svim segmentima društva u kojem se nastavnici, kao produkt već zastarjelog odgojno-obrazovnog sustava, moraju prilagoditi novim idejama i smjernicama kako bi ostvarili ideje suvremenog odgoja i obrazovanja. Odgojno-obrazovna politika pritom mora osigurati uvjete unutar kojih će se realizirati težnje suvremenih odgojnih i obrazovnih znanosti. Od posebnog značaja u obrazovanju nastavnika su: selekcija studenata pri upisu, plan i program nastavničkih studija, program profesionalnih usavršavanja i mogućnost napredovanja u struci. Trenutno se čini kako je još uvijek izražen diskontinuitet između inicijalnog obrazovanja praktičara i zahtjeva suvremene prakse, a to se, među ostalim, očituje u nedostatku didaktičara i istraživača u području nastave matematike. Stoga se kao nužnost inicijalnog obrazovanja pokazuju inovativne obrazovne strategije, provođenje relevantnih i za praksu vrijednih istraživanja, visoka razina djelovanja, učinkovitosti i kvalitete odgojno–obrazovnih ustanova na svim razinama obrazovanja. Nastavnici svoje kompetencije izgrađuju i razvijaju tijekom fakultetskog obrazovanja, daljnjim stručnim usavršavanjem i konstantnim radom na sebi. Rad s učenicima iziskuje stalno usavršavanje nastavnika budući da nastavnici dugi period svog profesionalnog života provode u školi. S druge strane, ukoliko tijekom inicijalnog obrazovanja budućih nastavnika i učitelja ne razvijemo potrebne kompetencije i kapacitete, oni će ulaskom u odgojno-obrazovnu praksu imati teškoće u snalaženju u složenim uvjetima nastavne prakse. Polazište je u pristupu kompetencijama nastavnika njihova izobrazba i kontinuirani profesionalni razvoj, odnosno osuvremenjivanje stečenih kompetencija. S druge strane, nastavnici matematike nemaju mogućnost poslijediplomskog usavršavanja u svojoj struci, a didaktičari/metodičari koji ih poučavaju imaju kvalifikacije znanstvenika jedino u supstratnoj znanosti. Teorijska i znanstvena podloga obrazovanja nastavnika na svim se razinama utemeljuje u predmetnim didaktikama, ali njihov položaj i prioriteti u znanstvenoj zajednici nisu jasno određeni u sustavno-znanstveno sistematskom poretku strukovnih didaktika (Lenzen, 1989; prema Gudjons, 1994). Pritom je potrebno razjasniti pripadaju li strukovne didaktike/metodike supstratnoj znanosti ili znanosti o odgoju te trebaju li prema tome didaktičari/metodičari nastave matematike zbog pedagogijskog problematiziranja u struci posjedovati i kvalifikaciju znanstvenika odgoja pa makar samo u kontekstu nastave

matematike? Time se implicira pitanje kvalifikacija stručnjaka koji obrazuju nastavnike te položaj i odnos strukovnih i općih didaktika što je Lenzen (1989) istaknuo kao jedno od otvorenih pitanja pedagogije. Naime, predmetne didaktike nisu našle svoje mjesto na svim fakultetima odgojnih znanosti, već su pridružene studijima pojedinih predmeta (Plöger, 1992) zbog čega se opća i predmetna didaktika sve više udaljavaju jedna od druge (Kiper i Mischke, 1999) što je i slučaj mnogih naših nastavničkih studija. Pitanje koje se odnosi na pripadanje strukovne didaktike/metodike supstratnoj znanosti ili znanosti o odgoju ne donosi jednoznačan odgovor, no poznavanje specifičnosti zahtjeva i problema u određenim predmetnim područjima može omogućiti iskorak iz uobičajenih poimanja dotične problematike. Tako primjerice u Sjedinjenim Američkim Državama postoje doktorski studiji za nastavnike matematike, ali se općenito smatra kako je već nedostatak standardiziranih programa za te studije u području matematičkog obrazovanja možda i najveći izazov u intencijama poboljšanja nastave matematike (Hiebert i ostali, 2001). Poslijediplomsko obrazovanje u području metodike nastave matematike u Republici Hrvatskoj još je u povojima pa se tek razvojem doktorskih studija u području nastave matematike mogu očekivati značajniji pomaci u didaktici i metodici nastave matematike. U dokumentu *Green Paper* naglašava se kako je potrebno preispitati relevantnost izdvajanja pojedinačnih didaktika i integracijom pojedinih područja ostvariti ciljeve koncepta cjeloživotnog učenja. Što se tiče nastave matematike i pedagoških izazova s kojima se susreću nastavnici matematike, svakako se mora razmatrati mogućnost osposobljavanja u praktičnom i znanstvenom usmjerenju s naglaskom na povezivanje pedagogijske teorije s nastavom matematike i problematičnim područjima matematičkog obrazovanja.

Sukladno tome, didaktičari/metodičari nastave matematike trebali bi, zbog količine pedagogijskog problematiziranja u struci, posjedovati znatno više pedagogijskih znanja zato što jedino ona daju znanstveno utemeljena polazišta i legitimnost područja didaktike matematike. Za sada se unutar formalnog profesionalnog obrazovanja i u okviru formalnih programa još uvijek premalo pažnje posvećuje razvijanju istraživačkih kompetencija budućih nastavnika koje su temelj kasnijeg autonomnog istraživanja prakse, ali i lakšeg snalaženja u različitim izazovima nastavnika početnika. Naime, praktičari mnoge izazove rješavaju kreativnim snalaženjem i refleksijom vlastite prakse, a to je veoma zahtjevno za nastavnike početnike zato što znaju kako i iskusniji nastavnici stalno nailaze na nove izazove te su svjesni kako nema općevrijedećih postupaka i metoda učinkovitih u radu s različitim razrednim odjelima. Zbog toga svako odstupanje između očekivanja budućih praktičara i njihovih trenutačnih kapaciteta i sposobnosti može uzrokovati niz izazovnih i stresnih situacija. Sintezom navedenoga možemo

utvrditi kako se kao najveći potencijal za unapređenje područja metodike i didaktike nastave matematike pokazuje u:

- interdisciplinarnom inicijalnom obrazovanju nastavnika matematike
- stručno-metodičkom i pedagoškom usavršavanju nastavnika matematike
- mogućnosti poslijediplomskog obrazovanja u području metodike nastave matematike.

Jedan od predstojećih izazova didaktike i metodike matematike jest nedostatan broj istraživača koji aktivno djeluju u tom području zato što je za osiguravanje inicijalnih koraka u koncepciji doktorskih nastavničkih studija nužno osigurati dostatan broj stručnjaka kojih nedostaje u okvirima našeg relativno malog sustava znanosti i obrazovanja. Oni su također preduvjet osiguravanju kvalitete takvih studija, ali i inicijalnih ideja i smjerova u kojima bismo mogli razvijati didaktiku matematike kao znanstveno-nastavnu i istraživačku disciplinu.

2.2.2. Odgojno-obrazovni standardi nastave matematike

Temeljno obilježje Nacionalnog okvirnog kurikuluma (2010) prelazak je na kompetencijski sustav i učenička postignuća, odnosno na obrazovne standarde. Stručni izraz „obrazovni standardi“ nije inačica za ciljeve učenja, odnosno ciljeve odgoja i obrazovanja, nego je to naziv za novi oblik postavljanja ciljeva školskim procesima učenja i poučavanja (Bašić, 2007, str. 117). Kompetencije su skup znanja, vještina, sposobnosti i stavova koje s indikatorima usvojenosti čine odgojno-obrazovni standard (Vican, Bognar, Previšić, 2007, 171).

Temeljno svojstvo obrazovnih standarda su mjerljive kompetencije u pojedinim područjima, odnosno nastavnim predmetima. Obrazovni standardi odabiru se temeljem znanstvenog pristupa tako da se ključni elementi matematike kao znanosti didaktički transformiraju u nastavni predmet uvažavajući psihofizičke karakteristike učenika pojedine dobi te zahtjeve društva, obrazovanja, politike i gospodarstva. Standardi nastavnih sadržaja predstavljaju osnovu za učenje temeljem kojih učenici razvijaju znanja i sposobnosti te stječu vještine. Bašić (2007) ističe kako se: *iz međunarodnih iskustava može naučiti da školi nisu potrebni standardi kao instrumenti (ekonomske) konkurentnosti škola na tržištu i vanjske kontrole. Ona treba pedagoško-psihološki legitimirane, na suvremenim znanstvenim spoznajama utemeljene i kulturno individualizirane standarde kvalitetne škole, odnosno kvalitetne nastave* (Bašić, 2007, str.149).

U Nacionalnom okvirnom kurikulumu određena su očekivana učenička postignuća za odgojno-obrazovna područja po ciklusima te je naznačena predmetna struktura svakog od tih područja. Nacionalni okvirni kurikulum čini polazište za izradu školskih kurikuluma te za

izradu predmetnih kurikuluma temeljenih na razrađenim postignućima odgojno–obrazovnih područja. Učenje i poučavanje matematike uključuje stjecanje znanja, vještina i sposobnosti računanja, procjenjivanja te logičkog i prostornog mišljenja. U skladu s time koncipirani su opći odgojno-obrazovni ciljevi matematičkog područja:

- usvojiti temeljna matematička znanja, vještine i procese te uspostaviti i razumjeti matematičke odnose i veze
- razviti pozitivan odnos prema matematici, odgovornost za svoj uspjeh i napredak te svijest o svojim matematičkim postignućima
- osposobljenost za apstraktno i prostorno mišljenje te logičko zaključivanje
- osposobljenost za rješavanje matematičkih problema i primjenu matematike u različitim kontekstima, uključujući i svijet rada
- prepoznati i razumjeti povijesnu i društvenu ulogu matematike u znanosti, kulturi, umjetnosti i tehnologiji te njezin potencijal za budućnost društva
- učinkovito komunicirati matematička znanja, ideje i rezultate služeći se različitim prikazima
- učinkovito primjenjivati tehnologiju
- steći čvrste temelje za cjeloživotno učenje i nastavak obrazovanja.
  (Nacionalni okvirni kurikulum, 2010, str. 80)

Obrazovni standardi, kao instrument kurikuluma za postizanje zadanih mu ciljeva, pritom istodobno imaju funkciju i kriterija i cilja u čemu je bitno jasno odrediti/formulirati ciljeve učenja kako bi isti služili kao kriterij kvalitete nastave, odnosno učinkovitosti procesa učenja i poučavanja (Bašić, 2007). Ciljevi učenja polazna su osnova učitelju za planiranje, organiziranje i vođenje odgojno-obrazovnog procesa (Jurčić, 2012). Autor ciljeve dijeli na opće i posebne koji su usmjereni prema promjenama učenika u pogledu njihovih novih znanja, vještina, vrijednosti, stavova i navika koje su rezultat organiziranoga poučavanja i učenja svakog nastavnog sata, a ostvaruju se aktivnošću učenika, odnosno učenjem.

Uvažavajući raznovrsnost problema nastave matematike, u matematičkom području moraju se pobliže razmatrati standardi sadržaja i standardi razine postignuća. Oni se trebaju preispitati s aspekta nastavnog plana i programa, osobito po pitanju opsega i dubine obrade nastavnih sadržaja. S obzirom na kumulativnu izgradnju matematičkih znanja, jedno je od ključnih problema nastave matematike upravo određivanje razine usvojenosti matematičkih znanja i vještina kako bi iste bile primjenjive u novim sadržajima, ali i u jednoj općoj kompetenciji razmišljanja i modeliranja problema matematičkim konceptima i idejama. Prema

Poljaku (1991), s obzirom na kvalitetu znanja, redom razlikujemo sljedeće stupnjeve: znanje prisjećanja, znanje prepoznavanja, znanje reprodukcije, operativno znanje te stvaralačko znanje. Razina reprodukcije znanja upućuje na usvojenost znanja bez primjenjivosti što u kontekstu matematičke kompetencije, kojoj je temeljni cilj primjenjivost, ukazuje na potrebu za višom razinom znanja. Naime, operativno znanje podrazumijeva kvalitetu znanja kojom učenik vlada sadržajima s punim razumijevanjem te ih primjenjuje u daljnjim sadržajima.

Stoga je za nastavu matematike potrebno razraditi učenička postignuća ne samo po kriterijima škole, obrazovnog smjera, razreda te graduiranja ocjena, već se mora voditi računa o tome jesu li standardi postignuća usklađeni s primjenjivošću matematičke kompetencije koju želimo da učenici postignu. Prema tome, standardima razine postignuća moraju se jasno definirati minimalni kriteriji koji će za svakog učenika svake škole opisati razinu kompetencije koju učenik mora postići za ocjenu dovoljan. Za nastavu je matematike možda i najbitnije odrediti tzv. srednji standard koji se očekuje od većine učenika, a koji je nužan i dovoljan za razumijevanje daljnjih sadržaja određenih nastavnim planom i programom. Taj bi standard trebao biti određen cjelokupnošću matematičke kompetencije prema konceptu temeljnih kompetencija Europske unije. S obzirom na činjenicu kako mnogi učenici akumuliraju probleme u matematici već od početka školovanja, ne čudi što kasnije matematičke sadržaje ne usvajaju u željenom intenzitetu i ekstenzitetu znanja.

Tu je i uvijek aktualno pitanje treba li reducirati i/ili promijeniti nastavni plan i program kako bi bilo više vremena za produbljivanje kvalitete temeljnih znanja. S druge strane, potrebno je kritički preispitati u kojoj mjeri usavršavanje nastavnika i osuvremenjivanje njihovih metoda može pomoći unutar ciljeva nastavnih planova i programa prema kojima realiziraju svoju odgojno-obrazovnu praksu. Kako se kroz sustave vanjskog vrednovanja (npr. državna matura, PISA istraživanje) pokazuje da učenici ne postižu željenu kvalitetu i primjenjivost znanja, pitanje je kako postići kvalitetu znanja ako se ne smanji kvantiteta, odnosno opseg nastavnog plana i programa. Reforma obrazovnih sustava putem uvođenja obrazovnih standarda i kompetencija implicira i problem određenja uloge i funkcije nastave: Kako oblikovati nastavu kao sredstvo izgrađivanja kompetencija kod učenika znajući kako model nastave orijentirane prema kompetencijama nije teorijski utemeljen ni empirijski provjeren model nastave? Naime, u recentnim kurikulumima temeljno je polazište kvalitetne nastave u određivanju pristupa kojim je najbolje oblikovati nastavu kako bi bila učinkovita i izražena u postignućima učenika na svekolikim testiranjima. Dakle, ne obraća se pažnja na sam nastavni proces koji bi trebao osigurati samoobrazovanje učenika, poticati pojedinog učenika, ostvariti mogućnost za razvoj potencijala učenika, otvoriti prostor i mogućnost za napredovanje svakom od učenika, već se

najviše pažnje usmjerava na to da nastava osigura prijenos što više znanja i informacija na što veći broj učenika u što kraćem roku.

U izdvojenom mišljenju kritika na cjelovitu kurikularnu reformu matematičkog područja Mišurac-Zorica (2016) ističe kako je orijentacija u cijelom dokumentu ostala tradicionalno usmjerena na nastavne sadržaje, a bitno manje na procese, odnosno vještine koje bi matematikom trebalo razviti ili stavove koje matematikom stječemo. Također navodi kako je u reformi bio pristup da primjerice: *sve srednje škole koje imaju 3 sata matematike, neovisno je li riječ o strukovnoj školi ili gimnaziji, imaju isti program iz matematike. U ovu kategoriju škola spada na primjer jezična gimnazija, ali i brojne strukovne škole (tehničar za mehatroniku, odjevni tehničar, pomorski analitičar ili smjerovi iz sektora šumarstvo, prerada i obrada drva i slično).* Ovo nedvojbeno upućuje na nedostatak jednog sveobuhvatnog i metodološki utemeljenog pristupa po pitanju primjerenosti, suvremenosti i pedagogijske legitimnosti odabira nastavnih sadržaja za odgojno-obrazovne smjerove u kojima se učenici obrazuju. Naime, ako se zadani ciljevi ne mogu realizirati kroz aktualne nastavne planove i programe, tada se mora jednoliko analizirati usklađenost obrazovnih standarda s nastavnim planom i programom te s odgovarajućim osposobljavanjem nastavnika. Također treba proučiti suvremene didaktičke pristupe u nastavi općenito te ih na praktičnoj razini utemeljiti u kontekstu nastave matematike kako bismo mogli odrediti koje vještine i znanja nastavnici trebaju posjedovati.

Premda su od velike teorijske važnosti razmatranja o pojmu i podjeli nastavnih metoda, odgojnih načela, sukladnosti i pojedinih zadaća nastave s osobnim i sa širim ciljevima škole i društva, ipak se kod takvih problema rješenja u pravilu ne donose znanstvenim istraživanjem, nego sučeljavanjem raznih mišljenja, stavova ideoloških društvenih i/ili pedagoških polazišta (Mužić, 1999). Obrazovni standardi nastave matematike također su dijelom šire problematike s početnom točkom u matematici kao znanosti, vodeći se pedagoškim načelima i smjernicama suvremenog obrazovanja u didaktičkom pristupu nastavi matematike. Jasno strukturirani obrazovni standardi primarno su smjernice nastavnicima u planiranju i strukturiranju nastavnog procesa te model i kriterij pri provjeravanju i evaluaciji učeničkih postignuća. Tako će i nastavnici i učenici određenog uzrasta imati jasan kriterij kompetencija koje učenici moraju steći/postići.

Standardizacija učeničkih postignuća pritom se odnosi na realizaciju obrazovnih ciljeva nastave što se u matematici očituje u stečenim vještinama i sposobnostima logičkog mišljenja, zaključivanja te matematičke argumentacije u rješavanju različitih problema modeliranih kroz svakodnevne situacije i probleme. S druge strane, redukcija obrazovnih standarda na uži pojam

„standardi učeničkih postignuća“ nema pedagošku intenciju i protivna je osnovnom zahtjevu suvremenog obrazovanja, zahtjevu za individualizacijom, a ne standardizacijom (Bašić, 2007, str.150). Zato u nastavi matematike posebnu pažnju treba posvetiti pedagoškim aspektima matematičkih kompetencija te njihovim intelektualnim, radnim, estetskim i moralnim dimenzijama. Matematika se kao znanost i nastavni predmet vodi općim načelom znanstvenosti i načinom razmišljanja koje je sastavni dio znanosti i svakodnevnog života. Stoga je kroz nastavu matematike potrebno razvijati svekolike vještine i sposobnosti te razumjeti matematiku kao praktičnu znanost čije dimenzije znanja i vještina sežu daleko izvan okvira njezina područja proučavanja i djelovanja. Pritom je bitno razvijati/njegovati pozitivan stav prema matematici i odgovornost za vlastiti napredak što je temelj stjecanja/razvoja samopouzdanja ne samo u matematici, nego i ostalim predmetima, kao i za izazove koji ih čekaju u životu.

Učenici koji imaju teškoće u učenju matematike imaju probleme u predznanju, posjeduju negativna uvjerenja i stavove o matematici slijedom čega podcjenjuju svoje sposobnosti. Međudjelovanjem tih okolnosti i nepovoljnih čimbenika iz školske i obiteljske okoline, učenici razvijaju animozitet prema matematici te nisu motivirani za učenje matematike već od početka osnovne škole. Navedene okolnosti i situacije isprepletene su emocijama učenika i emocionalnim reakcijama prema svim subjektima odgojno-obrazovnog procesa. Pekrun je (2006), uz emocionalne reakcije u nastavi, uveo termin „akademske emocije“ koje se odnose na emocije usko vezane uz nastavni proces, odnosno učenje, poučavanje i učenička postignuća. U nastavi matematike iste se očituju u emocijama koje učenik povezuje s matematikom i uvjerenjima o matematici te u odnosu učenika prema matematici. Poznato je kako je dominantna emocija u nastavi matematike upravo strah od matematike.

Međutim, prema prijedlogu kurikuluma od strane ekspertne skupine (2016), u dokumentu kurikuluma za vrednovanje jasno se ističe kako je osnovna svrha svih vrednovanja unapređivanje učenja i razvoja učenika, a temelji se na cjelovitome pristupu praćenja i poticanja individualnoga razvoja učenika te ga se usmjerava na prepoznavanje uspjeha i poticanje pozitivnih obrazaca motivacije i učenja. Prema elementima vrednovanja, iz istog dokumenta ističu se tri pristupa vrednovanju učeničkih postignuća i napredovanja: vrednovanje za učenje, vrednovanje kao učenje i vrednovanje naučenoga.

Naprotiv, u istom dokumentu stoji kako je: *Zaključna (pr)ocjena jest najučinkovitija i najvaljanija mjera kad odražava usvojenost odgojno-obrazovnih ishoda, a ne i neke druge, inače vrlo važne, elemente učenikova ponašanja: njegovu suradljivost, ulaganje truda, pohađanje nastave, sudjelovanje na nastavi, urednost i sl. O tim elementima je potrebno izvješćivati zasebno, osim ako su oni direktno ugrađeni u odgojno-obrazovne ishode predmeta.*

Upravo zbog toga što zaključne (pr)ocjene same ne mogu obuhvatiti sve navedene aspekte učenja, kombiniramo ih u svjedodžbi s kvalitativnim osvrtom na postignuća i napredovanja učenika (u 1. i 2. ciklusu) ili s ljestvicama procjena u kojima se zahvaćaju ti važni aspekti: učenikova odgovornost, samostalnost i samoinicijativnost, komunikacija i suradnja (procjena generičkih kompetencija u 3., 4. i 5. ciklusu (str. 27).

Iako se različitim dokumentima prijedloga kurikuluma (2016) ističe važnost pedagoškog pristupa u ocjenjivanju i vrednovanju, prisutna su mnoga proturječja po pitanju obrazovnih, odnosno odgojno-obrazovnih standarda. Prema ranije navedenom prijedlogu kurikuluma o vrednovanju u kontekstu zaključne (pr)ocjene postavlja se pitanje za koga je ta mjera najučinkovitija i najvaljanija - za odgojno-obrazovni sustav ili za učenika? Tu se otvara pitanje zastupljenosti odgojnih dimenzija nastave te suprotstavljanje dvaju smjerova: standardizacija i propisanost (od strane odgojno-obrazovne politike) te pristup usmjeren na učenika (temeljen na pedagoško-psihološkim spoznajama o školi, nastavi i učenju).

Bašić (2007) ističe kako se: *iz međunarodnih iskustava može naučiti da školi nisu potrebni standardi kao instrumenti (ekonomske) konkurentnosti škola na tržištu i vanjske kontrole. Ona treba pedagoško-psihološki legitimirane, na suvremenim znanstvenim spoznajama utemeljene i kulturno individualizirane standarde kvalitetne škole, odnosno kvalitetne nastave* (Bašić, 2007, str.149). Pritom također navodi kako se *kao prirodna posljedica tehnokratskog promatranja obrazovanja (kao proizvoda) smanjuje odgovornost za vlastito učenje, jer u prvom planu nije učenik (kao subjekt vlastitog obrazovanja) nego škola, uspjeh škole i usporedivost rezultata na testovima s drugim školama. Kompetitivnost škola je u prvom planu* (Bašić, 2007, str.123). Kao jedina istaknuta komponenta među odgojnim ciljevima navedenim u prijedlogu kurikuluma od strane ekspertne skupine (2016), slična onoj iz kurikuluma (2011), glasi: *Učenici će razviti samopouzdanje i svijest o vlastitim matematičkim sposobnostima, upornost, poduzetnost, odgovornost, uvažavanje i pozitivan odnos prema matematici i radu općenito*. Međutim, ta komponenta nije zastupljena u obrazovnim ishodima, već joj je cilj zadovoljavanje odgojno-obrazovnih potreba učenika s teškoćama te uvesti razlikovni kurikulum u skladu sa smjernicama *Okvira za poticanje iskustava učenja te vrednovanje postignuća djece i učenika s teškoćama.* S druge strane, isti je okvir općenito razrađen te nije konkretiziran prema matematičkom području, a kamoli prema nekom od specifičnih problematičnih područja distinktivnih za učenje i poučavanje matematike.

Prema svim relevantnim dokumentima kurikuluma i istraživanjima nastave matematike, ističe se kako je bitno razvijati i njegovati pozitivan stav prema matematici te odgovornost za vlastiti napredak. Međutim, je li moguće ostvariti ciljane odgojne (ali i obrazovne) ishode

ako se nameću gotove norme i propisuju vanjski kriteriji koji ne uvažavaju specifičnosti razrednog odjela, individualne karakteristike učenika, motivacijske čimbenike vrednovanja, te brojne teškoće u učenju s kojima se mnogi učenici suočavaju u nastavi matematike. Također, kurikulumom su propisani pedagoški standardi učenja i poučavanja te vrednovanja, ali nedostaje jasna poveznica s kurikulumima područja kako bi trenutno određeni obrazovni ishodi dobili legitimitet odgojno-obrazovnih ishoda koji su usmjereni na perspektive učenika i njihova napretka uvažavajući specifičnosti pojedinih područja.

Kako bi to postigli, potrebno je provesti sustavnu procjenu djetetova napretka temeljem pedagoškog pristupa svakom učeniku. Imajući na umu zastupljenost i raširenost teškoća učenika u nastavi matematike, treba promisliti jesu li recentni nastavni planovi i programi kurikuluma matematičkog područja uopće dostupni svakom učeniku te kako vrednovati proces učenja i poučavanja u danim okolnostima. Vrednovanje učenika mora biti integralni dio rada nastavnika, a (pr)ocjenjivanje ne bi smjelo biti u okovima državnih standarda, već se mora voditi pedagoško-psihološki legitimiranim standardima koji su prilagođeni učeniku od strane nastavnika koji poznaje učenika u njegovim specifičnostima. Cjelokupnim vrednovanjem potrebno je objediniti postignuća učenika i napredovanje kako bi iznjedrili zaključnu (pr)ocjenu koja je u funkciji napretka učenika, a ne u funkciji mjerenja i usporedbe s drugim učenicima, razredima i školama. Što se tiče kreiranja obrazovnih standarda nastave matematike, polazište bi trebalo biti u opsežnim istraživanjima u kojima bi se, pored međunarodnih studija, ispitivalo mišljenje praktičara te sustavna analiza prakse, a potom bi se u suradnji s didaktičarima i metodičarima krenulo u osuvremenjivanje i osmišljavanje nastavnih planova i programa te pripadnih obrazovnih ishoda.

Tako orijentiran kompetencijski pristup obrazovanju jest oruđe administrativne reforme sa složenim i kontradiktornim efektima čiji cilj nije poboljšanje procesa učenja i poučavanja ili kompetentnosti pojedinaca, već pružanje svojevrsne infrastrukture na temelju koje će učitelji i administratori brže i učinkovitije iskazati svoju odgovornost putem evaluacije u obrazovnoj politici (Jackson 1993; prema Ćatić, 2012). Trend evaluacije i usmjerenost na obrazovne ishode, koji trenutačno prevladava, nije didaktički utemeljen, a posljedica toga je da se profesionalnom djelovanju učitelja i nastavnika pripisuju čimbenici na koje nisu mogli utjecati (Ćatić, 2012). U intencijama da se te okolnosti obuhvate sve duljim popisima kompetencija, ustvari se prikriva didaktičko-operativna jezgra pedagoškog djelovanja, a nastavnička profesija proglasit će se odgovornom za probleme i zadatke utvrđene pripadnim evaluacijama (Prange, 2005). Hager (1995) navodi kako bez obzira na široko poimanje koncepta *kompetencija* u praksi, iste se postavljaju i procjenjuju u znatno manjem obujmu što ometa i degradira

obrazovanje (prema Ćatić, 2012). S obzirom na slojevitost područja matematičkog obrazovanja i niza različitih izazova s kojima se susreće suvremena nastava matematike, suvremenim trendovima obrazovnih politika ne naziru se rješenja za kvalitetnijom nastavom matematike, već samo za objektivnijim (ali ne i preciznijim) vrednovanjem nastavnog procesa prema mjerljivim parametrima učenja i poučavanja matematike.

2.2.2.1. Ciljevi i sadržaji nastave matematike

Ciljevi učenja temelj su planiranja nastave te organizacije i vođenje odgojno-obrazovnog procesa. Ciljeve učenja možemo podijeliti na opće i posebne koji su usmjereni prema ishodima učenja (učinku, rezultatima, ostvarenju, postignuću), odnosno prema promjenama učenika u pogledu njihova novog znanja, vještina, vrijednosti, stavova i navika koje su rezultat organiziranog poučavanja i učenja svakog nastavnog sata, a ostvaruju se aktivnošću učenika i utječu na njihov osobni razvoj (Jurčić, 2012). Isti autor ističe kako opći cilj treba formulirati tako da omogućuje odgovore na pitanja: *Kakva je učenikova zrelost u odgojnosti (tjelesnim, radnim, intelektualnim, moralnim i estetskim vrijednostima), a kakva u obrazovanosti (znanjima, umijećima i navikama) za prijelaz iz nižega odgojno-obrazovnog sustava u viši? Koliko ga kao zrelu osobu odlikuju kvalitete osobnosti kao što su: odnos prema sebi i vladanje sobom (osobna discipliniranost), odnos prema drugima (smisao za zajednicu), odnos prema učenju, radu, materijalnim i kulturnim vrijednostima […]. Posebne ciljeve učitelj formulira odgovorima na pitanja: Može li učenik primijeniti stečeno znanje? Kakva je njegova vještina komunikacije? Koliko je razvijeno njegovo kritičko mišljenje? Kako samovrednuje osobno učenje? Je li razvio timski duh? Može li učenik sebi postavljati ciljeve važne za uspješno odrastanje? Može li rješavati probleme na koje nailazi? Može li se odgovorno ponašati?* (Jurčić, 2012,str. 38,39). Razradom općih i posebnih ciljeva nastavnik ima osnovu na temelju koje može planirati aktivnosti te metode učenja i poučavanja kako bi ostvario određene obrazovne ishode.

Poučavanje u nastavi matematike ostvaruje se matematičkim sadržajima koji su odabrani iz korpusa znanja matematičke znanosti prema određenim kriterijima (dob učenika, obrazovni program i sl.) te su materijalna osnova nastavnog procesa što se utvrđuje nastavnim planom i programom. S obzirom na to da je učenje matematike uglavnom kumulativno stjecanje znanja i vještina, pri realizaciji ciljeva nastave potrebno je odrediti razinu znanja, odnosno kvalitetu usvojenosti prethodnih nastavnih sadržaja. Znanje se, kao logički pregled činjenica i

generalizacija o objektivnoj stvarnosti (Poljak, 1991), u matematici odnosi na usvojene pojmove, pravila, koncepte, procese, definicije te zaključke koje učenik usvaja i primjenjuje. U nastavi matematike pritom se isprepliću deklarativna i proceduralna znanja koja se komplementarno razvijaju i nadograđuju (Anderson, 1982). Deklarativna znanja odnose se na usvajanje činjenica i generalizacija, a proceduralna znanja odnose se na način izvođenja pojedinih operacija što se u matematici često naziva i *algoritamskim rješavanjem* zadataka. Tako Goldman i Hasselbrin (1997) opisuju konceptualna (deklarativna) znanja kao mrežu međusobno povezanih informacija u kojoj je povezivanje informacija jednako važno kao i svaka pojedinačna informacija među njima. Carnine (1997) proceduralno znanje definira kao sposobnost praćenja pravila i algoritama u rješavanju različitih zadataka, a svaki korak izvodi se u unaprijed određenom linearnom slijedu. Chinn i Aschroft (1998) sukladno tome opisuju dva specifična tipa učenika prema načinu na koji uče: skakavac (eng. *grasshopper*) i gusjenica (eng. *inchworm*), a navedeni su pojmovi metafore za konceptualno i proceduralno razumijevanje.

Prema tom opisu, učenik *skakavac* „vidi“ matematiku holistički, ima intuitivan pristup i izraženo konceptualno razumijevanje matematičkih principa i procesa zbog čega može rješavati određeni problem na više načina iz različitih perspektiva samog problema. S druge strane, učenik *gusjenica* daje prednost zadatcima i problemima koji se mogu svesti na određene sekvence, korake, odnosno propisane algoritme za rješavanje zadataka te su stoga vješti u zadatcima s unaprijed poznatim načinima i metodama rješavanja. Iako učenici iz navedene grupe „skakavaca“ imaju mentalni sklop koji bismo mogli okarakterizirati kao idealni za karijeru u matematici i prirodnim znanostima, oni nerijetko imaju teškoće upravo u proceduralnim zadatcima u kojima ponekad rade greške u trivijalnostima te općenito u bilješkama koje su često nepotpune. Oni zbog holističkog pristupa često vide rješenje prije raznolikih procedura te jednostavno nisu skloni temeljitosti u proceduri zbog specifičnog fokusa na holistički pristup.

Učenici „gusjenice“ često imaju teškoća s problemskim zadatcima, nekonvencionalnim zadatcima te svime što odstupa od nekih propisanih pravila, ali su zato češće uredni i temeljiti u bilješkama što je s godinama školovanja sve prisutniji aspekt učenja matematike. Učitelji i nastavnici matematike moraju pomoći učenicima kako bi izvukli maksimum iz obje kategorije zato što jedino tako mogu ostvariti potencijale te postati izvrsni matematičari. Vrijedi istaknuti kako u grupi „skakavaca“ ima (potencijalno) darovitih učenika koji u osnovnoj školi tijekom nastave posjeduju osjećaj dosade te ne razvijaju radne navike koje su, među ostalim, temeljni preduvjet za stjecanje proceduralnih znanja koja su nužna za usvajanje viših razina znanja u

srednjoj školi i na fakultetima. Pored mnogih izazova koji su prisutni kod učenika adolescentske dobi, nastala situacija dovodi do potpunog gubitka interesa i pada u kvaliteti znanja uslijed čega dolazi do određene „dezorijentacije“ učenika koji više nemaju samopouzdanja, nisu u stanju usvajati nova znanja i vještine čak ni uz prisustvo relativno podupiruće školske i obiteljske okoline.

Kako bi uspješno svladavali matematičke sadržaje, uz podupiruću školsku i obiteljsku okolinu, učenici unutar „koncepcije“ konceptualnih i proceduralnih znanja moraju razumjeti sintaksu i pravila matematičkog jezika, usvojiti osnovne matematičke procese te izdvoditi njima svojstvene postupke koji se kontinuirano akumuliraju i postupno stvaraju sve kompleksniju mrežu znanja. Pritom je neophodno da, nakon svladavanja nastavnih sadržaja, učenici postignu razinu znanja na kojoj će jasno komunicirati svoje ideje koristeći formalni matematički jezik i pripadnu terminologiju.

Izbor nastavnih sadržaja treba biti određen postavljenim ciljevima učenja i poučavanja uz optimalno opterećenje učenika te se također moraju razmatrati i ograničavajući čimbenici kao što su učenikove sposobnosti, interes, neprimjereni mediji i neosposobljenost učitelja (Cindrić i sur., 2010). Nastavni sadržaji primarno su odabrani prema znanstvenim okvirima struke, odnosno predmeta te na temelju didaktičko-metodičkih spoznaja. Odabir nastavnih sadržaja za pojedini razredni odjel poznat je kao faza procesa planiranja i programiranja, a odnosi se na utvrđivanje broja nastavnih sati za pojedinu temu te na izbor i didaktičko oblikovanje nastavnih sadržaja s obzirom na postavljene zadatke i cilj (Jurčić, 2012). Prema didaktičkim teorijama, zadatke/ciljeve nastave dijelimo na materijalne, funkcionalne i odgojne. Materijalne zadatke često još nazivamo kognitivnima i/ili spoznajnima zato što se odnose na stjecanje znanja i vještina predviđenih sadržajem programa. Realizacija materijalnih zadataka nastave očituje se u primjeni znanja i vještina u usvajanju činjenica, spoznavanju novih sadržaja te u mogućnosti prepoznavanja, razlikovanja, opisivanja, uočavanja, razumijevanja i organizacije ključnih elemenata, načela, metoda, definicija i zakonitosti pojedinih sadržaja.

Funkcionalni zadatci ili formalni odnose se na sposobnosti učenika za određeni način razmišljanja u okvirima nastavnih sadržaja i dotične struke te za izvođenje konkretnih radnji, operacija i uvježbanih postupaka. Ti zadatci odnose se na predviđanje onoga što će učenici postići ili u čemu će napredovati tijekom nastavnog sata glede sposobnosti i spretnosti, a općenito se odnose na prikupljanje i uporabu informacija, razgovor i raspravu o problemu i rezultatima rješavanja problema, sposobnost provedbe projekta i različitih načina prikazivanja njegovih rezultata (Jurčić, 2012). Odgojni ili afirmativni zadatci odnose se na formiranje ličnosti učenika kroz aktivnosti u kojima će razvijati vrijednosti i stavove koji su uz odgojne i

integralni dio obrazovnih vrijednosti i znanja. Naime, ukoliko materijalni i funkcionalni zadatci nisu prožeti primjerenim i za to prikladnim odgojnim vrijednostima, isti se ne mogu u potpunosti realizirati. Želimo li u nastavi postići primjenjivu matematičku kompetenciju kod učenika, moramo sustavno pristupiti realizaciji svih zadataka nastave. To, među ostalim, podrazumijeva usklađivanje predznanja, vještina s ciljevima pojedinih nastavnih jedinica, sadržaja te predmetnih kurikuluma.

Možda je i najpoznatiji koncept usmjeren na primjenjivost matematike Freudenthalova teorija realističkog matematičkog obrazovanja[1]. Prema RME teoriji nastava matematike i njezini sadržaju moraju biti u vezi s realnošću, a matematika se mora ostvariti i prikazati djeci kao humana aktivnost (Romano, 2009). Iako je težnja RME teorije na svakodnevnim situacijama, pojmovno se pod „realističkim“ smatra šire područje u kojem se nalaze problemi koji su realni u svijesti učenika, odnosno koje isti mogu zamisliti mentalnim reprezentacijama matematičkih objekata. Pet je bitnih karakteristika realističkog obrazovanja (Treffers, 1978):

- korištenje stvarnih životnih situacija kao polazište za učenje i poučavanje
- korištenje modela pri povezivanju realnosti s matematičkim apstrakcijama
- aktivno sudjelovanje učenika u nastavi i poticanje različitih smjerova razmišljanja kao rezultat njihovog osobnog bavljenja matematikom
- interakcija između učenika i nastavnika nužna je za učenje i poučavanje matematike
- povezivanje didaktičkih jedinica i uspostavljanje korelacija s drugim predmetima (disciplinama) te intelektualnim izazovima iz svakodnevnog života.

Pokazuje se kako i teorijski okvir međunarodnog istraživanja obrazovanja PISA za matematičko obrazovanje ima mnogo sličnosti sa realističkim matematičkim obrazovanjem, što se ponajprije očituje u težnji prema aspektu primjenjivosti (Domazet, Baranović, Matić, 2013). Nastava prema RME teoriji ne počinje formalnim znanjima i teorijom, već učenici kroz dane problemske situacije sami izvode relevantnu teoriju i koncepte čime se realiziraju matematički sadržaji. Matematika kao znanost često se percipira kao zatvoren sustav te je i cilj dotične teorije na aktivnostima koje imaju mnoge primjene što je i odredilo razvoj matematike kroz povijest. U tako organiziranoj nastavi primjene se najčešće ostvaruju problemski zadanim situacijama unutar matematike i modeliranjem unutar njezinih sadržaja. Neki su autori mišljenja (npr. De

[1] Teorija realističkog matematičkog obrazovanja (eng. *Realistic mathematics education*- RME) je teorija koja svoje početke bilježi krajem 60-ih godina 20. stoljeća u Nizozemskoj, a idejnim začetnikom smatra se Hans Freudenthal. Dva su ključna aspekta RME teorije: nastava matematike mora biti u vezi s realnošću te činjenica kako je bavljenje matematikom humana aktivnost.

Lange 1996, prema Romano, 2009) kako je dovoljna primjenjivost unutar matematike, a Freudenthal je isključivo smatrao kako se matematika mora naglasiti kao ljudska aktivnost te kako se potpuna primjenjivost može ostvariti polazeći od konkretnih situacija prema matematičkim konceptima i sadržajima, a ne obratno. Treffers (1987) je nadopunio i raščlanio Freudenthalovu teoriju u dva smjera *matematizacije* u nastavi: *horizontalno* i *vertikalno* matematiziranje u kontekstu primjene matematičkih sadržaja. Prvo se odnosi na pripremanje/usmjeravanje učenika kako bi organizirali i riješili problem iz svakodnevice kroz identifikaciju određene matematike u zadanom kontekstu, stvaranje shematskih odnosa, formuliranje i vizualiziranje problema, pronalaženje relacija, odnosa i pravilnosti te redom do mogućnosti u kojoj bi se zadani problem sveo na matematički problem koji znamo riješiti. S druge strane, vertikalno matematiziranje proces je organizacije znanja unutar matematike te se realizira dokazivanjem identiteta, korištenjem i dorađivanjem i/ili kombiniranjem i integracijom matematičkih modela, raznim generalizacijama, apstrakcijama i slično.

De Lange (1996) u sklopu RME teorije promatra proces učenja kroz tri faze, odnosno razine mišljenja:

1. učenik može manipulirati poznatim svojstvima na razini prepoznavanja
2. učenik razumije sadržaje do mjere povezivanja odnosa i karakteristika među njima
3. učenik barata sa suštinskim karakteristikama i odnosima među promatranim objektima matematičkih sadržaja.

Učenje novih sadržaja u nastavi matematike za pretpostavku ima znanje koje je na drugoj, ili čak trećoj razini, što se podudara s operativnim znanjem (prema Poljaku, 1990). Prema Freudenthalovim idejama učenja i poučavanja, u realističnom pristupu prihvaća se činjenica kako su učenici postigli tek prvu razinu mišljenja te se stoga prilikom obrade novih sadržaja isto ponavlja i nadograđuje kako bi daljnjim kontekstualnim problemima mogli razvijati i produbljivati znanja (Romano, 2009). U Republici Hrvatskoj RME teorija tek je u eksperimentalnoj provedbi u nekoliko osnovnih škola, a suradnjom kroz projekte Europske unije želi se proširiti ideja i na srednje škole. Međutim, za provedbu i evaluaciju istih trebat će još puno vremena uz kontinuiranu potporu obrazovnih politika, no pitanje je koliko ti projekti mogu biti uspješni kada u suradnji nema visokoškolskih institucija iz područja društvenih i humanističkih znanosti.

Međutim, unatoč recentnim tendencijama povećoj zastupljenosti problemskih zadataka i ideja primjenjivosti znanja, u nastavi matematike, u skladu s nastavnim planovima i programima, organizacija i planiranje nastavnih jedinica dominantno se svodi na „klasične“ zadatke koji su pretpostavka u razvijanju vještina i znanja potrebnih za razinu primjenjivosti

znanja, ali se zbog brojnosti istih često ne realiziraju željene (više) razine znanja. Naime, karakter sadržaja nastave matematike, za razliku od većine drugih predmetnih područja, ima izrazitu usmjerenost na rješavanje zadataka zbog čega svaka nastavna jedinica u nastavi matematike ima konačan cilj u obrazovnim ishodima usmjerenima na zadatke. Iako se podudaraju u mnogim sadržajima i konceptima, kao i pripadnim oblicima učenja i poučavanja, predmeti poput fizike, kemije, biologije, elektrotehnike, računalstva i slični imaju znatnu zastupljenost rješavanja zadataka u realizaciji nastavnog plana i programa naspram predmeta iz spektra društvenih znanosti, no ni jedan od navedenih nema toliko dominantnu zastupljenost rješavanja zadataka kao što je u slučaju nastave matematike.

S druge strane, nastavni predmeti koji primarno trebaju uzduž nastavnog plana i programa obuhvatiti određenu količinu činjenica i razumijevanje te poznavanje istih, ne moraju nužno podrazumijevati vježbanje posredovanih sadržaja nekakvim zadatcima kao u matematici i sadržajem sličnih predmeta u kojima je, među ostalim, bitno usvojiti određene algoritme kako bi se realizirali zadanih ishodi. Stoga se i kurikulum nastave matematike izdvaja među nastavnim predmetima iz STEM područja te srodnih struka i znanosti. Tu je potrebno istaknuti funkciju i svrhu zadataka u nastavi matematike te distinkcije naspram pojedinih predmeta iz STEM područja u kojima predmeti poput fizike, kemije, biologije, elektrotehnike imaju zadatke koji su primarno koncipirani tako da budu primjenjivi unutar dotičnih struka te se stoga mogu češće percipirati u svrhovitoj i bližoj svakodnevici nego što je to u slučaju nastave matematike. S druge strane, predmet matematike uzduž cijelog sustava predtercijarnog obrazovanja mora osigurati opću matematičku pismenost što pored mnogih drugih ciljeva podrazumijeva baratanje različitim algebarskim izrazima, prepoznavanje i rješavanje raznolikih jednadžbi te mnogih matematičkih koncepata, procesa i procedura koje se najčešće rijetko i teško mogu dovesti u kontekst svakodnevice pa čak ni artificijelnim hipotetskim primjenama. Kako je među temeljnim ciljevima nastave matematike razvoj vještina i sposobnosti postavljanja, formuliranja i rješavanja problema te interpretiranja, uspoređivanja i vrednovanja rješenja u odnosu na izvornu problemsku situaciju (*Nacionalni okvirni kurikulum*, 2010), očito je kako stjecanje matematičke kompetencije u sebi obuhvaća niz raznovrsnih zahtjeva koji su međusobno tijesno povezani i uvjetovani.

Stoga je matematika kao znanost i nastavni predmet u podređenom položaju, naročito po pitanju primjenjivosti kojom se često proziva sustav odgoja i obrazovanja kao i učestala kritika iste kao teorijske znanosti koja je sama sebi svrha. To je i, među ostalim, razlog zašto studenti STEM područja češće razumiju primjenjivost matematike i njezinih sadržaja te brojne odgojne i obrazovne vrijednosti koje su pritom potrebne i/ili se razvijaju u procesu učenja.

Matematika je ipak jezik znanosti i možemo reći kako svi predmeti STEM područja koriste matematički jezik i pismo, a to je i jedan od mnogih odgovora kritikama adresiranim na primjenjivost matematike koja se uskogrudno plasira kroz prizmu ponavljanih zadataka koji su „sami sebi svrha“. Stoga se kao važan izazov odgojno-obrazovnog sustava i nastavnika matematike pokazuje u intencijama da se ne umanjuje značaj i primjenjivost matematike kao ni uloga matematike u razvoju kognitivnih kapaciteta i stjecanju radnih navika djece. Kako je matematika jedini predmet iz STEM područja koji je prisutan od prvog razreda osnovne škole, unutar iste se stvaraju preduvjeti za opću znanstvenu pismenost i logičkom načinu razmišljanja, a to je temelj svake struke i znanosti te različitim područjima ljudskog djelovanja.

2.2.3. Struktura i organizacija nastave matematike

Organizacija nastave postupak je kojim se različiti odgojno-obrazovni ciljevi usklađuju i strukturiraju u etape sata kroz koje se realiziraju ciljevi i zadatci koristeći sadržaje, metode, didaktička načela, različite socijalne oblike rada, nastavna sredstva i izvore te vrednovanje koje je integralni dio svake etape i nastavnog procesa u cijelosti. Nastava se organizira i planira na godišnjoj, tjednoj i dnevnoj razini pa se sukladno tome nastavni proces artikulira sve do njegove najmanje vremenske organizacijske jedinice koju zovemo nastavni sat. Temeljna didaktička pitanja u vezi s nastavnim satom etape su nastavnog procesa kroz koje se osigurava kvaliteta u organizaciji i vođenju nastave.

Nastavna jedinica najčešće se određuje kroz tri etape: uvod ili dogovor, središnji dio ili realizacija i zaključak ili evaluacija. Uvodu u nastavni sat prethode razmišljanja o predznanjima i vještinama koje učenici posjeduju, o motivaciji, odabiru optimalnih metoda, oblika nastave, izvora znanja i nastavnih sredstava kako bi učenici svojim naporima ostvarili zadane odgojno-obrazovne ciljeve. Uvod nastavnog sata služi za motivaciju, pripremu i dogovor oko aktivnosti koje slijede. Pripremaju se nastavna sredstva i pomagala, raspodjeljuju se učenici prema ovisnosti o obliku rada te se učenicima daju osnovne ili indikativne informacije o onome što će se raditi i što će učiti. Etape se razlikuju ovisno od sata koji može biti: sat uvođenja novih sadržaja, sat ponavljanja i vježbanja, sat provjere i ocjenjivanja te kombinacije navedenih oblika. Osnovne komponente nastavnog procesa koje određuju strukturu i tijek nastavnog sata obrade novih sadržaja su: pripremanje učenika za nastavu, obrada nastavnih sadržaja, vježbanje, ponavljanje i provjeravanje. Što su učenici starije dobi, broj sati obrade može biti zastupljeniji u odnosu na broj sati vježbanja, no svakako je potrebno da na svakom satu obrade ujedno i

ponavljamo, a vrijedi i obratno (Pavleković, 2008). Prilikom obrade novih nastavnih sadržaja osnovni zadatak jest pripremiti učenike što se u nastavi matematike gotovo bez iznimaka provodi ponavljanjem prethodnih sadržaja koji su posloženi u nastavnom programu upravo prema slijedu izgradnje matematičkih znanja. Međutim, uvođenje novih sadržaja, pored netom obrađenih sadržaja, nerijetko podrazumijeva niz konceptualnih i proceduralnih znanja koja učenici godinama postupno stječu. Pritom je bitno istaknuti glavne ideje i probleme, dovesti temu nastavne jedinice u jasnu vezu s ranije svladanim sadržajima te motivirati učenike za rad. Nakon faze sata u kojoj učenici vježbaju rješavanje zadataka, slijedi proces utvrđivanja usvojenih znanja te zadavanje domaće zadaće.

Sat ponavljanja uglavnom se usmjerava na samostalan rad učenika u kojem se ponavljaju i vježbaju zadatci s ciljem produbljivanja razine znanja i detekcije problematičnih područja, a uglavnom se radi na kraju nekih poglavlja ili većih tema te često prethode kratkim provjerama i provjerama znanja. Sat vježbanja ima jednake ciljeve kao i sat ponavljanja, no isti se učestalije izvodi te je uglavnom sastavni dio nastavnog sata obrade novih sadržaja, ali ne treba nužno imati cilj pripreme nekog od oblika provjere znanja. Sat provjere znanja i ocjenjivanja može biti u obliku: pisane provjere, praktične provjere i usmene provjere (razgovor, razumijevanje pojedinih postupaka, procedura i usvojenost sadržaja). Osim u slučaju kraćih provjera znanja, ovaj tip nastavnog sata u praksi se možda i najčešće izvodi bez kombiniranja s ostalim tipovima nastavnih sati.

Naime, većina sati u nastavi matematike pretežito je kombiniranog tipa, s izuzetkom sati ponavljanja i vježbanja te provjere i ocjenjivanja. S druge strane, sat obrade novih sadržaja u početnim fazama nastavne jedinice podrazumijeva provjeru domaće zadaće, a pored toga i uvježbavanje zadataka koji su predviđeni radi usvajanja novih sadržaja. U cjelokupnoj nastavi matematike, u osnovnim i srednjim školama, znatno je manji udio sati čija obrada te uvođenje i prezentiranje novih sadržaja zauzimaju većinu nastavne jedinice što je posljedica koncepcije većine nastavnih jedinica u kojima je predviđen samostalan rad učenika vježbanjem. To se odvija u središnjem dijelu sata unutar kojeg se obrađuju nastavni sadržaji kojima se usvajaju, vježbaju, produbljuju, proširuju i ponavljaju određena znanja do razine stjecanja i realizacije odgojno-obrazovnih zadataka za taj nastavni sat. Cilj je na postupnom razvoju sposobnosti i vještina, koje se realiziraju kroz proširivanje znanja, produbljivanje sadržaja i stvaranje logičkog ustrojstva koje u nastavi matematike po prirodi matematičkih sadržaja najviše dolazi do izražaja te je sastavni dio matematičke znanosti i integralni dio obrazovnih ishoda nastave matematike na svim razinama školovanja. U nastavi matematike isto se najčešće ostvaruje tako što nastavnik učenima demonstrira određene radnje (rješava zadatke i objašnjava određene

odnose među matematičkim konceptima), objašnjava učenicima kako će to postići samostalnim radom i vježbanjem te pritom naglašava misaoni proces, odnosno način razmišljanja u pristupu zadatcima. U završnom dijelu sata usustavljuju se znanja te se evaluira u kojoj su mjeri učenici ostvarili te ciljeve. Iako je evaluacija prisutna uzduž cijelog nastavnog sata kao sastavni dio vrednovanja na makrorazini, na kraju sata ista se izvodi u smislu vrednovanja realizacije planiranih odgojno-obrazovnih ciljeva tog sata.

Nakon toga isto primjenjuju kroz procedure rješavanja zadataka kojima, među ostalim, produbljuju znanja o konceptima obrađivanih sadržaja. U skladu s time, nastava matematike mora imati cilj kojim se, rješavanjem zadataka i posredstvom nastavnika, usvajaju nova znanja te stječu vještine koje nastavnik može evaluirati na svakom nastavnom satu, a ne samo pri provjeri znanja. Pritom se graduiranje znanja ostvaruje simultanim proširivanjem i produbljivanjem znanja tako da se učenici susreću s novim činjenicama i generalizacijama koje se povezuju s prethodnim sadržajima te se istodobno produbljuju logičkim ustrojstvom samih sadržaja. Primjereno graduiranje ostvaruje se u skladu s kognitivnim mogućnostima učenika (Poljak, 1991), ali i u skladu s predznanjem učenika koje najčešće nije na željenoj razini ni u ekstenzitetu ni u intenzitetu znanja. To predstavlja dodatni napor nastavniku tijekom organizacije nastave te u realizaciji ciljeva koji su ponajviše uvjetovani nedostatnom razinom znanja prethodnih sadržaja.

To je samo jedan aspekt višeslojne problematike nastave matematike koja je, uz sve navedeno, u snažnom međudjelovanju s kognitivnim, afektivnim i motivacijskim aspektima nastave zbog čega se svaki sat matematike suočava s cijelim nizom poteškoća u ostvarivanju individualnih pretpostavki za učenje i poučavanje matematike. Stoga se suvremeni kurikulumi u organizaciji procesa učenja i poučavanja oslanjaju na shemu cilja i sredstva kao koncept nastave usmjeren na ciljeve učenja.

Polaznu točku takvih kurikuluma tvori teorijski model upravljanja procesima učenja koji se oslanja na kibernetički regulacijski krug (Terhart, 2001). U primjeni na nastavni proces, taj model preporučuje sljedeće korake:

1. Utvrđivanje i preciziranje poželjnog ponašanja učenika kao konačni ishod.
2. Utvrđivanje polaznih uvjeta i pretpostavki učenja kod učenika.
3. Planiranje koraka učenja koji će „stvarno stanje“ što djelotvornije prevesti u „idealno stanje“.
4. Osiguravanje različitih mogućnosti učenja i poučavanja uz primjenu primjerenih materijala, metoda i medija.

5. Kontrola učenja, odnosno završna usporedba ciljanog i stvarnog stanja kako bi se prikupili podatci o stupnju dostizanja cilja te utvrdili naputci za planiranje daljnjega procesa poučavanja i učenja.

Međutim, iako obrazovne politike zastupaju pristup usmjeren na ciljeve učenja te ga zagovaraju povećanom transparentnošću učenja za učenike, roditelje i javnost zbog jasno zadanih ciljeva, ipak se pokazuje kako je u znanstvenoj zajednici znatno opširnija kritika onih koji zagovaraju taj pristup (Terhart, 2001). Sintezom literature, Terhart (2001) iznosi neke od sljedećih kritika:

- Usmjerenošću na cilj učenja ovaj koncept u nastavi kao beznačajne ostavlja sve aktivnosti koje izravno ne vode cilju. Slijedom toga postoji opasnost da sve ono što je nemoguće operacionalizirati ostane isključeno iz procesa školskog učenja.
- Fokus je na kognitivnom području, a socijalno se učenje zanemaruje.
- Precizna razrada područja ciljeva učenja razara unutarnju povezanost složenih i većih sadržajnih područja te tako razbija jedinstvo obrazovnog procesa.
- Metodičko se strukturiranje tijeka nastave zanemaruje, odnosno sužava na dosljedno nastavniku okrenuto opisno poučavanje uz čisto receptivni stav učenika pri učenju.
- Nastavni planovi i programi služe željenoj kontroli nastavne situacije koju obavlja država čime se zadovoljavaju samo potrebe školske administracije.

Prema ovom modelu, proces obrazovanja u osnovi je proces vođenja učenika i postizanje određenog cilja učenja. Intencija je pritom da se proces učenja i nastava pojednostave u proceduru od nekoliko etapa kojima bi postigli zadane ciljeve. U temeljnim orijentacijskim pitanjima kojima se nastavnik koristi pri refleksiji vlastite prakse, Winkel (1986) ističe poremećene nastavne procese (prema Gudjons, 1994), odnosno aspekte i čimbenike smetanja (Winkel, 1987). Winkel (1986) ističe važnost pitanja provjere postignutih ciljeva poučavanja i učenja pa u vezi s evaluacijom vlastite djelatnosti navodi: *Jesu li prethodno postavljeni ciljevi učenja i poučavanja tijekom nastavnog komnikacijskog procesa potvrđeni, eventualno revidirani ili nadomješteni novim i drugačijim ciljevima te kako možemo sami sebe i druge, na temelju kojih postignuća u učenju, informirati o tome koje smo ciljeve stvarno postigli, koje smo promašili ili kojim smo se ciljevima samo donekle približili (zašto?) i to samo putem teškoća i pogreški (kojih točno?)?* (Winkel, 1986; prema Kiper i Mischke, 2001).

2.2.3.1 Strukturni model metodičkog djelovanja i odnosi učenika u nastavi

Meyer (1987) je koncipirao strukturni model argumentacije koji ima cilj sustavnim redom navesti sve elemente koji konstituiraju nastavni proces. Prema tom modelu, metodička organizacija nastave ima središnju ulogu pri čemu se nastavni proces konstituira u konkretnim situacijama djelovanja u kojima se ciljanim radom, društvenom interakcijom i jezičnim sporazumijevanjem nastavnika i učenika razrađuje nastavni sadržaj. Metodičko djelovanje pritom se odvija unutar triju dimenzija koje su međusobno povezane (kao i s dimenzijama cilja i sadržaja): socijalni oblici, obrasci djelovanja te nastavni koraci. Navedene dimenzije učvršćuju se unutar institucionalnog okvira školske nastave u oblike diferenciranja i integracije te oblike odvijanja nastavnog procesa što Meyer objedinjeno prikazuje kao *velike metodičke oblike.*

Socijalni oblici uređuju strukturu odnosa u nastavi s prostornom i komunikacijskom strukturom. Obrasci djelovanja uređuju akcijsku strukturu nastave s insceniranom stvarnosti i razvijanjem kompetencije za djelovanje. Treća dimenzija su nastavni koraci koji uređuju strukturu odvijanja nastave s vremenskim i metodičkim tijekom. Kiper i Mischke (2001) ističu kako je strukturni model metodičkog djelovanja bolji od prethodnika te nadilazi motiv pukog pojmovnog razvrstavanja, odnosno klasifikacije pri formuliranju metodičkih stajališta koji problem nastavne metode smješta u središte svog interesa. Meyer (1987) stoga napominje kako strukturni model treba uspostaviti teorijsku jasnoću između raznolikih pojavnih oblika metodičkog djelovanja, ali ipak navodi kako za nastavnu praksu isti ima samo ograničenu vrijednost.

Kako bismo učenicima osigurali optimalno i poticajno okružje unutar kojeg ćemo realizirati ciljeve nastave i cjelovitog predmetnog kurikuluma, potrebno je uravnoteženo kombinirati socijalne oblike rada. Mnoga djeca školske dobi provodi više vremena s učiteljima i nastavnicima nego s roditeljima te se stoga značajan dio socijalizacije učenika ostvaruje u nastavnom procesu. Iako je škola primarni izvor socijalizacije, Klarin (2006) ističe kako učitelji dijelom preuzimaju roditeljsku ulogu zbog čega se uz stručna znanja i vještine od njih očekuje razvijena socijalna kompetencija.

Prema Poljaku (1991), socijalni oblici rada u nastavi su: direktno poučavanje frontalnim radom te samostalni rad učenika koji se ostvaruje individualno, radom u paru, grupama ili u timu. Pod samostalnim radom pritom se smatra kako su učenici u direktnom odnosu s nastavnim sadržajima što može biti u grupnom radu, radu u paru te u individualnom radu učenika. Svi oblici, uz iznimku frontalnog rada, u literaturi se najčešće navode kao modeli diferencirane

nastave koja je primarno usmjerena na samostalni rad učenika.

U frontalnoj nastavi nastavnik posreduje između učenika i nastavnih sadržaja te su učenici u indirektnom odnosu s nastavnim sadržajem. Svaka nastava obično počinje ovim oblikom, ali i završava. Nastavnik vodi nastavni proces, a učenici stječu znanje na temelju promatranja i zaključivanja, odnosno ako učenici slušaju i povremeno postavljaju i odgovaraju na pitanja. Nastavnik frontalno komunicira sa svim učenicima radi zajedničkog poučavanja te je stoga frontalni oblik nastave najekonomičniji u vidu brzine obrađenih sadržaja, pripreme za nastavni sat te realizacije ciljeva učenja. Temeljni preduvjet za takav sat su interes i motivacija učenika. Frontalna nastava najprikladnija je u obradi novih sadržaja, osobito u određenim područjima matematike u kojima nije jasna poveznica aktualnih sadržaja s prethodno obrađenim. Budući da se takav način rada prilagođava „prosječnom učeniku“, nedostatak je pitanje individualizacije, odnosno uvažavanje različitih brzina učenja i usvajanja sadržaja. Ključni je nedostatak frontalne nastave ako se taj oblik pretvori u tzv. predavačku nastavu koja zapostavlja aktivnost učenika i svodi ju na slušanje i gledanje bez aktivnog sudjelovanja.

Rad u grupi temelji se na zajedničkom radu najčešće tri do šest učenika na rješavanju određenih zadataka tijekom nastave. Veličina grupe formira se ovisno o dobi i interesu učenika te nastavnih sadržaja radnih materijala. Nastava se odvija u više skupina kako bi učenici unutar skupine učili samostalno, ali pod vodstvom nastavnika. Nastavnik ima ulogu posrednika u odabiru sadržaja, pripremi sata, vođenju grupa te u vrednovanju. Nedostatak je niska kohezivnost te potencijalni nemiri i nestrukturiranost sata. Prednosti rada u skupinama su: neposredan odnos učenika s izvorima znanja i s ostalim učenicima u skupini, razvijanje radnih sposobnosti, individualizirani rad u skupini. Razlika je između rada u grupi i rada u timu u tome što u timskom radu svaki učenik ima točno određenu funkciju, odnosno ulogu koja se nadopunjuje s onom od ostalih učenika u timu. Za rad u grupi ili timu bitno je da nastavnik na početku sata motivira učenike te ih upozna sa zadatcima, načinom rada te pojedinačnim ulogama u ovisnosti od toga hoće li raditi kao grupa ili tim.

Rad u paru čine dva učenika koji zajednički obrađuju problem u nastavi. Takvim radom učenici udružuju svoje znanje i sposobnosti te zajednički postižu zadane ciljeve. Za razliku od rada u grupama, učenici se u paru lakše sporazumijevaju i surađuju. S obzirom na sposobnosti učenika, rad u paru može biti instruktivnog karaktera zato što bolji učenik pomaže slabijem ili zajednički rad u kojem ili rješavaju zajedno ili svaki zasebno nakon čega zajednički raspravljaju o rješenjima, postupcima i načinima razmišljanja. Pritom mogu biti dominantni sljedeći oblici komunikacije: simetrična (dvosmjerna) komunikacija te asimetrična komunikacija u kojoj je potencijalna dominacija jednog učenika unutar koje je moguć razvoj egocentrične

komunikacije (Poljak, 1991). U individualnom radu svaki učenik radi samostalno te je u direktnom odnosu s nastavnim sadržajem. Samim time veća je i obrazovna vrijednost nego u drugim oblicima rada, ali je nemoguće učinkovito provjeravati i usmjeravati sve učenike u vremenskim ograničenjima nastavnog sata. Suradnje s ostalim učenicima uglavnom nema, već se povremeno, po potrebi, komunicira s nastavnikom radi smjernica i/ili dodatnih uputa i nadzora. Učenici tako razvijaju samostalnost te stječu samopouzdanje i osjećaj za vlastite sposobnosti. Ovakav oblik pokazuje se naročito uspješnim u predmetima poput matematike u kojima je važno individualizirati zahtjeve mogućnostima svakog pojedinog učenika kako bi učenici napredovali tempom koji im odgovara.

Socijalna organizacija nastave jedan je od mnogih aspekata nastave koji su u međudjelovanju s ostalim čimbenicima nastave te ih se stoga mora razmatrati zajedno s ostalim indikatorima kvalitetne nastave. U teoriji i praksi često se spominje kako se frontalna (predavačka) nastava mora zamijeniti suvremenijim oblicima poučavanja. U skladu s time navodi se kako tradicionalna škola koči razvoj sposobnosti učenika te se njome ne mogu razviti vještine kritičkog mišljenja i rješavanja problema (Bognar i Matijević, 2002). U suvremenim teorijskim razmatranjima u pedagogiji mnogi se stoga sve više priklanjaju grupnom obliku učenja zato što se smatra kako taj socijalni oblik uklanja nedostatke frontalnog oblika koji se u pedagoškoj literaturi nerijetko nalazi kao sinonim loše nastave.

Međutim, svaki od oblika rada ima značajnih prednosti i nedostataka. Frontalni rad posebno je pogodan za korištenje različitih tehnologija te didaktičkih pomagala u okviru različitih tehnologija. Brojne su prednosti frontalnog oblika rada poput: unošenja mira i kontinuiteta u proces učenja i poučavanja, ekonomičnost (istodobno poučavanje cijelog razrednog odjela), izbjegavanje temeljnih praznina u znanju i pogrešnih veza, neposrednim povratnim informacijama učitelj doznaje koliko su učenici razumjeli nove sadržaje (doživljaj osobnoga zadovoljstva u poučavanju) (Bognar i Matijević 2002; prema Jurčić, 2012). Frontalni rad didaktički je gledano nešto jednostavnija metoda koja je naročito prikladna za rad na jednostavnijim sadržajima koji su trivijalni i nema potrebe da učenici na njima samostalno rade, već im nastavnici posreduju ključne informacije kako bi mogli obrađivati sadržaje koji se nadovezuju na iste.

Diferencirana nastava, pored prednosti koje se ističu nad frontalnim radom, također ima svojih nedostataka. Na samom početku problem je u složenosti ustrojavanja rada u skupinama što se odnosi na dugi uvodni dio i često poveći utrošak vremena. Uglavnom dominiraju bolji učenici čijim se rezultatima rada koriste slabiji učenici što uzrokuje njihovu pasivnost u radu. Kako bi se navedeno reduciralo do minimuma i podigla efikasnost grupnih aktivnosti,

učenicima se mogu dati radni listovi na kojima je preciziran zadatak grupe, a članovi mogu dobiti različite uloge kako bi svaki član preuzeo dio odgovornosti za uspjeh grupe, odnosno tima. Uz to, teškoće se javljaju kad pojedinci ometaju aktivnost grupe, kad unutar grupe dolazi do sukoba i neslaganja te ako se cijela grupa ne drži zadanog, već se počne baviti nekim drugim aktivnostima. Iako je istraživanje provedeno na učenicima nižih razreda osnovne škole, Jurčić (2007) je u svom istraživanju ustanovio kako 22 % djece ne voli raditi u grupama te pretpostavlja kako otprilike oko 20 do 30 % djece školske dobi ne voli raditi u grupi ili timu. Ovdje je bitno istaknuti kako grupni i timski rad omogućuju kvalitetniji razvoj socijalnih vještina, ali unatoč tome ne postoji konsenzus, kao ni teorijom i/ili praksom utvrđene razlike, u kvaliteti stečenih znanja i vještina. Što se tiče rada u paru, uvijek je otežano praćenje rada svih parova te je moguće da učenici odbijaju komunikaciju s partnerom ili ako neki od učenika preferira individualni rad. Nedostatci individualnog rada obilježeni su socijalnim aspektima nastave te se očituju u slabijoj suradnji učenika među sobom, potencijalnim zatvaranjem u sebe, malom učinkovitošću slabijih učenika te ograničenjima u vrednovanju svakog učenika i usmjeravanju pri svladavanju zadataka.

Stoga je potrebno uravnotežiti kombiniranje socijalnih oblika kako bi nastava uzduž godišnjeg plana i programa imala određenu dinamiku i raznovrsnost. Raznovrsnost nastavne situacije pritom znači prepletanje pojedinih socijalnih oblika nastave radi oslobađanja učenikovih potencijala koji inače mogu ostati skriveni (Meyer, 2012). Upravo zbog perspektive dinamike nastavnog procesa proizlaze kritike adresirane na frontalnu nastavu zato što su iste usmjerene na njezinu pretjeranu dominaciju kao i na njezinu pogrešnu primjenu. Međutim, uvažavajući kompleksnost nastavnog procesa moramo razumjeti kako se vrijednost različitih nastavnih metoda, odnosno oblika rada, ne može vrednovati općenito, već uvijek samo relativno, s obzirom na didaktičku namjeru i kvalitetu učenja koju treba dostići (Meyer, 1997; prema Terhart, 2001). Ako nastavnik ne uspije uskladiti ciljeve, zadatke, sadržaje i metode, sat će biti neuspješan (neovisno o socijalnim oblicima rada koji su se pritom koristilli).

Sukladno tome, Terhart (2001) navodi kako u lošem minimalnom obliku frontalna nastava, kao i ostale metode, gubi svoje prednosti kao i općenito svoju pozitivnu funkciju u spektru školskog poučavanja. Jurčić (2012) tvrdi kako u kontekstu suvremene nastave ne možemo govoriti odvojeno o frontalnoj nastavi i/ili o radu u skupinama zato što se rad u skupinama ne može voditi pa ni započeti bez frontalne (izravne) poduke učitelja. Autor stoga kao kvalitetne socijalne oblike ističe kombinaciju frontalnog s ostalim oblicima unutar nastavnog sata. Svaki od socijalnih oblika rada ima svojih prednosti i nedostataka te ih stoga nema smisla međusobno uspoređivati, već moramo razmišljati u smjeru njihova kombiniranja

kako bismo optimizirali prednosti svakog od oblika.

Svaka nastavna jedinica uvijek je kombinacija različitih socijalnih oblika nastave unutar kojih se sve usmjerava na stvaranje produktivnih procesa učenja za svakog učenika. Pritom je potrebno balansirati frontalni rad s ostalim oblicima rada što se realizira nizom postupaka nastavnika kojima odlučuje u kojoj će se mjeri direktno umiješati u nastavni proces, a koliko će prepustiti učenicima da rade bez direktnog posredovanja nastavnika. Od nastavnika se očekuje da odluči kada će i koliko često koristiti pojedine socijalne oblike rada, s obzirom na razredno ozračje i specifičnosti svakog razrednog odjela, a raznovrsnost će socijalnih oblika i nastavnih metoda, pored nastavne dinamike, omogućiti aktualizaciju potencijala većeg broja učenika u nastavi.

2.2.4. Didaktička načela nastave matematike

Didaktička se načela ne nameću nastavi, već se moraju izvesti iz njezinih zakonitosti (Jurčić, 2012) te moraju odražavati dijalektičnost nastavnoga procesa, odnosno kretanje po uzlaznoj crti, kretanje određeno suprotnosti polova te jedinstva bipolariteta. Temeljna načela nastave su: načelo zornosti i apstraktnosti, aktivnosti i razvoja, sustavnosti i postupnosti, diferencijacije i integracije, primjerenosti i akceleracije, individualizacije i socijalizacije, racionalizacije i ekonomičnosti te načelo prošlosti i suvremenosti (Poljak, 1991). Navedena načela su opća načela koja vrijede u svim školskim predmetima, no ista se pokazuju naročito značajnima u nastavi matematike što ćemo u nastavku ilustrirati na specifičnim situacijama i/ili obilježjima koja su karakteristična za nastavu matematike sve od razredne nastave pa do matematike koja se uči na studijima.

Načelo zornosti usmjereno je na usvajanje činjenica i znanja, a princip apstraktnosti na razvoj sposobnosti selektivne analize svojstava objekata ili pojava kako bi se promatranjem njihovih određenih svojstava došlo do svojevrsnih poopćenja. Apstrakcija je jedna od temeljnih obilježja matematike, ali je i među važnijim metodama koje se koriste u nastavi matematike. Zornost se odnosi na cjelovitost perceptivnog usvajanja znanja pomoću svih osjetila. Takvim pristupom omogućuje se učenicima potrebna kvaliteta znanja kako bi apstrakcijom mogli dovesti određeno znanje na drugu, višu razinu. Također, zornost doprinosi tome da učenici tijekom vremena akumuliraju dovoljnu kvantitetu činjenica kao materijalnu osnovu na temelju koje prelaze na apstrakcije i poopćenja znanja (Jurčić, 2012).

Zornost u nastavi matematike osnova je usvajanja svakog matematičkog pojma, koncepta, odnosno znanja. Može se tumačiti u kontekstu jasnoće pojašnjavanja nekih

geometrijskih objekata koji uključuju vizualnu percepciju, a razumijevanje aritmetičkih, algebarskih i nekih drugih tipova matematičkih koncepata i procesa podrazumijeva određenu multiperspektivnost, komunikacijsku vještinu i suštinsko razumijevanje sadržaja od strane nastavnika koji mu omogućuje strukturirano, jasno, sadržajno i učenicima prilagođeno poučavanje. Temeljna je pretpostavka visoka razina stručne osposobljenosti, poznavanje specifičnosti učenika u nastavi matematike te metakognitivne vještine nastavnika. Apstraktnost nije suprotno načelo od zornosti, već je njoj komplementarni dio u procesu logičkog rezoniranja i usvajanja matematičkih koncepata i procesa. Istovremeno, može se reći kako načelo apstraktnosti ima pretpostavku zornosti kao obilježje stečenih znanja. Stoga se pri evaluaciji učeničkih postignuća razina apstraktnosti kojom učenici barataju sadržajima uglavnom koristi i pokazuje kao jedan od ključnih kriterija visoko usvojenih razina znanja.

Načelo aktivnosti i razvoja podrazumijeva aktivnost učenika u nastavnom procesu uključujući njegove intelektualne, senzorne, praktične i izražajne sposobnosti. Dijalektičnost načela aktivnosti i razvoja u nastavi iskazuje se u odnosu: vođene i slobodne aktivnosti, reproduktivne i produktivne aktivnosti, jednostavne i složene aktivnosti, praktične i intelektualne aktivnosti (Jurčić, 2012). Najvažniji su aspekti aktivnosti i razvoja motivacija i emocionalna strana nastavnog procesa kao temeljni preduvjeti kvalitetne nastave matematike (više u poglavlju 2.4.1).

Diferenciranje nastavnog procesa u njegovim organizacijskim i konceptualnim sastavnicama prirodno mora slijediti proces integracije, odnosno organizacijskog sjedinjenja i sinteze svih tih elemenata. *Načelo integracije, osim sadržajnoga, ima i organizacijski aspekt koji se ogleda u zahtjevu da se pojedino vremensko razdoblje sagleda u svojoj kompleksnosti i specifičnosti, uz njega je vezano i načelo integracije koje, osim ovoga globalnog pristupa, naglašava i potrebu mikrostrukturiranja odgojno-obrazovnog procesa.* (Jurčić, 2012, str. 54) Na taj način, načelo diferencijacije i integracije povezano je s metodom analize i sinteze što ćemo prikazati općenito i na konkretnim primjerima u sljedećem poglavlju. Suprotstavljanje, odnosno sjedinjavanje diferencijacije i integracije kroz odgojno-obrazovne diskusije u prošlosti nije doživjelo potpuno suglasje, no u suvremenim obrazovnim trendovima to se mijenja, a naročito u kontekstu matematike u kojoj se jedinstveno načelo integracije i diferencijacije neminovno pokazuje kao jedini ispravan put u učenju i poučavanju matematike.

Načelo postupnosti i sustavnosti znači da nastavnik obrađuje nastavni sadržaj u određenom slijedu organiziranom u logičkim i svrsishodnim koracima kako bi učenici postigli očekivane odgojno-obrazovne ishode. Četiri osnovna pravila postupnosti prema Poljaku (1991) su: od bližeg prema daljem, od jednostavnog prema složenom, od lakšeg prema težem te od

konkretnog prema apstraktnom. O načelu postupnosti i sustavnosti suvišno je davati primjere iz nastave matematike zato što se matematika kao znanost i nastavni predmet temelji na istima te se i razvila prema navedenim načelima. Na nastavniku je izazov usuglašavanja nastavnih planova i programa s tempom rada i specifičnostima učenika u pojedinom razrednom odjelu kako bi ta načela saživjela s kontinuitetom u učenju i poučavanju.

Načelo primjerenosti i napora među temeljnim je obilježjima kurikuluma usmjerenog na učenika i obrazovne ishode koje učenici trebaju postići. Tim načelom osigurava se organizacija obrazovnog procesa primjerenog psihičkim i fizičkim karakteristikama učenika tako da nastava ne bude prelagana ili preteška te da se nastavni sadržaji proučavaju u vrijeme kada su za to zadovoljene pretpostavke predznanja, vještina i sposobnosti učenika. Zajedno s načelom postupnosti i sustavnosti, ovo se načelo pokazuje kao jedan od najvećih izazova nastave matematike. Naime, s godinama školovanja učenici akumuliraju znanja i vještine, no jednako tako nakupljaju se i propusti u učenju koji su nerijetko prisutni u razumijevanju fundamentalnih matematičkih koncepata i procesa. Jedan od načina rješavanja tog izazova su metode individualizacije i socijalizacije nastavnog procesa. Ukoliko nastavnik ne posreduje dovoljno informacija učenicima za obavljanje samostalnih aktivnosti, oni ne mogu ostvariti ciljeve nastave. S druge strane, ako nastavnik daje više no što im je potrebno kako bi samostalno odradili neke aktivnosti, učenicima će biti uskraćeno zadovoljstvo samostalnog pronalaska rješenja, ali i opterećenja potrebnog kako bi napredovali u razvoju vještina i stjecanju znanja.

Individualizacija i socijalizacija dva su suvremena didaktička načela kojima se nastavni ciljevi, sadržaji, oblici rada, metode i vrednovanje prilagođavaju učeniku i njegovim psihofizičkim, obrazovnim i odgojnim posebnostima te omogućuju razvoj socijalnih vještina, stjecanje društveno prihvatljivih normi, vrijednosti, stavova i sustava vrijednosti kako bi se razvio u odgovornu zrelu osobu. Slično tome, Bognar i Matijević (2002) navode kako načelo individualizacije zahtijeva organizaciju i izvođenje odgojno-obrazovnoga procesa na način koji omogućuje svakom učeniku zadovoljavanje njegovih specifičnih interesa i potreba te postupno izrastanje u autentičnu ličnost. Ova načela komplementarna su zato što je učenje individualna aktivnost, a čovjek kao društveno biće koje radi i živi s drugim ljudima mora usvojiti obrazovne, odgojne i socijalne vrijednosti kako bi mogao normalno funkcionirati u društvu. Kvalitetna individualizacija najlakše se ostvaruje u dopunskoj i dodatnoj nastavi (Jurčić, 2012). U redovnoj nastavi ista se provodi diferencijacijom nastavnih metoda, sadržaja i vrednovanja, ali se zbog načela primjerenosti nastava matematike kontinuirano suočava s problemima predznanja i nedostatkom motivacije učenika.

Putem principa historičnosti i suvremenosti učenici stječu odgojno-obrazovna dobra i vrijednosti u njihovom razvojnom kontekstu od prošlosti do danas. Mnogi prirodni i društveni fenomeni imaju svoj razvojni period i proces koji se u kontekstu nastavnih predmeta trebaju razmatrati i poučavati u dijalektičnom kretanju od prošlosti do sadašnjosti. Pored nastavnih sadržaja, isto je potrebno sagledati u kontekstu predmetnog područja te ulozi koju dotična struka i znanost ima u svijetu danas, kakvu je imala kroz prošlost te koje su joj moguće perspektive. Što se toga tiče, matematika je svakako među istaknutijim školskim predmetima koja pored sadržajnih i konceptualnih primjena u drugim strukama i znanostima ima i bogatu povijest ljudi, odnosno znanstvenika koji su kroz povijest svojim otkrićima pomicali spoznajne granice i mijenjali svijet. To upućuje na velik potencijal u smislu motivacije kroz različite zanimljivosti povezujući povijest, različite kulture i nacionalnosti s otkrićima koja su bila značajna za razvoj znanosti i društva ili pak užih područja znanstvenih i/ili stručnih djelatnosti.

Načelo racionalizacije i ekonomičnosti integralni je dio svake nastavne jedinice kao i operacionalizacije nastavnih planova i programa. Smisao je ekonomičnosti da se postigne najveći učinak sa što manjim utroškom vremena, sredstava i snaga. Racionalizirati nastavu znači provesti pomno smišljene metode u nastavnim postupcima kako bi se postigao kvalitetniji rezultat i veći učinak poučavanja. Radi se o jedinom načelu koje se na određeni način suprotstavlja svim ostalim načelima i ponajbolje odražava suvremene trendove unutar kojih se kapitalistički i industrijski modeli primjenjuju na gotovo sva područja ljudske djelatnosti.

Naime, ovo načelo proizlazi iz prostornih i vremenskih ograničenja, iz uvjeta karakterističnih za suvremene odgojno-obrazovne sustave koji podrazumijevaju:

- postupke koji su univerzalni, ali nisu individualizirani
- pojašnjavanje koje ima zornost kao cilj, ali nema vremena za procjenu realizacije zornosti
- nastavu koja je postupna u sadržajima i primjerena dobi te odgojno-obrazovnom programu, ali ne i učeniku
- nastavu u kojoj se princip historičnosti i suvremenosti svodi na imena matematičara iza teorema koji se uče u nastavi
- nastavu koja je diferencirana, ali nije popraćena sadržajnom integracijom.

Sukladno tome, načelo racionalizacije i ekonomičnosti mogli bismo svesti na obilježje i/ili pretpostavke sustava odgoja i obrazovanja te nastavnog procesa. Naime, ostala načela svojim su određenjem usmjerena na kvalitetu nastave i proces učenja i poučavanja u kojem sjedinjavanjem istih u komplementarni odnos omogućujemo realizaciju obrazovnih ishoda. S

druge strane, tamo gdje je potrebna racionalizacija i ekonomičnost, po prirodi će nastavnog procesa izostati neka od načela koja su prijeko potrebna za usvajanje znanja i razvoj vještina učenika. Kako bismo u nastavi optimalno primjenjivali pojedina didaktička načela, važno je razumjeti njihovu ulogu i funkciju u nastavi te složenost njihova međuodnosa u realizaciji ciljeva nastave. U kontekstu nastave matematike Kurnik (2009) izdvaja načelo znanstvenosti koje se sastoji od sljedećih metoda: analiza i sinteza, analogija, apstrakcija i konkretizacija, indukcija i dedukcija, generalizacija i specijalizacija koje će se detaljnije razraditi u sljedećem poglavlju.

2.2.5. Metode u nastavi matematike

Riječ „metoda“ proizlazi iz starogrčke riječi „methodos“ kojom se označava put ili redoslijed koraka koji vode do postavljena cilja. Nastava usmjerena na ciljeve učenja ima metodički organiziran proces učenja i proučavanja koji se oslanja na koncept cilja i sredstva, a pitanje kvalitetnog nastavnika istovjetno je potrazi za najboljom metodom usmjerenom na uvjete za uspjeh u učenju (Terhart, 2001). *Nastavne metode su oblici i postupci u i s kojima nastavnici i učenici pod institucionalnim okvirnim uvjetima usvajaju prirodnu i društvenu zbilju koja ih okružuje* (Meyer, 1987, I, str.45). Poljak (1991) definira nastavne metode kao didaktički promišljen i optimalno uređeni sustav aktivnosti poučavanja i učenja kojima je primarni cilj da učenik stekne određena znanja i vještine, razvije određene sposobnosti i druge relevantne osobine (Poljak, 1991). *Nastavne metode služe tome da se nastavniku omogući uspješno poučavanje, a učeniku uspješno učenje. Poučavanje i učenje su uvijek usmjereni na sadržaje okrenute određenom cilju - na znanja ili spoznaje, sposobnosti ili umijeća, obrasce ponašanja ili stavove* (Klafki, 1985, str.79). Dakle, one su sredstvo za postizanje ciljeva nastave, a temelje se na didaktičkom pristupu nastavi. Sintezom brojnih određenja i definicija nastavne metode, Terhart (2001) navodi četiri dimenzije koje se najčešće pojavljuju: dimenzija „postizanja cilja“, dimenzija „susreta s predmetom“, dimenzija „pomoć u učenju“, dimenzija „okvira“. Nastavne metode moraju biti usmjerene na sadržaj učenja te moraju biti u skladu s učenjem nastavnog predmeta.

Uvjetovano zadaćama nastavnog procesa, nastavnici i učenici u učenju i poučavanju kombiniraju metode, a prednost se daje onim metodama koje potiču učenikovu samostalnost, stvaralaštvo, stjecanje znanja, razvijanje sposobnosti i usvajanje vrijednosti (Jurčić, 2012). Uobičajene nastavne metode su: metoda demonstracije, metoda praktičnih radova, metoda crtanja, metoda pisanja, metoda čitanja i rada na tekstu, metoda razgovora te metoda usmenog

izlaganja. Svaka od metoda ima dvostrano značenje, tj. odnosi se na način rada nastavnika i učenika.

Međutim, u nastavi matematike posebno mjesto imaju metode mišljenja i logičkog rezoniranja. Prema načelu znanstvenosti, osnovne metode mišljenja i istraživanja u nastavi matematike su analiza i sinteza, apstrakcija i konkretizacija, indukcija i dedukcija, generalizacija i specijalizacija te analogija (Kurnik, 2009). Načelo znanstvenosti sastoji se od nužnog sklada nastavnih sadržaja i nastavnih metoda s jedne strane te zahtjeva i zakonitosti matematike kao znanosti s druge strane. Sve metode dolaze u parovima, osim analogije. Te su metode temelj matematičkog mišljenja i zaključivanja, ali su svojstvene i drugim znanostima što zbog svekolikih primjena pridaje značaju matematičkog načina razmišljanja.

Prvi par, metoda analiza i sinteza, na svojevrstan su način suprotne, ali se nadopunjuju i zajedno čine jedinstvenu analitičko-sintetičku metodu. Analiza je znanstvena metoda istraživanja koja se zasniva na raščlanjivanju cjeline na dijelove, proučavanju dijelova i izvođenju zaključaka o cjelini na temelju dobivenih rezultata (Kurnik, 2009). Analiza je misaoni postupak kojim započinjemo rješavanje svakog zadatka i problema te taj problem raščlanjujemo i/ili svodimo na jednostavnije probleme i tvrdnje čijim ćemo rješavanjem doći do rješenja zadatka. Prema tome, analiza je metoda kojom problem rješavamo unatrag, a ona završava kada je uspostavljena veza između postavljenog problema i utvrđenih činjenica. S druge strane, sinteza je metoda kojom povezujemo proučene/analizirane dijelove u cjelinu koja rješava postavljeni problem. Analizom utvrđujemo odnose u zadatku na temelju indikativnih komponenti zadatka sljedeći matematička pravila te temeljem toga stvaramo plan rješavanja i dolazimo do rješenja. Sintezom uvrštavamo rješenje u početni zadatak te provjeravamo istinitost tvrdnje. U matematici se ponekad može dogoditi da unatoč ispravnom postupku dobiveno rješenje nije rezultat zato što dobiveni rezultat može biti u proturječju s nekim pravilima i zakonitostima u konkretnom slučaju što se tipičnom analizom nije moglo predvidjeti.

To ćemo prikazati na primjeru rješavanja jednadžbe s algebarskim izrazima koje se uče u prvim razredima srednjih škola.

Primjer 1: *Riješi jednadžbu* $\frac{1}{2x}-\frac{1}{1-2x}=\frac{4x}{4x^2-1}$

Rješenje:

$$\frac{1}{2x}-\frac{1}{1-2x}=\frac{4x}{4x^2-1}$$

$$\frac{1}{2x}-\frac{1}{1-2x}=\frac{4x}{(2x-1)(2x+1)} \qquad /\cdot 2x(2x-1)(2x+1)$$

$$(2x-1)(2x+1)+2x(2x+1)=4x\cdot 2x$$

$$4x^2-1+4x^2+2x=8x^2$$

$$2x=1$$

$$x=\frac{1}{2}$$

Gore prikazani postupak odnosi se na analizu, odnosno raščlambu problema, tj. svođenje početne jednadžbe na njoj ekvivalentne jednadžbe koristeći za to primjerene računske operacije kako bi početnu jednakost pojednostavljivanjem doveli do njezine najjednostavnije forme koju najčešće smatramo završetkom zadatka. Tako provedenom analizom, početna je jednadžba svedena na konačno rješenje $x=\frac{1}{2}$ čime je završena analiza zadatka.

S druge strane, sintezom vršimo rekonstrukciju zadatka kojom, u konačnici, provjeravamo ispunjava li dobiveno rješenje početnu jednakost, odnosno je li dobivena nepoznanica *x* doista rješenje gornje jednadžbe. Tako se uobičajenim postupkom sinteze unazad provjeravaju svi koraci koji su prikazani u postupku rješavanja, a najvažniji je moment uvrštavanje konačnog rješenja u početnu jednakost (učenicima pritom treba sugerirati da stalno provjeravaju cijeli postupak, a neki od njih će s iskustvom i s vremenom razviti neke svoje mehanizme i intuiciju kada će imati problema u pronalasku rješenja).

Učinimo li to, dobit ćemo: $\frac{1}{2\cdot\frac{1}{2}}-\frac{1}{1-2\cdot\frac{1}{2}}=\frac{4\cdot\frac{1}{2}}{4\left(\frac{1}{2}\right)^2-1}$

$$\frac{1}{1}-\frac{1}{0}=\frac{2}{0}$$

Uvrštavanjem dobivenog rezultata u početnu jednakost dobivena je jednakost koja je u proturječju s osnovnim matematičkim pravilima što se u ovom slučaju iskazuje u dijeljenju s nulom. S obzirom na to da rješenje dobiveno analizom početne jednakosti ne ispunjava uvjete te jednadžbe, zaključujemo kako ova jednadžba nema rješenja, odnosno kako je rješenje da *jednadžba nema rješenja*.

U sintezi je bitno da se provjere svi koraci unatrag, do uvrštavanja u početnu jednakost, što je naročito bitno za učenike koji češće čine karakteristične greške. Naime, ukoliko su učenici u analizi jednadžbe primijenili pogrešne operacije ili ih krivo primijenili, mogu dobiti rješenje

koje sintezom također neće odgovarati početnoj jednadžbi, ali to ne znači nužno da jednadžba nema rješenja, već je vjerojatno neki drugi broj ili više njih.

Ovaj tip zadatka uobičajeno se prikazuje i rješava nakon nekoliko zadataka istog tipa koji imaju rješenja koja ne dolaze u kontradikciju s početnom jednakošću. Nastavnik pritom može odabrati hoće li to sam demonstrirati i heuristički navoditi učenike ili će na satu prikazati konvencionalne zadatke, a ovaj će ovaj tip zadatka ostaviti za domaću zadaću ili ih unutar nastavnog sata unaprijed dati uspješnijim učenicima, a kasnije i ostalima. Pri zadavanju takve zadaće, bitno je istaknuti koji se postupci i procedure koriste s naglaskom na tipične greške utvrđene na tom satu, a učenicima je dovoljno istaknuti da provjere odgovaraju li njihova rješenja onima iz udžbenika u kojima, u slučaju ovakvih zadataka, piše kako „nema rješenja“. U ovisnosti o razini znanja učenika, u razrednom odjelu nastavnik odlučuje koliko će uputa i „hintova“ dati učenicima kako bi ih u pomalo zagonetnom tonu motivirao za rješavanje zadaće.

Pri evaluaciji domaće zadaće, kao i u slučaju kada učenici samostalno rješavaju taj zadatak uz upute nastavnika, poželjno je da nastavnik zajedno s učenicima donese potrebne zaključke i ususstavi ovu (za učenike) pomalo neobičnu situaciju u kojoj se vjerojatno po prvi put susreću s jednadžbama ovog karaktera. Specifično je za jednadžbe ovog tipa nepoznanica x koja se u različitim oblicima pojavljuje u nazivniku algebarskih razlomaka. To implicira kako je nazivnik varijabilan te kako potencijalno rješenje koje tražimo u skupu realnih brojeva može biti i *nula*, a to je u proturječju s aksiomatskim polazištima u matematici. U nastavi matematike to službeno nazivamo uvjetima zadatka, a isti se mogu ispitivati prije rješavanja jednadžbe metodom analize ili nakon rješavanja kako smo prikazali u primjeru sinteze zadatka. Međutim, zbog brzopletosti i ponekog slavodobitnog zanosa nakon dobivenog rješenja jednadžbe, preporučljivo je učenicima sugerirati da provjere uvjete odmah na početku zadatka zato što praksa pokazuje da isto često zaborave.

Na gore prikazanom primjeru to se izvodi na sljedeći način:

Iz početne se jednakosti istaknu tri uvjeta zadatka budući da u jednadžbi imamo tri razlomka koji imaju *x* u nazivniku. Ta tri uvjeta ukazuju kako ti nazivnici moraju biti različiti od nule što ćemo zapisati na sljedeći način: (početna jednadžba $\frac{1}{2x}-\frac{1}{1-2x}=\frac{4x}{4x^2-1}$)

1. uvjet

$$2x \neq 0$$
$$x \neq 0$$

2. uvjet

$$1-2x \neq 0$$
$$2x \neq 1$$
$$x \neq \frac{1}{2}$$

3. uvjet

$$4x^2-1 \neq 0$$
$$4x^2 \neq 1$$
$$x^2 \neq \frac{1}{4}$$
$$x \neq \pm\frac{1}{2}$$

Na taj smo način dobili tri uvjeta, odnosno tri vrijednosti za nepoznanicu *x* koje nikako ne mogu biti rješenje početne jednadžbe te ih zbog toga nazivamo *uvjeti zadatka*. To su brojevi 0, $\frac{1}{2},-\frac{1}{2}$ koji neovisno o konačnom ishodu rješavanja jednadžbe ne mogu biti rješenja, a jedno od njih, rješenje $x=\frac{1}{2}$, pokazalo se kao rješenje nakon analize i prve faze rješavanja jednadžbe. To implicira kako ostali realni brojevi kao potencijalna rješenja zadatka neće biti izostavljeni u postupku sinteze i samog uvrštavanja rješenja u početni oblik jednadžbe te će ispunjavati uvjete zadane jednakosti.

Drugi je par metoda konkretizacija i apstrakcija koji se preklapa s načelom apstraktnosti i zornosti u nastavi. Konkretizacija je misaona aktivnost kojom se usredotočujemo na određeno svojstvo nekog objekta neovisno o ostalim svojstvima. Apstrakcija je proces misaonog odvajanja/izdvajanja promatranog svojstva objekta ili pojave od ostalih svojstava koja nisu u vezi s tim svojstvom.

Konkretizacija je manje zahtjevna vještina te ne traži toliko visok stupanj usvojenih znanja i logičkog zaključivanja, ali je zato prikladna za rad s učenicima koji imaju teškoće u učenju i uspijevaju usvojiti samo niže razine znanja. To se odnosi na uvrštavanje brojeva u poznate formule i izvođenje nekih jednostavnijih algoritama.

Možda je najbolji primjer toga rješavanje kvadratne jednadžbe u drugom razredu srednje škole uvrštavajući koeficijente kvadratne jednadžbe u formulu za njezina rješenja.

Primjer 2: *Riješi jednadžbu* $2x^2 - 6x - 8 = 0$.

Rješenje: Učenicima je prethodno prikazana formula za opća rješenja kvadratne jednadžbe oblika $ax^2 + bx + c = 0$ koja glasi:

$$x_{1,2} = \frac{-b \pm \sqrt{b^2 - 4ac}}{2a}$$

Rješavanje ove jednadžbe svodi se na konkretizaciju gornje formule na koeficijente a, b i c koji su u ovom slučaju jednaki a = 2, b = -6 te c = -8.

$$x_{1,2} = \frac{-6 \pm \sqrt{6^2 - 4 \cdot 2 \cdot (-8)}}{2 \cdot 2}$$

$$x_{1,2} = \frac{-6 \pm \sqrt{100}}{4}$$

$$x_{1,2} = \frac{-6 \pm 10}{4}$$

$$x_1 = 1 \qquad x_2 = -4$$

S druge strane, apstrakcija kao proces izdvajanja promatranih svojstava objekta ima svoju ulogu u gotovo svim aspektima razmatranja matematičkih koncepata i procesa. Kurnik (2009) navodi primjer nekog predmeta u ravnini i/ili prostoru čija svojstva možemo izdvajati sukladno svakom fizičkom objektu. Trivijalni je primjer toga trokut koji možemo razlikovati s obzirom na duljine stranica i veličine kutova. U takvoj specifičnoj apstrakciji možemo se fokusirati na duljine stranica te se pritom udaljavamo od svojstava koja se tiču veličine kutova ili nekih drugih svojstava. Rezultat je takve apstrakcije klasifikacija trokuta na raznostranične, jednakokračne i jednakostranične trokute. Za neko tijelo u prostoru to su položaj, oblik i veličina.

Kurnik (2009) ističe konkretizaciju i apstrakciju kroz specifične primjene matematike u fizici koje su opisane sljedećim formulama:

$v_t = v_0 + at$ *(brzina tijela ovisno o vremenu)*

$l_t = l_0 + bt$ *(linearno rastezanje metalnog štapa)*

$V_t = V_0 + ct$ *(volumno rastezanje čvrstih tijela pri zagrijavanju)*

$T_F = \frac{9}{5} T_c + 32$ *(veza između Celsiusovih i Fahrentheitovih stupnjeva)*

Svaka od navedenih formula konkretizacija je linearne funkcije pa stoga možemo reći kako apstrahiranjem navedenih formula utvrđenih temeljem konkretnih pojava apstrakcijom dolazimo do linearne funkcije $f(x) = ax + b$ kao apstraktnog matematičkog objekta koji u sebi obuhvaća sve navedene pojave. Daljnja analiza te funkcije, u smislu razvijanja teorije o njezinim svojstvima (što je karakteristično za matematiku), može na općenitoj razini doprinijeti mnogim zaključcima i detaljnijim analizama i razumijevanju koja su općenita egzaktna za svaku od navedenih primjena.

Indukcija i dedukcija temelj su u procesu zaključivanja i otkrivanja novih spoznaja na temelju poznavanja nekih relevantnih činjenica, pravila i zakonitosti. Indukcija je način zaključivanja kojim iz dvaju ili više pojedinačnih tvrdnji ili činjenica zaključujemo neku opću tvrdnju. Dedukcija je oblik zaključivanja kojim od opće tvrdnje ili više njih dolazimo do manje općenite tvrdnje koja iz njih proizlazi ili je u njima sadržana. Indukcija i dedukcija provode se matematičkim dokazom te proizlaze iz korpusa matematičkih znanja i vještina koje su preduvjet takvom zaključivanju. Po svojoj prirodi matematika je deduktivna znanost, a matematika u nastojanju eksperimentalna je induktivna znanost (Kurnik, 2009).

Primjer 3 (induktivno razmišljanje): Iz navedenih jednakosti utvrdi opću formulu za sumu prvih „n“ prirodnih brojeva.

$$1 = 1$$
$$1 + 2 = 3$$
$$1 + 2 + 3 = 6$$
$$1 + 2 + 3 + 4 = 10$$
$$1 + 2 + 3 + 4 + 5 = 15$$
$$1 + 2 + 3 + 4 + 5 + 6 = 21$$
$$1 + 2 + 3 + \ldots + 8 + 9 + 10 = 55$$
$$\vdots$$
$$1 + 2 + 3 + \ldots + 98 + 99 + 100 = 5050$$

<u>*Rješenje:*</u>

Iz navedenih jednakosti, uz poneke upute i sugestije nastavnika, može se navesti učenike da uoče određene pravilnosti koje se pojavljuju u svakoj jednakosti:

$$1 + 2 + 3 = 6 = \frac{3 \cdot 4}{2}$$

$$1 + 2 + 3 + 4 = 10 = \frac{4 \cdot 5}{2}$$

$$1 + 2 + 3 + 4 + 5 = 15 = \frac{5 \cdot 6}{2}$$

$$1 + 2 + 3 + 4 + 5 + 6 = 21 = \frac{6 \cdot 7}{2}$$

$$\vdots$$

$$1 + 2 + 3 + \ldots + 8 + 9 + 10 = 55 = \frac{10 \cdot 11}{2}$$

$$\vdots$$

$$1 + 2 + 3 + \ldots + 100 = 5050 = \frac{100 \cdot 101}{2}$$

Tako se dolazi do opće formule za zbroj prvih *n* prirodnih brojeva: $1 + 2 + \ldots + n = \frac{n \cdot (n+1)}{2}$

Ova je općenita tvrdnja istinita, no u nastavi matematike bitno je napomenuti kako ovo ne predstavlja dokaz zato što postoje tvrdnje koje vrijede u prvih nekoliko slučajeva, a u nekom koraku jednostavno nisu točne. Postupak dokazivanja ovakvih tvrdnji radi se metodom matematičke indukcije koja se uči u četvrtom razredu srednje škole (*dokaz nije prikazan jer nije relevantan za daljnju ilustraciju ovog didaktičkog načela*). Ovo je oblik induktivnog zaključivanja koji često podrazumijeva niz vještina i sposobnosti te je istraživačkog karaktera što je rijetko u nastavi matematike, ali je bitno za razvoj logičkog i kreativnog mišljenja djece.

Iz osmog razreda osnovne škole prikladan je primjer za induktivno utvrđivanje formule zbroj kutova u mnogokutu.

Primjer 4: Odredite formulu za zbroj kutova u n-terokutu (mnogokutu) tako da utvrdite redom zbroj kutova u četverokutu, peterokutu, šesterokutu itd. polazeći od činjenice da je zbroj kutova u trokutu 180°. (Pomoć: zbroj kutova u četverokutu možemo ustanoviti ako ga razdijelimo na dva trokuta.)

Rješenje:

Nakon što učenici raspodijele u svaki od mnogokuta, doći će do sljedećih rezultata.

Zbroj kutova u trokutu: 180°

Zbroj kutova u četverokutu: 360°

Zbroj kutova u peterokutu: 540°

Zbroj kutova u šesterokutu: 720°

Zbroj kutova u sedmerokutu: 900°

Ukoliko ne uoče pravilnosti među ovim rezultatima, učenike treba navesti da uoče sljedeće:
Zbroj kutova u trokutu:
Zbroj kutova u četverokutu: 360° = 2 · 180° = (4 - 2) · 180°
Zbroj kutova u peterokutu: 540° = 3 · 180° = (5 – 2) · 180°
Zbroj kutova u šesterokutu: 720° = 4 · 180° = (6 – 2) · 180°
Zbroj kutova u sedmerokutu: 900° = 5 · 180° = (7 – 2) · 180°
Na taj se način dolazi do opće formule za zbroj kutova u mnogokutu s *n* kutova:

$$K_n = (n - 2) \cdot 180°$$

Generalizacija ili poopćavanje jedna je od osnovnih znanstvenih metoda istraživanja, ali način razmišljanja općenito u životu. Generalizacija je prijelaz s razmatranja danog skupa činjenica i tvrdnji na razmatranje njegova nadskupa. Ona u sebi sadrži analogiju koja joj prethodi, a izvodi se induktivnim načinom zaključivanja i razmišljanja. Specijalizacija je suprotna generalizaciji kojom se iz skupa činjenica i tvrdnji prelazi na njihov podskup, odnosno na tvrdnje koje su sadržane u njima. Kako je specijalizacija obrnuti proces te se često svodi na uvrštavanje konkretnih vrijednosti u općenite formule, u nastavku ćemo se usredotočiti na metodu generalizacije i njezinu ulogu u logičkom zaključivanju. Sljedeći primjer također će se prikazati u izvođenju specifične formule koju učenici još nisu imali prilike vidjeti, a pritom će se koristiti i induktivno zaključivanje i apstrahiranje po određenim svojstvima kako bismo mogli generalizirati više formula iz principa koji se može ustanoviti iz danih zadataka.

Primjer 5: Izračunaj i utvrdi princip koji poopćava proces dolaska do rješenja u sljedećim zadatcima:

a) $2^3 \cdot 2^5$ *b)* $2^2 \cdot 2^7$ *c)* $2 \cdot 2^4$

Rješenje:

a) $2^3 \cdot 2^5 = 8 \cdot 32 = 256$ *(učenici moraju ustanoviti kako je* $2^8 = 256$*)*

b) $2^2 \cdot 2^7 = 4 \cdot 128 = 512$ *(učenici moraju ustanoviti kako je* $2^9 = 512$*)*

c) $2 \cdot 2^4 = 2 \cdot 16 = 32$ *(učenici moraju ustanoviti kako je* $2^5 = 32$*)*

Učenici poopćavanjem mogu uočiti kako je $2^3 \cdot 2^5 = 2^8$, $2^2 \cdot 2^7 = 2^9$ *te* $2 \cdot 2^4 = 2^5$ iz čega slijedi općenita formula $2^x \cdot 2^y = 2^{x+y}$.

Međutim, metodom poopćavanja, odnosno apstrakcije po određenim svojstvima ovih jednakosti mogu se izvesti sljedeće generalizacije (samo neke od njih):

Prva generalizacija (po bazi potencije): $a^x \cdot a^y = a^{x+y}$

Druga generalizacija (po brojčanosti baza potencija): $a^{x_1} \cdot a^{x_2} \cdot \ldots \cdot a^{x_n} = a^{x_1+x_2+\ldots+x_n}$

Treća generalizacija (po bazi potencije): $a^x \cdot a^x \cdot \ldots a^x = a^{x+x+\ldots x} = a^{nx}$

Iz treće generalizacije slijedi: $\left(a^x\right)^n = a^{n \cdot x}$

Ovaj je primjer prilično sličan onome iz induktivnog načina razmišljanja te je trivijalan za učenike prvog razreda srednje škole, uz pokoju uputu nastavnika i proizvoljnu pomoć kalkulatora u istraživanju odnosa među rezultatima danih zadataka. Međutim, sljedeći primjer ima poopćavanje koje se također odvija po određenom principu, ali to ne znači da će se pripadna formula mijenjati u skladu s očekivanjima.

Primjer 6: Odredi formulu udaljenosti između točaka (brojeva) na brojevnom pravcu. Poopćavanjem te metode, utvrdi formulu za udaljenost točaka u koordinatnom sustavu (dvodimenzionalnom prostoru).

Rješenje:

(Napomena: Formula za udaljenost između točaka (brojeva) na brojevnom pravcu u praksi se, uglavnom, direktno posreduje učenicima bez pojašnjavanja iste, a pažnja se više daje sadržajima na koje se ista nadovezuje.)

Ukoliko nastavnik odluči heuristički voditi učenike kako bi sami otkrili formulu, prikladno je dati im sljedeća tri para brojeva čiju udaljenost trebaju odrediti na brojevnom pravcu:

a) 3 i 8
b) -5 i -12
c) -6 i 10

Naime, iz a) zadatka čini se kako bi formula mogla biti „ x – y “ što bi podrazumijevalo da od većeg broja oduzmemo manji. Međutim, primjenom istog principa u b) zadatku dobili bismo negativno rješenje, a udaljenost mora biti pozitivan broj. To je izvjesno i u c) zadatku, a također je i pomalo nespretna konstatacija „veći broj minus manji broj“ (što se može očekivati od

učenika) zato što formula mora biti univerzalna za ulazne vrijednosti, odnosno brojeve *x* i *y* neovisno o njihovom rasporedu (prvi i drugi broj) te mora dati rezultat koji ima svojstva udaljenosti kao pozitivne vrijednosti i u skladu je s geometrijskom interpretacijom tog zadatka. U heurističkom razgovoru potrebno je usmjeriti mišljenje učenika te podsjetiti kako postoji funkcija koja „pretvara“ negativne brojeve (vrijednosti) u njima suprotne, odnosno pozitivne vrijednosti. Radi se o funkciji *apsolutne vrijednosti*, a ukoliko se netko od učenika dosjetio iste, jedino preostaje to primijeniti na početnu formulu x-y iz čega se pokazuje kako je rješenje jednako apsolutnoj vrijednosti razlike između zadanih brojeva što zapisujemo kao $|x-y|$.

Učenicima se na kraju može prepustiti da sami ustanove funkcionira li formula za sve zadane realne brojeve *x* i *y* neovisno o redoslijedu brojeva, tj. koji je broj *x*, a koji *y*. U takvoj koncepciji nastave poželjno je individualizirati usmjeravanje učenika prema rješenju tako što će nastavnik istovremeno komunicirati s cijelim razrednim odjelom, ali pritom imati svojevrsnu „skrivenu“ komunikaciju s učenicima koji brže zaključuju na način što ne izgovore rješenje na glas (kada je to moguće), kako bi većem broju učenika bilo omogućeno, samostalno i neovisno o drugima, doći do rješenja. Za bolje učenike opcionalno se može postaviti problem u dvodimenzionalnom i trodimenzionalnom prostoru te potencijalnoj generalizaciji za *n*-dimenzionalni prostor što je uobičajena procedura karakteristična za visokoškolsku matematiku (isto će biti prikazano na primjeru generalizacije u primjeru 7).

Analogija je jedina metoda koja ne dolazi u paru te se odnosi na proces kojim se iz podudaranja dvaju objekata u određenim svojstvima ili odnosima izvodi zaključak kako se oni podudaraju i u nekim drugim svojstvima. Analogija je sastavni dio gotovo svakog matematičkog mišljenja i logičkog razmišljanja, bilo u postupku induktivnog i deduktivnog razmišljanja, u izvođenju generalizacija i apstrakcija te u postupcima analize i sinteze koji često funkcioniraju po određenim principima analogije.

Kako je u *primjeru 6* utvrđena formula za udaljenost dvaju realnih brojeva *x* i *y*, metodom analogije na sljedećem primjeru provest ćemo generalizaciju formule za dvodimenzionalni i trodimenzionalni prostor.

Primjer 7: Odredi formulu za udaljenost dviju točaka A (x_1, y_1) i B (x_2, y_2).

Udaljenost između točaka uobičajeno se označava s *d (A, B)*, a u nastavku ćemo skraćeno zapisati samo *d*.

Izvođenje analogije i potencijalna generalizacije ove formule nešto je drugačija zato što se ne možemo fokusirati samo na formulu u njezinoj algebarskoj formi i zaključiti rješenje kao kod

poopćavanja pravila potenciranja, već prije svega moramo razumjeti što predstavlja udaljenost dviju točaka u koordinatnom sustavu.

Formula udaljenosti dviju točaka dolazi po Pitagorinu poučku prema kojem iz prikazana trokuta slijedi: $(x_2 - x_1)^2 + (y_2 - y_1)^2 = d^2$

Odavde slijedi konačna formula: $d(A, B) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$.

Dakle, ova formula analognim razmišljanjem i metodom apstrakcije pri prijelazu iz jednodimenzionalnog prostora u dvodimenzionalni nema očekivanih sličnosti, no pokazuje kako pri prijelazu iz dvodimenzionalnog u trodimenzionalni prostor ipak postoji i algebarski analogon koji je usuglašen s položajem i koordinatama točaka u prostoru A (x_1, y_1, z_1) i B (x_2, y_2, z_2) i u skladu je s očekivanom analogijom po obliku formule.

Dakle, formula za udaljenost točaka u (trodimenzionalnom) prostoru glasi:

$$d(A, B) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2 + (z_2 - z_1)^2}$$

Nastava matematike obiluje analogijama te je prožeta analognim načinom razmišljanja. Iste mogu biti u kontekstu algebarskih izraza, formula i pripadnih geometrijskih i analitičkih svojstava, ali i u najjednostavnijem opisivanju nekih matematičkih objekata i njihovih svojstava. Tako, primjerice, u osnovnoj školi djeca uče kako je kvadar kao tijelo u biti prostorni analogon pravokutnika, kako je kocka prostorni analogon kvadrata te kako je piramida prostorni analogon trokuta i sl. Analogija u paru s ostalim znanstvenim metodama karakterističnim za matematičko mišljenje čini osnovu općeg logičkog i intelektualnog rezoniranja pojedinca te se stoga njihova obrazovna vrijednost mora sagledavati puno šire od konteksta sadržaja nastave matematike.

2.2.6. Didaktički sustavi u nastave matematike

Didaktički sustavi nastave temelje se na načinu poučavanja nastavnika koji mogu biti: heuristički, problemski, egzemplarni, programirani i mentorski.

U heurističkoj nastavi nastavnici svojim načinom poučavanja misaono vode učenike do shvaćanja, usvajanja i razumijevanja obrađivanih sadržaja. Dominantno je mjesto u pripremi takve nastave poučavanje nastavnika koje mora biti odmjereno u davanju informacija i navođenju učenika prema zaključcima o odnosima promatranih činjenica i informacija. Prema tome, najlakše se može realizirati frontalnim radom nastavnika što je naročito potrebno pri

obradi složenijih sadržaja koje učenici jedino mogu shvatiti uz pomoć kvalitetnog vođenja od strane nastavnika. Nedostatak heurističke nastave nalazi se u procesu misaonog vođenja u kojem je komunikacija ograničena na manji broj učenika koji su prije došli do zaključaka. U nastavi matematike specifičnost je heurističke nastave u predznanju učenika koje je temeljni preduvjet razumijevanja nastavnikova vođenja budući da se sadržaji u matematici kumulativno izgrađuju. Pitanje predznanja opći je problem nastave matematike jer je svako stjecanje novih znanja i vještina uvjetovano učenikovim predznanjem, neovisno o didaktičkim sustavima kojima se nastavnik koristi. Zato nastavnici, pri svakom planiranju nastave, moraju voditi računa o predznanju učenika kako bi varijacijom nastavnih metoda unutar didaktičkih sustava omogućili učenicima povezivanje novih i starih nastavnih sadržaja u jednu smislenu cjelinu. To se može postići dodatnim ponavljanjem sadržaja koji su pretpostavka za svladavanje novih.

S obzirom na pitanje ekonomičnosti i racionalizacije u nastavi, ponavljanje se ne može raditi u tolikoj mjeri koliko su zastupljeni problemi predznanja zato što se u realizaciji nastavnog plana i programa općenito ne ostavlja dovoljno mjesta kako bi se više ponavljalo, već je to ostavljeno za dopunsku nastavu koja je u praksi, nažalost, ograničena s obzirom na realne potrebe iste u nastavi matematike. U pripremi se mora voditi računa o mogućim odgovorima učenika čije se predviđanje temelji na poznavanju istih, a vođenje nastavnog sata zahtjeva visoku razinu pripremljenosti nastavnika kako bi moment *otkrivanja* u učenju bio ostvaren kod većeg dijela učenika. Naime, vođenje učenika u heurističkoj nastavi često se svede, i u konačnici ostvaruje, samo kod uspješnijih učenika boljeg predznanja koji mogu od samog početka tako pripremljene nastave lakše pratiti ključne pojmove i prisjetiti se relevantnih znanja u kojima su ostali učenici ponekad svedeni na „sudionike-gledatelje“ koji pritom pokušavaju pratiti komunikaciju nastavnika s uspješnijim učenicima. Nastavnik treba nastojati individualizirati misaono usmjeravanje učenika u okvirima komunikacije s cijelim razredom. To se može postići neformalnim „dogovorom“ s uspješnijim učenicima tako što će tijekom heurističkog razgovora učenici pozvati nastavnika da dođe do njih kako ne bi morali pričati na glas ili će postaviti indikativna pitanja od kojih će nastavnik procijeniti jesu li saznali odgovor. Ostali učenici i dalje će samostalno otkrivati kako bi barem većina bila na tragu rješenja i/ili odgovora.

Isto se mora razmatrati u okviru razrednog ozračja za koji je potrebno da se svi učenici ugodno osjećaju, ali naglasak u ovom aspektu nastave matematike treba biti u sferi intelektualne autonomije i pozitivnog akademskog samopoimanja učenika. Cilj je pritom da učenici imaju kontinuitet u radu, ali s obzirom na specifičnosti afektivnih dimenzija nastave matematike, nastavnici trebaju jednako tako voditi računa o kontinuitetu motivacije učenika. Naime, kako

učenicima prijelazom u više razrede i na više razine obrazovanja postupno pada motivacija za učenje matematike, aspekt kontinuiteta u motivaciji pokazuje se kao jedan od prioritetnih ciljeva nastave matematike. Ukoliko se radi o nešto boljem razrednom odjelu te ukoliko tema nastavne jedinice nije presložena, obrada novih sadržaja može se prepustiti učenicima (uglavnom u srednjoj školi) kao neki oblik programirane nastave u kojoj će učenici dobiti jasne upute kako samostalno steći znanja i uvježbati vještine potrebne za svladavanje novih sadržaja.

Programirana nastava odnosi se na usvajanje znanja u etapama u kojoj svaka etapa sadrži spoznajnu vezu sa sljedećom etapom. Organizacija takve nastave dijeli se redom na: davanje informacija i njihovo usvajanje, formulacija i rješavanje zadataka te evaluacija, odnosno povratna informacija nastavniku. Prednost je takve nastave što se učenici u manjim koracima vode do cilja, njihov rad je individualiziran i dobivaju povratnu informaciju. Programirana je nastava najprikladnija te se najčešće koristi za rad u grupama i rad u timovima.

Egzemplarna nastava didaktički je sustav koji uključuje poučavanje nastavnika i samostalan rad učenika te stvaralački rad učenika i nastavnika. Pri osmišljavanju egzemplarne nastave, prvo treba diferencirati nastavne sadržaje kako bi se izdvojili oni bitni i reprezentativni (egzemplarni) pored onih ostalih, njima sličnih sadržaja. Time se osigurava realizacija opširnih nastavnih planova i programa te se učenicima šalje jasna poruka o sadržajima koji su temeljni u svakom poglavlju i nužni za svladavanje daljnjih sadržaja. Nakon te diferencijacije, obrađuju se egzemplarni sadržaji s naglaskom na kvalitetu logičkog ustrojstva nastavnih materijala i metodičkih strategija kako bi učenici mogli samostalno obrađivati slične sadržaje. Na kraju se svi sadržaji ponavljaju i provjeravaju što je idealni pristup u rješavanju zadataka tijekom obrade novog gradiva zato što nastavnik potiče učenike da samostalnim radom stječu nova znanja i vještine odmah nakon što ih je nastavnik primjerom demonstrirao.

Mentorska nastava slična je problemskoj nastavi, ali je razlika u poučavanju nastavnika koje se smanjuje i svodi uglavnom na povremenu pomoć i konzultacije kako bi se povećao samostalan rad učenika. Ukoliko su zadatci primjereni i kvalitetno vođeni od strane nastavnika, primjenom ovog didaktičkog sustava kvalitetno se ostvaruju odgojni i obrazovni ciljevi nastave koji često podrazumijevaju više razine usvojenih znanja te određeni stupanj matematičke zrelosti učenika. S obzirom na probleme predznanja u matematici, nastavnik mora procijeniti koliko je učenika u stanju raditi na taj način kako bi po potrebi unaprijed prilagodio metode i odabir sadržaja za takvu nastavu. U boljim razrednim odjelima, što se zbog selekcije učenika može u kontekstu srednjih škola svesti na gimnazije i poneke strukovne škole, mentorska nastava može se češće primjenjivati budući da u tim školama ima više motiviranih učenika koji

rade u kontinuitetu pa stoga nema potrebe za egzemplarnom nastavom kao u nekim manje zahtjevnim odgojno-obrazovnim programima.

Temeljem pregleda osnovnih didaktičkih sustava nastave matematike, razvidno je kako ti sustavi nisu međusobno isključivi, već naprotiv, može se kazati kako je poželjno, pa čak i nužno, kombinirati iste u većini nastavnih sati kako bi se mišljenje učenika kontinuirano vodilo i usmjeravalo u planiranim i programiranim koracima uvažajući specifičnosti razrednog odjela uz niz racionalno donesenih odluka od strane nastavnika koji odlučuje koliko će se voditi egzemplarnim metodama, a koliko mentorskim. U konačnici se sve svodi na njihovo kombiniranje ovisno o razini znanja i socijalnim dimenzijama razrednog odjela. Pritom je poželjno da bude, koliko je moguće, diferencirano prema razlikama među učenicima.

Problemska nastava didaktički je sustav usmjeren na osposobljavanje učenika za rješavanje brojnih životnih problema ili problema koji se mogu na njih svesti. Težište je na aktivnosti učenika, odnosno na njegovom pristupu zadanom problemu i načinu razmišljanja koji pritom koristi. Tijekom rješavanja problema razvija se stvaralačko mišljenje učenika za koje se općenito smatra kako je ključno za razvoj matematičkog načina razmišljanja, a istovremeno je ponajbolji indikator visoke razine usvojenosti znanja i pripadnog matematičkog mišljenja. S obzirom na važnost rješavanja problema u nastavi matematike i životu općenito, ova je tema sve aktualnija u odgojno-obrazovnim diskusijama te ćemo je zasebno prikazati u sljedećem poglavlju.

2.2.6.1 Problemska nastava

Problemska nastava didaktički je sustav usmjeren na osposobljavanje učenika za rješavanje brojnih životnih problema ili problema koji se mogu na njih svesti. Težište je na aktivnosti učenika, odnosno na njegovom pristupu zadanom problemu i načinu razmišljanja koji pritom koristi. Pri rješavanju problema razvija se stvaralačko mišljenje učenika za koje se općenito smatra kako je ključno za matematički način razmišljanja. Kurnik (2009) navodi kako suvremena nastava matematike zahtijeva i postavlja rješavanje dvaju važnih problema: problem razvoja stvaralačkog mišljenja i stvaralačkih sposobnosti učenika te problem odgovarajućeg osposobljavanja nastavnika matematike. S obzirom na to kako je težnja suvremenog obrazovanja da učenici što više vremena samostalno proučavaju matematičke sadržaje u kontekstu svakodnevnih situacija, problemska nastava pokazuje se idealnim modelom kojim će

učenici ovladati širokim spektrom misaonih operacija u rješavanju zadanih problema. Rješavanje problema jedan je od najviših oblika učenja zato što se učenika stavlja u istraživački položaj u kojem se pokreće njegovo stvaralačko mišljenje, a istovremeno podrazumijeva visoke razine stečenih znanja i usvojenih vještina.

U problemskoj nastavi naglasak je na iskustvenom učenju u rješavanju problema koji su najčešće iz svakodnevice kako bi se učenike motiviralo za učenje otkrivanjem. Nastavnik u problemskoj nastavi mora organizirati i isplanirati sljedeće: izbor problema, planiranje i selekciju nastavnih sadržaja, izbor metoda, oblika i sredstava nastavnog rada, pripremu didaktičkih materijala, motivacijske postupke, odabir elemenata za stvaranje problemske situacije, poticanje logičkog mišljenja. Tijekom organizacije i planiranja problemske nastave, potrebno je motivirati učenike kako bi svojim istraživačkim radom kreirali nastavni proces koji nastavnik nadalje samo usmjerava ovisno o učeničkoj aktivnosti. Međutim, problemska nastava i problemski zadatci slabo su zastupljeni u nastavi matematike te su uglavnom prisutni u matematičkim natjecanjima i dodatnoj nastavi koja najčešće služi za pripremu natjecatelja.

Problemska nastava s jedne se strane pokazuje nužnom u vidu stjecanja viših razina znanja, a s druge se strane pokazuje potrebnim povezati matematiku sa stvarnim životom kako bismo istaknuli njezinu važnost (važnost njezinih sadržaja) i ulogu u društvu. Međutim, s izuzetkom osnovnoškolskih matematičkih koncepata i sadržaja, većina se primjena matematike realizira kroz artificijelne primjere koji gotovo nikada ne opisuju stvarni život ili kroz kontekst nekih problema koje želimo prikazati kao probleme iz svakodnevice. Albert Einstein u tom je kontekstu kazao: *Tako dugo dok se matematički zakoni oslanjaju na realni svijet, u njih ne možemo biti sigurni. Čim u njih možemo biti sigurni, ne oslanjaju se na realni svijet*.

No, suštinski izazov problemske nastave razine su usvojenosti znanja naših učenika i pretpostavke potrebnih znanja i vještina za aktivno sudjelovanje u problemskoj nastavi. Jedna je od temeljnih namjera nastave matematike u osnovnim i srednjim školama ustanoviti koliko je učenika u stanju uspješno rješavati problemske zadatke te samostalno i aktivno sudjelovati u problemskoj nastavi. Naime, problemski zadatci ponajbolje odražavaju primjenjivost, ali i složenost matematike koja nije zahtjevna samo zbog apstraktnih sadržaja i koncepata koji se rade u nastavi, već je riječ o usvojenosti matematičkog pisma i proceduralnih znanja te izvrsnosti u čitanju s razumijevanjem. Uspješnost u problemskim zadatcima objašnjava se u modelima: matematičko-logički modeli i lingvistički modeli.

Matematičko-logički modeli upućuju na nedostatno razvijene lingvističke sposobnosti i vještine zbog čega učenici ne razumiju tekst zadatka i orijentiraju se prema ključnim riječima (Hudson, 1983; Kintsch i Greeno, 1985; DeCorte i Verschaffel, 1985). Lingvistički modeli

objašnjavaju teškoće kao posljedicu formulacije teksta u zadatku, nerazumijevanja leksičko-gramatičkih konstrukcija, situacijskog konteksta, logičko-matematičkog znanja i aritmetičkih vještina (Reusser, 1989).

Dakle, ako dijete ima teškoće u razumijevanja simbola pisanog jezika, u matematici se to isto može odraziti i u razumijevanju jezika matematičkih simbola bilo da se radi o brojevnim simbolima, računskim operacijama ili razumijevanje zadataka s riječima. Tako učenici s teškoćama u pisanju i čitanju često imaju probleme s matematikom zbog njezinih simbola, znakova i sveukupnosti matematičkog pisma. To posebno dolazi do izražaja kod problemskih zadataka koji, uz razumijevanje matematičkih koncepata i matematičkog pisma, zahtijevaju ne samo fluidne jezično-govorne i verbalne vještine, već i čitanje s razumijevanjem tako da mogu izdvojiti bitne od nebitnih informacija, postaviti problem i riješiti ga odgovarajućim matematičkim alatom. Prema tome, tijekom učenja svakog matematičkog koncepta, veliku pažnju trebamo posvetiti njegovoj jezičnoj komponenti, razumijevanju terminologije, matematičkoj sintaksi i uvježbavanju tzv. prevođenja matematičkog jezika u učenicima razumljive probleme. Sve to pretpostavlja i relativno napredno logično rezoniranje i zaključivanje te niz motivacijskih aspekata procesa učenja i poučavanja. Svaki zadatak u nastavi matematike sadrži u sebi jedinstvo navedenih komponenti zbog čega je nastavnicima ponekad teško detektirati izvor poteškoća koji učenicima stvara probleme tijekom razumijevanja zadataka te u uspješnosti njihova rješavanja.

Rješavanje zadataka najzastupljenija je aktivnost učenika u nastavi matematike. Kurnik (2010) ističe kako je zadatak složen matematički objekt kojeg nije uvijek jednostavno analizirati te izdvaja pet bitnih komponenti kojima je određen: uvjeti, cilj, teorijska osnova, rješavanje i osvrt. Kao istaknutu dimenziju tijekom rješavanju zadataka, Kurnik (2010) navodi usmjeravanje u mogućnostima ispitivanja novih ideja i načina razmišljanja učenika u rješavanju zadataka. Isto se može najbrže postići sljedećim pitanjima:

- Može li se način rješavanja zadatka pojednostavniti?
- Može li se zadatak riješiti na drugi način?
- Jesmo li opisani postupak rješavanja koristili već kod nekog drugog zadatka?
- Može li se zadatak pojednostavniti?
- Može li se zadatak poopćiti?
- Možete li se sastaviti neki slični zadatak?
- Kako glasi obrnuta tvrdnja?
- Vrijedi li obrnuta tvrdnja?

Navedene etape svojstvene su svim zadatcima u nastavi matematike, naročito u standardnim zadatcima koji su dominantni u nastavi te su kao takvi svedeni na prethodna teorijska i proceduralna znanja koja, ukoliko su u dovoljnoj mjeri usvojena, omogućuju učenicima uspješno svladavanje narednih sadržaja. Međutim, problemski zadatci imaju više nepoznatih sastavnica u zadatku, uvjeti i ograničenja nisu jasno postavljeni, a cilj i teorijska analiza ne naziru se iz poznatih činjenica zbog čega ni način rješavanja nije konvencionalan. Iz istog su razloga problemski zadatci često omraženi među učenicima te izdvajaju najbolje među odličnim učenicima. Naime, ima učenika koji izvrsno usvajaju proceduralna znanja i vješto se koriste poznatim pravilima i zakonitostima, ali nemaju dovoljno razvijene vještine za rješavanje nekonvencionalnih zadataka. Uvažavajući razine znanja s kojima učenici raspolažu, očito je kako neki učenici zbog nedostatno usvojenih predznanja jednostavno nemaju sredstva suočiti se s takvim zadatcima.

Problemski zadatci trebali bi biti poveznica između matematičkih sadržaja i svakodnevnog života, a, nažalost, pokazuje se kako se isti zadatci nedovoljno rade u osnovnoj i srednjoj školi. To je, među ostalim, zbog toga što su ti zadatci od početka osnovne škole selektivni te ih umiju rješavati uglavnom uspješniji učenici, no nisu dovoljno zastupljeni ni u recentnim kurikulumima. S obzirom na to da matematički daroviti učenici uz visoko razvijene numeričke sposobnosti i sposobnosti matematičkog rezoniranja češće pokazuju prosječne ili iznadprosječne rezultate na verbalnim sposobnostima, pokazuje se kako su verbalne sposobnosti među preduvjetima razvoja matematičkih sposobnosti te su svojevrsni indikator i prediktor potencijalnih teškoća ili uspješnosti u problemskim zadatcima te općenito u matematici.

S obzirom na značajan utjecaj problemskih zadataka na učenike, učitelji razredne nastave i nastavnici matematike trebaju dugoročno promišljati kako da iskustva iz problemski osmišljene nastave ne ostavljaju negativne posljedice i ne utječu na pad samopouzdanja učenika. Rješavanje zadataka i problema centralni su objekt metodike nastave matematike te je potrebno više pažnje posvetiti samom procesu rješavanja, načinu razmišljanja, pretpostavkama za rješavanje te poznavanju tipičnih teškoća s kojima se učenici pritom suočavaju. Tijekom rješavanja zahtjevnijih i/ili problemskih zadataka, nastavnici bi trebali raditi opsežniji osvrt, tj. svojevrsnu evaluaciju zadatka, procjenu i/ili provjeru rezultata, ali i promišljanja o mogućim načinima rješavanja (što dobrim, a što pogrešnim). Učenicima je pritom nužno ukazivati na potrebna znanja kako bi se zadatak riješio te na vještine kojima se to u konačnici može realizirati s namjerom stvaranja ispravne slike onoga što je potrebno za uspjeh u matematici kako isto ne

bi bilo prepušteno podcjenjivanju vlastitih sposobnosti ili nekim drugim stereotipima karakterističnim za matematiku.

2.2.7. Vrednovanje u nastavi matematike

Vrednovanje učeničkih postignuća jedno je od temeljnih obilježja suvremenih kurikuluma te označava procjenu valjanosti realizacije odgojno-obrazovnih ciljeva. U evaluaciji učeničkih postignuća možemo razlikovati vanjsko i unutarnje vrednovanje. Vanjsko vrednovanje odnosi se na vrednovanje različitih institucija i organizacija kao što su Nacionalni centar za vanjsko vrednovanje u provedbi državne mature, projekti PISA (međunarodno ispitivanje matematičke, znanstvene i čitalačke pismenosti), TIMSS (procjena učeničkih postignuća u području matematike te prirode i društva), PIRLS (međunarodno ispitivanje čitalačke pismenosti) te drugi projekti i institucije. Unutarnje vrednovanje odvija se u nastavnom procesu koji se shvaća kao zajednička aktivnost nastavnika i učenika unutar koje se vrednovanje provodi i odvija u svakodnevnim zajedničkim aktivnostima (Bognar i Matijević, 2005). Evaluacija uspjeha učenika takva je nastavna aktivnost kojom se želi utvrditi stupanj stečenih znanja i vještina u odnosu na postavljene ciljeve, a uz što je potrebno razmatrati interese, samostalnost i odgovornost koju se pritom pokazuje.

Određivanje vrijednosti postignuća učenika sastavni je i neodvojivi dio odgojno-obrazovnog procesa (Jurčić, 2012) koji se s didaktičkog i dokimološkog stajališta treba provoditi formativno, normativno i sumativno (Kyriacou, 2001). Normativno vrednovanje uobičajena je praksa u kojem se koriste propisane ljestvice za ocjenjivanje kao i sumativno koje se provodi na kraju nekog razdoblja kao ukupna ocjena do tog trenutka. S obzirom na specifičnosti učenja i poučavanja u nastavi matematike, najveći je potencijal svakako u formativnom vrednovanju koje uključuje kontinuirano praćenje svakog učenika s naglaskom na utvrđivanje i praćenje4 teškoća u učenju, prepoznavanju jakih i slabih strana te daljnjem usmjeravanju različitim pedagoškim postupcima kako bi učenici prevladali specifične teškoće.

Unatoč tome, različitim kurikularnim dokumentima jasno se očituje smjer obrazovnih politika kojima se načelno ističe važnost pedagoškog pristupa u ocjenjivanju i vrednovanju. Međutim, u pripadnim dokumentima prisutna su mnoga proturječja po pitanju obrazovnih, odnosno odgojno-obrazovnih standarda. Stoga je potrebno razmotriti je li moguće ostvariti ciljane odgojne (ali i obrazovne) ishode ako se nameću gotove norme i propisuju vanjski kriteriji koji ne uvažavaju raznovrsnost razrednih odjela i individualnih specifičnosti učenika. Ovdje je potrebno razjasniti što je s vrednovanjem u odnosu na samog učenika i razinu

razvijenosti znanja i vještina koje pokazuje u nastavi, a naročito u kontekstu nastave matematike i nekih predmeta iz STEM područja koji su obilježeni snažnim utjecajem afektivnih dimenzija nastave. Naime, učenici na početku školovanja imaju pozitivne ili barem neutralne stavove i uvjerenja prema matematici, ali isti s godinama obrazovanja postaju sve negativniji te postupno imaju sve značajniji utjecaj na obrazovanje učenika (Putney i Cass, 1998). Brojni se autori već gotovo pola stoljeća intenzivno bave uvjerenjima, stavovima i emocijama učenika u nastavi matematike (npr. Richardson and Suinn, 1972; Wigfield i Meece, 1988; Ashcraft and Kirk, 2001; Arambašić i sur., 2005; Geist, 2010; Sloan, 2010) zbog čega se u procesu učenja i poučavanja matematike razmatranje afektivnih dimenzija smatra kao integralni pa čak i prioritetni dio planiranja i izvedbe nastavnog procesa (*više u poglavlju 4.4.1*).

Provjeravanje i ocjenjivanje znanja učenika daje nam uvid u kvalitetu usvojenosti matematičkih sadržaja. Međutim, cjelovito vrednovanje i praćenje njihova razvoja koje uključuje povratne informacije o njihovu radu i smjernice za daljnji napredak nužnost su nastave matematike. S tim u vezi, Kyriacou (2001) navodi svrhe ocjenjivanja: osigurati nastavnicima povratne informacije o učeničkom napretku i vlastitom poučavanju, učenicima dati povratne pedagoške informacije, motivacija učenika i spremnost za buduće učenje, evidencija napretka te dokaz djelotvornosti škola i nastavnika. Nastavni proces, prema tome, mora biti utemeljen na različitim posebnostima učenika poput: razine stečenih znanja i vještina, usvojenih odgojnih vrijednosti, motivacije za predmet, emocijama, stavovima i uvjerenjima u kontekstu matematike i škole općenito te na poznavanju školske, društvene i obiteljske okoline učenika. U tim intencijama bitno je uskladiti intelektualne i emocionalne aspekte učenika u nastavi matematike s pretpostavkom kako nastavnik razumije načine stjecanja znanja i razvijanja matematičkih sposobnosti i vještina, ali i da jednako pridaje značaj emocionalnim doživljajima kako bi lakše regulirao odnos učenika prema nastavi matematike, njegovu recepciju vlastitih sposobnosti, motivaciju i stupanj aktivnosti u nastavnom procesu.

Zbog izvjesne vjerojatnosti razvijanja nepovoljnih stavova i uvjerenja učenika spram matematike, nastavnik treba usmjeriti svoj rad na razvoj samopouzdanja i povjerenja učenika u vlastite matematičke sposobnosti. Kako bi to postigli, nastavnici u svom radu moraju sjediniti metode i način rada s vrednovanjem i kontinuiranim praćenjem i podupiranjem učenika kako bi kod učenika razvili samopoštovanje, osjećaj vlastite vrijednosti te odgovornost za vlastiti uspjeh. U kontekstu odgovornosti za uspjeh potrebno je razmatrati drugu stranu medalje, tj. neuspjeh i neželjene posljedice kojima su učenici nerijetko izloženi. Stoga treba voditi računa o odgovornosti na način da se kod manje uspješnih učenika istakne mogućnost promjena kako osjećaj odgovornosti za (ne)uspjeh ne bi rezultirao osjećajem bespomoćnosti.

Te promjene trebale bi biti podupiruće poruke i postupci nastavnika usmjereni na ohrabrivanje učenika, pomoć u učenju i podizanje općeg samopouzdanja kako bi bili motiviraniji prema nekim boljim perspektivama, bilo onim kratkoročnim školskim ciljevima ili dugoročnim životnim ciljevima.

U protivnom, učenici bi mogli razviti neki oblik matematičke anksioznosti (Aschraft i sur., 1998; Sheffield i Hunt, 2007) što se pokazuje kao značajan čimbenik u visokom obrazovanju i izboru karijera pri upisima na fakultete (Chipman i ostali, 1992). Kako bi nastava matematike ostvarila ciljeve suvremenog odgoja i obrazovanja, proces vrednovanja mora biti pomno osmišljen i integrativan dio nastavnog procesa i suradnje nastavnika i učenika kako bi poticali učenike na usvajanje općih matematičkih znanja i vještina s naglaskom na motivacijske procese i razvoj samopouzdanja učenika. To podrazumijeva propitivanje općeg pristupa vrednovanju te razmatranje obrazovnih standarda propisanih od strane obrazovne politike i suprotstavljenog mu koncepta vrednovanja usmjerenog na učenika i njegov napredak.

Naime, standardizacija i propisivost obrazovnih ishoda opravdava se činjenicom kako učenici imaju mogućnost usporediti svoj uspjeh s očekivanim standardom postignuća među svojim vršnjacima kako bi ispravili i/ili poboljšali vlastiti rad. Međutim, to podrazumijeva kako učenici nekog odgojno-obrazovnog programa strukovne škole ili primjerice jezičnog smjera gimnazije unatoč uloženu trudu neće imati ocjene više od „dobar“, iako se pritom ne razmatra primjerenost i suvremenost aktualnih kurikuluma za pojedine odgojno-obrazovne programe.

Sukladno navedenome, u poglavlju 2.2.2 pod naslovom *Odgojno-obrazovni standardi* među kritikama na cjelovitu kurikularnu reformu matematičkog područja (koja se i dalje nije promijenila) Mišurac-Zorica (2016) ističe kako je orijentacija u cijelom dokumentu (kurikulumu) ostala tradicionalno usmjerena na nastavne sadržaje: *sve srednje škole koje imaju 3 sata matematike, neovisno je li riječ o strukovnoj školi ili gimnaziji, imaju isti program iz matematike. U ovu kategoriju škola spada na primjer jezična gimnazija, ali i brojne strukovne škole (tehničar za mehatroniku, odjevni tehničar, pomorski analitičar ili smjerovi iz sektora šumarstvo, prerada i obrada drva i slično)*. Isto uglavnom vrijedi i za odgojno-obrazovne programe koji u planu imaju dva ili četiri sata matematike tjedno te unatoč potpuno različitim vrstama škola i odgojno-obrazovnim usmjerenjima, učenici rade po programima koji su u velikoj većini isti ili su u potpunosti isti. Ako tome pridodamo obrazovno-političke smjernice za standardizacijom u vrednovanju učeničkih postignuća, postavlja se pitanje autoriteta koji takva obrazovna politika može imati nad nastavnicima matematike, a čak i samog legitimiteta tako postavljenog i orijentiranog kurikuluma.

Štoviše, tako postavljeni ciljevi mogu imati prilično negativne posljedice na već ionako

velike izazove s kojima se susreću učenici u učenju matematike. Naime, osvrnemo li se na dimenzije vrednovanja učeničkih postignuća koje se odnose na motivaciju učenika te evidenciju i poticanje napretka u učenju, postavlja se pitanje kako udovoljiti tim aspektima ako se u različitim srednjim školama radi prema istim zastarjelim kurikulumima koji se nisu nimalo mijenjali više od dvadeset godina te se jedine promjene rade na određivanju obrazovnih ishoda koji se pišu prema istima. Vrednovanje u nastavi matematike integralni je dio rada nastavnika, a (pr)ocjenjivanje, kao i cijeli proces evaluacije obrazovnih ishoda koji ne proizlaze iz osuvremenjenih kurikuluma, nema stručnih ni znanstvenih uporišta te je u proturječju s pedagoškim načelima prilagođenima učeniku koja bi trebala imati najviši prioritet u planiranju nastave matematike.

2.3. Učenici s posebnim potrebama u nastavi matematike

Dijete s posebnim potrebama svako je ono dijete koje se razlikuje od prosječnog djeteta u određenoj društvenoj i kulturnoj zajednici u: senzornim, komunikacijskim, intelektualnim sposobnostima, socijalnom ponašanju i emocionalnom doživljavanju te tjelesnim osobinama. (Thompson, 2016) Učenike s posebnim potrebama dijelimo na učenike s poteškoćama i nadarene učenike. Te učenike u nastavi možemo prepoznati po iznadprosječnim, odnosno ispodprosječnim razvijenim vještinama i sposobnostima s obzirom na njihovu kronološku dob. Važno je istaknuti kako učenici s posebnim potrebama nemaju samo posebne obrazovne potrebe prema kojima su primarno prepoznati, već im se barem u jednakoj mjeri moramo posvetiti s odgojnog aspekta. Zbog njihovih specifičnosti i različitosti, u nastavi im moramo drugačije pristupiti nego tzv. prosječnim učenicima prema kojima se primarno organizira i planira nastavni proces. Uspješna individualizacija i diferencijacija metoda nastavnikova rada prema takvim učenicima suočava se s općenitim problemom obrazovanja koji u prostornim i vremenskim ograničenjima mora svakom učeniku omogućiti optimalan razvoj. Naime, u težnjama da se u prisutnim ograničenjima nastave i školstva ostvari što veći odgojno-obrazovni utjecaj na učenike, škola se mora prilagoditi prosjeku, odnosno većini. Time su najviše zakimuti učenici s posebnim potrebama te nam je stoga dužnost pružiti im uvjete za razvoj kakve imaju i ostali učenici. Učenike već na početku školovanja često svrstavamo po sposobnostima što se posebno ističe u nastavi matematike u kojoj neki učenici pokazuju izrazito razvijene sposobnosti, a neki imaju potpuni izostanak istih. Ukoliko iste ne promatramo s razvojnog aspekta u vidu poticajne okoline koja je ujedno i sastavni dio specifičnosti prema kojima smo

ih kvalificirali u kategoriju učenika s posebnim potrebama, oni se neće razvijati u skladu s vlastitim sposobnostima.

U znanstveno-teorijskim i praktičnim tendencijama razumijevanja problema matematičkog obrazovanja, učenicima s posebnim potrebama morali bismo pristupati s većim interesom zato što nam svaka spoznaja o njihovim specifičnostima može dati odgovore na aktualne probleme u nastavi matematike koji se tiču ostalih učenika. Naime, problemi nastave matematike pripadaju globalnom fenomenu čiji problemi nisu samo u području učenika s posebnim potrebama, već se većinom odnose na problem kvalitetne nastave matematike te sveukupnost problematike razvoja matematičkih sposobnosti i vještina koje ne uspijeva aktualizirati ni većina učenika prema kojima je nastava primarno organizirana. Proučavanjem razvoja učenika koji su svojevrsni ekstremi uspjeha u matematici, potencijalne su mnogobrojne implikacije o razumijevanju čimbenika i okolnosti koje su preduvjet uspjeha i onog „prosječnog“ učenika. Pritom je potreban fenomenološki pristup kojim ćemo reducirati stereotipe o urođenosti i statičnosti nadarenosti te poteškoća u učenju što su osobito izraženi u kontekstu (nastave) matematike. Dakle, svaka spoznaja o učenicima s posebnim potrebama u nastavi matematike ima svrsishodnu vrijednost u odgoju i obrazovanju tih učenika, ali i u razmjerima cjelokupnog matematičkog obrazovanja zbog čega im moramo pristupati s intencijom pomaganja njihova razvoja, ali i zbog znanstvene znatiželje i praktičnog usavršavanja u cjelokupnoj problematici. Uvažavajući višeslojnost razvoja učenika te sposobnost i vještina koje pokazuju u nastavi, potrebno je uočiti i razumjeti pozadinu tih kvaliteta te utvrditi koliki su doista (skriveni) potencijali učenika. Ako ćemo trenutno stanje učenika, odnosno kvalitetu njihova znanja i vještina gledati kao determinantu daljnjeg uspjeha, tada im nikako ne možemo pomoći u mjeri koja im je potrebna. Sukladno pedagoškim načelima, to se u slučaju nadarenih i učenika s teškoćama može nazvati diskriminacijom po uspjehu, osobito ukoliko polazimo od stavova kako im za optimalan razvoj nije potrebna podržavajuća i poticajna okolina.

Učenike s teškoćama u razvoju potrebno je kontinuirano pratiti uvažavajući posljedice njihovih specifičnosti. Praćenje se ostvaruje tijekom rada s učenicima u svim etapama odgojno-obrazovnih i rehabilitacijskih aktivnosti (uvođenje novih sadržaja, uvježbavanje, ponavljanje, provjeravanje, ocjenjivanje). Prilagođeni program je program primjeren osnovnim karakteristikama teškoće djeteta, a u pravilu pretpostavlja smanjivanje intenziteta i ekstenziteta pri izboru nastavnih sadržaja obogaćenih specifičnim metodama, sredstvima i pomagalima. U Republici Hrvatskoj prilagođene programe sastavljaju nastavnici određene škole uz stručnu pomoć stručnih suradnika, a pritom treba poznavati učenika u cijelosti kako bi mu se priredio

odgovarajući program zato što je svaki program individualan. Prilagođavanje nastavnog programa učeniku s teškoćama u razvoju može se odnositi na: posebno određenje nastavnih sadržaja, posebno određenje vremenskih dimenzija za određene nastavne sadržaje, posebno određenje razine usvojenja određenih nastavnih sadržaja, posebno određenje nastavnih oblika i metoda rada te nastavnih sredstava (Guberina-Abramović, 2008). Pri izradi nastavnog plana i programa važno je da svaki učitelj vodi brigu o tome kako neki učenici s teškoćama u razvoju mogu napredovati kao i njihovi vršnjaci, a neki mogu napredovati do određene granice, kako nema učenika koji se ne bi mogao odgajati i obrazovati, neovisno o tome koliko su skromne njegove mogućnosti što je bitno za napredovanje učenika i oko toga treba koncentrirati programske sadržaje te kako učenici razvijaju sposobnosti čitanja, pisanja, računanja, svladavanja vještina u odgojnim područjima i socijalizaciji u sklopu redovne nastave. Uključivanje djece s posebnim potrebama u redovne programe dovodi do pozitivnog razvoja, kako njihovog tako i ostalih njihovih vršnjaka. Interakcija s vršnjacima, čiji je razvoj uobičajen, ima pozitivan utjecaj na usvajanje akademskih, funkcionalnih i socijalnih vještina, a i pridonosi povećanju socijalne kompetencije, ostvarenju ciljeva u obrazovanju, razvoju prijateljstva i poboljšanju kvalitete života učenika (Fulgosi-Masnjak, Kiš-Glavaš, 2002).

2.3.1. Učenici s teškoćama u nastavi matematike

Učenike s poteškoćama razlikujemo s obzirom na razvojne poteškoće, poteškoće u učenju, ponašanju te poteškoće uvjetovane odgojnim, socijalnim, ekonomskim, kulturnim i jezičnim čimbenicima. Kao posebne skupine pritom se ističu: učenici s poremećajima pažnje, učenici sa specifičnim teškoćama učenja, učenici s emocionalnim teškoćama i učenici s poremećajima ponašanja. Za razliku od ostalih skupina koje su uglavnom u domeni pedagogije, psihologije i defektologije, za nastavu matematike od posebnog su interesa učenici s teškoćama u učenju matematike te će stoga ovo poglavlje biti posvećeno isključivo toj skupini učenika. Generalne su zadaće učitelja u okviru integracije: uspostaviti pozitivan odnos, pohvaliti trud koji učenik ulaže, postaviti ciljeve u radu, omogućiti prikladno mjesto u razredu, prilagođavati rad sukladno sposobnostima učenika, dozirano poticati učenikovu samostalnost u radu, omogućiti mu dulje vrijeme za rad, poticati učenike i vršnjake na pozitivnu interakciju provođenjem zajedničkih aktivnost (Fulgosi-Masnjak, Kiš-Glavaš, 2002).

2.3.2 Učenici s diskalkulijom

Iako u zadnjih desetak godina svjedočimo povećanom interesu prema učenicima s posebnim odgojno-obrazovnim potrebama, isto je u kontekstu nastave matematike i dalje relativno slabo popraćeno istraživanjima, a to se posebno odnosi na djecu koja imaju diskalkuliju. Diskalkulija je široj javnosti poznata kao skup specifičnih teškoća u učenju matematike i u obavljanju matematičkih zadataka od kojih se ističu oni s računanjem bez pomoći kalkulatora. Diskalkuliju kao termin prvi je predložio Gerstmann 40-ih godina 20. stoljeća te ju je definirao kao izoliranu nemogućnost obavljanja kompleksnih aritmetičkih operacija uz poremećaj orijentacije u prepoznavanju niza brojeva i razlomaka (Alexander i Money, 1966). Međutim, pionir u području razvojne diskalkulije slovački je neuropsiholog iz Bratislave dr. Ladislav Košč koji je, proučavajući matematičke sposobnosti djece u dobi između deset i jedanaest godina, definirao različite oblike razvojne diskalkulije te je prvi sastavio niz specijaliziranih testova za dijagnosticiranje diskalkulije.

U istraživačkom kontekstu diskalkulija se definira, odnosno određuje, kao „razvojna diskalkulija“ (eng. developmental discalculia), a zbog jednostavnosti se u literaturi često ističe njezina skraćena inačica. S druge strane, to je možda i posljedica podzastupljenosti iste u istraživanjima i/ili neinformiranosti stručne i šire javnosti o potankostima dotičnog poremećaja. Ladislav Košč je 1974. godine prvi dao temeljitu definiciju pod nazivom „razvojna diskalkulija“ (eng. developmental discalculia) te ju je odredio kao razvojni strukturalni poremećaj matematičkih sposobnosti čiji su uzroci uvjetovani genetskim ili urođenim poremećajima u područjima mozga koji su anatomski i psihološki neposredno odgovorni za obavljanje matematičkih operacija bez istovremenog poremećaja općih kognitivnih funkcija. Teškoće koje djeca pritom imaju formiraju se u ranoj razvojnoj dobi, najčešće prije rođenja, i očituju se odmah čim je dijete počelo razvijati osjećaj za broj i obavljati elementarne računske operacije te se stoga taj oblik teškoća naziva „razvojnim”. Možda i najjednostavnija definicija diskalkulije koja je prihvaćena u znanstvenoj zajednici jest diskalkulija kao oblik neurorazličitosti koji utječe na sposobnost usvajanja aritmetičkih vještina (Department for Education and Skills (DfES), 2001).

Iako nema potpunog konsenzusa među istraživačima, većina se slaže kako je za diskalkuliju ključan nedostatak fundamentalnog osjećaja za broj koji se smatra ključnim kognitivnim mehanizmom odgovornim za reprezentaciju i procesuiranje numeričkih i kvantitativnih veličina (Butterworth 1999; Dehaene 1997). Kod učenika s diskalkulijom posebno se ističu problemi u aritmetici, odnosno u računskim operacijama s brojevima zbog

čega diskalkuliju možemo detektirati upravo kroz kroz teškoće u aritmetici. Za praksu je važno istaknuti kako ti učenici nemaju poremećaj općih kognitivnih funkcija te su prosječne ili iznadprosječne inteligencije. Stoga se diskalkulija ponekad definira kao stanje u kojem pojedinac ne uspijeva razviti sposobnost usvajanja aritmetičkih vještina (DfES, 2001). Za razliku od djece koja imaju teškoće u logici, dijete s teškoćama u obavljanju jednostavnih računskih radnji razumije logiku aritmetičkih operacija, ali se ne može automatski prisjetiti činjenica pa do rezultata dolazi uglavnom brojanjem na prste.

Prema intenzitetu teškoća diskalkulije, kao najteži stupanj teškoća navodi se *akalkulija* koja se odnosi na potpunu odsutnost osjećaja za broj i matematičko mišljenje. Akalkulija može biti primarna, ali se pokazuje da je u većini slučajeva sekundarni, stečeni poremećaj koji se događa u odrasloj dobi zbog moždane lezije ili bolesti centralnog živčanog sustava uslijed koje su zahvaćeni dijelovi i sustavi mozga odgovorni za obavljanje matematičkih operacija (Sharma, 2001). S druge strane, ne odnose se sve teškoće u matematici na diskalkuliju zato što postoji mnogo drugih razloga zašto neka djeca imaju teškoće u učenju matematike, a to su na primjer: nedovoljan stupanj kognitivnog funkcioniranja, nerazvijenost temeljnih predmatematičkih vještina, posebne jezične teškoće i teškoće u čitanju i pisanju, nekompatibilnost stilova učenja i poučavanja, emocionalno stanje djeteta i slično (Posokhova, 2001, prema Sharma, 2001). Prema nekim izvorima, razvojna diskalkulija također se dijeli na primarnu i sekundarnu.

Prema Košču (1974), primarna se odnosi na strukturalni poremećaj, a druga se odnosi na teškoće u matematici uvjetovane vanjskim čimbenicima kao što su: nekvalitetna nastava, socioekonomski status, problemi u ponašanju, problemi deficita pažnje i deficit općih kognitivnih funkcija. Međutim, prema Koščevoj definiciji i suvremenim testovima, sekundarna se diskalkulija ni ne može zvati diskalkulijom zato što je zbog distinkcije o uvjetovanosti teškoća koje učenici imaju u učenju matematike bitno razumjeti kako ponekad isti simptomi i teškoće mogu imati sasvim drugačiju pozadinu. Naposljetku, i jedni i drugi učenici trebaju dobiti podjednaku pažnju i potporu, no bitno je prepoznati distinkcije među tim učenicima kako bismo u praksi individualiziranim postupcima mogli odabrati optimalne metode rada ovisno o tipu teškoća koje smo prepoznali kod pojedinca. To će se detaljnije pojasniti u narednim poglavljima o pojavnosti, detekciji i implikacijama na nastavu od kojih će se isto ponajviše elaborirati kroz područje pedagoškog savjetovanja učenika s diskalkulijom.

2.3.2.1 Pojavnost i detekcija diskalkulije

Većina istraživača tvrdi kako je u zadnja dva desetljeća broj učenika koji imaju niska postignuća u nastavi matematike u značajnom porastu (Swanson, 2000), a s obzirom na to da su teškoće u učenju matematike prisutne uzduž cijelog osnovnoškolskog i srednjoškolskog obrazovanja, one koje su povezane s diskalkulijom rijetko dobivaju značajniji prostor u odgojno-obrazovnim diskusijama. Unutar određenja razvojne diskalkulije i standardiziranih testova koji se koriste pri detekciji diskalkulične djece, ipak ima ponekih odstupanja u kriteriju pa tako i u procjenama koje su istraživači dobili o udjelu populacije s diskalkulijom. Tako je Košč (1974) utvrdio 6 % populacije u Bratislavi, Badian (1983) u američkoj studiji također oko 6 %, njemački istraživači su procijenili oko 4 % (Klauer, 1992), a studije u Engleskoj također su pokazale pojavnost oko 4 % (Lewis i ostali, 1994). Od nešto recentnijih studija, Geary (2004) procjenjuje pojavnost diskalkulije između 5 % do 8 %, a to su isto u Belgiji utvrdili u rasponu od 3 % do 8 % (Desoete, Roeyers i De Clercq, 2004).

Unatoč brojnim opsežnim studijama koje procjenjuju pojavnost diskalkulije u rasponu od 3 % do 8 %, APA (American Psychiatric Association), američka udruga psihijatara koja je autoritet u dotičnoj istraživačkoj domeni, testom DSM-IV utvrđuje pojavnost diskalkulije u svega 1 % školske populacije (APA, 1994). Tako primjerice Butterworth (2004) koristi kriterij prema kojem se smatra kako pojedinac ima diskalkuliju ukoliko ima rezultat aritmetičkih sposobnosti i vještina za tri standardne devijacije od prosjeka populacije i/ili vršnjaka što bi otprilike ukazivalo na procjenu od 1 % populacije. No, kriterij samog testa aritmetičkih sposobnosti nije dostatan u prepoznavanju diskalkulije, a više će biti rečeno u dijelu s detekcijom diskalkulije i standardiziranim testovima.

Pri detekciji razvojne diskalkulije uglavnom se koriste standardizirani testovi matematičkih sposobnosti i test inteligencije. Iako ima odstupanja u kriterijima koje istraživači koriste, svi imaju zajednički glavni kriterij koji se u literaturi navodi kao „model diskrepancije“, odnosno *kriterij odstupanja* u navedenim testovima. Dakle, sukladno Koščevoj definiciji razvojne diskalkulije, kriterij odstupanja određuje pojedinca kao diskalkuličnog ukoliko su mu matematičke (aritmetičke) vještine na znatno slabijem stupnju razvijenosti od onih utvrđenih općim testom inteligencije. Neki autori koriste kriterij odstupanja tako što određuju diskalkuliju prema matematičkim vještinama i sposobnostima koje su ekvivalentne djeci koja su godinu ili dvije mlađa od pojedinca (Temple i Sherwood, 2002). Međutim, kako se svi statistički testovi, a naročito testovi inteligencije, pri tumačenju rezultata koriste standardnim devijacijama i egzaktno mjerenim odstupanjima, ranije navedeni kriterij svakako se pokazuje relativno

nepreciznim zato što razlika od jedne do dvije godine ne može imati jednaku statističku značajnost za djecu različite dobi. U recentnoj istraživačkoj praksi pokazuje se kako pri utvrđivanju diskalkulije više nije dovoljno ni sofisticirano korištenje kvantitativne metodologije, već se pokazuje nužnim kombinirati različite testove i tumačiti rezultate istih na prikladan način uvažavajući teorijsko određenje razvojne diskalkulije na temelju suvremenih spoznaja.

Zadnjih nekoliko desetljeća ubrzano se povećava broj različitih standardiziranih testova kojima se ispituju teškoće u matematici od kojih se većina dominantno usmjerava prema detekciji diskalkulije. Jedan je od takvih pouzdanih istraživačkih instrumenta TEDI-MATH (Van Nieuwenhoven, Grégoire i Noël, 2001) koji je primarno koncipiran za detekciju diskalkulije u dobi djece između četiri i osam godina. Isti je izvorno izrađen od strane belgijskih istraživača, preveden je i adaptiran za testiranje u Njemačkoj, Francuskoj i Nizozemskoj te je standardiziran na velikim uzorcima statistički prikladnima za legitimaciju instrumenta. Taj test ispituje više komponenti matematičkih sposobnosti vezanih uz procesuiranje brojeva, računanje i razinu razvijenosti osjećaja za broj, vještine logičkog rezoniranja i sl. U Italiji koriste AC-MT test (Lucangeli, Tressoldi i Fiore, 1998) te njegovu dorađenu inačicu ABCA test (Lucangeli i ostali, 1998) ili nešto recentnijeg datuma *Dyscalculia Test* (Lucangeli i ostali, 1998).

U Španjolskoj koriste test *Bateria para la Evaluacion de la Competencia Matematica*, odnosno test evaluacije matematičke kompetencije. Svi navedni testovi, kao i ostali koji su koncipirani na području Europe, dominantno su usmjerili test na opsežno ispitivanje matematičko-logičkih sposobnosti s naglaskom na područje aritmetike i osjećaja za broj. Koncepti koji se ispituju su sljedeći: zapisivanje brojeva, smještanje brojeva na brojevni pravac, nadopunjavanje nizova, računanje na papiru i mentalno, nadopunjavanje slika geometrijskih objekata, problemski zadatci, vizualno i prostorno snalaženje, pamćenje, prisjećanje matematičkih činjenica i raznovrsni tipovi zadataka logičkog zaključivanja.

Međutim, recentna literatura ukazuje na niz čimbenika koje bi trebalo istražiti kako bismo razlučili učenike s teškoćama u učenju matematike uzrokovanih vanjskim okolinskim faktorima od onih koji imaju diskalkuliju, iako imaju podjednake simptome u kontekstu nastave matematike (Shalev i sur., 2005; APA (DSM-5), 2013). Naime, suvremena literatura u istraživanjima diskalkulije pri detekciji učenika mora uvažiti sljedeće kriterije karakteristične za diskalkulične učenike ili pak relevantne za statističke testove:

- test mora biti prilagođen dobi pojedinca
- matematičke sposobnosti (naglasak na aritmetici)

- sposobnost procjene veličine skupa
- disparitet inteligencije
- prisjećanje i upamćivanje matematičkih činjenica
- uvažavanje teškoća u obrazovanju i svakodnevnom životu
- dugotrajnost diskalkulije.

Tako ranije navedeni testovi mogu svojom širinom obuhvatiti relevantne sposobnosti i vještine matematičkog mišljenja, kao i općeg stupnja kognitivnog funkcioniranja, a samim time disparitet inteligencije, odnosno odstupanja koja su nužni kriterij pri detekciji diskalkuličnih učenika. No, za utvrđivanje diskalkulije mora postojati dokaz prisutnosti simptoma karakterističnih za diskalkuliju uzduž duljeg vremenskog perioda (Shalev i sur., 2005) zato što se prema terminološkom određenju diskalkulije ista mora prepoznati kao neurorazličitost koja je prisutna i u odrasloj dobi, odnosno kao poremećaj koji je prisutan kao trajni deficit pojedinca. Uz to je potrebno ispitati specifičnost obiteljskog okruženja, zdravstveno-medicinske specifičnosti te jesu li ostali članovi obitelji imali sličnih poteškoća, odnosno jesu li možda i sada prisutne.

Za detekciju diskalkulije u znanstvenoj zajednici najčešće se koristi DSM (eng. *Diagnostic and Statistical Manual of Mental Disorders*) što se odnosi na dijagnostički i statistički priručnik za mentalne poremećaje sastavljen od strane američke udruge psihijatara (eng. APA). Navedeni test revidiran je nekoliko puta od kojih je možda najučestalije korišten DSM-IV koji je od 1994. do 2013. godine, kada je koncipiran posljednji u nizu DSM-5, bio najčešća referenca u istraživačkim i stručnim radovima. Taj test dominantno se koristi u Sjedinjenim Američkim Državama, no često ga se koristi u istraživanjima diljem svijeta. Njegova posljednja inačica (DSM-5) iz 2013. godine među rijetkim je istraživačkim instrumentima koji pri prepoznavanju diskalkulije uvažavaju niz teškoća s kojima se pojedinci suočavaju u svakodnevnom životu. Naposljetku, malo koji test obuhvaća baš sve navedene kriterije, no očito je kako više kriterija nudi veću preciznost, ali i manju pojavnost što je očito po procjenama američke udruge psihijatara APA koji su sa svojim DSM testovima došli do razine pojavnosti diskalkulije od svega 1 %.

2.3.2.2 Komorbiditet diskalkulije

Diskalkulija može biti samostalna i jedina djetetova teškoća, no često se pojavljuje u kombinaciji s nekom drugom teškoćom ili s više njih. Desoete (2008) tvrdi kako je istovremeno prisustvo više različitih poremećaja učenja više pravilo nego iznimka što se tiče djece s teškoćama u učenju matematike. Light i Defries (1995) navode kako disleksija često dolazi u paru s teškoćama u matematici. Predstojnik Odsjeka za matematiku u britanskoj školi za djecu s disleksijom, Aschroft, tvrdi kako čak 75 % učenika s disleksijom imaju i ozbiljne teškoće u matematici što ne čudi s obzirom na apstraktnost matematičkog pisma s kojim i ostali učenici imaju problema. Iako to ne znači da svi disleksičari imaju diskalkuliju, Chinn i Aschroft (2007) ističu kako disleksija i diskalkulija često dolaze u paru.

Recentna istraživanja upućuju kako je pojavnost diskalkulije podjednaka ostalim poremećajima poput disleksije, disgrafije, ADHD-a i sl. (WHO, 1992) Međutim, mnogi autori ističu podzastupljenost diskalkulije u istraživanjima (WHO, 1992; Ginsburg, 1997; Desoete, Roeyers o De Clercq, 2004) od kojih su neki ustanovili kako istraživanja disleksije brojčano nadmašuju istraživanja diskalkulije u omjeru 14 : 1 (Gersten, Clarke i Mazzocco, 2007). Istraživači procjenjuju kako diskalkulija dolazi u paru s teškoćama u čitanju u oko 17 % slučajeva (Gross-Tsur i ostali, 1996), a Badian (1943) isto procjenjuje na 43 %. Pojavnost diskalkulije u paru s teškoćama pisanja procjenjuje se na 50 % (Ostad, 1998). Intenzitet teškoća u matematici, pored ostalog, često je povezan s kvocijentom inteligencije i poremećajima pažnje pa su neka istraživanja pokazala kako 26 % djece s teškoćama u učenju matematike imaju simptome ADHD-a (Gross-Tsur i sur., 1996).

Pored komorbiditeta s poremećajima pažnje i poremećajima učenja, diskalkuliju je potrebno razmatrati i u socijalnom kontekstu zato što istraživanja i praksa jasno ukazuju kako kod učenika s poremećajima učenja postoji veća vjerojatnost slabije prihvaćenosti od tipične djece. Naime, brojna istraživanja pokazuju kako djeca s poremećajima učenja imaju niži socijalni status od djece bez poremećaja učenja (npr. Kavale i Forness, 1966). Među njima se posebno izdvajaju djeca s teškoćama u učenju matematike za koju se pokazuje kako imaju učestalije ponašajne i emocionalne probleme nego ostala djeca s poremećajima relevantnim za odgoj i obrazovanje. Pokazuje se kako ta djeca imaju nisku razinu percepcije akademske samoefikasnosti što se odražava na sva područja njihova obrazovanja i svakodnevnog života.

2.3.2.3 Diskalkulija u praksi

U procesu učenja matematike sva djeca čine više ili manje grešaka, no neka djeca matematiku smatraju iznimno zahtjevnim predmetom, uče sporije i čine više grešaka. Među njma se izdvajaju djeca s diskalkulijom koja se od ostalih razlikuju po tome što čine mnogo neuobičajenih, odnosno specifičnih grešaka po kojima ih možemo prepoznati (Sharma, 2001):

- uspoređivanje brojeva (znatno sporije od prosjeka)
- računanje preko desetice
- zamjenjivanje brojeva (greške u čitanju i pisanju istih)
- teškoće u zapamćivanju tablice množenja
- zrcalno okretanje znamenki ili redoslijeda znamenaka
- zamjenjivanje smjera rješavanja (s desna na lijevo)
- zamjenjivanje simbola računskih operacija
- preskakivanje koraka u rješavanju zadataka
- slabo pamćenje i prepoznavanje niza brojeva.

Nacionalno vijeće za evaluaciju kurikuluma u Sjedinjenim Američkim Državama utvrdilo je kako 66 % učitelja nikad ili gotovo nikad nije koristilo dijagnostičke testove, a njih 77 % nikad ili gotovo nikad nije koristilo standardizirane testove za procjenu matematičkih sposobnosti i vještina (NCCA, 2005).

S obzirom na to kako većina testova ima kao polazište disparitet inteligencije i aritmetičkih sposobnosti, u praksi se isto može prepoznati kod učenika čija je uspješnost u matematici znatno ispod razine njegove kronološke i mentalne dobi. Na primjer, učenik šestog razreda koji je prosječno intelektualno razvijen i uspješan u svim školskim predmetima, osim matematike koju razumije na razini trećeg razreda. Jedan od kriterija koji se može koristiti u nastavi je broj aritmetičkih činjenica koje su učenici upamtili zato što se pokazuje kako diskalkulična djeca u prosjeku zapamte tri puta manje od ostalih vršnjaka (Hasselbring i ostali, 1988). Također, mogući je indikator diskalkulije to što često dolazi u paru s disleksijom, disgrafijom i ADHD-om koji su češće identificirani u sustavu odgoja i obrazovanja pa bi početna točka za detekciju diskalkuličnih učenika u praksi mogla biti u široj primjeni testova aritmetičkih sposobnosti od strane školskog psihologa ili nekog drugog stručnjaka sličnog profila.

Učenik s diskalkulijom može napredovati u razumijevanju matematičkih sadržaja, ali znatno sporije od svojih vršnjaka (Sharma, 2001). Razvijemo li svijest o diskalkuliji s

naglaskom na određenje dotičnog poremećaja i karakteristike učenika koji imaju diskalkuliju, mogli bismo učiniti značajan iskorak u obrazovnim perspektivama i aspiracijama naših učenika zato što bismo ispravnim pristupom podigli očekivanja učenika, učitelja, nastavnika i ostalih školskih djelatnika te obitelji tih učenika. Također je očekivano kako bi se kroz institucionalni rad u školama kroz različite programe usmjerene na učenike s diskalkulijom pomoglo i brojnim drugim učenicima koji nisu nužno prepoznati kao takvi, ali imaju različitih teškoća u učenju matematike. Kod svih učenika s nekim oblikom ili vrstom teškoća u učenju matematike pojavljuje se problem praćenja sadržaja i razumijevanja matematičkih koncepata koji ovise o prethodno naučenom, a isto se naročito ističe početkom školovanja u razrednoj nastavi kada djeca koja imaju teškoće u računanju stalno nailaze na prepreke, nerazumijevanje sadržaja ili pak nedovoljno vremena kako bi učila i usvajala matematička znanja i vještine tempom predviđenim nastavnim planom i programom.

Mnoga djeca s diskalkulijom, naročito oni visoko inteligentni, mogu proći neopaženo kroz obrazovni sustav pa do trenutka kada netko ne ustanovi odstupanje njihovih intelektualnih kapaciteta i onih u matematici, može biti kasno u vidu o(ne)mogućavanja perspektive učenika koju bi mogao ostvariti svojim kapacitetima. Neki ljudi s diskalkulijom mogu biti izvanredni stručnjaci u geometriji, algebri, statistici, programiranju i nizu zanimanja iz STEM područja. Mnogim praktičarima, ali i široj društvenoj zajednici, teško je pojmiti kako netko s neuspjesima u početnoj matematici može postati stručnjak u području u kojem je dominantno matematičko mišljenje unatoč deficitima u osnovnim matematičkim vještinama i sposobnostima. Zato je na roditeljima, učiteljima, nastavnicima i stručnim suradnicima velika odgovornost jer ukoliko nije na vrijeme prepoznat i tretiran, poremećaj poput diskalkulije može postati doživotnom poteškoćom koja ograničava akademsku uspješnost i mogućnost samoostvarenja. U nastavi matematike tim učenicima možemo pomoći tako što ćemo dati prednost usmenim oblicima poučavanja i provjeravanja znanja; što ćemo koristiti tiskani tekst umjesto pisani rukom; što ćemo povećati razmak između slova i redova pri pisanju; označiti bitne dijelove teksta u udžbeniku; poredati zadatke od jednostavnijih prema složenima; odvojiti skupine zadataka u kojima se koristi ista računska operacija, odnosno isti princip rješavanja zadatka te niz individualiziranih postupaka u pomoći i uputama u razumijevanju sadržaja, motivaciji i pohvalama za svaki trud i napredak.

Kako je diskalkulija trajni razvojni poremećaj, nije preporučljivo previše ustrajati na tome da dijete upamti brojne aritmetičke činjenice u nadi da će napornim radom sve nadići. To je to trajni deficit koji se ne može značajno promijeniti, osim u slučaju simptoma koji ne upućuju na diskalkuliju kao pozadinu uočenog stanja učenika. Stoga je bolje vježbati neke

druge metode, vještine i koncepte zato što iz razumijevanja diskalkulije kao specifične neurorazličitosti logično proizlazi kako zbog pretpostavke iznad(prosječne) inteligencije ta djeca mogu puno brže napredovati u radu s drugačijim obrazovnim sadržajima, konceptima ili pak s drugačijim pristupom sadržajima koji su isključivo numeričkog karaktera. To je bitno zbog samog napretka u znanjima i vještinama, ali i zbog motivacije koja se ispravnim pristupom može pozitivno potkrijepiti. S druge strane, ustrajanje neprikladnim metodama, iako dobronamjerno, može dovesti dijete do još goreg emocionalnog stanja što je u slučaju diskalkulije prilično izvjesno. Tako na primjer, vježbe memoriranja tablice množenja neće ništa značajno promijeniti, naročito ne u nekom razumnom vremenskom periodu unutar kojeg je normalno očekivati rezultate, a samim time i emocionalnu komponentu samog procesa koja umjesto zadovoljstva može rezultirati frustracijom i osjećajem bespomoćnosti. Stoga pri obradi specifičnih sadržaja koji su prožeti računskim operacijama treba početi s primjerima s kojima se učenik osjeća ugodno i samopouzdano u rješavanju te nastojati raditi i omogućivati razvoj djeteta u logičko-matematičkim zadatcima koji nisu dominantno numeričkog karaktera, a opet su neizostavni dio matematike koja ih čeka u kasnijem školovanju.

U recentnoj praksi, prema najprisutnijem primjeru disleksije, tretman učenika sa specifičnim teškoćama u učenju dominantno se svodi na vođenje dokumentacije i na različite oblike prilagodbe u radu, ali se nedostatno vodi računa o perspektivi učenika i pedagoškom savjetovanju što je primarna svrha rada nastavnika s učenicima koji imaju teškoće u učenju. Pritom je nužno razumjeti kako je pedagoško savjetovanje jednako bitno i potrebno svakom drugom učenika u nastavnom procesu. Razumijevanje specifičnih poremećaja ili teškoća samo upućuje na prilagodbe nastavnika, ali isto ne podrazumijeva i prioritet u radu nastavnika nad ostalim učenicima s obzirom na to da iskustva iz prakse koninuirano ukazuju kako velikom broju učenika treba omogućiti značajnu podršku kojom bismo im pružili perspektivu da se ostvare u matematici, ali i na široj osobnoj i akademskoj razini.

2.3.3. Matematički daroviti učenici

Matematika kao znanost, ali i nastavni predmet u školama, zbog svoje je logičke strukture i prirode sadržaja kojima se bavi u privilegiranom položaju za detekciju i privlačenje darovitih učenika (Horvat i Kolak, 2014). Među najprihvaćenijim definicijama darovitosti njezino je određenje preko dostignuća. Tako Koren (1987) definira nadarenost kao svojevrstan sklop osobina (sposobnosti, motivacije i kreativnosti) koji pojedincu omogućuje postizanje izrazito natprosječnog rezultata u nekoj domeni ljudske djelatnosti.

Darovitost se može dijagnosticirati s nekoliko aspekata zato što terminološko određenje matematički darovitog učenika nema jednoznačno određenje te nije statičnog karaktera uzduž obrazovnog puta mnogih učenika. Neki autori (Vlahović-Štetić, 2005) spominju različite teorijske pristupe darovitosti, među kojima su pristupi usmjereni:

- na genetske čimbenike (Terman, Oden, 1959; prema Vlahović-Štetić, 2005)
- na kognitivne modele (Sternberg, 2001)
- na postignuće (Renzulli, 1986)
- na sustavni pristup (Tannenbaum, 1983, Heller i sur., 2000)

Prva dva pristupa pretežito su usmjerena na kognitivne i još neke karakteristične osobine, treći na specifična postignuća, a četvrti model ističe okolinske faktore u razvoju darovitih.

U okvirima prvog teorijskog pristupa matematičku darovitost učenika karakterizira bolje pamćenje brojki i spacijalnih odnosa, vješto korištenje numeričkih informacija te pokazuju prosječne ili iznadprosječne rezultate na verbalnim sposobnostima što potvrđuju i visoke korelacije između istih na svim standardiziranim testovima inteligencije (Vlahović-Štetić, 2005; Cvetković-Lay, Sekulić-Majurec, 2008). Čudina-Obradović (1991) matematičku darovitost promatra kroz interakciju različitih užih sposobnosti: numeričke, sposobnosti pamćenja i planiranja, sposobnosti prostornog predočavanja te sposobnosti logičkog zaključivanja i uočavanja veza. Neizostavno je prisustvo motivacije za rad i iznimna radna energija koja se očituje u izrazitoj usmjerenosti prema matematičkim aktivnostima.

Očito je kako je ovaj pristup darovitosti dominantno obilježen istraživanjima iz psihometrijske paradigme koji svoje početke bilježe u radovima Galtona, Pearsona, Bineta i Termana koji darovitost određuju putem testa inteligencije. Marland (1972) ističe kako pored inteligencije darovitost možemo prepoznati po nekim drugim sposobnostima i osobinama u kojima navodi područja općih i specifičnih akademskih sposobnosti, kreativne sposobnosti, sposobnosti vođenja i rukovođenja te umjetničke i psihomotorne sposobnosti. Navedena su se područja (prema Marland, 1972) pokazala kao dobar predložak teorije o višestrukim inteligencijama kojom je Gardner (1983) predstavio sedam specifičnih područja sposobnosti (talenata): logičko-matematička, lingvistička, vizualno-spacijalna, tjelesno-kinestetička, glazbena, interpersonalna i intrapersonalna. Ta je teorija sve zastupljenija u području pedagogije i psihologije čime je područje darovitosti dobilo svojevrstan okvir unutar kojeg može lakše klasificirati učenike na temelju njihovih posebnosti. Također, tim su se pristupom teorijska i praktična razmišljanja o inteligenciji udaljila od klasičnog pristupa putem testa inteligencije koji, među ostalim specifičnostima, preferira logičko-matematičku kompetenciju.

Međutim, testom inteligencije može se utvrditi određeni potencijal učenika, ali ne i realizacija određene darovitosti za koju je ipak potrebno više od toga. Naime, darovitost je kombinacija osobina, sposobnosti i ličnosti te se može pojaviti u različitim područjima sposobnosti ili kao jedna (grupa) izrazito razvijena(ih) sposobnost(i).

Pristupi usmjereni na kognitivne modele bilježe svoje početke u Piagetovima radovima u kojima je težište na procesu mišljenja i pamćenja. Sternberg (2001) u svom modelu navodi tri dimenzije inteligencije:

- analitička (komponentna)
- sintetička (iskustvena)
- praktična (kontekstualna).

Analitička ili komponentna inteligencija odnosi se na sposobnost analiziranja te apstraktnog i logičkog zaključivanja. Sintetička ili iskustvena inteligencija, naziva se još i kreativna inteligencija, podrazumijeva divergentno mišljenje, sposobnost izvođenja zaključaka i formuliranja novih ideja te kombiniranja i spajanja različitih ideja i sadržaja u smislene apstraktnije cjeline. Kontekstualna ili praktična inteligencija odnosi se na sposobnosti prilagođavanja različitim svakodnevnim situacijama.

Prema teorijskim pristupima usmjerenima na postignuće, Koren (1989) ističe kako je jedan od boljih pokazatelja darovitosti kontinuirana uspješnost koja se očituje u visokim postignućima pojedinca. Darovitost se pritom promatra kao interakcija natprosječnih sposobnosti, motivacije i kreativnosti. Osnovu te teorije čini Renzullijev troprstenasti model (1986) darovitosti prema kojem produktivnu darovitost uvjetuju:

- iznadprosječno razvijene sposobnosti
- osobine ličnosti
- kreativnost.

S druge strane, nekognitivne karakteristike darovitih učenika usmjerene su na fleksibilnost, otvorenost za nova iskustva, toleranciju na neizvjesnost, pozitivnu sliku o sebi, znatiželju, spremnost na rizik i predanost zadatku. Razmatranje okolinskih čimbenika u razumijevanju koncepta darovitosti temeljno je obilježje sustavnog teorijskog pristupa. Rezultati istraživanja o socijalnoj prilagodbi i postignuću nadarenih govore kako je stimulirajuća obiteljska klima glavni činitelj kasnijeg akademskog i profesionalnog uspjeha (Tomlinson-Keasy i Little, 1990; prema Vizek-Vidović i sur., 1996). Za realizaciju darovitosti, Renzulli i Reis (1985) ističu sljedeće okolinske čimbenike: socioekonomsko stanje obitelji, ličnost i obrazovanje roditelja,

stimuliranje dječjih interesa te mnoštvo slučajnih faktora iz društva, obitelji i života. Navedeni čimbenici podudaraju se s Hellerovim multifaktorskim modelom koji pojam nadarenosti određuje kao sklop osobnih, kognitivnih, konativnih i socijalnih mogućnosti za ostvarenje izrazitog postignuća u jednom ili više područja (Heller, 1996; prema Vizek-Vidović i sur., 1996). Model uključuje tri skupa prediktorskih varijabli (osobine ličnosti, kognitivni činitelji nadarenosti, značajke okoline) čijim međudjelovanjem dolazi do očitovanja nadarenosti u pojedinim područjima.

Temeljne su postavke toga modela:

- nadarenost se javlja u raznim područjima kao što su: opća intelektualna sposobnost, kreativnost, socijalna kompetencija, umjetnički talenti i psihomotorna sposobnost
- individualne dimenzije nadarenosti odgovaraju pojedinim oblicima akademskog i neakademskog postignuća
- uz kognitivne sposobnosti očitovanje nadarenosti ovisi i o nekognitivnim osobinama
- obitelj i škola glavni su socijalizacijski činitelji koji potiču nadarenost.

Za realizaciju visokih sposobnosti karakterističnih za nadarene učenike ključnu ulogu ima specifično rano obrazovno iskustvo, intelektualna i emocionalna podrška obitelji te poseban sklop osobnih značajki važnih za postignuće (Benbow i Arjmand, 1990; prema Vizek-Vidović, 1996). U školskom sustavu kao jedan od najvećih izazova javlja se problem pravovremenog otkrivanja i prepoznavanja matematički darovitih učenika, odnosno potencijalno darovitih učenika.

2.3.3.1 Identifikacija darovitih učenika

Matematički daroviti učenici, osim iznadprosječnih općih sposobnosti, pokazuju i iznadprosječne rezultate na testovima matematičkih sposobnosti (specifične sposobnosti). Oni tijekom školovanja razvijaju specifičan interes za područje matematike te uz specifičnu kombinaciju sposobnosti, vještina i odgojno-obrazovne podrške okoline pokazuju iznimne rezultate u nastavi matematike. Kako bi se darovitost mogla iskazati u izrazito natprosječnom postignuću u matematičkim aktivnostima, učenik mora imati određeni potencijal koji će mu omogućiti da se njegove sposobnosti razviju do tog stupnja. To se odnosi na osnovu

potencijalne darovitosti koju čine opće intelektualne sposobnosti, specifične osobine ličnosti koje pridonose iskazivanju darovitosti te povoljna i poticajna okolina.

Matematičku darovitost učenika karakterizira bolje pamćenje brojki i spacijalnih odnosa te vješto korištenje numeričkih informacija. Ti učenici uz visoke numeričke sposobnosti i sposobnosti matematičkog rezoniranja češće pokazuju prosječne ili iznadprosječne rezultate na verbalnim sposobnostima. Verbalne sposobnosti dolaze do izražaja u problemskim zadatcima (zadatci s riječima) kroz koje već unaprijed možemo izdvojiti potencijalno darovite učenika. S druge strane, u prethodnom poglavlju (poglavlje 2.3.2) istaknuto je kako učenici s teškoćama u pisanju i čitanju često imaju probleme s matematikom zbog njezinih simbola, znakova i specifičnosti matematičkog pisma. To posebno dolazi do izražaja u problemskim zadatcima koji pored usvojenosti matematičkog pisma zahtijevaju fluidne jezično-govorne i verbalne vještine. Pokazuje se kako ni to nije dovoljno jer ukoliko učenik ne umije čitati s razumijevanjem, tada ne može izdvojiti bitne od nebitnih informacija, modelirati problem i riješiti ga odgovarajućim matematičkim metodama i postupcima. To su zadatci u kojima se daroviti učenici posebno ističu već od najranije dobi zato što pored navedenih sposobnosti posjeduju duboko usvojena konceptualna matematička znanja. Stoga se u osnovnoj školi kao značajan faktor prepoznavanja (matematički) darovitih učenika pokazuju njihove vještine mentalne aritmetike pa se učenici često kategoriziraju po uspješnosti uglavnom po brzini računanja, a ostali kapaciteti u kontekstu nastave matematike ostaju manje zamijećeni.

U području identifikacije i prepoznavanja matematički darovitih pojedinaca značajan doprinos i pomoć učiteljima u donošenju odluka o matematičkoj darovitosti daju inteligentni ekspertni sustavi (Pavleković, Zekić-Sušac, Đurđević, 2010). Darovitost se u tim sustavima ispituje po područjima matematičkih kompetencija određenih korpusom matematičkih znanja: brojevi i računanje, veličine i mjerenje, prostorni odnosi i oblici te sređivanje podataka i rješavanje problemskih situacija. Učenici se kroz dijagnostiku tih sustava klasificiraju prema sljedećim kategorijama:

- učenik koji je darovit za matematiku
- učenik koji pokazuje poseban interes za matematiku
- učenik prosječnih matematičkih kompetencija
- učenik s nedovoljno razvijenim matematičkim kompetencijama.

(prema Vlahović-Štetić, 2007).

Sriraman (2005) ističe kako mnogi autori pri razvoju matematičke darovitosti neizostavnim smatraju kreativno razmišljanje te navodi kako su aktualna brojna neslaganja oko

pitanja kreativnosti u nastavi matematike. Razlog je tome percepcija kreativnosti kao najvišeg oblika darovitosti te činjenica kako je kreativnost sposobnost koja najviše doprinosi razvoju znanosti te se stoga i u aktualnim obrazovnim razmatranjima stvaralaštvo ističe kao jedan od prioritetnih ciljeva odgojno-obrazovnih sustava. Međutim, ne može se procijeniti koliko je kreativnosti potrebno za koju razinu izvrsnosti te koliko je kojih kvaliteta potrebno za uspješno studiranje matematike i srodnih znanosti, a naposljetku i koliko je bilo tih „kreativnih“ učenika među onima koji su ostvarili znanstvene karijere u matematici. Renzulli u određenje darovitosti, osim sposobnosti, uključuje motiviranost učenika kao i učeničku kreativnost što implicira problematiku razlikovanja matematičkih sposobnosti od matematičke kreativnosti. Naime, kreativni su učenici istovremeno i daroviti učenici, ali daroviti učenici nisu nužno i kreativni učenici (Vlahović-Štetić, 2007). Pritom je nužno razmatrati korpus matematičkih znanja i sadržaja te karakter i zahtjevnost matematike kao suvremene znanosti koja je svojim ubrzanim razvojem dosegla nevjerojatan obujam i širinu znanja za koje je nužno posjedovati kontinuitet u radu i postupno nadograđivati znanja, a ne ih stvarati.

Na tragu toga, dosta istraživača ispituje distinkcije i različitosti u (poimanju) kreativnosti (Usiskin, 2000; Beghetto i Kaufman, 2009; Karp, 2017, Mhlolo, 2017; Zazskis, 2017). Beghetto i Kufman (2009) prezentirali su problem „C vs. c“ i „T s. t“, (eng. „c“- creativity, „t“- talent) kojim izdvajaju iznimno visoke razine kreativnosti i talenta nasuprot onim svakodnevnim. Beghetto i Kaufman (2009) prema tome navode kako: *se veliko-C odnosi na eminentne i revolucionarne ekspresije kreativnosti na iznimno visokim razinama koje su na neki način dostupne samo malom broju pojedinaca. Malo-c se pritom odnosi na kreativnost u svakodnevnim situacijama te je svojom dostupnošću na raspolaganju većini pojedinaca*.

Karp (2017) ističe kako se u javnosti ta distinkcija rijetko razmatra te često dovodi do svojevrsnih nerazumijevanja dotične problematike. Usiskin (2000) tvrdi kako se moramo izuzeti od binarnih shvaćanja (biti i ne biti kreativan, talentiran nasuprot netalentiran), već se isto mora razmatrati kao kontinuum. On stoga tvrdi kako moramo u praksi razumjeti i razlikovati „prosječne“ učenike i njihovu kreativnost od velikih umova poput Gaussa i Einsteina na koje se mnogi često referiraju u promišljanjima o kreativnosti.

Kontinuum i proces za nastavnu praksu jednostavno podrazumijeva kako nastava (matematike) mora postaviti jasne ciljeve kako dovesti učenike na više razine znanja i razumijevanja te stjecanje zahtjevnijih vještina od onih koje trenutno pokazuju. Učenike stoga treba učiti razvoju kreativnosti i matematičke intuicije. Najveću ulogu u detekciji i poticanju potencijala i sposobnosti učenika imaju učitelji i nastavnici matematike koji snose obuhvatniju odgovornost s obzirom na to da je matematička darovitost jedan od glavnih pokazatelja opće

darovitosti učenika te značajno utječe na izbor budućih zanimanja koja, ukoliko nisu popraćene stručnom podrškom, mogu ograničiti potencijale i razvoj (potencijalno) darovitih učenika.

2.3.3.2 Rad s darovitim učenicima i pozicioniranje konstrukta darovitosti u nastavnom procesu

Uz identifikaciju darovitih učenika, ključno je odabrati strategiju podrške kako bi ti učenici napredovali u skladu sa svojim mogućnostima. Osim otkrivanja i identifikacije darovitosti, u uspješne strategije razvoja matematičke darovitosti ubrajaju se praćenje razvoja, odgojno-obrazovni tretman te profesionalni razvoj (Rosić, Vrcelj, Mušanović, 2004). Naime, među darovitim učenicima ima značajan udio djece koji lako i bez mnogo uloženog truda svladavaju sve nastavne sadržaje pa u početcima svog obrazovanja nisu stekli radne navike što im u srednjoškolskoj matematici može stvoriti nepremostive zapreke. Jedno je od bitnijih karakteristika darovitih učenika već u početnoj nastavi matematike situacijska dosada i problem optimalnog opterećenja kako bi stekli radne navike.

Naime, uobičajeni nastavni sadržaji darovitim učenicima iz područja matematike obično su nedovoljno izazovni što izaziva emocionalnu reakciju dosade koja se javlja kao situacijska dosada. Drugim riječima, emocionalnu reakciju dosade izaziva nedovoljno izazovan i primjeren sadržaj matematike kao i neprimjerena odgojno-obrazovna podrška učitelja i nastavnika. U određivanju didaktičko-metodičke strategije potrebno je uključiti samostalno učenje i ubrzano poučavanje, uvažiti potrebu učenika za usamljenim aktivnostima, osigurati vrijeme potrebno za odgovore na svrhovito postavljena pitanja, formirati grupe učenika koje će se baviti zajedničkim zanimljivim aktivnostima (rad na projektu), osigurati dostupnost potrebnih izvora znanja, mentora i stručnjaka (kontakt sa znanstvenikom).

Tako i u početnoj nastavi matematike daroviti učenici mogu bez uloženog truda pratiti i svladati sve sadržaje predviđene nastavnim planom i programom te su često pod rizikom nerazvijanja radnih navika koje su osnova u kasnijoj matematici koja po prirodi i redoslijedu svojih sadržaja s godinama postupno zahtijeva sve više kontinuiteta u radu. Zbog toga mnogi (potencijalno) daroviti učenici ne rade u skladu sa svojim kapacitetima u srednjim školama i još manje na fakultetima. Stoga se pokazuje kako je za školsku praksu možda i najveći izazov u otkrivanju, praćenju i potpori (potencijalno) darovitih, naročito u longitudinalnom kontekstu

u čijim se okvirima mnogi učenici gimnazijskih usmjerenja izgube u osrednjosti i prosječnosti zato što im nije pružena adekvatna odgojno-obrazovna i obiteljska podrška.

Za program podrške matematički darovitim učenicima bitno je razlikovati darovite učenike od učenika koji imaju vrlo dobar ili odličan uspjeh u matematici zato što učenik iz prve kategorije značajno premašuje očekivanja kurikuluma matematike od vršnjačke dobi, a učenik iz druge kategorije u skladu je ili nešto iznad očekivanja kurikulumskih odrednica (Pavleković, Zekić-Sušac, Đurđević, 2007). Podrška u nastavnoj praksi uglavnom se realizira akceleracijom putem ranijeg upisa u školski sustav ili preskakanjem razreda.

Pod akceleracijom podrazumijeva se svaka progresija obrazovnog procesa darovitog učenika smještanjem u napredniji razred, odnosno odgojno-obrazovni odjel iznad njegove kronološke dobi. Akceleracija sprječava razvoj navike mentalne lijenosti, izbjegavanje dosade, smanjuje samodopadnost i uobraženost darovitog učenika te mu omogućava raniji završetak školovanja. S druge strane, unatoč kognitivnim sposobnostima i zrelosti, nadareni učenici često su nespremni u socijalnom, emocionalnom i fizičkom području.

S obzirom na specifičnost matematičke darovitosti**,** realizacija akceleracije mora se zasebno razmatrati unutar predmeta (matematika) ili u punom obujmu duž cijelog programa, odnosno kao akceleracija preskakanjem razreda. Također, akceleraciju je moguće provoditi i *obogaćivanjem kurikuluma* putem produbljivanja i proširivanja iskustva učenja matematike. Kao poznati model obogaćivanja kurikuluma izdvaja se Renzullijev *trijadni model obogaćivanja* koji u obliku križaljke razlikuje pojmove, znanja, procesne vještine i stavove kroz tri kategorije: morali bi, trebali bi, mogli bi (George, 2005).

Matematički darovitom učeniku potrebno je pružiti odgojno-obrazovni paket podrške te bismo u praksi naročito trebali istaknuti odgojnu komponentu koja često izostaje, a itekako im je potrebna. Obrazovanje darovitih učenika ima kao jednu od temeljnih prepreka problem individualizacije koji je općeprisutan u odgojno-obrazovnom sustavu, a koji se u težnji kvalitete mora voditi ekonomičnošću i racionalizacijom nastavnih metoda u ostvarivanju ciljeva nastavnog plana i programa. Unatoč tome, nastavnici mogu i moraju individualizirati nastavne metode, u najmanju ruku da boljim učenicima daju zahtjevnije i složenije zadatke koji će im biti dovoljno izazovni. Možda su najbolji primjeri obrazovanja darovitih učenika centri izvrsnosti (npr. Varaždinska županija) koji su svojim rezultatima potvrdili kako su među najboljim primjerima rada s darovitim učenicima u našem odgojno-obrazovnom sustavu. To potkrepljuje činjenica kako su unatoč početcima koji sežu u 2002. godinu i dalje jedini centar izvrsnosti u Republici Hrvatskoj te kako su priznati na međunarodnoj razini 2018. godine kada

su postali *Europski centar za darovite učenike* kakvih ima još samo 25 u svijetu (*Europe Talent Centre Croatia).*

Područje matematičkog obrazovanja u mnogim je aspektima obilježeno stereotipima u društvu te se opravdano može kazati kako većina njih proizlazi iz problema darovitosti i obrazovanosti koji Giesecke (1993) u knjizi „Pedagogija - znanost o odgoju“ navodi kao središnji pedagoški problem. Među školskim predmetima, isti se zasigurno najčešće aktualizira u kontekstu nastave matematike. Naime, iako se u brojnim istraživanjima pokazalo kako je u realizaciji visokih sposobnosti ključna podupiruća i poticajna odgojno-obrazovna okolina te poseban sklop osobnih karakteristika, u nastavi matematike darovitost se pokazuje kao izdvojeni fenomen koji je pod značajnim utjecajem raznih uvjerenja društva o matematici.

Tako za darovitu djecu obično smatramo kako će biti uspješna u školi bez obzira na okolinske faktore. Iako problem darovitosti i obrazovanosti implicira na predrasude o darovitim učenicima, isti je u jednakoj mjeri zastupljen kod ostalih učenika, a naročito kod onih koji imaju teškoće u nastavi matematike**.** Naime, neovisno od sve zastupljenijih teorijskih i praktičnih razmišljanja o razvijanju višestrukih inteligencija koje su našle svoju refleksiju i u nastavnoj praksi (posebno u segmentu integrirane nastave), društvo nepisanim pravilima kroz sustav vrijednosti skriveno nameće svoju definiciju darovitosti (Horvat i Kolak, 2014). S izuzetkom manjeg broja onih koji su bili uspješni u školskoj matematici, cijela se problematika subjektivno oblikuje u svakom pojedincu koji određenim obrambenim mehanizmom objašnjava kako je neuspjeh nastao uslijed nedostatka nekih sposobnosti što je zbog nerazumijevanja širine dotičnog problema lakše prihvatiti, nego činjenicu da se uspjeh doista može ostvariti.

Unatoč tome što se u literaturi fenomen darovitosti sustavno istražio i raščlanio u nekoliko različitih teorijskih pristupa, u praksi nekako stalno pribjegavamo genetskom pristupu koji je bio dominantan i kroz povijest. To se naročito tiče nastave matematike u kojoj matematičke uspjehe stalno pripisujemo visoko razvijenim intelektualnim sposobnostima bez razmatranja postupnosti i uvjeta njihova razvoja. Pitanje koje se samo nameće je pitanje sposobnosti koje smatramo nužnim za svladavanje matematike te onih koje određuju darovite učenike.

Na primjer, Švarcburd (prema Kadum, 2006) smatra kako se matematičke sposobnosti izražavaju u sljedećem:

- razvijanje prostornog predočavanja
- sposobnost za odvajanje bitnog od nebitnoga

- sposobnost apstrahiranja, sposobnost prijelaza s konkretne situacije prema shemi koja sažeto karakterizira bit problemskog zadatka
- sposobnost deduktivnog mišljenja i zaključivanja
- primjena stečenog znanja i zaključaka na konkretne sadržaje
- sposobnost kritičkog promišljanja i postavljanje novih problemskih pitanja
- posjedovanje dovoljno razvijenog pismenog i usmenog matematičkog izražavanja
- posjedovanje strpljenja i upornosti pri rješavanju matematičkih problema.

Ta se znanja očituju u nalaženju racionalnih, ali i nekonvencionalnih puteva u rješavanju standardnih i nestandardnih zadataka, u poštivanju matematičkih pravila i koncepata pri proceduralnim, odnosno algoritamskim postupcima rješavanja. Ključno je pritom odgovoriti koliko je kojih sposobnosti potrebno posjedovati, i u kojoj mjeri, kako bi učenika smatrali nadarenim. Međutim, većinu je gore navedenih sposobnosti i pripadajućih vještina relativno teško prepoznati, tj. razaznati potencijal istih u početnoj matematici u kojoj je bitno što ranije uočiti specifične sposobnosti i vještine ili pak određeni mentalni sklop ličnosti za koji se najčešće vezuje sklonost prema matematici i prirodnim znanostima.

Naime, početna matematika u razrednoj nastavi i kasnije u višim razredima osnovne škole bazira se na aritmetici pa se tamo ponajprije može uočiti neuobičajeno zanimanje za brojeve i matematičke sadržaje te upornost i motivacija u rješavanju zagonetki ili težih problemskih zadataka. Međutim, u nastavi ima introvertirane djece kod kojih je teže uočiti sposobnosti i kapacitete ili pak potaknuti iste što često ograničava razvoj djece koja su sramežljiva i povučena zbog čega im treba više vremena kako bi se emocionalno pripremila i osposobila za sudjelovanje u nastavi. Ima više razloga zašto bismo trebali više pažnje posvetiti takvoj djeci: od onih pedagoških kako bi se dobro osjećali na nastavi pa do onih relevantnih za sklonost prema matematici kao što su introverzija, sklonost detaljima i perfekcionizmu, urednost u čitanju i pisanju, slaganje kompleksnih rečenica te mnoge slične kvalitete za koje je pouzdano utvrđeno kako su značajni prediktori visokih postignuća u matematici.

Zbog logičke strukture matematičkih sadržaja i koncepata, neupitna je korelacija između kvocijenta inteligencije i uspješnosti u matematici. Međutim, korelacija ne implicira uzročno-posljedičnu vezu, odnosno kako će inteligentniji učenici biti bolji u matematici i školi općenito ili kako prosječno inteligentan učenik ne može biti jednako uspješan ili bolji od iznadprosječno inteligentnog. Također, visok kvocijent inteligencije, barem u nekim užim znanstvenim krugovima, sve se manje smatra presudnim za uspjeh u školi i životu, a tome su doprinijeli Mayer i Salovey (1990) uvodeći pojam „emocionalna inteligencija“.

Tako Cattelovo istraživanje (prema Lacković-Grgin, 1994) pokazuje da od ukupne varijance školskog postignuća, rezultati na testovima inteligencije objašnjavaju oko 25 % te varijance, osobine ličnosti oko 36 %, a motivacijske osobine oko 27 %. J. S. Renzulli (1978) razlikuje školsku darovitost (visok IQ, uspješnost rješavanja zadataka i reproduciranje znanja) i produktivno-kreativnu darovitost. Pod školskom darovitosti smatra visok kvocijent inteligencije, uspješnost rješavanja zadatka i reproduciranje znanja, a pod produktivno-kreativnoj nadarenosta smatra sposobnost primjene znanja u životnim zadatcima. Ukupan broj takvih darovitih pojedinaca Renzulli procjenjuje na 30 %. Iako darovitost nije nužan uvjet za uspjeh u školi i općenito za uspjeh u životu, navedena ljestvica može objasniti uspjehe brojnih učenika koje inače smatramo prosječnima. Dakako, ni Renzullijeva ljestvica ne govori kako ostali učenici nisu sposobni za uspjeh u školi, samo što on razliku između darovitih i prosječnih učenika smatra znatno manjom nego što se to inače običava.

Detekciju darovitosti i standardizirane testove inteligencije možemo svesti pod zajednički nazivnik u kontekstu temeljnog zajedničkog obilježja, a to je da se isti odnose na rješavanje u ograničenom vremenu što se pokazuje kao test brzine, a ne samo može li netko neki zadatak i/ili problem uopće riješiti. Za nastavu matematike ključno je odgovoriti možemo li za svako matematičko poglavlje i pojedinačni zadatak svesti vještine, sposobnosti i predznanje na nekoliko koraka i ciljeva koji se moraju postići van okvira vremena i za to potrebnih sposobnosti. Pritom se mora uvažiti postupnost razvoja matematičkih sposobnosti koje variraju u specifičnim kapacitetima i sposobnostima koje su potrebne tijekom svladavanja gradiva u osnovnoškolskom (aritmetika i logika) i srednjoškolskom obrazovanju (algebra, logika, apstraktno mišljenje, analitičnost). Daroviti matematičari razviju većinu vještina još u srednjoj školi, a prosječan student matematike (kojeg se na smatra darovitim) mnoge od tih vještina razvije u istom intenzitetu tek tijekom studija i/ili daljnjeg usavršavanja u struci. Ključni faktor pritom je vrijeme koje zbog toga ponajprije ograničava krajnje domete.

Međutim, značajan izazov za nastavu matematike potaknuti je učenike da u što većoj mjeri koriste svoje kapacitete kako bismo uopće za pojedinca mogli kazati kako nešto ne može zato što za to nema dovoljno razvijenih sposobnosti i vještina. Naime, „matematička biografija“ tipičnog učenika ukazuje kako većina učenika ne radi matematiku u kontinuitetu te kako su s godinama školovanja interes i motivacija učenika za učenjem u značajnom padu. Implicitno se otvara pitanje vremena koje se daje učenicima kako bi riješili zadatak i kako se tome izazovu općenito pristupa u procesu učenja i poučavanja. To implicira pitanje nastavnih planova i programa koji u ovom kontekstu imaju dva suprotstavljena pojma *kvaliteta* i *kvantiteta* čiji se odnos u kontekstu primjerenosti i optimizacije učeničkih potencijala ne istražuje, a nažalost

rijetko se i razmatra u suvremenim odgojno-obrazovnim diskusijama i smjernicama aktualnih obrazovnih politika. Odgojno-obrazovni sustavi diljem svijeta usmjereni su na učeničke ishode i koncept didaktike kao teorije kurikuluma, a pritom se ne procjenjuje opsežnost nastavnih planova i programa, već se smatra kako će određivanje kvalitetnijih ishoda rezultirati višim razinama usvojenih znanja i stečenih vještina. To ima kao premisu kako nastava matematike nije dovoljno kvalitetna, a kritički se ne procjenjuje intenzitet i ekstenzitet znanja te samim time i temeljni preduvjeti prostorno-vremenskih okvira realizacije zadanih ishoda koji su donekle prikladni samo za manji dio, uglavnom uspješnijih i motiviranijih učenika.

Unatoč raširenom mišljenju o konstantnosti kvocijenta inteligencije i statičnosti matematičkih sposobnosti učenika, pokazuje se kako je problematika darovitosti znatno šira te utječe na svakog učenika na njemu svojstven način. Naime, fenomen darovitosti i obrazovanosti u nastavi matematike ima mnogostruke i višeslojne implikacije na učenike i cjelokupni nastavni proces. Zato su sve brojnija istraživanja nastave matematike koja proučavaju stavove, uvjerenja i emocionalne reakcije učenika u nastavi te relevantne čimbenike iz društva i obitelji. Uvažavajući slojevitost i raširenost cijele problematike, sa stajališta pedagoške struke nužna su promišljanja na sljedeća pitanja:

- Je li bitan stav društva i obitelji prema matematici te možemo li stoga reći kako je matematičko obrazovanje kulturno i društveno uvjetovano?

- Koje su pretpostavke i preduvjeti školskog uspjeha te ima li nastava matematike nešto specifično, odnosno zahtjeva li neke drugačije sposobnosti, vještine i osobne karakteristike učenika od drugih nastavnih predmeta?

- Može li učenik prosječnih intelektualnih kapaciteta biti izvrstan u školskoj matematici i potom završiti studij matematike?

- Utječe li (i kako) uspješnost darovitih učenika na ostale učenike u razredu?

- Može li se matematika svesti na niz procedura i činjenica zbog kojih, ukoliko ih usvojimo, imamo preduvjete postati vrsni matematičari?

- Koji su uvjeti uspješnosti u matematici? Postoji li „recept" za svakog učenika i poteškoće koje isti ima u matematici?

- Jesu li učenici koje smo prepoznali kao darovite uspjeli uz pozitivan utjecaj obitelji i škole, bez obzira na njihove genetske predispozicije, te koliko često nazivamo darovitim nekog

tko je uz puno truda i rada postizao iznadprosječne rezultate, a nekog s lošijim rezultatima smatramo nesposobnim iako se uopće nije trudio?

Zbog uvjerenja kako je darovitost nužan, ali i dovoljan uvjet za uspjeh u matematici, dolazi do svojevrsnog podcjenjivanja sposobnosti ostalih učenika do mjere u kojoj ne svladaju ni sadržaje koji su znatno ispod njihovih realnih mogućnosti. Uz to, nisu sve inteligencije, poput matematičke, cijenjene pa zato matematički daroviti učenici imaju povlašten status u školskoj hijerarhiji među ostalim učenicima. Istovremeno, taj status ostale učenike na određeni način čini inferiornijima zato što svaki od njih stvara sliku o sebi i svojim mogućnostima preko usporedbe s učenicima iz razrednog odjela (više u poglavlju 2.4.1.2). Sukladno istaknutom mjestu koje ima među nastavnim predmetima, matematika se suočava sa svekolikim uvriježenim mišljenjima o učenju matematike, matematičkim sadržajima te nastavnicima matematike. Uspjesi se u tom kontekstu poistovjećuju s urođenim sposobnostima, a neuspjesi se opravdavaju izostankom istih. Nastava matematike s time se svakodnevno suočava u školi i izvan nje. Naposljetku, taj pristup uglavnom implicira pitanje sposobnosti koje smatramo nužnim za svladavanje matematike te onih koje određuju darovite. Tu se nameće pitanje jesu li problemi koje učenici imaju pri učenju matematike nastali zbog nedostatka nekih sposobnosti te može li učenik prosječno razvijenih matematičkih sposobnosti uspješno studirati matematiku ili barem svladati srednjoškolsku matematiku? Ugledni ruski metodičar i matematičar Kolmogorov (prema Kurnik, 2001) tvrdi kako se često preuveličava potreba posebnih sposobnosti za učenje i razumijevanje matematike. Nadalje, tvrdi kako su prosječne ljudske sposobnosti potpuno dovoljne kako bi se uz dobro vođenje ili pomoću dobrih knjiga ne samo usvojila srednjoškolska matematika, nego i razumjele osnove diferencijalnog i integralnog računa (koji se najčešće navodi kao predstavnik uvoda u višu matematiku) kao i ostalih sadržajno zahtjevnijih matematičkih područja. S obzirom na to da djeci treba biti pružena potpora kako bi uz prisustvo afiniteta prema određenom području realizirali kognitivni potencijal, Devlin (2000) tvrdi kako većina ljudi zbog negativnih stavova, manjka potpore i brojnih drugih razloga nikad ni nije „okusila“ matematiku. Devlin u knjizi „Matematički gen“ tvrdi kako ljudski mozak razvija sposobnost usvajanja apstraktnih objekata usporedno s usvajanjem jezika kojim svatko vlada te tvrdi kako svi posjeduju sposobnost svladavanja matematike i matematičkih koncepata. Pokazuje se kako je problem darovitosti u nastavi matematike dio obrazovnog fenomena koji se zbog širine zastupljenosti u drugim odgojno-obrazovnim sustavima i različitim kulturama opravdano može tretirati kao društveni fenomen te mu je stoga nužno pristupati s aspekta odgojnih znanosti kako bismo dobili jasnije

razumijevanje prirode samog problema. Međutim, recentni problemi nastave matematike nedvojbeno govore kako se u teorijskim i praktičnim razmatranjima nedovoljno uvažavaju socijalne i afektivne dimenzije nastave matematike te okolinski čimbenici društva i škole. Pitanje sposobnosti koje učenici posjeduju samo je jedan aspekt njihova razvoja u matematici, a njihovi uspjesi su, među ostalim, značajno uvjetovani njihovim stavovima i uvjerenjima prema matematici, razinom samopouzdanja u učenju matematike, radnim navikama te mnogobrojnim okolinskim faktorima koje je potrebno suprotstaviti uvriježenim mišljenjima koji se vezuju za nastavu matematike. Stereotipi i predrasude o darovitosti i matematičkim sposobnostima ne uvažavaju postupnost izgradnje matematičkih znanja i vještina te uloženi trud i ostale pretpostavke koje uvjetuju njihov razvoj. Na primjer, u mnogim smo područjima ljudske djelatnosti skloni priznavati ustrajnost, iznimne napore i uloženi trud, a kod učenika koji su izvrsni u matematici i školi općenito uglavnom se ističu urođene sposobnosti i talent koji se prema tom uskogrudnom stavu očito razvija „sam od sebe“. S druge strane, daroviti učenici svjesni su uloženog truda i postupnosti izgradnje vještina i sposobnosti koje posjeduju pa stoga ne pripisuju svoj uspjeh vanjskim čimbenicima poput ostalih učenika (Vizek-Vidović i sur, 1996). Cijeli pristup darovitosti upućuje na potrebu za daljnjim istraživanjima o obiteljskoj i školskoj okolini, ali i na poticanje intrinzične motivacije potrebne za realizaciju visokih sposobnosti u određenom području. Longitudinalna istraživanja u području matematičke darovitosti pokazuju kako stimulacija kroz posebne obrazovne programe matematike i prirodnih znanosti dugoročno najviše pridonosi realizaciji visokih sposobnosti (Benbow i Arjmand, 1990).

Giesecke (1993), koji je izvorno istaknuo dotični problem, tvrdi kako darovitost i obrazovanost nisu nikakav prirodni, već su socio-kulturni fenomen te kako je za pedagogiju i odgojno-obrazovni sustav bitno pitanje prakse. Sukladno tome, pri razmatranju matematičkih sposobnosti, moramo polaziti od individualnosti učenika u svim njegovim posebnostima zato što stjecanje matematičkih znanja i vještina ne djeluje neovisno od ostalih karakteristika pojedinca te je stoga potrebno osvijestiti kako uspješnost u matematici nije „rezervirana“ samo za manji broj učenika, već kako svaki učenik prosječnih sposobnosti uz kontinuitet u radu i prikladnu odgojno-obrazovnu podršku može postati uspješan stručnjak u svakom području ljudskih djelatnosti u kojima se primjenjuju matematička znanja.

2.4. Socijalne i afektivne dimenzije matematičkog obrazovanja

U suvremenim razmatranjima nastave matematike neupitan je značaj društvenih i afektivnih dimenzija nastave matematike zbog čega je za didaktičko promišljanje nastave matematike suštinski izazov razumjeti kako društvo percipira matematiku te na koje se načine to reflektira na učenike, proces učenja i poučavanja matematike. Posljednjih se pedesetak godina učenici sve više promatraju kao socijalna bića koja se, pored kognitivnog aspekta, u svakodnevnom životu ponašaju i donose odluke na temelju vlastitih uvjerenja, emocija i stavova. Iako su brojna istraživanja pokazala kako je među ključnim čimbenicima za razvoj darovitosti podupiruća i poticajna odgojno-obrazovna okolina, u nastavi matematike darovitost se često percipira isključivo kroz prizmu kognitivnih sposobnosti i složenosti matematičkih sadržaja i koncepata. S druge strane, ukoliko je za realizaciju darovitosti potencijalno darovitih učenika potrebna posebna odgojno-obrazovna podrška, prirodno je pretpostaviti kako i za djecu prosječnih sposobnosti treba jednaka potpora, a isti su zbog često prisutnih pogrešnih uvjerenja u kontekstu nastave matematike stigmatizirani i slijedom toga osuđeni na neuspjeh. Škola i obitelj kao vanjski čimbenici imaju zadaću kod svakog učenika djelovati na motivaciju, ustrajnost, sustav vrijednosti, karakter i sl. Stoga učenicima treba pružiti one oblike i metode rada koji će, pored izazovnih sadržaja, osigurati razvoj komunikacijskih vještina, poticati suradničke odnose i vještine timskog rada te razvoj pozitivne slike o sebi.

Matematika je uz materinji i strani jezik od početka osnovnoškolskog obrazovanja dominantan i satnicom najzastupljeniji predmet te zbog jednako istaknutog položaja u suvremenim odgojno-obrazovnim reformama zaslužuje posebnu pažnju u sustavu primarnog obrazovanja. Matematičko područje ističe se svojim problemima već od početka osnovne škole zato što se pokazuje kako učenici na početku školovanja imaju pozitivne ili neutralne stavove i emocije prema matematici, a s godinama školovanja oni postaju sve negativniji (Lumsden, 1994; Ma i Kishor, 1997; Putney i Cass, 1998). Stavovi prema matematici prvotno su definirani kao tendencije učenika da ustraju ili izbjegavaju matematičke aktivnosti, uvjerenje učenika kako su uspješni ili neuspješni u matematici te vjerovanje o tome je li matematika korisna ili nepotrebna (Neale, 1969). To je kasnije rezultiralo modelom određenim s trima komponentama: emocionalni odgovor na matematiku, mjera u kojoj pojedinac razumije matematiku te ponašanje prema matematici (Hart, 1989).

Učenici pritom razvijaju negativne stavove, emocije i uvjerenja spram matematike kao predmeta te prema sebi i vlastitim potencijalima u matematici. Uz to se javljaju problemi sa samopouzdanjem i podcjenjivanjem sposobnosti za učenje matematike i srodnih predmeta,

najčešće iz prirodoslovnog područja. U predškolskoj i ranoj školskoj dobi formiraju se temelji za kasnije usvajanje matematike te se razvijaju tzv. predmatematičke vještine. One se odnose na sposobnosti procjenjivanja i vizualizacije, induktivno i deduktivno mišljenje i zaključivanje, prostorno orijentiranje, uspoređivanje po zadanim svojstvima, funkcionalno razumijevanje danih uputa i pravila. Uz roditelje koji trebaju osigurati poticajnu i obogaćenu okolinu, učitelji razredne nastave prvi su koji bi trebali potaknuti važne kognitivne procese zato što djeca u toj dobi trebaju svladati svekolika umijeća razmišljanja i učenja (Delors i sur., 1998), a da pritom nisu opterećeni nedostatkom samopouzdanja i podcjenjivanjem vlastitih sposobnost.

Također, u suvremenom odgojno-obrazovnom procesu bitna je uloga roditelja u kvalitetnoj suradnji s odgojno-obrazovnom institucijom radi stvaranja uvjeta za uspješno zadovoljenje djetetovih potreba, za uspješan cjelokupan djetetov razvoj u kojem se poštuju prava djeteta i stječe osjećaj sigurnosti (Ljubetić, 2011). Poznato je kako učenici stječu motivaciju iz odgojnih postupaka vlastite obitelji i škole te je pretpostavka kako neki od razloga problema u nastavi matematike proizlaze upravo iz njih. Najvažnija je struktura društva uopće, a tako i za uspješno učenje matematike, obitelj iz koje učenici preuzimaju sustav vrijednosti, stječu radne navike i motivaciju prema školi i obrazovanju. Stoga se razlozi poteškoća u školi i u nastavi matematike često mogu naći u obitelji u kojoj djeca odrastaju.

Mnoga su istraživanja pokazala kako uvjerenja o matematici učenici usvajaju kroz odgojne postupke roditelja (Dave, 1965; Hess i Holloway, 1985; Turner i sur., 2002). Naime, ista su istraživanja pokazala kako su karakteristike i obrazovanost obitelji povezane s njihovim stavovima prema akademskim postignućima što utječe na uspjehe učenika u školi. Naime, roditelji koji imaju negativan stav prema matematici, najčešće su i sami imali teškoće sa svladavanjem matematike te su se je bojali, a svoje su strahove i stavove (ne)svjesno prenosili na djecu.

S druge strane, roditelji natprosječnih sposobnosti i višeg socioekonomskog statusa mogu prenijeti sposobnosti na djecu genetski ili stvaranjem obogaćene okoline u čemu se pod obogaćenom okolinom podrazumijeva zanimljiv, raznolik i poticajan okoliš za dijete koje u njemu odrasta. Obogaćena okolina važna je i u unapređivanju normalnih stupnjeva razvoja, a osiromašena ih okolina usporava. Obogaćena okolina djetetu pruža izazove i podiže standarde njegove uspješnosti. Važna je roditeljska podrška i opskrbljivanje djeteta materijalima koje traži ili može iskoristiti. Snažnu ulogu ima i stupanj roditeljskog obrazovanja zato što obrazovani roditelji vrlo vjerojatno imaju mogućnosti i želje za osiguravanjem obogaćene okoline djetetu te bolje razumiju pretpostavke pri stvaranju iste.

Roditelji vrlo često stvaraju takvu okolinu kao odgovor na natprosječnu sposobnost svog

djeteta čime se vjerojatno potiče razvoj djetetovih sposobnosti. *Primjerice, roditelji pijanista su se gotovo uvijek i sami aktivno bavili glazbom, ili pasivno (odlazeći na koncerte i slušajući glazbu kod kuće), te su kod većine inicirali glazbenu poduku. Kod likovne umjetnosti roditelji uglavnom nisu bili sami umjetnici, ali polovica ih je posjećivala muzeje, a četvrtina je umjetnost smatrala vrijednom. Poruka koju su prenosili djeci bila je samoispunjenje, a ne dostignuća*. (Bloom, 1985, Weiner, 1985; prema Vizek-Vidović i sur., 1996). S druge strane, prosječnoj, ali i darovitoj djeci koja ne uspijevaju aktualizirati potencijale, roditelji uglavnom ne postavljaju visoke standarde.

Među recentnim razmatranjima u pedagogiji, afektivna strana odgojno-obrazovnog procesa pokazuje se kao jedna od najaktualnijih tema (Kolak i Majcen, 2011). Učenici se svakodnevno susreću s mnogim izazovnim i stresnim situacijama u školi i izvan nje, a kroz iskustva razvijaju i usvajaju različite emocije i uvjerenja prema svim subjektima odgojno-obrazovnog procesa**.** Kompetentnost učenika u matematici vrednujemo ispitivanjem stečenih znanja i vještina, ali pritom često zanemarujemo emocionalne reakcije i stavove učenika koji su često i uzrok i posljedica tih rezultata te nužni dio svakog vrednovanja učenika**.**

2.4.1 Emocionalne reakcije učenika u nastavi matematike

Naime, mnoga su istraživanja pokazala kako se za uspjeh u matematici značajnim pokazuju upravo njihovi stavovi prema matematici, razina samopouzdanja u učenju matematike i radne navike. Emocije se javljaju kao osobna reakcija na neku životnu situaciju pa se stoga umjesto emocija često koristi termin „emocionalna reakcija“ (Milivojević, 2007). Kolak (2014) dijeli emocionalne reakcije u nastavi na one koje su usmjerene prema subjektima školskog i nastavnog procesa (učenici, nastavnici, roditelji), na emocionalne reakcije među učenicima te na emocionalne reakcije vezane uz nastavni proces. Uz emocionalne reakcije također se koristi termin „akademske emocije“ koje se odnose na emocije usko vezane uz nastavni proces, odnosno na učenje, poučavanje i učenička postignuća (Pekrun 2006). U nastavi matematike iste se očituju kroz emocije koje učenik povezuje s matematikom, njegova uvjerenja o matematici te kroz cjelokupan odnos učenika prema matematici. Među njima je bitno izdvojiti emocionalne reakcije vezane uz nastavno ozračje, odnos nastavnika i učenika, opće emocionalno stanje učenika te one koje direktno utječu ili su rezultat procesa učenja i poučavanja.

Emocije koje se javljaju u nastavi su: anksioznost, strah, dosada, sramežljivost, (ne)zadovoljstvo, radoznalost, opuštenost, trema, zabrinutost, ljutnja, tuga, samopoštovanje, samopouzdanje, bezbrižnost, uzbuđenje, interes, ponos itd. Od mnogobrojnih emocija koje

učenici pokazuju u nastavi, često se dominantnom pokazuje emocija dosade (Kolak i Majcen, 2011). Međutim, u nastavi matematike prevladava strah od matematike što se u stranoj literaturi najčešće navodi kao „matematička anksioznost" (eng. *math anxiety*) (Geist, 2010; Sloan, 2010). Strah od matematike (više u poglavlju 2.4.1.1) po svom određenju pripada akademskim emocijama te se pokazuje kao jedna od glavnih prepreka uspjeha u matematici. Naime, emocije i uvjerenja koje pojedinci imaju prema matematici utječu na njihovu motivaciju zbog čega izbjegavaju samostalno učenje matematike. Mandler (1989) ističe kako su negativni stavovi rezultat ponavljanih neuspjeha u radu, a pripadne emocionalne reakcije postaju trajni obrasci njihova ponašanja *u* i *prema* nastavi matematike. S druge strane, kod uspješnijih učenika samopouzdanje i osjećaj vlastite vrijednosti rastu svakim uspjehom te se uzajamno podupiru i jačaju. U literaturi (npr. Koshy i sur., 2009) se zato sve češće spominje ciklus uspješnosti razvoja matematičkih sposobnosti.

Nastavni proces ispunjen je emocionalnim reakcijama učenika i nastavnika te se zbog raširenosti i specifičnosti problema nastave matematike iste moraju ozbiljnije razmatrati u svakom planiranju nastave. Prema smjernicama suvremene pedagogije, uvažava se individualnost djeteta i njegovo socijalno biće pri čemu se polazi od škole kao društvenog bića (Previšić, 1999). Emocije, stavovi i uvjerenja imaju primarnu ulogu u motivaciji učenika što je i jedna od temeljnih pretpostavki školskog uspjeha pa tako i uspjeha u matematici. Međutim, teorijske se spoznaje o emocijama u nastavi matematike nedovoljno primjenjuju te nisu dovoljno zastupljene u sustavu obrazovanja nastavnika matematike, kao ni u praktičnim i/ili refleksivnim promišljanjima. S obzirom na zastupljenost problema nastave matematike, među socijalnim i afektivnim dimenzijama nastave neki autori tvrde kako didaktika matematike pripada društvenim znanostima (npr. Straesser, 2007) što je i jedno od otvorenih problema pedagogije po pitanju kompetentencija nastavnika te načina i sadržaja njihova obrazovanja. Proučavanje emocija, stavova i uvjerenja o matematici treba biti usmjereno na razumijevanje „akademskoga ponašanja" učenika na satovima matematike, a za to su potrebna znanja o stavovima i uvjerenjima učenika kako bi iste mogli ugraditi u načine poučavanja matematike.

Polazište je pritom kako metode poučavanja mogu izravno, pa i neizravno, utjecati na učeničke stavove i uvjerenja o matematici te na odgovarajuće emocionalne reakcije. Autori na tom području većinom odvojeno proučavaju kognitivne, motivacijske ili emocionalne varijable, a kada je riječ o stavovima i uvjerenjima o matematici, najčešće se odvojeno istražuju specifične kategorije stavova i uvjerenja. Među školskim čimbenicima, Eynde i De Corte (2003) istraživanjem su pokazali kako sustav stavova i uvjerenja o matematici čine četiri faktora: uloga i postupci nastavnika matematike, važnost matematike i sposobnost za njezino svladavanje,

matematika kao društvena aktivnost i matematika kao područje uspjeha. Naime, nastavni proces prožet je emocijama koje su u konstantnom međudjelovanju s procesom vrednovanja učenika i nizom metoda nastavnika. Nastavnik se pritom mora pobrinuti kako ne bi došlo do neželjenih emocija podupirući učenike u (ne)uspjesima, a kako bi oni stekli i/ili razvili pozitivan odnos prema matematičkim sadržajima te, u konačnici, prema vlastitim sposobnostima i sebi samima.

Zbog raširenosti negativne percepcije matematike, nastavnik mora kod učenika razviti samopouzdanje i povjerenje u vlastite matematičke sposobnosti. Kako bi to postigli, nastavnici moraju kod učenika razviti samopoštovanje, osjećaj vlastite vrijednosti te odgovornost za vlastiti uspjeh. Prema tome, nastavni proces mora biti utemeljen na svekolikim posebnostima učenika poput: razine stečenih znanja i vještina, usvojenih odgojnih vrijednosti, motivacije za predmet, emocijama, stavovima i uvjerenjima u kontekstu matematike i škole općenito te na poznavanju cjelokupne školske, društvene i obiteljske okoline. U tim intencijama bitno je uskladiti intelektualne i emocionalne aspekte učenika u nastavi matematike. Naime, bitno je da nastavnik razumije načine stjecanja znanja i razvijanja matematičkih sposobnosti i vještina, ali i da jednako pridaje značaj emocionalnim doživljajima kako bi lakše regulirao odnos učenika prema nastavi matematike, njegovu percepciju o samoefikasnosti te, u konačnici, njegovu motivaciju i stupanj aktivnosti u nastavnom procesu.

Kako bi nastavnik upravljao kompetencijama učenika, mora i sam ovladati metodom emocionalne metakompetencije (Kolak i Majcen, 2011) čime bi ostvario razredno ozračje u kojem će se njegovati pozitivan odnos učenika prema nastavnim aktivnostima. Učenici u nastavi imaju relativno trajne i specifične oblike ponašanja, oblike međuodnosa, odnos prema učenju i sudjelovanju u nastavnim aktivnostima, način komuniciranja među sobom te socijalnu interakciju s učiteljima (Jurčić, 2012). Prema tome, Jurčić navodi kako sveukupnost života i rada nastavnika i učitelja čini njihovo razredno ozračje. Sve emocije koje se javljaju tijekom nastavnog procesa, uključujući emocionalno stanje učenika, odnos nastavnika i učenika te učenika međusobno, dio su razrednog ozračja. U okviru razrednog ozračja u nastavi matematike važnim se pokazuje ukupno emocionalno stanje sudionika odgojno-obrazovnog procesa čime Bognar i Dubovički (2012) određuju emocionalnu klimu. Uz motivaciju prema nastavnim aktivnostima, razredno ozračje temeljni je čimbenik mentalnog, afektivnog i socijalnog razvoja učenika u nastavi.

Elemente koji određuju razredno ozračje možemo podijeliti u četiri skupine (Jurčić, 2012):

- učiteljeva potpora
- (pre)opterećenje učenika nastavom
- razredna kohezija
- strah od školskog neuspjeha.

Elementi razrednog ozračja djeluju pojedinačno, ali međudjelovanjem utječu na ishode učenja i poučavanja. Jurčić pritom (2012) kao determinante razrednog ozračja navodi: učiteljevu potporu, (pre)opterećenje učenika nastavom, razrednu koheziju i strah od školskog neuspjeha.

Emocije koje učenici doživljavaju u okviru nastave matematike ukazuju na to kako je na emocije učenika potrebno gledati kao aspekt učenja i poučavanja koji je jednako važan kao i kognitivni aspekt nastavnog procesa. Štoviše, prema zastupljenosti i učinku emocija na nastavu matematike, može se kazati kako su afektivne dimenzije nastave nadređene kognitivnima budući da uvjetuju rad i motivaciju učenika te su stoga među temeljnim pretpostavkama uspješne nastave.

2.4.1.1 Strah od matematike i matematička anksioznost

Društvo često ima predrasude prema matematici koju percipira kao logičnu, apsolutističku, rigidnu, hladnu, objektivnu, nehumanu i apstraktnu znanost (Andrews, Rowland, Brindley i ostali, 2014). Uvažavajući poteškoće koje učenici imaju u nastavi matematike i druge specifičnosti u matematičkom obrazovanju, pokazuje se kako emocije ponekad imaju i presudnu ulogu u uspjehu iz matematike.

Tu se ističe strah od matematike koji po svom određenju pripada akademskim emocijama te se definira kao osjećaj napetosti i anksioznosti koji otežava manipulaciju brojevima i rješavanje matematičkih problema u svakodnevnim i školskim situacijama (Richardson i Suinn, 1972). Kod mnogih se učenika strah od matematike javlja kao posljedica početnih neuspjeha u razumijevanju matematičkih pojmova što se po redoslijedu sadržaja osnovne škole primarno odnosi na aritmetiku. Aschraft (2002) navodi kako u nekim slučajevima razlika u postignućima učenika u matematici ne nastaje zbog nedostatka sposobnosti i potencijala, već upravo zbog straha od matematike i različitih emocija učenika u nastavi.

Wigfield i Meece (1988) razlikuju kognitivnu i afektivnu komponentu straha od matematike. Afektivna komponenta odnosi se na negativne afektivne reakcije prema

matematici, kao što su nervoza, strah i nelagoda. Kognitivna komponenta odnosi se na zabrinutost za uradak i uspjeh u matematici. Matijević (2005) prema tome tvrdi kako bi se budući učitelji trebali pripremati za *funkcije dijagnostičara, realizatora, evaluatora i terapeuta, u pedagoškom smislu. Samo tako pripremani i osposobljeni učitelji i nastavnici moći će upravljati i regulirati složenim procesima kakvi su odgoj i obrazovanje tijekom školovanja*. Istraživanja o emocijama u nastavi matematike ukazuju kako bi razredno ozračje u nastavi matematike trebalo biti na vrhu prioriteta u predmetnom kurikulumu nastave matematike, a kompetencije nastavnika trebale bi biti više usmjerene na uočavanje emocionalnih stanja i reakcija učenika što bi se u kontekstu straha od matematike trebalo realizirati dijagnostičkim i terapeutskim djelovanjem prema učenicima koji imaju teškoće u afektivnoj domeni.

Neki autori stoga određuju „kurikulum protiv anksioznosti“ za nastavu matematike kojim bi se suzbile negativne emocionalne reakcije učenika (Geist, 2010). U tim nastojanjima, didaktičko-metodičke odrednice nastave matematike trebale bi sadržavati poticajno i ohrabrujuće razredno ozračje koje se temelji na individualnostima učenika te zahtjevima i poteškoćama s kojima se susreću u nastavi. Cilj kurikuluma protiv anksioznosti upravo je u tome da dovede učenike do ciklusa uspješnosti razvoja matematičkih vještina i znanja (Koshy i ostali, 2009). Upravo u kontekstu kurikuluma protiv anksioznosti pokazuje se potreba za nastavnikom koji ima ulogu svojevrsnog terapeuta koji zna kako će negativna uvjerenja i stavove učenika prema matematici usmjeriti prema uspješnosti, odnosno prema aktivnostima učenika koja neće biti ograničena nedostatcima u afektivnom području.

Bitno je pritom da učenik kroz nastavne aktivnosti na djelu osvjesti kako je upravo on u središtu nastave te da shvati kako nastavni proces ne ispunjava svoju svrhu ukoliko učenik ne sudjeluje aktivno u nastavi. Kako bismo to postigli u nastavi, nije dovoljno samo postavljati pitanja, bilo ona heuristička ili problemska, već se mora osigurati jedno poticajno ozračje prožeto uspjesima, pohvalama, empatijom, savjetima i potporom kako bismo kod učenika potaknuli komponente intrinzične i ekstrinzične motivacije

Emocije i uvjerenja koje pojedinci imaju prema matematici utječu na njihovu motivaciju zbog čega izbjegavaju samostalno učenje matematike. Istraživanja pokazuju kako stavovi i uvjerenja o matematici, o njezinu učenju i o rješavanju matematičkih zadataka utječu na to kako učenici pristupaju matematičkim zadatcima te koje tehnike i strategije rabe u njihovu rješavanju (npr. Lester, Garofalo i Kroll, 1989). Osim toga, pokazalo se kako su stavovi i uvjerenja o matematici povezani i s motivacijskim procesima, tj. sa željom za učenje matematike što nadalje utječe i na uspjeh u tom predmetu (npr. Kloostermann, 1996). Zbog toga u matematici, kao i u svakoj aktivnosti, samopouzdanje i osjećaj vlastite vrijednosti rastu svakim uspjehom

te se uzajamno podupiru i jačaju daljnjom aktivnošću. Prema tome je koncipiran model *ciklusa uspješnosti* razvoja matematičkih sposobnosti (Koshy i sur., 2009). Taj se ciklus sastoji od tri ključne komponente:

- samopouzdanje prema vlastitim sposobnostima, pozitivna uvjerenja o matematici
- trud, upornost i zahtjevi za izazovnim zadatcima
- postignuće i uspjeh u matematici.

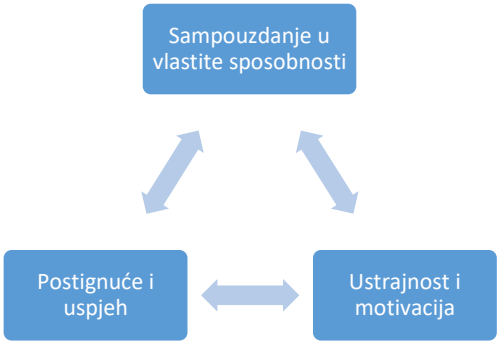

Slika 1. (Koshy i sur., 2009)

Te komponente ciklički su povezane te su u konstantnom međudjelovanju s nastavnim procesom i odgovarajućim emocijama učenika. Nasuprot tome, Preis i Biggs (2001) opisuju ciklus matematičke anksioznosti kao svojevrsni „negativ“ ciklusa uspješnosti. U tom ciklusu neugodne emocije utječu na smanjenu motivaciju učenika i izostanak samostalnog učenja matematike. Te emocije i uvjerenja o matematici povezani su s nedostatkom samopouzdanja i osjećajem nekompetentnosti zbog čega mnogi, objektivno sposobni učenici, izbjegavaju teške zadatke, ulažu malo napora te lako odustaju kada se suoče s poteškoćama (Hembree, 1990; Sheffield i Hunt, 2007).

Bezinović (1988) je u okviru svog rada na području validacije konstrukta percepcije osobne kompetentnosti razvio tri ljestvice koje predstavljaju tri aspekta percepcije osobne kompetentnosti. U faktorskim analizama ljestvice koje predstavljaju tri konstrukta izdvajaju se kao zasebni faktori: faktor generalizirane samoefikasnosti, faktor percipirane nekompetentnosti i faktor ustrajnosti. Bezinovićeva istraživanja (1988) pokazala su kako je percepcija osobne kompetentnosti (definirana ljestvicom percipirane nekompetentnosti) okosnica globalnog samopoštovanja (definiranog Rosenbergovom ljestvicom). Postoje dva osnovna modela koja predlažu objašnjenje kauzalnog odnosa percepcije samoefikasnosti i postignuća. Model „samojačanja“ bazira se na pretpostavci kako samoefikasnost utječe na školsko postignuće.

Cilj je tog modela poboljšati školsko postignuće preko razvijanja i povećavanja uvjerenja u osobnu efikasnost. Suprotno tome, model „razvoja vještina“ polazi od pretpostavke

kako školsko postignuće utječe na percepciju osobne efikasnosti. Prema tom modelu, uvjerenje u visoku samoefikasnost razvija se vježbanjem i usavršavanjem konkretnih vještina i sposobnosti određene struke ili profesije. Stoga se u planiranje nastave matematike moraju uključiti sve emocije koje se javljaju tijekom nastavnog procesa, uključujući emocionalno stanje učenika, odnos nastavnika i učenika, odnos učenika prema predmetu, odnos prema učenju i sudjelovanju u nastavnim aktivnostima i sl. Bitno je pritom uočiti koje su komponente intrinzične i ekstrinzične motivacije prisutne kod učenika u kontekstu nastave matematike.

Cilj je pritom postići poticajnu radnu okolinu u kojoj nastavnik vodi računa o emocionalnom stanju učenika, naročito u kontekstu akademskih emocija i odnosa između učenika u razredu. To bi trebao biti sastavni dio svakog sata u kojem bi se diskutiralo o načinima razmišljanja i sposobnostima potrebnim za određene zadatke i matematiku općenito, kao i načinima na koji svaki učenik može postići bolje rezultate te kako i koliko uspješniji učenici rade i uče matematiku. Težnjom prema tome, nastava matematike postat će dostupnija svakom učeniku, a njihove obrazovne perspektive trebale bi biti u skladu s njihovim kapacitetima.

Kako bi se kod slabijih učenika razvilo samopouzdanje i potaknula motivacija za učenje matematike, nastavnici moraju imati izniman autoritet i povjerenje učenika u procesu učenja i poučavanja. Autoritet nastavnika možemo gledati kao odraz međudjelovanja svih njegovih kompetencija u njegovu radu, ali i kao sastavni dio njegova odgojno-obrazovnog rada kao produkta tih kompetencija. Pritom je važno nastavničko poimanje autoriteta i optimalno razredno ozračje kako bi se odredila optimalna mjera vladanja nastavnim procesom u vidu nastavnih sadržaja (prilagoditi interesima i sposobnostima učenicima tako da samostalni rad učenika bude u idealnom omjeru s aktivnostima koje frontalno vodi nastavnik) te u profesionalnom autoritetu utemeljenom na kvalitetama suvremene škole. Za nastavnika je pritom bitno da izgradi zdravi autoritet koji se temelji na uzajamnom poštovanju, iskrenoj komunikaciji i razumijevanju te potpori u učeničkim aktivnostima.

Što se tiče kurikuluma protiv anksioznosti, on bi trebao biti individualiziran te bi se trebao realizirati kroz dopunsku, odnosno dodatnu nastavu kao nadopunu na ustanovljene teškoće koje učenik ima u učenju matematike. S obzirom na navedenomo, možemo kazati kako se nastava matematike suočava s problemom „učiti kako učiti“, ali se kao veći izazov pokazuje suočavanje s pitanjem „mogu li naučiti?“. No, kako bismo to postigli, predstoji nam riješiti dva problema: *problem uspjeha* i *problem usporedbe* (Horvat, 2016) među učenicima.

2.4.1.2 Odnosi među učenicima i percepcija akademske samoefikasnosti

Tema darovitosti i obrazovanosti na sebi je svojstven način dio razrednog ozračja svake učionice te je stoga dotična problematika izazov koji bi trebao biti okosnica didaktičkog pristupa nastavi matematike. Učenici prosječnog, ali i oni iznadprosječnog znanja matematike i ostalih predmeta iz STEM područja, često ne žele upisivati fakultete kojima su ta predmetna područja dominantna u nastavnom planu i programu (Chipman i sur. 1992; Aschraft, 2002).

Teorija o razrednom odjelu kao referentnoj točki percepcije akademske samoefikasnosti među učenicima ustranoj literaturi poznato je pod nazivom BFLPE (*Big Fish Little Pond Effect*) što se odnosi na pojedinca koji je postigao značajan rezultat i/ili status, ali u maloj i relativno (ne)važnoj grupi, organizaciji te slijedom toga ima utjecaj na ostale pojedince (Marsh, 1987). Pretpostavke kojima se vode istraživači u dokazivanju i istraživanju ovog fenomena polaze od činjenice kako učenici uspoređuju svoja postignuća s vršnjacima te isto ugrađuju u vlastiti sustav vrijednosti i percepciju vlastite kompetentnosti što dugoročno određuje njihovu motivaciju i odluke vezane uz njihovo obrazovanje (Cambria i sur., 2017). Sukladno tome se smatra kako uspješni vršnjaci mogu imati negativan utjecaj na percepciju akademske samoefikasnosti i druge čimbenike očekivanog uspjeha učenika koji su u istom razrednom odjelu. Cvrtila (1996) je utvrdila postojanje povezanosti procjena samoefikasnosti u matematici s ocjenama iz matematike, odnosno kako uspješniji učenici imaju viša očekivanja osobne efikasnosti te su ustrajniji i uspješniji u učenju, a to povratno utječe na očekivanja koja od njih imaju nastavnici što dodatno pospješuje proces njihova razvoja. Sintezom navedenog može se pretpostaviti kako postoji teorijski okvir i potreba za istraživanjem BFLPE efekta čije je polazište kako je razredni odjel referentna točka sustava vrijednosti u nastavi matematike. Bitno je napomenuti kako navedeni učenici boljeg uspjeha ne trebaju nužno biti u kategoriji darovitih, ali zbog dinamike rada i specifičnosti nastave matematike imaju značajan utjecaj na motivacijske procese ostalih učenika.

Spomenuti autori, eksperimentom u longitudinalnom istraživanju, dokazali su kako učitelji i nastavnici mogu bitno utjecati na obrazovne aspiracije i školski uspjeh učenika ukoliko za njih smatraju kako imaju potencijala neovisno o njihovim realnim kapacitetima. Naime, u matematici se isto očituje u odnosima učenika u kontekstu njihove uspješnosti što se zajedno s interpersonalnim odnosima i ozračjem unutar razrednog odjela pokazuju među dominantnim čimbenicima motivacije, a stoga i pretpostavkom uspjeha svakog učenika (shema 1).

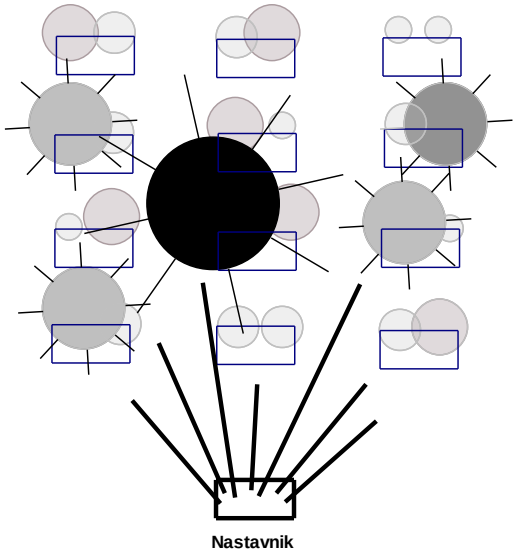

Slika 2. - *prikaz pažnje nastavnika i odnosa među učenicima u razrednom odjelu*

Svaki krug na shematskom prikazu sa slike 2 (Horvat, 2018) predstavlja jednog učenika, a veličina i boja kruga odnose se na pojedini ciklus uspješnosti svakog učenika (Koshy i sur. 2009) ili na matematičku anksioznost (*veći i tamniji krugovi odnose se na uspješnije učenike, manji i svjetliji krugovi na učenike slabijeg uspjeha povezanih s anksioznošću*). Svaki krug predstavlja ciklus pojedinog učenika opisan shematskim prikazom (slika 3).

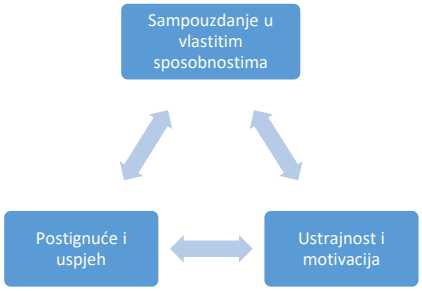

Slika 3. (prema Koshy i sur., 2009)

Na shematskom prikazu (slika 2) nalazi se „tipična“ učionica s učenicima koji su temeljem dosadašnjeg rada u nastavi i obrazovanju općenito formirali vlastiti ciklus (ne)uspješnosti (slika 3) i stekli uvažavanje nastavnika, ali i viša očekivanja nastavnika u vidu postignutih standarda. Zrake koje se šire iz tamnijih i većih krugova na slici 2 odnose se na utjecaj(nost), odnosno BFLPE utjecaj uspješnijih učenika koji svojom superiornošću utječu na manje uspješne te im onemogućuju povoljne motivacijske aspekte i razvoj samopouzdanja kao i ukupnog akademskog samopoimanja.

Tako uspješniji učenici imaju značajnu prednost pred ostalim učenicima u vidu kontinuiranog praćenja od strane nastavnika bilo tijekom davanja odgovora, tijekom obrade novih sadržaja ili u samom očekivanju da učenici da prate nastavu. Takva interakcija od strane nastavnika njima stvara obvezu sudjelovanja u vidu istinskog pedagoškog kontakta i odnosa koji s ostalim učenicima nije zapravo uspostavljen zato što su se oni poistovjetili s neuspjehom zbog čega nastavnik ni nema značajnijih očekivanja od njih. Naime, slabiji učenici uglavnom mogu riješiti jedino jednostavnije zadatke te su svjesni napora koji su u to uložili i toga kako ostali učenici to rade znatno bolje s manje uloženog truda. Samim time, riješeni zadatci ne mogu dati toliko zadovoljstvo manje uspješnim učenicima zato što postignuće nema objektivnu težinu kao kod boljih učenika koji znaju (i vjeruju) da mogu riješiti zadatke koje većina ne može. Pohvale te niz poticajnih metoda nastavnika usmjerenih na daljnji napredak učenika pritom se suočavaju s objektivnom slikom razreda u kojoj svaki učenik jasno zna koliko je dobar u matematici u usporedbi s ostalim učenicima u razredu. S obzirom na to da visoko postavljena očekivanja nastavnika mogu značajno utjecati na uspjeh i samopoimanje učenika, refleksijom vlastita rada moramo se pitati kolike potencijale učenika nismo otkrili i/ili potakli kako bi se razvijali te jesu li trenutno istaknuti učenici u razredu mogli biti neki drugi, pod pretpostavkom drugačijih okolnosti nastavnog procesa.

2.5. Kompetencije nastavnika

Usmjerenost prema kompetencijama temeljna je značajka društva znanja kojom će se udovoljiti potrebe pojedinca u svim područjima njegova života. Kompetentnost predstavlja priznatu stručnost i sposobnost kojom netko raspolaže te se odnosi na djelokrug prava odlučivanja jedne osobe ili ustanove te mjerodavnost i nadležnost (Anić i Goldstein, 2004). Prema Eurydice Izvješću Europske komisije (2012), kompetencije općenito predstavljaju kombinaciju znanja, vještina i stavova koji su potrebni za osobno ispunjenje i razvoj, aktivno građanstvo, socijalnu uključenost i zapošljavanje. *Kompetencije su kognitivne sposobnosti i vještine kojima pojedinci raspolažu ili ih mogu naučiti kako bi riješili određene probleme, kao i s tim povezane motivacijske, voluntativne i društvene spremnosti i sposobnosti, kako bi se rješenja problema mogla uspješno i odgovorno rabiti u promjenjivim situacijama* (Weinert, 2001, 27/8). U kontekstu nastavničke profesije kompetencije se najčešće navode kao kombinacija znanja, vještina, stavova i sustava vrijednosti koje omogućuju nastavniku osigurati kontinuirani razvoj učenika u njegovim intelektualnim, radnim, moralnim i estetskim dimenzijama ličnosti.

Masterpasqua (1991) ističe kako su kompetencije s jedne strane fokusirane na osobne karakteristike (znanja, vještine i stavove) koje vode do prilagodbe okruženju ili kao naučeni stavovi i sklonosti koje su korištenjem socijalnih i spoznajnih vještina vidljive kao sposobnosti suočavanja i rješavanja životnih problema, a s druge strane navodi kompetencije koje naglašavaju emocionalnu i motivacijsku važnost ocjenjivanja pojedinca i očekivanja od njihovih sposobnosti prilagodbe (prema Kostović-Vranješ i Ljubetić, 2008).

Promjene u suvremenom društvu zahtjevaju sve širi raspon kompetencija kako bi učitelji bili spremni na predstojeće izazove. Odgojno-obrazovna politika primarno mora odgovoriti suvremenim obrazovanjem učitelja koje će biti utemeljeno na znanstvenoteorijskim dostignućima odgojnih i obrazovnih znanosti. Neka dominantna područja primjene novog načina izobrazbe, osposobljavanja i stručnog usavršavanja učitelja zajednička su bez obzira na specifičnosti obrazovnih politika:

- povijesni i tradicionalni razvoj izobrazbe učiteljstva
- kulturne i političke perspektive poučavanja i učenja
- stupanj profesionalne autonomije
- kurikulumske promjene: selekcija, ustroj učiteljskih studija i proširene profesionalne kompetencije učitelja, posebno interkuturalne.
  (Alexander, 2000; prema Hrvatić i Piršl, 2007)

S obzirom na to da u pedagoškoj literaturi postoji velika različitost u terminološkom shvaćanju koncepta kompetencija, pokazuje se kako se pri određenju kompetencija najčešće navode:

- osobne značajke: znanja, vještine, stavovi i crte ličnosti
- odnose se na intervencije koje pogoduju uspjesima, odnosno moraju biti u funkciji napretka učenika
- njima se postižu rezultati u različitim dimenzijama
- kompetencije nisu stabilne ni stalne karakteristike
- one su prenosive i primjenjive u svakoj aktivnosti i sektoru
- mogu se usvojiti i razvijati različitim programima i aktivnostima. (Ferrandez-Berrueco i Sanchez-Tarazaga, 2014).

Od nešto užih određenja unutar nastavnog procesa Kyriacou (2001) navodi temeljna nastavna umijeća potrebna za uspješan rad u razredu te ih dijeli na:

- planiranje i priprema nastave
- izvedba nastavnog sata
- vođenje i tijek nastavnog sata
- ugođaj u razredu, disciplina
- ocjenjivanje učeničkog napretka te samoanaliza i prosudba vlastita rada.

Slično navodi i Perrenoud (2004) te ističe deset kompetencija koje bi nastavnici trebali posjedovati od kojih je konkretizirao one koje su direktno na djelu u nastavnom procesu:

- organizacija poticajnog okruženja za učenje
- upravljanje napretkom u učenju
- razvoj sredstava diferencijacije
- uključivanje učenika u učenje i rad
- rad u timu
- participacija u školskom menadžmentu
- suradnja s roditeljima; korištenje novih tehnologija
- kritičnost prema etičkim dilemama i zahtjevima struke
- profesionalni razvoj i usavršavanje.

Perrenoud (2002) ističe kako je kompetentnost sposobnost učinkovitog djelovanja u brojnim situacijama koja se temelji na stečenom znanju, ali nije ograničena tim znanjem. S obzirom na složenost koncepta kompetencija i njihova odnosa s praksom učenja i poučavanja, u razmatranju temeljnih pretpostavki kvalitetnog obrazovanja nužno je kritički pristupiti pitanju načina i sadržaja osposobljavanja nastavnika. Studija *Green Paper*, utemeljena na istraživanju skupine nazvane *Thematic Network on Teacher Education in Europe* (TNTEE), iznijela je sljedeće predmete rasprave u svrhu poboljšanja kvalitete obrazovanja nastavnika (Buchberger i sur., 2000: 6):

- politika obrazovanja nastavnika
- partnerstvo između obrazovanja nastavnika i škola
- refleksivna praksa u obrazovanju nastavnika
- osiguravanje plodnog okruženja za učenje unutar obrazovanja nastavnika
- didaktika kao znanost nastavničke profesije

- multikulturalizam i obrazovanje nastavnika
- rodna problematika i obrazovanje nastavnika.

Navedena studija rezultat je holističkog pristupa obrazovanju iako je ciljani fokus isključivo na obrazovanju nastavnika u kojem su izdvojena ključna područja, aspekti i dimenzije obrazovanja nastavnika koje bi nadalje trebale omogućiti iskorak prema realizaciji ključnih kompetencija koje tražimo od suvremenih nastavnika.

U turskom obrazovnom sustavu kao dio projekta SBEP (*Support to Basic Education project*) proces reforme, koji su godinama pripremali financiranog od strane Europske unije, kao cilj je imao dati odgovor na pitanje „kakvo bi trebalo biti kvalitetno obrazovanje u 21. stoljeću te koje su kvalitete suvremenog nastavnika i učitelja“. U reformi su sudjelovali stručnjaci sa svih razina i institucija odgojno-obrazovnog sustava: znanstvenici, sveučilišni profesori, prosvjetne inspekcije te učitelji i nastavnici (ukupno oko 3000 sudionika). Nakon niza aktivnosti koje su bile ostvarene kroz radionice, seminare, projekte, istraživanja te analize kurikularnih dokumenata diljem svijeta, cijeli proces rezultirao je sljedećim područjima kompetentnosti nastavnika (SBEP, 2006):

1. Osobne i profesionalne vrijednosti - profesionalni razvoj
2. Znanje o učenicima
3. Znanje o procesu učenja i poučavanja
4. Vrednovanje, praćenje i evaluacija učenja i razvoja učenika
5. Suradnja obitelji i škole te socijalno okružje nastavnika
6. Znanje o kurikulumu.

Iz recentne literature razvidno je kako nastavnička profesija podrazumijeva multidisciplinarno obrazovanje zato što u sebi sadrži opće, predmetno i pedagoško znanje te razumijevanje višeslojnosti aspekata suvremenog obrazovanja. Među mnogim zahtjevima koji predstoje nastavnicima sve se češće spominje napuštanje tradicionalne uloge nastavnika koji se suočavaju s činjenicom kako je njihova dosadašnja uloga temeljena na prenošenju znanja nedovoljna u ostvarivanju ciljeva suvremenog odgoja i obrazovanja (Ferrandez-Berrueco i Sanchez-Tarazaga, 2014). Težište se pritom mora preusmjeriti s poučavanja na učenje, primjenu suvremenih tehnologija, osposobljenost za rad s različitim učenicima, suradnju s drugim učenicima, sposobnost refleksije i evaluacije svog rada. Prema tome, suvremeni učitelj mora biti odgojitelj, medijator i socijalni integrator, a njegovo djelovanje usmjereno je na pomaganje učeniku uz dogovaranje, organiziranje, poticanje, savjetovanje i ohrabrivanje

(Previšić, 2003, str. 267). Dakle, koncept cjeloživotnog učenja premješta prioritet odgojno-obrazovnog procesa s nastavnika i učitelja na učenika, a proces učenja usmjeren je na učenika i njegove individualne sposobnosti, stečena znanja, vještine i odgojne vrijednosti.

Konceptom cjeloživotnog učenja trebali bismo ostvariti temeljne preduvjete za obrazovni sustav i sustav stručnog osposobljavanja, odnosno profesionalnog razvoja nastavničkog kadra. Budući da su temeljna polazišta cjeloživotnog učenja kompetencije nastavnika te učenik kao središnji subjekt čiji je razvoj svrha svih odgojno-obrazovnih procesa, nameće se pitanje i određenje pedagoških kompetencija nastavnika. S obzirom na specifičnosti nastave matematike koji su u domeni pedagoške teorije i prakse, također se pokazuje potreba za određenjem pedagoških kompetencija u kontekstu nastave matematike. Početna točka mora biti u pedagogiji kao znanosti o odgoju koja polazi od formiranja učenikove osobnosti prema aktualizaciji potencijala i mogućnosti realizacije samoodređenja i samoostvarenja. U kontekstu nastavnih predmeta moralno zrela sposobnost djelovanja kao samoodređenje moguća je samo ako nastavnik/učitelj raspolaže poznavanjem predmeta i predmetnom kompetencijom kao sposobnošću društvenog odlučivanja i društvenom kompetencijom (Roth, 1971). Odgojem u nastavi moraju se izgraditi pozitivne osobine ličnosti, stavovi i uvjerenja te karakterne i moralne, radne i društvene vrijednosti. Pod odgojem se pritom smatra proces svjesnog formiranja učenikove osobnosti s njegovim individualnim, socijalnim i razvojnim posebnostima, duhovnim potrebama, obiteljskim i društvenim dužnostima.

Katz i McClellan (1999) ističu pedagoški kompetentnog nastavnika kao stručnjaka koji može iskoristiti poticaje iz svog okruženja i vlastitih kapaciteta kako bi postigao dobre razvojne rezultate. Drugim riječima, to je nastavnik koji sebe doživljava kao osobu koja ima kontrolu nad svojim pedagoškim djelovanjem u odnosu s učenicima i roditeljima te se dobro osjeća u svojoj učiteljskoj ulozi (Kostović-Vranješ i Ljubetić, 2008; prema Milanović, 2000). U tom određenju pedagoške kompetentnosti ističu se tri osnovna elementa: „doživljaj kontrole“, „odnos“ te „dobar osjećaj“. Doživljaj kontrole odnosi se na kontrolu nad sobom i svojim ponašanjem te kontrolu nad odgojno-obrazovnim procesom u smislu planiranja, biranja djelotvornih ponašanja, prevenciji i rješavanju konflikata, preuzimanju odgovornosti za vlastiti rad te stvaralački pristupati ostvarivanju odgojno-obrazovnih zadaća i unapređivanju svojih znanja, vještina i sposobnosti (Kostović-Vranješ i Ljubetić, 2008).

Jurčić (2012) navodi kako su pedagoške kompetencije suvremenog nastavnika: osobna, predmetna, komunikacijska, didaktičko-metodička, refleksivna, socijalna, emocionalna, interkulturalna i građanska kompetencija. Pritom tvrdi kako je važna pretpostavka za uspješan rad nastavnika njegova pedagoška kompetentnost u pet područja:

- metodologija izgradnje kurikuluma nastave
- organizacija i vođenje odgojno-obrazovnoga procesa
- oblikovanje razrednoga ozračja
- utvrđivanje učenikova postignuća u školi
- oblikovanje modela odgojnoga partnerstva s roditeljima.

Samim time pedagoška kompetencija može se razmatrati kao opća kompetentnost pojedinca čije su podkategorije kompetencije koje se uglavnom navode pri određivanju cjelokupnog kompetencijskog profila nastavnika. Upravo zato neki istraživači ističu kako su pedagoške kompetencije još uvijek preopćenit pojam zato što su povezane s obrazovanjem i profesionalnim razvojem učitelja i nastavnika te njihovim stručnim i nastavničkim kompetencijama što mnogi poistovjećuju s pedagoškim (Buljubašić-Kuzmanović, 2014). Koncept pedagoških kompetencija ponekad se koristi u određenju minimalnog profesionalnog standarda, najčešće određenog zakonom, koji bi trebao posjedovati nastavnik kako bi djelovao sukladno standardima i zahtjevima nastavničke profesije (Gliga, 2002). Pedagoške kompetencije u skladu s time često se percipiraju stupnjevito kao određeni standard ili repertoar unutar kojeg razina kompetentnosti nastavnika odgovara ukupnoj količini znanja i vještina te sustava vrijednosti koje nastavnik posjeduje.

S druge strane, didaktičko-metodička kompetencija može se gledati kao rezultantna i djelatna dimenzija pretpostavljene joj pedagoške kompetencije koja se prema tome očituje u oblicima poučavanja i učenja usmjerenim na stjecanje ključnih znanja i razvijanje temeljnih vještina. Sukladno tome, Jurčić (2014) navodi kako se didaktičke kompetencije nastavnika iskazuju kroz odabir i primjenu metodologije izgradnje predmetnog kurikuluma, organiziranje i vođenje odgojno obrazovnog procesa, oblikovanje razredno-nastavnog ozračja, utvrđivanje učenikova postignuća u školi i u pogledu razvoja modela odgojnoga partnerstva s roditeljima. Navedeni segmenti didatičke kompetencije nastavnika vrlo su bitni za profesionalni rad učitelja, pedagoga i ostalih djelatnika škole. Metodologija izrade kurikuluma vrlo je aktualno pitanje budući da kurikulum obuhvaća sve elemente odgojno-obrazovnog procesa zbog čega je neophodno koristiti primjerenu i pedagoški legitimnu metodologiju izrade kurikuluma. Pored toga, prema pretpostavkama nastavnog procesa koji polaze od učenika, jedna je od najvažnijih didaktičkih kompetencija nastavnika umijeće organizacije i vođenja odgojno–obrazovnog procesa. Isto se očituje *u stvaranju produktivnih procesa učenja za svakoga učenika; jasnom, razumljivom, strukturiranom prikazu novih sadržaja, u kontekstu izbora didaktičkih alternativa, prema konkretnim nastavnim situacijama i postavljenim ciljevima i zadatcima,*

odnosno u razumnoj kombinaciji nastavnih metoda i socijalnih oblika rada, didaktičkih sustava nastave i didaktičkih načela; u domišljenoj artikulaciji sata utemeljena na dogovoru (suplaniranju i suorganizaciji), realizaciji dogovora i zajedničkom vrednovanju (suanalizi nastave). (Jurčić, 2014). Razredno ozračje utječe na zadovoljstvo nastavnika te primarno na učenike koji su približno iste dobi i stupnja razvoja, provode zajedno mnogo vremena zbog čega im je potrebno stvoriti pozitivne uvjete za rad i optimalan razvoj. Uz to, potrebno je vrednovati rad učenika pri čemu nastavnik mora biti didaktički kompetentan za to područje što obuhvaća neke usvojene dimenzije u radu nastavnika kao što su: „razumijevanje školske ocjene, razumijevanje pojma znanje, primjena pravednog kriterija, kontinuirana provjera, ocjenjivanje javno i zajedno s razredom, objektivno interpretiranje rezultata učenikova postignuća, umanjivanje učenikova straha od školskoga neuspjeha te razvoj ugodnog i ležernijeg ozračja u tijeku ispitivanja i ocjenjivanja.“ (Jurčić, 2012). Didaktičko-metodička kompetencija temelji se na širokom stručnom, pedagoško-psihološkom znanju o nastavi i učenicima te je rezultat umreženosti sviju područja kompetentnosti nastavnika u analizi i strukturiranju didaktičkih oblika poučavanja i učenja koje nastavnik unaprjeđuje i nadograđuje temeljem doživljenih situacija te uočenih zakonitosti i odnosa u praksi.

Razvijanje i podizanje profesionalnih kompetencija nastavnika ili „kompetencija za djelovanjem“ (Meyer, 2002, 190) ili sposobnost iznalaženja novih i nekonvencionalnih puteva ovisi o teorijskom znanju (koje se stječe tijekom studija), stručnom znanju (određeno kao praktično ili profesionalno znanje) te biografijom učenja nastavnika koju čini osobna i socijalna kompetencija. Kako bi se izgradio vlastiti pedagoški koncept nastave temeljen na kompetencijama, potrebno je kritički promatrati vlastitu nastavnu praksu, njene procese i ishode, odnosno razviti „refleksivnu distancu” koja označava sposobnost preispitivanja vlastite prakse iz drugih perspektiva (Meyer, 2005). Refleksija je na taj način metakognicija ili metakognitivni proces iskustvenog učenja, a može se sagledati i ostvariti i uz pomoć druge osobe, kritičkog prijatelja koji postavlja pitanja, razjašnjava dvojbe, širi perspektive i potiče dubinsku analizu nastave i njezine razvojne odrednice (Bell, 1993). Nastavnik kao refleksivni praktičar kritički razmatra svoju praksu te stalno propituje što radi, zašto to radi te kako može temeljem toga poboljšati svoj rad. Stalnim propitivanjem dobiva cjelovitu sliku o sebi i o značajkama svoga rada, bile one pozitivne ili negativne.

Brojna istraživanja, poput TRAC projekta (Teaching, Reflection and Collaboration) u kojem su sudjelovali volonteri-praktičari koji su vodili refleksivne dnevnike i tako unaprijeđivali svoj rad, dokazala su kako samorefleksija pomaže unapređivanju prakse (Scott i Weeks, 1998). Kontinuirano cjeloživotno obrazovanje i osposobljavanje pritom može biti

smisleno jedino ukoliko dolazi iz potrebe nastavnika za samonapredovanjem i željom da se razvija u individualnom, profesionalnom i akademskom smislu. Potrebno je biti svjestan osobnog praktičnog iskustva i djelovanja kako bismo na temelju opserviranja prakse te njezinom refleksijom i samorefleksijom svakodnevno mijenjali i unaprjeđivali odgojno-obrazovnu praksu.

Akcijsko istraživanje „kao dio profesionalne realizacije određenih ideja“ (Light i Cox, 2001, 227) predstavlja provjeru i transformaciju „akademske prakse“ u kojoj se razvija kritički odnos prema vlastitim neposrednim akcijama i akcijama ostalih kolega i putem kojeg se omogućuje svima njima profesionalna i osobna emancipacija i razvijanje stvarnog, konkretnog i neposrednog odgojno-obrazovnog konteksta. Akcijska istraživanja omogućuju praktičarima identificiranje individualnih ili zajedničkih područja interesa (dilema, pitanja ili problema) u konkretnim sredinama, usmjerenost na traženje odgovora na temelju podataka, opservacija, promišljanja i refleksije te stvaranju (privremenih) zaključaka o rješavanju dilema iz prakse.

Vlastiti pedagoški koncept nastave, preko teorijskog i iskustvenog znanja te kompetencija za djelovanje, razvija „refleksiju u djelovanju” koja je nastala kao rezultat „refleksije praktičnog nastavnog djelovanja” i „usmjeravanja praktičnog nastavnog djelovanja”. Refleksivni didaktičari *razmišljaju u hipotezama i metodički kontrolirano provjeravaju uspjeh svojega naučavanja* (Meyer, 2005, 137). Temelje za ovu tvrdnju postavio je Schön (prema Waks, 1999) koji smatra kako bi osposobljavanje budućih praktičara, pa tako i pedagoga, trebalo uključiti pripremanje za istraživanja koja su nužna za jednog refleksivnog praktičara. Istraživanja koja Schön ističe kao vrlo važna akcijska su istraživanja koja praktičari koriste kako bi istražili pitanja koja ih zanimaju, našli rješenja i unaprijedili praksu (Auger i Wideman, 2008). Frey u svom određenju kompetencije također ističe refleksiju nastavnika kao sastavni dio kompetencije koju definira kao *snop tjelesnih i duhovnih sposobnosti koje netko treba da bi mogao riješiti predstojeće zadatke ili probleme na odgovoran i cilju orijentiran način, kako bi ta rješenja mogao ocijeniti i dalje razvijati vlastiti repertoar djelatnih obrazaca* (Frey, 2004; 904). Akcijsko istraživanje refleksivni je proces, suradnička aktivnost među kolegama i učenicima u potrazi za rješenjima svakodnevnih, stvarnih problema u odgojno-obrazovnoj ustanovi ili na načinima unapređenja znanja i razvoja vještina učenika.

Stoga se u recentnim teorijskim razmatranjima ističe sve veći interes i potreba za nastavnicima koji kontinuirano razvijaju sposobnost teorijske refleksije u praktične uvjete i obrnuto, praksom i razmišljanjem o njoj izgrađuju novu teoriju. Unutar uspješnih odgojno-obrazovnih organizacija, tražene osobine praktičara su i motivacija za daljnjim napredovanjem i učenjem, razvijanje fleksibilnosti, prilagodljivosti, originalnosti te vještina komuniciranja,

analiziranja i reflektiranja vlastitih i tuđih postupaka u pedagoškoj praksi (Senge i sur., 2007, Fullan, 2007). To, među ostalim, zahtjeva potpunu osobu, realiziranu, stručnu, pedagoški i psihološki osposobljenu koja je zadovoljna sobom i svojim poslom. U nastavi matematike to podrazumijeva široki spektar znanja iz područja pedagogije i didaktike, psihologije te poznavanje specifičnosti zahtjeva i izazova nastave matematike, a to uključuje poznavanje posebnosti učenika u učenju matematike kao i razumijevanje izazova s kojima se učenici pritom susreću.

2.5.1 Kompetencije nastavnika matematike

Kompetentnost predstavlja priznatu stručnost i sposobnost kojom netko raspolaže te se odnosi na djelokrug prava odlučivanja jedne osobe ili ustanove te mjerodavnost i nadležnost (Anić, Goldstein, 2004). U kontekstu nastavničkog rada kompetencije se najčešće navode kao kombinacija znanja, vještina, stavova i sustava vrijednosti koje omogućuju pojedincu aktivno (su)djelovanje u nekoj situaciji. Unatoč fokusu na razumijevanju i utvrđivanju onoga što nastavnici moraju znati o matematici, polje matematičkog obrazovanja i dalje premalo zna o matematičkom znanju potrebnom za poučavanje (Ball, Luibenski, Mewborn, 2001). Ball i suradnici (2005), na temelju analiza istraživanja u matematičkom obrazovanju, koncipirali su okvir koji opisuje znanje potrebno za poučavanje matematike:

- znanje matematike u okvirima školskog kurikuluma
- znanje matematike korišteno u poučavanju koje je van okvira školskog kurikuluma
- znanje o učenicima i njihovim specifičnostima relevantnim za matematičko obrazovanje
- kombinacija znanja o poučavanju i znanja o matematici.

U aktualnim razmatranjima o obrazovanju zahtjevi suvremene nastave matematike ukazuju na nužnost promjena u pristupu obrazovanju nastavnika te cjelovitom predmetnom kurikulumu matematike. Temeljni je izazov u obrazovanju nastavnika odgovoriti u kojoj mjeri možemo i/ili trebamo poboljšati kvalitetu njihova obrazovanja i stručnih usavršavanja, a koliko moramo razmatrati druge pretpostavke sustava. Naime, život i rad nastavničke struke određen je obrazovnom politikom, kurikulumom, predmetnim kurikulumom, društvom i obitelji, ali i težnjama, kritikama i interesima znanstvenih zajednica te drugih interesnih skupina u društvu. Suvremeni nastavnici trebaju biti motivirani u jačanju i razvijanju svoje istraživačke kompetencije kako bi bili u stanju adekvatno evaluirati i unaprjeđivati svoju odgojno-obrazovnu praksu. Većina autora pritom raščlanjuje kompetencijski profil nastavnika na

mnoštvo podkategorija kompetencija izvedenih iz prirode nastavničke profesije: didaktičko-metodička, predmetna, pedagoška, osobna, komunikacijska, socijalna, interkulturalna, emocionalna, građanska, refleksivna itd. Pritom se zaključuje kako se određena kompetencija može smatrati potpuno usvojenom tek u trenutku kada se ista učinkovito koristi u praksi.

Budući da nastavnici dobivaju sve veću konkurenciju u obliku visoko-standardiziranih i lako usvojivih oblika prenošenja znanja, nužno je refleksivno osvjedočenje njihove djelatnosti i objašnjenje posebnog znanja profesije (Kipper i Mischke, 2008). Za nastavu matematike to podrazumijeva artikuliranje vlastitog matematičkog mišljenja putem koherentne i jasne usmene, pisane i vizualne komunikacije logičkog mišljenja i zaključivanja. Tome pridonosi jednostavnost iznošenja informacija, preglednost i jasnoća iznošenja sadržaja, primjeri koji podupiru važne informacije, zadatci i pitanja, novi oblici rada u grupi, paru. Pritom je potrebno da nastavnik analizira i vrednuje matematičko mišljenje i strategije učenika kako bismo razvili samostalnost učenika i autonomiju u radu.

Kako bi se to ostvarilo, treba znati što želimo postići (nastavni ciljevi), kako to postići (nastavne metode) i imati uvid u mogućnosti i osobine svakog pojedinog učenika. Kada se to postigne, lakše je razumjeti učenike te im pružiti odgovarajuću potporu, razvijati osjećaj osobne vrijednosti i samopoštovanja, a oni će zato biti koncentriraniji, više zainteresirani i aktivniji u nastavnim aktivnostima. Za poučavanje nastave matematike potrebne su kompetencije koje svojom obuhvatnošću na svojevrstan način odgovaraju slojevitosti izazova matematičkog obrazovanja što se odnosi na razumijevanje društvenih i socijalnih dimenzija nastave matematike, razumijevanje poteškoća učenika, promišljanje i refleksiju metodičkih postupaka, ali i osvješćivanje vlastitih stavova i uvjerenja o matematici koji oblikuju svakodnevni rad nastavnika te znanja, vještine, vrijednosti i stavove koje učenici pritom stječu i razvijaju. U nastavi se isto ostvaruje didaktičkim pristupom nastavi vodeći se pedagoškim znanjima o nastavi, učenicima te procesu učenja i poučavanja.

Didaktika se pita o tome *što* treba znati i umjeti i *zašto* i *čemu* to treba naučiti te time otvara pitanja o idejama vodiljama nastave kao što su: obrazovanje, kvalifikacija, kompetencija, profesionalno osposobljavanje, osposobljavanje za studij (Kiper i Mischke, 2008). Didaktika se pritom mora razmatrati s aspekta nastavnih planova i programa te kurikuluma koji utvrđuju redoslijed i vremensko opterećenje usvajanja određenih znanja i umijeća i na kojoj razini nešto treba znati umjeti. S obzirom na to da se nastava matematike primarno realizira i vrednuje u vještinama rješavanja zadataka, nastavnici moraju posjedovati znanje o tome kako se isto posreduje učenicima zbog čega je težište na kvalitetnoj izvedbi usmjerenoj na učeničke aktivnosti kako bi isti kasnije bili u stanju samostalno demonstrirati prikazana znanja i vještine.

Stoga se tijekom rješavanja zadataka i problema moraju uskladiti metodički aspekti nastave matematike s čimbenicima koji učenicima (potencijalno) olakšavaju i/ili otežavaju procese razmišljanja i samog rješavanja zadataka. Polya ističe kako se sposobnosti za rješavanje matematičkih problema naročito iskazuju u sljedećem: razumijevanje zadataka, izrada i stvaranje plana rada za rješavanje problema, realizacija i izvršenje toga plana, analiza rješenja problema, tj. osvrt na dobiveno rješenje problema (prema Kadum, 2005, 63). Na temelju potreba učenika i prirode nastavnih sadržaja matematike, Nisbet (1990) predlaže smjernice za uspješnu nastavu matematike i ostalih prirodoslovnih predmeta: pričanje na glas (objašnjavanje misaonog procesa) pri rješavanju zadataka i problema, demonstracija procesa rješavanja složenih zadataka, argumentirana analiza procesa rješavanja i razmišljanja, kooperativno učenje, Sokratova metoda razgovora (Nisbet, 1990; prema Leikin, 2011).

Među nastavnicima prisutna su uvjerenja kako je za kvalitetno poučavanje dovoljno posjedovati duboko, konceptualno razumijevanje matematike kao znanosti. Naime, nastavnik koji umije posredovati samo matematička znanja i vještine ne može realizirati obrazovne ishode bez poznavanja učenika i njihovih specifičnosti te metakognitivnih vještina kako bi poučavanje prilagodio učenicima. Kako bi se to ostvarilo, nastavnici u svom radu trebaju koristiti metode kojima potiču pozitivno ozračje kako bi lakše motivirali učenike da svojom aktivnošću steknu znanja. Zahtjevnost rada nastavnika matematike ne očituje se u pojašnjavanju matematičkih pojmova, već u sposobnosti da učenike izloži i suoči s matematičkim sadržajima, u nastojanju da im se pomogne u otklanjanju i nadilaženju poteškoća i/ili problema s kojima se pritom suočavaju. Zbog toga svaki nastavnik mora poznavati načine na koje djeca usvajaju matematiku, koji su čimbenici njihova uspjeha u učenju matematike te razumjeti prirodu i vrste specifičnih teškoća. Stoga je za nastavu matematike i didaktičko-metodičke smjernice u poučavanju nastavnika bitno poznavati kognitivno funkcioniranje učenika, razvijenost predmatematičkih vještina, stilove učenja matematike, radne navike, poznavanje matematičkog jezika i pisma, razine usvojenosti matematičkih sadržaja.

Pritom se ne smiju zanemariti obiteljski, društveni i drugi okolinski faktori koji mogu pomoći nastavnicima u razumijevanju pozadine i prirode teškoća što je nužno kako bi bili u stanju pomoći učenicima u nadilaženju poteškoća s kojima se nose u školi općenito, a osobito u matematici. Iz cijelog spektra kompetencija koje tražimo od suvremenog nastavnika, pokazuje se kako stručnost koju stječu svojim obrazovanjem nije dovoljna, već su potrebne određene crte ličnosti, ali i određeno životno iskustvo koje je okosnica njihovog profesionalnog, ali i osobnog usavršavanja. Neovisno o nesuglasju u području predmetnih didaktika, smjernice za kvalitetnu nastavu matematike uvijek moramo temeljiti na učenicima i njihovim potrebama

te ukoliko smatramo da nastavnici primarno moraju biti vrsni matematičari, tada impliciramo kako su problemi i izazovi nastave matematike isključivo metodičke naravi te kako učenici ne uspijevaju zbog nerazumljivo posredovanih sadržaja od strane nastavnika. Time negiramo pedagošku sliku škole i vrijednost pedagogijskih spoznaja u odgoju i obrazovanju, osobito onim specifičnim za nastavu matematike. Kako uspjeh učenika nije ograničen čimbenicima nastavog procesa, već je dio cjelokupne školske, obiteljske i socijalne okoline u kojoj se dijete razvija, izazovi nastave matematike značajnim su dijelom i pedagoški problemi koji kod učenika imaju ozbiljne implikacije na odgojne i općeobrazovne vrijednosti njihova (daljnja) školovanja.

Uvažavajući mnogobrojne specifičnosti u sferi osobina ličnosti, stavova i uvjerenja učenika karakterističnih za nastavu matematike, pokazuje se kako odgojne dimenzije učenja i poučavanja matematike imaju izniman utjecaj na odgojno-obrazovni proces i cjelokupno obrazovanje učenika zbog čega je pedagogijsko razmatranje izazova nastave matematike neizostavno u istraživanjima matematičkog obrazovanja. To je potrebno ostvarivati nastavnom praksom kroz svekolike odgojne situacije, a ne samo kroz učenje gotovih normi, vrijednosti i stavova. Takav pristup može se utemeljiti jedino po načelima pristupa obrazovanju usmjerenog na učenika što se za nastavu matematike i specifičnosti matematičkog obrazovanja pokazuje potrebnim za razumijevanje i detekciju izvorišnih problema.

2.5.1.1 Uvjerenja nastavnika matematike

Nastavnici od prvih dana svog nastavničkog posla ulaze u učionice posjedujući određena uvjerenja o nastavi, učenju, vrednovanju učeničkih postignuća, nastavnom planu i programu te sposobnostima učenika (Brown, 2004). Među istraživačima vlada suglasje kako su ta uvjerenja moderatori uspješnosti njihove odgojno-obrazovne djelatnosti (Hattie, 2009).

S obzirom na to da je ponašanje dijelom određeno vještinama koje su pod utjecajem uvjerenja, kao indikator kompetentnosti nastavnika neki istraživači navode kako je ponašanje pojedinaca u privatnom životu najveći odraz njihove profesionalne kompetentnosti te ističu kako se pri razmatranju kompetencija nastavnika treba fokusirati na sposobnosti, ponašanje i uvjerenja (Struyf, Adriaensens i Meynen, 2011). Naime, profesionalna uvjerenja u značajnoj mjeri određuju kako će se nastavnici ponašati i kako će poučavati (Richardson i sur., 1991), a nastavnici ih stječu vrlo rano, najčešće kroz vlastita iskustva i prisutna emocionalna stanja i razna uvjerenja. Uvjerenja učitelja i nastavnika vrlo su trajna i duboko ukorijenjena te tijekom njihovog obrazovanja mogu odolijevati racionalnim argumentima i znanstvenim dokazima koji

su suprotnog stajališta (Domović, 2011). Mnogi autori ukazuju na kompleksnost uvjerenja nastavnika o nastavi i učenju (npr. Boulton-Lewis i sur. 2001), a u kontekstu nastave matematike često se ističe kako se odnos uvjerenja nastavnika i njihove odgojno-obrazovne prakse može objasniti kulturološkim i kurikularnim specifičnostima (Andrews i Hatch, 1999).

Naime, neke su studije ukazale na razlike u uvjerenjima nastavnika matematike u Sjedinjenim Američkim Državama i Kini o tome na koji način učenici uče matematiku (npr. Correa i sur., 2008). U tom istraživanju utvrđeno je kako nastavnici u Kini smatraju da kod učenika treba razvijati interes učenika za matematiku povezujući je sa svakodnevnim životom, a nastavnici u SAD-u više su usmjereni na stilove učenja učenika i korištenje nekih specifičnih načina poučavanja. Sukladno tome, pokazalo se kako je značajna veza između uvjerenja nastavnika s jedne strane i tipova matematičkih zadataka koji se rade na nastavi i poimanja sposobnosti učenika te procesa učenja kao i razrednog ozračja s druge strane.

Premda se polazi od pretpostavke kako se radi o stabilnim konstruktima povezanosti između uvjerenja i postupaka nastavnika, ovim problemima uvijek se mora pristupati s oprezom zato što odnos između uvjerenja nastavnika u pristupu svakodnevnim izazovima iz prakse ponekad može značajno varirati, pa čak i proturječiti istima. Na tragu toga, rezultati pojedinih intervencijskih studija pokazali su kako je lakše promijeniti nastavnu praksu nastavnika, a promjena uvjerenja znatno je zahtjevnija te podrazumijeva dugotrajniji proces (Natan i Knuth, 2003; Turner, Warzon i Criestensen, 2011). Pritom je bitno da nove, poboljšane prakse budu donekle u skladu s trenutnim uvjerenjima, a naglasak je na osvješćivanju odstupanja između istih kojih nastavnici često nisu svjesni.

Temeljno polazište u mijenjaju načina rada nastavnika pretpostavka je kako ponašanje nastavnika izravno utječe na rad i ponašanje učenika što je osnova učeničkog uspjeha i ostvarivanja kurikulumom zadanih obrazovnih ishoda. Istraživanja pokazuju kako na učeničko dostignuće utječu i stavovi i očekivanja nastavnika, a uspjeh je najveći kod nastavnika koji nastavu poimaju na temelju svoje uloge i odgovornosti za istu pa stoga od učenika očekuju uspješnije učenje (Brophy, 1986.). U istraživanju koje su provele Šimić i Sorić (2004.) pokazalo se kako se osobine ličnosti nastavnika javljaju kao prediktori nastavničkih osjećaja, stavova i očekivanja u procjeni učeničkih znanja.

Karakteristike nastavnika odnose se na vrijednosti, uvjerenja, znanja, komunikacijske vještine, vještine poučavanja, poznavanje teorija učenja i procesa poučavanja te poznavanje razvoja djece u odgojnim i obrazovnim specifičnostima. Od navedenih čimbenika najvažniji su oni koji su direktno u fokusu procesa učenja i poučavanja. Brojna istraživanja potvrdila su kako nastavnici koji imaju pozitivna uvjerenja o sposobnostima i potencijalima učenika također

imaju visoka očekivanja te kako njihovi učenici postižu bolje rezultate (Rosenthal i Jacobsen, 1968). Isto je istraživanje mnogo puta replicirano te je bez izuzetaka potvrđeno u istraživanjima diljem svijeta. Međutim, ukoliko vrijednosti, uvjerenja i znanja nastavnika nisu temeljena na poznavanju učenika i njihovih specifičnosti u nastavi matematike, tada vještine poučavanja i opći pristup nastavi ne može imati željenu kvalitetu i obrazovne ishode učenika. Tu se moraju posebno razmatrati predrasude i stereotipi o obrazovanju općenito te razumijevanje onih koji su karakteristični za nastavu matematike.

U socijalizacijskom procesu veliku ulogu imaju spolni stereotipi koji su često prisutni na različitim razinama društva te su povezani s njihovom percepcijom sposobnosti za svladavanje matematike te s očekivanjima budućeg uspjeha u u matematici. Jacobs (1991.) je u analizi obiteljskih čimbenika u svom istraživanju pokazala kako su jači roditeljski spolni stereotipi bili povezani s jačim specifičnim uvjerenjima u sposobnost sinova da svladaju matematiku u usporedbi s uvjerenjima koja su se odnosila na kćeri. Uz stererotip o matematici kao muškoj domeni uvijek se veže problem nadarenosti i obrazovanosti (više u poglavlju 2.3.3.2). Naime, opće je prisutno uvjerenje kako su samo neki učenici sposobni uspješno svladati matematičke sadržaje što upravo kroz nastavu matematike uvijek iznova tematizira središnji pedagoški problem - *problem nadarenosti i obrazovanosti* (Giesecke, 1993). Društvo kroz svoje stavove i sustav vrijednosti poistovjećuje svaki matematički uspjeh s urođenim potencijalima i kacpacitetima, a neuspjeh opravdava izostankom istih. Time se zanemaruje i omalovažava svaki trud onih „sposobnih" i uspješnih, a ostalima se omogućuje pripisivanje neuspjeha nekim vanjskim čimbenicima.

Također, nastavnici matematike moraju biti svjesni kako s godinama školovanja stavovi učenika o matematici bivaju sve negativniji te da loše utječu na motivaciju i uspjeh (Arambašić, Severinac, 2003). Problemi, predrasude i stereotipi o nastavi matematike već su tradicionalno utkani u društvo, obitelj i školu zbog čega je za željenu kvalitetu učenja i poučavanja matematike potrebno mijenjati stavove i uvjerenja o matematici u svim strukturama društva i obrazovanja, a naročito na nastavničkim i učiteljskim studijima. Time se ne implicira kako učitelji i nastavnici imaju iste stereotipe, ali svakako moraju biti osposobljeni nositi se s učenicima koji su njima izloženi ne bi li im pravovremenim reakcijama i ispravnim postupcima omogućili optimalan razvoj. Ipak, što se tiče distinkcija među učiteljima (razredne nastave) i nastavnicima, pokazuje se kako su prisutna uvjerenja da učenici nisu uspješni u matematici zato što učitelji(ce) razredne nastave imaju nedostatno razvijene stručne kompetencije za kvalitetno poučavanje. Iako se ne može točno reći gdje i kada nastaju problemi učenika, svejedno se pokazuje kako presudnu ulogu pritom ima odnos učenika i učitelja matematike u nižim

razredima osnovne škole (Sherman i Richardson, 1995).

Relevantna istraživanja ukazuju na emocionalnu sferu nastavnog procesa u kojem se pokazuje kako učitelji(ce) razredne nastave posjeduju visok stupanj anksioznosti prema matematici (Widmer i Chavez, 1982; Hembree, 1990; Vinson, 2001) te kako isto prenose na svoje učenike (Vinson, 2001; Peker, 2008). Naime, problem matematičke anksioznosti prisutan je u gotovo svim odgojno obrazovnim sustavima u kojima se općenito pokazuje kako je značajan broj studenata učiteljskih studija tijekom svojeg školovanja imao problema u učenju matematike. Tako se, primjerice, pokazalo kako trećina budućih učitelja razredne nastave ima negativne asocijacije na matematiku, četvrtina njih se boji matematike, a čak tri četvrtine njih nisu voljeli matematiku ni u školi (Mišurac-Zorica, 2007).

Kako razumijevanje nastavnog predmeta zajedno s pripadajućim stavovima i uvjerenjima oblikuje način poučavanja učitelja i nastavnika u praksi, pretpostavka je kako ima puno mjesta za poboljšanja upravo u tom području, a ne samo u stručnim kompetencijama na koje se u matematici običava davati značajniji naglasak. Metcalf (1995) ističe kako bi inicijalno obrazovanje nastavnika moglo biti učinkovitije za nastavnu praksu kada bi ono bilo više usmjereno na proces učenja i poučavanja, razvoj ispravnih i znanstveno utemeljenih uvjerenja o nastavi i učenicima (prema Hattie, 2009).

Bitan aspekt u radu nastavnika također čine (ne)zadovoljstvo nastavničkim poslom, percepcija samoefikasnosti te opći stavovi prema obrazovanju i prema učenju i poučavanju. Tako niska samoefikasnost nastavnika može se u njihovu radu odraziti kao posrednik nastavničkoj ljutnji i stresu te kao prediktor kažnjavanja učenika (Melby, 2001).

Takvi nastavnici pokazuju i sklonost prema nadzoru i kontroli, pesimistični su u pogledu učeničkih sposobnosti i motivacije te se čvrsto vode principima vanjskih nagrada i kažnjavanja učenika (Tschannen-Moran i sur., 1998). Poznato je kako su grupe s autoritarnim stilom rukovođenja najproduktivnije u smislu uspješnosti izvođenja zadatka (Andrilović i Čudina-Obradović, 1996), a grupe s autoritativnim voditeljima nešto su manje efikasne u izvođenju zadatka, ali u njima vladaju prijateljski odnosi i zadovoljstvo obavljanjem zadatka. Sintezom relevantnih istraživanja utvrđeno je kako se kombiniranjem raznih metoda i strategija poučavanja postiže veća kvaliteta učenikova znanja, vještina, umijeća i sposobnosti, a sve se to događa u kontekstu aktivnog poučavanja (Robson, 1998).

Učenici koji imaju potporu nastavnika percipiraju veću autonomiju i pozitivnije funkcioniraju u smislu njihova angažmana u razredu, kreativnosti, intrinzične motivacije, opće dobrobiti, razumijevanja sadržaja, akademskog dostignuća te motivacije učenika. S druge strane, permisivan i indiferentan stil rukovođenja nije uspješan ni po jednom kriteriju, a

posljedice su ovog stila rukovođenja slaba uspješnost u izvođenju zadatka i nezadovoljstvo izvođenjem zadatka, kao i loši međuljudski odnosi (Vizek-Vidović i sur., 2003). Brekelmans i suradnici (1993) navode kako direktivni, autoritativni i tolerantni nastavnici ostvaruju više „stvarnog“ učenja u kojem su učenici aktivni i sudjeluju, nego nastavnici s drugim tipovima međuljudskih odnosa. Interakcija s učenicima jedan je od korelata nastavničkoga zadovoljstva poslom. Nekoliko istraživanja došlo je do rezultata kako nastavnici interakciju s učenicima, kao aspekt poučavanja, procjenjuju najpozitivnijom (Kim i Loadman, 1994) što je konzistentno s nalazima brojnih studija (Pajares, 1992; Pekhonen, 1992; Gamoran, 1993; Crosnoe, Johnson i Elder, 2004) kojima su učenici potvrdili kako su nastavnici koje su ocijenili najboljima s njima imali pozitivnu interakciju, pomagali im u pronalasku efikasnih strategija učenja te su im bili na raspolaganju kada su trebali pomoć u radu. Huitt (2003) naglašava kako je, pored uvjerenja nastavnika, osjećaj samoefikasnosti nastavnika najvažnija karakteristika te je dobar prediktor njihova rada i učeničkog uspjeha, a očituje se u interesu učenika, povjerenju, motivaciji za učenje i drugih pozitivnih ishoda kod učenika.

2.5.1.2 Samoefikasnost nastavnika matematike

Nastavnički osjećaj efikasnosti pokazuje se kao konstrukt koji je u visokoj korelaciji s učeničkim uspjehom, motivacijom i osjećajem efikasnosti kod učenika (Tschannen-Moran i sur., 1998). Nastavnici s višim osjećajem efikasnosti pokazuju više poleta prilikom poučavanja, osjećaju veću obvezu prema poučavanju i vjerojatnije je da će ostati u nastavničkom poslu (Tschannen-Moran i sur., 1998). Uz to, Fives (2003.) ističe kako ti nastavnici pokazuju ljubav prema poučavanju, osjećaju obvezu posao obavljati profesionalno te su općenito zadovoljniji svojim poslom. Istraživanja su pokazala kako se samoefikasnost nastavnika može povezati s entuzijazmom koji nastavnici imaju u vezi s procesom učenja i poučavanja (Guskey, 1984; Hall i sur., 1992), naporima koje ulažu u planiranje i organizaciju nastave (Stein i Wang, 1988; Allinder, 1994) te s tretiranjem grešaka učenika uslijed čega rade dulje s učenicima koji se trude**.** To također podrazumijeva otvorenost za nove ideje, sklonost eksperimentiranju s novim metodama kako bi zadovoljili potrebe svojih učenika te obuhvatnije razine planiranja i organizacije nastavnog procesa.

U istraživanjima odnosa nastavničkih osobina ličnosti i uspjeha učenika, utvrđena je pozitivna povezanost između učeničkog uspjeha i nastavničke fleksibilnosti, kreativnosti (Darling-Hammond, 2000). Uspješni nastavnici nastoje primijeniti razne strategije poučavanja

i stilove interakcije, a ne pojedinačne, rigidne pristupe. Nadalje, takvi nastavnici svoje poučavanje prilagođavaju sposobnostima i potrebama učenika, kao i zahtjevima nastavnih ciljeva, služeći se pritom raznim metodama poučavanja, tipovima testova te nastavnim sredstvima, materijalima i aktivnostima (Doyle, 1985; prema Darling-Hammond, 2000). S obzirom na karakteristike nastavnika koji imaju visoke procjene samoefikasnosti, u razmatranju njihova utjecaja na učenički uspjeh može se razmatrati i priroda interakcije s učenicima.

Ross i Bruce (2007.) navode kako nastavnici s višim osjećajem samoefikasnosti češće upotrebljavaju nove ideje, pristupe i strategije poučavanja, kako pristupaju rukovođenju razredom stimulativno, poštujući učeničku autonomiju, a pritom smanjuju nadzor i kontrolu nad učenicima, pružaju specifičnu pomoć učenicima slabijih sposobnosti, nastoje pomoći promijeniti negativne obrasce kod učenika i učeničke percepcije vlastitih akademskih sposobnosti te stoga postavljaju ostvarive ciljeve i ustrajniji su u suočavanju s učeničkim neuspjesima. U kontekstu nastave matematike neka istraživanja pokazuju kako nastavnici matematike smatraju da je za kvalitetno poučavanje dovoljno posjedovati duboko, konceptualno razumijevanje i poznavanje matematike (npr. Patton i sur., 2008) pa možda u skladu s time kreiraju vlastito poimanje efikasnosti. Teorija i praksa potvrđuju kako je visoka stručnost u matematici nužna, ali ne i dovoljna za uspješno poučavanje. Naime, iako bi se moglo pretpostaviti kako nastavnici koji posjeduju visoko razvijena stručna znanja o sadržajima mogu bolje razumjeti proces učenja kod učenika, nema studija koje bi to potkrijepile (Hattie, 2009). Neki istraživači (Yoon, 2002) bavili su se odnosom nastavničkog stresa i samoefikasnosti nastavnika u kontekstu interakcije između nastavnika i učenika u nastavnom procesu.

Yoon je pritom utvrdio kako stres nastavnika korelira s negativnim aspektima samoefikasnosti i odnosa nastavnika i učenika pri čemu često dolazi do neprijateljskih odnosa koji su obilježeni nedostatkom povjerenja, nezadovoljstvom i nedostatkom motivacije na svim relacijama njihova odnosa. Drugi su se istraživači (Ivanov i Penezić, 2004) pri razmatranju negativnih karakteristika nastavnika fokusirali na perfekcionizam te su utvrdili kako je perfekcionizam nastavnika značajno povezan s lošijom prilagodbom učenika i lošijim postignućima. U toj su studiji autori konstrukt perfekcionizma pojasnili nerealnim očekivanjima nastavnika prema sebi i učenicima što zbog nezadovoljstva ispunjenim ciljevima može rezultirati autoritarnim stilom vođenja nastavnog procesa.

U nastavi matematike isto se može pokazati kod nastavnika koji imaju visoku razinu samopouzdanja u vlastitu stručnu kompetenciju te mnogo ulažu u pripremu i izvođenje nastave pa vjerujući kako su uspješni u tome, po načelu reciprociteta, očekuju jednako visoko znanje učenika kao svojevrsno priznanje za trud koji su pritom uložili. Naime, kada nastavnik ulaže

dodatne napore u planiranje nastave te se osjeća uspješnim u primjeni različitih strategija poučavanja, veća su i njegova očekivanja visokih postignuća učenika (Stein i Wang, 1988; Allinder, 1994). No, ukoliko je to svedeno na uske koncepte posredovanja sadržaja i poučavanja kojima se ne razmatraju specifičnosti učenika, tada navedeni pristup može imati suprotan učinak od očekivanog.

3. METODOLOGIJA ISTRAŽIVANJA

Kvalitetan odgoj i obrazovanje moguće je postići jedino uz kvalitetne učitelje i nastavnike zbog čega je neophodno kvalitetno inicijalno obrazovanje i kontinuirano stručno usavršavanje odgojno-obrazovnih djelatnika. Govoreći o poboljšanju kvalitete njihova obrazovanja, ne misli se samo na inicijalno visokoškolsko obrazovanje, već na trajni profesionalni razvoj što u kontekstu cjeloživotnog usavršavanja ima zajednički cilj u obnavljanju znanja i vještina učitelja i nastavnika, a sve u funkciji realizacije odgojnih i obrazovnih perspektiva učenika. Što se tiče modela stjecanja kompetencija nastavnika matematike, potrebno je razmatrati strukturu i zastupljenost stručnih, pedagoških i didaktičko-metodičkih sadržaja u obrazovanju nastavnika. Naime, percepcija nastave matematike kao znanstvene discipline ima implikacije na sadržaj i način obrazovanja nastavnika zbog čega je metodika nastave matematike usmjerena na nastavnika, a kompetencijski profil nastavnika na vrhu hijerarhije ima upravo stručnu kompetenciju. U pristupu matematičkim sadržajima, nastavnici matematike često ne uspijevaju u općem pedagoškom pristupu nastavi i učenicima kako bi se usmjerili na poučavanje umjesto pojašnjavanja, odnosno na metode koje su najprimjerenije sposobnostima, predznanju i emocionalnom stanju učenika.

Odnos između kompetencija nastavnika i uspjeha učenika jedan je od ključnih, a ujedno i najvećih izazova u istraživanjima odgoja i obrazovanja. Čimbenici koji imaju utjecaj na obrazovne ishode učenika u okvirima kompetencijskog pristupa obrazovanju često se razmatraju s aspekta uvjerenja, stavova, samoprocjena i nastavnih praksi nastavnika, no iste se rijetko postavlja u međusobni odnos što će biti i okosnica metodološkog pristupa ovog rada.

3.1 Polazne vrijednosti i problem istraživanja

Kompetentnost nastavnika jedno je od temeljnih pitanja kvalitete odgojno-obrazovnog sustava te se stalno teži utvrđivanju kompetencija uspješnih nastavnika i značajkama po kojima se razlikuju od manje uspješnih nastavnika. Suvremeni pogledi na profesionalnu kompetenciju (Cheetham i Chivers, 1996), time i pedagošku, imaju dva osnovna polazišta: potrebu za holističkim pristupom u istraživanju kompetentnosti te spregu formalnoga obrazovanja i programa usavršavanja nakon formalnoga obrazovanja (Kostović – Vranješ i Ljubetić, 2008). Jedan je od ključnih problema u razumijevanju kompetencija nastavnika i njihove odgojno-obrazovne prakse određivanje odnosa, tj. utjecaja koji određene prakse nastavnika imaju na proces učenja njihovih učenika. Najčešće se navode sljedeće dimenzije utjecaja nastavnika (Hattie, 2009):

- kvaliteta poučavanja
- očekivanja nastavnika
- uvjerenja nastavnika o nastavi, učenju, potencijalima učenika i sl.
- otvorenost nastavnika
- razredno ozračje
- artikulacija ciljeva, kriterija i zahtjeva u nastavi
- potkrepljenje uloženog truda učenika
- angažman učenika
- iskustvo nastavnika
- obrazovanje i osposobljavanje nastavnika.

Međutim, navedene dimenzije, područja i/ili aspekti rada nastavnika nisu u ravnopravnim odnosima zato što su mnoge dimenzije podskup ostalih ili svojim pojmovnim određenjem u sebi sažimaju ostale navedene kategorije, kao na primjer obrazovanje i osposobljavanje nastavnika. Unatoč tome, navedene dimenzije nastavničke kompetencije, počevši s kategorijom inicijalnog obrazovanja na dalje, sažimaju sve bitne momente izazova i problema relevatnih za područje matematičkog obrazovanja. Sukladno tome, sve se više pažnje posvećuje obrazovanju i usavršavanju učitelja i nastavnika, naročito u području pedagoško-psiholoških kompetencija.

Naime, ono što je karakteristično za nastavu matematike Buchberger i suradnici (2000) istaknuli su općenito za srednjoškolske nastavnike koje prati tradicija prema kojoj su oni ponajprije stručnjaci u svojem području, a tek onda praktičari i odgojni stručnjaci. Sukladno

tome se često ističe kako su nastavnici matematike školovani na paradigmi didaktike i metodike nastave usmjerene na nastavnike, umjesto na učenike (Matijević, 2010). Iako recentna istraživanja ukazuju na potrebu za kvalitetnijim pedagoškim znanjem nastavnika, i dalje su aktualna neslaganja oko kompetencijskog profila nastavnika matematike, odnosno u hijerarhiji kompetencija adekvatnih zahtjevima nastave matematike.

Suvremeni nastavnik matematike mora osigurati poticajno i motivirajuće razredno ozračje koje će biti prožeto radnom disciplinom i pozitivnim odnosima s učenicima. Naime, pedagogijska tradicija najveću važnost pridaje načinu na koji djeca uče (Marsh, 1994), a ne toliko sadržajima učenja. Pedagogijsko usmjerenje teži učenju otkrivanjem u kojem se integracija i participacija, suradnja i partnerstvo doista ostvaruju (Buljubašić-Kuzmanović, 2014). Stoga se pedagoško osposobljavanje nastavnika, za predmet poput matematike, mora usmjeriti na specifičnosti učenja i poučavanja, a samim time i nadopuniti didaktičko-metodičke odrednice nastave. S obzirom na širinu problematike matematičkog obrazovanja, potrebno je terminološki razjasniti određenje didaktičko-metodičke kompetencije koju bismo prema Jurčiću (2012) mogli promatrati kao djelatnu kompetenciju nastavnika, odnosno kao svojevrsnu manifestaciju ukupnog kompetencijskog sklopa nastavnika u njegovoj odgojno-obrazovnoj djelatnosti. Prema tome, didaktičko-metodička kompetencija očituje se u oblicima poučavanja i učenja usmjerenim na stjecanje ključnih znanja i razvijanje temeljnih vještina te je stoga središnji pojam metodike i didaktike nastave matematike.

Didaktika nastave matematike ujedinjuje pitanja opće didaktike sa specifičnostima nastave matematike i aspektima učenja i poučavanja matematike. S druge strane, metodika nastave matematike disciplina je koja primjenjuje didaktička načela, zakonitosti i metode svojstvene nastavi matematike i matematici kao znanosti. Primarni je interes metodike oblikovanje konkretnih nastavnih sadržaja koje bi učenici mogli usvojiti stjecanjem odgovarajućih znanja i razvijanjem za to potrebnih vještina. *Metodičko djelovanje podrazumijeva ukupnost svih aktivnosti koje se neposredno odnose na oblikovanje i prilagođavanje određenim situacijama učenja ili pak na njihove posljedice, odnosno područja učenja* (Schulze, 1978, str.34).

Slijedom toga, didaktičko-metodička kompetencija temelji se na širokom stručnom, pedagoško-psihološkom znanju o nastavi i učenicima te je rezultat umreženosti svih područja kompetentnosti nastavnika u analizi i strukturiranju didaktičkih oblika poučavanja i učenja koje nastavnik poboljšava i nadograđuje temeljem uočenih zakonitosti i odnosa u praksi. Međutim, kako bismo razumjeli kako kompetencije nastavnika utječu na njihovu praksu i učenike, potrebno je razmatrati njihova uvjerenja o procesu učenja i poučavanja, o nastavi, učenicima te

prema sebi samima u ulozi nastavnika. Pri istraživanju uvjerenja i stavova nastavnika direktno vezanih uz nastavni proces, veći broj istraživača bavio se tipovima uvjerenja (Nespor, 1987), pretpostavkama i razvojem uvjerenja (Pajares, 1992) te odnosom uvjerenja i konkretnih postupaka nastavnika (Bryan i Atwater, 2002). Vodeći se teorijskim pregledom literature, polazimo od pretpostavke kako su percepcija akademske samoefikasnosti, sustav vrijednosti i uvjerenja nastavnika ponajbolji prediktori kompetencija koje pokazuju u praksi, određuju njihov odgojno-obrazovni rad te su temelj u stjecanju odgojnih vrijednosti i ostvarivanju obrazovnih postignuća učenika.

3.2 Kontekst i sudionici istraživanja

Planirani uzorak istraživanja činilo je 500 nastavnika osnovnih i srednjih škola čime je obuhvaćena populacija nastavnika i učitelja matematike iz svih županija Republike Hrvatske. Ciljana skupina ispitanika bili su nastavnici matematike koji rade u srednjim školama i učitelji matematike koji rade u predmetnoj nastavi od petog do osmog razreda osnovnih škola. Od predviđenog uzorka, konačna brojka potpuno ispunjenih anketa svela se na 348 nastavnika i učitelja matematike. Za evaluaciju veličine uzorka koristila se kombinacija Cochranove formule i njezine modifikacije (1963):

$$n_0 = \frac{z^2 pq}{e^2} \qquad \text{(Cochranova formula, 1963)}$$

$$n = \frac{n_0}{1 + \frac{n_0 - 1}{N}} \qquad \text{(modifikacija Cochranove formule)}$$

Prema prvoj Cochranovoj formuli, tražena veličina uzorka jest pod oznakom n_0; z se odnosi na apscisu normalne krivulje koja označava rubni dio krivulje (α) s obzirom na razinu značajnosti izraženu u standardnim devijacijama koju želimo postići; e se odnosi na pripadnu razinu značajnosti (najčešće 0.05, 0.01); p je procijenjeni udio uzorka koji ima svojstva koja istražujemo za populaciju koja je u fokusu istraživanja; q se odnosi na onaj preostali dio od procijenjenog udjela uzorka pa je po principu vjerojatnosti isti jednak q = 1 - p. Obje se vrijednosti prema zakonima vjerojatnosti uzimaju jednakima, odnosno p = q = 0.5, tj. p se postavlja kao 0.5 iz čega slijedi q = 1 – 0.5 = 0.5.

Prema podatcima Ministarstva znanosti i obrazovanja Republike Hrvatske, u ispitivanoj populaciji nastavnika matematike koji rade u osnovnim i srednjim školama na radnim mjestima zaposleno je 2285 djelatnika na radnom mjestu učitelja matematike u osnovnim školama od 5. do 8. razreda te 1450 djelatnika na radnom mjestu nastavnika matematike u srednjim školama. To ukupno čini 3735 učitelja i nastavnika matematike. Dakle, primijenimo li Cochranovu formulu za reprezentativnost uzorka na cjelokupu populaciju, dobit ćemo:

$$n_0 = \frac{1.96^2 \cdot 0.5 \cdot 0.5}{0.05^2} = 384.16$$

Za odabranu razinu značajnosti odabrana je razina od 5 % (e = 0.05) razine statističke greške, odnosno komplementarnih 95 % te je stoga prema zakonitostima površine ispod normalne krivulje uzeta vrijednost z = 1.96 što se odnosi na širinu intervala od dvije standardne devijacije od prosjeka. Dobivena vrijednost, zajedno s ukupnom populacijom (N = 3375), uvrsti se u modificiranu Cochranovu formulu iz čega slijedi:

$$n = \frac{n_0}{1 + \frac{n_0 - 1}{N}} = \frac{384}{1 + \frac{384 - 1}{3735}} = 348.29$$

Dakle, za promatranu populaciju nastavnika i učitelja matematike na području Republike Hrvatske utvrđeno je kako je broj od 348 nastavnika upravo na granici intervala statističke značajnosti 0.05 te se stoga promatrani uzorak smatra reprezentativnim za cjelokupnu popuaciju koja je u fokusu ovog istraživanja.

Od 348 nastavnika u istraživanju je sudjelovalo 287 nastavnica (82.5 %) i 61 nastavnik (17.5 %). Struktura ispitanika prema duljini radnog staža bila je sljedeća: 21 % nastavnika do 5 godina radnog staža, 22 % nastavnika sa stažem između 6 i 15 godina, 35 % nastavnika sa stažem između 16 i 29 godine, a 20 % nastavnika s više od 30 godina radnog staža.

Većina ispitanika završila je Prirodoslovno-matematički fakultet (Matematički odsjek) od kojih je 198 nastavnika (57 %) završilo nastavnički smjer, a 72 nastavnika (21 %) završilo je inženjerski smjer (tablica 2). Od ostalih ispitanika njih 43 (12.4 %) završilo je Učiteljski fakultet, a ostalih 35 (10 %) završilo je ili bivšu Pedagošku akademiju ili Fakultet za odgojne i obrazovne znanosti u Osijeku ili Filozofski fakultet u Rijeci - smjer matematika i informatika.

Što se tiče radnog mjesta ispitanika, pokazalo se kako je dosta ujednačena situacija zato što u osnovnoj školi u predmetnoj nastavi radi 136 nastavnika (39 %), u srednjim strukovnim školama radi 105 nastavnika (30 %) te 106 nastavnika (30 %) koji rade u gimnazijama.

3.3 Konceptualni okvir istraživanja

U istraživanjima kompetencija nastavnika iste se uglavnom razmatraju s aspekta uvjerenja (Munby, 1982; Fives i Buehl, 2008), nastavnih praksi (Andrews i Hatch, 1999; Nathan i Knuth, 2003), osjećaja samoefikasnosti (Guskey, 1984; Hall i sur., 1992; Tschannen-Moran i sur., 1998) nastavnika, no nedostatan je broj istraživanja koji objedinjuje navedene kategorije te analizira odnose među njima. U intencijama utvrđivanja odnosa između nastavnih praksi te uvjerenja i samoprocjena efikasnosti nastavnika, istraživački instrument koncipiran je u četiri dijela/upitnika:

1. Sociodemografski i osobni podatci nastavnika. (*Prilog 1*)
2. Ljestvica uvjerenja nastavnika o nastavi i obrazovanju općenito te o specifičnostima i problematičnim područjima matematičkog obrazovanja u školskom, obiteljskom i širem društvenom kontekstu. (*Prilog 2*)
3. Ljestvica samoefikasnosti nastavnika (kako nastavnici percipiraju vlastitu kompetentnost i osposobljenost za suočavanje s zahtjevima iz nastave). (*Prilog 3*)
4. Ljestvica učestalosti nastavnih praksi te učešće u profesionalnom razvoju i usavršavanju. (*Prilog 4*)

Od sociodemografskih i osobnih podataka obuhvaćeni su: spol, dob, godine radnog staža, inicijalno obrazovanje, stečena dodatna naobrazba, radno mjesto (osnovna škola, srednja škola ili fakultet).

Ljestvica uvjerenja nastavnika koncipirana je za potrebe ovog istraživanja na temelju teorijskog pregleda literature. Sastoji se od 32 čestice formiranih u izjave Likertova tipa na ljestvici od pet stupnjeva/razina slaganja (1 = uopće se ne slažem; 2 = ne slažem se; 3 = niti se slažem niti se ne slažem; 4 = slažem se; 5 = u potpunosti se slažem).

Ispitat će se stavovi i znanja nastavnika o kompetencijama općenito, nastavi matematike, učenju i poučavanju, didaktičkim sustavima, metodama, o ulozi nastavnika matematike u nastavi, školi i društvu, o percepciji matematike kao znanstvene discipline i kao nastavnog predmeta, o matematičkoj darovitosti, o razrednom ozračju i socijalnim vještinama,

profesionalnom razvoju, kurikulumu itd.

Ljestvica samoefikasnosti nastavnika također je koncipirana za potrebe ovog istraživanja te se sastoji od 20 čestica. Tvrdnje su ponovno bile Likertova tipa na ljestvici od pet stupnjeva/razina slaganja (1 = uopće se ne slažem; 2 = ne slažem se; 3 = niti se slažem niti se ne slažem; 4 = slažem se; 5 = u potpunosti se slažem).

Posebno će se ispitivati percepcija vlastite kompetentnosti u poučavanju i kategorijama znanja potrebnim za uspješno poučavanje, ali i opće poznavanje specifičnosti učenika (s posebnim odgojno-obrazovnim potrebama) kao i čimbenika koji utječu na uspješnost učenja i poučavanja. Također se ispituju samoprocjene iz područja poznavanja kurikularnih dokumenata te razumijevanje koncepta cjeloživotnog učenja.

Ljestvica učestalosti nastavnih praksi, kao i ostale ljestvice, koncipirana je za potrebe ovog istraživanja. Sastoji se od 25 čestica formiranih u izjave Likertova tipa na ljestvici od pet stupnjeva koji se odnose na učestalost nastavnih i izvannastavnih praksi nastavnika (1 = nikad/gotovo nikad; 2 = rijetko; 3 = ponekad; 4 = često; 5 = uvijek/gotovo uvijek). Pritom su se ispitivali aspekti njihova rada koji se tiču njihova stručnog usavršavanja i profesionalnog razvoja, strukturiranja nastave te različitih metoda, aktivnosti i ponašanja u sferi potpore učenicima i načina poučavanja kojima se koriste u nastavi.

3.3.1 Ciljevi istraživanja

Jedna je od polaznih pretpostavki u izradi upitnika proizašlog iz pregleda literature iz teorijskog dijela rada ispitati kako se uvjerenja o različitim aspektima učenja i poučavanja matematike i releventnim čimbenicima iz obiteljske i školske okoline razlikuju s obzirom na sociodemografska obilježja i profesionalni profil nastavnika. S obzirom na to da su brojne karakteristike nastavnika povezane s uspjehom učenika, jedan je od glavnih ciljeva ovako koncipiranog upitnika odrediti prediktivnu vrijednost individualnih karakteristika nastavnika proizašlih iz njihovih stavova i uvjerenja, samoprocjena, odnosno u kojoj mjeri iste doprinose kvaliteti poučavanja u kontekstu specifičnih zahtjeva nastave matematike i suvremenog obrazovanja.

Osnovni je cilj istraživanja steći jasniji uvid u njihova uvjerenja o nastavi matematike, njihovu percepciju samoefikasnosti te odrediti njihove afinitete u profesionalnom razvoju, u pedagoškim znanjima, poznavanju specifičnosti učenika u nastavi matematike kako bismo ustanovili prioritete u njihovom kompetencijskom profilu s naglaskom na odnos metodičkih,

stručnih (matematičkih) i pedagoških kompetencija te drugih dimenzija rada nastavnika koje će proizaći iz eksplorativnih faktorskih analiza istraživačkog upitnika.

3.3.2 Hipoteze istraživanja

S obzirom na teorijski pregled literature te predmet i cilj istraživanja ove doktorske radnje, postavljene su sljedeće hipoteze:

I. Opće hipoteze (sociodemografska obilježja i profesionalni profil nastavnika):

H1.1: Postoje razlike u sklopu uvjerenja, samoprocjenama nastavnika i učestalosti nastavnih i izvannastavnih praksi nastavnika s obzirom na spol.

H1.2: Postoje razlike u sklopu uvjerenja, samoprocjenama nastavnika i učestalosti nastavnih i izvannastavnih praksi nastavnika s obzirom na dob i radni staž.

H1.2.1: Postoje razlike u sklopu uvjerenja, samoprocjenama nastavnika i učestalosti nastavnih i izvannastavnih praksi nastavnika početnika i iskusnijih nastavnika.

H1.3: Postoje razlike u sklopu uvjerenja, samoprocjenama nastavnika i učestalosti nastavnih i izvannastavnih praksi nastavnika s obzirom na inicijalno obrazovanje.

H1.4: Postoje razlike u sklopu uvjerenja, samoprocjenama nastavnika i učestalosti nastavnih i izvannastavnih praksi nastavnika s obzirom na stečenu dodatnu naobrazbu i profesionalno usavršavanje.

H1.5: Postoje razlike u sklopu uvjerenja, samoprocjenama nastavnika i učestalosti nastavnih i izvannastavnih praksi nastavnika s obzirom na radno mjesto.

II. Specifične hipoteze (očekivane dimenzije kompetentnosti nastavnika iz eksplorativne faktorske analize istraživačkog upitnika)

H2.1: Očekuje se kako će fakorska analiza prvog dijela upitnika (uvjerenja nastavnika) izdvojiti specifične faktore kao što su:

- uvjerenja o stereotipima karakterističnim za nastavu matematike

- stavovi i uvjerenja o kurikulumu
- znanja o učenicima
- indikatori socijalne kompetencije
- indikatori metodičke kompetencije.

H2.1.1 Očekuje se kako će u navedenoj faktorskoj strukturi dominantni faktor biti socijalna kompetencija i znanja o specifičnosti učenika u nastavi matematike, odnosno kako iz tih uvjerenja možemo lakše razumjeti i pojasniti ostala uvjerenja i postupke nastavnika.

H2.2 Očekuje se kako će fakorska analiza drugog dijela upitnika (samoprocjena kompetentnosti i samoefikasnosti) izdvojiti specifične faktore kao što su:

- socijalna kompetencija i poznavanje specifičnosti učenika
- stručna kompetencija
- uvjerenja o kurikulumu
- emocionalna kompetencija

H2.2.1 Očekuje se kako će u navedenoj faktorskoj strukturi dominantan faktor biti samoprocjene nastavnika u sferi stručnih (matematičkih) kompetencija.

H2.2.1 Očekuje se kako će u dijelu upitnika sa samoprocjenama nastavnika najviše ocjene biti u sferi stručnih (matematičkih) kompetencija.

H2.3 Očekuje se kako će fakorska analiza trećeg dijela upitnika (učestalost nastavnih i izvannastavnih praksi) izdvojiti specifične faktore kao što su:

- socijalna dimenzija
- metodička kompetencija
- refleksivna kompetencija
- metakognitivna kompetencija
- profesionalni razvoj.

H2.3.1 Očekuje se kako će u navedenoj faktorskoj strukturi dominantni faktori biti učestalost nastavnih i izvannastavnih praksi u području metodičke kompetencije i metakognitivnih vještina.

III. Hipoteze o povezanosti uvjerenja, samoprocjena kompetentnosti i učestalosti nastavnih i izvannastavnih praksi (povezanost dominantnih dimenzija između triju faktorskih struktura)

H3.1 Postoji povezanost uvjerenja nastavnika te njihove samoprocjene kompetentnosti i samoefikasnosti.

H3.1.1 Postoji povezanost uvjerenja nastavnika o stereotipima u nastavi matematike te njihovih samoprocjena kompetentnosti i samoefikasnosti.

H3.1.2 Postoji povezanost uvjerenja nastavnika o kurikulumu te njihovih samoprocjena kompetentnosti i samoefikasnosti.

H3.1.3 Postoji povezanost uvjerenja nastavnika o socijalnim vještinama u nastavi te njihovih samoprocjena kompetentnosti i samoefikasnosti.

H3.1.4 Postoji povezanost uvjerenja nastavnika metodičkom strukturiranju nastave te njihovih samoprocjena kompetentnosti i samoefikasnosti.

H3.2 Postoji povezanost uvjerenja nastavnika te učestalosti određenih nastavnih i izvannastavnih praksi.

H3.2.1 Postoji povezanost uvjerenja nastavnika o stereotipima u nastavi matematike i učestalosti određenih nastavnih i izvannastavnih praksi.

H3.2.2 Postoji povezanost uvjerenja nastavnika o kurikulumu i učestalosti određenih nastavnih i izvannastavnih praksi.

H3.2.3 Postoji povezanost uvjerenja nastavnika o socijalnim vještinama u nastavi te učestalosti određenih nastavnih i izvannastavnih praksi.

H3.3 Postoji povezanost samoprocjene kompetentnosti i samoefikasnosti u nastavi matematike te učestalosti određenih nastavnih i izvannastavnih praksi.

H3.3.1 Postoji povezanost samoprocjene socijalne kompetencije i učestalosti određenih nastavnih i izvannastavnih praksi.

H3.3.2 Postoji povezanost samoprocjene stručne (matematičke) kompetencije i učestalosti određenih nastavnih i izvannastavnih praksi.

H3.3.3 Postoji povezanost samoprocjene u poznavanju specifičnosti učenika u nastavi matematike te učestalosti određenih nastavnih i izvannastavnih praksi.

3.3.3 Varijable istraživanja

S obzirom na primijenjenu metodologiju i statističke analize, u ovom smo istraživanju varijable podijelili na nezavisne i zavisne zasebno u prvom dijelu istraživanja u kojem smo utvrđivali osnovne deskriptivne parametre i statistički značajne razlike te smo tijekom korištenja regresijske analize u korelacijskom dijelu istraživanja koristili širi spektar nezavisnih varijabli, za razliku od prvo navedenih analiza.

Tako su u prvom dijelu nezavisne varijable bile:

- dob nastavnika
- spol nastavnika
- radni staž nastavnika
- inicijalno obrazovanje nastavnika
- stečena dodatna naobrazba nastavnika
- radno mjesto nastavnika.

Zavisne varijable pritom su činili:

- uvjerenja nastavnika o nastavi matematike i matematičkom obrazovanju
- uvjerenja nastavnika o stereotipima karakterističnim za nastavu matematike
- uvjerenja o kurikulumu
- znanja o specifičnostima učenika u nastavi matematike
- indikatori socijalne kompetencije
- indikatori metodičke kompetencije
- samoprocjene nastavnika u području socijalne kompetencije
- samoprocjene nastavnika u području stručne kompetencije
- samoprocjene nastavnika u području poznavanja kurikularnih dokumenata
- samoprocjene nastavnika u području emocionalne kompetencije

- samoprocjene nastavnika u području rada s učenicima sa specifičnim teškoćama u učenju
- nastavne prakse nastavnika u konceptu nastave usmjerene na učenika
- postupci i metode nastavnika u sferi metakognitivne dimenzije
- sudjelovanje nastavnika u profesionalnom razvoju
- stručno usavršavanje nastavnika u projektima mobilnosti i akcijskim istraživanjima
- nastavne prakse nastavnika u području refleksivne dimenzije.

U modelima regresijskih analiza među nezavisne varijable uključena su, pored navedenih varijabli, uvjerenja i samoprocjene nastavnika koje su izdvojene provedenim faktorskima analizama te su korištene kao prediktorske varijable u razumijevanju i analizi nastavnih praksi ispitanika.

3.3.4 Obrada podataka i etape istraživanja

U analizi istraživanja primijenit će se kvantitavna metodologija koja će se temeljiti na anketnom upitniku koncipiranom prema ljestvici Likertova tipa s pet stupnjeva odgovora (od „uopće se ne slažem" do „u potpunosti se slažem"). Svi prikupljeni podatci dobiveni ovim istraživanjem analizirat će se odgovarajućim postupcima kvantitativne analize, a prikupljeni podatci upitnikom obradit će se pomoću statističkog paketa SPSS i prikazati parametrima deskriptivne statistike: mjere centralne tendencije (medijan, mod i aritmetička sredina), standardna devijacija i kvartilna odstupanja. U kvantitativnoj analizi podataka još će se koristiti jednosmjerna analiza varijance (Anova, F-test) T-test na binarnim varijablama, analiza korelacije, faktorska analiza te regresijske analize prozašle iz prethodno navedenih analiza.

U svrhu redukcije podataka i utvrđivanju dimenzionalnosti pojedinih ljestvica koristit će se eksplorativna faktorska analiza budući da je upitnik prvi put koncipiran za potrebe ovog istraživanja temeljem teorijskog pregleda literature.

Određivanje broja faktora u svakoj faktorskoj analizi odredit će se pomoću triju kriterija:

- svojstvene vrijednosti jediničnih vektora
- točka infleksije na Dijagramu svojstvenih vrijednosti (Scree Plot)
- Monte Carlo paralelna analiza (Watkins, 2000).

Kaiser-Meyer-Olkin testom prikladnosti, Cronbach Alpha koeficijentom i Bartlettovim testom spljoštenosti utvrdit će se jesu li podatci prikladni za faktorizaciju. U svakoj ljestvici korištena

je eksplorativna faktorska analiza metodom glavnih komponenata (PCA- eng. *Principal Components analysis*) s *Oblimin* kosom rotacijom i po potrebi s *Varimax* rotacijom, ovisno o korelaciji među faktorima utvrđenim pokretanjem faktorske analize. Primarno smo svaku faktorsku analizu pokrenuli s Oblimin (kosokutnom) rotacijom zato što se ista više preporuča u istraživanju društvenih znanosti, naročito kada se očekuju znatnije korelacije ($r > 0.3$) između faktora (Costello i Osborne, 2005).

Deskriptivna analiza ljestvice uvjerenja opsežnija je te je usmjerena na široki spektar uvjerenja nastavnika koja će se pojedinačno razmatrati zbog čega nije prioritetno predviđeno da se iz iste izvede stabilna faktorska struktura punog obujma te ljestvice. Dakle, ljestvica općih uvjerenja i stavova nastavnika o matematičkom obrazovanju dominatno je usmjerena prema nešto širem okviru stavova i uvjerenja nastavnika te smo, za razliku od drugih dviju ljestvica istraživačkog upitnika pri analizi glavnih komponenata, postupcima faktorske analize početnu ljestvicu uvjerenja prilično smanjili (s 32 tvrdnje na 13 tvrdnji) pa se ispitivane korelacije među faktorima te ljestvice odnose samo na uži dio tog dijela upitnika.

Potom će se analizirati korelacije unutar svake od triju faktorskih struktura kako bismo dobili jasniju podlogu za daljnje ispitavanje povezanosti pojedinih faktorskih struktura što će se zaključiti regresijskim analizama kako bismo, osim povezanosti, utvrdili i potencijalne prediktorske konstrukte u razmatranju kompetencija nastavnika. U provedbi regresijske analize, odnosno pri evaluaciji modela ispitat će se koeficijent multiple determinacije R^2. Radi se o statističkoj mjeri koja se odnosi na udio varijance u zavisnoj (kriterijskoj) varijabli koje se mogu pojasniti u nezavisnoj varijabli promatranog regresijskog modela. Tu će se istaknuti mjera R, R^2 te prilagođena mjera od R^2.

Za svaki regresijski model provest će se jednosmjerna analiza varijance (ANOVA) kojom ćemo odrediti u kojoj mjeri regresijske jednažbe predviđaju zavisne varijable što će biti ključni kriterij razmatranja pojedinih regresijskih jednadžbi na osnovi p-vrijednosti, odnosno statističke značajnosti *F*-distribucije danog modela. Također, pri određivanju prediktorskih varijabli koristit će se standaridizirani regresijski beta (β) koeficijenti koji predstavljaju veličinu promjene zavisne varijable izraženu u dijelovima standardne devijacije pri jediničnom porastu standardizirane vrijednosti nezavisne varijable. U završnim kombiniranim regresijskim analizama utvrdit će se jesu li sociodemografska obilježja bolji prediktori od stavova i uvjerenja nastavnika u samoprocjenama nastavnika te, naposljetku, koji su čimbenici i/ili obilježja nastavnika najbolji prediktori njihovih nastavnih i izvannastavnih praksi relevantnih za kvalitetu nastavnog procesa.

4. REZULTATI ISTRAŽIVANJA

4.1 Uzorak ispitanika i osnovna sociodemografska obilježja

Ovim smo istraživanjem planirali obuhvatiti 450 - 500 učitelja i nastavnika matematike s područja cijele Republike Hrvatske. Ciljana skupina ispitanika bili su nastavnici matematike koji rade u srednjim školama i učitelji matematike koji rade u predmetnoj nastavi. Od predviđenog uzorka, konačna se brojka potpuno ispunjenih anketa svela na 348 nastavnika i učitelja zato što smo uz nepotpuno ispunjene ankete iz daljnjih analiza izuzeli i četrdesetak učitelja koji nisu završili studij s pojačanom matematikom (a rade u razrednoj nastavi) zbog čega se nisu uklopili u okvire i ciljeve ovog istraživanja. Od 348 nastavnika u istraživanju je sudjelovalo 287 nastavnica (82.5 %) i 61 nastavnik (17.5 %).

Tablica 1. 1 Struktura sudionika istraživanja prema godinama radnog staža

	Frekvencije	Postotci
0 - 5	74	21.3
6 - 15	81	23.3
16 - 29	122	35.1
30 - 45	71	20.4
Ukupno:	348	100.0

Struktura ispitanika prema duljini radnog staža bila je sljedeća (tablica 1.1): 21 % nastavnika do 5 godina radnog staža, 22 % nastavnika sa stažem između 6 i 15 godina, 35 % nastavnika sa stažem između 16 i 29 godine, a 20 % nastavnika s više od 30 godina radnog staža.

Tablica 1. 2: *Struktura sudionika istraživanja prema završenom inicijalnom obrazovanju*

	Frekvencije	Postotci
PMF (nastavnički smjer)	198	56.9
PMF (inženjerski smjer)	72	20.7
Učiteljski fakultet	43	12.4
Ostalo	35	10.1
Ukupno:	348	100.0

Većina ispitanika završila je Prirodoslovno-matematički fakultet (PMF), Odsjek za matematiku, od kojih je 198 nastavnika (57 %) završilo nastavnički smjer, a 72 nastavnika (21 %) završilo je inženjerski smjer (tablica 2). Od ostalih ispitanika njih 43 (12.4 %) završilo je Učiteljski fakultet, a ostalih 35 (10 %) završilo je ili bivšu Pedagošku akademiju ili Fakultet za odgojne i obrazovne znanosti u Osijeku ili Filozofski fakultet u Rijeci - smjer matematika i informatika.

Tablica 1. 3: *Struktura sudionika istraživanja prema radnom mjestu*

	Frekvencije	Postotci
Osnovna škola (predmetna nastava)	136	39.1
Srednja strukovna škola	105	30.2
Gimnazija	106	30.5
Visoko učilište ili fakultet	1	.3
Ukupno:	348	100.0

Što se tiče radnog mjesta ispitanika, imamo dosta ujednačenu situaciju zato što u osnovnoj školi u predmetnoj nastavi radi 136 nastavnika (39 %), u srednjim strukovnim školama radi 105 nastavnika (30 %) te 106 nastavnika (30 %) koji rade u gimnazijama.

Tablica 1. 4: *Stečena dodatna naobrazba/napredovanje u zvanju*

	Frekvencije	Postotci
Profesor/učitelj mentor	70	20.1
Profesor/učitelj savjetnik	49	14.1
Magisterij i/ili doktorat znanosti	3	0.9
Ništa od navedenoga	226	64.9
Ukupno:	348	100.0

U tablici 1.4 prikazano je koliko je nastavnika svojim stručnim usavršavanjem i profesionalnim razvojem steklo statuse mentora i savjetnika te onih koji su završili magisterij i/ili doktorat znanosti. Uzmemo li u obzir kako je među ispitanicima bilo 74 nastavnika (21 %) koji imaju do pet godina radnog staža te još nisu u mogućnosti steći status mentora ili savjetnika, tada je postotni udio mentora i savjetnika potrebno razmotriti i unutar brojke ispitanika koja isključuje mlađe nastavnike koji to još ne mogu biti.

U tom slučaju, 70 mentora čini 26 %, a 49 savjetnika čini 18 % nastavnika koji imaju dovoljno radnog staža kako bi napredovali u zvanju, a to je ukupno 44 % nastavnika koji su napredovali u zvanju.

Tablica 1. 5: *Broj ispitanika po županijama*

Županija	Broj ispitanika po županiji	Postotci
Bjelovarsko-bilogorska županija	9	2.6
Brodsko-posavska županija	10	2.9
Dubrovačko-neretvanska	10	2.9
Istarska	32	9.2
Karlovačka	5	1.4
Koprivničko-križevačka	7	2.0
Krapinsko-zagorska	15	4.3
Međimurska	16	4.6
Osječko-baranjska	15	4.3
Požeško-slavonska	4	1.1
Primorsko-goranska	20	5.7
Sisačko-moslavačka	6	1.7
Splitsko-dalmatinska	26	7.5
Varaždinska	34	9.8
Virovitičko-podravska	6	1.7
Vukovarsko-srijemska	9	2.6
Zadarska	6	1.7
Zagrebačka	111	31.9
Šibensko-kninska	7	2.0
Ukupno:	348	100.0

Od svih županija na području Republike Hrvatske, jedino nisu sudjelovali nastavnici iz Ličko-senjske županije. Od 198 nastavnika koji su završili nastavnički smjer na PMF-u, njih 30 % radi u osnovnim školama, 32 % radi u srednjim strukovnim školama, 37 % radi u gimnazijama te jedna osoba radi u visokoškolskoj ustanovi (tablica 1.6). Od 72 nastavnika koji su završili inženjerski smjer na PMF-u, njih 50 % radi u srednjim strukovnim školama, 35 % radi u gimnazijama te 15 % radi u osnovnim školama (tablica 1.6). Od 43 nastavnika koji su završili Učiteljski fakultet, njih 95 % radi u osnovnim školama te 5 % radi u gimnazijama (tablica 1.6).

Tablica 1. 6: *Struktura nastavnika po radnom mjestu s obzirom na inicijalno obrazovanje*

		Inicijalno obrazovanje			
		PMF (nastavnički smjer)	PMF (inženjerski smjer)	Učiteljski fakultet	Ostalo
Radno mjesto	Osnovna škola (predmetna nastava)	60	11	41	24
	Srednja strukovna škola	64	36	0	5
	Gimnazija	73	25	2	6
	Visoko učilište ili fakultet	1	0	0	0
	Ukupno:	198	72	43	35

Od 136 nastavnika koji rade u osnovnim školama, njih 19 % napredovalo je u status mentora, 15 % steklo je status savjetnika, 1 % ima magisterij ili doktorat znanosti, a njih 64 % nije napredovalo u zvanju (tablica 1.7). Slična je situacija i kod nastavnika koji rade u srednjim strukovnim školama u kojima je njih 16 % steklo status mentora, 10 % steklo je status savjetnika, a preostalih 74 % nije napredovalo u zvanju. Također, prema tablici 1.7, utvrđeno je kako je 25 % nastavnika koji rade u gimnazijama napredovalo u status mentora, 17 % steklo je status savjetnika, 1 % ima magisterij ili doktorat znanosti, a preostalih 57 % nije napredovalo u zvanju.

Tablica 1. 7: *Struktura nastavnika po stečenoj dodatnoj naobrazbi s obzirom na inicijalno obrazovanje*

	Stečena dodatna naobrazba				
	Profesor/ učitelj mentor	Profesor/učitelj savjetnik	Magisterij ili doktorat znanosti	Ništa od navedenoga	Ukupno
Osnovna škola (predmetna nastava)	26	20	2	88	136
Srednja strukovna škola	17	11	0	77	105
Gimnazija	26	18	1	61	106
Visoko učilište ili fakultet	1	0	0	0	1
Ukupno:	70	49	3	226	348

Prema tablici 1.8, od 198 nastavnika koji su završili nastavnički smjer na PMF-u, njih 17 % su muškarci, a 83 % su žene. Na inženjerskom smjeru na PMF-u nešto je više muških nastavnika, no ipak ih je znatno manje (24 % nastavnika naspram 76 % nastavnica koje su završile isti studij).

Tablica 1. 8: *Struktura nastavnika po spolu s obzirom na inicijalno obrazovanje*

	Inicijalno obrazovanje				Ukupno
	PMF (nastavnički smjer)	PMF (inženjerski smjer)	Učiteljski fakultet	Ostalo	
Muški	34	17	4	6	61
Ženski	164	55	39	29	287
Ukupno:	198	72	43	35	348

Također očekivano, 10 % nastavnika koji su završili Učiteljski fakultet te 90 % nastavnica, odnosno učiteljica. Od ostalih studija iz ispitivanog uzorka njih 17 % je nastavnika te 83 % nastavnica (prema tablici 1.8).

Podatci iz tablice 1.9 očekivano su konzistentni s udjelom nastavnica koje su u većini (90 %) završile Učiteljski fakultet i većina radi u osnovnim školama pa se pokazalo kako je od 136 nastavnika koji rade u osnovnim školama 15 % nastavnika i 85 % nastavnica.

Tablica 1. 9: *Struktura nastavnika na radnom mjestu s obzirom na spol*

	Radno mjesto			Ukupno
	Osnovna škola (predmetna nastava)	Srednja strukovna škola	Gimnazija	
Muški	20	19	21	60
Ženski	116	86	85	287
Ukupno:	136	105	106	347

S obzirom na to kako je u cjelokupnom uzorku istraživanja 82 % žena, distribucija po spolu nije značajno drugačija u gimnazijama i strukovnim školama. Dakle, u strukovnim školama radi 18 % nastavnika i 82 % nastavnica, a u gimnazijama 20 % nastavnika i 80 % nastavnica (tablica 1.9).

Tablica 1. 10: *Struktura nastavnika u stečenoj dodatnoj naobrazbi s obzirom na spol*

	Stečena dodatna naobrazba				Ukupno
	Profesor/učitelj mentor	Profesor/učitelj savjetnik	Magisterij ili doktorat znanosti	Ništa od navedenoga	
Muški	13	10	0	38	61
Ženski	57	39	3	188	287
Ukupno:	70	49	3	226	348

Prema tablici 1.10, pokazalo se kako je od ukupnog uzorka muških nastavnika njih 21 % steklo status mentora, njih 16 % steklo je status savjetnika, a 63 % nije napredovalo u zvanju. S druge strane, 20 % nastavnica napredovalo je u status mentora, 14 % u status savjetnika, 1 % ima magisterij ili doktorat znanosti, a 65 % nije napredovalo u zvanju.

4.2 Deskriptivna analiza

4.2.1. Deskriptivna analiza ljestvice uvjerenja i stavova nastavnika

Prvo dio instrumenta sastoji se od uvjerenja i stavova nastavnika o nastavi i obrazovanju općenito te o specifičnostima i problematičnim područjima matematičkog obrazovanja u školskom, obiteljskom i širem društvenom kontekstu (tablica 2.1). Navedenim trvdnjama/varijablama pridružena je peterostupanjska ljestvica procjene Likertova tipa (1 = uopće se ne slažem; 2 = ne slažem se; 3 = niti se slažem niti se ne slažem; 4 = slažem se; 5 = u potpunosti se slažem). Isto je tako bilo za preostalih 12 pitanja (od 1.21 do pitanja 1.32) koja su formulirana zasebno zbog konteksta unutar kojeg su na Likertovoj ljestvici ispitanici trebali odrediti u kojoj se mjeri slažu kako nastavnik matematike mora posjedovati određene kvalitete kako bi kompetentno izvodio nastavu. U nastavku (tablica 2.1) slijedi analiza tvrdnji iz ljestvice uvjerenja i stavova nastavnika prema osnovnim parametrima deskriptivne statistike (aritmetička sredina, mod i standardna devijacija) te će se interpretirati dominantne vrijednosti odgovora po pojedinim tvrdnjama te one na kojima su nastavnici imali najviše razine (ne)slaganja.

Tablica 2. 1: *Ljestvica uvjerenja nastavnika o nastavi i obrazovanju općenito te o specifičnostima određenih područja matematičkog obrazovanja*

Tvrdnje	Aritmetička sredina	Mod	Standardna devijacija
1.1 Nastava matematike trebala bi se više temeljiti na rješavanju problemskih zadataka nego na standardnim proceduralnim zadatcima.	4.02	4	.76
1.2 Korištenje didaktičkih materijala i pomagala potrebno je zbog unaprjeđenja kvalitete procesa učenja i poučavanja matematike.	4.36	5	.70
1.3 Prostorna organizacija razrednog odjela utječe na kvalitetu učenja i poučavanja.	3.88	4	.80
1.4 Matematički način razmišljanja ima veću obrazovnu vrijednost od usvojenosti pojedinih matematičkih sadržaja.	4.27	5	.79
1.5 Grupnim oblicima rada postižu se kvalitetniji odgojni ishodi nego frontalnim oblikom rada.	3.47	3	.85
1.6 Grupnim oblicima rada postižu se kvalitetniji obrazovni ishodi nego frontalnim oblikom rada.	3.25	3	.84
1.7 Svladavanje matematičkih sadržaja potrebno je kako bi učenici mogli logički razmišljati i zaključivati u različitim situacijama iz svakodnevice.	4.44	5	.63
1.8 Nastavni proces treba se planirati prema smjernicama Nacionalnog okvirnog kurikuluma.	3.81	4	.77
1.9 Primjenjivost matematičkih znanja unutar matematike ima prioritet nad primjenjivošću u svakodnevnim situacijama.	2.80	2	.91

1.10 Ostvarivanje korelacija matematičkih sadržaja sa svakodnevnim životom podiže kvalitetu usvojenih znanja.	4.41	5	.61
1.11 Korelacije matematike s ostalim predmetima i disciplinama nužne su za podizanje kvalitete učenja.	4.23	4	.66
1.12 Povijesni razvoj matematike nedovoljno je zastupljen u nastavi matematike.	3.68	4	.94
1.13 Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi.	3.69	4	1.05
1.14 Učenik prosječnih sposobnosti može imati ocjenu „odličan“ u rirodoslovno-matematičkoj gimnaziji.	2.61	2	1.06
1.15 Učenik koji ima problema s računanjem - tablicom množenja može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji.	1.90	1	1.13
1.16 Matematički daroviti učenici imat će uspješnu karijeru u matematici bez obzira na potporu okoline.	2.82	3	1.00
1.17 Razvijene radne navike i motivacija dovoljni su za visoke uspjehe u matematičkim natjecanjima.	2.94	2	.97
1.18 Matematički daroviti učenici motiviraniji su za učenje matematike od ostalih učenika.	3.57	4	.99
1.19 Učenici nisu bolji matematičari od učenica.	3.89	5	1.04
1.20 Komunikacija između nastavnika utječe na kvalitetu njihova rada s učenicima.	4.10	4	.87
Na pitanja 1.21 - 1.32 nastavnici su po ljestvici Likertova tipa trebali odgovoriti: „u kojoj mjeri se slažete kako je za kvalitetnu nastavu matematike potrebno da nastavnik…:“			
1.21 Uvažava individualne razlike pri ocjenjivanju i očekivanjima koje postavlja pred učenike.	3.83	4	.83
1.22 Daje učenicima anonimni evaluacijski upitnik kako bi iznijeli svoje kritike, mišljenja i prijedloge o aktivnostima te načinima rada u nastavi.	3.84	4	.95
1.23 Poznaje socio-kulturni i ekonomski status učenika i njihovih roditelja.	3.32	4	1.01
1.24 Posjeduje visoko razvijene komunikacijske vještine.	4.42	5	.62
1.25 Koristi humor u poučavanju matematike.	4.22	4	.71
1.26 Potiče pozitivne stavove prema učenju matematike.	4.68	5	.503
1.27 Zna kako ukloniti i prevenirati negativne stavove i uvjerenja učenika u kontekstu nastave matematike.	4.44	5	.630
1.28 Smatra kako svaki učenik može zavoljeti matematiku.	3.85	4	.899
1.29 Smatra kako učenici moraju voljeti matematiku da bi bili uspješni u njoj.	3.20	3	.957
1.30 Razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.	3.81	4	.847
1.31 Razumije temeljne smjernice koncepta cjeloživotnog učenja.	4.04	4	.764
1.32 Razumije odgojno-obrazovne ciljeve i učenička postignuća po svim obrazovnim ciklusima matematičkog područja.	4.16	4	.743

Najviši stupanj afirmativnog slaganja u kojem se nastavnici u potpunosti slažu ili se uglavnom slažu pokazalo se u sljedećim tvrdnjama (tablica 2.2):

Tablica 2. 2: *Izdvojene tvrdnje s najvišim razinama slaganja nastavnika*

Tvrdnja	Aritmetička sredina	Mod	Standardna devijacija
1.2 Korištenje didaktičkih materijala i pomagala potrebno je zbog unaprjeđenja kvalitete procesa učenja i poučavanja matematike.	4.36	5	.701
1.4 Matematički način razmišljanja ima veću obrazovnu vrijednost od usvojenosti pojedinih matematičkih sadržaja.	4.27	5	.794
1.7 Svladavanje matematičkih sadržaja potrebno je kako bi učenici mogli logički razmišljati i zaključivati u različitim situacijama iz svakodnevice.	4.44	5	.626
1.10 Ostvarivanje korelacija matematičkih sadržaja sa svakodnevnim životom podiže kvalitetu usvojenih znanja.	4.41	5	.613
1.11 Korelacije matematike s ostalim predmetima i disciplinama nužne su za podizanje kvalitete učenja.	4.23	4	.662
1.24 Posjeduje visoko razvijene komunikacijske vještine.	4.42	5	.624
1.25 Koristi humor u poučavanju matematike.	4.22	4	.713
1.26 Potiče pozitivne stavove prema učenju matematike.	4.68	5	.503
1.27 Zna kako ukloniti i prevenirati negativne stavove i uvjerenja učenika u kontekstu nastave matematike.	4.44	5	.630

Gornje tvrdnje pretežno se odnose na komunikacijske vještine nastavnika i mogućnost pozitivnog djelovanja na stavove učenika te na raznovrsnost nastave pri izboru metoda i načina rada kako bi učenici razvili matematički način razmišljanja. To je donekle očekivano budući da se odnosi na metodički pristup koji se već duže vrijeme potiče kao sastavni dio poučavanja, ali je i sastavni dio recentnih razmišljanja o reformi kurikuluma kao i svakog osuvremenjivanja nastave i odgojno-obrazovne prakse.

Što se tiče socijalnih oblika rada u nastavi, pokazalo se kako nastavnici zauzimaju neutralan stav prema tvrdnjama 1.5 i 1.6, odnosno kako se niti slažu niti ne slažu da se grupnim oblicima rada postižu bolji odgojni (M = 3.47) ili obrazovni (M = 3.25) rezultati. Od posebnog su interesa prvog dijela ovog istraživanja stereotipi koji se odnose na tvrdnje od 1.13 do 1.19 kojima se ispituju stavovi i uvjerenja o uvriježenim stereotipima o matematici kao što su rodne razlike te problem nadarenosti i obrazovanosti (više u poglavlju 4.2.1.2).

Dakle, kod tvrdnje 1.1 pokazalo se kako se 76.7 % nastavnika slaže ili se u potpunosti slaže s tvrdnjom kako bi se nastava matematike trebala više temeljiti na rješavanju problemskih zadataka nego na standardnim proceduralnim zadatcima. To je pitanje izravno povezano s pitanjem nastavnih planova i programa te samih kurikuluma matematičkog područja za koje nema istraživanja kao ni konstruktivnih ideja za osuvremenjivanjem prema kvaliteti nasuprot kvantitete. Tvrdnja 1.4 ide u prilog tome da 85 % nastavnika smatra kako matematički način razmišljanja ima veću obrazovnu vrijednost od usvojenosti konkretnih sadržaja.

Tablica 2. 3: *Svladavanje matematičkih sadržaja potrebno je kako bi učenici mogli logički razmišljati i zaključivati u različitim situacijama iz svakodnevice.*

1.7 Svladavanje matematičkih sadržaja potrebno je kako bi učenici mogli logički razmišljati i zaključivati u različitim situacijama iz svakodnevice.			
	Učestalost	Postotci	Kumulativni postotci
Uopće se ne slažem	1	.3	.3
Niti se slažem niti se ne slažem	19	5.5	5.7
Slažem se	152	43.7	49.4
U potpunosti se slažem	176	50.6	100.0
Ukupno	348	100.0	

Rezultatima tablice 2.3 utvrđeno je da 94 % nastavnika smatra kako je svladavanje matematičkih sadržaja potrebno kako bi učenici mogli logički razmišljati i zaključivati u različitim situacijama iz svakodnevice. Pri tumačenju ove varijable mora se uočiti kako tvrdnja nije u isključivom kontekstu te nam preostaje pretpostavljati kakvi bi bili odgovori da je umjesto „potrebno“ navedeno „nužno“ ili „dovoljno“. Naime, od 348 nastavnika samo je jedna osoba istaknula kako se uopće ne slaže, a njih se 19, što je svega 5.5 %, niti slaže niti ne slaže. U svakom slučaju, ostaje upitnim jesu li matematički sadržaji doista neophodni za razvoj logičkog razmišljanja u svakodnevnom životu te je li to njihova svrha prema mišljenju ispitanika. To govori kako nastavnici matematike dosta nekritički percepiraju matematičke sadržaje što je indikativno prema njihovu pristupu nastavi i učenicima u kontekstu poučavanja te koliko su skloni kritički propitivati matematičke sadržaje.

Nadalje, oko 70 % nastavnika slaže se kako se nastavni proces treba planirati prema smjernicama Nacionalnog okvirnog kurikuluma, a njih je 28 % suzdržano što se moglo pretpostaviti s obzirom na to da je cijeli odgojno-obrazovni sustav pomno planiran i

isprogramiran do svake nastavne jedinice. Među tvrdnjama s uvriježenim strereotipima pokazuje se kako 68 % nastavnika smatra da učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi, 19 % je suzdržanih te 13 % koji se ne slažu. Međutim, samo njih 23 % smatra kako učenik prosječnih sposobnosti može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji, 28 % je suzdržanih, a čak 49 % se ne slaže. U tvrdnjama koje su se odnosile na stereotipe karakteristične za nastavu matematike utvrđena su najviša odstupanja u kojima su sve standardne devijacije bile više od 1 na peterostupanjskoj Likertovoj ljestvici.

Tablica 2. 4: *Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi*.

	Frekvencije	Postotci
Uopće se ne slažem	10	2.9
Ne slažem se	46	13.2
Niti se slažem niti se ne slažem	65	18.7
Slažem se	148	42.5
U potpunosti se slažem	79	22.7
Ukupno	348	100.0

Tablica 2. 5: *Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u prirodoslovno-matematičkoj gimnaziji*“

	Frekvencije	Postotci
Uopće se ne slažem	55	15.8
Ne slažem se	114	32.8
Niti se slažem niti se ne slažem	99	28.4
Slažem se	71	20.4
U potpunosti se slažem	9	2.6
Ukupno	348	100.0

Iz tablice 2.4 očito je kako nastavnici imaju donekle pozitivan stav prema sposobnostima učenika budući da se njih 68 % slaže ili se potpuno slaže s tvrdnjom kako učenici prosječnih sposobnosti mogu imati ocjenu odličan u osnovnoj školi. Međutim, iz tablice 2.5 u tvrdnji 1.14 pokazalo se kako isto smatra manje od četvrtine nastavnika, njih 23 %, od čega samo 3 % nastavnika koji se potpuno slažu kako učenik prosječnih sposobnosti može imati ocjenu odličan u prirodoslovno-matematičkoj gimnaziji. Uzmemo li u obzir kako termin „prosječan“ podrazumijeva većinu populacije čiji su kapaciteti relativno blizu prosjeka (68 % oko aritmetičke sredine), to implicira kako nastavnici smatraju da su sposobnosti i inteligencija

dominantniji preduvjet za uspjeh nego radne navike, kontinuitet i motivacija za učenje. Također se postavlja pitanje jesu li nastavnici kroz formalno obrazovanje, stručno usavršavanje i profesionalni razvoj promišljali o specifičnostima i raznolikosti djece, odnosno ljudi koji su izvrsni u matematici i završili fakultete u matematici ili srodnim područjima te koliko su promišljali o toj problematici bilo zbog sebe ili svojih učenika.

Naime, nastavnik koji ima određenu vrstu pedagoškog optimizma ne smije biti ograničen u tim pogledima zato što time svojim učenicima ograničava obrazovne perspektive. Poznato je kako nastavnici koji imaju pozitivan i optimističan stav prema svojim učenicima više truda i vremena ulažu u pomoć učenicima pri učenju, imaju viša očekivanja (Hattie, 2009) te, naposljetku, učenici postižu bolje rezultate (Rosenthal i Jacobsen, 1968). S druge strane, isto se može povezati s pojavom stručnog egoizma kod nastavnika. Ukoliko nastavnici smatraju kako samo djeca s posebnim, tj. iznadprosječnim sposobnostima mogu biti i postati izvrsna u matematici, to rezultira time da i sebe percipiraju kao takve. Za nastavu matematike takva su uvjerenja potencijalno opasna za učenike te je upitno u kojoj su mjeri nastavnici takvih uvjerenja osposobljeni za motivaciju učenika te imaju li podupirući stav prema učenicima.

S druge strane, učenici s posebnim odgojno-obrazovnim potrebama negdje su na granici između stereotipa i (ne)pripremljenosti nastavnika za detekciju i rad s takvim učenicima. U kontekstu nastave matematike to se primarno odnosi na djecu s diskalkulijom koja su prepoznatljiva po odstupanju aritmetičkih i općih intelektualnih vještina i sposobnosti.

Tablica 2. 6: *Učenik koji ima problema s usvajanjem tablice množenja može imati ocjenu odličan u prirodoslovno-matematičkoj gimnaziji*

	Frekvencije	Postotci	Kumulativni postotci
Uopće se ne slažem	173	49.7	49.7
Ne slažem se	89	25.6	**75.3**
Niti se slažem niti se ne slažem	47	13.5	88.8
Slažem se	25	7.2	96.0
U potpunosti se slažem	14	4.0	100.0
Ukupno	348	100.0	

Podatci iz tablice 2.6 pokazuju kako nastavnici nisu upoznati sa specifičnostima diskalkulije te kako za uspjeh u srednjoškolskoj matematici do izražaja postupno dolazi sve više sposobnosti, vještina i radnih navika koje nisu toliko određene vještinama računanja bez kalkulatora što je više prisutno u osnovnim školama. Premda gornja tvrdnja nije direktno određena kao kriterij prepoznavanja diskalkulije (ima djece koja nisu vješta u računanju i jednako tako u drugim

sposobnostima i vještinama pa ih se svrstava u tu kategoriju), ali je indikativna za brojne pretpostavke. Međutim, kako je prema Košču (1974) diskalkulija određena kao poremećaj koji se manifestira jedino u području aritmetike te kako se radi o pojedincima prosječnih ili iznadprosječnih intelektualnih sposobnosti, 11 % nastavnika koji su afirmativno odgovorili zabrinjavajući je malen udio što upućuje na nužnost edukacija nastavnika u tom području. S druge strane, kako se diskalkulija dijagnosticira kod učenika koji su u najmanju ruku prosječnih intelektualnih sposobnosti (Košč, 1974; Sharma, 2001), bilo bi za očekivati kako nastavnici koji razumiju terminološko određenje diskalkulije imaju donekle isto očekivanje kao i u tvrdnji 1.14 u kojem je isto pitanje bilo za učenike prosječnih sposobnosti.

U tvrdnji 1.16 također je utvrđen značajan udio nastavnika koji razmišljaju u skladu sa stereotipima o učenju matematike, to jest kako će matematički daroviti učenici imati uspješnu karijeru u matematici bez obzira na potporu okoline (tablica 2.7) što smatra gotovo 38 % nastavnika, 40 % nastavnika se niti slažu niti ne slažu, a svega 22 % nastavnika se ne slaže i uopće ne slaže s tom tvrdnjom.

Tablica 2. 7: *Matematički daroviti učenici imat će uspješnu karijeru u matematici bez obzira na potporu okoline.*

	Frekvencije	Postotci
Uopće se ne slažem	20	5.7
Ne slažem se	58	16.7
Niti se slažem niti se ne slažem	139	39.9
Slažem se	101	29.0
U potpunosti se slažem	30	8.6
Ukupno	348	100.0

Iz tablice 2.7 razvidno je kako nastavnici nisu dovoljno educirani o darovitim učenicima te ne uvažavaju radne navike, opće intelektualne kapacitete, motivaciju i svekolike čimbenike iz obiteljskog i društvenog okruženja za koje je dokazano kako su dominantni prediktori uspjeha (darovitih) učenika. Dakle, čak 38 % nastavnika se slaže ili se u potpunosti slaže kako će matematički daroviti učenici imati uspješnu karijeru u matematici bez obzira na okolinske čimbenike, njih je 40 % suzdržanih (niti se slažu niti se ne slažu) te samo 22 % onih koji se ne slažu. Naime, matematička anksioznost ne zaobilazi bolje i uspješnije učenike te su brojna istraživanja potvrdila kako i objektivno sposobni učenici često razvijaju matematičku anksioznost, slijedom čega i izbjegavaju fakultete iz STEM područja (Hembree, 1990; Sheffield i Hunt, 2007).

Glede rodnih stereotipa, pokazuje se kako među nastavnicima ne vlada mišljenje karakteristično za stereotipe zato što se čak 35 % nastavnika u potpunosti slaže i 31 % se slaže kako dječaci nisu bolji u matematici od djevojčica. Svega 10 % nastavnika se ne slaže s tom tvrdnjom pa je očito kako nastavnici nisu skloni rodnim stereotipima.

Tablica 2. 8: *Učenici nisu bolji matematičari od učenica*.

	Frekvencije	Postotci
Uopće se ne slažem	8	2.3
Ne slažem se	26	7.5
Niti se slažem niti se ne slažem	84	24.1
Slažem se	108	31.0
U potpunosti se slažem	**122**	**35.1**
Ukupno	348	100.0

Testiranje razlika među ispitanicima s obzirom na spol, inicijalno obrazovanje, radni staž, stečenu dodatnu naobrazbu te radno mjesto nastavnika

Analizu cjelokupne ljestvice uvjerenja u nastavku ćemo interpretirati i objediniti zajedno s testiranjem statističke značajnosti u razlikama redom po tvrdnjama s obzirom na nezavisne varijable koristeći se jednosmjernom analizom varijance (One-way ANOVA), post-hoc testovima i T-testom (na binarnim varijablama):

a) spol (poglavlje 4.2.1.1)
b) inicijalno obrazovanje (poglavlje 4.2.1.2)
c) radni staž (poglavlje 4.2.1.3)
d) stečena dodatna naobrazba (poglavlje 4.2.1.4)
e) radno mjesto (poglavlje 4.2.1.5).

4.2.1.1 Razlike s obzirom na spol

Od 348 nastavnika, u istraživanju je sudjelovalo 287 nastavnica (82.5 %) i 61 nastavnik (17.5 %). U nastavku slijedi analiza odgovora u kojoj su istaknute tvrdnje (vidi tablicu) za koje se pokazalo kako postoje razlike u stavovima i uvjerenjima s obzirom na spol na razini statističke značajnosti od 5 %.

Tablica 2. 9: *Razlike u stavovima i uvjerenjima s obzirom na spol nastavnika (analiza varijance)*

Tvrdnje	F-omjer	Stat. znač.
1.2 Korištenje didaktičkih materijala i pomagala potrebno je zbog unaprjeđenja kvalitete procesa učenja i poučavanja matematike.	5.033	.025*
1.7 Svladavanje matematičkih sadržaja potrebno je kako bi učenici mogli logički razmišljati i zaključivati u različitim situacijama iz svakodnevice.	6.230	.013*
1.8 Nastavni proces treba se planirati prema smjernicama Nacionalnog okvirnog kurikuluma.	7.044	.008**
1.10 Ostvarivanje korelacija matematičkih sadržaja sa svakodnevnim životom podiže kvalitetu usvojenih znanja.	5.435	.020*
1.11 Korelacije matematike s ostalim predmetima i disciplinama nužne su za podizanje kvalitete učenja.	8.058	.005**
1.13 Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi.	6.532	.011*
1.26 Potiče pozitivne stavove prema učenju matematike.	5.563	.019*
1.28 Smatra kako svaki učenik može zavoljeti matematiku.	8.033	.005**
1.29 Smatra kako učenici moraju voljeti matematiku da bi bili uspješni u njoj.	4.758	.030*
1.30 Razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.	5.193	.023*
1.31 Razumije temeljne smjernice koncepta cjeloživotnog učenja.	7.430	.007**

** $p < 0.01$, * $p < 0.05$

U tablici 2.9 izdvojene su tvrdnje za koje smo jednosmjernom analizom varijance utvrdili na razini statističke značajnosti od 0.05 i 0.01 kako postoje razlike između nastavnica i nastavnika u odgovorima na navedena pitanja. Sve istaknute razlike utvrđene su i t-testom usporedbi ispitanika s obzirom na spol. U nastavku slijedi analiza frekvencija istaknutih tvrdnji prema odgovorima koje su dali pripadnici oba spola kako bismo imali jasniji uvid u utvrđene razlike.

Tvrdnja 1.2: *Korištenje didaktičkih materijala i pomagala potrebno je zbog unaprjeđenja kvalitete procesa učenja i poučavanja matematike.*

Gornja tvrdnja ima visoke razine slaganja u oba spola, no pokazuje se kako se 50 % nastavnica u potpunosti slaže s tvrdnjom, a isto vrijedi samo za 33 % nastavnika. Međutim, objedinimo li afirmativne tvrdnje oba spola, pokazuje se kako su s 90 % slaganja svi suglasni s tvrdnjom (tablica 2.10).

Tablica 2. 10: *Korištenje didaktičkih materijala i pomagala potrebno je zbog unaprjeđenja kvalitete procesa učenja i poučavanja matematike.*

		1.2 Korištenje didaktičkih materijala i pomagala potrebno je zbog unaprjeđenja kvalitete procesa učenja i poučavanja matematike.				Ukupno
		Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
Spol	Muški	2	5	34	20	61
	Ženski	5	19	119	144	287
Ukupno		7	24	153	164	348

Jednako kao za tvrdnju 1.2, rezultati upućuju kako se nastavnice u većem broju nego nastavnici u potpunosti slažu s tvrdnjom 1.7, no zbirno gledano razina je slaganja u oba spola visoka što je i prethodno opisano u analizi frekvencija cjelokupnog uzorka (tablica 2.11). Stoga razina statističke značajnosti ovdje upućuje na razliku koja u praktičnom kontekstu nema neku interpretaciju iz koje bismo mogli izvoditi daljnje zaključke.

Tablica 2. 11: *Svladavanje matematičkih sadržaja potrebno je kako bi učenici mogli logički razmišljati i zaključivati u različitim situacijama iz svakodnevice*

		1.7 Svladavanje matematičkih sadržaja potrebno je kako bi učenici mogli logički razmišljati i zaključivati u različitim situacijama iz svakodnevice.				Ukupno
		Uopće se ne slažem	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
Spol	Muški	1	4	33	23	61
	Ženski	0	15	119	153	287
Ukupno		1	19	152	176	348

Prema priloženoj tablici 2.12, za tvrdnju 1.8 nastavnice se u većem broju slažu s tvrdnjom (njih 71 %), a svega se 54 % nastavnika slaže, pored kojih je 38 % koji se niti slažu,niti ne slažu te 8 % koji se ne slažu s tvrdnjom. Prikazane razlike upućuju na to kako su muški nastavnici nešto manje skloni potpunom suglasju izvedbe i planiranja nastave prema kurikulumu.

Tablica 2. 12: *Nastavni proces treba se planirati prema smjernicama Nacionalnog okvirnog kurikuluma*

		1.8 Nastavni proces treba se planirati prema smjernicama Nacionalnog okvirnog kurikuluma.					Ukupno
		Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
Spol	Muški	0	5 (8 %)	23 (38 %)	26 (43 %)	7 (11 %)	61
	Ženski	2 (0.7 %)	6 (2 %)	75 (26 %)	151 (53 %)	53 (18 %)	287
Ukupno		2	11	98	177	60	348

U tvrdnji 1.10 koja se odnosi na uvjerenje postiže li se korelacijom matematičkih sadržaja sa svakodnevnim životom bolja kvaliteta usvojenih znanja, pokazalo se kako se nastavnici u nešto manjoj mjeri odlučuju na potpuno suglasje s tvrdnjom od nastavnica, no svi su prilično jednoglasni u slaganju s tvrdnjom (iznad 90 % u oba spola koji se slažu ili se potpuno slažu).

Tablica 2. 13: *Ostvarivanje korelacija matematičkih sadržaja sa svakodnevnim životom podiže kvalitetu usvojenih znanja*

		1.10 Ostvarivanje korelacija matematičkih sadržaja sa svakodnevnim životom podiže kvalitetu usvojenih znanja.				Ukupno
		Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
Spol	Muški	0	3	40	18	61
	Ženski	1	17	122	147	287
Ukupno		1	20	162	165	348

Slično se ispitivalo tvrdnjom 1.11 u kojoj su nastavnice iskazale visok stupanj slaganja s tvrdnjom: njih 39 % potpuno je suglasno i 51 % suglasno s tvrdnjom (tablica 2.14). Kod nastavnika je 21 % potpuno suglasno, 61 % suglasno, a ostali su odgovori statistički zanemarivi (tablica 2.14). Međutim, razine neslaganja praktički nema, a zbirno gledano razine slaganja prilično su visoke te nema uporišta za izvođenje znakovitih zaključaka.

Tablica 2. 14: *Korelacije matematike s ostalim predmetima i disciplinama nužne su za podizanje kvalitete učenja*

		1.11 Korelacije matematike s ostalim predmetima i disciplinama nužne su za podizanje kvalitete učenja.				Ukupno
		Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
Spol	Muški	1	10	37 (61 %)	13 (21 %)	61
	Ženski	1	29	146 (51 %)	111 (39 %)	287
Ukupno		2	39	183	124	348

U pitanjima kojima se ispituju potencijalna stereotipna uvjerenja nastavnika izdvojila se tvrdnja 1.13 kojom se ispitivalo smatraju li nastavnice i nastavnici kako učenik prosječnih sposobnosti može imati ocjenu odličan iz matematike u osnovnoj školi.

Tablica 2. 15: *Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi*

		1.13 Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi.					Ukupno
		Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
Spol	Muški	0	6 (10 %)	6 (10 %)	31 (50 %)	18 (30 %)	61
	Ženski	10 (4 %)	40 (14 %)	59 (20 %)	117 (41 %)	61 (21 %)	287
Ukupno		10	46	65	148	79	348

Iako se većina nastavnica slaže i potpuno slaže s gornjom tvrdnjom (62 %), kod nastavnika to iznosi 80 % od čega je 10 % suzdržanih te 10 % onih koji se ne slažu s tvrdnjom. S druge strane, kod nastavnica ima 20 % suzdržanih te 18 % onih koji se ne slažu što upućuje kako su nastavnice sklonije tradicionalnom poimanju pitanja sposobnosti i darovitosti za matematiku.

Tvrdnjom 1.29 ispitivalo se u kojoj je mjeri bitno da nastavnik matematike smatra kako učenici moraju voljeti matematiku da bi bili uspješni u njoj te se 51 % muških nastavnika slaže s tvrdnjom, 34 % je suzdržano te 15 % onih koje se ne slaže. Među nastavnicama se 36 % slaže, 40 % je suzdržano te 24 % onih koje se ne slažu s tvrdnjom.

Tablica 2. 16: *U kojoj mjeri se slažete kako je bitno da nastavnik matematike smatra kako učenici moraju voljeti matematiku da bi bili uspješni u njoj*

		1.29 Smatram kako učenici moraju voljeti matematiku da bi bili uspješni u njoj.					
		Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
Spol	Muški	1	7	21	28	4	61
	Ženski	13	56	115	81	22	287
	Ukupno	14	63	136	109	26	348

Iz ovih rezultata može se pretpostaviti kako su muški nastavnici, koji su završili studij matematike, odabrali matematiku zato što su rano ostvarili svojevrsnu sklonost i povezanost s istom, a ne nužno zbog toga što su je zavoljeli s godinama školovanja. U svakom slučaju, takve bi zaključke trebalo dodatno ispitati kako bismo imali jasniji uvid u ove razlike.

U tvrdnjama 1.26 i 1.28 potvrđene su statistički značajne razlike unutar kojih se opet pokazuje prilično značajna razlika u potpunom slaganju kod nastavnica među kojima je više izražena tendencija poticanja pozitivnih stavova učenika prema učenju matematike pri čemu nastavnice češće smatraju kako svaki učenik može zavoljeti matematiku.

Analiza rezultata tvrdnji 1.30 i 1.31 pokazuje kako se nastavnici u nešto manjoj mjeri odlučuju na potpuno suglasje u razumijevanju smjernica koncepta cjeloživotnog učenja i Nacionalnog okvirnog kurikuluma što znači da se manje priklanjaju smjernicama proizašlih iz obrazovno-političkih dokumenata ili možda na taj način izražavaju svojevrsno negodovanje prema istima.

(Tvrdnja 1.30: „U kojoj mjeri se slažete kako je bitno da nastavnik matematike razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.“

Tvrdnja 1.31: „U kojoj mjeri se slažete kako je bitno da nastavnik matematike razumije temeljne smjernice koncepta cjeloživotnog učenja.“)

4.2.1.2 Razlike s obzirom na inicijalno obrazovanje

Većina ispitanika završila je Prirodoslovno-matematički fakultet (Matematički odsjek) među kojima je 198 nastavnika (57 %) završilo nastavnički smjer, a 72 nastavnika (21 %) inženjerski smjer (tablica 2). Od ostalih ispitanika, njih 43 (12.4 %) završilo je Učiteljski fakultet, a ostalih 35 (10 %) završilo je ili bivšu Pedagošku akademiju (PA) ili Fakultetu za odgojne i obrazovne znanosti u Osijeku (FOOZOS) ili Filozofski fakultet u Rijeci (FFRI) - smjer matematika i informatika (tablica 2.17).

Tablica 2. 17: *Struktura sudionika istraživanja prema završenom inicijalnom obrazovanju*

	Frekvencije	Postotci
PMF (nastavnički smjer)	198	56.9
PMF (inženjerski smjer)	72	20.7
Učiteljski fakultet	43	12.4
Ostalo	35	10.1
Ukupno:	348	100.0

U tablici 2.18 izdvojene su tvrdnje za koje smo jednosmjernom analizom varijance na razini statističke značajnosti od 0.05 i 0.01 utvrdili kako postoje razlike između nastavnica i nastavnika na ljestvici uvjerenja.

Tablica 2. 18: *Analiza varijance za uvjerenja nastavnika s obzirom na inicijalno obrazovanje*

Tvrdnje	F-omjer	Stat. značajnost
1.1 Nastava matematike trebala bi se više temeljiti na rješavanju problemskih zadataka nego na standardnim proceduralnim zadatcima.	3.940	.009**
1.5 Grupnim oblicima rada postižu se kvalitetniji odgojni ishodi nego frontalnim oblikom rada.	5.752	.001**
1.9 Primjenjivost matematičkih znanja unutar matematike ima prioritet nad primjenjivošću u svakodnevnim situacijama.	3.380	.018*
1.10 Ostvarivanje korelacija matematičkih sadržaja sa svakodnevnim životom podiže kvalitetu usvojenih znanja.	4.471	.004**
1.12 Povijesni razvoj matematike nedovoljno je zastupljen u nastavi matematike.	3.711	.012*
1.18 Matematički daroviti učenici motiviraniji su za učenje matematike od ostalih učenika.	3.010	.030*
1.28 Smatra kako svaki učenik može zavoljeti matematiku.	3.511	.016*
1.30 Razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.	2.805	.040*

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

S obzirom na to da imamo više grupa nastavnika prema završenom inicijalnom obrazovanju, u nastavku ćemo analizirati istaknute tvrdnje post-hoc Scheffe testom pomoću kojeg ćemo utvrditi između kojih su grupa nastavnika ustanovljene značajne razlike. Za iste ćemo tvrdnje prikazati i analizu frekvencija istaknutih tvrdnji prema odgovorima koje su dali nastavnici prema završenom inicijalnom obrazovanju kako bismo imali jasniji uvid u utvrđene razlike.

Tablica 2. 19: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na incijalno obrazovanje ispitanika*

TVRDNJA	(I) Inicijalno obrazovanje	(J) Inicijalno obrazovanje	Razlika u arit. sredinama (I-J)	Std. Greška	Stat. znač.
1.1 Nastava matematike trebala bi se više temeljiti na rješavanju problemskih zadataka nego na standardnim proceduralnim zadatcima.	Učiteljski fakultet	PMF(nastavnički smjer)	.195	.126	.495
		PMF (inženjerski smjer)	.367	.144	.094
		Ostalo	.513*	.171	.030*
1.5 Grupnim oblicima rada postižu se kvalitetniji odgojni ishodi nego frontalnim oblikom rada.	PMF (nastavnički smjer)	PMF (inženjerski smjer)	.341*	.114	.032*
		Učiteljski fakultet	.033	.140	.997
		Ostalo	.505*	.152	.012*
1.9 Primjenjivost matematičkih znanja unutar matematike ima prioritet nad primjenjivošću u svakodnevnim situacijama.	PMF (nastavnički smjer)	PMF (inženjerski smjer)	-.391*	.124	.020*
		Učiteljski fakultet	-.145	.152	.822
		Ostalo	-.051	.166	.992
1.10 Ostvarivanje korelacija matematičkih sadržaja sa svakodnevnim životom podiže kvalitetu usvojenih znanja.	Učiteljski fakultet	PMF(nastavnički smjer)	.289*	.102	.046*
		PMF (inženjerski smjer)	.406*	.116	.007**
		Ostalo	.383	.137	.052
1.12 Povijesni razvoj matematike nedovoljno je zastupljen u nastavi matematike.	Učiteljski fakultet	PMF (nastavnički smjer)	-.468*	.157	.032*
		PMF (inženjerski smjer)	-.513*	.180	.045*
		Ostalo	-.235	.212	.746
1.28 Smatra kako svaki učenik može zavoljeti matematiku.	PMF (nastavnički smjer)	PMF (inženjerski smjer)	.354*	.122	.041*
		Učiteljski fakultet	-.021	.150	.999
		Ostalo	-.119	.163	.911
1.30 Razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.	PMF (inženjerski smjer)	PMF (nastavnički smjer)	-.198	.116	.403
		Učiteljski fakultet	-.468*	.162	.041*
		Ostalo	-.175	.173	.796

**** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$*

Tablica 2. 20: *Razlike s obzirom na inicijalno obrazovanje u tvrdnji 1.1*

	1.1 Nastava matematike trebala bi se više temeljiti na rješavanju problemskih zadataka nego na standardnim proceduralnim zadatcima.				
	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
PMF (nastavnički smjer)	5	36	99	58	198
PMF (inženjerski smjer)	1	20	37	14	72
Učiteljski fakultet	1	5	19	18	43
Ostalo	1	12	17	5	35
Ukupno	8	73	172	95	348

Tvrdnjom 1.1 pokazala se značajna razlika između nastavnika koji su završili Učiteljski fakultet (30 % se potpuno slaže i 50 % se slaže) te nastavnika iz kategorije *ostalo* koji su znatno manje suglasni s tvrdnjom (14 % potpuno se slaže, 50 % koji se slažu te 34 % koji su suzdržani). S obzirom na to da je 86 % nastavnika s Učiteljskog fakulteta koji se slažu ili se potpuno slažu, razvidno je kako se oni svojim iskustvom rada u osnovnim školama više priklanjaju fundamentalnim vještinama za koje pretpostavljaju da ih učenici moraju bolje uvježbati kako bi bili uspješniji u rješavanju problemskih zadataka. S druge strane, nastavnici koji su završili FFRI, FOOZOS i PA više su skloni suvremenim trendovima i obrazovnim diskusijama kojima se ističe kako naši učenici nisu razvili kritičko mišljenje i nisu postigli razinu primjenjivosti znanja.

Tablica 2. 21: *Razlike s obzirom na inicijalno obrazovanje u tvrdnji 1.5*

	1.5 Grupnim oblicima rada postižu se kvalitetniji odgojni ishodi nego frontalnim oblikom rada.					
	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
PMF (nastavnički smjer)	2	12	75	85	24	198
PMF (inženjerski smjer)	2	7	35	27	1	72
Učiteljski fakultet	0	3	21	11	8	43
Ostalo	1	8	16	7	3	35
Ukupno:	5	30	147	130	36	348

Višestrukim usporedbama u tvrdnji 1.5 nađene su značajne razlike između nastavničkog i inženjerskog te između nastavničkog i nastavnika s ostalih studija. Naime, 13 % nastavnika

nastavničkog smjera potpuno se slaže, a 42 % slaže se s tvrdnjom. Nastavnici inženjerskog smjera ili se potpuno slažu s tvrdnjom, njih 1 %, ili se slažu s tvrdnjom, njih 38 %. S druge strane, nastavnici ostalih studija dominantno su izrazili (47 %) kako se niti slažu niti ne slažu s danom tvrdnjom, a ostali su odgovori praktični normalno distribuirani. S obzirom na to da su hipoteze ovog poglavlja temeljene na razlikama proizašlim iz završenog nastavničkog studija, može se pretpostaviti kako su te razlike izraženije kod mlađih nastavnika te kako se iste s godinama prakse smanjuju među nastavnicima dotičnih studija. To će se detaljnije prikazati u sljedećoj tablici, no potencijalni zaključci neće imati statističku utemeljenost zato što je u podkategorijama nastavnika koji imaju do 5 godina radnog staža premalo nastavnika.

Tablica 2. 22: *Razlike s obzirom na inicijalno obrazovanje i godine radnog stažu u tvrdnji 1.5*

			1.5 Grupnim oblicima rada postižu se kvalitetniji odgojni ishodi nego frontalnim oblikom rada.					Ukupno
Inicijalno Obrazovanje		Radni staž	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
PMF (nastavnički smjer)	Godine radnog staža	**0 - 5**	**0**	**2**	**24**	**13**	**10**	**49**
		6 - 15	0	2	17	24	1	44
		16 - 29	1	5	25	35	7	73
		30 - 45	1	3	9	13	6	32
	Ukupno		2	12	75	85	24	198
PMF (inženjerski smjer)	Godine radnog staža	**0 - 5**	**0**	**3**	**8**	**5**	**0**	**16**
		6 - 15	0	0	4	7	1	12
		16 - 29	1	1	13	9	0	24
		30 - 45	1	3	10	6	0	20
	Ukupno		2	7	35	27	1	72

Iz gornje tablice 2.22 proizlazi kako se upravo mlađi nastavnici koji su završili nastavnički smjer na PMF-u znatno češće slažu, od onih sa završenim inženjerskim smjerom, kako se grupnim oblicima rada postižu kvalitetniji odgojni ishodi. Međutim, s obzirom na prilično malen broj nastavnika koji su u tim kategorijama incijalnog obrazovanja i radnog staža, ovi rezultati nemaju uporište u statistici pri izvođenju zaključaka na temelju prikazanog.

Tvrdnja 1.9 specifična je zbog same percepcije matematičkih sadržaja te matematike kao znanosti u cjelosti. Značajna razlika pokazala se upravo među nastavnicima inženjerskog i nastavničkog studija PMF-a zato što se očekivano pokazalo kako nastavnici sa završenim inženjerskim smjerom smatraju vrijednijim primjenjivost unutar matematike.

Tablica 2. 23: *Razlike s obzirom na inicijalno obrazovanje nastavnika u tvrdnji 1.9*

	1.9 Primjenjivost matematičkih znanja unutar matematike ima prioritet nad primjenjivošću u svakodnevnim situacijama.					
	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
PMF (nastavnički smjer)	8	88 (44 %)	63 (32 %)	35 (18 %)	4 (2 %)	198
PMF (inženjerski smjer)	2	19 (27 %)	26 (36 %)	21 (29 %)	4 (6 %)	72
Učiteljski fakultet	3	12	18	9	1	43
Ostalo	2	13	13	6	1	35
Ukupno	15	132	120	71	10	348

Naime, kako inženjerski smjer ima više kolegija koji su isključivo iz područja matematike, studenti tog smjera imaju više prilika osvijestiti specifičnost matematičkih znanja te proces i važnost izgradnje istih, kao i zadovoljstvo u procesu učenja i shvaćanja tih sadržaja. Za kvalitetu procesa učenja i poučavanja bitno je osvijestiti oba koncepta, no recentne diskusije u obrazovno-političkim krugovima imaju tendenciju isključivo prema primjenjivosti zato što su usmjereni na konačnan rezultat, odnosno na razinu učeničkih postignuća za koja želimo da budu na razini primjenjivosti. Međutim, tu se ne smije izostaviti činjenica kako se već u nižim razredima osnovne škole neki učenici izdvajaju sklonošću prema matematici koja je, među ostalim, proizašla upravo zbog specifičnosti matematičkih sadržaja koji su toj djeci poput igre i zabavnih izazova, a ne zato što su primjenjivi. Kako bismo stekli detaljniji uvid u te razlike, ispitat će se nastavnici iz tih kategorija završenih studija s dodatnom varijablom radnog staža u kojoj će naglasak biti na mlađim nastavnicima. Naime, analizom odgovora nastavnika do 5 godina radnog staža možemo jasnije odrediti kolike su razlike te koliki je utjecaj programske sfere njihova inicijalnog obrazovanja (nastavnički i inženjerski smjer na PMF-u).

Tablica 2. 24: *Razlike s obzirom na inicijalno obrazovanje i radni staž nastavnika u tvrdnji 1.9*

Inicijalno Obrazovanje		Radni staž	1.9 Primjenjivost matematičkih znanja unutar matematike ima prioritet nad primjenjivošću u svakodnevnim situacijama.					Ukupno
			Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
PMF (nastavnički smjer)	Godine radnog staža	0 - 5	1	26	13	7	2	49
		6 - 15	3	16	19	5	1	44
		16 - 29	3	37	19	13	1	73
		30 - 45	1	9	12	10	0	32
	Ukupno		8	88	63	35	4	198
PMF (inženjerski smjer)	Godine radnog staža	0 - 5	0	7	5	3	1	16
		6 - 15	0	2	6	3	1	12
		16 - 29	1	6	10	7	0	24
		30 - 45	1	4	5	8	2	20
	Ukupno		2	19	26	21	4	72

Rezultati ukazuju kako nema zakovitih razlika između mlađih nastavnika koji su završili nastavnički i inženjerski studij na PMF-u.

U tvrdnji 1.10 utvrđene su razlike u percepciji korelacija matematičkih sadržaja sa svakodnevnim od strane nastvnika koji su završili nastavnički i inženjerski studij na PMF-u. Naime, korelacije sadržaja povezane su s primjenom znanja te su stoga utvrđeni stavovi prikazani u tablici 2.24 konzistentni prethodnoj tvrdnji 1.9.

Tablica 2. 25: *Razlike s obzirom na inicijalno obrazovanje nastavnika u tvrdnji 1.10*

	1.10 Ostvarivanje korelacija matematičkih sadržaja sa svakodnevnim životom podiže kvalitetu usvojenih znanja.				
	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
PMF (nastavnički smjer)	0	13	91	94	198
PMF (inženjerski smjer)	0	5	41	26	72
Učiteljski fakultet	0	1	11	31	43
Ostalo	1	1	19	14	35
Ukupno	1	20	162	165	348

Prema tome, utvrđeno je kako nastavnici sa završenim nastavničkim studijem smatraju bitnijim ostvarivanje korelacija sa svakodnevnim životom te kako to podiže kvalitetu znanja učenika.

U tvrdnji 1.12 ističu se nastavnici Učiteljskog fakulteta od kojih se 42 % slaže kako je povijesni razvoj matematike nedovoljno zastupljen u nastavi, s nastavnici oba smjera PMF-a slažu se s tvrdnjom u više od 65 % slučajeva.

Tablica 2. 26: *Razlike s obzirom na inicijalno obrazovanje nastavnika u tvrdnji 1.12*

	1.12 Povijesni razvoj matematike nedovoljno je zastupljen u nastavi matematike.					
	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
PMF (nastavnički smjer)	3	15	58	75	47	198
PMF (inženjerski smjer)	0	3	21	36	12	72
Učiteljski fakultet	1	9	15	13	5	43
Ostalo	2	2	12	14	5	35
Ukupno	6	29	106	138	69	348

Budući da su nastavnici koji su završili nastavnički i inženjerski studij na PMF-u stekli znatno više stručnih znanja i bolje upoznali korpus matematičkih znanja, pretpostavlja se kako su dobili bolji uvid u društveni i povijesni kontekst razvoja matematike.

U tvrdnji 1.28 rezultati pokazuju kako se 50 % nastavnika inženjerskog smjera slaže te se čak 75 % nastavnika nastavničkog smjera slaže s tvrdnjom kako svaki učenik može zavoljeti matematiku.

Tablica 2. 27: *Razlike s obzirom na inicijalno obrazovanje nastavnika u tvrdnji 1.28*

	1.28 Smatram kako svaki učenik može zavoljeti matematiku.					
	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
PMF (nastavnički smjer)	2	8	49	86	53	198
PMF (inženjerski smjer)	1	8	27	22	14	72
Učiteljski fakultet	0	1	15	13	14	43
Ostalo	0	2	4	20	9	35
Ukupno	3	19	95	141	90	348

Sukladno prethodnim analizama razlika između nastavnika iz navedenih kategorija, i ovdje će se prikazati analiza odgovora nastavnika do 5 godina radnog staža iz čega će se dobiti jasniji uvid razlika programske sfere njihova inicijalnog obrazovanja.

Tablica 2. 28: *Razlike s obzirom na inicijalno obrazovanje i radni staž nastavnika u tvrdnji 1.28*

Inicijalno Obrazovanje	Radni staž		1.28 Smatra kako svaki učenik može zavoljeti matematiku.					Ukupno
			Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
PMF (nastavnički smjer)	Godine radnog staža	0 - 5	0	1	10	19	19	49
		6 - 15	1	2	10	19	12	44
		16 - 29	0	5	23	29	16	73
		30 - 45	1	0	6	19	6	32
	Ukupno		2	8	49	86	53	198
PMF (inženjerski smjer)	Godine radnog staža	0 - 5	0	5	4	**3**	**4**	16
		6 - 15	0	0	4	5	3	12
		16 - 29	0	1	11	7	5	24
		30 - 45	1	2	8	7	2	20
	Ukupno		1	8	27	22	14	72

Nastavnici sa završenim nastavničkim smjerom u gotovo 80 % slučajeva slažu se s tvrdnjom kako svaki učenik može zavoljeti matematiku, a to isto smatra svega 43 % nastavnika sa završenim inženjerskim smjerom koji imaju do 5 godina radnog staža.

Kod tvrdnje 1.30: „U kojoj mjeri smatrate bitnim da nastavnik matematike razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.“ Pokazala se statistički značajna razlika između Učiteljskog fakulteta i inženjerskog smjera PMF-a zato što nastavnici Učiteljskog fakulteta znatno važnijim za svoj rad smatraju opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.

Post-hoc Scheffe testom utvrđeno je kako nema razlike među grupama u tvrdnji 1.18: *Matematički daroviti učenici motiviraniji su za učenje matematike od ostalih učenika*.

4.2.1.3 Razlike s obzirom na radni staž

Za metodiku i didaktiku nastave matematike neke su od bitnijih, a možda i najintrigantnijih razlika upravo razlike između mlađih i iskusnijih nastavnika. Naime, kako u našem odgojno-obrazovnom sustavu nedostaje istraživanja koja su metodičkog i didaktičkog karaktera, uvid u razlike između početnika i iskusnijih nastavnika mogu dati nešto širi uvid u samu pripremljenost nastavnika za rad u nastavi, a specifičnost tih razlika možemo interpretirati kao svojevrsnu refleksiju nastavne prakse na stavove i uvjerenja nastavnika čije promjene odražavaju suštinu izazova suvremene nastave matematike unutar kojih mlađi nastavnici nastoje optimizirati metode poučavanja. Za didaktički pristup nastavi nužno je te razlike odrediti, no za praksu i istraživački rad važnije je te razlike razumjeti, odnosno shvatiti kroz što prolaze nastavnici ulaskom u praksu.

Tablica 2. 29: *Struktura ispitanika prema godinama radnog staža*

	Frekvencije	Postotci
0 - 5	74	21.3
6 - 15	81	23.3
16 - 29	122	35.1
30 - 45	71	20.4
Ukupno:	348	100.0

U donjoj tablici 2.30 izdvojene su tvrdnje za koje smo jednosmjernom analizom varijance na razini statističke značajnosti utvrdili kako postoje razlike između nastavnica i nastavnika u odgovorima na navedena pitanja.

Tablica 2. 30: *Analiza varijance za uvjerenja nastavnika s obzirom na radni staž*

Tvrdnje	F-omjer	Stat. značajnost
1.1 Nastava matematike trebala bi se više temeljiti na rješavanju problemskih zadataka nego na standardnim proceduralnim zadatcima.	5.143	.002**
1.3 Prostorna organizacija razrednog odjela utječe na kvalitetu učenja i poučavanja.	2.721	.044*
1.4 Matematički način razmišljanja ima veću obrazovnu vrijednost od usvojenosti pojedinih matematičkih sadržaja.	6.100	.000***
1.8 Nastavni proces treba se planirati prema smjernicama Nacionalnog okvirnog kurikuluma.	4.712	.003**
1.10 Ostvarivanje korelacija matematičkih sadržaja sa svakodnevnim životom podiže kvalitetu usvojenih znanja.	3.620	.013*
1.17 Razvijene radne navike i motivacija dovoljni su za visoke uspjehe u matematičkim natjecanjima.	3.306	.020*
1.20 Komunikacija između nastavnika utječe na kvalitetu njihova rada s učenicima.	4.563	.004**
1.30 Razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.	4.397	.005**

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

S obzirom na to da ima više grupa nastavnika prema dobnim kategorijama radnog staža, u nastavku ćemo analizirati istaknute tvrdnje post-hoc Scheffe testom pomoću kojeg ćemo utvrditi između kojihsu grupa nastavnika ustanovljene značajne razlike. Očekivano su se razlike u istaknutim tvrdnjama pokazale između nastavnika početnika i ostalih nastavnika prema radnom stažu. Za iste ćemo tvrdnje prikazati i analizu frekvencija istaknutih tvrdnji prema odgovorima koje su dali nastavnici prema završenom inicijalnom obrazovanju kako bismo imali jasniji uvid u utvrđene razlike.

Tablica 2. 31: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na radni staž ispitanika*

Tvrdnje	(I) Godine radnog staža	(J) Godine radnog staža	Razlika u arit. sredinama (I-J)	Std. greška	Stat. znač.
1.1 Nastava matematike trebala bi se više temeljiti na rješavanju problemskih zadataka nego na standardnim proceduralnim zadatcima.	0 - 5	6 - 15	.158	.120	.629
		16 - 29	.412*	.110	.003**
		30 - 45	.285	.124	.154

1.3 Prostorna organizacija razrednog odjela utječe na kvalitetu učenja i poučavanja.	0 - 5	6- 15	.269	.128	.221
		16 - 29	.264	.117	.168
		30 - 45	348	.132	.076
1..4 Matematički način razmišljanja ima veću obrazovnu vrijednost od usvojenosti pojedinih matematičkih sadržaja.	0 - 5	6 - 15	.355*	.125	.046*
		16 - 29	.450*	.114	.002**
		30 - 45	.146	.129	.733
1.8 Nastavni proces treba se planirati prema smjernicama Nacionalnog okvirnog kurikuluma.	0 - 5	6 - 15	-.300	.122	.113
		16 - 29	-.358*	.112	.018*
		30 - 45	-.431*	.126	.010*
1.10 Ostvarivanje korelacija matematičkih sadržaja sa svakodnevnim životom podiže kvalitetu usvojenih znanja.	0 - 5	6 - 15	.083	.097	.869
		16 - 29	.093	.089	.783
		30 - 45	.316*	.101	.021*
1.17 Razvijene radne navike i motivacija dovoljni su za visoke uspjehe u matematičkim natjecanjima.	0 - 5	6 - 15	.186	.155	.698
		16 - 29	.411*	.142	.041*
		30 - 45	.092	.160	.954
		16 - 29	.319	.144	.181
1.20 Komunikacija između nastavnika utječe na kvalitetu njihova rada s učenicima.	0 - 5	6 - 15	.382	.137	.054
		16 - 29	.444*	.126	.007**
		30 - 45	.377	.142	.072
1.30 Razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.	0 - 5	6 - 15	-.351	.134	.080
		16 - 29	-.437*	.123	.006**
		30 - 45	-.317	.139	.157

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Iz deskriptivnih podataka očito je kako se 90 % nastavnika početnika slaže s tvrdnjom, 69 % nastavnika od 16 do 29 godina radnog staža slaže se s tvrdnjom, a 28 % niti se slaže niti ne slaže.

Tablica 2. 32: *Razlike s obzirom na godine radnog staža u tvrdnji 1.1*

		1.1 Nastava matematike trebala bi se više temeljiti na rješavanju problemskih zadataka nego na standardnim proceduralnim zadatcima.				Ukupno
		Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
Godine radnog staža	0 - 5	1	7	38	28	74
	6 - 15	1	15	40	25	81
	16 - 29	4	34	61	23	122
	30 - 45	2	17	33	19	71
	Ukupno	8	73	172	95	348

Očito je kako utjecaj radnog iskustva mijenja percepciju nastavnika o jednom od ključnih pitanja metodike nastave matematike koji se tiču tipova zadataka.

Scheffeov test među grupama pokazao je kako u tvrdnji 1.3 nema statistički značajnih razlika između navedenih kategorije po radnom stažu (*na razini 5 % statističke značajnosti*).

Tablica 2. 33: *Razlike s obzirom na godine radnog staža u tvrdnji 1.3*

Dependent Variable	(I) Godine radnog staža	(J) Godine radnog staža	Razlika u arit. sredinama (I-J)	Std. greška	Stat. znač.
1.3 Prostorna organizacija razrednog odjela utječe na kvalitetu učenja i poučavanja.	**0 - 5**	6 - 15	.269	.128	.221
		16 - 29	.264	.117	.168
		30 - 45	348	.132	.076

* $p < 0.05$

U tvrdnji 1.4 nastavnici početnici vrijednijim smatraju matematički način razmišljanja, a stariji nastavnici, koji imaju od 16 do 29 godina radnog staža, također se slažu s time, ali sa znatno višom razinom slaganja. Pretpostavlja se kako su temeljem iskustava rada u nastavi osvijestili važnost kumulativne izgradnje znanja te kako je kontinuitet u radu i stjecanju znanja jedan od temeljnih preduvjeta izvrsnosti.

Tablica 2. 34: *Razlike s obzirom na godine radnog staža u tvrdnji 1.4*

		Matematički način razmišljanja ima veću obrazovnu vrijednost od usvojenosti pojedinih matematičkih sadržaja.					
		Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
Godine radnog staža	0 - 5	0	0	8	18	48	74
	6 - 15	0	2	11	38	30	81
	16 – 29	1	7	15	56	43	122
	30 - 45	0	0	8	27	36	71
Ukupno		1	9	42	139	157	348

U tvrdnji 1.8 razlika se pokazala između nastavnika do pet godina radnog staža i nastavnika koji imaju 16 i više godina staža (tablica 2.35). Navedeno pitanje pomalo je neodređeno pa se ne može konkretno interpretirati, no pokazalo se kako se iskusniji nastavnici, s više od 15 godina staža, više slažu s navedenom tvrdnjom što bi se moglo pripisati tome kako su iskusniji nastavnici svjesniji da nastavni planovi i programi te usmjerenost prema maturi strogo nalažu *što* i *kako* se treba raditi u nastavi.

Tablica 2. 35: *Razlike s obzirom na godine radnog staža u tvrdnji 1.8*

		1.8 Nastavni proces treba se planirati prema smjernicama Nacionalnog okvirnog kurikuluma.					Ukupno
		Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
Godine radnog staža	0 - 5	2	6	25	33	8	74
	6 - 15	0	1	24	44	12	81
	16 - 29	0	2	32	66	22	122
	30 - 45	0	2	17	34	18	71
	Ukupno	2	11	98	177	60	348

Isto se pokazuje i u tvrdnji 1.30 u kojoj se iskusniji nastavnici više slažu kako je bitno da nastanik matematike razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma (tablica 2.36). Stoga se očekuje kako će u faktorskoj analizi ovog dijela istraživačkog upitnika ove dvije varijable biti dio istog faktora, odnosno kako pripadaju nekom širem sklopu uvjerenja unutar kojih se te tvrdnje izdvajaju kao dio konstrukta koji objašnjava njihove stavove i uvjerenja relevantna za kurikulumske odrednice.

Tablica 2. 36: *Razlike s obzirom na godine radnog staža u tvrdnji 1.30*

		1.30 Razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.					Ukupno
		Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
Godine radnog staža	0 - 5	2	8	21	36	7	74
	6 - 15	0	3	23	37	18	81
	16 - 29	0	3	29	61	29	122
	30 - 45	1	3	21	28	18	71
	Ukupno	3	17	94	162	72	348

U tvrdnji 1.10 također je prisutna visoka razina slaganja svih kategorija nastavnika prema radnom stažu, no razlika se pokazala između najmlađih i najikusnijih nastavnika koji nisu pokazali toliko visoku razinu slaganja zato što se tek jedna trećina njih potpuno slaže naspram nastavnika početnika od kojih se 58 % potpuno slaže s tim (tablica 2.37).

Tablica 2. 37: *Razlike s obzirom na godine radnog staža u tvrdnji 1.10*

		1.10 Ostvarivanje korelacija matematičkih sadržaja sa svakodnevnim životom podiže kvalitetu usvojenih znanja.				Ukupno
		Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
Godine radnog staža	0 - 5	0	4	27	43 (58 %)	74
	6 - 15	0	5	35	41	81
	16 - 29	0	4	61	57	122
	30 - 45	1	7	39	24 (34 %)	71
	Ukupno	1	20	162	165	348

To vjerojatno proizlazi iz težnje nastavnika početnika za „idealnom“ nastavom matematike kakvu su željeli kad su i sami bili učenici. No, kroz svoj rad još nisu došli do nekog formiranog stava, koji se često naziva i konzervativnim, kojeg je uglavnom efikasnije i lakše izvoditi u okvirima postojećih nastavnih planova i programa.

Što se tiče percepcije radnih navika i motivacije kao temeljnih preduvjeta za uspjehe u matematičkim natjecanjima, najmanje su se „optimističnim“ izjasnili nastavnici iz najmnogobrojnije skupine koji imaju između 16 i 29 godina radnog staža (tablica 2.38). Naime, njih se čak 46 % ne slaže ili se uopće ne slaže s tom tvrdnjom što je isto kod nastavnika početnika izjavilo nih 30 %.

Tablica 2. 38: *Razlike s obzirom na godine radnog staža u tvrdnji 1.17*

		1.17 Razvijene radne navike i motivacija dovoljni su za visoke uspjehe u matematičkim natjecanjima.					Ukupno
		Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
Godine radnog staža	0 - 5	0	22	25	21	6	74
	6 - 15	2	28	26	21	4	81
	16 - 29	9	47	36	27	3	122
	30 - 45	3	18	27	18	5	71
	Ukupno	14	115	114	87	18	348

Neovisno o tome što se tu radi o učenicima koji postižu iznimna postignuća, suvremeno promišljanje o nastavi i učenicima trebalo bi biti sklonije afirmativnim odgovorima i kontinuiranom promišljanju o neotkrivenim potencijalima učenika i samom shvaćanju izvrsnosti i preduvjetima za aktualizaciju potencijala učenika.

U tvrdnji 1.20 nastavnici početnici očekivano su se u najvećoj mjeri složili kako komunikacija između nastavnika utječe na kvalitetu njihova rada. Naime, mlađi nastavnici u prvim godinama rada u nastavi puno uče kroz formalne i neformalne situacije njihova stručnog djelovanja te se statistički značajnim pokazala razlika između njih i nastavnika koji imaju između 16 i 29 godina radnog staža. No, ohrabruje činjenica kako su u svim skupinama radnog staža visoke razine slaganja.

Tablica 2. 39: *Razlike s obzirom na godine radnog staža u tvrdnji 1.20*

		1.20 Komunikacija između nastavnika utječe na kvalitetu njihova rada s učenicima.					Ukupno
		Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
Godine radnog staža	0 - 5	0	1	9	22	42	74
	6 - 15	1	1	15	41	23	81
	16 - 29	2	7	20	56	37	122
	30 - 45	2	3	5	41	20	71
Ukupno		5	12	49	160	122	348

Međutim, ne može se zaključiti u kojoj se mjeri nastavnici priklanjaju tom tipu usavršavanja pa će se stoga pri analizi ljestvice učestalosti nastavnih i izvannastavnih praksi provjeriti povezanost ovih stavova i uvjerenja s participacijom u raznim oblicima stručnog usavršavanja od kojih se očekuje određena povezanost sa sudjelovanjem u kolegijalnom opažanju nastave.

4.2.1.4 Razlike s obzirom na stečenu dodatnu naobrazbu

U tablici 2.40. prikazano je koliko je nastavnika svojim stručnim usavršavanjem i profesionalnim razvojem steklo statuse mentora i savjetnika te onih koji su završili magisterij i/ili doktorat znanosti. S obzirom na to da su samo tri osobe s magisterijem i/ili doktoratom znanosti, njih nećemo razmatrati u daljnjim analizama zbog nereprezentativnosti uzorka.

Tablica 2. 40: *Struktura ispitanika s obzirom na stečenu dodatnu naobrazbu*

	Frekvencije	Postotci
Profesor/učitelj mentor	70	20.1
Profesor/učitelj savjetnik	49	14.1
Magisterij i/ili doktorat znanosti	3	.9
Ništa od navedenoga	226	64.9
Ukupno:	348	100.0

Naposljetku se pokazalo kako ni u jednoj tvrdnji nema statistički značajnih razlika u uvjerenjima i stavovima nastavnika s obzirom na stečenu dodatnu naobrazbu i napredovanje u zvanju nastavnika.

4.2.1.5 Razlike s obzirom na radno mjesto

Tablica 2. 41: *Struktura ispitanika s obzirom na radno mjesto*

	Frekvencije	Postotci
Osnovna škola (predmetna nastava)	136	39.1
Srednja strukovna škola	105	30.2
Gimnazija	106	30.5
Visoko učilište ili fakultet	1	.3
Ukupno:	348	100.0

Što se tiče radnog mjesta ispitanika, imamo dosta ujednačenu situaciju zato što u osnovnoj školi u predmetnoj nastavi radi 136 nastavnika (39 %), u srednjim strukovnim školama radi 105 nastavnika (30 %) te 106 nastavnika (30 %) koji rade u gimnazijama. Samo je jedna osoba među nastavnicima koja ne radi u srednjoj ili osnovnoj školi te je stoga nećemo razmatrati u analizama odgovora s obzirom na radno mjesto.

Tablica 2. 42: *Analiza varijance za uvjerenja nastavnika s obzirom na radno mjesto*

Tvrdnje	F-omjer	Stat. znač.
1.2 Korištenje didaktičkih materijala i pomagala potrebno je zbog unaprjeđenja kvalitete procesa učenja i poučavanja matematike.	4.103	.017*
1.8 Nastavni proces treba se planirati prema smjernicama Nacionalnog okvirnog kurikuluma.	3.125	.045*
1.9 Primjenjivost matematičkih znanja unutar matematike ima prioritet nad primjenjivošću u svakodnevnim situacijama.	3.109	.046*
1.10 Ostvarivanje korelacija matematičkih sadržaja sa svakodnevnim životom podiže kvalitetu usvojenih znanja.	5.317	.005**
1.13Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi.	3.460	.033*
1.23 Poznaje socio-kulturni i ekonomski status učenika i njihovih roditelja.	11.536	.000***
1.28 Smatra kako svaki učenik može zavoljeti matematiku.	3.570	.029*
1.30 Razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.	8.491	.000***
1.31 Razumije temeljne smjernice koncepta cjeloživotnog učenja.	13.778	.000***
1.32 Razumije odgojno-obrazovne ciljeve i učenička postignuća po svim obrazovnim ciklusima matematičkog područja.	8.430	.000***

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

U tablici 2.42 izdvojene su tvrdnje za koje smo jednosmjernom analizom varijance utvrdili statistički značajne razlike između ispitanika u odgovorima na navedena pitanja. S obzirom na to da imamo više grupa nastavnika prema radnom mjestu, u nastavku ćemo analizirati istaknute tvrdnje post-hoc Scheffe testom pomoću kojeg ćemo utvrditi između kojih su grupa nastavnika ustanovljene značajne razlike. Za iste ćemo tvrdnje prikazati i analizu frekvencija istaknutih tvrdnji prema odgovorima koje su dali nastavnici prema radnom mjestu kako bismo imali jasniji uvid u utvrđene razlike.

Tablica 2. 43: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na radno mjesto ispitanika*

TVRDNJA	(I) Radno mjesto	(J) Radno mjesto	Razlika u arit. sredinama (I-J)	Stad. greška	Stat. znač.
1.2 Korištenje didaktičkih materijala i pomagala potrebno je zbog unaprjeđenja kvalitete procesa učenja i poučavanja matematike.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.245*	.090	.026*
		Gimnazija	.181	.090	.133
1.8 Nastavni proces treba se planirati prema smjernicama Nacionalnog okvirnog kurikuluma.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.211	.100	.110
		Gimnazija	-.029	.100	.960
1.9 Primjenjivost matematičkih znanja unutar matematike ima prioritet nad primjenjivošću u svakodnevnim situacijama.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	-.157	.118	.411
		Gimnazija	-.291*	.117	.048*
1.10 Ostvarivanje korelacija matematičkih sadržaja sa svakodnevnim životom podiže kvalitetu usvojenih znanja.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.220*	.079	.021*
		Gimnazija	.214*	.078	.025*
1.13 Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi.	Gimnazija	Osnovna škola (predmetna nastava)	.242	.136	.205
		Srednja strukovna škola	.372*	.144	.037*
1.23 Poznaje socio-kulturni i ekonomski status učenika i njihovih roditelja.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.499*	.128	.001**
		Gimnazija	.538*	.127	.000***
1.28 Smatra kako svaki učenik može zavoljeti matematiku.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.111	.116	.632
		Gimnazija	.308*	.116	.030*
1.30 Razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.443*	.108	.000***
		Gimnazija	.222	.108	.120
1.31 Razumije temeljne smjernice koncepta cjeloživotnog učenja.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.498*	.096	.000***
		Gimnazija	.279*	.096	.015*
1.32 Razumije odgojno-obrazovne ciljeve i učenička postignuća po svim obrazovnim ciklusima matematičkog područja.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.388*	.095	.000***
		Gimnazija	.189	.094	.135

**** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$*

Iz tablice 2.44 vidljivo je kako nastavnici koji rade u osnovnim školama imaju bitno drugačija uvjerenja od nastavnika koji rade u srednjim strukovnim školama po pitanju korištenja didaktičkih materijala.

Tablica 2. 44: *Razlike s obzirom na radno mjesto u tvrdnji 1.2*

	1.2 Korištenje didaktičkih materijala i pomagala potrebno je zbog unaprjeđenja kvalitete procesa učenja i poučavanja matematike.			
	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem
Osnovna škola (predmetna nastava)	1	7	52	76
Srednja strukovna škola	3	7	56	39
Gimnazija	3	10	44	49
Ukupno	7	24	152	164

Iako se obje skupine nastavnika uglavnom slažu, pokazalo se kako nastavnici osnovnih škola pokazuju znatno višu razinu potpunog slaganja (56 %)bnego nastavnici strukovnih škola kojih se 37 % potpuno slaže. Između ostalih grupa nastavnika nisu utvrđene razlike. Navedeno se može pojasniti prirodom matematičkih sadržaja i metodikom nastave matematike iz osnovne škole čiji je opći karakter i tempo rada sasvim drugačiji nego u srednjim školama. Međutim, kako nema statistički značajnih razlika između nastavnika osnovnih škola i nastavnika koji rade u gimnazijama, tumačenje ovih razlika ne može se u potpunosti utvrditi navedenim čimbenicima.

U tvrdnji 1.8 *Nastavni proces treba se planirati prema smjernicama Nacionalnog okvirnog kurikuluma*. post-hoc Scheffe analizom pokazalo se kako nema razlike među nastavnicima s obzirom na radno mjesto.

Nadalje, tvrdnje 1.9 i 1.10 koje se tiču primjenjivosti matematičkih znanja i korelacija matematičkih sadržaja pokazuju kako se nastavnici koji rade u osnovnoj školi više priklanjaju primjenjivosti, što je nekako i više u skladu sa sadržajima i konceptima osnovnoškolske matematike, a nastavnici koji rade u gimnaziji te oni sa završenim inženjerskim smjerom ističu važnost primjenjivosti unutar matematike. Stoga nastavnici koji rade u osnovnim školama smatraju kako korelacije matematičkih sadržaja sa svakodnevnim životom podižu kvalitetu usvojenih znanja učenika. Međutim, budući da je to posljedica iskustva iz prakse, ne možemo dati konkretne zaključke zato što su takvi stavovi i uvjerenja konzistentni sa sadržajima matematike koji s prelaskom na više stepenice obrazovanja sve češće imaju teorijski karakter,

a zadatci su često nepovezivi sa stvarnim pa čak i hipotetskim situacijama iz svakodnevnog života.

Tablica 2. 45: *Razlike s obzirom na radno mjesto u tvrdnji 1.13*

	1.13 Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi.				
	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem
Osnovna škola (predmetna nastava)	4	18	28	57	29
Srednja strukovna škola	3	20	20	43	19
Gimnazija	3	8	17	47	31
Ukupno	10	46	65	147	79

Što se tiče stereotipa o matematičkim sposobnostima, tvrdnja 1.13 pokazuje kako nastavnici u strukovnim školama u značajno manjoj mjeri smatraju kako učenik prosječnih sposobnosti može imati ocjenu odličan u osnovnoj školi, a ta se razlika pokazala u usporedbi s nastavnicima koji rade u gimnaziji. Razlog tome vjerojatno je u samoj populaciji koja upisuje strukovne škole koja je u prosjeku manje uspješna od onih koji upisuju gimnazije zbog čega nastavnici koji rade u strukovnim školama imaju drugačiji referentni okvir pri razmatranju učenika prosječnih sposonosti. Budući da gimnazije upisuju učenici odličnog općeg uspjeha i uspjeha u matematici, očito je kako nastavnici koji rade s tom djecom percipiraju većinu te populacije prosječnom, a s druge strane, nastavnici koji rade u strukovnim školama u prosjeku imaju manje djece koja su toliko uspješna pa slijedom toga vjerojatno zauzimaju navedeni stav.

U preostalim tvrdnjama koje smo utvrdili post-hoc Scheffe testom višestrukih uspredbi, sve razlike bile su između nastavnika osnovnih škola i ostalih grupa nastavnika pa ćemo ih zbog konzistentosti u nastavku prokomentirati. U tvrdnja 1.23 vezanoj uz poznavanje socio-kulturnog i ekonomskog statusa učenika pokazala se značajna razlika jedino između nastavnika koji rade u osnovnoj školi i onih koji rade u srednjim školama. Od nastavnika koji rade u osnovnim školama, njih 59 % slaže se kako nastavnici trebaju poznavati socio-kulturni i ekonomski status učenika, a kod nastavnika koji rade u gimnazijama i strukovnim školama isto misli 40 % nastavnika.

U tvrdnji 1.28 pokazalo se kako nastavnici koji rade u osnovnim školama češće smatraju kako je za kvalitetu nastave bitno da nastavnik ima uvjerenje kako svaki učenik može zavoljeti matematiku nego što to smatraju nastavnici koji rade u gimnazijama. Za posljednje tri tvrdnje 1.30, 1.31 i 1.32 utvrđena je statistički značajna razlika između nastavnika osnovnih škola i

nastavnika strukovnih škola zato što prvonavedeni većinskim dijelom (od 80 % do 90 %) smatraju bitnim da nastavnici razumiju opće i specifične ciljeve *Nacionalnog okvirnog kurikuluma*, koncepta cjeloživotnog učenja te odgojno-obrazovnih standarda kurikuluma matematičkog područja.

4.2.1.6 Deskriptivni pokazatelji nastavničkih uvjerenja i stavova o stereotipima karakterističnim za nastavu matematike

Opće je prisutno uvjerenje kako su samo neki učenici sposobni uspješno svladati matematičke sadržaje, a uz navedeno značajnu ulogu u nastavi matematike imaju i spolni stereotipi koji su prisutni na različitim razinama društva te su ujedno povezani s njihovom percepcijom sposobnosti za svladavanje matematike te s očekivanjima budućeg uspjeha u u matematici i zanimanjima iz STEM područja. Problemi, predrasude i stereotipi u nastavi matematike već su tradicionalno sastavni dio društva, obitelji i škole zbog čega je za željenu kvalitetu učenja i poučavanja matematike potrebno mijenjati stavove i uvjerenja nastavnika te ih osposobiti kako bi smanjili utjecaj stereotipa na proces učenja i poučavanja matematike.

4.2.1.6.1 Percepcija problema nadarenosti i obrazovanosti

Problem nadarenosti i obrazovanosti (Giesecke, 1993) nazastupljeniji je stereotip o matematici te zaslužuje posebno mjesto u razmatranju izazova s kojima se susreću nastavnici matematike i njihovi učenici. U tablici 2.46 izdvojene su tri tvrdnje kojima smo obuhvatili tvrdnje koje se odnose na percepciju dotičnog problema od strane nastavnika.

Tablica 2. 46: *Uvjerenja nastavnika o stereotipima o matematičkim sposobnostima*

Tvrdnje	Arit. sredina	Mod	Stand. devijacija
1.13 Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi.	3.69	4	1.05
1.14 Učenik prosječnih sposobnosti može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji.	2.61	2	1.06
1.15 Učenik koji ima problema s računanjem (tablicom množenja) može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji.	1.90	1	1.13

Iz gornje tablice očito je kako je pitanje sposobnosti za matematiku i implicitnog stigmatiziranja kroz kvocijent inteligencije prisutno na ispitivanom uzorku. Vrijedi istaknuti kako su na ljestvici uvjerenja pitanja iz područja stereotipa o matematici imali najviša odstupanja utvrđena prema vrijednostima standardne devijacije. Za očekivati je bilo kako će nastavnici imati pozitivniji stav kao pojedinci koji su se ostvarili u dotičnom području zbog čega se pretpostavlja kako su svjesni vrijednosti napornog rada i kontinuiteta te okolinskih čimbenika koji su potrebni za određenu uspješnost i izvrsnost te su samim time manje skloni pripisivati rezulate nečijeg rada genetici i nekim prirodnim datostima pojedinca.

Tablica 2. 47: *Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi.*

1.13 Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi.		
	Frekvencije	Postotci
Uopće se ne slažem	10	2.9
Ne slažem se	46	13.2
Niti se slažem niti se ne slažem	65	18.7
Slažem se	148	42.5
U potpunosti se slažem	79	22.7
Ukupno:	348	100.0

Iz tablice 2.47 očito je kako se za uspješnost u osnovnoj školi 68 % nastavnika slaže, a 16 % smatra kako učenici prosječnih sposobnosti ne mogu imati ocjenu „odličan“ (tablica 2.47). Međutim, što se tiče uspješnosti u prirodoslovno-matematičkoj gimnaziji, svega 3 % se u potpunosti slaže, 20 % se slaže, a čak 49 % se ne slaže ili se uopće ne slaže s time (tablica 2.48). Iako gimnazije upisuju učenici boljeg školskog uspjeha te se pretpostavlja kako su isti iznad prosjeka, ti se rezultati mogu pripisati tome što od tih učenika samo manji dio (10 – 20 %) ima ocjenu odličan. Modalnu vrijednost tvrdnje „2 - ne slažem se“ istaknulo je 33 % ispitanika. Iako su brojna istraživanja u području darovitosti, talentiranosti i svojevrsne predodređenosti pojedinca genetikom i različitim testovima sposobnosti pokazala kako su stručnjaci supstratnih područja i disciplina manje skloni stereotipima, ovdje se to nije potvrdilo.

Tablica 2. 48: *Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u prirodoslovno-matematičkoj gimnaziji.*

1.14 Učenik prosječnih sposobnosti može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji.		
	Frekvencije	Postotci
Uopće se ne slažem	55	15.8
Ne slažem se	114	32.8
Niti se slažem niti se ne slažem	99	28.4
Slažem se	71	20.4
U potpunosti se slažem	9	2.6
Ukupno	348	100.0

Te su dvije tvrdnje značajno korelirane sa srednje jakom povezanošću (r = 0.492, na razini statističke značajnosti 0.01) te će se stoga prikazati i objedinjena deskriptivna obilježja tih dviju tvrdnji u tablici 2.49.

Tablica 2. 49: *Odnos između tvrdnji 1.13 i 1.14: Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi/prirodoslovno-matematičkoj gimnaziji.*

		Učenik prosječnih sposobnosti može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji.					
		Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi.	Uopće se ne slažem	10	0	0	0	0	10
	Ne slažem se	20	25	1	0	0	46
	Niti se slažem niti se ne slažem	10	27	26	2	0	65
	Slažem se	8	44	53	42	1	148
	U potpunosti se slažem	7	18	19	27	8	79
	Ukupno	55	114	99	71	9	348

U gornjoj tablici istaknute su vrijednosti u kojima se preklapaju afirmativni i negacijski odgovori objedinjeni za navedene tvrdnje. Dakle, 55 (16 %) nastavnika smatra kako učenici prosječnih sposobnosti ne mogu imati ocjenu „odličan“ ni u osnovnoj školi ni u prirodoslovno-matematičkoj gimnaziji, a 78 (23 %) nastavnika smatra kako prosječan učenik može imati

ocjenu odličan i u osnovnoj školi i u prirodoslovno-matematičkoj gimnaziji. To otprilike znači da jedan od četiriju nastavnika matematike nije sklon stereotipima te uvažava složenost odgojno-obrazovnih izazova, odnosno posjeduje potrebni pedagoški optimizam koji je preduvjet realizacije sposobnosti učenika, njihovih postignuća te njihova cjelovita razvoja.

4.2.1.6.2 Osposobljenost i samoprocjena nastavnika za prepoznavanje diskalkulije

Diskalkulija je specifičan oblik neurorazličitosti u kojem pojedinac ne uspijeva razviti sposobnosti usvajanja aritmetičkih vještina (DfES, 2001), ali nema poremećaj općih kognitivnih funkcija, tj. prosječne je ili iznadprosječne inteligencije. S obzirom na to da učenici s diskalkulijom nemaju poremećaja općih kognitivnih funkcija te su prosječne ili iznadprosječne inteligencije, sasvim je izvjesno kako su uz dobru odgojno-obrazovnu potporu upisali neki od gimnazijskih programa što bi se, statistički gledano, moglo i očekivati ukoliko su iznadprosječne inteligencije koja je snažan prediktor ocjena u osnovnoj školi, a koje su preduvjet upisa u srednju školu. Iako je metodologija i sam proces detekcije djece s diskalkulijom složen postupak, tvrdnjom 1.15 tek se donekle indirektno ispituje jesu li nastavnici upoznati s temeljnim obilježjima diskalkulične djece koja, unatoč slabijim aritmetičkim vještinama, mogu biti iznadprosječno inteligentna.

Tablica 2. 50*: Učenik koji ima problema s računanjem (tablicom množenja) ne može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji.“*

1.15 Učenik koji ima problema s usvajanjem tablice množenja može imati ocjenu odličan u prirodoslovno-matematičkoj gimnaziji		
	Frekvencije	Postotci
Uopće se ne slažem	173	49.7
Ne slažem se	89	25.6
Niti se slažem niti se ne slažem	47	13.5
Slažem se	25	7.2
U potpunosti se slažem	14	4.0
Ukupno	348	100.0

Većina se nastavnika (75 %) ne slaže s tvrdnjom, a njih samo 11 % smatra kako učenik s diskalkulijom može imati ocjenu „odličan“ iz matematike. Pretpostavka je kako nastavnici diskalkuliju kategoriziraju u teškoće uvjetovane vanjskim čimbenicima kao što su: nekvalitetna nastava, socioekonomski status, problemi u ponašanju, problemi deficita pažnje te deficit općih

kognitivnih funkcija. Poučeni iskustvima stoga smatraju kako se tu ne može dogoditi neka pozitivna promjena u kontekstu nastave matematike.

Međutim, u kontekstu srednjoškolskog kurikuluma matematike dominantni sadržaji više nisu iz područja aritmetike, već su to redom algebra, geometrija, trigonometrija, matematička analiza itd. Kako se težište premješta s aritmetike na druga područja matematike, učenici s diskalkulijom imaju znatno veće šanse pokazati svoje kapacitete i na određeni način demantirati percepciju matematike isključivo kroz brojeve, odnosno aritmetiku. To je temeljno obilježje srednjoškolske matematike za koju je karakterističan prijelaz na druga područja matematike u kojima se mnogi objektivno sposobni učenici ne snalaze te se time povećava njihov animozitet prema matematici. S druge strane, ustrajni učenici s razvijenim radnim navikama i ponekim teškoćama u aritmetici imaju više vjerojatnosti za uspjeh u srednjoškolskim sadržajima nego objektivno sposobniji koji nemaju radne navike.

Kao što je ranije navedeno, pokazuje se kako su nastavnici nedostatno informirani i educirani o diskalkuliji i karakteristikama djece s diskalkulijom. Objedinimo li tvrdnje 1.14 i 1.15 tako da prikažemo presjek odgovora ispitanika, u te dvije varijable možemo dobiti još detaljniji uvid u stavove i uvjerenja nastavnika (tablica 2.51). Dakle, najučestaliji je odgovor na tvrdnju 1.14 „ne slažem se“ što je odgovorilo 114 (33 %) nastavnika, a dominantni je odgovor na tvrdnju 1.15 „uopće se ne slažem“ odgovorilo 174 (50 %) nastavnika. Preklapanjem odgovora na ove dvije tvrdnje pokazalo se kako se 133 (38 %) nastavnika ne slaže ili se uopće ne slaže ni s jednom tvrdnjom. S druge strane, svega se 6 (2 %) nastavnika slaže ili se u potpunosti slaže s obje tvrdnje.

Tablica 2. 51: odnos tvrdnji 1.14: *Učenik prosječnih sposobnosti može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji.* i 1.15*: Učenik koji ima problema s računanjem (tablicom množenja) ne može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji*.

		1.15 Učenik koji ima problema s usvajanjem tablice množenja može imati ocjenu odličan u prirodoslovno-matematičkoj gimnaziji					
		Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
1.14 Učenik prosječnih sposobnosti može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji.	Uopće se ne slažem	32	10	3	4	6	55
	Ne slažem se	64	27	9	11	3	114
	Niti se slažem niti se ne slažem	43	24	24	6	2	99
	Slažem se	33	23	11	**3**	**1**	71
	U potpunosti se slažem	2	5	0	**1**	**1**	9
Ukupno		174	89	47	25	13	348

Prethodno navedene tvrdnje i zaključke istaknutih rezultata završno ćemo potkrijepiti tvrdnjom 2.14: *Znam prepoznati učenika koji ima diskalkuliju*. iz ljestvice samoprocjene nastavnika (detaljnija analiza u poglavlju 4.2.2.) koju ćemo prikazati zajedno s tvrdnjom 1.15.

Tablica 2. 52: odnos tvrdnji 1.15*: Učenik koji ima problema s računanjem (tablicom množenja) ne može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji*. i 2.14 *Znam prepoznati učenika koji ima diskalkuliju.*

		2.14 Znam prepoznati učenika koji ima diskalkuliju.					
		Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
1.15 Učenik koji ima problema s usvajanjem tablice množenja može imati ocjenu odličan u prirodoslovno-matematičkoj gimnaziji	Uopće se ne slažem	4	15	67	**66**	**22**	174
	Ne slažem se	0	6	38	**40**	**5**	89
	Niti se slažem niti se ne slažem	0	6	13	21	7	47
	Slažem se	0	3	8	**8**	**6**	25
	U potpunosti se slažem	1	0	8	**4**	**0**	13
Ukupno		5	30	134	139	40	348

Premda nešto više od polovice (51 %) nastavnika smatra kako zna prepoznati učenika koji ima diskalkuliju, njih svega 5 % smatra kako učenik koji ima problema s tablicom množenja može imati ocjenu odličan u prirodoslovno-matematičkoj gimnaziji što je u proturječju s teorijskim polazištima određenja diskalkulije. S druge strane, među nastavnicima koji smatraju da znaju prepoznati diskalkulično dijete, njih čak 38 % smatra kako učenik koji ima teškoće s usvajanjem tablice množenja ne može imati ocjenu odličan u prirodoslovno-matematičkoj gimnaziji. Ovi podatci nedvojbeno upućuju na veliku neinformiranost nastavnika te na nerazumijevanje općih značajki diskalkulične djece, odnosno kako njihovi opći intelektualni potencijali značajno nadmašuju one u aritmetici te kako takva djeca mogu postati izvrsni matemtičari.

4.2.1.6.3 Uvjerenja o radnim navikama i motivaciji darovitih učenika

Uvjerenja o radnim navikama i motivaciji (darovitih) učenika konzistentna su s problemom darovitosti i obrazovanosti te će se isto prikazati rezultatima u tablici 2.53.

Tablica 2. 53: *Uvjerenja o radnim navikama i motivaciji darovitih učenika*

Tvrdnje	Arit. sredina	Mod	Stand. devijacija
1.16 Matematički daroviti učenici imat će uspješnu karijeru u matematici bez obzira na potporu okoline.	2.82	3	1.001
1.17 Razvijene radne navike i motivacija dovoljni su za visoke uspjehe u matematičkim natjecanjima.	2.94	2	.973
1.18 Matematički daroviti učenici motiviraniji su za učenje matematike od ostalih učenika.	3.57	4	.998

U tvrdnji 1.16 odgovori nastavnika grupirali su se dominantno oko odgovora „niti se slažem niti se ne slažem“ što je odgovorilo 40 % nastavnika. Od ostalih, 37 % se ne slaže, a 23 % se slaže s tvrdnjom kako će daroviti učenici imati uspješnu karijeru u matematici bez potpore okoline. Zbog istraživačkih interesa s ciljem boljeg razumijevanja i unpređenja nastave matematike, na ovoj tvrdnji bilo bi poželjno kvalitativnom metodologijom dobiti jasniji uvid u razmišljanja skupine nastavnika koji se slažu s ovom tvrdnjom zato što se daljnji zaključci od prikazanih podataka mogu svesti samo na pretpostavke.

Tablica 2. 54: *Uvjerenja o uspjehu darovitih učenika*

1.16 Matematički daroviti učenici imat će uspješnu karijeru u matematici bez obzira na potporu okoline.		
	Frekvencije	Postotci
Uopće se ne slažem	30	8.6
Ne slažem se	100	28.7
Niti se slažem niti se ne slažem	139	39.9
Slažem se	59	17.0
U potpunosti se slažem	20	5.7
Ukupno	348	100.0

Pojedinci koji su ostvarili karijere u matematici često su bili uspješni natjecatelji u matematici te se stoga tvrdnja 1.17 uvelike podudara s prethodnom tvrdnjom, a to su pokazali i deskriptivni podatci iz tablice 2.55 koji su podjednaki, ali s nešto višom razinom slaganja nego u tvrdnji 1.16.

Tablica 2. 55: Tvrdnja 1.17: *Povezanost radnih navika i motivacije s uspjehom na matematičkim natjecanjima*

Razvijene radne navike i motivacija dovoljni su za visoke uspjehe na matematičkim natjecanjima.		
	Frekvencije	Postotci
Uopće se ne slažem	14	4.0
Ne slažem se	115	33.0
Niti se slažem niti se ne slažem	114	32.8
Slažem se	87	25.0
U potpunosti se slažem	18	5.2
Ukupno	348	100.0

U tvrdnji 1.18 nastavnici su pokazali višu razinu slaganja od prethodnih (tablica 2.56) te se njih 57 % slaže s tvrdnjom, a svega 16 % se ne slaže što ukazuje na to kako su nastavnici svjesni motivacije i truda koji ulažu uspješniji učenici te ne pripisuju iste stereotipnim uvjerenjima.

Tablica 2. 56: *Uvjerenja o motivaciji darovitih učenika*

1.18 Matematički daroviti učenici motiviraniji su za učenje matematike od ostalih učenika.		
	Frekvencije	Postotci
Uopće se ne slažem	7	2.0
Ne slažem se	49	14.1
Niti se slažem niti se ne slažem	92	26.4
Slažem se	140	40.2
U potpunosti se slažem	60	17.2
Ukupno	348	100.0

4.2.1.6.4 Percepcija rodnih stereotipa

Iako s nešto nižom prosječnom vrijednosti (M = 3.89), modalna je vrijednost pod brojem „5 - u potpunosti se slažem“ što se odnosilo na potpuno slaganje s tvrdnjom kako nastavnici smatraju da učenici nisu bolji matematičari od učenica (tablica 2.57).

Tablica 2. 57: *Deskriptivni parametri percepcije rodnih stereotipa*

Tvrdnja	Arit. sredina	Mod	Stand.. devijacija
1.19 Učenici nisu bolji matematičari od učenica.	3.89	5	1.044

Prema podatcima iz tablica 2.57 i 2.58, pokazuje se kako nema prisutnih uvjerenja karakterističnih za rodne stereotipe među nastavnicima matematike.

Tablica 2. 58: *Deskriptivni parametri percepcije rodnih stereotipa*

	Frekvencije	Postotci	Kumulativni postotci
Uopće se ne slažem	8	2.3	2.3
Ne slažem se	26	7.5	9.8
Niti se slažem niti se ne slažem	84	24.1	33.9
Slažem se	108	31.0	64.9
U potpunosti se slažem	122	35.1	100.0
Ukupno	348	100.0	

Populacija nastavnika matematike dominantno je ženskog spola pa je prirodno pretpostaviti kako su među takvom populacijom manje zastupljeni stereotipi u razlikama među spolovima, a naročito među onima koji su završili studij matematike koji čine većinu ispitivane populacije nastavnika.

4.2.2 Deskriptivna analiza ljestvice percipirane kompetentnosti i samoefikasnosti

Nakon analize uvjerenja nastavnika o nastavi i obrazovanju općenito te o specifičnostima i problematičnim područjima matematičkog obrazovanja, slijedi analiza percipirane kompetentnoti nastavnika. Za navedena pitanja ispitanici su trebali zaokružiti brojeve od jedan do pet na Likertovoj ljestvici (1 = uopće se ne slažem; 2 = ne slažem se; 3 = niti se slažem niti se ne slažem; 4 = slažem se; 5 = u potpunosti se slažem). U nastavku (u tablici 2.59) slijedi analiza tvrdnji prema osnovnim parametrima deskriptivne statistike (aritmetička sredina i standardna devijacija).

Tablica 2. 59: *Deskriptivni parametri ljestvice percipirane kompetentnosti i samoefikasnosti*

Tvrdnje	Arit. sred.	Stand. dev.
2.1 Posjedujem znanja o naprednim matematičkim temama koje nisu dio školske matematike.	3.97	.766
2.2 Razumijem povijesnu i društvenu ulogu matematike u znanosti, kulturi, umjetnosti i tehnologiji te njezin potencijal za budućnost društva.	4.11	.611
2.3 Razumijem prednosti i nedostatke pojedinih oblika i načina poučavanja kojima se koristim u nastavi.	4.32	.551
2.4 Imam duboko razvijena konceptualna znanja matematike.	4.00	.646
2.5 Osjećam se kompetentnim za pripremu nadarenih učenika za državno natjecanje.	3.74	.842
2.6 Razumijem temeljna načela alternativnih pedagoških koncepata i njihove primjene u nastavi matematike.	3.65	.735
2.7 Posjedujem znanja o interesima svojih učenika.	3.86	.726
2.8 Upoznat sam sa socio-kulturnim i ekonomskim statusom svojih učenika.	3.56	.929
2.9 Uvažavam socijalne i kulturne razlike učenika u nastavnim aktivnostima kao i kod ocjenjivanja i očekivanjima koje postavljam pred njih.	3.70	.870

2.10 Uočavam odnose učenika u razredu te kako oni utječu na njihovu aktivnost u nastavi matematike.	4.10	.643
2.11 Razumijem prirodu i vrste specifičnih teškoća s kojima se učenici suočavaju u nastavi matematike.	4.16	.564
2.12 Svjestan sam motivacije kojom moji učenici pristupaju matematici.	4.21	.561
2.13 U nastavi uočavam tempo kojim učenici svladavaju matematičke sadržaje.	4.28	.588
2.14 Znam prepoznati učenika koji ima diskalkuliju.	3.51	.860
2.15 Znam kako ukloniti i prevenirati probleme u učenju matematike.	3.61	.681
2.16 Uočavam emocije učenika u nastavnim aktivnostima.	4.15	.627
2.17 Razumijem osnovna načela u radu s nadarenim učenicima.	4.07	.649
2.18 Razumijem temeljne smjernice koncepta cjeloživotnog učenja te ulogu matematičkog područja u tom kontekstu.	4.10	.710
2.19 Razumijem opće i specifične ciljeve te smjernice Nacionalnog okvirnog kurikuluma.	3.88	.712
2.20 Nastavni proces organiziram prema odgojno-obrazovnim ciljevima pojedinih područja matematike zadanih Nacionalnim okvirnim kurikulumom.	3.87	.693

Analizu iz gornje tablice detaljnije ćemo interpretirati i objediniti zajedno s testiranjem statističke značajnosti u razlikama, redom po tvrdnjama, s obzirom na nezavisne varijable koristeći se jednosmjernom analizom varijance (One-way ANOVA) i t-testom na binarnim varijablama s obzirom na:

a) spol (poglavlje 4.2.2.1)
b) inicijalno obrazovanje (poglavlje 4.2.2.2)
c) radni staž (poglavlje 4.2.2.3)
d) stečena dodatna naobrazba (poglavlje 4.2.2.4)
e) radno mjesto (poglavlje 4.2.2.5).

4.2.2.1 Razlike u percipiranoj kompetentnosti i samoefikasnosti s obzirom na spol

U tablici 2.60 slijedi prikaz statistički značajnih razlika po tvrdnjama s obzirom na spol koristeći se jednosmjernom analizom varijance (One-way ANOVA test).

Tablica 2. 60: *Analiza varijance za procjenu samoefikasnosti nastavnika s obzirom spol*

Tvrdnje	F-omjer	Stat. znač.
2.1 Posjedujem znanja o naprednim matematičkim temama koje nisu dio školske matematike.	8.988	.003**
2.3 Razumijem prednosti i nedostatke pojedinih oblika i načina poučavanja kojima se koristim u nastavi.	11.927	.001**
2.6 Razumijem temeljna načela alternativnih pedagoških koncepata i njihove primjene u nastavi matematike.	21.397	.000***
2.7 Posjedujem znanja o interesima svojih učenika.	27.990	.000***
2.8 Upoznat sam sa socio-kulturnim i ekonomskim statusom svojih učenika.	10.610	.001**
2.10 Uočavam odnose učenika u razredu te kako oni utječu na njihovu aktivnost u nastavi matematike.	6.047	.014*
2.11 Razumijem prirodu i vrste specifičnih teškoća s kojima se učenici suočavaju u nastavi matematike.	28.773	.000***
2.12 Svjestan sam motivacije kojom moji učenici pristupaju matematici.	12.104	.001**
2.16 Uočavam emocije učenika u nastavnim aktivnostima.	8.907	.003*
2.17 Razumijem osnovna načela u radu s nadarenim učenicima.	4.030	.045*
2.18 Razumijem temeljne smjernice koncepta cjeloživotnog učenja te ulogu matematičkog područja u tom kontekstu.	14.757	.000***
2.19 Razumijem opće i specifične ciljeve te smjernice Nacionalnog okvirnog kurikuluma.	5.221	.023*

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Iz tablice 2.61 najveće su razlike vidljive u razini slaganja s tvrdnjom koja je u oba spola visoko ocijenjena, no 39 % muških nastavnika smatra kako posjeduju znanja o naprednim matematičkim temama, a to isto misli samo 19 % nastavnica. S obzirom na utvrđene različite varijance, sve su tvrdnje podvrgnute t-testu kojim se pokazalo kako se ispitanici razlikuju s obzirom na spol (sukladno provedenoj analizi varijance na danim tvrdnjama).

Tablica 2. 61: *Razlike s obzirom na spol u tvrdnji 2.1*

	2.1 Posjedujem znanja o naprednim matematičkim temama koje nisu dio školske matematike.					
	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
Muški	0	1	8	28 (46 %)	24 (39 %)	61
Ženski	1	14	49	169 (59 %)	54 (19 %)	287
Ukupno	1	15	57	197	78	348

Dakle, muški nastavnici sebe procjenjuju kompetentnijima u stručnosti u matematici (tablica 2.61), no s druge strane, u metodici u kontekstu samoprocjene pokazuje se suprotno (tablica 2.62). Naime, u tvrdnji 2.3 90 % ispitanika procjenjuje se kompetentnim u razumijevanju prednosti i nedostataka pojedinih oblika i načina poučavanja, ali je statistički značajna razlika u potpunom slaganju s tvrdnjom – 39 % nastavnica nasuprot 21 % muških nastavnika.

Tablica 2. 62: *Razlike s obzirom na spol u tvrdnji 2.3*

		2.3 Razumijem prednosti i nedostatke pojedinih oblika i načina poučavanja kojima se koristim u nastavi.				
		Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
Spol	Muški	1	5	42 (69 %)	13 (21 %)	61
	Ženski	0	7	169 (59 %)	111 (39 %)	287
Ukupno		1	12	211	124	348

Što se tiče alternativnih pedagoških koncepata i njihove primjene u nastavi matematike, jedna trećina nastavnika tvrdi kako su upoznati s temeljnim načelima, a njih 56 % se niti slažu niti ne slažu s tvrdnjom (tablica 2.63). S druge strane, dvije trećina nastavnica procjenjuje kako su upoznate s alterntivnim pedagoškim konceptima, a 30 % njih nije se konkretno izjasnilo što govori kako nastavnice procjenjuju svoje znanje o alternativnim pedagoškim konceptima znatno boljim.

Tablica 2. 63: *Razlike s obzirom na spol u tvrdnji 2.6*

	2.6 Razumijem temeljna načela alternativnih pedagoških koncepata i njihove primjene u nastavi matematike.					Ukupno
	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
Muški	1	5	34	19	2	61
Ženski	0	12	86	157	32	287
Ukupno	1	17	120	176	34	348

U brojnim razlikama koje smo utvrdili jednosmernom analizom varijance (prema tablici 2.60), značajnim se pokazuju razlike u spolu koje karakteriziraju znatno više samoprocjene nastavnica naspram muških nastavnika, stoga ćemo za niz sljedećih tvrdnji, koje su samoprocjene socijalne kompetencije i znanja o učenicima, zbirno prikazati rezultate i specifične razlike koje u konzistentne unutar tih tvrdnji. Pretpostavka je kako će se u faktorskoj analizi ovog dijela upitnika sljedeće tvrdnje grupirati unutar istog faktora. To će se dodatno analizirati u poglavlju 4.2.2 u kojem će se primijeniti faktorska analiza čiji će se faktori također analizirati jednosmjernom analizom varijance. Radi se o sljedećim tvrdnjama:

Tvrdnja 2.7: *Posjedujem znanja o interesima svojih učenika*.

Tvrdnja 2.8: *Upoznat sam sa socio-kulturnim i ekonomskim statusom svojih učenika*.

Tvrdnja 2.10: *Uočavam odnose učenika u razredu te kako oni utječu na njihovu aktivnost u nastavi matematike*.

Tvrdnja 2.11: *Razumijem prirodu i vrste specifičnih teškoća s kojima se učenici suočavaju u nastavi matematike*.

Tvrdnja 2.12: *Svjestan sam motivacije kojom moji učenici pristupaju matematici*.

Tvrdnja 2.16: *Uočavam emocije učenika u nastavnim aktivnostima*.

Dakle, u gore navedenim tvrdnjama dosta se ujednačeno pokazuju razlike u samoprocjenama koje su znatno više kod nastavnica nego kod muških nastavnika. Utvrđeno je kako se nastavnici rijetko (u rasponu od 5 – 15 %) u potpunosti slažu te se 30 – 50 % slaže s samoprocjenom kompetentnosti u navedenim tvrdnjama. Nastavnice se u potpunosti slažu u rasponu 20 – 32 % te je njih 40 - 60 % koje se slažu s samoprocjenama kako posjeduju znanja o interesima svojih učenika te uočavaju odnose među učenicima za vrijeme nastavnih aktivnosti. Također, sukladno navedenim rezultatima, nastavnice procjenjuju svoje sposobnosti uočavanja emocija i motivacije učenika višim te razumijevanje vrsta specifičnih teškoća s kojima se učenici suočavaju u nastavi matematike. Naposljetku, u oba spola zabilježene su

relativno visoke samoprocjene u kojima se, prema Likertovoj ljestvici tipa od 1 do 5 u razini slaganja s tvrdnjom, kao dominantna vrijednost u oba spola pojavljuje 4: „Slažem se“. U faktorskoj analizi, sukladno hipotezma, očekuje se kako će ista izdvojiti faktor socijalne kompentencije i/ili znanja o specifičnosti učenika u nastavi matematike.

U rezultatima samoprocjene nastavnika u radu s nadarenim učencima, nastavnici se osjećaju manje spremnima za rad s nadarenim učenicima, iako se 75 % slaže ili potpuno slaže. Isto je znatno manje nego kod nastavnica (tablica 2.64).

Tablica 2. 64: *Razlike s obzirom na spol u tvrdnji 2.17*

		2.17 Razumijem osnovna načela u radu s nadarenim učenicima.				
		Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
Spol	Muški	0	15	36 (59 %)	10 (16 %)	61
	Ženski	5	32	179 (62 %)	71 (25 %)	287
Ukupno		5	47	215	81	348

Analiza rezultata tvrdnji 2.18 i 2.19, u kojima se ispituje samoprocjena razumijevanja koncepta cjeloživotnog učenja te općih i specifičnih ciljeva i smjernica Nacionalnog okvirnog kurikuluma, konzistentna je s tvrdnjama 1.30 i 1.31 u kojima smo u prvom dijelu istraživačkog upitnika ispitivali razlike u stvovima i uvjerenjima o navedenim tvrdnjama.

Tvrdnja 2.18: *Razumijem temeljne smjernice koncepta cjeloživotnog učenja te ulogu matematičkog područja u tom kontekstu*.

Tvrdnja 2.19: *Razumijem opće i specifične ciljeve te smjernice Nacionalnog okvirnog kurikuluma.*

Sukladno tim rezultatima, muški se nastavnici u manjoj mjeri procjenjuju informiranima od nastavnica, a s obzirom na stavove u tvrdnjama 1.30 i 1.31 u kojima ne smatraju relevantnim temeljne smjernice koncepta cjeloživotnog učenja te opće i specifične ciljeve Nacionalnog okvirnog kurikuluma, za njihovu praksu, poput nastavnica, pretpostavka je kako muški nastavnici manje prate obrazovno-političke trendove ili možda nemaju pozitivno mišljenje o istima.

(Tvrdnja 1.30: *U kojoj mjeri se slažete kako je bitno da nastavnik matematike razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.*

Tvrdnja 1.31: *U kojoj mjeri se slažete kako je bitno da nastavnik matematike razumije temeljne smjernice koncepta cjeloživotnog učenja*.)

4.2.2.2 Razlike u percipiranoj kompetentnosti i samoefikasnosti s obzirom na inicijalno obrazovanje

U tablici 2.65 slijedi prikaz statistički značajnih razlika u samoprocjenama nasatavnika s obzirom na inicijalno obrazovanje koristeći se jednosmjernom analizom varijance (One-way ANOVA test).

Tablica 2. 65: *Analiza varijance u samoprocjenama nastavnika s obzirom na inicijalno obrazovanje*

Tvrdnje	F-omjer	Stat. znač.
2.1 Posjedujem znanja o naprednim matematičkim temama koje nisu dio školske matematike.	9.250	.000***
2.7 Posjedujem znanja o interesima svojih učenika.	5.466	.001**
2.8 Upoznat sam sa socio-kulturnim i ekonomskim statusom svojih učenika.	5.434	.001**

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Za istaknute tvrdnje u tablici 2.66 slijedi post-hoc Scheffeov test statističke značajnosti između pojedinih grupa nastavnika s obzirom na završeno inicijalno obrazovanje.

Tablica 2. 66: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na inicijalno obrazovanje ispitanika*

Tvrdnje	(I) Inicijalno obrazovanje	(J) Inicijalno obrazovanje	Razlika u arit. sredinama (I-J)	Std. greška	Stat. znač
2.1 Posjedujem znanja o naprednim matematičkim temama koje nisu dio školske matematike.	Učiteljski fakultet	PMF (nastavnički smjer)	-.500*	.125	.001**
		PMF (inženjerski smjer)	-.715*	.143	.000***
		Ostalo	-.678*	.168	.001**
2.7 Posjedujem znanja o interesima svojih učenika.	Učiteljski fakultet	PMF (nastavnički smjer)	.341*	.120	.046*
		PMF (inženjerski smjer)	.529*	.137	.002*
		Ostalo	.495*	.162	.027*
2.8 Upoznat sam sa socio-kulturnim i ekonomskim statusom svojih učenika.	Učiteljski fakultet	PMF (nastavnički smjer)	.587*	.153	.002**
		PMF (inženjerski smjer)	.574*	.176	.015*
		Ostalo	.332	.208	.466

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Rezultati odgovora na tvrdnju 2.1 očekivano pokazuju veliku razliku između nastavnika koji su završili Učiteljski fakultet usporedno sa svim grupama nastavnika s obzirom na inicijalno obrazovanje.

Tablica 2. 67: *Razlike u samoprocjenama nastavnika s obzirom na inicijalno obrazovanje u tvrdnji 2.1*

	2.1 Posjedujem znanja o naprednim matematičkim temama koje nisu dio školske matematike.					
	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
PMF (nastavnički smjer)	0	7	35	114	42	198
PMF (inženjerski smjer)	0	2	7	39	24	72
Učiteljski fakultet	1	6	11	22	3	43
Ostalo	0	0	4	22	9	35
Ukupno	1	15	57	197	78	348

Tako se 79 % nastavnika sa završenim PMF-om (nastavnički smjer) slaže s tvrdnjom procjenjujući visokim svoja znanja o naprednim matematičkim temama koje nisu dio školske matematike. Isto vrijedi za 88 % nastavnika sa završenim inženjerskim smjerom na PMF-u, 91 % s ostalih studija te za samo 58 % nastavnika sa završenim Učiteljskim fakultetom (tablica 2.67).

Značajniji rezultati odgovora na tvrdnje 2.7 i 2.8 opet su se pozicionirali oko nastavnika Učiteljskog fakulteta, no pokazalo se suprotno, odnosno pokazalo se kako su nastavnici sa završenim Učiteljskim fakultetom procijenili svoje znanje o interesima učenika i njihovim socio-kulturnim i ekonomskim statusom višim od ostalih nastavnika. Naime, u navedenim tvrdnjama nastavnici učiteljskog studija daju pozitivnu samoprocjenu u rasponu 80 – 90 % ispitanika što se pokazuje značajno višim od nastavnika svih drugih skupina završenog fakulteta čije se samoprocjene kreću u rasponu od 50 – 60 %.

4.2.2.3 Razlike u percipiranoj kompetentnosti i samoefikasnosti s obzirom na radni staž

U tablici 2.68 slijedi prikaz statistički značajnih razlika po istaknutim tvrdnjama s obzirom na radni staž nastavnika koristeći se jednosmjernom analizom varijance (One-way ANOVA test).

Tablica 2. 68: *Analiza varijance u samoprocjenama nastavnika s obzirom na radni staž*

Tvrdnje	F-omjer	Stat. znač.
2.2 Razumijem povijesnu i društvenu ulogu matematike u znanosti, kulturi, umjetnosti i tehnologiji te njezin potencijal za budućnost društva.	2.892	.035*
2.5 Osjećam se kompetentnim za pripremu nadarenih učenika za državno natjecanje.	4.720	.003**
2.17 Razumijem osnovna načela rada s nadarenim učenicima.	6.397	.000***

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

U nastavku slijede post-hoc testovi višestrukih usporedbi među grupama na tvrdnjama koje su se izdvojile značajnima u jednosmjernoj analizi varijance.

Tablica 2. 69: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama nastavnika u samoprocjenama s obzirom na radni staž*

Tvrdnje	(I) Godine radnog staža	(J) Godine radnog staža	Std. greška	Stat. znač.
2.2 Razumijem povijesnu i društvenu ulogu matematike u znanosti, kulturi, umjetnosti i tehnologiji te njezin potencijal za budućnost društva.	0 - 5	6-15	.097	.413
		16-29	.089	.139
		30-45	.101	.054
2.5 Osjećam se kompetentnim za pripremu nadarenih učenika za državno natjecanje.	30 - 45	0-5	.138	.016*
		6-15	.135	.029*
		16-29	.124	.510
2.17 Razumijem osnovna načela rada s nadarenim učenicima.	0 - 5	6-15	.102	.084
		16-29	.094	.002**
		30-45	.105	.003**

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Iako smo jednosmjernom analizom varijance utvrdili kako postoje statistički značajne razlike u tvrdnji 2.2, daljnjim ispitivanjem Scheffe testa usporedbe među grupama pokazalo se kako nema statistički značajnih razlika između bilo kojih grupa (na razini od 5 %) u samoprocjeni razumijevanja povijesne i društvene uloge matematike u znanosti, kulturi, umjetnosti i tehnologiji te u razumijevanju njezina potencijala za budućnost društva.

Najkompetentniijim za rad s nadarenom djecom osjećaju se nastavnici koji imaju 30 i vše godina radnog staža, a utvrđene su statistički značajne razlike između najiskusnijih nastavnika i obiju skupina do 15 godina radnog staža (tablica dolje). Iz tablice se vidi kako se nastavnici postupno s godinama iskustva osjećaju sve spremnijima za rad s nadarenima.

Tablica 2. 70: *Razlike među nastavnicima s obzirom na radni staž u tvrdnji 2.5*

		2.5 Osjećam se kompetentnim za pripremu nadarenih učenika za državno natjecanje.					Ukupno
		Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
Godine radnog staža	0 - 5	1	7	24	34 (46 %)	8 (11 %)	74
	6 - 15	0	8	26	38 (47 %)	9 (11 %)	81
	16 - 29	1	7	32	56	26	122
	30 - 45	0	1	16	36 (51 %)	18 (26 %)	71
Ukupno		2	23	98	164	61	348

Isto je utvrđeno u tvrdnji 2.17 kojom se pokazalo kako se mlađi nastavnici zbog nedostatnog iskustva ne osjećaju spremnim te ne razumiju načela rada s nadarenim učenicima. Pritom je ustanovljeno kako se nastavnici početnici osjećaju znatno manje osposobljeno za rad s nadarenim učenicima nego nastavnici s 15 i više godina radnog staža (tablica 2.71).

Tablica 2. 71: *Razlike među nastavnicima s obzirom na radni staž u tvrdnji 2.17*

		2.17 Razumijem osnovna načela u radu s nadarenim učenicima.				Ukupno
		Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	
Godine radnog staža	0 - 5	2	21	41	10	74
	6 - 15	1	9	55	16	81
	16 - 29	2	13	70	37	122
	30 - 45	0	4	49	18	71
Ukupno		5	47	215	81	348

4.2.2.4 Razlike u percipiranoj kompetentnosti i samoefikasnosti s obzirom na stečenu dodatnu naobrazbu

U tablici u nastavku slijede statistički značajne razlike po tvrdnjama s obzirom na spol koristeći se jednosmjernom analizom varijance (One-way ANOVA test).

Tablica 2. 72: *Razlike među nastavnicima u samoprocjenama kompetnenosti i samoefikasnosti s obzirom na radni staž*

Tvrdnje	F-omjer	Stat. znač.
2.1 Posjedujem znanja o naprednim matematičkim temama koje nisu dio školske matematike.	3.586	.029*
2.2 Razumijem povijesnu i društvenu ulogu matematike u znanosti, kulturi, umjetnosti i tehnologiji te njezin potencijal za budućnost društva.	5.132	.006**
2.4 Imam duboko razvijena konceptualna znanja matematike.	8.588	.000***
2.5 Osjećam se kompetentnim za pripremu nadarenih učenika za državno natjecanje.	4.826	.009**
2.15 Znam kako ukloniti i prevenirati probleme u učenju matematike.	3.296	.038*
2.17 Razumijem osnovna načela rada s nadarenim učenicima.	7.031	.001**

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Na istaknutim tvrdnjama provest će se post-hoc Scheffe testovi višestrukih usporedbi među grupama na tvrdnjama koje su se pokazale značajnima u provedenoj jednosmjernoj analizi varijance.

Tablica 2. 73: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na stečenu dodatnu naobrazbu ispitanika*

Tvrdnje	(I) Stečena dodatna naobrazba	(J) Stečena dodatna naobrazba	Razlika u arit. sredinama (I-J)	Std. greška	Stat. znač.
2.1 Posjedujem znanja o naprednim matematičkim temama koje nisu dio školske matematike.	Profesor/učitelj mentor	Profesor/učitelj savjetnik	-.367*	.142	.036*
		Ništa od navedenoga	-.094	.104	.664
2.2 Razumijem povijesnu i društvenu ulogu matematike u znanosti, kulturi, umjetnosti i tehnologiji te njezin potencijal za budućnost društva.	Ništa od navedenoga	Profesor/učitelj mentor	-.236*	.082	.017*
2.4 Imam duboko razvijena konceptualna znanja matematike.	Ništa od navedenoga	Profesor/učitelj mentor	-.282*	.086	.005**
		Profesor/učitelj savjetnik	-.315*	.099	.007**
2.5 Osjećam se kompetentnim za pripremu nadarenih učenika za državno natjecanje.	Ništa od navedenoga	Profesor/učitelj mentor	-.264	.114	.070
		Profesor/učitelj savjetnik	-.329*	.131	.045*
2.15 Znam kako ukloniti i prevenirati probleme u učenju matematike.	Profesor/učitelj mentor	Ništa od navedenoga	.213	.093	.073
2.17 Razumijem osnovna načela rada s nadarenim učenicima.	Ništa od navedenoga	Profesor/učitelj mentor	-.261*	.087	.012*
		Profesor/učitelj savjetnik	-.283*	.100	.019*

**** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$*

U prvoj tvrdnji (2.1) pomalo neočekivano značajna razlika pokazala se između nastavnika koji su napredovali u status mentora i nastavnika u statusu savjetnika (tablica 2.74).

Tablica 2. 74: *Razlike u samoprocjenama nastavnika s obzirom na stečenu dodatnu naobrazbu u tvrdnji 2.1*

	2.1 Posjedujem znanja o naprednim matematičkim temama koje nisu dio školske matematike.					
	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
Profesor/učitelj mentor	0	6	8	46 (66 %)	10 (14 %)	70
Profesor/učitelj savjetnik	0	0	8	22 (45 %)	19 (39 %)	49
Ništa od navedenoga	1	9	39	128	49	226
Ukupno	1	15	55	196	78	345

Iako se obje skupine nastavnika procjenjuju kompetentnim u naprednim matematičkim temama, ipak se pokazuje kako se nastavnici mentori znatno manje (14 %) potpuno slažu s navedenom tvrdnjom što je iskazalo gotovo 40 % nastavnika savjetnika.

U tvrdnji 2.2 rezultati su očekivano hipotezama pokazali kako nastavnici koji nisu napredovali u status mentora svoje razumijevanje matematike i njezine povijesne i društvene uloge ne procjenjuju na toliko visokoj razini kao nastavnici mentori (tablica 2.75).

Tablica 2. 75: *Razlike u samoprocjenama nastavnika s obzirom na stečenu dodatnu naobrazbu u tvrdnji 2.2*

	2. 2 Razumijem povijesnu i društvenu ulogu matematike u znanosti, kulturi, umjetnosti i tehnologiji te njezin potencijal za budućnost društva.				
	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
Profesor/učitelj mentor	0	5	41	24	70
Profesor/učitelj savjetnik	0	4	30	15	49
Ništa od navedenoga	3	29	151	43	226
Ukupno	3	38	222	82	345

U tvrdnji 2.4 također se očekivanim pokazalo kako su nastavnici koji su napredovali u zvanja znatno manje procjenjuju svoju stručnu kompetentnost u matematici nego nastavnici savjetnici i mentori (tablica 2.76).

Tablica 2. 76: *Razlike u samoprocjenama nastavnika s obzirom na stečenu dodatnu naobrazbu u tvrdnji 2.4*

	2.4 Imam duboko razvijena konceptualna znanja matematike.					
	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
Profesor/učitelj mentor	1	0	2	50 (71 %)	17 (24 %)	70
Profesor/učitelj savjetnik	0	0	6	27 (55 %)	16 (33 %)	49
Ništa od navedenoga	0	1	56	136 (60 %)	33 (15 %)	226
Ukupno	1	1	64	213	66	345

To je u skladu s tvrdnjom 2.5 (tablica 2.77) kojom se također potvrdilo kako se nastavnici koji nisu napredovali u zvanju osjećaju manje kompetentnim, od nastavnika savjetnika, u pripremi nadarenih učenika za državna natjecanja, a to je dobar pokazatelj stručnih znanja koja su izvan okvira nastavnih planova i programa ili pak po dubini razumijevanja i primjene istih znanja.

Tablica 2. 77: *Razlike u samoprocjenama nastavnika s obzirom na stečenu dodatnu naobrazbu u tvrdnji 2.5*

	2.5 Osjećam se kompetentnim za pripremu nadarenih učenika za državno natjecanje.				
	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
Profesor/učitelj mentor	3	13	37	16	70
Profesor/učitelj savjetnik	0	13	24	12	49
Ništa od navedenoga	20	69	103	33	226
Ukupno	23	95	164	61	345

Tu je nužno istaknuti specifičnost zadataka na matematičkim natjecanjima koji su tematski iz područja koja se redovito rade u nastavnom planu i programu. Praksa pokazuje kako i učenici odličnog uspjeha u prirodoslovno-matematičkim gimnazijama nemaju prilike imati značajan rezultat na školskim i županijskim natjecanjima ukoliko se redovito, pored redovne nastave, ne pripremaju u sklopu dodatnih nastava, centara izvrsnosti i drugih oblika stjecanja znanja. Sukladno tome, nastavnici koji nemaju kontinuitet u rad s nadarenim učenicima jednostavno ne mogu biti spremni na raznolikost i specifičnost zahtjeva tih zadataka za razliku od nastavnika kojima su ti zadatci već u nekoj rutinskoj pripremi u okvirima njihove odgojno-obrazovne prakse.

Međutim, kod nastavnika koji ne procjenjuju svoju stručnost kao nastavnici koji su napredovali u zvanja, potrebno je oprezno izvoditi zaključke o općoj stručnoj pripremljenosti nastavnika zato što to ne mora značiti kako oni nisu stručni na visokoj razini u pripremi i izvođenju redovne nastave. Naime, mnogi od tih nastavnika rade u strukovnim i medicinskim školama, općoj gimnaziji te zbog selekcije učenika po odgojno-obrazovnim srednjoškolskim programima jednostavno nemaju toliko prilike raditi s darovitom djecom pa njihova stručna znanja i vježbanje natjecateljskih zadataka nije dio njihove prakse, a s godinama rada osjećaju se manje spremnima za iste. Slično kao i za neka napredna područja matematike koja su zadnji put proučavali u vrijeme studija.

Utjecaj prakse na stručnu osposobljenost nastavnika ima još veći utjecaj kod nastavnika koji rade u osnovnim školama zato što su nastavni planovi i programi osnovne škole svojim opsegom tek u začetcima matematičkih sadržaja, koncepata i teorija pa je očekivano kako s godinama rada u osnovnoj školi nastavnici postupno izađu iz kontinuiteta naprednijih matematičkih znanja. Jednako se pokazalo kako mentori i savjetnici procjenjuju s višim ocjenama svoje znanje u radu s nadarenim učenicima nego nastavnici koji nisu napredovali u zvanju (tablica 2.78).

Tablica 2. 78: *Razlike u samoprocjenama nastavnika s obzirom na stečenu dodatnu naobrazbu u tvrdnji 2.17*

	2.17 Razumijem osnovna načela rada s nadarenim učenicima.				
	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
Profesor/učitelj mentor	0	7	39 (56 %)	24 (34 %)	70
Profesor/učitelj savjetnik	2	0	30 (61 %)	17 (35 %)	49
Ništa od navedenoga	3	38	145 (64 %)	40 (18 %)	226
Ukupno	5	45	214	81	345

U preostaloj tvrdnji 2.15: *Znam kako ukloniti i prevenirati probleme u učenju matematike*. pokazalo se kako nastavnici mentori imaju više samoprocjene od nastavnika koji nisu napredovali u zvanju.

Tablica 2. 79: *Razlike u samoprocjenama nastavnika s obzirom na stečenu dodatnu naobrazbu u tvrdnji 2.15*

	2.15 Znam kako ukloniti i prevenirati probleme učenika u učenju matematike					
	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
Profesor/učitelj mentor	0	0	25	37 (53 %)	8 (11 %)	70
Profesor/učitelj savjetnik	0	0	14	35	0	49
Ništa od navedenoga	1	14	86	111 (49 %)	14 (6 %)	226
Ukupno	1	14	125	183	22	345

Znakovito je kako tvrdnja 2.15 ima među varijablama iz samoprocjena kompetentnosti jednu od najnižih aritemetičkih sredina (3.61) uz relativno niska odstupanja, a s obzirom na specifičnosti nastave matematike u kontekstu afektivnog i emocionalnog područja, ovo je dosljedno teorijskim promišljanjima i brojnim istraživanjima unutar kojih je razvidno kako je u tom području velik potencijal za razvoj kvalitete nastave matematike.

4.2.2.5 Razlike u percipiranoj kompetentnosti i samoefikasnosti s obzirom na radno mjesto

Razlike u samoprocjenama nastavnika s obzirom na radno mjesto slijede u tablici 2.80 prema rezultatima jednosmjerne analize varijance (One-way ANOVA test).

Tablica 2. 80: *Analiza varijance za samoprocjene nastavnika s obzirom na radno mjesto*

Tvrdnje	F-omjer	Stat. znač.
2.6 Razumijem temeljna načela alternativnih pedagoških koncepata i njihove primjene u nastavi matematike.	3.538	.030*
2.7 Posjedujem znanja o interesima svojih učenika.	6.766	.001**
2.8 Upoznat sam sa socio-kulturnim i ekonomskim statusom svojih učenika.	16.535	.000***
2.9 Uvažavam socijalne i kulturne razlike učenika u nastavnim aktivnostima kao i kod ocjenjivanja i očekivanjima koje postavljam pred njih.	9.401	.000***
2.13 U nastavi uočavam tempo kojim učenici svladavaju matematičke sadržaje.	3.210	.042*
2.14 Znam prepoznati učenika koji ima diskalkuliju.	9.345	.000***
2.15 Znam kako ukloniti i prevenirati probleme u učenju matematike.	4.293	.014*
2.17 Razumijem osnovna načela rada s nadarenim učenicima.	4.215	.016*
2.18 Razumijem temeljne smjernice koncepta cjeloživotnog učenja te ulogu matematičkog područja u tom kontekstu.	3.065	.048*

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

U nastavku će se u tablici 2.81 prikazati rezultati post-hoc Scheffe testa višestrukih usporedbi među grupama nastavnika prema radnom mjestu te će se istaknuti samo grupe između kojih su ustanovljene razlike na razini od 5 % statističke značajnosti.

Tablica 2. 81: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na radno mjesto nastavnika*

Tvrdnje	(I) Radno mjesto	(J) Radno mjesto	Razlika u arit. sredinama (I-J	Std. greška	Stat. znač.
2.6 Razumijem temeljna načela alternativnih pedagoških koncepata i njihove primjene u nastavi matematike.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.239*	.095	.044*
2.7 Posjedujem znanja o interesima svojih učenika.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.315*	.093	.003*
		Gimnazija	.256*	.093	.023*
2.8 Upoznat sam sa socio-kulturnim i ekonomskim statusom svojih učenika.		Srednja strukovna škola	.497*	.116	.000***

	Osnovna škola (predmetna nastava)	Gimnazija	.614*	.115	.000***
2.9 Uvažavam socijalne i kulturne razlike učenika u nastavnim aktivnostima kao i kod ocjenjivanja i očekivanjima koje postavljam pred njih.	Osnovna škola (predmetna nastava)	Gimnazija	.478*	.110	.000***
2.13 U nastavi uočavam tempo kojim učenici svladavaju matematičke sadržaje.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.185	.076	.054
2.14 Znam prepoznati učenika koji ima diskalkuliju.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.295*	.109	.027*
		Gimnazija	.460*	.109	.000***
2.15 Znam kako ukloniti i prevenirati probleme u učenju matematike.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.228*	.088	.035*
2.17 Razumijem osnovna načela rada s nadarenim učenicima.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.229*	.084	.024*
2.18 Razumijem temeljne smjernice koncepta cjeloživotnog učenja te ulogu matematičkog područja u tom kontekstu.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.227*	.092	.048*
		Gimnazija	.104	.092	.524
	Srednja strukovna škola	Osnovna škola (predmetna nastava)	-.227*	.092	.048*
		Gimnazija	-.123	.097	.451

**** p < 0.001, ** p < 0.01, * p < 0.05*

Post-hoc Scheffe testom utvrđene su razlike (2.81) koje se dominantno ističu kod nastavnika koji rade u osnovnim školama, a svoja znanja u istaknutim tvrdnjama samoprocjenjuju značajno boljima od nastavnika koji rade u srednjim školama. Stoga ćemo za sljedeća pitanja objedinjeno prikazati utvrđene razlike:

Tvrdnja 2.6: „Razumijem temeljna načela alternativnih pedagoških koncepata i njihove primjene u nastavi matematike.“

Tvrdnja 2.7: „Posjedujem znanja o interesima svojih učenika.“

Tvrdnja 2.8: „Upoznat sam sa socio-kulturnim i ekonomskim statusom svojih učenika.“

Tvrdnja 2.9: „Uvažavam socijalne i kulturne razlike učenika u nastavnim aktivnostima kao i kod ocjenjivanja i očekivanjima koje postavljam pred njih.“

Tvrdnja 2.13: „U nastavi uočavam tempo kojim učenici svladavaju matematičke sadržaje.“

Tvrdnja 2.14: „Znam prepoznati učenika koji ima diskalkuliju.“

Tvrdnja 2.15: „Znam kako ukloniti i prevenirati probleme u učenju matematike“

Tvrdnja 2.17: „Razumijem osnovna načela rada s nadarenim učenicima.“

Tvrdnja 2.18: „Razumijem temeljne smjernice koncepta cjeloživotnog učenja te ulogu matematičkog područja u tom kontekstu.“

U tvrdnji 2.6 očekivanim se pokazuje kako su nastavnici osnovnih škola stekli više znanja o alternativnim pedagoškim konceptima. S obzirom na to da je jedna trećina tih nastavnika završila Učiteljski fakultet gdje su nastavnici stekli više pedagoško-psiholoških i didaktičko-metodičkih znanja i vještina te kako je rad u osnovnoj školi u većoj mjeri odgojnog karaktera, može se pretpostaviti (prema tvrdnjama 2.7, 2.8. 2.9 i 2.15) kako su i ostali nastavnici koji rade u osnovnim školama kroz praksu naučili svoj rad prilagoditi djeci i njihovim potrebama, upoznati su sa socio-kulturnim i ekonomskim statusom svojih učenika te uvažavaju socijalne i kulturne razlike učenika u nastavnim aktivnostima kao i kod ocjenjivanja i očekivanjima koje postavljj pred njih.

Također, specifično je u kontekstu nastave matematike prepoznavanje diskalkulije zato što se nastavnici koji rade u osnovnim školama smatraju osposobljenima u 65 % slučajeva, u slučaju nastavnika koji rade u srednjim strukovnim školama to isto iznosi 46 % te 42 % za nastavnike koji rade u gimnazijama.

Tablica 2. 82: *Razlike u samoprocjenama nastavnika s obzirom radno mjesto u tvrdnji 2.14*

	2.14 Znam prepoznati učenika koji ima diskalkuliju.					
	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem	Ukupno
Osnovna škola (predmetna nastava)	1	5	44	64	22	136
Srednja strukovna škola	2	10	45	35	13	105
Gimnazija	2	15	45	39	5	106
Ukupno	5	30	134	138	40	347

Međutim, s obzirom na složenost detekcije diskalkulične djece, ovi podatci samoprocjena relativno su visoki. Svakako je bilo očekivano da u osnovnim školama zbog drugačije metodike i sadržaja, koji su ponajviše usmjereni na aritmetiku, više dolaze do izražaja vještine mentalne aritmetike koja je kod neke djece znatno ispod njihova stupnja općeg kognitivnog funkcioniranja. Međutim, teško je dati zaključak prepoznaju li učitelji u osnovnim školama djecu koja imaju diskalkuliju ili je razlog u prirodi sadržaja početne nastave matematike zato

što se lakše uočavaju djeca koja nešto sporije računaju, od kojih neki imaju diskalkuliju, te drugi koji sporije računaju uslijed nepovoljnih čimbenika iz njihove odgojno-obrazovne okoline.

U tvrdnjama 2.15 i 2.18 također se pokazalo kako nastavnici koji rade u osnovnim školama više od ostalih nastavnika smatraju kako znaju ukloniti i prevenirati probleme u učenju matematike te kako su upoznati s temeljnim smjernicama koncepta cjeloživotnog učenja te ulogu matematičkog područja u tom kontekstu.

4.2.3 Deskriptivna analiza ljestvice učestalosti nastavnih i izvannastavnih praksi

Nakon analize uvjerenja nastavnika o nastavi i obrazovanju općenito te samoprocjene kompetentnosti nastavnika, provedena je analiza učestalosti nastavnih i izvannastavnih praksi. Za navedena pitanja ispitanici su trebali zaokružiti brojeve od jedan do pet na Likertovoj ljestvici koja opisuju učestalost njihovih nastavnih aktivnosti, metoda te aktivnosti i učešća u profesionalnom razvoju i stručnom usavršavanju**:**
(1 = nikad / gotovo nikad; 2 = rijetko; 3 = ponekad; 4 = često; 5 = uvijek/gotovo uvijek)

U nastavku (tablica 2.83) slijedi analiza tvrdnji prema osnovnim parametrima deskriptivne statistike te će se interpretirati učestalosti odgovora po pojedinim tvrdnjama.

Tablica 2. 83: *Osnovni deskriptivni parametri ljestvice učestalosti nastavnih i izvannastavnih praksi*

Tvrdnje	Arit. sredina	Stand. Dev.
2.21 Pohađam stručno-metodičke skupove i (među)županijska vijeća.	4.61	.619
2.22 Sudjelujem u projektima mobilnosti nastavnika.	2.36	1.245
2.23 Sudjelujem u projektima kolegijalnog opažanja zajedno s drugim nastavnicima.	3.04	1.228
2.24 Uspješnost svog rada evaluiram prema ciljevima Nacionalnog okvirnog kurikuluma.	3.28	.953
2.25 Evaluiram i procjenjujem uspješnost svojeg poučavanja na kraju sata.	3.62	.920
2.26 Sudjelujem u akcijskom istraživanju zajedno s kolegama i učenicima.	2.95	1.149
2.27 Učenicima dajem anonimni evaluacijski upitnik kako bi iznijeli svoje kritike, mišljenja i prijedloge o aktivnostima te načinima unapređenja nastavnog procesa.	2.85	1.222
2.28 U nastavi ističem da svaki učenik može biti uspješan u matematici.	4.20	.730
2.29 Ukazujem na važnost upornosti i radnih navika za uspjeh u matematici.	4.68	.503
2.30 Potičem pozitivne stavove prema učenju matematike kod slabijih učenika.	4.50	.605
2.31 U poučavanju matematike koristim se humorom.	4.22	.754
2.32 Individualno radim s učenicima koji sporije usvajaju sadržaje.	3.95	.867

2.33 Preventivno djelujem i pomažem učenicima koji imaju negativne stavove prema učenju matematike.	3.92	.730
2.34 Uočavam specifične reakcije kada učenici ne razumiju pojedine sadržaje.	4.26	.639
2.35 Koristim informatičke i komunikacijske tehnologije u poučavanju matematike.	3.76	.936
2.36 Pratim znanstvene inovacije u matematici.	3.62	.918
2.37 Koristim stvarne životne situacije kao polazište za učenje i poučavanje.	4.19	.707
2.38 U nastavi rješavam problemske zadatke povezane sa svakodnevicom.	4.10	.745
2.39 Odgojno-obrazovne aktivnosti temeljim na frontalnom obliku rada.	3.34	.793
2.40 Učenike uključujem u nastavne aktivnosti formiranjem u grupe i timove.	3.40	.831
2.41 Učenici usvajaju matematičke sadržaje radom u paru.	3.41	.800
2.42 Ostvarujem korelacije matematike s ostalim predmetima i disciplinama.	3.81	.746
2.43 Objašnjavam matematičke sadržaje, koncepte i procese jednostavnim jezikom koji učenici razumiju.	4.49	.555
2.44 Prilagođavam metode poučavanja tipičnim greškama i teškoćama učenika.	4.26	.598
2.45 Dajem učenicima da sami odaberu aktivnosti i način rada u nastavi.	2.61	.892

Detaljnije analize gornje tablice interpretirat i objedinit ćemo u nastavku zajedno sa testiranjem statističke značajnosti u razlikama redom po tvrdnjama s obzirom na nezavisne varijable koristeći se jednosmjernom analizom varijance (One-way ANOVA) s obzirom na:

a) spol (poglavlje 4.2.3.1)
b) inicijalno obrazovanje (poglavlje 4.2.3.2)
c) radni staž (poglavlje 4.2.3.3)
d) stečena dodatna naobrazba (poglavlje 4.2.3.4)
e) radno mjesto (poglavlje 4.2.3.5).

4.2.3.1 Razlike s obzirom na spol

Tablica 2. 84: *Analiza varijance ljestvice učestalosti nastavnih i izvannastavnih praksi s obzirom na spol nastavnika*

Tvrdnje	F-omjer	Stat. znač.
2.20 Nastavni proces organiziram prema odgojno-obrazovnim ciljevima pojedinih područja matematike zadanih Nacionalnim okvirnim kurikulumom.	9.935	.002**
2.21 Pohađam stručno-metodičke skupove i (među)županijska vijeća.	24.847	.000***
2.22 Sudjelujem u projektima mobilnosti nastavnika.	8.682	.003**
2.24 Uspješnost svog rada evaluiram prema ciljevima Nacionalnog okvirnog kurikuluma.	6.706	.010*
2.26 Sudjelujem u akcijskom istraživanju zajedno s kolegama i učenicima.	7.199	.008**
2.27 Učenicima dajem anonimni evaluacijski upitnik kako bi iznijeli svoje kritike, mišljenja i prijedloge o aktivnostima te načinima unapređenja nastavnog procesa.	5.329	.022*
2.28 U nastavi ističem da svaki učenik može biti uspješan u matematici.	13.862	.000***
2.29 Ukazujem na važnost upornosti i radnih navika za uspjeh u matematici.	12.389	.000***
2.30 Potičem pozitivne stavove prema učenju matematike kod slabijih učenika.	42.727	.000***
2.31 U poučavanju matematike koristim se humorom.	4.524	.034*
2.32 Individualno radim s učenicima koji sporije usvajaju sadržaje.	5.124	.024*
2.33 Preventivno djelujem i pomažem učenicima koji imaju negativne stavove prema učenju matematike.	6.673	.010*
2.34 Uočavam specifične reakcije kada učenici ne razumiju pojedine sadržaje.	8.572	.004**
2.37 Koristim stvarne životne situacije kao polazište za učenje i poučavanje.	11.237	.001**
2.38 U nastavi rješavam problemske zadatke povezane sa svakodnevicom.	32.772	.000***
2.39 Odgojno-obrazovne aktivnosti temeljim na frontalnom obliku rada.	6.417	.012*
2.40 Učenike uključujem u nastavne aktivnosti formiranjem u grupe i timove.	13.847	.000***
2.41 Učenici usvajaju matematičke sadržaje radom u paru.	7.829	.005**
2.43 Objašnjavam matematičke sadržaje, koncepte i procese jednostavnim jezikom koji učenici razumiju.	12.693	.000***
2.44 Prilagođavam metode poučavanja tipičnim greškama i teškoćama učenika.	4.144	.043*
2.45 Dajem učenicima da sami odaberu aktivnosti i način rada u nastavi.	8.742	.003**

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

S obzirom na utvrđene različite varijance, sve su tvrdnje podvrgnute t-testu kojim se pokazalo kako se ispitanici razlikuju s obzirom na spol sukladno provedenoj analizi varijance na danim tvrdnjama. Budući da se u većini tvrdnji ovog dijela ljestvice pokazuju značajne razlike u spolu, prikazat ćemo ih zbirno prema tvrdnjama za koje očekujemo da su dio neke latentne dimenzije što ćemo u poglavlju 4.3 istražiti korištenjem faktorske analize. Rezultati pokazuju kako se nastavnice u pripremi, izvedbi i evaluaciji nastavnog procesa znatno više vode dokumentima Nacionalnog okvirnog kurikuluma. Pored toga, nastavnice dvostruko češće pohađaju stručno-metodičke skupove i (među)županijska vijeća te sudjeluju u projektima mobilnosti i akcijskim istraživanjima.

Što se tiče evaluacije vlastita rada kroz mišljenja učenika, pokazalo se kako 37 % nastavnica nikad ili rijetko daju učenicima evaluacijski upitnik glede njihova rada, a kod muških nastavnika njih 52 % nikad ili rijetko daju isto u svrhu evaluacije i refleksije vlastita rada. Također se očekivanim pokazalo kako 40 % nastavnica i 62 % muških nastavnika nikad ili rijetko daju učenicima da sami odaberu aktivnosti i način rada u nastavi. Premda se to može tumačiti kao negativan aspekt, ipak se mora uzeti u obzir kako su nastavni planovi i programi nastave matematike objektivno preopterećeni. Zbog značajnog mjesta matematike u kontekstu državne mature i svih relevantnih istraživanja obrazovanja te zbog selekcije studenata na fakultetima, pokazuje se kako je dosta pritisaka i obvezujućih čimbenika koji direktno i indirektno utječu na rad nastavnika matematike.

U sljedećim tvrdnjama koje se tiču socijalne i emocionalne kompetencije (tvrdnje od 2.28 do 2.34) također se značajanim pokazalo kako nastavnice uglavnom dvostruko učestalijim procjenjuju svoje nastavne metode i aktivnosti u navedenim tvrdnjama nego što to čine muški nastavnici.

Tvrdnja 2.28: „U nastavi ističem da svaki učenik može biti uspješan u matematici.“

Tvrdnja 2.29: „Ukazujem na važnost upornosti i radnih navika za uspjeh u matematici.“

Tvrdnja 2.30: „Potičem pozitivne stavove prema učenju matematike kod slabijih učenika.“

Tvrdnja 2.31: „U poučavanju matematike koristim se humorom.“

Tvrdnja 2.32: „Individualno radim s učenicima koji sporije usvajaju sadržaje.“

Tvrdnja 2.33: „Preventivno djelujem i pomažem učenicima koji imaju negativne stavove prema učenju matematike.“

Tvrdnja 2.34: „Uočavam specifične reakcije kada učenici ne razumiju pojedine sadržaje.“

Ovdje će se također raditi detaljnije analize s faktorskom analizom i utvrđivanjem povezanosti sa stavovima i uvjerenjima te samoprocjenama iz prvih dviju ljestvica istraživačkog upitnika. Nakon provedenih faktorskih analiza, provest će se i regresijska analiza u kojoj se očekuje kako će spol biti među značajnijim prediktorima stavova, uvjerenja, samoprocjena i učestalosti nastavnih i izvannastavnih metoda i aktivnosti nastavnika.

U kontekstu učestalosti nastavnih metoda u sferi metodičke kompetencije (tvrdnje 2.37, 2.38, 2.43 i 2.44) samoprocjena nastavnica također je znatno viša od muških nastavnika što upućuje kako pored socijalnih i emocionalnih znanja i vještina nastavnice u svom radu koriste metode primjerenije suvremenom poimanju poučavanja.

Tvrdnja 2.37: „Koristim stvarne životne situacije kao polazište za učenje i poučavanje.“
Tvrdnja 2.38: „U nastavi rješavam problemske zadatke povezane sa svakodnevicom.“
Tvrdnja 2.43: „Objašnjavam matematičke sadržaje, koncepte i procese jednostavnim jezikom koji učenici razumiju.“
Tvrdnja 2.44: „Prilagođavam metode poučavanja tipičnim greškama i teškoćama učenika.“

Što se tiče socijalnih oblika rada, ustanovljene su znakovite razlike (tablica dolje). Dakle, 61 % muških nastavnika često ili gotovo uvijek svoje odgojno-obrazovne aktivnosti temelje na frontalnom obliku rada, a to isto pokazalo se kod 38 % nastavnica.

Tablica 2. 85: *Razlike u učestalosti nastavnih i izvannastavnih praksi nastavnika u tvrdnji 2.39*

		2.39 Odgojno-obrazovne aktivnosti temeljim na frontalnom obliku rada.					
		Nikad/gotovo nikad	Rijetko	Ponekad	Često	Uvijek/gotovo uvijek	Ukupno
Spol	Muški	2	1	20	36 (59 %)	2 (3 %)	61
	Ženski	5	30	144	92 (32 %)	16 (6 %)	287
Ukupno		7	31	164	128	18	348

U skladu s time, očekivano se organizacija procesa učenja i poučavanja u timskom, grupnom i radu u grupama znatno češće realizira kod nastavnica.

Tablica 2. 86: *Razlike u učestalosti nastavnih i izvannastavnih praksi nastavnika u tvrdnji 2.40*

		2.30 Učenike uključujem u nastavne aktivnosti formiranjem u grupe i timove.					
		Nikad/gotovo nikad	Rijetko	Ponekad	Često	Uvijek/gotovo uvijek	Ukupno
Spol	Muški	3	10	31	15	2	61
	Ženski	0	29	120	110	28	287
Ukupno		3	39	151	125	30	348

Iako je u oba spola najfrekventniji odgovor „ponekad“ koji je kod muških nastavnika u obje tvdnje bio oko 50 %, a kod nastavnica 40 %, značajne razlike utvrđene su u afirmativnim odgovorima u kojima 50 % nastavnica i 30 % muških nastavnika često ili uvijek učenike uključuju u nastavne aktivnosti formiranjem u grupe, timove ili rad u paru (tablica 2.86, tablica 2.87).

Tablica 2. 87: *Razlike u učestalosti nastavnih i izvannastavnih praksi nastavnika u tvrdnji 2.41*

		2.41 Učenici usvajaju matematičke sadržaje radom u paru.					
		Nikad/gotovo nikad	Rijetko	Ponekad	Često	Uvijek/gotovo uvijek	Ukupno
Spol	Muški	2	10	29	17	3	61
	Ženski	0	26	127	110	24	287
Ukupno		2	36	156	127	27	348

4.2.3.2 Razlike s obzirom na inicijalno obrazovanje

Jednosmjernom analizom varijance ljestvice učestalosti nastavnih i izvannastavnih praksi nastavnika s obzirom na njihovo inicijalno obrazovanje, utvrđeni su sljedeći rezultati (tablica 2.88).

Tablica 2. 88: *Analiza varijance ljestvice učestalosti nastavnih i izvannastavnih praksi s obzirom na inicijalno obrazovanje nastavnika*

	F-omjer	**Stat. znač.**
2.28 U nastavi ističem da svaki učenik može biti uspješan u matematici.	3.154	.025*
2.31 U poučavanju matematike koristim se humorom.	3.264	.022*
2.32 Individualno radim s učenicima koji sporije usvajaju sadržaje.	8.855	.000***
2.33 Preventivno djelujem i pomažem učenicima koji imaju negativne stavove prema učenju matematike.	4.719	.003**
2.36 Pratim znanstvene inovacije u matematici.	2.970	.032*
2.37 Koristim stvarne životne situacije kao polazište za učenje i poučavanje.	8.835	.000***
2.38 U nastavi rješavam problemske zadatke povezane sa svakodnevicom.	9.156	.000***
2.40 Učenike uključujem u nastavne aktivnosti formiranjem u grupe i timove.	3.867	.010*
2.43 Objašnjavam matematičke sadržaje, koncepte i procese jednostavnim jezikom koji učenici razumiju.	3.139	.026*

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

U nastavku slijede post-hoc Scheffe testovi višestrukih usporedbi među grupama na tvrdnjama koje su se izdvojile jednosmjernom analizom varijanci.

Tablica 2. 89: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na radno mjesto nastavnika*

Dependent Variable	(I) Inicijalno obrazovanje	(J) Inicijalno obrazovanje	Std. greška	Stat. znač.
2.31 U poučavanju matematike koristim se humorom.	Učiteljski fakultet	PMF (nastavnički smjer)	.126	.428
		PMF (inženjerski smjer)	.144	.400
		Ostalo	.170	.023*
2.32 Individualno radim s učenicima koji sporije usvajaju sadržaje.	Učiteljski fakultet	PMF (nastavnički smjer)	.141	.000***
		PMF (inženjerski smjer)	.162	.000***
		Ostalo	.191	.017*
2.33 Preventivno djelujem i pomažem učenicima koji imaju negativne stavove prema učenju matematike.	Učiteljski fakultet	PMF (nastavnički smjer)	.121	.009**
		PMF (inženjerski smjer)	.138	.010*
		Ostalo	.164	.040*

2.36 Pratim znanstvene inovacije u matematici.	Učiteljski fakultet	PMF (nastavnički smjer)	.153	.294
		PMF (inženjerski smjer)	.175	.406
		Ostalo	.207	.032*
2.37 Koristim stvarne životne situacije kao polazište za učenje i poučavanje.	Učiteljski fakultet	PMF (nastavnički smjer)	.115	.004**
		PMF (inženjerski smjer)	.132	.000***
		Ostalo	.156	.176
2.38 U nastavi rješavam problemske zadatke povezane sa svakodnevicom.	Učiteljski fakultet	PMF (nastavnički smjer)	.121	.002**
		PMF (inženjerski smjer)	.139	.000***
		Ostalo	.164	.095
2.40 Učenike uključujem u nastavne aktivnosti formiranjem u grupe i timove.	Učiteljski fakultet	PMF (nastavnički smjer)	.138	.429
		PMF (inženjerski smjer)	.158	.083
		Ostalo	.187	.031*
2.43 Objašnjavam matematičke sadržaje, koncepte i procese jednostavnim jezikom koji učenici razumiju.	Učiteljski fakultet	PMF (nastavnički smjer)	.092	.083
		PMF (inženjerski smjer)	.105	.317
		Ostalo	.124	.044*

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Sve utvrđene razlike ustanovljene su oko nastavnika sa završenim Učiteljskim fakultetom. Međutim, višestrukom usporedbom među grupama pomoću Scheffe testa, ustanovljeno je kako na tvrdnji 2.28: *U nastavi ističem da svaki učenik može biti uspješan u matematici* nema razlika među grupama. Nastavnici sa završenim Učiteljskim fakultetom znatno se češće koriste humorom u nastavi matematike nego nastavnici iz kategorije „ostalo“.

U tvrdnjama 2.32, 2.33, 2.37 i 2.38 ustanovljene su razlike između nastavnika sa završenim Učiteljskiim fakultetom i nastavnika sa završenim nastavničkim i inženjerskim smjerom na Prirodoslovno-matematičkom fakultetu.

2.32: „Individualno radim s učenicima koji sporije usvajaju sadržaje.“

2.33: „Preventivno djelujem i pomažem učenicima koji imaju negativne stavove prema učenju matematike.“

2.37: „Koristim stvarne životne situacije kao polazište za učenje i poučavanje.“

2.38: „U nastavi rješavam problemske zadatke povezane sa svakodnevicom.“

Očekivanim se pokazalo kako nastavnici sa završenim PMF-om značajno rijeđe individualiziraju svoj rad prema učenicima s teškoćama, no također se pokazalo kako rijeđe rješavaju problemske zadatke i ostvaruju koncept problemske nastave kojom bi povezali matematiku sa svakodnevicom i stvarnim životnim situacijama. Ostale razlike utvrđene višestrukim usporedbama ustanovljene su između nastavnika Učiteljskog fakulteta i nastavnika

iz kategorije „ostalo“. Time se pokazalo kako nastavnici Učiteljskog fakulteta znatno češće realiziraju nastavne aktivnosti kroz rad u grupama i timovima te pojašanjavaju sadržaje jednostavnim jezikom razumljivim učenicima, no znatno manje prate znanstvene inovacije u matematici.

4.2.3.3 Razlike s obzirom na radni staž

U tablici 2.90 slijedi prikaz statistički značajnih razlika u nastavnima i izvannastavnim praksama nastavnika s obzirom na radni staž nastavnika koristeći se jednosmjernom analizom varijance (One-way ANOVA test).

Tablica 2. 90: *Analiza varijance ljestvice učestalosti nastavnih i izvannastavnih praksi s obzirom na radni staž*

	F-omjer	Stat. znač
2.20 Nastavni proces organiziram prema odgojno-obrazovnim ciljevima pojedinih područja matematike zadanih Nacionalnim okvirnim kurikulumom.	3.959	.009**
2.21 Pohađam stručno-metodičke skupove i (među)županijska vijeća.	4.614	.004**
2.24 Uspješnost svog rada evaluiram prema ciljevima Nacionalnog okvirnog kurikuluma.	12.537	.000***
2.26 Sudjelujem u akcijskom istraživanju zajedno s kolegama i učenicima.	3.188	.024*
2.27 Učenicima dajem anonimni evaluacijski upitnik kako bi iznijeli svoje kritike, mišljenja i prijedloge o aktivnostima te načinima unapređenja nastavnog procesa.	2.700	.046*
2.36 Pratim znanstvene inovacije u matematici.	3.129	.026*
2.45 Dajem učenicima da sami odaberu aktivnosti i način rada u nastavi.	2.969	.032*

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

U nastavku slijede post-hoc Scheffe testovi višestrukih usporedbi među grupama u tvrdnjama koje su se izdvojile jednosmjernom analizom varijanci u rezultatima prikazanim u tablici 2.90.

Tablica 2. 91: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na radni staž ispitanika*

Tvrdnje	(I) Godine radnog staža	(J) Godine radnog staža	Razlika u arit. sredinama (I-J)	Std. greška	Stat. znač.
2.21 Pohađam stručno-metodičke skupove i (među)županijska vijeća.	0 - 5	6 - 15	-.296*	.098	.029*
		16 - 29	-.264*	.090	.036*
		30 - 45	-.075	.101	.909
	6 - 15	0 - 5	.296*	.098	.029*
		16 - 29	.032	.087	.988
		30 - 45	.221	.099	.174
2.24 Uspješnost svog rada evaluiram prema ciljevima Nacionalnog okvirnog kurikuluma.	0 - 5	6 - 15	-.210	.146	.558
		16 - 29	-.673*	.134	.000***
		30 - 45	-.726*	.151	.000***
	6 - 15	0 - 5	.210	.146	.558
		16 - 29	-.463*	.130	.006**
		30 - 45	-.516*	.148	.007**
2.26 Sudjelujem u akcijskom istraživanju zajedno s kolegama i učenicima.	0 - 5	6 - 15	-.392	.183	.207
		16 - 29	-.375	.168	.173
		30 - 45	-.561*	.189	.034*
2.27 Učenicima dajem anonimni evaluacijski upitnik kako bi iznijeli svoje kritike, mišljenja i prijedloge o aktivnostima te načinima unapređenja nastavnog procesa.	0 - 5	6 - 15	-.401	.195	.240
		16 - 29	-.443	.179	.107
		30 - 45	-.500	.202	.106
2.36 Pratim znanstvene inovacije u matematici.	0 - 5	6 - 15	-.241	.146	.438
		16 - 29	-.378*	.134	.048*
		30 - 45	-.381	.151	.097
2.45 Dajem učenicima da sami odaberu aktivnosti i način rada u nastavi.	0 -5	6 - 15	-.061	.142	.980
		16 - 29	-.264	.130	.252
		30 - 45	-.370	.147	.098

**** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$*

Prema očekivanjima, sve su utvrđene razlike između nastavnika početnika i iskusnijih nastavnika koji su pretežito u kategorijama 6 - 15 i 16 - 29 godina radnog staža. U tvrdnjama 2.21, 2.24, 2.26 i 2.36 podjednako se pokazalo kako mlađi nastavnici rjeđe sudjeluju u akcijskim istraživanjima i rjeđe pohađaju stručno-metodičke skupove te da uspješnost svog rada ne evaluiraju prema ciljevima Nacionalnog okvirnog kurikuluma kao nastavnici s više radnog

staža. Pomalo neočekivanim pokazalo se kako mlađi nastavnici manje prate znanstvene inovacije od iskusnijih nastavnika.

Tvrdnja 2.21: „Pohađam stručno-metodičke skupove i (među)županijska vijeća.“
Tvrdnja 2.24: „Uspješnost svog rada evaluiram prema ciljevima Nacionalnog okvirnog kurikuluma.“
Tvrdnja 2.26: „Sudjelujem u akcijskom istraživanju zajedno s kolegama i učenicima.“
Tvrdnja 2.36: „Pratim znanstvene inovacije u matematici. „
Za tvrdnje 2.27 i 2.45 post-hoc Scheffe analizom višestrukih usporedbi među grupama utvrđeno je kako nema statistički značajnih razlika.

4.2.3.4 Razlike s obzirom na stečenu dodatnu naobrazbu

Od svih do sada ispitivanih razlika između nastavnika s obzirom na stečenu dodatnu naobrazbu, na ovoj ljestvici pokazalo se najviše razlika te ćemo pored faktorske analize primijeniti i linearnu regresijsku analizu (u poglavlju 4.4) kako bismo utvrdili koliko koje od nezavisnih varijabli doprinose utvrđenim razlikama. U tablici 2.92 istaknute su tvrdnje na kojima su utvrđene razlike jednosmjernom analizom varijance.

Tablica 2. 92: *Analiza varijance ljestvice učestalosti nastavnih i izvannastavnih praksi s obzirom na stečenu dodatnu naobrazbu*

Tvrdnje	F-omjer	Stat. znač.
2.21 Pohađam stručno-metodičke skupove i (među)županijska vijeća.	3.766	.024*
2.22 Sudjelujem u projektima mobilnosti nastavnika.	4.018	.019*
2.24 Uspješnost svog rada evaluiram prema ciljevima Nacionalnog okvirnog kurikuluma.	5.659	.004**
2.26 Sudjelujem u akcijskom istraživanju zajedno s kolegama i učenicima.	5.535	.004**
2.27 Učenicima dajem anonimni evaluacijski upitnik kako bi iznijeli svoje kritike, mišljenja i prijedloge o aktivnostima te načinima unapređenja nastavnog procesa.	3.170	.043*
2.31 U poučavanju matematike koristim se humorom.	5.527	.004**
2.35 Koristim informatičke i komunikacijske tehnologije u poučavanju matematike.	5.984	.003**
2.36 Pratim znanstvene inovacije u matematici.	9.088	.000***
2.38 U nastavi rješavam problemske zadatke povezane sa svakodnevicom.	3.596	.028*
2.39 Odgojno-obrazovne aktivnosti temeljim na frontalnom obliku rada.	3.112	.046*
2.40 Učenike uključujem u nastavne aktivnosti formiranjem u grupe i timove.	8.982	.000***
2.41 Učenici usvajaju matematičke sadržaje radom u paru.	5.270	.006**

2.43 Objašnjavam matematičke sadržaje, koncepte i procese jednostavnim jezikom koji učenici razumiju	3.964	.020*

**** p < 0.001, ** p < 0.01, * p < 0.05*

U tablici 2.93 slijedi prikaz utvrđenih razlika prema rezultatima višestrukih usporedbi među grupama.

Tablica 2. 93: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na stečenu dodatnu naobrazbu nastavnika*

Tvrdnje	(I) Stečena dodatna naobrazba	(J) Stečena dodatna naobrazba	Std. greška	Stat. znač.
2.21 Pohađam stručno-metodičke skupove i (među)županijska vijeća.	Profesor/učitelj mentor	Profesor/učitelj savjetnik	.115	.999
		Ništa od navedenoga	.084	.082
2.22 Sudjelujem u projektima mobilnosti nastavnika.	Profesor/učitelj savjetnik	Profesor/učitelj mentor	.229	.125
		Ništa od navedenoga	.193	.019*
2.24 Uspješnost svog rada evaluiram prema ciljevima Nacionalnog okvirnog kurikuluma.	Profesor/učitelj savjetnik	Profesor/učitelj mentor	.175	.527
		Ništa od navedenoga	.148	.010*
2.26 Sudjelujem u akcijskom istraživanju zajedno s kolegama i učenicima.	Profesor/učitelj savjetnik	Profesor/učitelj mentor	.211	.864
		Ništa od navedenoga	.179	.025*
2.27 Učenicima dajem anonimni evaluacijski upitnik kako bi iznijeli svoje kritike, mišljenja i prijedloge o aktivnostima te načinima unapređenja nastavnog procesa.	Profesor/učitelj mentor	Profesor/učitelj savjetnik	.225	.517
		Ništa od navedenoga	.166	.045*
2.31 U poučavanju matematike koristim se humorom.	Ništa od navedenoga	Profesor/učitelj mentor	.102	.030*
		Profesor/učitelj savjetnik	.117	.045*
2.35 Koristim informatičke i komunikacijske tehnologije u poučavanju matematike.	Ništa od navedenoga	Profesor/učitelj mentor	.126	.032*
		Profesor/učitelj savjetnik	.145	.025*
2.36 Pratim znanstvene inovacije u matematici.	Ništa od navedenoga	Profesor/učitelj mentor	.123	.040*
		Profesor/učitelj savjetnik	.141	.001**
2.39 Odgojno-obrazovne aktivnosti temeljim na frontalnom obliku rada.	Profesor/učitelj savjetnik	Profesor/učitelj mentor	.147	.146
		Ništa od navedenoga	.125	.049*
2.40 Učenike uključujem u nastavne aktivnosti formiranjem u grupe i timove.	Ništa od navedenoga	Profesor/učitelj mentor	.111	.007**
		Profesor/učitelj savjetnik	.128	.004**
2.41 Učenici usvajaju matematičke sadržaje radom u paru.	Profesor/učitelj savjetnik	Profesor/učitelj mentor	.147	.877
		Ništa od navedenoga	.125	.030*
2.43 Objašnjavam matematičke sadržaje, koncepte i procese jednostavnim jezikom koji učenici razumiju.	Profesor/učitelj mentor	Profesor/učitelj savjetnik	.102	.629
		Ništa od navedenoga	.075	.025*

**** p < 0.001, ** p < 0.01, * p < 0.05*

Sve dobivene razlike utvrđene su između nastavnika koji nisu napredovali u zvanju i onih koji su mentori ili savjetnici (tablica 2.93). Tako nastavnici mentori i savjetnici češće sudjeluju u akcijskim istraživanjima i projektima mobilnosti. Očekivanim se pokazalo da nastavnici koji su napredovali u zvanju uspješnost svog rada češće evaluiraju prema ciljevima Nacionalnog okvirnog kurikuluma, a što se tiče evaluacije putem anonimnog upitnika za učenike, značajna se razlika pokazala između mentora koji učestalije procjenjuju svoj rad tim putem od nastavnika koji nisu napredovali u zvanju.

Iako se većina nastavnika izjasnila kako relativno često koristi informacijsko-komunikacijske tehnologije u nastavi, ipak je utvrđeno da nastavnici mentori i savjetnici značajno češće koriste informatičko-komunikacijske tehnologije od ostalih koji nisu napredovali u zvanju. Naime, u predmetnoj nastavi matematike sadržaji su takvog karaktera da jedino u krajnje kreativnim i inovativnim primjenama ili u radu sa specifičnim sadržajima iz geometrije korištenje IKT-a može učiniti razliku. Premda nema relevantnih istraživanja o utjecaju IKT-a na kvalitetu učenja i poučavanja nastave matematike, iz donje je tablice 2.94 teško protumačiti što je to „često“ ili „gotovo uvijek“ pa pored utvrđenih razlika ne možemo pouzdano tvrditi o kolikoj se učestalosti točno radi.

Tablica 2. 94: *Razlike s obzirom na stečenu dodatnu naobrazbu nastavnika u tvrdnji 2.35*

		Koristim informatičke i komunikacijske tehnologije u poučavanju matematike.					
		Nikad/gotovo nikad	Rijetko	Ponekad	Često	Uvijek/gotovo uvijek	Ukupno
	Profesor/učitelj mentor	0	2 (3 %)	17	33 (47 %)	18 (26 %)	70
	Profesor/učitelj savjetnik	0	3 (6 %)	11	17 (35 %)	18 (37 %)	49
	Ništa od navedenoga	5 (2 %)	22 (10 %)	66	93 (41 %)	40 (18 %)	226
Ukupno:		5	27	94	143	76	345

Naime, 73 % mentora i savjetnika koristi IKT često ili gotovo uvijek, a kod ostalih nastavnika to iznosi 59 %. S druge strane, svega 3 % mentora, 6 % savjetnika te 12 % ostalih nastavnika koristi IKT rijetko ili nikada što je doista izvan očekivanih okvira s obzirom da je nastava matematike svojim sadržajima, konceptima i metodikom dominantno usmjerena na ploču, kredu i bilježnicu te puno vježbanja u užurbanom ritmu opsežnih nastavnih planova i programa koji se nastoje realizirati.

Kod tvrdnje 2.36 utvrđena je razlika između nastavnika savjetnika od kojih 72 % tvrdi kako često ili uvijek prati znanstvene inovacije u matematici, a to isto tvrdi svega 50 % ostalih nastavnika od kojih značajan broj ne prati uopće ili rijetko.

Također se pokazalo kako gotovo polovica nastavnika matematike nastavu temelji na frontalnom obliku rada, a to isto radi 40 % nastavnika mentora te 30 % nastavnika savjetnika. Sukladno tome, što se tiče rada u paru, grupi ili timu pokazalo se kako oko 50 – 60 % nastavnika mentora i savjetnika izvodi nastavu u navedenim socijalnim oblicima često ili uvijek, a to isto je kod ostalih nastavnika na razini 30 – 35 %.

U tvrdnji 2.31: *U poučavanju matematike koristim se humorom*. utvrđena je razlika između nastavnika savjetnika koji znatno češće koriste humor u nastavi nego nastavnici koji nisu napredovali u zvanju.

U tvrdnji 2.43: *Objašnjavam matematičke sadržaje, koncepte i procese jednostavnim jezikom koji učenici razumiju.* pokazalo se kako nastavnici mentori procjenjuju višim, odnosno kako češće u svom radu pričaju jednostavnim jezikom razumljivim učenicima nego nastavnici koji nisu napredovali u zvanju. Međutim, ovdje je teško dati precizno tumačenje zato što se ovo pitanje može gledati kao učestalost prilagodbe složenijih sadržaja i pojmova pod cijenu stručnog izražavanja kao neki vid prilagodbe učenicima ili pak kao pitanje kojim se nastavnike pita koliko su metodički i komunikacijski spretni u svojoj nastavnoj praksi. Iz tog se razloga ne mogu davati promišljanja o stvarnoj kvaliteti njihove nastave, naročito ako se podsjetimo kako se ovdje radi o samoprocjenama te bi za ovo pitanje jedino primjereno bilo pitati njihove učenike.

U tvrdnjama 2.38: *U nastavi rješavam problemske zadatke povezane sa svakodnevicom*. i 2.21: *Pohađam stručno-metodičke skupove i (među)županijska vijeća*. Scheffe testom višestrukih usporedbi pokazalo se kako nema značajnih razlika među nastavnicima s obzirom na njihovo napredovanje u zvanju.

4.2.3.5 Razlike s obzirom na radno mjesto

U tablici 2.95 slijedi prikaz statistički značajnih razlika po tvrdnjama s obzirom na radno mjesto koristeći se jednosmjernom analizom varijance (One-way ANOVA test).

Tablica 2. 95: *Analiza varijance ljestvice učestalosti nastavnih i izvannastavnih praksi s obzirom na radno mjesto nastavnika*

Tvrdnje	F-omjer	Stat. znač.
2.20 Nastavni proces organiziram prema odgojno-obrazovnim ciljevima pojedinih područja matematike zadanih Nacionalnim okvirnim kurikulumom.	5.212	.006**
2.22 Sudjelujem u projektima mobilnosti nastavnika.	5.947	.003**
2.24 Uspješnost svog rada evaluiram prema ciljevima Nacionalnog okvirnog kurikuluma.	7.256	.001**
2.26 Sudjelujem u akcijskom istraživanju zajedno s kolegama i učenicima.	6.091	.003**
2.27 Učenicima dajem anonimni evaluacijski upitnik kako bi iznijeli svoje kritike, mišljenja i prijedloge o aktivnostima te načinima unapređenja nastavnog procesa.	7.463	.001**
2.28 U nastavi ističem da svaki učenik može biti uspješan u matematici.	3.478	.032*
2.32 Individualno radim s učenicima koji sporije usvajaju sadržaje.	35.908	.000***
2.33 Preventivno djelujem i pomažem učenicima koji imaju negativne stavove prema učenju matematike.	15.701	.000***
2.35 Koristim informatičke i komunikacijske tehnologije u poučavanju matematike.	6.153	.002**
2.37 Koristim stvarne životne situacije kao polazište za učenje i poučavanje.	18.758	.000***
2.38 U nastavi rješavam problemske zadatke povezane sa svakodnevicom.	17.242	.000***
2.42 Ostvarujem korelacije matematike s ostalim predmetima i disciplinama.	4.467	.012*

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

U tablici 2.96 istaknute su tvrdnje na kojima su utvrđene razlike prikazane rezultatima višestrukih usporedbi među grupama.

Tablica 2. 96: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na radno mjesto nastavnika*

Varijable	(I) Radno mjesto	(J) Radno mjesto	Std. greška	Stat. znač.
2.20 Nastavni proces organiziram prema odgojno-obrazovnim ciljevima pojedinih područja matematike zadanih Nacionalnim okvirnim kurikulumom.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.089	.009*
		Gimnazija	.089	.874
2.22 Sudjelujem u projektima mobilnosti nastavnika.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.160	.003**
		Gimnazija	.159	.385
2.24 Uspješnost svog rada evaluiram prema ciljevima Nacionalnog okvirnog kurikuluma.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.122	.001**
		Gimnazija	.121	.423
2.26 Sudjelujem u akcijskom istraživanju zajedno s kolegama i učenicima.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.147	.003**
		Gimnazija	.147	.568
2.27 Učenicima dajem anonimni evaluacijski upitnik kako bi iznijeli svoje kritike, mišljenja i prijedloge o aktivnostima te načinima unapređenja nastavnog procesa.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.156	.001**
		Gimnazija	.155	.375
2.32 Individualno radim s učenicima koji sporije usvajaju sadržaje.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.103	.000***
		Gimnazija	.103	.000***
2.33 Preventivno djelujem i pomažem učenicima koji imaju negativne stavove prema učenju matematike.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.091	.000***
		Gimnazija	.091	.000***
2.35 Koristim informatičke i komunikacijske tehnologije u poučavanju matematike.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.120	.005**
		Gimnazija	.127	.022*
2.37 Koristim stvarne životne situacije kao polazište za učenje i poučavanje.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.088	.000***
		Gimnazija	.087	.000***
2.38 U nastavi rješavam problemske zadatke povezane sa svakodnevicom.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.093	.000***
		Gimnazija	.092	.000***
2.42 Ostvarujem korelacije matematike s ostalim predmetima i disciplinama.	Osnovna škola (predmetna nastava)	Srednja strukovna škola	.096	.015*
		Gimnazija	.096	.765

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Prva je istaknuta razlika među nastavnicima prema radnom mjestu sudjelovanje u projektima mobilnosti čime se pokazalo kako nešto više od polovice nastavnika osnovnih škola sudjeluje ponekad, često i gotovo uvijek, a to isto slučaj je kod 30 % nastavnika strukovnih škola. Što se tiče evaluacije i refleksije nastavne prakse, utvrđena razlika ponovno je prisutna kod nastavnika strukovne škole od kojih 25 – 30 % redovito evaluira uspješnost svog rada prema ciljevima

Nacionalnog okvirnog kurikuluma te daje učenicima evaluacijski upitnik. S druge strane, isto čini 50 % nastavnika osnovnih škola.

Statistički značajne razlike pokazale su se i u sferi prilagodbe i pomoći učenicima koji uče sporije te imaju negativne stavove prema učenju matematike, a za koje se pokazalo kako nastavnici u osnovnim školama znatno više vremena odvajaju za učenike s teškoćama. Među istim skupinama nastavnika utvrđena je razlika u korištenju IKT-a koji je znatno više zastupljen u radu nastavnika osnovnih škola. U području metodičke dimenzije rada nastavnika očekivanim se pokazalo kako nastavnici osnovnih škola dvostruko češće rade problemske zadatke, povezuju nastavu matematike sa stvarnim životnim situacijama te češće ostvaruju korelacije s drugim predmetima.

4.3 Faktorska analiza istraživačkog instrumenta

Faktorska analiza je skup statističkih metoda i postupaka koje koristimo kako bismo razumjeli i pojednostavnili uzorke i/ili odnose između promatranih varijabli (Schmitt, 2011). Faktorska analiza podrazumijeva korištenje eksplorativne (EFA- eng. *Exploratory Factor Analysis*) i konfirmativne (CFA- eng. *Confirmatory Factor Analysis*) faktorske analize (Jennrich i Bentler, 2011). Konfirmativna faktorska analiza testira može li faktorski model predvidjeti strukturu promatranih podataka unutar danog istraživačkog instrumenta (DeCoster, 1998), a korištenjem eksplorativne faktorske analize nastoji se otkriti specifične obrasce među vrijablama te je prikladna za korištenje u početnoj fazi izrade novih istraživačkih instrumenata (Child, 2006). U navedenom istraživačkom upitniku koristit će se eksplorativna faktorska analiza zato što je upitnik prvi put koncipiran za potrebe ovog istraživanja temeljem teorijskog pregleda literature te je stoga prikladno koristiti EFA-u kako bi se pripadajućim statističkim postupcima ustanovilo ima li upitnik neku specifičnu strukturu te koliko je ista konzistenta s literaturom. Stoga se može očekivati kako zadani model neće zadovoljiti visoke kriterije pouzdanosti koji se koriste u postupcima konfirmativne faktorske analize.

Eksplorativnom faktorskom analizom (Tabachnik i Fidell, 2001) ekstrahiraju se faktori, ili preciznije, komponente prema visokim faktorskim opterećenjima na istom faktoru te istovremeno niskim opterećenjima na ostalim faktorima (Hair i ostali, 1998). Kako je EFA multivarijatni statistički postupak, prikladno je reducirati broj faktora/komponenti ispitivanjem odnosa između kategorija i evaluacijom samog modela (Williams i ostali, 2010). Sukladno tome, većina autora preporuča i koristi analizu glavnih komponenti (CPA) kako bismo reducirali broj varijabli na način da se zadrži što više varijanci od početno zadanog instrumenta (npr. Convway i Huffcutt, 2003). Cilj je analize glavnih komponenti ekstrahirati maksimalnu varijancu iz seta podataka sa svakom komponentom. Prva glavna komponenta linearna je kombinacija promatranih vrijednosti koja razdvaja subjekte maksimizirajući varijancu njihovih komponentnih vrijednosti. Druga se komponenta oblikuje iz rezidualnih korelacija; to je linearna kombinacija promatranih varijabli koja ekstrahira maksimalnu varijabilnost koja ne korelira s prvom komponentom. Sljedeće komponente također ekstrahiraju maksimalnu varijabilnost iz rezidualnih korelacija i ortogonalne su na sve prethodno ekstrahirane komponente. Glavne komponente potom se poredaju tako da prva komponenta ekstrahira najviše varijance, a posljednja komponenta najmanje.

Određivanje broja faktora u svakoj faktorskoj analizi odredit će se pomoću triju kriterija:

- svojstvene vrijednosti jediničnih vektora
- točka infleksije na Dijagramu svojstvenih vrijednosti (Scree Plot)
- Monte Carlo paralelna analiza (Watkins, 2000).

Međutim, tijekom određivanja broja faktora primarni je cilj optimizirati potencijalnu faktorsku strukturu koja mora podupirati istraživački problem, a to podrazumijeva jednoznačne i interpretabilne faktore (s dovoljno visokim doprinosom varijanci i faktorskim opterećenjima na pojedinim česticama) čija struktura i interpretacija treba jasno reflektirati istraživački problem. Bitno je istaknuti kako navedena tri kriterija nećemo koristiti po principu srednje vrijednosti istih, već kao opći okvir razmatranja prirode faktorske strukture te će se sukladno rezultatima pojedinih metoda ponavljano provoditi analize glavnih komponenti s fiksiranim brojem faktora kako bismo optimizirali i usuglasili istu s temeljnim polazištima ovog istraživanja.

Prva brza procjena broja faktora dobiva se iz veličina svojstvenih vrijednosti koje se dobiju nakon prvog pokretanja analize glavnih komponenti. Svojstvene vrijednosti predstavljaju varijancu na način da se zbroje sve svojstvene vrijedosti. Iz razloga što varijanca koju svaka standardizirana varijabla donosi ekstrakciji glavnih komponenti iznosi 1, komponenta sa svojstvenom vrijednosti manjom od 1 iz perspektive varijance nije toliko važna kao promatrana varijabla. Ako je to razuman broj faktora za skup podataka i teorijski konstrukt, isti može biti dobar za zadani instrument, no često ovaj kriterij može ili podcijeniti ili precijeniti broj faktora u setu podataka. Što se tiče određivanja broja faktora, pokazuje se kako sve veći broj istraživača metodu ekstrakcije faktora po principu svojstvenih vrijednosti većih od 1 ne smatra pouzdanom (Velicer i Jackson, 1990). Costello i Osborne (2005) utvrdili su kako više od trećine tako provedenih istraživanja daje previše faktora. U literaturi se stoga preporučuju dodatni testovi kao što su *paralelna analiza*, *Scree test* i *Velicerov MAP kriterij* (Velicer i Jackson, 1990). Stoga smo se pri ekstrakciji faktora, uz Kaieserov kriterij, koristili *paralelnom analizom Monte Carlo* (Tablica 6) te metodom određivanja točke infleksije na *Scree Plot* dijagramu. Određivanje točke infleksije na *Scree* testu često ima problem uslijed dominacije prvih nekoliko faktora, ili možda samo prvog faktora, slijedom čega pri većem odstupanju svojstvenih vrijednosti između faktora navedena analiza može često sugerirati kako faktorska struktura ima dva do tri faktora, a teorijski konstrukt nerijetko pritom nalaže znatno više faktora. Iako su korišteni svi navedeni kriteriji, pokazalo se kako je *Monte Carlo* paralelna analiza svojstvenih vrijednosti bila najpreciznija metoda, no ista nije uvijek bila u suglasju s teorijskim polazištima. S obzirom na to da svaka metoda određivanja broja faktora ima ponekih

nedostataka i izvjesnih grešaka, višestrukim analizama glavnih komponenti ponovit će se procedura analize glavnih komponenti kako bismo odredili faktorsku strukturu koja je u skladu s literaturom teorijskog dijela rada te s relevantnom metodološkom literaturom o faktorskoj analizi. Stoga je u svakoj ljestvici korištena eksplorativna faktorska analiza metodom glavnih komponenti (PCA- eng. *Principal Components analysis*) s *Oblimin* kosom rotacijom i po potrebi s *Varimax* rotacijom, ovisno o korelaciji među faktorima utvrđenih pokretanjem faktorske analize.

Primarno smo svaku faktorsku analizu pokrenuli s *Oblimin* (kosokutnom) rotacijom zato što se ista više preporuča u istraživanju društvenih znanosti, naročito kada se očekuju znatnije korelacije između faktora (Costello i Osborne, 2005). S druge strane, temeljna je pretpostavka kod ortogonalne rotacije da faktori ne koreliraju zbog čega su ortogonalna rješenja jednostavnija za tumačenje, opisivanje i izvještavanje rezultata. No, ponekad isti ne odražavaju realnu strukturu, osim ako je u teorijskom konstruktu utemeljeno kako su ishodišni procesi gotovo nezavisni. Ukoliko predviđamo kako će dimenzije istraživačkog upitnika korelirati, svakako je preporučljivo koristiti kosokutnu rotaciju. Kod takve rotacije faktori mogu biti u korelaciji uz konceptualne prednosti, ali i praktične nedostatke pri tumačenju, opisivanju i izvještavanju rezultata. S druge strane, ukoliko su korelacije između komponenti niske (manje od 0.3), često je prikladnije koristiti Varimax rotaciju zato što ista može rezultirati smislenijom faktorskom strukturom, a naposljetku je bitno da se ista podudara s teorijskim okvirima istraživanog problema.

4.3.1 Faktorska analiza ljestvice uvjerenja nastavnika

Prvom analizom glavnih komponenti cjelokupne ljestvice istraživačkog instrumenta dobili smo sedam faktora. Korištena je faktorska analiza metodom glavnih komponenata (CPA) s *Oblimin* kosokutnom rotacijom i Kaiserovom normalizacijom (Costello i Osborne, 2005). Potom je utvrđeno kako nema značajnih korelacija među faktorima te je naposljetku pokrenuta faktorska analiza s Varimax rotacijom. Uz to, ljestvica uvjerenja nastavnika dominatno je usmjerena prema nešto širem okviru stavova i uvjerenja nastavnika te, za razliku od drugih dviju ljestvica istraživačkog upitnika, nije predviđena da u svom punom obujmu ocrtava jasnu faktorsku strukturu prema specifičnim dimenzijama uvjerenja nastavnika. Prvi je dio istraživačkog upitnika eksplorativne naravi te je stoga u poglavlju 4.1 primijenjena detaljnija deskriptivna analiza. Mnoge tvrdnje i pripadajući odgovori ispitanika imali su kao cilj utvrditi određeni sustav vrijednosti nastavnika zato što iste često nisu imale jasnu interpretaciju poželjnog

odgovora, već su kao cilj imale razumijevanje pozadine danih odgovora. Stoga se od početnih 32 pitanja i sugeriranih sedam faktora, prema metodi svojstvenih vrijednosti, pokazalo kako faktorska struktura nema jednoznačne faktore, čestice nisu imale dovoljno visoka opterećenja kao pokriće za te rezultate pa se postupnom redukcijom početne ljestvice uvjerenja i stavova nastavnika cijeli upitnik reducirao na 13 pitanja koja su grupirana u četiri faktora. To je sugerirala i metoda svojstvenih vrijednosti (tablica 3.1) kao i višestruke faktorske analize s (potencijalnim) drugačijim strukturama. Pokazalo se kako je navedena struktura od četiriju faktora dobila jasno interpretabilne faktore koji su konzistentni s teorijskim pregledom literature.

Tablica 3. 1: *Prikaz svojstvenih vektora i udjela varijance po faktorima dobivenih metodom analize glavnih komponenti*

Komponente (faktori)	Inicijalni svojstveni vektori		
	Svojstveni vektori	Udio varijance	Kumulativni udio varijance
1	3.490	26.847	26.847
2	1.721	13.238	40.085
3	1.521	11.702	51.787
4	**1.466**	**11.275**	**63.062**
5	.882	6.785	69.847
6	.797	6.131	75.978
7	.759	5.837	81.815

Četiri dobivena faktora objašnjavaju 63 % varijance ispitivanih stavova i uvjerenja nastavnika. Kaiser-Meyer-Olkin testom prikladnosti i Bartlettovim testom spljoštenosti utvrđeno je kako su podatci prikladni za faktorizaciju (KMO = 0.74). Bartlettov test u ovom je istraživanju značajan što potvrđuje kako je u reduciranom faktorskom modelu ostalo dosta zajedničke varijance. Cronbachov Alpha koeficijent, prema pretpostavci, nije naročito visok, ali iznosi 0.72 što je iznad donje granice pouzdanosti te se za primjenu ove eksplorativne faktorske analize smatra pouzdanim ponajprije zbog toga što je faktorska struktura konzistentna s literaturom te je istu jednostavno tumačiti u kontekstu istraživačkog problema. *Monte Carlo PCA for Parallel Analysis* (prema Watkins, 2000), nastala učitavanjem 348 ispitanika, 13 varijabli i 100 replikacija u programu, također je sugerirala četiri do pet faktora što se podudara s gornjom tablicom. Ekstrahirani su faktori sljedeći (tablica 3.2):

Tablica 3. 2: *Ekstrahirani faktori, varijable i faktorska opterećenja dobiveni provedbom eksplorativne faktorske analize temeljene na analizi glavnih komponenti*

Faktor I: Uvjerenja o kurikulumu- F1.1		**Faktorsko opterećenje**
1.30	Smatram bitnim da nastavnik matematike razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.	0.87
1.32	Smatram bitnim da nastavnik matematike razumije odgojno-obrazovne ciljeve i učenička postignuća po svim obrazovnim ciklusima matematičkog područja.	0.80
1.31	Smatram bitnim da nastavnik matematike razumije temeljne smjernice koncepta cjeloživotnog učenja.	0.79
1.8	Nastavni proces treba se planirati prema smjernicama Nacionalnog okvirnog kurikuluma.	0.62
Faktor II: Uvjerenja o socijalnim vještinama nastavnika- F1.2		**Faktorsko opterećenje**
1.24	Smatram bitnim da nastavnik matematike posjeduje visoko razvijene komunikacijske vještine.	0.76
1.26	Smatram bitnim da nastavnik matematike potiče pozitivne stavove prema učenju matematike.	0.75
1.25	Smatram bitnim da nastavnik matematike koristi humor u poučavanju matematike.	0.68
1.27	Smatram bitnim da nastavnik matematike zna ukloniti i prevenirati negativne stavove i uvjerenja učenika u kontekstu nastave matematike.	0.60
Faktor III: Uvjerenja o metodičkom strukturiranju nastave- F1.3		**Faktorsko opterećenje**
1.6	Grupnim oblicima rada postižu se kvalitetniji obrazovni ishodi nego frontalnim oblikom rada.	0.91
1.5	Grupnim oblicima rada postižu se kvalitetniji odgojni ishodi nego frontalnim oblikom rada.	0.88
1.1	Nastava matematike trebala bi se više temeljiti na rješavanju problemskih zadataka nego na standardnim proceduralnim zadatcima.	0.54

Faktor IV: Uvjerenja (stereotipi) o matematičkim sposobnostima-F1.4		**Faktorsko opterećenje**
1.14	Učenik prosječnih sposobnosti može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji.	0.87
1.13	Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi.	0.87

Dakle, navedeni faktori objašnjavaju 63 % varijance, a ni jedna od drugih čestica nema faktorska opterećenja veća od 0.38 na nekom drugom faktoru. Koeficijenti unutarnje konzistencije pokazuju zadovoljavajuću pouzdanost za sve navedene faktore. U tablici 3.3 navedeni su faktori s pripadnim nazivima i postotkom objašnjene varijance.

Tablica 3. 3: *Faktorska struktura i udio varijance po faktorima i kumulativni udio varijance za prikazanu strukturu*

Faktori	**Udio varijance**	**Kumulativni udio varijance**
F1.1 Uvjerenja o kurikulumu	26.85 %	26.85 %
F1.2 Uvjerenja o socijalnim vještinama nastavnika	13.24 %	40.09 %
F1.3 Uvjerenja o metodičkom strukturiranju nastave	11.7 %	51.79 %
F1.4 Uvjerenja (stereotipi) o matematičkim sposobnostima	11.28 %	63.07 %

Suprotno pretpostavkama, pomalo su se iznenađujuće kao dominantnim faktorom izdvojila uvjerenja o kurikulumu koja objašnjavaju 27 % varijance te uvjerenja o socijalnim vještinama nastavnika s 13 % kao drugi faktor po udjelu varijance u ostalim uvjerenjima nastavnika. To pokazuje kako se u navedenim faktorima stavova i uvjerenja nastavnika upravo iz stavova o kurikulumu mogu lakše predvidjeti stavovi i uvjerenja u ostalim dimenzijama koje su utvrđene faktorskom analizom. Navedeno će se kasnije analizirati korelacijskom analizom s ostalim faktorskim analizama te regresijskom analizom istih. Međutim, u prvotnoj faktorskoj strukturi, koja nije bila usuglašena sa statističkim standardima provedene analize (u punom obujmu te ljestvice), stavovi i uvjerenja o socijalnim vještinama pokazali su se kao dominantan faktor, no zbog validnosti rezultata daljnjih analiza ta će se ljestvica u nastavku analizirati u gore navedenom faktorskom modelu (tablica 3.3).

Treći faktor odnosi se na razmatranje odgojnih i obrazovnih ishoda u različitim socijalnim oblicima rada u nastavi što se grupiralo zajedno s tvrdnjom o percepciji nastavnika o aktualnim diskusijama oko zastupljenosti proceduralnih i problemskih zadataka. Stoga ova latentna dimenzija, koja se odnosi na treći faktor, u sebi sadrži suprostavljanje modernog i tradicionalnog poimanja nastave koje je, među ostalim, pod utjecajem brojnih obrazovno-političkih perspektiva koje svojim redukcionističkim pristupom obrazovanju često svode kvalitetu nastave na (ne)frontalne oblike rada i problemske zadatke koji bi trebali zamijeniti proceduralne (dominantne u nastavi). Navedeni faktor pojašnjava 11.7 % varijance ovog dijela upitnika što je gotovo jednako kao i drugi faktor o socijalnim vještinama nastavnika.

Četvrti faktor predviđen je i među hipotezama te je i u pregledu literature pozicioniran kao jedna od važnijih tema koje čine specifičan sklop uvjerenja cjelokupnog društva pa tako i nastavnika matematike. Odnosi se na (stereotipna) uvjerenja karakteristična za nastavu matematike te pojašnjava gotovo podjednaki udio (11.3 %) kao drugi i treći faktor u varijanci uvjerenja i stavova nastavnika. Također je bitno istaknuti kako se ovaj faktor sastoji od samo dvije tvrdnje, a u literaturi se uglavnom navodi kako bi svaki faktor trebao imati barem tri tvrdnje koje ga opisuju (Tabachnik i Fidell, 2007). Unatoč tome, ukoliko je faktor jasno opisan s te dvije tvrdnje te ako su iste međusobno visoko korelirane, mogu se uvažiti kao faktor (Yong i Pearce, 2013). U našem slučaju dotične tvrdnje visoko su korelirane na razini statističke značajnosti 0.001 te imaju visoka opterećenja na faktoru koja iznose 0.87 u oba slučaja. Budući da uz teorijska polazišta ima uporište i u statistčkim parametrima metodoloških okvira, taj smo faktor zadržali.

Tablica 3. 4**:** *Osnovne deskriptivne vrijednosti faktorske strukture prvog dijela istraživačkog instrumenta*

Faktori	**Min**	**Max**	**Aritmetička sredina**	**Standardna devijacija**
F1.1 Uvjerenja o kurikulumu	1.50	5.00	3.96	.62
F1.2 Uvjerenja o socijalnim vještinama nastavnika	3.00	5.00	4.44	.44
F1.3 Uvjerenja o metodičkom strukturiranju nastave	1.67	5.00	3.58	.65
F1.4 Uvjerenja (stereotipi) o matematičkim sposobnostima	1.00	5.00	3.15	.92

Među navedenim faktorima očito je kako svi, osim faktora F1.2 o socijalnim vještinama nastavnika, imaju raspon rezultata praktički u punom obujmu primijenjene Likertove ljestvice što upućuje na značajnija razilaženja u mišljenjima nastavnika. Što se tiče faktora F1.2, razvidno je kako su nastavnici u visokom suglasju u kojem je aritmetička sredina 4.44, uz

relativno nisku standardnu devijaciju, što znači kako većina ispitivane populacije smatra bitnim socijalne i komunikacijske vještine nastavnika.

S druge strane, analizom uvjerenja (stereotipa) o matematičkim sposobnostima utvrđeno je kako se nastavnici u prosjeku (arit. sredina 3.15) niti slažu niti ne slažu s relativno visokom standardnom devijacijom te punim rasponom odgovora od 1 do 5 Likertove ljestvice što podrazumijeva više nesuglasja nastavnika na tom faktoru.

4.3.1.1 Razlike u uvjerenjima nastavnika s obzirom na spol

Prikaz statistički značajnih razlika u dimenzijama uvjerenja nastavnika s obzirom na spol slijedi u tablici 3.5 u kojoj su rezultati utvrđeni jednosmjernom analizom varijance..

Tablica 3. 5: *Rezultati analize varijance ljestvice uvjerenja s obzirom na spol nastavnika*

Faktori		**Suma kvadrata odstupanja**	**F-omjer**	**Statistička značajnost**
F1.1 Uvjerenja o kurikulumu	Između grupa	2.878	7.606	.006**
	Unutar grupa	130.931		
	Ukupno	133.810		
F1.2 Uvjerenja o socijalnim vještinama nastavnika	Između grupa	1.229	6.409	.012*
	Unutar grupa	66.346		
	Ukupno	67.575		
F1.3 Uvjerenja o metodičkom strukturiranju nastave	Između grupa	.356	.838	.361
	Unutar grupa	146.993		
	Ukupno	147.350		
F1.4 Uvjerenja o matematičkim sposobnostima	Između grupa	4.063	4.827	.029*
	Unutar grupa	291.266		
	Ukupno	295.330		

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Sve su tvrdnje podvrgnute t-testu kojim se pokazalo kako se ispitanici razlikuju s obzirom na spol sukladno provedenoj analizi varijance na danim tvrdnjama. Iz tablice je očito kako su razlike u spolu ispitanika utvrđene na svim faktorima, osim u metodičkom strukturiranju nastave, od kojih su najznačajnije razlike na faktoru uvjerenja nastavnika o kurikulumu na razini statističke značajnosti 0.01 zato što se nastavnice u većoj mjeri priklanjaju obrazovno-političkim okvirima i kurikularnim dokumentima.

Nastavnice također u većoj mjeri smatraju bitne socijalne kompetencije nastavnika te sukladno razlikama spolova u emocionalnoj inteligenciji pridaju veći značaj istima. Što se tiče

četvrtog faktora, pokazalo se kako se nastavnice nešto više priklanjaju stereotipnom razmišljanju te je čak jedna trećina njih uvjerena kako za ocjenu odličan u osnovnoj školi i prirodoslovno-matematičkoj gimnazije treba imati iznadprosječne sposobnosti

To je u skladu s tvrdnjom 1.14 unutar koje se pokazalo kako 30 % muških nastavnika smatra da učenici prosječnih sposobnosti mogu imati ocjenu odličan u prirodoslovno-matematičkoj gimnaziji, a to isto smatra 20 % nastavnica. Gledano u relativnom odnosu, to je 50 % više muških nastavnika nego nastavnica koji imaju pozitivnija uvjerenja i stavove o vezi između matematičkih sposobnosti i uspjeha u matematici.

4.3.1.2 Razlike u uvjerenjima i stavovima nastavnika s obzirom na inicijalno obrazovanje

U tablici 3.6 slijedi prikaz statistički značajnih razlika po tvrdnjama s obzirom na inicijalno obrazovanje koristeći se jednosmjernom analizom varijance.

Tablica 3. 6: *Analiza varijance ljestvice uvjerenja s obzirom na spol nastavnika*

Faktori		Suma kvadrata	F-omjer	Stat. znač.
F1.1 Uvjerenja o kurikulumu	Između grupa	1.861	1.617	.185
	Unutar grupa	131.949		
	Ukupno	133.810		
F1.2 Uvjerenja o socijalnim vještinama nastavnika	Između grupa	1.638	2.848	.038*
	Unutar grupa	65.938		
	Ukupno	67.575		
F1.3 Uvjerenja o metodičkom strukturiranju nastave	Između grupa	6.842	5.584	.001**
	Unutar grupa	140.507		
	Ukupno	147.350		
F1.4 Uvjerenja o matematičkim sposobnostima	Između grupa	5.264	2.081	.102
	Unutar grupa	290.066		
	Ukupno	295.330		

**** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$*

Jednosmjernom analizom varijance utvrđene su razlike na drugom i trećem faktoru s obzirom na inicijalno obrazovanje nastavnika. Analizom višestrukih usporedbi među grupama nastavnika prema inicijalnom obrazovanju Scheffe testom utvrđena je statistički značajna razlika (na razini 0.05) u uvjerenjima o socijalnim vještinama između nastavnika koji su završili inženjerski fakultet na PMF-u i nastavnika koji su završili Učiteljski fakultet s pojačanom

matematikom. Sukladno pojedinačnim tvrdnjama analiziranim u poglavlju 4.1, nastavnici Učiteljskog fakulteta značajno bitnijim smatraju socijalne vještine nastavnika nego nastavnici inženjerskog smjera.

Što se tiče nekih aspekata metodičke kompetencije nastavnika, na trećem faktoru višestrukim analizama među grupama istaknuli su se nastavnici studija „ostalo“ koji se znanto manje priklanjaju grupnim oblicima rada i problemskoj nastavi kao odgovor na zahtjeve suvremene nastave matematike nego nastavnici sa završenim nastavničkim studijem na PMF-u te oni sa završenim Učiteljskim fakultetom.

4.3.1.3 Razlike u uvjerenjima i stavovima nastavnika s obzirom na radni staž

U tablici 3.7 slijedi prikaz statistički značajnih razlika po tvrdnjama s obzirom na radni staž ispitanika utvrđenih na temelju rezultata jednosmjerne analize varijance.

Tablica 3. 7: *Analiza varijance ljestvice uvjerenja s obzirom na radni staž nastavnika*

Faktori		**Suma kvadrata**	**F- omjer**	**Stat. znač.**
F1.1 Uvjerenja o kurikulumu	Unutar grupa	4.298	3.805	.010*
	Između grupa	129.512		
	Ukupno	133.810		
F1.2 Uvjerenja o socijalnim vještinama nastavnika	Unutar grupa	.153	.260	.854
	Između grupa	67.423		
	Ukupno	67.575		
F1.3 Uvjerenja o metodičkom strukturiranju nastave	Unutar grupa	4.038	3.231	.023*
	Između grupa	143.311		
	Ukupno	147.350		
F1.4 Uvjerenja o matematičkim sposobnostima	Unutar grupa	.502	.195	.900
	Između grupa	294.827		
	Ukupno	295.330		

**** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$*

Daljnjim analizama post-hoc Scheffe testom utvrđene su razlike između nastavnika početnika i onih koji imaju 16 - 29 te 30 i više godina radnog staža koji su, sukladno rezultatima iz poglavlja 4.1 po pojedinačnim tvrdnjama, iskazali znatno višu razinu slaganja s kurikulumskim dokumentima i općim smjernicama koncepta cjeloživotnog učenja. To se može pripisati nedostatnoj zastupljenosti obrazovno-političkih i kurikulumskih tema u njihovu inicijalnom

obrazovanju te pretežito stručnom i metodičkom usavršavanju u prvim godinama rada nastavnika pri adaptaciji na izazove nastavne prakse.

U faktoru uvjerenja nastavnika o metodičkom oblikovanju nastave mlađi nastavnici znatno bitnijim smatraju grupni rad i odgojne i obrazovne ishode koje učenici pritom postižu te smatraju kako bi se nastava matematike trebala više temeljiti na problemskoj nastavi nego što to smatraju nastavnici koji imaju između 16 - 29 godina radnog staža.

4.3.1.4 Razlike u uvjerenjima i stavovima nastavnika s obzirom na stečenu dodatnu naobrazbu

U tablici 3.8 slijedi prikaz statistički značajnih razlika po tvrdnjama s obzirom na stečenu dodatnu naobrazbu nastavnika koristeći se jednosmjernom analizom varijance.

Tablica 3. 8: *Analiza varijance ljestvice učestalosti nastavnih i izvannastavnih praksi s obzirom na spol nastavnika*

Faktori		Suma kvadrata	F-omjer	Stat. znač.
F1.1 Uvjerenja o kurikulumu	Između grupa	2.285	2.987	.052
	Unutar grupa	130.814		
	Ukupno	133.099		
F1.2 Uvjerenja o socijalnim vještinama nastavnika	Između grupa	.676	1.738	.177
	Unutar grupa	66.513		
	Ukupno	67.189		
F1.3 Uvjerenja o metodičkom strukturiranju nastave	Između grupa	.250	.292	.747
	Unutar grupa	146.460		
	Ukupno	146.710		
F1.4 Uvjerenja o matematičkim sposobnostima	Između grupa	.731	.426	.653
	Unutar grupa	293.023		
	Ukupno	293.754		

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Višestrukim usporedbama korištenjem Scheffe testa utvrđeno je kako nema razlika među grupama po navedenim faktorima na razini 0.05 statističke značajnosti između nastavnika mentora i savjetnika te onih koji nisu napredovali u zvanju.

4.3.1.5 Razlike u uvjerenjima nastavnika s obzirom na radno mjesto

Sukladno prethodnim analizama na faktoru koji se tiče socijalnih vještina nastavnika, pokazala se značajna razlika između nastavnika koji rade u osnovnim školama i ostalih grupa nastavnika. Naime, prethodnim analizama iz poglavlja 4.2.1.2, 4.2.2.2 i 4.2.3.2 utvrđeno je kako su nastavnici sa završenim Učiteljskim fakultetom skloniji uvjerenjima, samoprocjenama i primjeni nastavnih metoda te kako su im socijalne vještine važne i vrijedne, za razliku od nastavnika koji rade u srednjim školama. S druge strane, post hoc Scheffe testovima utvrđeno je kako se stavovi i uvjerenja nastavnika o kurikulumu posebno ističu kod nastavnika strukovnih škola, a isti se razlikuju kod nastavnika osnovnih škola i kod nastavnika koji rade u gimnazijama (tablica 3.9).

Tablica 3. 9: *Analiza varijance ljestvice uvjerenja nastavnika s obzirom na spol*

Varijabla	(I) Radno mjesto	(J) Radno mjesto	Std. greška	Stat. znač.
F1.1 Uvjerenja o kurikulumu	Srednja strukovna škola	Osnovna škola (predmetna nastava)	.07830	.000***
		Gimnazija	.08299	.031*

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Rezultati usporedbi među gore (u tablici) istaknutim grupama ukazuju na nastavnike strukovnih škola koji značajno manje (razina 0.05 statističke značajnosti), nego nastavnici koji rade u gimnazijama, smatraju kako su smjernice kurikuluma iz obrazovno-političke sfere važne za njihov odgojno-obrazovni rad. Ta je razlika još istaknutija u usporedbi s nastavnicima osnovnih škola, koja je na razini 0.01 statističke značajnosti, zato što nastavnici osnovnih škola znatno bitnijim i relevantnijim za svoj rad smatraju tvrdnje iz ove faktorske dimenzije.

4.3.2 Faktorska analiza ljestvice percipirane kompetentnosti i samoefikasnosti

Početnom analizom glavnih komponenti cjelokupne ljestvice istraživačkog instrumenta dobili smo pet faktora. Korištena je faktorska analiza metodom glavnih komponenti (CPA) s *Oblimin* kosokutnom rotacijom i Kaiserovom normalizacijom (Costello i Osborne, 2005), budući da se očekuju znakovite korelacije između faktora samoprocjene nastavnika.

Stoga se od početnih 20 pitanja i sugeriranih četiri faktora prema metodi svojstvenih

vrijednosti pokazalo kako faktorska struktura nema potpuno jednoznačne faktore pa se minimalnom redukcijom početne ljestvice samoprocjena nastavnika došlo do strukture od pet faktora i 18 tvrdnji. Metoda svojstvenih vrijednosti (tablica dolje) sugerirala je četiri faktora, Scree test sugerirao je dva do tri faktora pa je primijenjena i paralelna analiza. *Monte Carlo PCA for Parallel Analysis* (prema Watkins, 2000), nastala učitavanjem 348 ispitanika, 18 varijabli i 100 replikacija, u programu je sugerirala pet faktora budući da je nasumična svojstvena vrijednost generirana paralelnom analizom upravo na petom faktoru utvrdila vrijednost koja premašuje (1.17 > 0.99) onu na petom faktoru iz gornje tablice dobivene analizom glavnih komponenti.

Tablica 3. 10: *Prikaz svojstvenih vektora i udjela varijance po faktorima dobivenih metodom analize glavnih komponenti*

Komponente (faktori)	Inicijalni svojstveni vektori		
	Svojstveni vektori	Udio varijance	Kumulativni udio varijance
1	5.244	27.601	27.601
2	2.074	10.918	38.519
3	1.353	7.122	45.641
4	1.305	6.867	52.508
5	.991	5.214	**57.722**

Dakle, pet dobivenih faktora objašnjavaju 58 % varijance ispitivanih stavova i uvjerenja nastavnika. Kaiser-Meyer-Olkin testom prikladnosti i Bartlettovim testom spljoštenosti utvrđeno je kako su podatci prikladni za faktorizaciju (KMO = 0.82). Bartlettov test u ovom je istraživanju značajan što potvrđuje kako je u reduciranom faktorskom modelu ostalo dovoljno zajedničke varijance. S obzirom na okvir ljestvice samoprocjena i zadovoljavajuće visokih faktorskih opterećenja na česticama, pokazalo se kako je struktura od pet faktora dobila jasno interpretabilne faktore koji su konzistentni s početnim teorijskim okvirom. Cronbachov Alpha koeficijent iznosi zadovoljavajućih 0.84 te se za primjenu eksplorativne faktorske analize ovaj model smatra pouzdanim.

Dobiveni su sljedeći faktori samoprocjena nastavnika (tablica 3.11):

Tablica 3. 11: *Ekstrahirani faktori samoprocjena nastavnika, varijable i faktorska opterećenja dobiveni provedbom eksplorativne faktorske analize temeljene na analizi glavnih komponenti*

Faktor I: Poznavanje specifičnosti učenika u nastavi matematike- F2.1		Faktorsko opterećenje
2.12	Svjestan sam motivacije kojom moji učenici pristupaju matematici.	0.86
2.11	Razumijem prirodu i vrste specifičnih teškoća s kojima se učenici suočavaju u nastavi matematike.	0.74
2.13	U nastavi uočavam tempo kojim učenici svladavaju matematičke sadržaje.	0.61
2.3	Razumijem prednosti i nedostatke pojedinih oblika i načina poučavanja kojima se koristim u nastavi.	0.57
2.16	Uočavam emocije učenika u nastavnim aktivnostima.	0.46
Faktor II: Stručna kompetencija- F2.2		Faktorsko opterećenje
2.1	Posjedujem znanja o naprednim matematičkim temama koje nisu dio školske matematike.	0.85
2.5	Osjećam se kompetentnim za pripremu nadarenih učenika za državno natjecanje.	0.67
2.4	Imam duboko razvijena konceptualna znanja matematike.	0.44
2.17	Razumijem osnovna načela rada s nadarenim učenicima.	0.41
Faktor III: Socijalna kompetencija- F2.3		Faktorsko opterećenje
2.9	Uvažavam socijalne i kulturne razlike učenika u nastavnim aktivnostima kao i kod ocjenjivanja i očekivanjima koje postavljam pred njih.	0.88
2.8	Upoznat sam sa socio-kulturnim i ekonomskim statusom svojih učenika.	0.78
2.10	Uočavam odnose učenika u razredu te kako oni utječu na njihovu aktivnost u nastavi matematike.	0.75
2.7	Posjedujem znanja o interesima svojih učenika.	0.42

Faktor IV: Rad s učenicima sa specifičnim teškoćama- F2.4		Faktorsko opterećenje
2.14	Znam prepoznati učenika koji ima diskalkuliju.	0.71
2.15	Znam kako ukloniti i prevenirati probleme u učenju matematike.	0.49
Faktor V: Znanja o kurikulumu- F2.5		Faktorsko opterećenje
2.19	Razumijem opće i specifične ciljeve te smjernice Nacionalnog okvirnog kurikuluma.	0.86
2.18	Razumijem temeljne smjernice koncepta cjeloživotnog učenja te ulogu matematičkog područja u tom kontekstu.	0.78
2.2	Razumijem povijesnu i društvenu ulogu matematike u znanosti, kulturi, umjetnosti i tehnologiji te njezin potencijal za budućnost društva.	0.49

Iako se očekivalo kako će stručna kompetencija imati značajniji udio u varijanci sukladno tradicionalnom poimanju nastavnika matematike koji je stručnjak primarno u domeni supstratne struke, ista se ipak pokazala kao drugi faktor po udjelu varijance s 11 %, a kao glavni faktor pokazale su se samoprocjene nastavnika u kontekstu poznavanja specifičnosti učenika u kontekstu nastave matematike s 28 % udjela u varijanci samoprocjena nastavnika. To potvrđuje naša polazišta i pretpostavke poznavanja specifičnosti učenika i socijalne kompetencije kao ključna uvjerenja koja su okosnica pedagoške kompetencije standarda kvalitete kompetencijskog profila nastavnika matematike.

Socijalna kompetencija izdvojila se kao treći faktor, a četvrti faktor odnosi se na osposobljavanje nastavnika za rad s učenicima sa specifičnim teškoćama. S obzirom na to da je taj faktor određen s dvjema česticama: 2.14: *Znam prepoznati učenika koji ima diskalkuliju.* i 2.15: *Znam kako ukloniti i prevenirati probleme u učenju matematike.*, provjerili smo je li korelacija između tih tvrdnji dovoljno visoka (prema Yong i Pearce, 2013) kako bismo taj faktor mogli zadržati kao dio ove faktorske strukture. Analizom Pearsonova koeficijenta korelacije utvrđeno je kako su te tvrdnje visoko korelirane na razini 0.01 statističke značajnosti, stoga ćemo ovu faktorsku strukturu zadržati kao pouzdan okvir za daljnje analize.

Sukladno pretpostavkama kosokutne *Oblimin* rotacije o koreliranim faktorima, provođenjem faktorske analize metodom glavnih komponenti potrebno je protumačiti

povezanost među faktorima te, pored ostalog, utvrditi ima li korelacija viših od 0.3 što je jedan od preduvjeta korištenja spomenute rotacije.

Tablica 3. 12: *Matrica korelacija (Pearsonov koeficijent korelacije) između faktora dobivenih iz ljestvice samoprocjena nastavnika*

Faktori	**F2.1**	**F2.2**	**F2.3**	**F2.4**	**F2.5**
F2.1 Poznavanje specifičnosti učenika u nastavi matematike	1	.21**	.33**	.11	-.41**
F2.2 Stručna kompetencija	.21**	1	.067	-.03	-.33**
F2.3 Socijalna kompetencija	.33**	.067	1	.14*	-.23**
F2.4 Rad s učenicima sa specifičnim teškoćama	.12*	-.03	.14*	1	-.14*
F2.5 Znanja o kurikulumu	-.41**	-.33**	-.23**	-.14*	1

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Prvi faktor očekivano je ponajviše povezan s trećim faktorom što konkretnije znači da nastavnici koji procjenjuju visokim svoje poznavanje specifičnosti učenika u kontekstu nastave matematike, u skladu s time procjenjuju i svoju socijalnu kompetenciju. Međutim, prvi faktor ima najviši stupanj povezanosti sa samoprocjenama znanja o kurikulumu (faktor F2.5), no utvrđena korelacija negativnog je predznaka (-0.411). Spomenuti peti faktor negativno korelira sa svim faktorima u strukturi samoprocjena nastavnika što znači da nastavnici s višim procjenama svojih socijalnih kompetencija, stručno-metodičkih te pedagoških znanja i vještina imaju znatno niže samoprocjene znanja o kurikulumskim odrednicama suvremenog obrazovanja.

4.3.2.1 Razlike u percipiranoj kompetentnosti i samoefikasnosti nastavnika s obzirom na spol

U tablici 3.13 slijedi prikaz statistički značajnih razlika u samoprocjenama nastavnika s obzirom na spol koristeći se jednosmjernom analizom varijance

Tablica 3. 13: *Analiza varijance u dimenzijama samoprocjena nastavnika s obzirom na spol*

Faktori	F-omjer	Stat. znač.
F2.1 Poznavanje specifičnosti učenika u nastavi matematike	23.588	.000***
F2.2 Stručna kompetencija	.341	.560
F2.3 Socijalna kompetencija	16.057	.000***
F2.4 Rad s učenicima sa specifičnim teškoćama	.244	.621
F2.5 Znanja o kurikulumu	10.916	.001**

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Sukladno analizi varijance u poglavlju 4.2.2.1, sve istaknute razlike grupirale su se na očekivanim faktorima kojima se pokazalo kako nastavnice znatno višim procjenjuju svoju kompetentnost u poznavanja specifičnosti učenika, socijalnoj kompetenciji i u znanjima o kurikulumu i smjernicama koncepta cjeloživotnog učenja nego muški nastavnici. S obzirom na utvrđene različite varijance, sve tvrdnje podvrgnute su t-testu kojim se pokazalo kako se ispitanici razlikuju s obzirom na spol sukladno provedenoj analizi varijance na danim tvrdnjama.

4.3.2.2 Razlike u percipiranoj kompetentnosti i samoefikasnosti nastavnika s obzirom na inicijalno obrazovanje

Analizom varijance utvrđena je razlika na drugom i trećem faktoru, a s obzirom na to da ima više od dvije grupe na ovoj nezavisnoj varijabli, faktori su nadalje podvrgnuti post-hoc testovima.

Tablica 3. 14: *Analiza varijance u dimenzijama samoprocjena nastavnika s obzirom na inicijalno obrazovanje*

Faktori	F-omjer	Stat. znač.
F2.1 Poznavanje specifičnosti učenika u nastavi matematike	2.294	.078
F2.2 Stručna kompetencija	4.337	.005**
F2.3 Socijalna kompetencija	5.585	.001**
F2.4 Rad s učenicima sa specifičnim teškoćama	.774	.509
F2.5 Znanja o kurikulumu	.256	.857

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Višestrukim usporedbama Scheffe testom između grupa nastavnika na faktoru samoprocjena stručne kompetencije utvrđena je statistički značajna razlika (na razini 0.01) između nastavnika koji su završili inženjerski smjer na PMF-u i nastavnika koji su završili Učiteljski fakultet. S druge strane, u samprocjenama socijalne kompetencije nastavnici Učiteljskog fakulteta značajno višim (na razini 0.01) procjenjuju svoje socijalne vještine nego nastavnici sa završenim PMF-om nastavničkog i inženjerskog smjera.

4.3.2.3 Razlike u percipiranoj kompetentnosti i samoefikasnosti nastavnika s obzirom na radni staž

U tablici 3.15 slijedi prikaz statistički značajnih razlika po tvrdnjama samoprocjena nastavnika s obzirom na radni staž koristeći se jednosmjernom analizom varijance.

Tablica 3. 15: *Analiza varijance u dimenzijama samoprocjena nastavnika s obzirom na radni staž*

Faktori	F-omjer	Stat. znač.
F2.1 Poznavanje specifičnosti učenika u nastavi matematike	.902	.441
F2.2 Stručna kompetencija	5.488	.001**
F2.3 Socijalna kompetencija	.521	.668
F2.4 Rad s učenicima sa specifičnim teškoćama	.621	.602
F2.5 Znanja o kurikulumu	1.449	.228

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

S obzirom na radni staž, utvrđene su razlike jedino u sferi stručne kompetencije u kojoj su nađene statistički značajne razlike, primarno s razlikom od nastavnika Učiteljskog fakulteta. Prema tablici 3.16, najkompetentnijim u smislu stručnih matematičkih kompetencija osjećaju se najiskusniji nastavnici koji imaju 30 i više godina radnog staža. Njihove samoprocjene značajno su više (na razini 0.05) od nastavnika koji imaju 6 - 15 godina radnog staža te su još istaknutije (na razini 0.01) s obzirom na nastavnike s 5 i manje godina radnog staža.

Tablica 3. 16: *Rezultati post-hoc Scheffe testa višestrukih usporedbi među grupama nastavnika s obzirom na radni staž*

Varijabla	(I) Godine radnog staža	(J) Godine radnog staža	Stat. znač.
F2.2 Stručna kompetencija	30-45	0-5	.004**
		6-15	.041*
		16-29	.547

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

4.3.2.4 Razlike u percipiranoj kompetentnosti i samoefikasnosti nastavnika s obzirom na stečenu dodatnu naobrazbu

Razlike u samoprocjenama nastavnika prikazane su u tablici 3.17 u kojoj su utvrđene statistički značajne razlike u dimenzijama samoprocjena s obzirom na stečenu dodatnu naobrazbu koristeći se jednosmjernom analizom varijance.

Tablica 3. 17: *Analiza varijance u dimenzijama samoprocjena nastavnika s obzirom na stečenu dodatnu naobrazbu*

Faktori	F-omjer	Stat. znač.
F2.1 Poznavanje specifičnosti učenika u nastavi matematike	1.657	.192
F2.2 Stručna kompetencija	8.534	.000***
F2.3 Socijalna kompetencija	2.220	.110
F2.4 Rad s učenicima sa specifičnim teškoćama	.783	.458
F2.5 Znanja o kurikulumu	4.764	.009**

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Nastavnici koji su stekli status mentora i savjetnika razlikuju se u samoprocjenama stručne kompetencije i znanja o kurikulumu. Post hoc analizama utvrđeno je kako nastavnici koji su napredovali u zvanju procjenjuju svoje stručne kompetencije i znanja o kurikulumu značajno višim nego nastavnici koji nisu napredovali u zvanju.

4.3.2.5 Razlike u percipiranoj kompetentnosti i samoefikasnosti nastavnika s obzirom na radno mjesto

Razlike u samoprocjenama nastavnika prikazane su u tablici 3.18 u kojoj su utvrđene statistički značajne razlike u dimenzijama samoprocjena s obzirom na radno mjesto koristeći se jednosmjernom analizom varijance.

Tablica 3. 18: *Analiza varijance u dimenzijama samoprocjena nastavnika s obzirom na radno mjesto*

Faktori	F-omjer	Stat. znač.
F2.1 Poznavanje specifičnosti učenika u nastavi matematike	.897	.409
F2.2 Stručna kompetencija	1.658	.192
F2.3 Socijalna kompetencija	13.661	.000***
F2.4 Rad s učenicima sa specifičnim teškoćama	9.473	.000***
F2.5 Znanja o kurikulumu	4.118	.017*

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Sukladno prethodnim analizama iz poglavlja 4.2.2.5, utvrđene su značajno više samoprocjene nastavnika osnovnih škola u sferi stručne kompetencije te u radu s učenicima sa specifičnim teškoćama. U donjoj tablici priloženi su i deskriptivni parametri navedenih faktora te je očigledna razlika u obje kategorije zato što se nastavnici u osnovnim školama ističu znatno višim samoprocjenama. Daljnjim analizam post-hoc testovima iste su razlike potvrđene na razini 0.01 statističke značajnosti između nastavnika osnovnih i strukovnih škola te na razini 0.001 između nastavnika gimnazija i nastavnika osnovnih škola.

Tablica 3. 19: *Prikaz deskriptivnih parametara u samoprocjenama među grupama nastavnika s obzirom na radno mjesto ispitanika*

Faktori		Veličina uzorka	M	Stand. dev.
F2.3 Socijalna kompetencija	Osnovna škola (predmetna nastava)	136	4.0	.59
	Srednja strukovna škola	105	3.74	.53
	Gimnazija	106	3.65	.59
	Ukupno	347	3.83	.59
F2.4 Rad s učenicima sa specifičnim teškoćama	Osnovna škola (predmetna nastava)	136	3.74	.61
	Srednja strukovna škola	105	3.48	.68
	Gimnazija	106	3.41	.61
	Ukupno	347	3.56	.65

4.3.3 Faktorska analiza ljestvice učestalosti nastavnih i izvannastavnih praksi

Analizom glavnih komponenti ljestvice učestalosti nastavnih i izvannastavnih praksi dobili smo sedam faktora. Sukladno faktorskoj analizi samoprocjena nastavnika, primijenjena je *Oblimin* kosokutna rotacija budući da se ponovno očekuju znakovite korelacije između dobivenih faktora. Od početnih 25 pitanja i šest faktora prema metodi svojstvenih vrijednosti pokazalo se kako faktorska analiza nema pouzdanu i interpretabilnu strukturu pa se uklanjanjem četiriju tvrdnji početne ljestvice uvjerenja i stavova nastavnika došlo do strukture od sedam faktora i 21 tvrdnje.

Metoda svojstvenih vrijednosti (tablica 3.20) sugerirala je šest faktora, Scree test sugerirao je dva faktora pa je primijenjena i paralelna analiza. *Monte Carlo PCA for Parallel Analysis* (prema Watkins, 2000), nastala učitavanjem 348 ispitanika, 21 varijable i 100 replikacija, u programu je sugerirala tri faktora budući da je nasumična svojstvena vrijednost generirana paralelnom analizom upravo na trećem faktoru utvrdila vrijednost koja premašuje (1.32 > 1.27) onu na trećem faktoru iz gornje tablice dobivene analizom glavnih komponenti. Međutim, to nije odgovaralo danoj faktorskoj strukturi u kontekstu teorijskih konstrukata pa smo višestrukim pokretanjem analize glavnih komponenti došli do idealnog modela od sedam faktora koji pristaje teorijskim polazištima u određivanju dimenzija rada nastavnika.

Tablica 3. 20: *Prikaz svojstvenih vektora i udjela varijance po faktorima dobivenih metodom analize glavnih komponenti*

Komponente (faktori)	Inicijalni svojstveni vektori		
	Svojstveni vektori	Udio varijance	Kumulativni udio varijance
1	6.072	28.915	28.915
2	1.785	8.498	37.413
3	1.272	6.056	43.470
4	1.235	5.880	49.350
5	1.125	5.358	54.707
6	1.030	4.905	59.612
7	**.993**	**4.728**	**64.340**
8	.902	4.295	68.635

Sedam ekstrahiranih faktora objašnjava 64 % varijance ispitivanih procjena nastavnika. Kaiser-Meyer-Olkin testom prikladnosti i Bartlettovim testom spljoštenosti utvrđeno je kako su podatci prikladni za faktorizaciju (KMO = 0.88). Bartlettov test u ovom je istraživanju značajan što potvrđuje kako je u reduciranom faktorskom modelu ostalo dovoljno zajedničke varijance. S

obzirom na okvir ljestvice samoprocjena i zadovoljavajuće visoka faktorska opterećenja na česticama, pokazalo se kako je struktura od sedam faktora jedina dobila jasne faktore koji su dosljedni isptivanim dimenzijama nastavnih i izvannastvnih praksi nastavnika. Cronbachov Alpha koeficijent iznosi dovoljno visokih 0.86. Dobiveni su sljedeći faktori samoprocjena nastavnika (tablica 3.21):

Tablica 3. 21: *Ekstrahirani faktori nastavnih praksi nastavnika, varijable i faktorska opterećenja dobiveni provedbom eksplorativne faktorske analize temeljene na analizi glavnih komponenti*

Faktor I: Nastava usmjerena na učenika. F3.1		**Faktorska opterećenja**
2.32	Individualno radim s učenicima koji sporije usvajaju sadržaje.	0.80
2.37	Koristim stvarne životne situacije kao polazište za učenje i poučavanje.	0.67
2.33	Preventivno djelujem i pomažem učenicima koji imaju negativne stavove prema učenju matematike.	0.63
2.38	U nastavi rješavam problemske zadatke povezane sa svakodnevicom.	0.61
Faktor II: Metakognitivna dimenzija- F3.2		
2.44	Prilagođavam metode poučavanja tipičnim greškama i teškoćama učenika.	0.78
2.43	Objašnjavam matematičke sadržaje, koncepte i procese jednostavnim jezikom koji učenici razumiju.	0.69
2.34	Uočavam specifične reakcije kada učenici ne razumiju pojedine sadržaje.	0.62
Faktor III: Socijalni oblici rada- F3.3		
2.39	Odgojno-obrazovne aktivnosti temeljim na frontalnom obliku rada.	0.85
2.41	Učenici usvajaju matematičke sadržaje radom u paru.	-0.53
2.40	Učenike uključujem u nastavne aktivnosti formiranjem u grupe i timove.	-0.48
Faktor IV: Potpora učenicima- F3.4		
2.29	Ukazujem na važnost upornosti i radnih navika za uspjeh u matematici.	0.84

2.30	Potičem pozitivne stavove prema učenju kod slabijih učenika.	0.82
2.28	U nastavi ističem da svaki učenik može biti uspješan u matematici.	0.66
Faktor V: Profesionalni razvoj- F3.5		
2.21	Pohađam stručno-metodičke skupove i (među)županijska vijeća.	0.71
2.35	Koristim informatičke i komunikacijske tehnologije u poučavanju matematike.	0.66
2.36	Pratim znanstvene inovacije u matematici.	0.51
Faktor VI: Refleksivna dimenzija- F3.6		
2.27	Učenicima dajem anonimni evaluacijski upitnik kako bi iznijeli svoje kritike, mišljenja i prijedloge o aktivnostima te načinima unapređenja nastavnog procesa.	0.76
2.25	Evaluiram i procjenjujem uspješnost svojeg poučavanja na kraju sata.	0.49
Faktor VII: Stručno usavršavanje u projektima i akcijskim istraživanjima-F3.7		
2.23	Sudjelujem u projektima kolegijalnog opažanja zajedno s drugim nastavnicima.	0.82
2.22	Sudjelujem u projektima mobilnosti nastavnika.	0.72
2.26	Sudjelujem u akcijskom istraživanju zajedno s učenicima.	0.70

Najistaknutiji faktor *nastava usmjerena na učenika* pojašnjava 29 % u varijanci odgovora nastavnika na ljestvici učestalosti nastavnih i izvannastavnih praksi, a odnosi se na različite oblike prilagodbe nastave učenicima, pojašnjavanje i obradu sadržaja na učenicima razumljiviji način i slično. Navedeni faktor na neki je način komplementaran s dominantnim faktorom iz samoprocjena nastavnika koji se odnosi na poznavanje specifičnosti učenika u kontekstu nastave matematike što je s podjednakim udjelom u varijanci (28 %) samoprocjena nastavnika. Drugim riječima, razlike u samopoimanju nastavnika vezane uz prepoznavanja specifičnosti učenika mogu biti dobar prediktor ostalih samoprocjena, a po pitanju nastavnih praksi izdvojile su se socijalne i metodičke kompetencije u različitim oblicima prilagodbi rada nastavnika koje su također potencijalni prediktor ostalih nastavnih i izvannastavnih praksi.

Detaljnije analize i određivanje prediktorskih svojstava nekih faktora i varijabli odredit i opisat ćemo u poglavlju 4.4 u kojem ćemo ispitati korelacije među svim faktorima triju

ljestvica ovog istraživanja. Navedeno ćemo zaključiti regresijskim analizama koncipiranim na temelju do sada utvrđenih razlika i povezanosti određenih faktora kako bismo odredili značajnost prediktorskih varijabli koje proizlaze ili iz pregleda literature ili iz nekih specifičnih rezultata u koje smo stekli uvid dosadašnjim analizama.

U ovoj faktorskoj analizi drugi po redu faktor koji se izdvojio svojim udjelom u varijanci jest *metakognitivna dimenzija* praksi nastavnika što bi se moglo spojiti s prvim faktorom s obzirom na to da su dio istog šireg konstrukta. S druge strane, u području matematičkog obrazovanja metakognitivne sposobnosti i vještine nastavnika imaju istaknuto mjesto zbog specifičnosti učenja i poučavanja matematike pa je stoga taj faktor opravdano zadržan u ovoj faktorskoj strukturi.

Treći faktor *metodičko strukturiranje nastave* specifičan je po tome što jedini ima negativnih faktorskih opterećenja koja su vezana uz oblike rada u paru te u grupama i timovima. Ono što jasno upotpunjuje taj konstrukt, odnosno latentnu dimenziju koja opisuje taj faktor, jest činjenica kako najviše opterećenje u tom faktoru ima tvrdnja koja se odnosi na poučavanje u frontalnom obliku rada koje je pozitivnog predznaka, za razliku od tvrdnji 2.40 i 2.41 koje se odnose na rad u paru, grupi ili timu. Taj faktor nazvali smo socijalni oblici rada, ali zbog daljnjih analiza nužno ga je s oprezom tumačiti u vidu nekih tumačenja povezanosti u korelacijskim analizama u poglavlju 4.4. Naime, tvrdnje koje se odnose na učestalost primjene grupnih oblika rada i rada u paru očekivano su negativno korelirane na razini 0.01 statističke značajnosti s učestalošću primjene frontalnog oblika rada, a međusobno su visoko korelirane ($r = 0.6$) na razini 0.001 statističke značajnosti. To znači da će se znakovite korelacije faktora „socijalni oblici rada“ s nekim drugim obilježjima i/ili faktorima tumačiti kao povezanost s (ne)tradicionalnim poimanjem socijalnih oblika u kontekstu kvalitete nastave.

Četvrti faktor *potpora učenicima* odnosi se na potporu kroz odgojni rad nastavnika u poticanju pozitivnih stavova i radnih navika te u nastojanjima da se učenicima matematika približi ne samo u sadržajnom i životnom kontekstu, već u vidu njihovih akademskih perspektiva koje zbog nedostatnog pedagoškog rada u nastavi matematike mogu biti prilično ograničene.

Preostali faktori odnose se na razne oblike profesionalnog i stručnog usavršavanja i refleksivnu dimenziju nastavnikova rada koja se u šestom faktoru izdvojila s dvije tvrdnje koje smo, unatoč teorijskim okvirima u ekstrakciji faktora zbog jasne i nedvosmislene strukture, zadržali kao faktor koji je bitan u razumijevanju profesionalnog razvoja nastavnika. S obzirom da je analiza glavnih komponenti provedena pomoću *Oblimin* rotacije koja kao pretpostavku ima korelacije među faktorima, potrebno je protumačiti povezanost između pojedinih faktora.

Također, očito je kako su mnoge korelacije nešto ispod 0.3, no unatoč tom kriteriju, sve su druge pretpostavke za ovu faktorsku strukuturu i povezanosti među faktorima ispunjene.

Tablica 3. 22: *Matrica korelacija (Pearsonov koeficijent korelacije) između faktora dobivenih iz ljestvice nastavnih praksi nastavnika*

Faktori	F3.1	F3.2	F3.3	F3.4	F3.5	F3.6	F3.7
F3.1 - Nastava usmjerena na učenika	1	.28**	-.21**	.29**	-.24**	.28**	.28**
F3.2 - Metakognitivna dimenzija	.28**	1	-.08	.28**	-.21**	.11	.14*
F3.3 - Metodičko strukturiranje nastave	-.21**	-.08	1	-.08	.11	-.14*	-.14*
F3.4 - Potpora učenicima	.29**	.28**	-.08	1	-.20**	.11	.16
F3.5 - Profesionalni razvoj	-.24**	-.21**	.11	-.20**	1	-.14*	-.26
F3.6 - Refleksivna dimenzija	.28**	.11	-.14*	.11	-.14*	1	.18**
F3.7 - Stručno usavršavanje u projektima i akcijskim istraživanjima	.28**	.14*	-.14*	.16**	-.26**	.18**	1

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Upravo zbog rubnog kriterija u vidu korelacija koje ne premašuju 0.3, pokrenute su i višestruke analize glavnih komponenti s *Varimax* rotacijom kako bi se optimizirala faktorska struktura ovog dijela upitnika. Nijedan model nije ni približno odgovorao teorijskim okvirima kao prethodno analizirani zbog čega smo sve analize radili s ovim modelom i kosokutnom *Oblimin* rotacijom.

Što se tiče korelacija, očekivano većina faktora visoko korelira s prvim faktorom što potvrđuje i relativno visokih 29 % varijance u cjelokupnoj ljestvici ovog dijela upitnika. Dakle, nastavnici koji metodičko strukturiranje nastave podređuju učenicima i uvjetima kako bi bili uspješniji u nastavi češće koriste različite metakognitivne sposobnosti kao i različite oblike emocionalne potpore učenicima. Ti nastavnici također u većoj mjeri iskazuju svoje refleksivne vještine kroz redovni rad u nastavi, putem anonimnih evaluacijskih upitnika za učenike, te se češće usavršavaju kroz rad u projektima kolegijalnog opažanja, projektima mobilnosti i akcijskim istraživanjima.

Od istaknutih faktora vrijedi izdvojiti još i peti faktor koji se odnosi na profesionalni razvoj vezan uz pohađanje stručnih skupova, praćenje znanstvenih inovacija te kroz korištenje informatičkih i komunikacijskih tehnologija u poučavanju. Naime, taj faktor negativno korelira praktički sa svim faktorima u ovoj strukturi od kojih su najznačajnije one s faktorom socijalnih i metodičkih dimenzija nastavnikova rada te, pomalo iznenađujuće, s posljednjim faktorom koji

se odnosi na rad u projektima kolegijalnog opažanja, projektima mobilnosti i akcijskim istraživanjima.

4.3.3.1 Razlike u učestalosti nastavnih i izvannastavnih praksi s obzirom na spol

Već se ranije pokazalo kako su razlike u spolu možda i među najistaknutijma u dosad provedenim analizama. Navedeno se potvrđuje i rezultatima iz tablice 3.23 te se jasno vidi kako je većina razlika utvrđena na razini 0.01 statističke značajnosti.

Tablica 3. 23: *Analiza varijance u dimenzijama nastavnih praksi nastavnika s obzirom na spol*

Faktori	F-omjer	Stat. znač.
F3.1 Nastava usmjerena na učenika	19.881	.000***
F3.2 Metakognitivna dimenzija	14.341	.000***
F3.3 Metodičko strukturiranje nastave	5.050	.025*
F3.4 Potpora učenicima	32.855	.000***
F3.5 Profesionalni razvoj	6.979	.009**
F3.6 Refleksivna dimenzija	5.240	.023**
F3.7 Stručno usavršavanje u projektima i akcijskim istraživanjima	9.826	.002**

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

S obzirom na utvrđene razlike u varijancama na pojedinim faktorima, provedeni su i t-testovi koji su, uz pretpostavku različitih varijanci na razini 0.05, potvrdili sve razlike među ispitanicima redom po navedenim faktorima. Sve utvrđene razlike među spolovima istog su karaktera te se pokazalo kako nastavnice značajno češće od muškh nastavnika prilagođavaju učenicima svoje metode poučavanja u metodičkom, pedagoškom, socijalnom i emocionalnom kontekstu njihova rada. Najznačajnije razlike na razini 0.001 utvrđene su u prvom, drugom i četvrtom faktoru koji se odnose na socijalne i afektivne dimenzije njihova rada te se najveća razlika pokazala u pedagoškim aspektima potpore učenicima. Detaljniji uvid u potencijalne uzročno-posljedične odnose pokušat ćemo utvrditi korelacijskim analizama, odnosno različitim regresijskim modelima pokušat ćemo utvrditi više od samih povezanosti i/ili značajnih razlika među nastavnicima.

4.3.3.2 Razlike u učestalosti nastavnih i izvannastavnih praksi s obzirom na inicijalno obrazovanje

Analizom varijance utvrđene su razlike s obzirom na inicijalno obrazovanje na prva dva faktora te će se provesti daljnje analize u kojima će se utvrditi razlike između svih grupa nastavnika među sobom.

Tablica 3. 24: *Analiza varijance u dimenzijama nastavnih praksi nastavnika s obzirom na inicijalno obrazovanje*

Faktori	F-omjer	Stat. znač.
F3.1 Nastava usmjerena na učenika	12.824	.000***
F3.2 Metakognitivna dimenzija	2.979	.032*
F3.3 Metodičko strukturiranje nastave	1.251	.291
F3.4 Potpora učenicima	1.878	.133
F3.5 Profesionalni razvoj	1.292	.277
F3.6 Refleksivna dimenzija	2.625	.050
F3.7 Stručno usavršavanje u projektima i akcijskim istraživanjima	1.418	.237

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Post-hoc Scheffe testom među grupama nastavnika s obzirom na inicijalno obrazovanje u oba faktora utvrđene su razlike kod grupe nastavnika koji su završili Učiteljski fakultet. Naime, oni se u socijalnoj i metodičkoj dimenziji rada razlikuju od svih ostalih grupa nastavnika na razini 0.01 statističke značajnosti što se konkretno odnosi na učestalije individualizacije učenja i poučavanja, korištenje stvarnih životnih situacija kao polazišta za učenje te preventivno djelovanje u različitim oblicima potpore učenicima koji imaju negativne stavove prema učenju matematike.

Metakognitivna dimenzija rada nastavnika pokazala se različitom jedino među nastavnicima Učiteljskog fakulteta i onih koji su završili neke od ostalih nastavničkih studija koje smo svrstali u kategoriju „ostalo“. Utvrđena je razlika na razini 0.05 Scheffeova testa zato što su nastavnici Učiteljskog fakulteta pokazali učestalije prilagodbe rada u metakognitivnim aspektima učenja i poučavanja matematike. Na petom faktoru, koji se odnosi na profesionalni razvoj nastavnika, jednosmjerna analiza varijance pokazala je rubnih 0.05 statističke značajnosti, no post-hoc testovima nisu nađene razlike među pojedinim kategorijama.

4.3.3.3 Razlike u učestalosti nastavnih i izvannastavnih praksi s obzirom na radni staž

U dosad odrađenim analizama pokazalo se dosta značajnih razlika s obzirom na sociodemografska obilježja nastavnika te se pokazalo kako radni staž, kao nezavisna varijabla, jedinu razliku ima u faktoru profesionalnog razvoja.

Tablica 3. 25: *Analiza varijance u dimenzijama nastavnih praksi nastavnika s obzirom na radni staž*

Faktori	F-omjer	Stat. znač.
F3.1 Nastava usmjerena na učenika	.646	.586
F3.2 Metakognitivna dimenzija	1.164	.323
F3.3 Metodičko strukturiranje nastave	1.882	.132
F3,4 Potpora učenicima	1.443	.230
F3.5 Profesionalni razvoj	2.794	.052
F3.6 Refleksivna dimenzija	2.039	.108
F3.7 Stručno usavršavanje u projektima i akcijskim istraživanjima	2.495	.060

**** p < 0.001, ** p < 0.01, * p < 0.05*

Međutim, daljnjim analizama među grupama nismo utvrdili nikakve statistički značajne razlike na tom faktoru.

Tablica 3. 26: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na radni staž ispitanika*

Varijabla	(I) Godine radnog staža	(J) Godine radnog staža	Razlika u arit. sredinama (I-J)	Std. greška	Stat. znač.
Profesionalni razvoj	0 - 5	6 - 15	-.22917	.10	.157
		16 - 29	-.24945	.09	.062
		30 - 45	-.14281	.10	.592
	6 - 15	0 - 5	.22917	.10	.157
		16 - 29	-.02027	.089	.997
		30 - 45	.08636	.10	.866
	16 - 29	0 - 5	.24945	.09	.062
		6 - 15	.02027	.09	.997
		30 - 45	.10663	.09	.725
	30 - 45	0 - 5	.14281	.10	.592
		6 - 15	-.08636	.10	.866
		16 - 29	-.10663	.093	.725

**** p < 0.001, ** p < 0.01, * p < 0.05*

Iz tablice 3.26 očito je kako je najveća razlika između nastavnika početnika i nastavnika koji imaju između 16 i 29 godina radnog staža, no ta se razlika nije pokazala statistički značajnom u dimenziji profesionalnog razvoja nastavnika.

4.3.3.4 Razlike u učestalosti nastavnih i izvannastavnih praksi s obzirom na stečenu dodatnu naobrazbu

Nastavnici koji su napredovali u zvanje mentora ili savjetnika svojim se nastavnim i izvannastavnim aktivnostima izdvajaju od ostalih nastavnika u metakognitivnoj dimenziji, zastupljenosti socijalnih oblika rada te u učešću u različitim oblicima stručnog i profesionalnog razvoja od pohađanja stručnih skupova, kolegijalnog opažanja pa sve do sudjelovanja u akcijskim istraživanjima i projektima mobilnosti.

Tablica 3. 27: *Analiza varijance u dimenzijama nastavnih praksi nastavnika s obzirom na stečenu dodatnu naobrazbu*

Faktori	F-omjer	Stat. znač.
F3.1 Nastava usmjerena na učenika	2.609	.075
F3.2 Metakognitivna dimenzija	5.271	.006**
F3.3 Metodičko strukturiranje nastave	5.539	.004**
F3.4 Potpora učenicima	.906	.405
F3.5 Profesionalni razvoj	11.142	.000***
F3.6 Refleksivna dimenzija	2.958	.053
F3.7 Stručno usavršavanje u projektima i akcijskim istraživanjima	5.227	.006**

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

U metakognitivnim aspektima rada nastavnika Scheffeovim testom utvrđena je statistički značajna razlika između nastavnika mentora i ostalih nastavnika koji znatno manje prilagođavaju svoje metode poučavanja posebnostima učenika. Također su skloniji formirati razred u timove, grupe ili omogućiti učenicima rad u paru. Od utvrđenih razlika očekivanima su se, kao najizraženije, pokazale one u sferi profesionalnog razvoja i različitih oblika stručnog usavršavanja te su utvrđene razlike između mentora i onih koji nisu napredovali u zvanju. No, najveće su razlike na razini 0.001 između nastavnika savjetnika i nastavnika koji nisu napredovali u zvanju .

4.3.3.5 Razlike u učestalosti nastavnih i izvannastavnih praksi s obzirom na radno mjesto

Razlike među nastavnicima s obzirom na radno mjesto uglavnom su se pozicionirale oko nastavnika koji rade u osnovnim školama što ni na ovoj faktorskoj strukturi nije bila iznimka. Daljnjom analizom među grupama nastavnika utvrđeno je kako su se nastavnici osnovnih škola najviše istakli (u odnosu na nastavnike strukovnih škola i gimnazija) na prvom faktoru koji se odnosio na metodičke i socijalne dimenzije njihova poučavanja. Premda je bilo očekivano kako će se isto utvrditi i u dimenziji potpore učenicima u učenju, pokazalo se kako ima razlika, ali nisu statistički značajne prema provedenom Scheffe testu.

Tablica 3. 28: *Analiza varijance u dimenzijama nastavnih praksi nastavnika s obzirom na radno mjesto*

Faktori	F-omjer	Stat. znač.
F3.1 Nastava usmjerena na učenika	38.891	.000***
F3.2 Metakognitivna dimenzija	2.026	.133
F3.3 Metodičko strukturiranje nastave	1.228	.294
F3.4 Potpora učenicima	3.751	.024*
F3.5 Profesionalni razvoj	5.353	.005**
F3.6 Refleksivna dimenzija	7.583	.001**
F3.7 Stručno usavršavanje u projektima i akcijskim istraživanjima	5.865	.003**

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Posljednjim trima faktorima, na kojima smo jednosmjernom analizom varijance utvrdili razlike, pokazale su se razlike u profesionalnom i stručnom razvoju te u refleksivnoj dimenziji rada nastavnika između nastavnika osnovnih škola i nastavnika strukovnih škola koji znatno manje participiraju u različitim oblicima formalnih oblika stručnog usavršavanja, a s time i u refleksiji vlastite nastavne prakse.

4.4 Korelacijska analiza istraživačkog instrumenta

Dosadašnjim analizama prikazali smo bitne deskriptivne parametre i statistički značajne razlike s obzirom na sociodemografska obilježja i profesionalni profil nastavnika. U provedenim faktorskim analizama prikazane su korelacije unutar samoprocjena nastavnika po pitanju njihove kompetentnosti i učestalosti nastavnih praksi, no nisu prikazane povezanosti u uvjerenjima nastavnika u prvoj faktorskoj strukturi zbog specifičnosti provedbe te faktorske analize. Stoga ćemo na početku ovog poglavlja prikazati korelacije unutar triju faktorskih struktura kako bismo dobili jasniju podlogu za daljnje ispitivanje povezanosti između pojedinih dimenzija iz provedenih faktorskih analiza, a navedeno će se zaključiti regresijskim analizama kako bismo, pored već utvrđenih relacija, utvrdili i potencijalne prediktorske konstrukte u razmatranju kompetencija nastavnika.

Ljestvica općih uvjerenja i stavova nastavnika o matematičkom obrazovanju usmjerena je prema nešto širem okviru stavova i uvjerenja nastavnika te smo, za razliku od drugih dviju ljestvica istraživačkog upitnika, pri analizi glavnih komponenti početnu ljestvicu značajno smanjili (s 32 tvrdnje na 13 tvrdnji). Utvrđene korelacije među tim faktorima dane su u tablici 4.1.

Tablica 4. 1: *Matrica korelacija između faktora dobivenih iz ljestvice uvjerenja nastavnika*

Faktori	F1.1	F1.2	F1.3	F1.4
F1.1 Uvjerenja o kurikulumu	1	.34**	.27**	.03
F1.2 Uvjerenja o socijalnim vještinama nastavnika	.34**	1	.19**	.00
F1.3 Uvjerenja o metodičkom strukturiranju nastave	.27**	.19**	1	.04
F1.4 Uvjerenja o matematičkim sposobnostima	.03	.00	.04	1

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$ (*Pearsonov koeficijent korelacije*)

Prvi faktor u kojem su se izdvojili stavovi i uvjerenja o kurikulumu sukladno je relativno visokom udjelu (27 %) u varijanci uvjerenja i stavova, od kojih je viša korelacija s uvjerenjima o socijalnim vještinama nastavnika. Također je utvrđeno kako su uvjerenja o kurikulumu povezana s uvjerenjima o kvaliteti odgojnih i obrazovnih ishoda rada u grupnim oblicima rada. Četvrti faktor, koji se odnosi na (stereotipna) uvjerenja karakteristična za nastavu matematike, unutar ove faktorske strukture nema nikakvih znakovitih korelacija s danim faktorima.

U drugoj faktorskoj strukturi, tijekom analize glavnih komponenti, provedena je kosokutna rotacija koja podrazumijeva korelacije među faktorima pa su iste odmah izdvojene u provedenoj faktorskoj analizi (tablica 4.2).

Tablica 4. 2: *Matrica korelacija između faktora dobivenih iz ljestvice samoprocjena nastavnika*

Faktori	F2.1	F2.2	F2.3	F2.4	F2.5
F2.1 - Poznavanje specifičnosti učenika u nastavi matematike	1	.21**	.33**	.12*	-.41**
F2.2 - Stručna kompetencija	.21**	1	.07	-.03	-.33**
F2.3 - Socijalna kompetencija	.33**	.07	1	.14*	-.26**
F2.4 - Rad s učenicima sa specifičnim teškoćama	.12*	-.03	.14*	1	-.14*
F2.5 - Znanja o kurikulumu	-.41**	-.33**	-.26**	-.14*	1

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$ (*Pearsonov koeficijent korelacije*)

Prvi faktor ima najveću povezanost s trećim faktorom što konkretnije znači kako nastavnici koji procjenjuju visokim svoje poznavanje specifičnosti učenika u kontekstu nastave matematike u skladu s time procjenjuju i svoju socijalnu kompetenciju. Međutim, prvi faktor ima najviši stupanj povezanosti sa samoprocjenama znanja o kurikulumu (peti faktor), no utvrđena korelacija negativnog je predznaka (-0.41). Faktor *znanja o kurikulumu* negativno korelira sa svim faktorima u strukturi samoprocjena nastavnika, tj. nastavnici s višim procjenama svojih socijalnih kompetencija, stručno-metodičkih te pedagoških znanja i vještina imaju znatno niže samoprocjene znanja o kurikulumskim odrednicama suvremenog obrazovanja.

U trećem dijelu upitnika očekivano većina faktora visoko korelira s prvim faktorom koji se odnosi na nastavu usmjerenu na učenika što znači da nastavnici koji prilagođavaju nastavni proces učenicima i uvjetima, kako bi bili uspješniji u nastavi, koriste različite metakognitivne sposobnosti kao i različite oblike emocionalne potpore učenicima (tablica 4.3). Ti nastavnici češće procjenjuju svoju praksu, uvažavaju mišljenja učenika o njihovu radu te češće sudjelujuju u projektima kolegijalnog opažanja, projektima mobilnosti i akcijskim istraživanjima.

Tablica 4. 3: *Matrica korelacija između faktora dobivenih iz ljestvice nastavnih praksi nastavnika*

Faktori	F3.1	F3.2	F3.3	F3.4	F3.5	F3.6	F3.7
F3.1 - Nastava usmjerena na učenika	1	.28**	-.21**	.29**	-.24**	.28**	.28**
F3.2 - Metakognitivna dimenzija	.28**	1	-.08	.28**	-.21**	.11	.14*
F3.3 - Metodičko strukturiranje nastave	-.21**	-.08	1	-.08	.11	-.14*	-.14*
F3.4 - Potpora učenicima	.29**	.28**	-.08	1	-.20**	.11	.16
F3.5 - Profesionalni razvoj	-.24**	-.21**	.11	-.20**	1	-.14*	-.26
F3.6 - Refleksivna dimenzija	.28**	.11	-.14*	.11	-.14*	1	.18**
F3.7 - Stručno usavršavanje u projektima i akcijskim istraživanjima	.28**	.14*	-.14*	.16**	-.26**	.18**	1

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$ (*Pearsonov koeficijent korelacije*)

Kao što je ranije navedeno, profesionalni razvoj pohađanjem stručnih skupova, praćenje znanstvenih inovacija te kroz korištenje IKT-a u poučavanju negativno koreliraju sa svim faktorima u ovoj strukturi od kojih su najznačajnije one s faktorom *Nastava usmjerena na učenika* te, pomalo iznenađujuće, s posljednjim faktorom koji se odnosi na rad u projektima kolegijalnog opažanja, projektima mobilnosti i akcijskim istraživanjima. Čini se da nastavnici koji sudjeluju u „klasičnim“ oblicima usavršavanja, poput pohađanja stručnih skupova, imaju svojevrsni animozitet prema modernijim oblicima usavršavanja kao što su projekti mobilnosti, kolegijalno opažanje i akcijska istraživanja.

Najistaknutiji faktor *Nastava usmjerena na učenika* pojašnjava 29 % u varijanci odgovora nastavnika na ljestvici učestalosti nastavnih i izvannastavnih praksi, a odnosi se na različite oblike prilagodbe nastave učenicima, pojašnjavanje i obradu sadržaja na učenicima razumljiviji način i slično. Navedeni faktor na neki je način komplementaran s dominantnim faktorom iz samoprocjena nastavnika koji se odnosi na poznavanje specifičnosti učenika u kontekstu nastave matematike što je s podjednakim udjelom u varijanci (28 %) samoprocjena nastavnika. Drugim riječima, razlike u samopoimanju nastavnika po pitanju prepoznavanja specifičnosti učenika mogu biti dobar prediktor ostalih samoprocjena, a po pitanju nastavnih praksi izdvojile su se *dimenzije rada nastavnika usmjerene na učenika* koje se očituju u različitim oblicima prilagodbi rada nastavnika te su također potencijalni prediktor ostalih nastavnih i izvannastavnih praksi.

4.4.1 Korelacije između faktorskih struktura

Kako bismo bolje razumjeli razvoj profesionalnog identiteta nastavnika i pozadinu utvrđenih uvjerenja nastavnika i samoprocjena kompetentnosti te nastavnih praksi, u ovome poglavlju analizirat će se kako osobna sfera nastavnika i njegova nastavna iskustva utječu na percepciju kompetentnosti te kako stavovi i uvjerenja i percepcija samoefikasnosti nastavnika utječu na njihovu praksu. Nakon provedenih faktorskih analiza, određeni su okviri unutar kojih se možemo približiti odgovorima na postavljene probleme i ciljeve istraživanja unutar kojih želimo utvrditi jasnu vezu između uvjerenja nastavnika te njihovih samoprocjena u kontekstu kompetentnosti kao i učestalosti nastavnih i izvannastavnih praksi.

4.4.1.1 Povezanost stavova i uvjerenja nastavnika s percepcijom kompetentnosti i samoefikasnosti

Stavove i uvjerenja nastavnika o matematičkom obrazovanju nizom testova analizirali smo u kontekstu sociodemografskih podataka kao i sa samoprocjenama kompetentnosti i samoefikasnosti u kontekstu nastavničkog posla. Međutim, kako bismo jasnije razumjeli odnose među tim konstruktima u odnosu na profil nastavnika matematike, potrebno je ispitati povezanost pojedinih uvjerenja i percepcije kako bismo daljnjim analizama stekli detaljniji uvid u određena uvjerenja, stavove i postupke relevantne za njihov odgojno-obrazovni rad. Korelacije između faktorskih struktura stavova i uvjerenja te samoprocjena nastavnika u kontekstu nastave matematike prikazane su u tablici 4.4.

Tablica 4. 4: *Korelacije između dimenzija uvjerenja i samoprocjena nastavnika*

(F2) Samoprocjene / **(F1) Stavovi i uvjerenja**	F2.1 Poznavanje specifičnosti učenika u nastavi matematike	F2.2 Stručna kompetencija	F2.3 Socijalna kompetencija	F2.4 Rad s učenicima sa specifičnim teškoćama	F2.5 Znanja o kurikulumu
F1.1 Stavovi i uvjerenja o kurikulumu	.352**	.257**	.283**	.245**	.476**
F1.2 Uvjerenja o socijalnim vještinama nastavnika	.443**	.169**	.309**	.130*	.263**
F1.3 Uvjerenja i stavovi o metodičkom oblikovanju nastave	.133*	-.001	.166**	.126*	.063
F1.4 Uvjerenja o matematičkim sposobnostima	-.033	-.108*	.061	-.013	-.011

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$ (*Pearsonov koeficijent korelacije*)

Očekivanim se pokazalo kako su najviše korelacije između najznačajnijih faktora u obje faktorske strukture analiziranih ljestvica. Među statistički značajnim korelacijama, najviše razlike utvrđene su između stavova i uvjerenja o kurikulumu te socijalnim vještinama nastavnika s prve ljestvice sa svim faktorima druge ljestvice koji se odnose na samoprocjene nastavnika. Stavovi i uvjerenja o kurikulumu najviše koreliraju sa samoprocjenama po pitanju njihovih znanja o kurikulumu. Također se pokazalo kako su stavovi o kurikulumu iz prve ljestvice povezani redom po jačini povezanosti s poznavanjem specifičnosti učenika u nastavi matematike, sa socijalnom kompetencijom, a potom sa stručnom kompetencijom i osposobljenošću za rad s učenicima sa specifičnim teškoćama u učenju matematike.

Uvjerenja o socijalnim vještinama nastavnika su u preliminarnoj faktorskoj analizi ljestvice uvjerenja i stavova nastavnika bila dominantni faktor, međutim, reduciranjem na znatno manju i stabilniju faktorsku strukturu ipak se pokazuju kao drugi faktor po varijanci stavova i uvjerenja nastavnika u istaknutim dimenzijama opisanih faktorima. Budući da su dio istog konstrukta, očekivano se potvrdilo kako su visoka uvjerenja o socijalnim vještinama nastavnika povezana s poznavanjem specifičnosti učenika u kontekstu nastave matematike te sa samoprocjenom vlastite kompetentnosti u socijalnim dimenzijama odgojno-obrazovnog rada. Znakovito je kako su uvjerenja o socijalnim vještinama nastavnika više povezana sa samoprocjenama u znanju o kurikulumu nego sa stručnom kompetencijom ili sa

samoprocjenama za rad s učenicima sa specifičnim teškoćama u učenju matematike. Sve navedene korelacije statistički su značajne na razini 0.01, međutim, nisu sve jednako povezane te je i donekle očekivano kako samoprocjene stručne kompetencije neće biti toliko snažno povezane sa socijalnim dimenzijama nastave kao različiti oblici podupirućih elemenata nastavnikova rada.

4.4.1.2 Povezanost stavova i uvjerenja nastavnika s učestalošću nastavnih i izvannastavnih praksi

Kako bismo odgovorili na osnovne ciljeve istraživanja, potrebno je primarno razumjeti vezu između uvjerenja nastavnika i njihove odgojno-obrazovne prakse. Povezanost određenih uvjerenja i učestalosti nastavnih i izvannastavnih praksi prikazane su u donjoj tablici.

Tablica 4. 5: *Korelacije između dimenzija uvjerenja te nastavnih i izvannastavnih aktivnosti nastavnika*

(F3) Nastavne i izvannastavne metode i aktivnosti / **(F1) Stavovi i uvjerenja**	F3.1 Nastava usmjerena na učenika	F3.2 Metakognitivna dimenzija	F3.3 Metodičko strukturiranje nastave	F3.4 Potpora učenicima	F3.5 Profesionalni razvoj	F3.6 Refleksivna dimenzija	F3.7 Stručno usavršavanje u projektima i akcijskim istraživanjima
F1.1 Stavovi i uvjerenja o kurikulumu	.41**	.31**	.27**	.30**	.39**	.37**	.19**
F1.2 Uvjerenja o socijalnim vještinama nastavnika	.35**	.43**	.13*	.29**	.18**	.18**	.16**
F1.3 Uvjerenja i stavovi o metodičkom oblikovanju nastave	.28**	.13*	.19**	.17**	.13*	.21**	.12*
F1.4 Uvjerenja o matematičkim sposobnostima	.08	.02	.09	.05	.01	.12*	.06

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$ (*Pearsonov koeficijent korelacije*)

Korelacijskom analizom utvrđeno je kako između svih faktora obiju struktura postoje statistički značajne povezanosti, s izuzetkom korelacija faktora uvjerenja o matematičkim sposobnostima koji jedino ima znakovitu korelaciju s refleksivnom dimenzijom rada nastavnika. No, ista je prilično slabog intenziteta te je nećemo tumačiti s obzirom na ostale korelacije koje su na višim razinama statističke značajnosti i znatno viših korelacija. Sukladno značajnoj varijanci (27 %), u prvoj faktorskoj strukturi uvjerenja o kurikulumu visoko su povezana sa svim oblicima nastavnih i izvannastavnih praksi što znači da su odstupanja na tom faktoru potencijalno značajni prediktor u svim dimenzijama rada nastavnika.

Među njima se najviše ističe povezanost uvjerenja o kurikulumu s nastavom usmjerenom na učenika (r = 0.41) kao i s ostalim faktorima koji se odnose na potporu i prilagodbe rada nastavnika prema specifičnostima učenika. Međutim, pored povezanosti s nastavom usmjerenom na učenika, pokazalo se kako su uvjerenja o kurikulumu u visokoj korelaciji s profesionalnim razvojem (r = 0.39) te s refleksivnom dimenzijom (r = 0.37) rada nastavnika. Drugim riječima, nastavnici koji smatraju bitnim razumijevanje općih i specifičnih ciljeva kurikuluma te smjernica koncepta cjeloživotnog učenja češće pohađaju stručno-metodičke skupove, koriste IKT u nastavi, prate znanstvene inovacije u matematici te češće evaluiraju svoju praksu.

Uvjerenja o socijalnim vještinama nastavnika najviše su povezana s metakognitivnom dimenzijom (r = 0.43), s nastavom usmjerenom na učenika (r = 0.35) te s potporom učenicima (r = 0.29). To je i očekivano s obzirom na uvjerenja o socijalnim vještinama koja se odnose na razvijenost komunikacijskih vještina nastavnika, poticanje pozitivnih i prevencija negativnih stavova učenika prema matematici. Pokazalo se kako nastavnici koji preferiraju grupne oblike rada i problemsku nastavu više prilagođavaju nastavu učenicima te češće evaluiraju svoj rad. Iako se pokazala statistički značajna korelacija između stavova o socijalnim oblicima rada i učestalosti primjene istih u nastavi, isto se ne može jednoznačno tumačiti zato što faktor F 3.3, koji se odnosi na socijalne oblike rada, ne govori jednoznačno koliko se koriste koji oblici rada u nastavi, osim ako ih razmatramo kao pojedinačne tvrdnje. Uvjerenja o matematičkim sposobnostima imaju statistički značajnu korelaciju na razini 0.05 jedino s refleksivnom dimenzijom rada nastavnika, no ista nije dovoljno visoka (r = 0.12) kako bismo iznosili konkretnije zaključke.

4.4.1.3 Povezanost percepcije kompetentnosti i samoefikasnosti s učestalošću nastavnih i izvannastavnih praksi

Sukladno očekivanjima, korelacijskom analizom utvrđena je visoka povezanost između samoprocjena nastavnika te različitih dimenzija njihova rada u praksi.

Tablica 4. 6: *Korelacije između dimenzija samoprocjena te nastavnih i izvannastavnih aktivnosti nastavnika*

(F3) Nastavne i izvannastavne metode i aktivnosti / **(F2) Samoprocjene**	F3.1 Nastava usmjerena na učenika	F3.2 Metakognitivna dimenzija	F3.3 Metodičko strukturiranje nastave	F3.4 Potpora učenicima	F3.5 Profesionalni razvoj	F3.6 Refleksivna dimenzija	F3.7 Stručno usavršavanje u projektima i akcijskim istraživanjima
F2.1 Poznavanje specifičnosti učenika u nastavi matematike	.41**	.50**	.21**	.49**	.32**	.36**	.28**
F2.2 Stručna kompetencija	.24**	.26**	.20**	.22**	.34**	.23**	.35**
F2.3 Socijalna kompetencija	.41**	.30**	.30**	.32**	.29**	.23**	.28**
F2.4 Rad s učenicima sa specifičnim teškoćama	.32**	.29**	.14**	.17**	.21**	.18**	.25**
F2.5 Znanja o kurikulumu	.37**	.34**	.20**	.29**	.44**	.29**	.35**

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$ (*Pearsonov koeficijent korelacije*)

Dakle, pokazalo se kako samoprocjene nastavnika u poznavanju specifičnosti učenika u nastavi matematike visoko koreliraju s metakognitivnim vještinama poučavanja (0.50), općenito s nastavom usmjerenom na učenika (0.41) te s potporom učenicima (0.49). Navedene samoprocjene statistički su značajno povezane ($p < 0.01$) sa svim faktorima iz treće ljestvice, a pored navedenih najviše koreliraju s refleksivnom dimenzijom (0.36). Najniža korelacija očekivano je ona sa socijalnim oblicima rada koji nemaju konzistentnu strukturu intrepretabilnu u vidu pouzdanosti faktora.

Samoprocjene stručne kompetencije nastavnika najviše su povezane s profesionalnim razvojem (0.34) i sa stručnim usavršavanjem u projektima mobilnosti, kolegijalnom opažanju i akcijskim istraživanjima (0.35). Samoprocjene socijalne kompetencije najviše su povezane s nastavom usmjerenom na učenika (0.41), s potporom učenicima (0.32), s metakognitivnom

dimenzijom poučavanja (0.3) i gotovo podjednakom povezanošću (0.29) s dimenzijama stručnog usavršavanja i profesionalnog razvoja.

Nastavnici koji su imali više samoprocjene znanja u radu s učenicima sa specifičnim teškoćama u učenju svoj rad više individualiziraju potrebama učenika (0.32) te pritom češće koriste metakognitivne vještine u poučavanju (0.29). Samoprocjene znanja o kurikulumu imaju nekoliko znakovitih korelacija od kojih je najznačajnija povezanost s profesionalnim razvojem (0.44), nastava usmjerena na učenika (0.37) te metakogintivna dimenzija (0.34).

Kako su utvrđene brojne korelacije koje impliciraju povezanost između raznih uvjerenja, samoprocjena i djelovanja nastavnika, potrebno je odrediti u kojoj mjeri, koji faktori ili neke osobne značajke nastavnika utječu i/ili posreduju u utvrđenim odnosima te možemo li naći dominantna obilježja/čimbenike kao potencijalne prediktore utvrđenih relacija.

Detaljnije analize i određivanje prediktorskih svojstava nekih faktora i varijabli preciznije ćemo odrediti i opisati regresijskim analizama koncipiranim na temelju dosada utvrđenih razlika i povezanosti određenih faktora kako bismo odredili značajnost prediktorskih varijabli koje proizlaze ili iz pregleda literature ili iz nekih specifičnih rezultata u koje smo stekli uvid dosadašnjim analizama.

4.4.2 Regresijska analiza

Dosadašnjom korelacijskom analizom utvrdili smo i izdvojili brojne povezanosti između stavova i uvjerenja, samoprocjena kompetentnosti nastavnika te njihove odgojno-obrazovne prakse. Međutim, korelacije ukazuju samo na povezanost između varijabli, odnosno faktora iz pojedinih dijelova istraživačkog upitnika. Iako su neke korelacije očekivane i konzistentne s teorijskim okvirima, opet ih je zbirno teško ispravno tumačiti zato što prema polazištima ima mnogo međusobno povezanih varijabli koje su isprepletene te se zaključci moraju donositi s oprezom, naročito ako želimo razmatrati uzročno-posljedične odnose. Isto tako, za razliku od drugih vrsta analiza, korelacijska je analiza specifična zato što u provedbi iste nema nezavisnih i zavisnih varijabli, već ih sve možemo tretirati kao nasumične varijable za koje možemo ustanoviti određenu vrstu i intenzitet povezanosti.

Kako bismo se približili uzročno-posljedičnim odnosima i potencijalnim prediktorskim čimbenicima, u nastavku ćemo koristiti regresijsku analizu. Osnovna je ideja regresijske analize odrediti/izdvojiti prediktorske varijable kojima je cilj ispitati u kojoj mjeri iste mogu predvidjeti zavisne varijable te na koji način utječu na njih. Dakle, regresijskom analizom utvrđuje se utjecaj jedne varijable ili skupa varijabli na neku kriterijsku varijabli te se nastoji odrediti

funkcionalna veza između prediktorskih varijabli i kriterijske varijable utvrđivanjem regresijske jednadžbe.

Montgomery i suradnici (1982) navode četiri svrhe korištenja regresijske analize:

- *opisivanje podataka* - pronalazak regresijskih jednadžbi koje najbolje opisuju vezu između promatranih varijabli
- *procjena koeficijenata* - beta koeficijenti koji opisuju značaj, odnosno utjecaj nekih varijabli na zadane zavisne varijable
- *predviđanje* - na temelju regresijskog modela koji se izvodi iz utvrđenih dominantnih prediktorskih varijabli
- *kontrola varijabli* - odnosi se na izolaciju pojedinih varijabli od ostalih koje koreliraju sa zavisnim varijablama tako da se odredi realni utjecaj/povezanost svake varijable s određenim konstruktima i zavisnim varijablama.

Regresijska analiza napredniji je oblik korelacijske analize čiji je cilj upotpuniti nedostatke utvrđenih relacija i povezanosti. Regresijska analiza tako klasičnu korelacijsku analizu dovodi na razinu inferencijske statistike te smanjuje vjerojatnost postojanja nekih latentnih konstrukata koji bi mogli pojasniti odnose koje istražujemo.

U ovom istraživanju korištene su višestruke (multiple) linearne regresijske analize zato što se vodimo pretpostavkom kako su varijable u linearnoj vezi, tj. kako se povećavanjem jedne varijable druga jednoliko povećava, budući da nemamo tipove varijabli koje se uglavnom promatraju u kontekstu prirodnih i tehničkih znanosti, medicine i sl. To je ponajprije razvidno iz tipova varijabli koje smo izdvojili faktorskim analizama, a koje imaju obilježja kontinuiranih varijabli ograničenih Likertovom ljestvicom od pet stupnjeva unutar kojih nema nikakvih matematičkih osnova za postojanje nelinearnih povezanosti. Također, regresijska analiza ima prednost nad mnogim statističkim testovima zato što može raditi s nominalnim, ordinalnim i kontinuiranim varijablama bez ikakvih ograničenja. To nam omogućuje da u isti regresijski model kao prediktore stavimo i sociodemografske podatke, različita uvjerenja, procjene i slično. U tablici će stoga biti prikazane i p-vrijednosti kojima ćemo odrediti vrijede li utvrđene veze, razlike i ostali statistički parametri na razini cjelokupne populacije nastavnika matematike.

U sažetcima rezultata provedenih regresijskih analiza posebno će se istaknuti koeficijenti multiple determinacije R^2 koji se odnose na statističku mjeru koja predstavlja udio varijance u zavisnoj (kriterijskoj) varijabli koje se mogu pojasniti u nezavisnoj varijabli promatranog regresijskog modela. Tu će se istaknuti mjera R, R^2 te prilagođena mjera od R^2.

Navedena prilagođena mjera standardizirana je mjera s obzirom na veličinu uzorka i ostale parametre regresijskog modela što se naročito moraju razmatrati u multiploj regresijskoj analizi u kojoj R^2 prirodno raste s dodavanjem prediktorskih varijabli što naizgled čini model prikladnijim. Prilagođena mjera kompenzira taj učinak i rezultira većom vrijednosti jedino ukoliko dodane varijable doista doprinose varijanci odgovora neovisno o drugim prediktorima. Međutim, iako se pri provedbi linearne regresije najčešće navodi koeficijent multiple determinacije *R*, isti pak ne govori je li model dobar ili ne, zato što često niža vrijednost koeficijenta *R* (oko 0.05) ne govori kako model nije prikladan, a ni visoki *R* ne govori kako model nužno pojašnjava ciljane varijable. Stoga će za svaki regresijski model biti provedena jednosmjerna analiza varijance (ANOVA) kojom ćemo odrediti u kojoj mjeri regresijske jednadžbe predviđaju zavisne varijable što će biti ključni kriterij razmatranja pojedinih regresijskih jednadžbi na osnovu p-vrijednosti, odnosno statističke značajnosti *F*-distribucije danog modela.

Također, pri određivanju prediktorskih varijabli koristit će se standardizirani regresijski beta (β) koeficijenti koji predstavljaju veličinu promjene zavisne varijable izražene u dijelovima standardne devijacije pri jediničnom porastu standardizirane vrijednosti nezavisne varijable. Cilj je ovog dijela analize ispitati doprinos sociodemografskih obilježja, akademskog obrazovanja i stručnog usavršavanja u objašnjavanju stavova i uvjerenja nastavnika (4.4.2.1), samoprocjena nastavnika (4.4.2.2) te u nastavnoj praksi (4.4.2.3). Uvažavajući prethodno utvrđene razlike s obzirom na navedene varijable, regresijskim analizama ispitat će se prediktivna snaga pojedinih varijabli kako bi se izdvojile dominantne kategorije.

U poglavlju 4.4.2.4 kombiniranim regresijskim analizama utvrdit će se jesu li sociodemografska obilježja bolji prediktori od stavova i uvjerenja nastavnika u samoprocjenama nastavnika te, naposljetku, koji su čimbenici i/ili obilježja nastavnika najbolji prediktori njihovih nastavnih i izvannastavnih praksi relevantnih za odgojno-obrazovnu praksu.

4.4.2.1 Regresijska analiza sociodemografskih obilježja i profesionalnog profila nastavnika kao prediktorima stavova i uvjerenja nastavnika kao zavisnom varijablom

U dosadašnjim analizama pokazalo se kako je najviše utvrđenih razlika u uvjerenjima i stavovima nastavnika bilo s obzirom na spol, inicijalno obrazovanje i radno mjesto nastavnika. Za prvi dio upitnika i faktorsku strukturu koju smo sveli na četiri kategorije uvjerenja i stavova nastavnika, regresijskom analizom pokušat ćemo odrediti prediktorsku snagu istih te ima li regresijski model značajan utjecaj na zavisne varijable. Kao nezavisne varijable (prediktore) u regresijskom modelu navest ćemo varijable koje smo u dosadašnjim analizama testirali kao razlike među ispitanicima: radno mjesto, spol, stečena dodatna naobrazba, inicijalno obrazovanje i godine radnog staža. Zavisne (kriterijske) varijable su stavovi i uvjerenja o kurikulumu, uvjerenja o socijalnim vještinama, uvjerenja o metodičkom oblikovanju nastave te uvjerenja o matematičkim sposobnostima.

Tablica 4. 7: *Sažetak regresijskih analiza sa sociodemografskim podatcima i profesionalnim profilom nastavnika kao prediktorskim te sa stavovima i uvjerenjima kao kriterijskim varijablama*

	F1.1 Stavovi i uvjerenja o kurikulumu		F1.2 Uvjerenja o socijalnim vještinama nastavnika		F1.3 Uvjerenja i stavovi o metodičkom oblikovanju nastave	
	Std. β	p	Std. β	p	Std. β	p
Spol	.151**	.004	.129*	.017	.042	.438
Godine radnog staža	.142*	.014	-.050	.392	-.096	.104
Inicijalno obrazovanje	-.040	.477	.003	.958	-.148*	.010
Stečena dodatna naobrazba	-.089	.119	-.125*	.032	-.001	.986
Radno mjesto	-.146**	.009	-.114	.046	-.087	.127
Regresijski model	R= 0.275 R^2 = 0.075 Pril. R^2= 0.062 F(5, 348) = 5.51***		R= 0.209 R^2 = 0.044 Pril. R^2= 0.029 F(5, 348) = 2.97*		R= 0.192 R^2 = 0.037 Pril. R^2= 0.023 F(5, 348) = 2.648*	

**** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$*

U tablici su prikazane tri regresijske analize, od planirane četiri, zato što se pokazalo da regresijski model za kriterijsku varijablu *uvjerenja o matematičkim sposobnostima* ne ispunjava temeljne kriterije regresijske analize. Naime, jednosmjernom analizom varijance (ANOVA) pokazalo se kako regresijske jednažbe u nedostatnoj mjeri predviđaju zavisne varijable *uvjerenja o matematičkim sposobnostima* te se pokazalo kako p-vrijednosti statističke značajnosti te koeficijent multiple determinacije *R* nisu na potrebnoj razini zbog čega taj regresijski model nema relevantnih rezultata i odnosa među navedenim varijablama.

U preostala tri regresijska modela pokazalo se kako odabrane varijable razmjerno dobro predviđaju stavove i uvjerenja nastavnika u svakoj od triju dimenzija. U sva tri modela utvrđena je relativno niska vrijednost koeficijenta multiple determinacije, no pokazalo se kako su modeli statistički značajni, s izuzetkom ranije spomenute kriterijske varijable uvjerenja o matematičkim sposobnostima. U prvom modelu, koji se odnosio na uvjerenja o kurikulumu, pokazalo se kako je model statistički značajan na razini $p < 0.001$ budući da je $F (5, 348) = 5.51$. Prilagođena vrijednost od R^2 ukazuje kako je udio varijance nešto ispod 10 % pa stoga isto nećemo navoditi kao bitnu mjeru, s obzirom da smo utvrdili prediktore koji značajno utječu na kriterijsku varijablu tog modela. Prema standardiziranim beta koeficijentima i pripadajućim p-vrijednostima statističke značajnosti, pokazalo se kako su redom najbolji prediktori uvjerenja nastavnika o kurikulumu: spol ($\beta = .151^{**}$), radno mjesto ($\beta = .146^{**}$), godine radnog staža ($\beta = .142^{**}$). Međutim, kako se spol i radno mjesto u mnogočemu podudaraju zbog visokog udjela nastavnica u osnovnim školama, neke razlike koje su pritom utvrđene vjerojatno imaju zajedničko polazište zato što nastavnice, kao i populacija nastavnika osnovnih škola, smatraju kurikulumske dokumente bitne nego što to smatraju ostali nastavnici drugačijih sociodemografskih obilježja. Godine radnog staža također su se pokazale kao dobar prediktor uvjerenja nastavnika o kurikulumu što su i potvrdile prethodne analize u razlikama između nastavnika početnika i onih koji imaju 16 i više godina radnog staža koji su iskazali više razine slaganja s kurikulumskim dokumentima i općim smjernicama koncepta cjeloživotnog učenja

Regresijski model u kojem su se odabrani prediktori također pokazali značajnima je u varijanci uvjerenja nastavnika o socijalnim vještinama u kojem je $F (5, 348) = 2.97$ što se na razini 0.05 pokazalo statistički značajnim. Najbolji su prediktori spol ($\beta = .129^{*}$) i stečena dodatna naobrazba nastavnika ($\beta = .125^{*}$). Nastavnice su ponovno značajno afirmativnije u navedenim uvjerenjima, a pitanje napredovanja u zvanju pokazalo kao nešto slabiji prediktor. Međutim, kako analiza varijance nakon provedene faktorske analize stavova i uvjerenja nastavnika nije našla statistički značajne razlike na varijabli uvjerenja o socijalnim vještinama

s obzirom na stečenu dodatnu naobrazbu, isto ćemo sukladno nižem koeficijentu multiple determinacije *R* smatrati manje bitnim prediktorom na toj kriterijskoj varijabli.

U trećem regresijskom modelu također se pokazalo kako prediktorske varijable imaju značajan udio u varijanci uvjerenja relevantnih za socijalne oblike rada i problemsku nastavu te se pokazalo kako je od svih varijabli jedini statistički značajan prediktor inicijalno obrazovanje nastavnika. U toj se analizi pokazalo kako se nastavnici studija „ostalo“ znatno manje priklanjaju grupnim oblicima rada i problemskoj nastavi nego nastavnici sa završenim nastavničkim studijem na PMF-u te oni sa završenim Učiteljskim fakultetom.

4.4.2.2 Regresijska analiza sociodemografskih obilježja i profesionalnog profila nastavnika kao prediktorima samoprocjena nastavnika kao zavisnom varijablom

Kod samoprocjena nastavnika također je najviše utvrđenih razlika u uvjerenjima i stavovima nastavnika s obzirom na spol, inicijalno obrazovanje i radno mjesto nastavnika. Stoga je za očekivati kako nam regresijskim analizama predstoji odrediti koliki je doprinos kojih obilježja nastavnika u samoprocjenama prema faktorskoj analizi iz poglavlja 4.3.2. Nezavisne varijable (prediktori) u regresijskom modelu su: radno mjesto, spol, stečena dodatna naobrazba, inicijalno obrazovanje i godine radnog staža. Zavisne (kriterijske) varijable su samoprocjene nastavnika u: poznavanju specifičnosti učenika u nastavi matematike, stručnoj kompetenciji, socijalnoj kompetenciji, radu s učenicima sa specifičnim teškoćama te u znanjima o kurikulumu.

Tablica 4. 8: *Sažetak regresijskih analiza sa sociodemografskim podatcima i profesionalnim profilom nastavnika kao prediktorskim te sa samoprocjenama nastavnika kao kriterijskim varijablama*

	F2.1 Poznavanje specifičnosti učenika u nastavi matematike		F2.2 Stručna kompetencija		F2.3 Socijalna kompetencija		F2.4 Rad s učenicima sa specifičnim teškoćama		F2.5 Znanja o kurikulumu	
	Std. β	p	Std. β	p	Std. β	p	Std. β	p	Std. β	p
Spol	.251***	.000	-.020	.704	.203***	.000	.021	.696	.117*	.028
Godine radnog staža	.077	.182	.178**	.002	.030	.586	.072	.212	.098	.092
Inicijalno obrazovanje	-.002	.973	-.075	.181	.004	.940	-.066	.245	-.052	.358
Stečena dodatna naobrazba	-.079	.163	-.123*	.031	-.119*	.032	-.055	.333	-.137*	.018
Radno mjesto	-.040	.472	-.083	.137	-.26***	.000	-.249***	.000	-.058	.306
Regresijski model	R = 0.275 R^2 = 0.075 Pril. R^2 = 0.06 F (5, 348) = 5.78***		R = 0.258 R^2 = 0.066 Pril. R^2 = 0.05 F (5, 348) = 4.815***		R = 0.356 R^2 = 0.127 Pril. R^2 = 0.114 F (5, 348) = 9.83***		R = 0.25 R^2 = 0.062 Pril. R^2 = 0.048 F (5, 348) = 4.488**		R = 0.229 R^2 = 0.052 Pril. R^2 = 0.038 F (5, 348) = 3.73**	

**** p < 0.001, ** p < 0.01, * p < 0.05*

Provedeno je pet regresijskih analiza te se pokazalo kako regresijske jednažbe u značajnoj mjeri predviđaju zavisne varijable, a vrijednosti koeficijenata multiple determinacije ponovno su relativno niski. No, pokazalo se kako su prema udjelu varijance nešto više od prvog seta regresijskih analiza, a regresijski modeli su prema svim parametrima statistički značajni. Pet odabranih prediktorskih varijabli objašnjava 8 % varijance u poznavanju specifičnosti učenika u nastavi matematike, 7 % u varijanci stručne kompetencije, 13 % u varijanci socijalne kompetencije, 6 % varijance u radu s učenicima sa specifičnim teškoćama te 5 % varijance znanja o kurikulumu samoprocjena nastavnika.

Što se tiče poznavanja specifičnosti učenika u nastavi matematike, kao jedini značajni prediktor pokazao se spol nastavnika (β = .251***), a ranijim analizama utvrđeno je kako nastavnice imaju znatno više samoprocjene od njihovih muških kolega. U kontekstu stručne kompetencije značajni su prediktori radni staž (β = .178**) i stečena dodatna naobrazba (β = -.123*). Očito je radni staž bolji prediktor od stečene dodatne naobrazbe nastavnika, a to su i

potvrdile ranije analize u kojima iskusniji nastavnici procjenjuju svoju stručnu kompetentnost znatno višom od nastavnika koji imaju do pet godina radnog staža. Negativna vrijednost standardiziranog beta koeficijenta ne upućuje na negativnu povezanost, već je to rezultat upisivanja podataka u statističkom programu SPSS zato što su kao nominalne varijable upisani redom od jedan do tri savjetnici, mentori te potom nastavnici koji nisu napredovali u zvanju. Drugim riječima, ta se varijabla pokazala kao prediktor konzistentan s teorijskim okvirima i prethodno provedenim analizama.

Regresijski model samoprocjena nastavnika u socijalnoj kompetenciji pokazao se najznačajnijim budući da prediktori pojašnjavaju 13 % u varijanci, a regresijske jednadžbe na visokoj razini (F(5, 348) = 9.83***) statističke značajnosti predviđaju zavisne varijable regresijskog modela. U tom su modelu utvrđena dva značajna prediktora od kojih je značajnija varijabla radno mjesto (β = .26***) nego spol koji ima nešto manji udio u varijanci socijalne kompetencije (β = .203***). Ranijim analizama utvrđeno je kako nastavnice procjenjuju svoju socijalnu kompetenciju višom od nastavnika te kako nastavnici koji rade u osnovnim školama istu procjenuju višom od nastavnika koji rade u srednjim školama. Međutim, te se dvije kategorije uvelike podudaraju zbog feminizacije nastavničke struke koja je najviše izražena u osnovnim školama, no prema standardiranoj vrijednosti beta koeficijenta na prediktorskoj varijabli radnog mjesta ipak se pokazuje kako iskustvo rada u osnovnoj školi više doprinosi samoprocjeni socijalne kompetencije nego spol nastavnika.

U četvrtom regresijskom modelu, u kojem su se određivali prediktori samoprocjena nastavnika u radu s učenicima sa specifičnim teškoćama, pokazalo se kako je jedini i prilično značajan (β = .249***) prediktor radno mjesto nastavnika što je potvrđeno i u ranijim analizama u kojima se pokazalo kako nastavnici u osnovnim školama procjenuju svoju osposobljenost višom od nastavnika srednjih škola. To je ranije utvrđeno analizom tvrdnje 2.14, koja se odnosi na prepoznavanje učenika s diskalkulijom, u kojoj nastavnici osnovnih škola procjenjuju sposobnost detekcije diskalkulične djece znatno višom od nastavnika srednjih škola.

U petom regresijskom modelu, u kojem su se ispitivale prediktorske varijable samoprocjena nastavnika u znanjima o kurikulumu, utvrđeno je kako je regresijski model statistički značajan što je i potvrđeno dvjema varijablama koje su se izdvojile kao prediktori. Dakle, utvrđeno je kako spol (β = .117*) i stečena dodatna naobrazba (β = .137*) imaju najveći udio u varijanci samoprocjena nastavnika u znanjima o kurikulumu te je utvrđeno kako je stečena dodatna naobrazba bolji prediktor.

4.4.2.3 Regresijska analiza sociodemografskih obilježja i profesionalnog profila nastavnika kao prediktora učestalosti nastavnih i izvannastavnih aktivnosti nastavnika kao zavisnom varijablom

Nakon faktorske analize ljestvice učestalosti nastavnih i izvannastavnih aktivnosti nastavnika, utvrđene razlike među ispitanicima primarno su utvrđene s obzirom na spol, radno mjesto te stečenu dodatnu naobrazbu nastavnika koja se jedino na ovoj ljestvici pokazala kao potencijalni prediktor. Nezavisne varijable (prediktori) u regresijskom modelu, kao i u prethodnim poglavljima, su: radno mjesto, spol, stečena dodatna naobrazba, inicijalno obrazovanje i godine radnog staža. S druge strane, zavisne (kriterijske) varijable nastavne i izvannastavne prakse nastavnika u sljedećim su dimenzijama: nastava usmjerena na učenika, metakognitivna dimenzija, potpora učenicima, refleksivna dimenzija te stručno usavršavanje u projektima i akcijskim istraživanjima.

Tablica 4. 9: *Sažetak regresijskih analiza sa sociodemografskim podatcima i profesionalnim profilom nastavnika kao prediktorskim te s učestalošću nastavnih i izvannastavnih praksi kao kriterijskim varijablama*

	F3.1 Nastava usmjerena na učenika		F3.2 Metakognitivna dimenzija		F3.4 Potpora učenicima		F3.5 Profesionalni razvoj		F3.6 Refleksivna dimenzija		F3.7 Stručno usavršavanje u projektima i akcijskim istraživanjima	
	Std. β	p	Std. β	p	Std. β	p	Std. β	p	Std. β	p	Std. β	p
Spol	.212***	.000	.199**	.000	.286***	.000	.144**	.006	.130*	.016	.174**	.001
Godine radnog staža	-.031	.567	-.050	.389	-.060	.287	.002	.974	.093	.110	.141*	.015
Inicijalno obrazovanje	.005	.928	-.004	.936	.032	.559	.020*	.720	.017	.759	-.102	.070
Stečena dodatna naobrazba	-.152**	.004	-.199**	.001	-.094	.093	-.231***	.000	-.093	.108	-.081	.153
Radno mjesto	-.36***	.000	-.056	.318	-.107	.051	-.037	.506	-.082	.149	-.095	.090
Regresijski model	R = 0.448 R^2 = 0.20 Pril. R^2 = 0.19 F (5, 348) = 16.95***		R = 0.273 R^2 = 0.075 Pril. R^2 = 0.061 F (5, 348) = 5.463***		R = 0.323 R^2 = 0.104 Pril. R^2 = 0.091 F (5, 348) = 7.884***		R = 0.272 R^2 = 0.074 Pril. R^2 = 0.060 F (5, 348) = 5.380**		R = 0.216 R^2 = 0.046 Pril. R^2 = 0.032 F (5, 348) = 3.295**		R = 0.266 R^2 = 0.071 Pril. R^2 = 0.057 F (5, 348) = 5.145***	

**** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$*

U tablici 4.9 prikazano je sedam regresijskih analiza te se pokazalo kako regresijske jednažbe u značajnoj mjeri predviđaju zavisne varijable, a regresijski modeli prema svim parametrima statistički su značajni. To znači da postavljeni modeli imaju značajan udio u varijanci odgovora na danim zavisnim varijablama, a vrijednosti koeficijenata multiple determinacije na nekim su kriterijskim varijablama znatno viši nego što su bili u prethodnim analizama. Pet odabranih prediktorskih varijabli objašnjava 20 % varijance u nastavi usmjerenoj na učenika, 8 % u metakognitivnoj dimenziji rada nastavnika, 10 % u varijanci potpore učenicima, 7 % varijance u profesionalnom razvoju, 5 % u refleksivnoj praksi nastavnika te 7 % u stručnom usavršavanju u projektima i akcijskim istraživanjima.

. Među nastavnicima koji svoj rad prilagođavaju specifičnostima učenika, dani regresijski model najznačajnije opisuje prediktore na faktoru nastave usmjerene na učenika čime je s pet prediktorskih varijabli pojašnjeno 20 % varijance u radu nastavnika. Rezultati regresijske analize dali su tri značajna prediktora: radno mjesto (β = .36***), spol (β = .212**) i stečena dodatna naobrazba (β = .152*). Radno mjesto nastavnika očekivano se pokazalo najboljim prediktorom nastave usmjerene na učenika što je u skladu s prethodnim analizama varijance i post-hoc testovima kojima je utvrđeno da nastavnici koji rade u osnovnim školama svoj odgojno-obrazovni rad više prilagođavaju učenicima od nastavnika srednjih škola.

Kod metakognitivne dimenzije utvrđeno je kako spol i stečena dodatna naobrazba jednako (β = .199**) doprinose metakonitivnoj dimenziji rada nastavnika. Potporu učenicima znatno više pružaju nastavnice te je i u pripadnom regresijskom modelu utvrđeno kako je spol jedini i statistički značajni čimbenik (β = .286***) na ovoj zavisnoj varijabli. Profesionalni razvoj pod utjecajem je spola nastavnika, a nastavnice zato češće participiraju u različitim oblicima stručnog usavršavanja, no boljim prediktorom (β = .231***) očekivano se pokazuje stečena dodatna naobrazba koja se temelji na tom aspektu rada nastavnika.

Što se tiče refleksivnih praksi, kao jedini prediktor iz ovog modela pokazuje se spol unutar kojeg smo ranije utvrdili kako nastavnice češće evaluiraju svoj rad putem refleksivnog promišljanja i uvažvanja mišljenja učenika o njihovoj praksi. S druge strane, stručno usavršavanje u projektima mobilnosti, kolegijalnom opažanju i akcijskim istraživanjima primarno je određeno spolom nastavnika (β = .174**) te godinama radnog staža (β = .141*). U ranijim analizama već je utvrđeno kako nastavnice participiraju u navedenim aktivnostima češće nego muški nastavnici, a nastavnici koji imaju 16 i više godina radnog staža češće nego mlađi nastavnici.

4.4.2.4 Kombinirane regresijske analize sociodemografskih obilježja i profesionalnog profila nastavnika s dominantnim uvjerenjima kao prediktorskim varijablama

Dosad provedenim regresijskim analizama pokazalo se kako regresijske jednadžbe u značajnoj mjeri predviđaju uvjerenja, samoprocjene i rad nastavnika, a pripadni regresijski modeli bili su statistički značajni, s izuzetkom modela za kriterijsku varijablu uvjerenja nastavnika o matematičkim sposobnostima. Međutim, u prethodnim smo regresijskim analizama kao prediktore fiksirali sociodemografska obilježja i profesionalni profil nastavnika, a time smo

odredili u kojoj mjeri isti doprinose istraživačkim pitanjima ovog rada. No, zbog nedostatno uvjerljivih parametrara koeficijenata multiple determinacije, u regresijskim modelima izvjesna je vjerojatnost kako postoje neki drugi konstrukti i/ili čimbenici koji bolje određuju i pojašnjavaju problem istraživanja.

Naime, iako su regresijski modeli prema statističkoj značajnosti F-distribucije bili značajni u prediktivnim parametrima istraživačkog upitnika, za očekivati je kako ćemo uključivanjem dominantnih uvjerenja i samoprocjena nastavnika u dotične modele steći jasniji uvid u povezanosti i potencijalne uzročno-posljedične odnose zato što su postavljeni modeli na promatranim zavisnim varijablama imali nešto manji udio u varijanci odgovora od željenog. To potvrđuju koeficijenti multiple determinacije koji su dosegli maksimalnih 20 % varijance na samo jednom od 15 analiziranih modela, ostali su imali uglavnom ispod 10 % što ukazuje kako ima dosta mjesta za poboljšati regresijske modele.

Tome u prilog idu i korelacijske analize unutar svake ljestvice te naročito korelacije među ljestvicama kojima smo ispitivali povezanost uvjerenja, samoprocjena kompetentnosti i učestalosti praksi nastavnika u kojima su se, sukladno provedenim faktorskim analizama, izdvojili dominantni faktori koji vjerojatno imaju veći prediktivni potencijal nego varijable koje smo postavili kao prediktore u prvim regresijskim analizama. U prvom dijelu istraživačkog upitnika istaknula su se uvjerenja o kurikulumu te uvjerenja o socijalnim vještinama nastavnika kao potencijalni prediktori samoprocjena nastavnika i njihova rada u nastavi i izvan nje. U prvi takav regresijski model, zbog potpunog pregleda svih varijabli, uvršteni su svi prediktori iz provedenih regresijskih analiza, uključujući sve četiri dimenzije uvjerenja nastavnika koji će zajedno u ovom mješovitom regresijskom modelu biti prediktori samoprocjena kompetentnosti nastavnika u dimenzijama izdvojenim faktorskom analizom na tom dijelu istraživačkog upitnika. Time ćemo jasnije razabrati prediktore te utvrditi u kojoj su mjeri isti prisutni u nekim obilježjima nastavnika, a koliko u ispitivanim uvjerenjima. Tako ćemo upotpuniti dosadašnje rezultate i dobiti nešto pouzdaniju osnovu/oslonac/uporište za konkretnije zaključke, implikacije istraživanja te okvire nekih budućih istraživanja.

Tablica 4. 10*: Sažetak regresijskih analiza sa sociodemografskim podatcima, profesionalnim profilom te uvjerenjima nastavnika kao prediktorima samoprocjena kompetencija nastavnika*

	F2.1 Poznavanje specifičnosti učenika u nastavi matematike		F2.2 Stručna kompetencija		F2.3 Socijalna kompetencija		F2.4 Rad s učenicima sa specifičnim teškoćama		F2.5 Znanja o kurikulumu	
	Std. β	p	Std. β	p	Std. β	p	Std. β	p	Std. β	p
Spol	.180***	.000	-.077	.139	.163**	.001	-.015	.771	.037	.447
Godine radnog staža	.065	.212	.140*	.014	.032	.558	.056	.339	.034	.526
Inicijalno obrazovanje	.012	.805	-.073	.184	.014	.783	-.053	.344	-.045	.375
Stečena dodatna naobrazba	-.017	.739	-.096	.086	-.082	.123	-.034	.550	-.084	.103
Radno mjesto	.027	.592	-.035	.520	-.211***	.000	-.212***	.000	.014	.780
Stavovi i uvjerenja o kurikulumu	.193***	.000	.215***	.000	.125*	.023	.181**	.002	.44***	.000
Uvjerenja o socijalnim vještinama nastavnika	.352***	.000	.110*	.047	.196***	.000	.034	.544	.120*	.020
Uvjerenja i stavovi o metodičkom oblikovanju nastave	.018	.715	-.062	.255	.083	.113	.063	.256	-.077	.126
Uvjerenja o matematičkim sposobnostima	-.020	.679	-.118*	.023	.078	.112	-.013	.806	-.018	.699
Regresijski model	R = 0.528 R^2 = 0.279 Pril. R^2 = 0.259 F (9, 348) = 16.175***		R = 0.375 R^2 = 0.140 Pril. R^2 = 0.117 F (9, 348) = 6.801***		R = 0.464 R^2 = 0.215 Pril. R^2 = 0.194 F (9, 348) = 10.173***		R = 0.328 R^2 = 0.108 Pril. R^2 = 0.084 F (9, 348) = 4.476***		R = 0.509 R^2 = 0.259 Pril. R^2 = 0.239 F (9, 348) = 12.981***	

**** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$*

U tablici 4.10 prikazano je pet regresijskih analiza sa samoprocjenama nastavnika kao kriterijskim varijablama kojima je ustanovljeno kako regresijske jednadžbe u značajnoj mjeri predviđaju zavisne varijable. Regresijski modeli, prema očekivanjima ovih nadopunjenih modela i prema svim relevantnim parametrima, statistički su značajni te imaju značajno jače i

pouzdanije prediktivne varijable od onih na prethodnim analizama.

Devet prediktorskih varijabli objašnjava 28 % varijance u samoprocjenama nastavnika u poznavanju specifičnosti učenika u nastavi matematike. Očito je kako smo dodavanjem uvjerenja nastavnika kao prediktora dobili znatno pouzdaniji regresijski model koji ima visoke razine statističke značajnosti (F(9, 348) = 16.175***) te nekoliko prediktora koji značajno doprinose udjelu varijance. U prvim regresijskim analizama kao najbolji prediktor izdvojio se spol nastavnika koji je ovdje značajan, no korelacijskom analizom u poglavlju 4.4.1.1 pokazalo se kako su uvjerenja nastavnika o kurikulumu (r = 0.35) i socijalnim vještinama (r = 0.44) nastavnika značajno povezana sa samoprocjenama nastavnika u poznavanju specifičnosti učenika u natavi matematike. Rezultati regresijske analize dali su tri značajna prediktora: spol (β = .18***), stavovi i uvjerenja o kurikulumu (β = .19**), uvjerenja o socijalnim vještinama (β = .35*). Dakle, uvjerenja o socijalnim vještinama nastavnika najbolji su prediktor samoprocjena nastavnika u poznavanju specifičnosti učenika u nastavi matematike.

U drugoj regresijskoj analizi prediktorske varijable objašnjavaju 14 % varijance u samoprocjenama nastavnika u stručnoj kompetentnosti. Ovaj regresijski model ima visoke razine statističke značajnosti (F(9, 348) = 6.801***) te čak četiri prediktora koji značajno doprinose udjelu varijance. U faktorskoj analizi ljestvice samoprocjena nastavnika utvrđeno je kako su razlike u samoprocjenama stručne kompetencije najistaknutije s obzirom na radni staž nastavnika zato što se iskusniji nastavnici procjenuju znatno kompetentnijima od mlađih nastavnika koji imaju do pet godina radnog staža. Prediktori utvrđeni ovom analizom i pripadajući standardizirani beta koeficijenti su: radni staž (β = .14*), stavovi i uvjerenja o kurikulumu (β = .22***), uvjerenja o socijalnim vještinama (β = .11*) i uvjerenja o matematičkim sposobnostima (β = -.12*). Uvjerenja o socijalnim vještinama nešto su slabiji prediktor percepcije vlastite stručne kompetencije, a uvjerenja o matematičkim sposobnostima učenika prediktor su s negativnim predznakom što znači da nastavnici koji imaju optimističniji stav prema učenicima i njihovim sposobnostima imaju nešto nižu procjenu vlastite stručne kompetencije. Najistaknutiji prediktor su utvrđena uvjerenja i stavovi o kurikulumu kojima se pokazuje kako nastavnici koji smatraju kurikulumske odrednice suvremenog obrazovanja bitnim višim ocjenuju svoju stručnost u matematici.

Treća regresijska analiza odnosi se na samoprocjene nastavnika u socijalnoj kompetenciji, a prediktorske varijable objašnjavaju 22 % varijance u odgovorima ispitanika na tom faktoru. Ovaj regresijski model također ima visoke razine statističke značajnosti (F(9, 348) = 10.173***) te četiri prediktora koji dominantno utječu na varijancu utvrđenu u tim

samoprocjenama. Prediktori utvrđeni ovom analizom su: spol (β = .163**), radno mjesto (β = .21***), uvjerenja o socijalnim vještinama (β = .196***) i stavovi i uvjerenja o kurikulumu (β = -.125*). Radno mjesto najbolji je prediktor samoprocjene socijalne kompetencije nastavnika što samo potvrđuje ranije utvrđene razlike između nastavnika koji rade u osnovnim školama i ostalih nastavnika koji se osjećaju znatno manje kompetentni u socijalnoj sferi svog rada u nastavi. Iako je bilo očekivano kako će uvjerenja o socijalnim vještinama biti najbolji prediktor, ipak se pokazalo da su prema udjelu varijance na tom faktoru odmah poslije radnog mjesta, ali zato objašnjavaju više varijance od varijable spola na kojoj su dosadašnjim analizama utvrđene brojne značajne razlike.

U četvrtoj regresijskoj analizi ispitivali su se potencijalni prediktori u samoprocjenama nastavnika u radu s učenicima sa specifičnim teškoćama u učenju matematike. Regresijski model objašnjava 11 % varijance u odgovorima ispitanika. Utvrđena su dva statistički značajna prediktora samoprocjena nastavnika na tom faktoru. Prediktori utvrđeni ovom analizom su: radno mjesto (β = .21***) te stavovi i uvjerenja o kurikulumu (β = -.18*). Radno mjesto istaknutiji je prediktor i na ovom faktoru što je također u skladu s prethodnim analizama u ovoj dimenziji samporocjena nastavnika unutar kojih se pokazalo kako nastavnici koji rade u osnovnim školama imaju više iskustva u individualizaciji i različitim prilagodbama rada prema specifičnostima učenika. U petoj regresijskoj analizi ispitivali su se potencijalni prediktori u samoprocjenama nastavnika u znanjima o kurikulumu. Regresijski model objašnjava relativno visokih 26 % varijance, a očekivanim se, kao statistički značajan prediktor, pokazao sklop uvjerenja o kurikulumu što se odnosi na isti konstrukt, samo u kontekstu uvjerenja o važnosti istih. Pokazalo se kako su uvjerenja o socijalnim vještinama također značajna, no isto je na razini $p < 0.05$ te je zanemarivo spram uvjerenja o kurikulumu, uvažavajući vrijednosti standardiziranog beta koeficijenta na te dvije varijable.

4.4.2.5 Kombinirane regresijske analize sociodemografskih obilježja i profesionalnog profila nastavnika s dominantnim uvjerenjima i samoprocjenama kao prediktorskim varijablama odgojno-obrazovnih dimenzija rada nastavnika

Kako bismo upotpunili dosadašnje kvantitativne analize uvjerenja, stavova, različitih procjena nastavnika i njihova profesionalnog djelovanja, preostaje nam odrediti odnos između dominantnih sociodemografskih obilježja te uvjerenja i samoprocjena s učestalosti nastavnih i izvannastavnih aktivnosti nastavnika. U posljednji regresijski model, kojim želimo saznati ključne dimenzije koje utječu na odluke koje nastavnici donose u svom odgojno-obrazovnom radu, uključit ćemo sve dominantne dimenzije iz posljednih regresijskih modela, uključujući samoprocjene nastavnika u područjima poznavanja specifičnosti učenika u nastavi matematike te u samoprocjenama stručne i socijalne kompetencije.

Time smo dobili najobuhvatniji regresijski model u kojem nezavisne varijable (prediktori) uključuju sociodemografska obilježja, profesionalni profil nastavnika te glavne dimenzije izdvojene iz uvjerenja, stavova i samoprocjena nastavnika. Time smo odabrali ukupno desest prediktorskih varijabli kojima ćemo pokušati pobliže opisati praksu nastavnika. Zavisne (kriterijske) varijable su nastavne i izvannastavne prakse nastavnika u sljedećim dimenzijama: nastava usmjerena na učenika, metakognitivna dimenzija, socijalni oblici rada, potpora učenicima, refleksivna dimenzija, profesionalni razvoj te stručno usavršavanje u projektima i akcijskim istraživanjima. Korelacijskom analizom u poglavlju 4.4.1.2 utvrđeno je kako nastavnici koji smatraju bitnim razumijevanje općih i specifičnih ciljeva kurikuluma te smjernica koncepta cjeloživotnog učenja češće prilagođavaju nastavu specifičnostima učenika, pohađaju stručno-metodičke skupove, koriste IKT u nastavi, prate znanstvene inovacije u matematici te češće evaluiraju svoju praksu. Isto tako su se izdvojila uvjerenja o socijalnim vještinama nastavnika koja su, među ostalim, najviše povezana s metakognitivnom dimenzijom te s nastavom usmjerenom na učenika, uključujući različite oblike potpore učenicima. U poglavlju 4.4.1.3 ustanovljene su relativno visoke korelacije između svih dimenzija samoprocjena nastavnika i njihove odgojno-obrazovne prakse pa se regresijska analiza pokazuje nužnom kako bismo razjasnili/utvrdili što utječe na praksu nastavnika, njihove metode, težnju za usavršavanjem te opći pristup nastavi i učenicima.

Kako su utvrđene brojne korelacije koje impliciraju povezanost između raznih uvjerenja, samoprocjena i djelovanja nastavnika, potrebno je odrediti u kojoj mjeri, koji faktori ili pak osobne značajke nastavnika utječu i/ili posreduju u utvrđenim odnosima te možemo li naći dominantna obilježja i čimbenike kao potencijalne prediktore utvrđenih relacija.

Tablica 4. 11: *Sažetak regresijskih analiza sa sociodemografskim podatcima, profesionalnim profilom te uvjerenjima i samoprocjenama nastavnika kao prediktorima nastavnih i izvannastavnih praksi nastavnika*

	F3.1 Nastava usmjerena na učenika		F3.2 Metakognitivna dimenzija		F3.4 Potpora učenicima		F3.5 Profesionalni razvoj		F3.6 Refleksivna dimenzija		F3.7 Stručno usavršavanje u projektima i akcijskim istraživanjima	
	Std. β	p	Std. β	p	Std. β	p	Std. β	p	Std. β	p	Std. β	p
Spol	.105*	.020	.075	.112	.168**	.001	.066	.181	.027	.597	.126	.015
Godine radnog staža	-.089	.064	-.091	.069	-.117*	.023	-.088	.093	.028	.610	.083	.133
Inicijalno obrazovanje	.026	.574	.005	.919	.043	.384	.048	.336	.032	.547	-.075	.154
Stečena dodatna naobrazba	-.084	.074	-.126*	.011	-.037	.462	-.163	.002	-.049	.365	-.022	.677
Radno mjesto	.272***	.000	.009	.853	-.051	.313	.053	.305	-.026	.626	-.020	.714
Stavovi i uvjerenja o kurikulumu	.210***	.000	.078	.121	.118*	.023	.27***	.000	.26***	.000	.009	.869
Uvjerenja o socijalnim vještinama nastavnika	.093	.059	.22***	.000	.030	.563	-.045	.404	-.041	.474	.019	.739
Poznavanje specifičnosti učenika u nastavi matematike	.158**	.004	.31***	.000	.34***	.000	.082	.175	.24***	.000	.056	.376
Stručna kompetencija	.091	.054	.095	.056	.083	.103	.22***	.000	.066	.223	.27***	.000
Socijalna kompetencija	.136**	.007	.031	.551	.054	.317	.136*	.015	.030	.602	.176**	.003
Regresijski model	R = 0.448 R^2 = 0.20 Pril. R^2 = 0.19 F (10, 348) = 16.95***		R = 0.584 R^2 = 0.341 Pril. R^2 = 0.322 F (10, 348) = 17.259***		R = 0.559 R^2 = 0.313 Pril. R^2 = 0.292 F (10, 348) = 15.141***		R = 0.526 R^2 = 0.277 Pril. R^2 = 0.255 F (10, 348) = 12.734***		R = 0.459 R^2 = 0.21 Pril. R^2 = 0.187 F (10, 348) = 8.876***		R = 0.453 R^2 = 0.205 Pril. R^2 = 0.181 F (10, 348) = 8.599***	

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

U tablici 4.11 prikazano je šest regresijskih analiza s učestalošću nastavnih i izvannastavnih praksi nastavnika kao kriterijskim varijablama. Iz seta kriterijskih varijabli izuzeta je varijabla koja se odnosi na socijalne oblike rada budući da ista nema konzistenntnu strukturu ni mogućnost tumačenja u zbirnom razmatranju pojedinačnih tvrdnji. Regresijske jednažbe prilično pouzdano predviđaju zavisne varijable što potvrđuju regresijski modeli koji su na najvišim razinama statističke značajnosti u dosad provedenim analizama. Koeficijenti multiple determinacije na sedam promatranih kriterijskih varijabli ukazuju na udjele u varijanci koji se kreću između 20 % i 35 % što potvrđuje kako su dani modeli prilično kompletni te prikladni za razumijevanje pozadinskih koncepata odgojno-obrazovne prakse nastavnika.

Na prvom faktoru, koji se odnosi na nastavu usmjerenu na učenika, set prediktorskih varijabli pojašnjava 20 % u varijanci odgovora te je utvrđeno čak pet statistički značajnih prediktora u radu nastavnika. Prediktori i standaridizirani beta koeficijenti utvrđeni ovom analizom redom su: spol (β = .105*), radno mjesto (β = .272***), stavovi i uvjerenja o kurikulumu (β = .210***), samoprocjene u poznavanju specifičnosti učenika u nastavi matematike (β = .158**) te samoprocjene socijalne kompetencije (β = .136**). Dakle, radno mjesto najistaknutiji je prediktor dimenzije rada nastavnika koje se odnose na koncept nastave usmjerene na učenika. Prethodnim analizama varijance i post-hoc testovima također su utvrđene prilično značajne razlike između nastavnika na tom faktoru. Te analize pokazale su da nastavnici koji rade u osnovnim školama češće pomažu učenicima koji sporije usvajaju sadržaje, povezuju zadatke sa svakodnevicom, pomažu učenicima koji imaju negativne stavove prema učenju matematike nego što to rade nastavnici srednjih škola,

U drugoj regresijskoj analizi postavljene nezavisne varijable pojašnjavaju čak 34 % varijance u učestalosti različitih praksi i postupaka nastavnika u sferi metakognitivne dimenzije rada nastavnika. Ovaj regresijski model izvrsno opisuje postupke nastavnika u kontekstu navedenog faktora za koji je jednosmjerna analiza varijance za deset prediktora pokazala najvišu razinu statističke značajnosti regresijskog modela ($F(10, 348) = 6.801$, $p < 0.001$) te tri prediktora koji ponajviše utječu na rad nastavnika u kontekstu promatrane zavisne varijable. Koeficijenti multiple determinacije također su na visokim razinama te su se značajnim pokazali u tri varijable: stečena dodatna naobrazba (β = .126*), uvjerenja o socijalnim vještinama nastavnika (β = .212***) te samoprocjene u poznavanju specifičnosti učenika u nastavi matematike (β = .313***). Dakle, metakognitivne dimenzije rada nastavnika najviše su povezane sa samoprocjenama nastavnika u poznavanju specifičnosti učenika u nastavi matematike. Ti su rezultatati očekivani zato što su to dvije komplementarne dimenzije istog

konstrukta u kojima realizacija vještina ima kao pretpostavku za to relevantna znanja, a za realizaciju istih jedina je preostala premisa voljni faktor nastavnika. Drugi faktor, koji svojim udjelom u varijanci najviše doprinosi metakognitivnim praksama nastavnika, su uvjerenja o socijalnim vještinama koje bi trebao posjedovati nastavnik matematike. To se odnosi na sklop uvjerenja iz prvog dijela istraživačkog upitnika koji samo potvrđuje kako su uvjerenja nastavnika konzistentna s njihovom praksom kao i sa samoprocjenama stručnosti u navedenim aspektima njihova rada.

Na zavisnoj varijabli koja se odnosila na potporu učenicima u nastavi prediktorske varijable pojašnjavaju 31 % varijance te se pokazuje kako je taj regresijski model prema provedenoj ANOVI i koeficijentima multiple determinacije drugi najznačajniji po pouzdanosti prediktorskih varijabli u danom regresijskom modelu ($F(10, 348) = 15.141$, $p < 0.001$). Značajniji prediktori i standaridizirani beta koeficijenti u ovom modelu su: spol ($\beta = .168^{**}$), godine radnog staža ($\beta = -.117^{*}$), stavovi i uvjerenja o kurikulumu ($\beta = .118^{*}$) te, kao najznačajnije, samoprocjene u poznavanju specifičnosti učenika u nastavi matematike ($\beta = .341^{***}$). Dakle, radno mjesto najistaknutiji je prediktor dimenzije rada nastavnika koji se odnosi na koncept nastave usmjerene na učenika. Iz rezultata je vidljivo kako su stavovi i uvjerenja o kurikulumu nešto slabiji prediktor među istaknutim varijablama koje su statistički značajne za ovaj regresijski model u kojem se spol pokazuje nešto značajnijim, a samoprocjene u poznavanju specifičnosti učenika u nastavi matematike dominantni su čimbenik i najbolji prediktor u ovom regresijskom modelu. Vrijedi istaknuti kako su godine radnog staža negativno povezane s metodama nastavnika u sferi potpore učenicima, tj. mlađi nastavnici skloniji su isticati važnost upornosti i radnih navika u učenju matematike te češće u svom radu potiču stavove prema učenju kod manje uspješnih učenika te vjeruju i ističu kako svaki učenik može biti uspješan u matematici.

U četvrtoj regresijskoj analizi postavljenim smo modelom tražili potencijalne prediktore profesionalnog razvoja i usavršavanja nastavnika kroz pohađanje stručno-metodičkih skupova, korištenje IKT-a te kroz praćenje znanstvenih inovacija u matematici. Ovaj regresijski model ima visoke razine statističke značajnosti ($F(10, 348) = 12.734^{***}$) te četiri prediktora koji značajno doprinose udjelu varijance. Najznačajniji prediktori su: stečena dodatna naobrazba ($\beta = .163^{**}$), stavovi i uvjerenja o kurikulumu ($\beta = .269^{***}$), samoprocjene u stručnoj kompetenciji ($\beta = .224^{***}$) te samoprocjene u socijalnoj kompetenciji ($\beta = .136^{*}$). Dominantni faktor u ovom regresijskom modelu su stavovi i uvjerenja o kurikulumu što znači da se nastavnici, koji smatraju smjernice koncepta cjeloživotnog učenja i ciljeve Nacionalnog

okvirnog kurikuluma bitnim, češće usavršavaju u navedenim oblicima profesionalnog razvoja. Među samoprocjenama nastavnika, svojim udjelom u varijanci odgovora najviše se ističu samoprocjene nastavnika u stručnoj kompetenciji. Od istaknutih varijabli stečena dodatna naobrazba nastavnika jedini je prediktor među početnim varijablama iz skupa sociodemografskih obilježja i profesionalnog profila nastavnika.

Peta regresijska analiza odnosila se na faktor refleksivne dimenzije rada nastavnika u kojoj set prediktorskih varijabli pojašnjava značajnih 20 % u varijanci odgovora koji su ponajviše određeni s dva statistički značajna prediktora, a koji s ostalim prediktorima također čine stabilan i statistički značajan regresijski model ($F(10, 348) = 8.876$, $p < 0.001$). Jedan je prediktor iz skupine uvjerenja nastavnika i odnosi se na uvjerenja o kurikulumu ($\beta = .256^{***}$), a drugi je iz skupine samoprocjena nastavnika te je ponovno izdvojeno poznavanje specifičnosti učenika u nastavi matematike ($\beta = .235^{***}$).

U zadnjem setu regresijskih analiza na faktoru stručnog usavršavanja u projektima mobilnosti, kolegijalnog opažanja i akcijskim istraživanjima, odabrane prediktorske varijable imaju udio od 21 % u varijanci na promatranoj zavisnoj varijabli te čine statistički značajan regresijski model ($F(10, 348) = 8.599$, $p < 0.001$) s tri statistički značajna prediktora. Prvi je prediktor spol nastavnika ($\beta = .126^{*}$), a ranije su analize pokazale kako nastavnice češće sudjeluju u navedenim oblicima stručnog usavršavanja. No, značajnijim prediktorima pokazale su se samoprocjene nastavnika u sferi socijalne ($\beta = .176^{**}$) i stručne ($\beta = .273^{***}$) kompetencije nastavnika. Dakle, nastavnici koji se procjenjuju kompetentnijima u području stručne kompetencije najčešće sudjeluju u navedenim oblicima usavršavanja.

5. ZAVRŠNA RAZMATRANJA I OSVRT NA REZULTATE ISTRAŽIVANJA

5.1 Verifikacija istraživačkih hipoteza

Temeljem obrade podataka i analize rezultata postavljenog istraživačkog problema i hipoteza istraživanja, dobiveni rezultati u nastavku će se evaluirati i prikazati redom prema hipotezama navedenim u poglavlju 3.3.2.

Opće hipoteze (sociodemografska obilježja i profesionalni profil nastavnika):

H1.1: Postoje razlike u sklopu uvjerenja, samoprocjenama nastavnika i učestalosti nastavnih i izvannastavnih praksi nastavnika s obzirom na spol

Hipoteza H1.1 potvrđena je u najviše aspekata uvjerenja, samoprocjena i nastavnih praksi naših nastavnika. Tako nastavnice smatraju više korisnim korištenje didaktičkih materijala i pomagala u svrhu unaprjeđenja kvalitete procesa učenja i poučavanja matematike pa pritom češće ostvaruju korelaciju matematike s ostalim predmetima i disciplinama te se pri planiranju nastavnog procesa više vode smjernicama Nacionalnog okvirnog kurikuluma. S druge strane, nastavnice su sklonije tradicionalnom poimanju pitanja sposobnosti i darovitosti za matematiku te su nešto manje optimistične u kontekstu uspješnosti u matematici od strane učenika prosječnih sposobnosti. U skladu s time, nastavnici u većoj mjeri smatraju kako učenici moraju voljeti matematiku da bi bili uspješni u njoj.

Nastavnici se procjenjuju kompetentnijima u stručnosti u matematici, no s druge strane, suprotno se pokazuje u kontekstu samoprocjena u metodama poučavanja pri čemu se manji broj nastavnika procjenjuje kompetentnim u razumijevanju prednosti i nedostataka pojedinih oblika i načina poučavanja. Što se tiče alternativnih pedagoških koncepata i njihove primjene u nastavi matematike, jedna od dvije trećine nastavnica procjenjuje kako su upoznate s alternativnim pedagoškim konceptima, a to isto je potvrdilo upola manje nastavnika.

U brojnim razlikama utvrđenim jednosmjernom analizom varijance i popratnim testovima značajnim se pokazuju razlike u spolu koje karakteriziraju znatno više opće samoprocjene nastavnica naspram nastavnika. Tako nastavnice procjenjuju kako posjeduju više znanja o interesima svojih učenika, upoznate su sa socio-kulturnim i ekonomskim statusom svojih učenika, uočavaju odnose učenika u razredu te kako oni utječu na njihovu aktivnost u nastavi matematike, razumiju prirodu i vrste specifičnih teškoća s kojima se učenici suočavaju

u nastavi matematike, svjesnije su emocija i motivacije kojom učenici pristupaju nastavi matematike, osjećaju se više spremnima za rad s darovitim učenicima, razumiju temeljne smjernice koncepta cjeloživotnog učenja te ulogu matematičkog područja u tom kontekstu, razumiju opće i specifične ciljeve te smjernice Nacionalnog okvirnog kurikuluma.

Sukladno tome, u njihovoj odgojno-obrazovnoj praksi pokazuje se kako se nastavnice u pripremi, izvedbi i evaluaciji nastavnog procesa znatno više vode dokumentima Nacionalnog okvirnog kurikuluma, češće pohađaju stručno-metodičke skupove i (među)županijska vijeća te sudjeluju u projektima mobilnosti i akcijskim istraživanjima. Također je utvrđeno da nastavnice češće evaluiraju svoj rad kroz ispitivanje mišljenja učenika putem anonimnog evaluacijskog upitnika u svrhu evaluacije i refleksije vlastita rada.

Što se tiče socijalne i emocionalne kompetencije, također se značajanim pokazalo kako nastavnice u nastavi ističu da svaki učenik može biti uspješan u matematici te važnost upornosti i radnih navika za uspjeh u matematici, češće se koriste humorom u nastavi i potiču pozitivne stavove kod manje uspješnih učenika, individualno rade s učenicima koji sporije usvajaju sadržaje. U kontekstu učestalosti nastavnih metoda u sferi metodičke kompetencije samoprocjena nastavnica također je znatno viša nego kod nastavnika te je kod nastavnica utvrđeno da češće koriste stvarne životne situacije kao polazište za učenje i poučavanje, u nastavi rješavaju problemske zadatke povezane sa svakodnevicom, objašnjavaju matematičke sadržaje, koncepte i procese jednostavnim jezikom koji učenici razumiju, prilagođavaju metode poučavanja tipičnim greškama i teškoćama učenika.

H1.2: ***Postoje razlike u sklopu uvjerenja, samoprocjenama te učestalosti nastavnih i izvannastavnih praksi nastavnika s obzirom na radni staž***

Ova je hipoteza potvrđena, ali je gotovo isključivo utvrđena između nastavnika početnika koji imaju do pet godina radnog staža što se odnosi na podhipotezu (H1.2.1).

H1.2.1: ***Postoje razlike u sklopu uvjerenja, samoprocjenama nastavnika i učestalosti nastavnih i izvannastavnih praksi nastavnika početnika i iskusnijih nastavnika.***

Većina nastavnika početnika slaže se s tvrdnjom kako bi se nastava matematike trebala više temeljiti na problemskim zadatcima nego na standardnim zadatcima, a to isto smatra značajno manji broj iskusnijih nastavnika. Očito je da utjecaj radnog iskustva mijenja percepciju nastavnika o jednom od aktualnih pitanja metodike nastave matematike. Pretpostavka je kako su iskusniji nastavnici, temeljem iskustava rada u nastavi, osvijestili važnost kumulativne

izgradnje znanja te kako je kontinuitet u radu i stjecanju znanja jedan od temeljnih preduvjeta izvrsnosti pa tako i u pogledu razvijanja vještina rješavanja problemskih zadataka. Također, nastavnici početnici vrjednijim smatraju matematički način razmišljanja nego primjenjivost matematičkih sadržaja. S navedenim se slažu i stariji nastavnici koji imaju od 16 do 29 godina radnog staža, ali u znatno manjoj mjeri. U tvrdnji 1.8 razlika se pokazala između nastavnika do pet godina radnog staža i nastavnika koji imaju 16 i više godina staža. Iskusniji nastavnici više se slažu kako je bitno da nastavnik matematike razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.

Što se tiče percepcije radnih navika i motivacije kao temeljnih preduvjeta za uspjehe u matematičkim natjecanjima, najmanje su se „optimističnima“ izjasnili nastavnici najmnogobrojnije skupine koji imaju između 16 i 29 godina radnog staža. Naime, njih se čak 46 % ne slaže ili se uopće ne slaže s tom tvrdnjom, a to isto je kod nastavnika početnika izjavilo njih 30 %. Neovisno o tome što se tu radi o učenicima koji postižu iznimna postignuća, suvremeno promišljanje o nastavi i učenicima trebalo bi biti sklonije afirmativnim odgovorima i kontinuiranom promišljanju o neotkrivenim potencijalima učenika te o poimanju izvrsnosti i preduvjetima za aktualizaciju potencijala učenika. Mlađi nastavnici očekivano su se u najvećoj mjeri složili kako komunikacija između nastavnika utječe na kvalitetu njihova rada. Naime, mlađi nastavnici u prvim godinama rada u nastavi puno uče kroz formalne i neformalne situacije njihova stručnog djelovanja te se statistički značajnim pokazala razlika između njih i nastavnika koji imaju imaju između 16 i 29 godina radnog staža. No, ohrabruje činjenica kako su u svim skupinama radnog staža relativno visoke razine slaganja.

Nastavnici koji imaju 30 i više godina radnog staža više procjenjuju da razumiju povijesnu i društvenu ulogu matematike u znanosti, kulturi, umjetnosti i tehnologiji te njezin potencijal za budućnost nego mlađi nastavnici. Isto tako, iskusniji nastavnici procjenjuju svoje kompetencije za rad s darovitim učenicima (što uključuje i pripremu istih za državna natjecanja) višima od ostalih kategorija nastavnika s obzirom na radni staž. Mlađi nastavnici rjeđe sudjeluju u akcijskim istraživanjima i rjeđe pohađaju stručno-metodičke skupove te uspješnost svog rada ne evaluiraju prema ciljevima Nacionalnog okvirnog kurikuluma kao nastavnici s više radnog staža. Pomalo neočekivanim pokazalo se kako mlađi nastavnici rjeđe prate znanstvene inovacije nego iskusniji nastavnici.

H1.3: Postoje razlike u sklopu uvjerenja, samoprocjenama nastavnika i učestalosti nastavnih i izvannastavnih praksi nastavnika s obzirom na inicijalno obrazovanje

Između nastavnika koji su završili Učiteljski fakultet i nastavnika iz kategorije ostalo koji su znatno manje suglasni s tvrdnjom kako bi se nastava matematike trebala više temeljiti na fundamentalnim znanjima nego na primjenjivosti istih. Očito je kako se nastavnici svojim iskustvom rada u osnovnim školama više priklanjaju fundamentalnim vještinama za koje pretpostavljaju kako učenici moraju bolje vježbati kako bi bili uspješniji u rješavanju problemskih zadataka. S druge strane, nastavnici koji su završili FFRI, FOOZOS i PA više su skloni suvremenim trendovima i obrazovnim diskusijama kojima se stalno ističe kako naši učenici nisu razvili kritičko mišljenje i nisu postigli razinu primjenjivosti znanja.

Višestrukim usporedbama u tvrdnji 1.5 (kojom se ispitivalo doprinosi li rad u grupi i timu stjecanju odgojnih vrijednosti učenika) nađene su značajne razlike između nastavničkog i inženjerskog smjera PMF-a te između nastavničkog smjera i nastavnika ostalih studija. Naime, većina nastavnika nastavničkog smjera PMF-a potpuno se slaže, nastavnici inženjerskog smjera ne slažu s tvrdnjom, a nastavnici ostalih studija većinski su izrazili kako se niti slažu niti ne slažu s danom tvrdnjom. Tvrdnja 1.9 specifična je zbog same percepcije matematičkih sadržaja te matematike kao znanosti u cjelosti.

H1.4: Postoje razlike u sklopu uvjerenja, samoprocjenama nastavnika i učestalosti nastavnih i izvannastavnih praksi nastavnika s obzirom na stečenu dodatnu naobrazbu i profesionalno usavršavanje.

Na prvom dijelu instrumenta, u kojem su se ispitivale dimenzije uvjerenja nastavnika, utvrđeno je kako nema razlika između nastavnika s obzirom na stečenu dodatnu naobrazbu i profesionalno usavršavanje. Nastavnici koji su stekli status savjetnika osjećaju se najkompetentnijima u naprednim matematičkim temama što je pomalo iznenađujuće zbog širine znanja s kojom dolaze mlađi nastavnici koji su nedavno završili studije. No, pokazuje se kako je tome možda razlog nesigurnost zato što pored stečenih znanja imaju svijest koliko toga ne znaju, a u kontekstu školske matematike tek će iskustvom stabilizirati i upotpuniti temelje stečenih znanja.

U dimenziji samoprocjena nastavnika rezultati su očekivano hipotezama pokazali kako nastavnici koji nisu napredovali u status mentora svoje razumijevanje matematike i njezine

povijesne i društvene uloge ne procjenjuju na toliko visokoj razini kao nastavnici mentori (tablica dolje). U tvrdnji 2.4 također se očekivanim pokazalo kako nastavnici koji nisu napredovali u zvanja znatno manje procjenjuju svoju stručnu kompetentnost u matematici nego nastavnici savjetnici i mentori. To je u skladu s tvrdnjom 2.5 kojom se također potvrdilo kako se nastavnici koji nisu napredovali u zvanju osjećaju manje kompetentnim, nego nastavnici savjetnici, za pripremu darovitih učenika za državna natjecanja, a to je dobar pokazatelj stručnih znanja koja su van okvira nastavnih planova i programa ili pak po dubini razumijevanja i primjene istih znanja. Tu je nužno istaknuti specifičnost zadataka na matematičkim natjecanjima koji su tematski iz područja koja se redovito rade u nastavnom planu i programu, no praksa pokazuje kako i učenici odličnog uspjeha u prirodoslovno-matematičkim gimnazijama nemaju prilike imati značajan rezultat na školskim i županijskim natjecanjima ukoliko se, pored redovne nastave, redovito ne pripremaju u sklopu dodatnih nastava, centara izvrsnosti i drugih oblika stjecanja znanja.

Sukladno tome, pretpostavka je kako nastavnici koji nemaju kontinuitet u rad s nadarenim učenicima vjerojatno ne mogu biti spremni na raznolikost i specifičnost zahtjeva tih zadataka kao nastavnici kojima su ti zadatci već u nekoj rutinskoj pripremi u okvirima njihove odgojno-obrazovne prakse u radu s darovitim učenicima. Nastavnici mentori procjenjuju svoje vještine u pomoći učenicima s teškoćama znatno višima od nastavnika koji nisu napredovali u struci te smatraju kako znaju ukloniti i prevenirati probleme koje imaju učenici u učenju matematike. Nastavnici mentori i savjetnici češće sudjeluju u akcijskim istraživanjima i projektima mobilnosti. Očekivanim se pokazalo kako nastavnici koji su napredovali u zvanju češće evaluiraju uspješnost svog rada prema ciljevima Nacionalnog okvirnog kurikuluma,. Što se tiče evaluacije putem anonimnog upitnika za učenike, značajna razlika pokazala se između mentora koji učestalije procjenjuju svoj rad tim putem od nastavnika koji nisu napredovali u zvanju. Iako se većina nastavnika izjasnila kako relativno često koristi informacijsko-komunikacijske tehnologije u nastavi, ipak je utvrđeno kako nastavnici mentori i savjetnici značajno češće koriste informatičko-komunikacijske tehnologije nego ostali koji nisu napredovali u zvanju. Naime, u predmetnoj nastavi matematike sadržaji su takvog karaktera da jedino u krajnje kreativnim i inovativnim primjenama ili u radu sa specifičnim sadržajima iz geometrije korištenje IKT-a može učiniti razliku.

Premda nema relevantnih istraživanja o utjecaju IKT-a na kvalitetu učenja i poučavanja nastave matematike, iz danih podataka o učestalosti, koji su bili prilagođeni za širi teorijski okvir ispitivanih područja, teško je protumačiti što je to „često“ ili „gotovo uvijek“ te jesu li

odgovori više u skladu sa suvremenim trendovima ili nastavnici matematike doista u tolikoj mjeri koriste IKT u nastavi. Naime, tri četvrtine mentora i savjetnika koristi IKT često ili gotovo uvijek, a kod ostalih nastavnika to iznosi 59 %.

Rezultati ukazuju na razlike između nastavnika savjetnika, od kojih 72 % tvrdi kako često ili uvijek prati znanstvene inovacije u matematici, i ostalih nastavnika od kojih to isto tvrdi svega 50 %, a među kojima značajan broj ne prati uopće ili rijetko. Gotovo polovica nastavnika koji nisu napredovali u zvanju svoju nastavu temelje na frontalnom obliku rada, to isto radi 40 % nastavnika mentora te 30 % nastavnika savjetnika. Sukladno tome, po pitanju rada u paru, grupi ili timu, pokazalo se da oko 50 - 60 % nastavnika mentora i savjetnika izvodi nastavu u navedenim socijalnim oblicima često ili uvijek, a to isto je kod ostalih nastavnika na razini 30 - 35 %. Nastavnici savjetnici češće koriste humor u nastavi nego nastavnici koji nisu napredovali u zvanju, a nastavnici mentori procjenjuju kako objašnjavaju matematičke sadržaje, koncepte i procese jednostavnim jezikom koji učenici razumiju.

H1.5: Postoje razlike u sklopu uvjerenja, samoprocjenama nastavnika i učestalosti nastavnih i izvannastavnih praksi nastavnika s obzirom na radno mjesto

Što se tiče uvjerenja o primjenjivost matematičkih znanja i korelacija matematičkih sadržaja, pokazalo se kako se nastavnici koji rade u osnovnoj školi više priklanjaju primjenjivosti što je nekako i više u skladu sa sadržajima i konceptima osnovnoškolske matematike, a nastavnici koji rade u gimnazijama, kao i oni sa završenim inženjerskim smjerom, ističu važnost primjenjivosti unutar matematike. Stoga nastavnici koji rade u osnovnim školama smatraju kako korelacije matematičkih sadržaja sa svakodnevnim životom podižu kvalitetu usvojenih znanja učenika. Međutim, budući da je to posljedica iskustava iz prakse, ovdje ne možemo izvući znakovite zaključke zato što su takvi stavovi i uvjerenja konzistentni sa sadržajima matematike koji s prelaskom na više stepenice obrazovanja sve češće imaju teorijski karakter, a zadatci su često nepovezivi sa stvarnim pa čak i hipotetskim situacijama iz svakodnevnog života.

Što se tiče vjerojatno najučestalijeg stereotipa u nastavi matematike, u tvrdnji 1.13 pokazalo se kako nastavnici u strukovnim školama u značajno manjoj mjeri smatraju da učenik prosječnih sposobnosti može imati ocjenu odličan u osnovnoj školi, a ta se razlika pokazala u usporedbi s nastavnicima koji rade u gimnaziji. Razlog tome vjerojatno je u samoj populaciji

koja upisuje strukovne škole, zato što gimnazije upisuju učenici odličnog općeg uspjeha i uspjeha u matematici, slijedom čega su nastavnici razvili ta uvjerenja.

Po pitanju poznavanja socio-kulturnog i ekonomskog statusa učenika, pokazala se značajna razlika jedino između nastavnika koji rade u osnovnoj školi i onih koji rade u gimnazijama. Nastavnici srednjih strukovnih škola sličnog su mišljenja kao oni u gimnazijama, ali se isto nije pokazalo statistički značajnim u međusobnim usporedbama između grupa nastavnika. Nastavnici koji rade u osnovnim školama smatraju kako je za kvalitetu nastave bitno da nastavnik ima uvjerenje kako svaki učenik može zavoljeti matematiku, za razliku od nastavnika koji rade u gimnazijama. Nastavnici osnovnih škola znatno više od nastavnika strukovnih škola smatraju bitnim da nastavnici razumiju opće i specifične ciljeve Nacionalnog okvirnog kurikuluma, koncepta cjeloživotnog učenja te odgojno-obrazovnih standarda kurikuluma matematičkog područja.

Po pitanju nastavne prakse, očekivanim se pokazalo kako su nastavnici osnovnih škola stekli više znanja o alternativnim pedagoškim konceptima. S obzirom na to kako je jedna trećina tih nastavnika završila Učiteljski fakultet gdje su nastavnici stekli više pedagoško-psiholoških i didaktičko-metodičkih znanja i vještina te kako je rad u osnovnoj školi u većoj mjeri odgojnog karaktera, pretpostavka je kako su i ostali nastavnici koji rade u osnovnim školama naučili kroz praksu prilagoditi svoj rad djeci i njihovim potrebama.

Također, specifično u kontekstu nastave matematike jest prepoznavanje diskalkulije za koju se nastavnici koji rade u osnovnim školama smatraju osposobljenima u 65 % slučajeva, što u slučaju nastavnika koji rade u srednjim strukovnim školama iznosi 46 % te u gimnazijama 42 %. Međutim, s obzirom na složenost detekcije diskalkulične djece, ovi podatci samoprocjena relativno su visoki. No, svakako je bilo očekivano u osnovnim školama zbog drugačije metodike i sadržaja koji su ponajviše usmjereni na aritmetiku pa više dolaze do izražaja vještine mentalne aritmetike koja je kod djece s diskalkulijom znatno ispod njihova stupnja općeg kognitivnog funkcioniranja. Međutim, teško je dati zaključak prepoznaju li učitelji u osnovnim školama djecu koja imaju diskalkuliju ili je razlog u prirodi sadržaja početne nastave matematike u kojoj se lakše uočavaju djeca koja nešto sporije računaju, a od kojih nije lako prepoznati distinkcije među onima koji imaju diskalkuliju i onih koji sporije računaju uslijed nepovoljnih uvjeta iz odgojno-obrazovne okoline.

Nešto više od polovice nastavnika osnovnih škola sudjeluje ponekad, često i gotovo uvijek u projektima mobilnosti, a isto je slučaj kod 30 % nastavnika strukovnih škola. Što se tiče evaluacije i refleksije nastavne prakse, utvrđena je razlika ponovno kod nastavnika strukovne škole od kojih 25 – 30 % redovito evaluiraju uspješnost svog rada prema ciljevima

Nacionalnog okvirnog kurikuluma te daju učenicima evaluacijski upitnik u svrhu poboljšanja kvalitete nastavnog procesa. S druge strane, isto čini 50 % nastavnika osnovnih škola.

Statistički značajne razlike pokazale su se i u sferi prilagodbe i pomoći učenicima koji uče sporije te imaju negativne stavove prema učenju matematike te se pokazalo kako nastavnici u osnovnim školama znatno više vremena odvajaju za učenike s teškoćama. Među istim skupinama nastavnika utvrđena je razlika u korištenju IKT-a koji je znatno više zastupljen u radu nastavnika osnovnih škola. Što se tiče područja metodičke dimenzije rada nastavnika, očekivanim se pokazalo kako nastavnici osnovnih škola dvostruko češće rade problemske zadatke, povezuju nastavu matematike sa stvarnim životnim situacijama te češće ostvaruju korelacije s drugim predmetima.

Specifične hipoteze (očekivane dimenzije kompetentnosti nastavnika iz eksplorativne faktorske analize istraživačkog upitnika)

H2.1: Očekuje se kako će faktorska analiza prvog dijela upitnika (uvjerenja nastavnika) izdvojiti specifične faktore kao što su:

- uvjerenja o stereotipima karakterističnim za nastavu matematike
- stavovi i uvjerenja o kurikulumu
- znanja o specifičnostima učenika
- indikatori socijalne kompetencije
- indikatori metodičke kompetencije.

Ova je hipoteza potvrđena, a detaljniji opis faktorske strukture bit će naveden u komentarima u sljedećoj hipotezi.

H2.1.1 Očekuje se kako će u navedenoj faktorskoj strukturi dominantni faktor biti socijalna kompetencija, odnosno kako iz tih uvjerenja možemo lakše razumjeti i pojasniti ostala uvjerenja i postupke nastavnika.

Suprotno navedenoj hipotezi, pomalo su se iznenađujuće kao dominantnim faktorom izdvojila uvjerenja o kurikulumu koji objašnjavaju 27 % varijance, a uvjerenja o socijalnim vještinama nastavnika s 13 % drugi su faktor po udjelu varijance u ostalim stavovima i uvjerenjima nastavnika. To znači da se u navedenim faktorima stavova i uvjerenja nastavnika upravo iz stavova o kurikulumu mogu lakše predvidjeti stavovi i uvjerenja u ostalim dimenzijama koje su utvrđene faktorskom analizom.

Dakle, prema rezultatima faktorske analize uvjerenja nastavnika o dominantnom faktoru, dobivena struktura u proturječju je s hipotezom te je stoga odbacujemo. Međutim, utvrđeno je kako su nastavnici na tom faktoru postigli najvišu razinu slaganja (M = 4.44) među ostalim dimenzijama uvjerenja nastavnika.

H2.2 Očekuje se kako će fakorska analiza drugog dijela upitnika (samoprocjena kompetentnosti i samoefikasnosti) izdvojiti specifične faktore kao što su:

- socijalna kompetencija i poznavanje specifičnosti učenika
- stručna kompetencija
- uvjerenja o kurikulumu
- emocionalna kompetencija.

Gornja je hipoteza potvrđena, smo što se prema zakonitostima provođenja faktorske analize i pouzdanosti dobivene strukture pokazalo kako je navedeni instrument rezultirao 5-faktorskim modelom umjesto predviđenog 4-faktorskog modela. Dobivene dimenzije su: poznavanje specifičnosti učenika u nastavi matematike, stručna kompetencija, socijalna kompetencija, rad s učenicima sa specifičnim teškoćama, znanja o kurikulumu.

H2.2.1 Očekuje se kako će u navedenoj faktorskoj strukturi dominantan faktor biti samoprocjene nastavnika u sferi stručnih (matematičkih) kompetencija.

Ova hipoteza nije potvrđena budući da se očekivalo kako će stručna kompetencija imati značajniji udio u varijanci sukladno tradicionalnom poimanju nastavnika matematike koji je stručnjak primarno u domeni supstratne struke. Ista se ipak pokazala kao drugi faktor po udjelu varijance s 11 %, a kao glavni faktor pokazale su se samoprocjene nastavnika u kontekstu poznavanja specifičnosti učenika u kontekstu nastave matematike s 28 % udjela u varijanci samoprocjena nastavnika. To potvrđuje naša polazišta i pretpostavke poznavanja specifičnosti učenika i socijalne kompetencije kao ključna uvjerenja koja su okosnica pedagoške kompetencije kao standarda kvalitete kompetencijskog profila nastavnika matematike.

H2.2.2 Očekuje se kako će u dijelu upitnika sa samoprocjena nastavnika najviše ocjene biti u sferi stručnih (matematičkih) kompetencija.

Ova hipoteza također se nije pokazala istinitom budući da su prosječne vrijednosti na faktoru poznavanja specifičnosti učenika u nastavi matematike imale više vrijednosti (M= 4.22) od

samoprocjena stručne kompetencije (M = 3.94). Međutim, radi se o vrijednostima na cijelom ispitivanom uzorku, a već je ranije utvrđeno kako u slučaju pojedinih kategorija isto ne vrijedi (npr. samoprocjene između nastavnika koji su završili Učiteljski fakultet i neki od smjerova na Prirodoslovno-matematičkom fakultetu).

H2.3 Očekuje se kako će fakorska analiza trećeg dijela upitnika (učestalost nastavnih i izvannastavnih praksi) izdvojiti specifične faktore kao što su:

- socijalna dimenzija
- metodička kompetencija
- refleksivna kompetencija
- metakognitivna kompetencija
- profesionalni razvoj.

Hipoteza je djelomično povrđena budući da su se izdvojile navedene dimenzije, no, kao i u hipotezi 2.2.1, faktorska struktura ovog dijela instrumenta rezultirala je s više dimenzija no što je očekivano, odnosno 7-faktorska struktura umjesto 5-faktorske strukture. Konačno, na instrumentu ljestvice nastavnih i izvannastavnih praksi nastavnika izdvojeno je sedam dimenzija: nastava usmjerena na učenika, metakognitivna dimenzija, metodičko strukturiranje nastave, potpora učenicima, profesionalni razvoj, refleksivna dimenzija, stručno usavršavanje u projektima i akcijskim istraživanjima.

H2.3.1 Očekuje se kako će u navedenoj faktorskoj strukturi dominantni faktori biti učestalost nastavnih i izvannastavnih praksi u području metodičke kompetencije i metakognitivnih vještina.

Najistaknutiji faktor „nastava usmjerena na učenika“ pojašnjava 29 % u varijanci odgovora nastavnika na ljestvici učestalosti nastavnih i izvannastavnih praksi, a odnosi se na različite oblike prilagodbe nastave učenicima, pojašnjavanje i obradu sadržaja na učenicima razumljiviji način i slično. Stoga zaklkjučujemo kako ova hipoteza nije potvrđena.

Navedeni faktor na neki je način komplementaran s dominantnim faktorom iz samoprocjena nastavnika koji se odnosi na poznavanje specifičnosti učenika u kontekstu nastave matematike što je s podjednakim udjelom u varijanci (28 %) samoprocjena nastavnika. Drugim riječima, razlike u samopoimanju nastavnika u vezi s prepoznavanjem specifičnosti učenika mogu biti dobar prediktor ostalih samoprocjena, a po pitanju nastavnih praksi, izdvojile

su se socijalne i metodičke kompetencije u različitim oblicima prilagodbi rada nastavnika kao potencijalni prediktor ostalih nastavnih i izvannastavnih praksi. Što se tiče konkretnih odgovora na izdvojenim faktorima nastavnih i izvannastavnih praksi nastavnika, najviše vrijednosti postignute su u dimenziji *potpore učenicima* (M = 4.46) te na *metakognitivnoj dimenziji* (M = 4.34)

Hipoteze o povezanosti uvjerenja, samoprocjena kompetentnosti i učestalosti nastavnih i izvannastavnih praksi

(povezanost dominantnih dimenzija između triju faktorskih struktura)

H3.1 ***Postoji povezanost između uvjerenja nastavnika te njihove samoprocjene kompetentnosti i samoefikasnosti.***

Hipoteza je potvrđena te su rezultati pokazali kako su najviše korelacije između najznačajnijih faktora u obje faktorske strukture analiziranih ljestvica (detaljnije u nastavku).

H3.1.1 Postoji povezanost između uvjerenja nastavnika o kurikulumu te njihovih samoprocjena kompetentnosti i samoefikasnosti.

Među istaknutim statistički značajnim korelacijama, najviše korelacije utvrđene su između stavova i uvjerenja o kurikulumu te o socijalnim vještinama nastavnika s prve ljestvice sa svim faktorima druge ljestvice koji se odnose na samoprocjene nastavnika. Stavovi i uvjerenja o kurikulum najviše koreliraju sa samoprocjenama po pitanju njihovih znanja o kurikulumu. Također se pokazalo kako su stavovi o kurikulumu iz prve ljestvice povezani redom po jačini povezanosti s poznavanjem specifičnosti učenika u nastavi matematike, sa socijalnom kompetencijom, a potom sa stručnom kompetencijom i osposobljenošću za rad s učenicima sa specifičnim teškoćama u učenju matematike.

H3.1.2 Postoji povezanost između uvjerenja nastavnika o socijalnim vještinama u nastavi te njihovih samoprocjena kompetentnosti i samoefikasnosti.

Uvjerenja o socijalnim vještinama nastavnika u prelimiranoj faktorskoj analizi ljestvice uvjerenja i stavova nastavnika bila su dominantni faktor. Međutim, reduciranjem na znatno

manju i stabilniju faktorsku strukturu ipak se pokazuju kao drugi faktor po varijanci stavova i uvjerenja nastavnika u istaknutim dimenzijama opisanih faktorima. Budući da su dio istog konstrukta, očekivano se potvrdilo kako su visoka uvjerenja o socijalnim vještinama nastavnika povezana s poznavanjem specifičnosti učenika u kontekstu nastave matematike te sa samoprocjenom vlastite kompetentnosti u socijalnim dimenzijama odgojno-obrazovnog rada. Znakovito je kako su uvjerenja o socijalnim vještinama nastavnika više povezana sa samoprocjenama u znanju o kurikulumu nego sa stručnom kompetencijom ili sa samoprocjenama za rad s učenicima sa specifičnim teškoćama u učenju matematike. Sve navedene korelacije statistički su značajne na razini 0.01, međutim, nisu sve jednako povezane te je donekle i očekivano kako samoprocjene stručne kompetencije nisu toliko snažno povezane sa socijalnim dimenzijama nastave kao što su različiti oblici pedagoških aspekata nastavnikova rada.

H3.1.3 Postoji povezanost između uvjerenja nastavnika metodičkom strukturiranju nastave te njihovih samoprocjena kompetentnosti i samoefikasnosti.

Hipoteza je donekle potvrđena te se pokazalo kako postoji statistički značajna povezanost između uvjerenja nastavnika o metodičkom strukturiranju nastave, njihovih samoprocjena u sferi socijalne kompetencije te u području rada s učenicima sa specifičnim teškoćama u učenju. Međutim, radi se o slabim povezanostima za koje je regresijskim analizama potvrđeno kako nemaju prediktivnu vrijednost.

H3.2 ***Postoji povezanost između uvjerenja nastavnika te učestalosti određenih nastavnih i izvannastavnih praksi.***

Korelacijskom analizom utvrđeno je kako između svih faktora iz obiju struktura postoje statistički značajne povezanosti, s izuzetkom korelacija na faktora uvjerenja o matematičkim sposobnostima koje jedino imaju znakovitu korelaciju s refleksivnom dimenzijom rada nastavnika, no ista je prilično slabog intenziteta te je nećemo tumačiti s obzirom na ostale korelacije koje su na višim razinama statističke značajnosti i znatno viših korelacija. Dakle, hipoteza 3.2 je potvrđena, a detaljniji pregled slijedi u podhipotezama 3.2.1, 3.2.2, 3.2.3 u nastavku.

H3.2.1 Postoji povezanost između uvjerenja nastavnika o stereotipima (matematičke sposobnosti) u nastavi matematike i učestalosti određenih nastavnih i izvannastavnih praksi.

Ova hipoteza samo je djelomično potvrđena sa slabom povezanošću između uvjerenja o stereotipima s refleksivnom dimenzijom rada nastavnika koja je statistički značajna (0.05) samo zbog veličine uzorka, ali kasnije regresijske analize nisu potvrdile prediktivnu vrijednost navedenih uvjerenja.

H3.2.2 Postoji povezanost između uvjerenja nastavnika o kurikulumu i učestalosti određenih nastavnih i izvannastavnih praksi.

Sukladno značajnoj varijanci (27 %) u prvoj faktorskoj strukturi, uvjerenja o kurikulumu visoko su povezana sa svim oblicima nastavnih i izvannastavnih praksi što znači kako su odstupanja na tom faktoru potencijalno značajni prediktor u svim dimenzijama rada nastavnika. Među njima se najviše ističe povezanost uvjerenja o kurikulumu s nastavom usmjerenom na učenika (r = 0.41) kao i s ostalim faktorima koji se odnose na potporu i prilagodbe rada nastavnika prema specifičnostima učenika. Međutim, pored povezanosti s nastavom usmjerenom na učenika, pokazalo se kako su uvjerenja o kurikulumu u visokoj korelaciji s profesionalnim razvojem (r = 0.39) te s refleksivnom dimenzijom (r = 0.37) rada nastavnika. Drugim riječima, nastavnici koji smatraju bitnim razumijevanje općih i specifičnih ciljeva kurikuluma te smjernica koncepta cjeloživotnog učenja češće pohađaju stručno-metodičke skupove, koriste IKT u nastavi, prate znanstvene inovacije u matematici te češće evaluiraju svoju praksu.

H3.2.3 Postoji povezanost između uvjerenja nastavnika o socijalnim vještinama u nastavi te učestalosti određenih nastavnih i izvannastavnih praksi.

Uvjerenja o socijalnim vještinama nastavnika najviše su povezana s metakognitivnom dimenzijom (r = 0.43), s nastavom usmjerenom na učenika (r = 0.35) te s potporom učenicima (r = 0.29). To je i očekivano s obzirom na uvjerenja o socijalnim vještinama koja se odnose na razvijenost komunikacijskih vještina nastavnika, poticanje pozitivnih i prevenciju negativnih stavova učenika prema matematici.

H3.3 Postoji povezanost između samoprocjene kompetentnosti i samoefikasnosti u nastavi matematike te učestalosti određenih nastavnih i izvannastavnih praksi.

Sukladno očekivanjima, korelacijskom analizom utvrđena je visoka povezanost između samoprocjena nastavnika te različitih dimenzija njihova rada u praksi, a s time je ova hipoteza potvrđena.

H3.3.1 Postoji povezanost između samoprocjene socijalne kompetencije i učestalosti određenih nastavnih i izvannastavnih praksi.

Samoprocjene socijalne kompetencije najviše su povezane s nastavom usmjerenom na učenika (0.41), s potporom učenicima (0.32), s metakognitivnom dimenzijom poučavanja (0.3) i gotovo podjednako povezane (0.29) s dimenzijama stručnog usavršavanja i profesionalnog razvoja.

H3.3.2 Postoji povezanost između samoprocjene stručne (matematičke) kompetencije i učestalosti određenih nastavnih i izvannastavnih praksi.

Samoprocjene stručne kompetencije nastavnika najviše su povezane s profesionalnim razvojem (0.34) i sa stručnim usavršavanjem u projektima mobilnosti, kolegijalnom opažanju i akcijskim istraživanjima (0.35).

H3.3.3 Postoji povezanost između samoprocjene u poznavanju specifičnosti učenika u nastavi matematike te učestalosti određenih nastavnih i izvannastavnih praksi.

Samoprocjene nastavnika u poznavanju specifičnosti učenika u nastavi matematike visoko koreliraju s metakognitivnim vještinama poučavanja (0.50), općenito s nastavom usmjerenom na učenika (0.41) te s potporom učenicima (0.49). Navedene samoprocjene statistički su značajno povezane ($p < 0.01$) sa svim faktorima iz ljestvice nastavnih i izvannastavnih aktivnosti nastavnika, a osim navedenih, najviše koreliraju s refleksivnom dimenzijom (0.36).

5.2 Sinteza rezultata i zaključci provedenog istraživanja

Individualne karakteristike nastavnika poput vrijednosti, uvjerenja, stavova, komunikacijskih i socijalnih vještina, metakognitivnih vještina, emocionalne kompetencije, sposobnosti mišljenja te svekolikih znanja o učenicima, nastavi, obrazovanju i sl. pretpostavka su uspješnog rada nastavnika, a time i učeničkog uspjeha. Provedenim analizama utvrđeno je kako uvjerenja nastavnika korespondiraju njihovim samoprocjenama u osjećaju efikasnosti u nastavnoj praksi što utječe na njihov pristup nastavi i učenicima. Pritom su se izdvojile brojne varijable poput radnog mjesta i spola nastavnika te brojnih uvjerenja i samoprocjena efikasnosti u obavljanju rada nastavnika. Za kraj ćemo navesti sintezu navedenih analiza i varijabli koje su se pokazale kao dominantni prediktori istraživačkih problema i cilja samog istraživanja.

Što se tiče poznavanja specifičnosti učenika u nastavi matematike, kao jedini značajni prediktor pokazao se spol nastavnika kojim se potvrdilo kako nastavnice imaju znatno više samoprocjene od njihovih muških kolega. U kontekstu stručne kompetencije značajni su prediktori radni staž i stečena dodatna naobrazba kojima iskusniji nastavnici procjenjuju svoju stručnu kompetentnost znatno višom nego nastavnici koji imaju do pet godina radnog staža. Kako je ranijim analizama već utvrđeno da nastavnice procjenjuju svoju socijalnu kompetenciju višom od nastavnika, tako i nastavnici koji rade u osnovnim školama istu procjenjuju višom od nastavnika koji rade u srednjim školama.

U varijanci samoprocjene socijalne kompetencije utvrđena su dva značajna prediktora od kojih je značajnija varijabla radno mjesto, a spol ima nešto manji udio. U radu s učenicima sa specifičnim teškoćama pokazalo se kako je jedini i prilično značajan prediktor radno mjesto nastavnika što je potvrđeno i u ranijim analizama kojima se pokazalo kako nastavnici u osnovnim školama procjenuju svoju osposobljenost za rad s učenicima s teškoćama u učenju višom nego nastavnici srednjih škola. Što se tiče prepoznavanje učenika s diskalkulijom, nastavnici osnovnih škola također procjenjuju sposobnost detekcije diskalkulične djece znatno višom nego nastavnici srednjih škola. Međutim, iako nešto više od polovice nastavnika smatra kako zna prepoznati učenika koji ima diskalkuliju, čini se kako ne razumiju opće značajke diskalkulične djece te je upitno razlikuju li učenike koji sporije računaju i zaostaju u učenju matematike od onih koji odgovaraju karakteristikama diskalkulične djece, kako ih je primarno odredio Košč (1974) i kako ih se identificira suvremenim testovima kao što su DSM testovi koncipirani od strane američke udruge psihijatara APA.

Dimenzija nastave usmjerene na učenika ima tri značajna prediktora: radno mjesto, spol i stečena dodatna naobrazba. Radno mjesto nastavnika očekivano se pokazalo najboljim

prediktorom nastave usmjerene na učenika te je utvrđeno da nastavnici koji rade u osnovnim školama svoj odgojno-obrazovni rad više prilagođavaju učenicima nego nastavnici srednjih škola. Kod metakognitivne dimenzije utvrđeno je kako spol i stečena dodatna naobrazba jednako doprinose metakognitivnoj dimenziji rada nastavnika. Potporu učenicima znatno više pružaju nastavnice te je i u pripadnom regresijskom modelu utvrđeno kako je spol jedini i statistički značajan čimbenik na ovoj zavisnoj varijabli. Profesionalni razvoj također je pod utjecajem spola nastavnika što potvrđuje činjenica kako nastavnice češće participiraju u različitim oblicima stručnog usavršavanja. No, boljim prediktorom očekivano se pokazuje stečena dodatna naobrazba koja se temelji na tom aspektu rada nastavnika. Što se tiče refleksivnih praksi nastavnika, kao jedini prediktor iz ovog modela pokazuje se spol unutar kojeg smo ranije utvrdili kako nastavnice češće evaluiraju svoj rad putem refleksivnog promišljanja i uvažavanja mišljenja učenika o njihovoj praksi. S druge strane, stručno usavršavanje u projektima mobilnosti, kolegijalnom opažanju i akcijskim istraživanjima također je određeno spolom nastavnika te godinama radnog staža. Već je ranijim analizama utvrđeno kako nastavnice češće participiraju u navedenim aktivnostima nego nastavnici, odnosno nastavnici koji imaju 16 i više godina radnog staža češće nego mlađi nastavnici. Uvjerenja o socijalnim vještinama nastavnika najbolji su prediktor samoprocjena nastavnika u poznavanju specifičnosti učenika u nastavi matematike.

U faktorskoj analizi ljestvice samoprocjena nastavnika utvrđeno je kako su razlike u samoprocjenama stručne kompetencije najistaknutije s obzirom na radni staž nastavnika zato što se iskusniji nastavnici procjenuju znatno kompetentnijima od mlađih nastavnika koji imaju do pet godina radnog staža. Uvjerenja o matematičkim sposobnostima učenika prediktor su negativnog predznaka što znači da nastavnici koji imaju optimističniji stav prema učenicima i njihovim sposobnostima potvrđuju nešto nižu procjenu vlastite stručne kompetencije, a navedeno je u ovom slučaju povezano s nastavnicima osnovnih škola koji su završili Učiteljski fakultet.

Kao najistaknutiji prediktor stručne kompetencije nastavnika pokazala su se uvjerenja o kurikulumu, a nastavnici koji smatraju kako su kurikulumske odrednice suvremenog obrazovanja važne, ocjenuju višim i svoju stručnost u matematici. Radno mjesto najbolji je prediktor samoprocjene socijalne kompetencije nastavnika, a njime su se izdvojili nastavnici koji rade u osnovnim školama. U sklopu toga, utvrđeno je kako je radno mjesto u osnovnoj školi povezano sa samoprocjenama nastavnika u radu s učenicima sa specifičnim teškoćama u učenju matematike te općenito s dimenzijom „nastave usmjerene na učenika“. Te analize pokazale su kako nastavnici koji rade u osnovnim školama češće pomažu učenicima koji sporije

usvajaju sadržaje, povezuju zadatke sa svakodnevicom, pomažu učenicima koji imaju negativne stavove prema učenju matematike nego što to rade nastavnici srednjih škola U učestalosti različitih praksi i postupaka nastavnika u sferi metakognitivne dimenzije rada nastavnika, najveća je povezanost s uvjerenjima o socijalnim vještinama nastavnika te samoprocjenama u poznavanju specifičnosti učenika u nastavi matematike koje su također visoko povezane s elementima poučavanja usmjerenim na potporu učeenicima.

Godine radnog staža negativno su povezane s metodama nastavnika u sferi potpore učenicima, tj. mlađi nastavnici skloniji su isticati važnost upornosti i radnih navika u učenju matematike, češće u svom radu potiču stavove prema učenju kod manje uspješnih učenika te vjeruju i ističu kako svaki učenik može biti uspješan u matematici. Najkompetentniijim za rad s darovitom djecom osjećaju se nastavnici koji imaju 30 i više godina radnog staža, a utvrđene su statistički značajne razlike između najiskusnijih nastavnika iz obiju skupina do 15 godina radnog staža. Stavovi i uvjerenja o kurikulumu te samoprocjene u stručnoj kompetenciji prediktori su profesionalnog razvoja i usavršavanja nastavnika kroz pohađanje stručno-metodičkih skupova.

Refleksivna dimenzija rada nastavnika ponajviše je određena poznavanjem specifičnosti učenika u nastavi matematike od strane nastavnika, a u tome su se više istakle nastavnice. Nastavnice češće sudjeluju u stručnom usavršavanju kroz projekte mobilnosti, kolegijalno opažanje i akcijska istraživanja. No, značajnijim prediktorima pokazale su se samoprocjene nastavnika u sferi stručne kompetencije nastavnika, a nastavnici koji se procjenjuju kompetentnijima u području stručne kompetencije najčešće sudjeluju u navedenim oblicima usavršavanja.

Dakle, nastavnici sebe procjenjuju kompetentnijima u stručnosti u matematici, no s druge strane, u kontekstu samoprocjene u metodičkom aspektu nastave procjenjuju se manje stručnima od nastavnica. Rezultati pokazuju kako se nastavnice u pripremi, izvedbi i evaluaciji nastavnog procesa znatno više vode dokumentima Nacionalnog okvirnog kurikuluma, češće pohađaju stručno-metodičke skupove i (među)županijska vijeća te sudjeluju u projektima mobilnosti i akcijskim istraživanjima.

Jedna od važnijih odrednica suvremenog pristupa obrazovanju nastavnika jest razina teorijskih znanja (općih i posebnih) koja prema rezultatima istraživanja ima višu razinu vrijednosti od treninga praktičnih rutina i stalnog naglašavanja potrebe za nekim neizvjesnim praktičnim sposobnostima (Mijatović, 2005). To upućuje na pristup koji ne zahtjeva nužno praktične postupke, već teorijsku podlogu koja daje određenu sigurnost u radu i legitimnost postupaka koji su znanstveno utemeljeni i svrsishodni. Ovo se, pored mnogih drugih rezultata

istraživanja, ističe u prepoznavanju diskalkulije od strane nastavnika te se zbog proturječnih rezultata pokazuje potreba za detaljnijim istraživanjima diskalkulije u nastavnoj praksi kao i nužnost edukacije nastavnika u tom području. Unatoč brojnim rezultatima kojima su utvrđene razlike između nastavnika s obzirom na njihova sociodemografska i profesionalna obilježja, odnos između kompetencija nastavnika i uspjeha učenika i dalje je jedan od najvećih izazova u istraživanjima odgoja i obrazovanja te se mora sustavno istraživati kako bi ovakva istraživanja imala pouzdaniji okvir u tumačenju rezultata. Ross i Bruce (2007) navode kako nastavnici s višim osjećajem samoefikasnosti češće rabe nove ideje, pristupe i strategije poučavanja, kako poticajno i autoritativno pristupaju rukovođenju, pomažu učenicima slabijih sposobnosti, postavljaju ostvarive ciljeve i ustrajniji su u suočavanju s učeničkim neuspjesima. No, unutar istih istraživanja isto bi trebalo biti objedinjeno metodološkim pristupima koji su puno obuhvatniji te koncipirani longitudinalnim praćenjem odnosa nastavne prakse i uspjeha učenika.

Naime, dva su bitna pitanja koja općenito nisu razjašnjena po pitanju kompetencija nastavnika:

1. Koja je veza između kompetencija nastavnika i uspjeha učenika u matematici?
2. Koji su relevantni prediktori uspjeha učenika u nastavi matematike te postoji li ikakva korelacija između kompetencija nastavnika i uspjeha učenika.

Premda se u sličnim istraživanjima polazi od pretpostavke kako se radi o stabilnim konstruktima povezanosti između uvjerenja i postupaka nastavnika, kontinuirano je prisutan problem kompetencija za koje Palekčić (2005) navodi kako ne postoji, odnosno nije izrađen empirijski pojam kompetencije, a ni empirijski provjerljivi modeli kompetencije i stupnjeva kompetencija. Nastava matematike pritom je dodatno obilježena brojnim posebnostima unutar kojih je očito da ukoliko vrijednosti, uvjerenja i znanja nastavnika nisu temeljena na poznavanju učenika i njihovih specifičnosti u nastavi matematike, tada vještine poučavanja i opći pristup nastavi ne mogu imati željenu kvalitetu i obrazovne ishode učenika. Tako kompleksnost uvjerenja nastavnika o nastavi i učenju matematike dodatno otežava navedene izazove kompetencija nastavnika. Metcalf (1995) ističe kako bi inicijalno obrazovanje nastavnika moglo biti učinkovitije za nastavnu praksu kada bi bilo usmjerenije na proces učenja i poučavanja, razvoj ispravnih i znanstveno utemeljenih uvjerenja o nastavi i učenicima kako bi se nastava više orijentirala na njihov angažman u razredu, kreativnost, motivaciju, razumijevanje sadržaja te na njihova akademska dostignuća.

Što se tiče modela stjecanja kompetencija nastavnika matematike, potrebno je razmatrati

strukturu i zastupljenost stručnih, pedagoških i didaktičko-metodičkih sadržaja u njihovoj izobrazbi. To je povezano s problematikom predmetnih didaktika i njihovom ovisnosti o odlukama obrazovne politike, ali i znanstvenim i istraživačkim potencijalima kojima trenutno raspolažemo kao i suradnjom između nastavničkih i učiteljskih studija s relevantnim društvenim znanostima u područjima gdje se razmatraju izazovi nastave matematike čiji su istraživački problemi u domenama znanosti (poput pedagogije i psihologije).

Zbog količine pedagogijskog problematiziranja koje se pokazuje nužnim u području matematičkog obrazovanja, ovo istraživanje koncipirano je i provedeno kako bismo dobili detaljniji uvid u znanja, stavove i uvjerenja nastavnika te, među ostalim, pomnije razumijevanje programske sfere učiteljskih i nastavničkih studija. U našem odgojno-obrazovnom sustavu još je uvijek izražen diskontinuitet između inicijalnog obrazovanja praktičara i zahtjeva suvremene prakse. To je naročito izraženo u nastavi matematike pa se provođenje relevantnih i za praksu korisnih istraživanja, poput ove doktorske disertacije, pokazuje kao nužnost suvremenijeg inicijalnog obrazovanja te osiguravanja pretpostavki za inovativnim obrazovnim strategijama koje će unaprijediti učinkovitost i kvalitetu cjelokupnog područja matematičkog obrazovanja.

Stalno posredujući znanje, zaboravljamo na ono poučavanje koje je najvažnije za ljudski razvoj: poučavanje koje može biti pruženo jedino pukom prisutnošću jedne zrele osobe koja nas voli. (Erich Fromm)

6. LITERATURA

- Alexander, D.; Money, J. (1966). *Turner's syndrome and Gerstmann's syndrome: neuropsychologic comparisons*. Neuropsychologica, 4, 265–273.
- Allinder, R.M. (1994). The relationship betweenefficacy and the instructional practices of specialeducation teachers and consultants. TeacherEducation and Special Education, 17, 86–95.
- American Psychiatric Association (2000). *Diagnostic and statistical manual of mental disorders. Fourth edition, Text Revision.* Washington, DC.
- Anderson, J. R. (1982). Acquisition of cognitive skill. Psychological Review, 89(4), 369-406.
- Andrews, P. and Hatch, G.: 1999, 'A new look at secondary teachers' conceptions of mathematics and its teaching', British Educational Research Journal 25(3), 203–223.
- Andrews, P., Rowland, T., Brindley , S., et al. (2014), MasterClass in Mathematics Education: International Perspectives on Teaching and Learning. Bloomsbury Academic.
- Andrilović, V. i Čudina-Obradović, M. (1996) Psihologija učenja i nastave: (psihologija odgoja i obrazovanja III). Zagreb: Školska knjiga.
- Anić, V. i Goldstein, I. (1999), Rječnik stranih riječi. Zagreb: Novi Liber.
- Anić, V. (2000), Rječnik hrvatskoga jezika. Zagreb: Novi Liber.
- Arambašić, L; Vlahović-Štetić, V; Severinac, A. (2005.) *Je li matematika bauk? Stavovi, uvjerenja i strah od matematike kod gimnazijalaca.* Društvena istraživanja, 6, 80, 1081-1102.
- Arslanagić, Š. (2011.) *Doprinos matematike razvoju osobe*. Poučak,12(47),18-25.
- Aschersleben, K. (1986). Moderner Frontabunterricht. Neuhergrundung einer umstrittener Unterrichtsmethode. Frankfurt: Lang 1985.
- Ashcraft, M.H., Kirk, E.P., Hopko, D. (1998). On the cognitive consequences of mathematics anxiety. InDonlan, C. (Ed.), The development of mathematical skills (pp. 175–196). Hove, England: Psychology Press.
- Ashcraft, M. H., Kirk, E. P. (2001). The relationships among working memory, math anxiety, and performance. *Journal of Experimental Psychology: General, 130*(2), 224–237.
- Aschraft, M. H. (2002), Math anxiety: Personal, educational, and cognitive consequences. *Current Directions in Psychological Science*, 11(5), 181-185.
- Auger, W., Wideman, R. (2000), Using Action Research to Open the Door to Life- Long Professional Learning. Education, 121 (1): 120- 127.
- Badian, N. A. (1983). Aritmetic and nonverbal learning. In Myklebust, H. R. (Ed). *Progress in learning disabilities, vol 5* (pp 235-264). New York: Grune and Stratton.

- Ball, D., Lubienski, S., Mewborn, D. (2001). Research on teaching mathematics: The unsolved problem of teachers' mathematical knowledge. In V. Richardson (Ed.), Handbook of Research on Teaching (4th ed.) (pp. 433-456). Washington, DC: American Education Research Association.
- Ball, D. L., Hill, H. C., & Bass, H. (2005). Knowing mathematics for teaching: Who knows mathe-matics well enough to teach third grade, and how can we decide?American Educator, Fall 2005,14–22.
- Ball, Deborah & Thames, Mark & Phelps, Geoffrey. (2008). Content Knowledge for Teaching What Makes It Special?. Journal of Teacher Education. 59. 10.1177/0022487108324554.
- Bandura, A. (1989), Perceived self-efficacy in the exercise of personal agency. *The Psychologist: Bulletin of the British Psychological Society*, 2, 411-424.
- Bandura, A. (1991), *Self-regulation of motivation through anticipatory and self-regulatory mechanisms*. In R. A. Dienstbier (Ed.), Perspectives on motivation: Nebraska symposium on motivation (Vol. 38, pp. 69-164). Lincoln: University of Nebraska Press.
- Barth, B.M. (2004). Razumjeti što djeca razumiju. Zagreb: Profil international.
- Bašić, S. (2007). *Obrazovni standardi- didaktički pristup metodologiji izgradnje kurikuluma.* U: Previšić, V. (ur.), Kurikulum- Teorije, metodologija, sadržaj, struktura. *Zagreb*: Zavod za pedagogiju Filozofskog fakulteta u *Zagrebu* i Školska knjiga, 117-155.
- Bell, B.(1993), I know about LiSP but how do I put it into practice? Final report of the learning in scien-ce project (teacher development). Aotearoa New Zealand: Centre for science and mathematics edu-cation research, University of Waikato Hamilton.
- Benbow, C. P., Stanley, J. C. (1980). Sex differences in mathematical ability: Fact or artifact? *Science, 210*(4475), 1262–1264. https://doi.org/10.1126/science.7434028.
- Benbow, C. P., Arjmand, O. (1990), *Predictors of High Academic Achievement in Mathematics and Science by Matematically Talented Students: A Longitudinal Study*. Journal of Educational Psychology, Vol. 83., No. 3, 430-441.
- Bezinović, P. (1988). Percepcija osobne kompetentnosti kao dimenzija samopoimanja. Neobjavljena doktorska disertacija. Zagreb: Odsjek za psihologiju Filozofskog fakulteta.
- *Bloom, B. S. (1985.). Developing talent in young people. New York, Ballantine Books.*
- Bognar, L., Matijević, M. (2002), *Didaktika,* Školska knjiga, Zagreb.
- *Bognar*,L., *Matijević*,M. (*2005*.) Didaktika (treće izmijenjeno izdanje), Školska knjiga, Zagreb.
- Bognar, L.; Dubovički, S. (2012), Emocije u nastavi. *Hrvatski časopis za odgoj i obrazovanje*. Vol. 14, No.1, 135-153.

- Boulton-Lewis, G. M., Smith, D. J. H., McCrindle, A. R., Burnett, P. C., Campbell, K. J. (2001). *Secondary teaychers conceptions of teaching and learning.* Learning and Instruction, 11, 35-51.

- Branch, R. M., & Kopcha, T. J. (2014). Instructional Design Models. In Handbook of Research on Educational Communications and Technology (pp. 77–87). http://doi.org/10.1007/978-1-4614-3185-5.

- Brekelmans, M., Levy, J., Rodriguez, R. (1993). A typology of teacher communication style. U T. Wubbels, J. Levy, (Ur.), Do you know what you look like? (str. 46-55). London: The Folmer Press.

- Brophy, J. (1986). Teacher influences on student achievement. *American Psychologist, 41*(10), 1069–1077. https://doi.org/10.1037/0003-066X.41.10.1069.

- Brown, G. T. L. (2004). Teachers‟ conceptions of assessment: implications for policy and professional development. Assessment in Education: Principles, Policy and Practice, 11(3),301–318.

- Bruner, J. S. (2000), Kultura obrazovanja. Zagreb: Educa.

- Bryan, L. A., Atwater, M. M. (2002), Teacher beliefs and cultural models: A challenge for science teacher preparation programs. *Science Education, 86, 821-839.*

- Butterworth, B. (1999). What counts: How every brain is hardwired for math. *New York: The Free Press.*

- Buchberger, F., Campos, B. P., Kallos, D., & Stephenson, J., (Eds.). (2000). Green Paper on Teacher Education in Europe: High Quality Teacher Education for High Quality Education and Training: Thematic Network on Teacher Education in Europe. Umea: Umea University.

- Buljubašić-Kuzmanović, V. (2014), *Integrirani kurikulum u funkciji razvoja pedagoških kompetencija.* Pedagogijska istraživanja, 11(1), 95-109.

- Butterworth, B. (2003). Dyscalculia screener. *London: NFER Nelson Publishing Company Ltd.*

- Cambria, J., Brandt, H, Nagengast, B., Trautwein, U. (2017), *Frame of Reference effects on values in mathematics: evidence from German secondary school students,* ZDM Mathematics Education, 49: 435-447.

- Carnine, D. W. (1997). Instructional design in mathematics for students with learning disabilities. *Journal of Learning Disabilities, 30,* 130–141

- Chan,W.D. (2011), *Beliefs, actions, and characteristics of teachers. Characheristics and Competencies of Teachers of Gifted Learners: The Hong Kong Student Perspective,* Roper Review, 33: 160-169.

- Child, D. (2006). The essentials of factor analysis. (3rd ed.). New York, NY: Continuum International Publishing Group.

- Chinn, S.J., & Ashcroft, J.R. (1998). *Mathematics/or dyslexics: A teaching handbook.* London: Whurr Publishers.
- Cindrić, M., Miljković, D., Strugar, V. (2010), Didaktika i kurikulum. Zagreb: IEP-D2.
- Chinn, S., Ashcroft, R. (2006). Mathematics for Dyslexics: Including Dyscalculia. *Wiley Publishing*.
- *Chipman, S. F., Krantz, D. H., & Silver, R.* (*1992*). Mathematics anxiety and science careers among able college women. Psychological Science, 3(5), 292–295.
- Cjelovita kurikularna reforma- Okvir nacionalnog kurikuluma. http://www.kurikulum.hr/ [Pristupano tokom prosinca 2016.]
- Cochran, W. G. (1963), *Sampling techniques, 2nd Ed.*, New York: John Wiley and Sons, Inc.
- *Conway*, J. M., & *Huffcutt*, A. I. (*2003*). A review and evaluation of exploratory *factor analysis* practices in organizational research. *Organizational Research Methods, 6*(2), 147-168.
- Correa, C. A., Perry, M., Sims, L. M., Miller, K. F., Fang, G. (2008), *Connected and culturally embedded beliefs: Chinese and US teachers talk about how their students best learn mathematics.* Teaching and Teacher Education, 24, 140-153.
- Costello, A. B. and Osborne, J. W. (2005). Best practices in exploratory factor analysis: Four recommendations for getting the most from your analysis. Practical Assessment, Research & Evaluation, 10, 1-9.
- Crosnoe, R., Monica, K.J and Glen, H.E.Jr. (2004). School size and the interpersonal side of education: An example of Race/Ethnicity and organizational context. Social Science Quarterly, 85(5
- Cvrtila, R. (1996), *Ispitivanje procjena samoefikasnosti, njihove povezanosti sa školskim uspjehom, te razlika među spolovima*. Zagreb: Odsjek za psihologiju Filozofskog fakulteta u Zagrebu.
- Cvetković-Lay; J; Sekulić-Majurec, A. (2008.) *Darovito je, što ću s njim?* Zagreb: Alinea.
- Čudina-Obradović,M.(1991.) *Nadarenost: razumijevanje, prepoznavanje, razvijanje*. Zagreb: Školska knjiga.
- Ćatić, I. (2012), *Kompetencije i kompetencijski pristup obrazovanju*. Pedagogijska istraživanja, 9 (1-2), 175-189.
- D' Ambrosio, U. (1999), Literacy, Matheracy, and Tehnoracy: A trivium for today. *Mathematical Thinking and Learning*, 1(2), 131-154.
- Darling-Hammond, L. (2000), Teacher quality and student achievement: Review of state policy evidence. EPPA, 8(1): 1-50.
- De Corte, E., Verschaffel, L. (1985), Beginning first graders initial representations of arithmetic word problems. *The Journal of Mathematical Behaviour, 4, 3-21.*

- De Lange, J. (1996). Using and applying mathematics in education. In: A.-J. Bishop, K. Clements, Ch. Keitel, J. Kilpatrick, & C. Laborde (Eds.). International handbook of mathematics education (Part 1, pp. 49-97). Dordrecht: Kluwer Academic Publishers.
- DeCoster, J. (1998). *Overview of Factor Analysis,* http://stat-help.com. *(*Pristupljeno 15. veljače 2019.)
- Delors, J. (1998). Učenje: blago u nama; Izvješće UNESCO-ovog Međunarodnog povjerenstva za razvoj obrazovanja za 21. stoljeće. Zagreb: Educa
- Dehaene, S. (1992). *Varieties of numerical abilities*. Cognition, 44, 1-42.
- Dehaene, S. (1997). The Number Sense. *Pinguin books Ltd.*
- Dehaene, S.; Cohen, L. (1997). *Cerebral pathways for calculation: double dissociation between rote verbal and quantitative knowledge of arithmetic*. Cortex, 33, 219-250.
- Dejić, M. (2002.) *Matematičke sposobnosti*. U : Gojkov-Rajić,A; Prtljaga,J.(ur.) *Daroviti i šta sa njima*, VŠOV, 101-157.
- Dellatolas, G., Von Aster, M., Willadino-Braga, L., Meier, M., Deloche, G. (2000). *Number processing and mental calculation in school children aged 7 to 10 years: a transcultural comparison.* European child & adolescent psychiatry, 9(2),S102–S110.
- Dejić, M. (2004.) *Strategije rada sa matematički nadarenim učenicima.* U : Zbornik radova sa 10. okruglog stola – *Strategije podsticanja darovitosti*, Scoala superioara pentru educatoare Varset i VŠZOV Vršac, 36-45.
- Delors, J. i sur. (1998). Učenje: blago u nama; Izvješće UNESCO-ovog Međunarodnog povjerenstva za razvoj obrazovanja za 21. stoljeće. Zagreb: Educa.
- Department for Education and Skills(DfES) (2001). *National Numeracy Strategy:*

  Guidance to support pupils with dyslexia and dyscalculia.
- Desoete, A., Roeyers, H.; De Clercq, A. (2002). Assessment of off-line metacognitive skills in young children with mathematics learning disabilities. *FOCUS. On Learning problems in mathematics, 24 (2 ,53-69.*
- Desoete, A. (2008). *Co-Morbidity in Mathematical Learning Disabilities: Rule or Exception?* The Open Rehabilitation Journal, 1(1), 15–26.
- Detterman,D.K; Daniel,M.H. (1989). *Correlations of mental tests with each other and with cognitive veriables are highest of low IQ groups*. Intelligence, 13,4,349-359.
- Devide, V. (2000), *Škola u Japanu*. Matematika i škola, Element, Zagreb.
- Devlin, K. (2000), MATEMATIČKI GEN- Zašto ga svi imaju, ali ga većina ne rabi. Algoritam, Zagreb.
- Domazet, M., Baranović, B., Matić, J. (2013), *Mathematics Competence and International Mathematics Testing: Croatian Starting Point*, Journal dor spatial and socio-cultural development studies, 51(1): 109-131.
- Domović, V. i Cindrić, I. (2008), Key competences reflected in the program for primary school teacher- education and primary foreign language teacher education. U: Cindrić,

M., Domović, V.,Matijević, M. (ur.), Pedagogy and the KnowledgeSociety. Zagreb: Učiteljski fakultet Sveučilišta u Zagrebu.

- Domović, V. (2009), Bolonjski proces i promjene u inicijalnom obrazovanju učitelja i nastavnika. U: Vizek Vidović, V. (ur.), Planiranje kurikuluma usmjerenoga na kompetencije u obrazovanju učitelja i nastavnika. Zagreb: Filozofski fakultet Sveučilišta u Zagrebu i Učiteljski fakultet Sveučilišta u Zagrebu, str. 9-17.

- Domović, V. (2011). Učiteljska profesija i profesionalni identitet učitelja, u: Vizek Vidović, V. (Ur.). Učitelji i njihovi mentori. Zagreb: Institut za društvena istraživanja.

- Europska Komisija/EACEA/Eurydice (2012), Developing Key Competences at Schools in Europe: Challenges and Opportunities for Policy. *Eurydice Report*. Luksemburg: Ured za publikacije Europske unije.

- Europska unija. (2000). Memorandum o cjeloživotnom učenju.

- Europsko Vijeće. (2006). Preporuka Europskog parlamenta i savjeta od 18. prosinca 2006. o ključnim kompetencijama za cjeloživotno učenje.

- Eurydice (2002), Key Competences. A developing concept in general compulsory education. Brussels: Eurydice European Unit. (http://promitheas.iacm.forth.gr/icurriculum/Assets/Docs/Key%20Competences%20Eurydice.pdf)

- Fennema, J., Sherman, J. (1977*), Sex-Related Differences in Mathematics Achievement, Spatial Visualization and Affective Factors.* American Educational Research Journal.

- Ferrandez-Berrueco R., Sanchez-Tarazaga, L. (2014), *Teaching Competencies in Secondary Education. Analysis of Teachers Profile.* e-Journal of Educational Research, Assesment and Evaluation. RELIECE, v. 20 (1), art.1.

- Fey, J.T. (2006), *Connecting technology and school mathematics: A review of didactical challenge of symbolic calculators: Turning a copmutional device into a mathematical instrument.* Journal for Research in Mathematics Education, 37(4): 348-352.

- Fives, H. (2003), *What is teacher efficacy and how does it relate to teachers knowledge? A theoretical review.* American Educational Research Association Annual Conference, Chicago.

- Fox, L. H. (1975) Career interests and mathematical acceleration for girls. Paper presented at annual meeting of American Psychological Association, Chicago.

- Frey, A. (2004), Die Kompetezstruktur von Studierenden des Lehrerberufs. Eine internationale Studie. Zeitschrift für Pädagogik 50 (6), 903– 925.

- Fullan, M. (2007), The New Meaning of Educational Change (4. izd.), New York / London: Teachers College Columbia University.

- Gamoran, A. (1993) Alternative uses of ability grouping in secondary schools: Can we bring high-quality instruction to low-ability classes?, American Journal of Education, 101: 1-22.
- Gardner, H. (1983.) *Frames of mind: The theory of multiple inteligences*. New York:Basic Books.
- Garmaz, J. (2005), *Sadržajni aspekti didaktike školskog vjeronauka*, Crkva u svijetu, Vol 40, 3.
- Geary, D. C., Bow-Thomas, C. C., Fan, L., Siegler, R. S. (1993), Even before formal instruction, Chinese children outperform American children in mental addition. *Cognitive Development*, 8, 517-529.
- Geary, D. C. (2004). *Mathematics and learning disabilities*. Journal of learning disabilities, 37, 4-15.
- Geist, E. (2010), *The Anti-Anxiety Curriculum: Combating Math Anxiety in the Classroom*, Journal of Instructional Psychology, 37 (1).
- George, D. (2005.) *Obrazovanje darovitih*. Zagreb: Educa.
- Gersten, R., Clark, B.; Mazzocco, M., M. (2007). *Why is Math So Hard for Some Children? The Nature and Origins of Mathematical Learning Difficulties and Disabilities.* Historical and contemporary perspectives on mathematical learning disabilities. In D. Berch, & M. M. Mazzocco (Eds.), (pp. 7-27). Baltimore, MD: Brookes Publishers.
- Giesecke, H. (1993), Uvod u pedagogiju. Educa, Zagreb.
- Ginsburg, H. P. (1997). *Mathematics learning disabilities: a view from developmental psychology.* Journal of learning disabilities, 30, 20-33.
- Gliga, L. (2002), Standarde profesionale pentru profesia didactica. Bucuresti: M.E.C.
- Goldman, S. R., & Hasselbring, T. S. (1997). Achieving meaningful mathematics literacy for students with learning disabilities. *Journal of Learning Disabilities, 30*(2), 198–208. https://doi.org/10.1177/002221949703000207
- Gross-Tsur, V., Manor, O., Shalev, R. S. (1996). *Developmental dyscalculia: prevalence and demographic features.* Developmental Medicine and Child Neurology, 38.
- Godišnje izvješće o nastavnome, znanstvenom i stručnom radu te drugim aktivnostima na Prirodoslovno-matematičkom fakultetu u akad. god. 2016./2017. (2018), Prirodoslovno-matematički fakultet Sveučilišta u Zagrebu.
- Guberina-Abramović, D. (2008).Priručnik za rad s učenicima s posebnim potrebama integriranim u razrede osnovne škole. Zagreb: Školska knjiga.
- Gudjons, H. (1994.), Pedagogija-temeljna znanja. Zagreb: Educa.
- Guskey, T. R. (1984), The influence of change in instructional effectiveness upon the affective characteristics of teachers. *American Educational Research Journal, 21, 245-259.*

- Hager. P. (1995), Competency Standards – a Help or a Hindrance? An Australian Perspective. The Vocational Aspect of Education, 47 (2), str. 141-151. (http://dx.doi.org/10.1080/0305787950470203)

- Hair, J. F., Anderson, R., Tatham, R., Black, W. (1998). *Multivariate Data Analysis*, 5th Ed., Englewood Cliff s, NJ: Prentice Hall.

- Hart L. (1989) Describing the Affective Domain: Saying What We Mean In Mc Leod, Adams (Eds.), Affect and Mathematical Problem Solving. New York: Springer Verlag

- Hasselbring, T. S., Goin, L. I., Bransford, J. D. (1988). *Developing math automaticity in learning handicapped children: The role of computerized drill and practice.* Focus on Exceptional Children, 20, 1–7.

- Hattie, J. A. C.(2009). Visible Learning: A synthesis of over 800 meta-analyses relating to achievement. London: Routledge

- Hembree, R. (1990), The nature, effect and relief of mathematics anxiety. *Journal for Research in Mathematics Education*, 21(1), 33-46.

- Hess, R. D., Chi-Mei, C., McDevitt, T. M. (1987). Cultural variations in family beliefs about children`s performance in mathematics: Comparisons among People`s Republic of China, Chinese-American, and Caucasian-American families. Journal of Educational Psychology, 79, 179-188.

- Hiebert, J., Kilpatrick, J., Lindquist, M. M. (2001), Improving U.S. doctoral programs in mathematics education. In R. Reys, J. Kilpatrick, *One field, many paths: U.S. doctoral programs in mathematics education* (pp. 153-159). Washington, DC: Conference Board of the Mathematical Sciences.

- Hopko, D. R., McNeil, D. W., Lejuez, C. W., Aschraft, M. H., Eifert, G. H., Riel, J. (2003), *The effects of anxious responding on mental and arithmetic and lexical decision task performance,* Journal of Anxiety Disorders, 17 (6), 647.

- Horvat, Z., Kolak, A. (2014), *Teaching mathematics and mathematically gifted students*, TEACHER International Journal of Education, University „St. Kliment Ohridski“ Faculty of Education, Bitola, Vol. 7, 262-271.

- Horvat, Z., (2016). *Motivacija u nastavi matematike*. Sedmi kongres nastavnika matematike Republike Hrvatske, Zagreb.

- Horvat, Z. (2018), *Problem darovitosti i obrazovanosti- distinktivnost STEM područja i implikacije na odgojno-obrazovnu praksu*. U: Vladimir Džinović, V. i Grbić, S: (ur.), *Kvalitativna istraživanja u društvenim naukama: od ličnog iskustva do socijalnih praksi*. XXIII naučna konferencija „Pedagoška istraživanja i školska praksa", zbornik radova. Filozofski fakultet Univerziteta u Beogradu.konferencija Pedagoška istraživanja i školska praksa", zbornik radova. Filozofski fakultet Univerziteta u Beogradu.

- Hrvatić, N. (2007.a), *Škola budućnosti: nove kompetencije učitelja*, Križevci: HPKZ.

- Hrvatić, N. i Piršl, E. (2007), Kurikulum pedagoške izobrazbe učitelja. U: Previšić, V. (ur.), Kurikulum: teorije, metodologija, sadržaj, struktura. Zagreb: Zavod za pedagogiju Filozofskog fakulteta Sveučilišta u Zagrebu i Školska knjiga, str. 385-412.
- Hudson, T. (1983). Correspondences and numerical difference between disjoint sets. Child Development, 54, 84-90.
- Huitt, W. (2003). A systems model of the teaching/learning process. Educational Psychology Interactive. Valdosta, GA: Valdosta State University.
- Huntsinger, C. S., Jose, P., Liaw, F. R., Ching, W. D. (1997), *Cultural Differences in Early Mathematics Learning: A Comparison of Euro-American, Chinese-American, and Taiwan-Chinese Families*. International Journal of Bihevioral Development, 21(2): 371-388.
- Ivanov, L., Penezić, Z. (2004), Burnsova skala perfekcionzma. U: A. Proroković (ur.), *Zbirka psihologijskih skala i upitnika,* 13-18, Filozofski fakultet Zadar.
- Jennrich, R. I., Bentler, P. M. (2011). Exploratory Bi-Factor Analysis. Psychometrika, 76, 537-549.
- Johnson, D.T. (2001.) *Teaching Mathematics to Gifted Students in a Mixed-Ability Classroom*. ERIC Digest.Preuzeto:21. 10. 2018. http://www.ericdigests.org/2001-1/math.html.
- Jurčić, M. (2007*), Uravnotežena kombinacija socijalnih oblika nastave u funkciji oslobađanja potencijala učenja i poučavanja. Pedagogija - prema cjeloživotnom obrazovanju i društvu znanja* / Previšić, V. i sur. (ur.). Sveta Nedelja: Kratis: Hrvatsko pedagogijsko društvo, 2007. str. 271-27.
- Jurčić, M. (2012), *Pedagoške kompetencije suvremenog učitelja,* Recedo, Zagreb.
- Jurčić, M. (2014), *Kompetentnost nastavnika – pedagoške i didaktičke dimenzije. Pedagogijska istraživanja, 11(1), 77-93.*
- Kadum,V. (2004.) *Neke paradigme za uspješnu nastavu i usmjeravanje učenja u matematici*. Metodički ogledi, 11, 2, 95-110.
- Kadum, V. (2006.), *O problemu sposobnosti i nesposobnosti za matematiku*. Metodički obzori 1, 95-101.
- Kadum, V., Vranković, K., Vidović, S. (2007), *Nastavni sadržaji, jezik i vještine, te kognitivni razvoj učenika kao činitelji matematičkog odgajanja i obrazovanja.* Metodički obzori: časopis za odgojno-obrazovnu teoriju i praksu, Vol. 2, 1(3).
- Karp, A. (2017). Some thoughts on gifted education and creativity. ZDM, 49(1), 159-168.
- Katz, L. G., Mcclelan, D. E., (1999), *Poticanje razvoja dječje socijalne kompetencije*, Educa, Zagreb.
- Kaufman, J. C., & Beghetto, R. A. (2009). Beyond big and little: The Four C Model of Creativity. Review of General Psychology, 13, 1−12.

- Kaufmann, L.; Mazzocco, M. M., Dowker, A., Von Aster, M., Göbel, S. M., Grabner, R. H., Nuerk, H.-C. (2013). *Dyscalculia from a developmental and differential perspective. Frontiers in Psychology*, 4(August).

- Kavale, K. A. and Forness, S. R. (2000). *What definitions of learning disability say and don't say*. A critical analysis. Journal of learning disabilities, *33*, 239-256.

- Keck, W. R. (1975): Zielorientierte Unterrichtsplanung. Bad Heilbrunn.

- Khalil, M. K., & Elkhider, I. A. (2016). Applying learning theories and instructional design models for effective instruction. Advances in Physiology Education, 40(2), 147–156. http://doi.org/10.1152/advan.00138.2015.

- Knowlton, D. S., & Simms, J. (2010). Computer-based instruction and generative strategies: Conceptual framework & illustrative example. Computers in Human Behavior, 26(5), 996–1003. http://doi.org/10.1016/j.chb.2010.02.013.

- Kim, I., Loadman, W. e. (1994), *Predicting teacher job satisfaction across years of teaching experience.* Mid-Western Educational Research Association, Chicago, IL.

- Kintsch, W. i Greeno, J.G. (1985). Understanding and solving word arithmetic problems. Psychological Review, 92, 109-129.

- Kiper, H., Mischke, W. (2008), *Uvod u opću didaktiku.* Educa, Zagreb.

- Kiš-Glavaš, L., Fulgosi-Masnjak, R. (2002): Do prihvaćanja zajedno: Integracija djece s posebnim potrebama, Priručnik za učitelje. Zagreb: Hrvatska udruga za stručnu pomoć djeci s posebnim potrebama IDEM.

- Klaić, B. (1982), Rječnik stranih riječi: tuđice i posuđenice. Zagreb: Nakladni zavod Matice hrvatske.

- Klaić, B. (2007), Rječnik stranih riječi: tuđice i posuđenice. Zagreb: Školska knjiga.

- Klafki, W. (1976), *Lehrerausbildung, Erziehunhswissenschaft, Fachdidaktik, u: Roth (ur.)* Handlexikon zur Erziehungwissenschadt, Munchen, 1976., str. 267-276.

- *Klafki*, W. (*1985*). Neue Studien zur Bildungstheorie und Didaktik.

- Klafki, W. (1992), Didaktika kao teorija obrazovanja u okviru kritičko-konstruktivne odgojne znanosti. U: Gudjons i sur. (ur), Didaktičke teorije. Zagreb: Educa.

- Klauer, K. J. (1992). *In Mathematik mehr leistungsschwache Madchen, im Lesen und Rechschreiben mehr leistungsschwache Junden?* Zeitschift fur Entwicklungspsychologie und Padagogische Psychologie, 26, 48-65.

- Kloostermann, P. (1996.), *Students' beliefs about knowing and learning mathematics: Implications for motivation*. U: M. Carr (ur.), *Motivation in mathematics*, Cresskill, N. J., Hampton Press, str. 131-156.

- Kolak. A., Majcen, M. (2011), Emocionalne reakcije učenika u nastavnom procesu kao poticaj razvoju kreativnosti. U : Gojkov-Rajić,A; Grozdanka, G. (ur.) The gifted in the process of globalization, 337-360.
- Kolak, A. (2014), Students` Emotional Responses Related to the Teaching Activity, *International Teacher Education Conference*, Dubai.
- Koren, I. (1989.), *Kako prepoznati i identificirati nadarenog učenika*. Zagreb: Školske novine.
- Kosc, L. (1974). *Developmental dyscalculia*. Journal of Learning Disabilities, *7*, 46-59.
- Koshy, V., Ernest, P., Casey, R. (2009), Mathematically gifted and talented learners: theory and practice. *International Journal of Mathematical Education in Science and Technology*, Vol 40., No. 2, 213-228.
- Kurnik, Z. (2009), *Znanstveni okviri nastave matematike*, Element, Zagreb.
- Kurnik, Z. (2010), *Terminološki problemi u nastavi matematike*. Matematika i škola, 55, 195-199.
- Kyriacou, K. (2001), *Temeljna nastavna umijeća*. Educa, Zagreb.
- Lacković – Grgin, K. (1994.). Samopoimanje mladih. Jastrebarsko: Naklada Slap.
- Lampert, M. (1990), *When the problem is not the question and solution is not the answer: Mathemtical knowing and* teaching, American Educational Research Journal, 27, 29-63.
- Lenzen, D. (2002.), Vodič za studij znanosti o odgoju: što može, što želi. Zagreb, Educa.
- Leikin, R. (2011), *The education of mathematically gifted students: Some complexities and questions*, Montana Mathematics Enthusiast, vol 8, ½, 167-188.
- Lester, F., Garofalo, J., Kroll, D. L. (1989), *Self-Confidence, Interests, Beliefs, and Metacognition: Key Influences on Problem-Solving Behavior.* Affect and mathematical problem solving: A new perspective, pp. 75-88.
- Lewis, C., Hitch, G. J., Walker, P. (1994). *The prevalence of specific arithmetic difficulties and specific reading difficulties in 9- to 10-year old boys and girls*. Journal of Child Psychology and Psychiatry, 35, 283-292.
- Light, G. J. i DeFries, J. C. (1995). *Comorbidity for reading and mathematics disabilities: Genetic and environmental etiologies.* Journal of Learning Disabilities, 28, 96-106.
- Light, G., Cox, R. (2001), Learning and Teaching in Higher Education: The Ref lective Professional. London: Paul Chapman Publishing.
- Lucangeli, D., Tressoldi, P., Fiore, C. (1998). *Test ABCA – Abilità di calcolo aritmetico*. Trento, Italy: Erickson.
- Ma, X., & Kishor, N. (1997). *Assessing the Relationship Between Attitude Toward Mathematics and Achievement in Mathematics: A Meta-Analysis*. Journal for Research in Mathematics Education, 28 (1), 26-47.

- Marsh, C. J. (1994), *Kurikulum: temeljni pojmovi. Zagreb, Educa.*
- Masterpasqua, F. (1991.), A Competence Paradigm for Psychological Practice. American Psychological Association Inc. American Psychologist, 44, 1366.-1371.
- Matijević, M. (2005), Evaluacija u odgoju i obrazovanju. Pedagogijska istraživanja, 2 (2): 279-298.
- Matijević, M. (2010), *Između didaktike nastave usmjerene na učenika i kurikulumske teorije*. U: Zbornik radova Četvrtog kongresa matematike. Zagreb: Hrvatsko matematičko društvo i Školska knjiga, str. 391-408.
- Matijević, M., Rajić, V. (2015), *Metodologije kurikulumskih promjena: nekad i danas. Researching Paradigms of Childhood and Education, Opatija, Croatia.*
- McLeod, D.B. and Ortega, M. (1993) Affective Issues in Mathematics Education. In: Wilson, P.S., Ed., Research Ideas for the Classroom. High School Mathematics, National Council of Teachers of Mathematics, New York, 21-36.
- Melbi, G. L. (2001), *High teacher efficacy as a marker of teacher effectiveness in the domain of classroom managment.* California Council of Teacher Education, San Diego, CA.
- Metcalf, K. K. (1995), *Laboratory Experiences in Teacher Education: A Meta-Analytic Review of Research. American Educational Research Association.*
- Meyer, H. (1987) *UnterrichtsMethoden*. Berlin: Scriptor Cornelsen. Meyer, H. (1987) *UnterrichtsMethoden*. Berlin: Scriptor Cornelsen.
- Meyer, H. (2002), Didaktika razredne kvake. Zagreb: Educa.
- Meyer, H. (2005), Što je dobra nastava, Zagreb: Erudita.
- Mhlolo, K. M. (2018), *Regular classroom teachers' recognition and support of the creative potential of mildly gifted mathematics learners.* ZDM: International journal on mathematics education, 49: 81-94.
- Mijatović, A. (2000), Leksikon temeljnih pedagoških pojmova. Zagreb: Edip.
- Milivojević, Z. (2007), Emocije. Novi Sad: Psihopolis Institut.
- Milovanović, M., Romano, D., Todić, V. (2012), *Različiti teorijski aspekti istraživanja nastave matematike; Nova škola (Bijeljina).*
- Ministarstvo znanosti, obrazovanja i športa, RH (2010), Nacionalni okvirni kurikulum za predškolski odgoj i obrazovanje te opće obvezno i srednjoškolsko obrazovanje. Zagreb.

- Mišurac Zorica, I. (2007.), „*Stavovi studenata učiteljskih studija o matematici*“, Zbornik radova sa skupa Matematika i dijete (International Scientific Colloquium Mathematics and Children), (ur. Margita Pavleković), Osijek.
- Montgomery, D. C., and Peck, E. A. (1982). Introduction to Linear Regression Analysis. New York: John Wiley & Sons, INC.
- Mullis, I. V. S., Martin, O., Foy , P., Arora, A., (2011), The *TIMSS 2011: International Results in Mathematics, International Study Center, Lynch School of Education, Boston*.
- *Mužić*, V. (1999), Uvod u metodologiju istraživanja odgoja i obrazovanja. Impressum. Zagreb : Educa.
- Mužić, V. Vrjednovanje u odgoju i obrazovanju. Zagreb : Hrvatski pedagoško-književni zbor, 2005.
- MZOS (2006), *Nastavni plan i program za osnovnu školu*. Ministarstvo znanosti, obrazovanja i športa, Zagreb.
- Nacionalni okvirni kurikulum za predškolski odgoj i obrazovanje te opće obvezno i srednjoškolskoobrazovanje (2010), Zagreb: Ministarstvo znanosti, obrazovanja i športa (http://public.mzos.hr/Default.aspx?sec=2685)
- Natan, M. J., Knuth, E. J. (2003). A Study of Whole Classroom Mathematical Discourse and Teacher Change. *Cognition and Instruction, 21(2), 175-207.*
- NCCA, (2005). *NCCA Review of Mathematics in Post-Primary Education Response of the Royal Irish Academy Committee for Mathematical Sciences*, Irish Mathematics Society, Bulletin 57, 11–20.
- Neale D. (1969). The role of attitudes in learning mathematics. The Arithmetic Teacher, Dec. 1969, 631–641.
- Nespor, J. (1987), The role of beliefs in the practice of teaching. *Journal of Curriculum Studies, 19, 317-328.*
- OECD (2013), PISA 2012 Results: Ready to Learn. Students Engagement, Drive and Self-Beliefs (Volume *III). PISA, OECD Publishing*.
- OECD (2013), PISA 2012 Results:What Makes Schools Successful? Resources, Policies and Practices (Volume IV). *PISA, OECD Publishing*.
- *Pajares, M. (1992). Teachers' Beliefs and Educational Research: Cleaning Up a Messy Construct.*
- Palekčić, M. (2005), Utjecaj kvalitete nastave na postignuća učenika. Pedagogijska istraživanja, 2 (2), str. 209-233.
- Palekčić, M. (2007), Od kurikuluma do obrazovnih standarda. U: Previšić, V. (ur.), Kurikulum- Teorije, metodologija, sadržaj, struktura. *Zagreb*: Zavod za pedagogiju Filozofskog fakulteta u *Zagrebu* i Školska knjiga, 39-115.

- Palekčić, M. (2008), Uspješnost i/ili učinkovitost obrazovanja nastavnika. *Odgojne znanosti*. 10 , (2), 157-177.
- Palekčić, M. (2014), *Kompetencije i nastava: obrazovno-politička i pedagogijska teorijska perspektiva.* Pedagogijska istraživanja, 11 (1), 7-26.
- Pastuović, N. (2008). „Cjeloživotno učenje i promjene u školovanju“. *Odgojne znanosti,* 10 (2): 253-267.
- Patton, B. A., Fry, J., Klages, C. (2008), *Teacher Candidates' and Master Math Teachers' Personal Concepts about Teaching Mathematics. Education, 128 (3), 486-497.*
- Pavleković,, M. (2008), *Metodika nastave matematike s informatikom I.* Element, Zagreb.
- Pavleković,M; Zekić-Sušac,M; Đurđević,I. (2010.) *Prepoznavanje matematički darovite djece s pomoću ekspertnog sustava, nastavnika i psihologa*. Društvena istraživanja, 19,3(107),487-510.
- Pavleković,M; Zekić-Sušac,M; Đurđević,I. (2007.) *Expert system for detecting a child's gift in mathematics*. U: Pavleković,M.(ur). *Mathematics and children - how to teach and learn mathematics*. International Scientific Colloquium, 98-117.
- Pavleković, M., Benšić, M., Zekić-Sušac, M. (2010), Modelling Children's Mathematical Gift By Neural Networks and Logistic Regression. *Expert systems with applications,* **37**, 10; 7167-7173.
- Pavleković,M; Zekić-Sušac,M; Đurđević,I. (2011.) *A neural network model for predicting children's mathematical gift*. Croatian Journal of Education. 13(1/2011), 10-41.
- Peker, M. (2008), Pre-service teachers` teaching anxiety about mathematics and they learning styles. *Eurasia Journal of Mathematics, Science & Technology Education*, 5(4), 335-345.
- Pehkonen, J. (1992).“Survey expectations and stochastictrends in modelling the employment-output equation.”Oxford Bulletin of Economics and Statistics 54, 579–590.
- Pekrun, R. (2006), The Control Value Theory of Achievement Emotions: Assumptions, Collollaries and Implications for Educational Research and Practice. *Educ. Psychol. Rev*. 18: 315-341.
- Perrenoud, P. (2002), Key Competencies. Brusseles: Eurydice, Europen Unit.
- *Plöger,* W. (1992), *Allgemeine Didaktik und Fachdidakti. Modelltheoretische Untersuchungen.* Frankfurt.
- Poljak, V. (1991). *Didaktika.* Školska knjiga, Zagreb.
- Prange, K. (2005), Kompetencije između profesionalizacije i evaluacije. Pedagogijska istraživanja, 2 (1), str. 35-48.
- Preis, C., Biggs, B.T. (2001), Can Instructors Help Learners Overcome Math Anxiety? *ATEA Journal*, 28(4), 6-10.

- Previšić, V. (1999), Škola budućnosti: humana, stvaralačka i socijalna zajednica. *Napredak*, 140 (1), 7-16.
- Previšić, V. (2003), Suvremeni učitelj: odgojitelj-medijator-socijalni integrator. U: Prskalo, I., Vučak, S. (ur.), Učitelj-učenik-škola. Petrinja: VUŠ, HPKZ.
- Putney, L.. D., Cass, M. (1998.) Preservice teacher attitudes toward mathematics: Improvement through manipulative approach. College StudentJournal, Vol. 32, Issue 4, 626-633.
- Ramaa, S. i Gowramma, I., P. (2002). *A systematic procedure for identifying and classifying children with dyscalculia among primary school children in India*. Dyslexia (Chichester, England), 8(2), 67–85.
- Renzulli, J. S. (1978). What Makes Giftedness: A Reexamination of the Definition. *Phi Delta Kappan, 60, 180-184, 261*.
- Renzulli,J. S. (1986). *The Three-ring conception of giftedness:A developmental model for creative productivity*. U: Sternberg,R.J; Davidson,J.E.(ur.) *Conception of Giftedness*. New York:University Press.
- Resnick, H.,Viehe, J.,Segal, S. (1982). *Is math anxiety a local phenomenon? A study of prevalence and dimensionality.* Journal of Counseling Psychology, Vol 29(1), 39-47.
- Reusser, K. (1989). Textual and situational factors in solving mathematical word problems. (Research Rep. No 7). Bern: Universität Bern.
- Richardson, F., Suin, R. M. (1972), Mathematics anxiety rating scale: Psychometric data. *Journal of Counseling Psychology*, 19, 551-554.
- Richardson, V., Anders, P., Tidwell, D., &Lloyd, C. (1991). The relationship between teachers‟ beliefs and practices in reading comprehension instruction. American Educational Research Journal, 28, 559–586.
- Rijavec, M., Miljević-Riđički, R. i Vizek Vidović, V. (2006), Professional beliefs and percieved competences of pre-service teachers and beginning teachers. Odgojne znanosti, 8 (1) str. 159-170.
- Robson, J. (1998). Active teaching and learning. Paper presented at TALESSI workshop.
- Romano, D.A. (2009), *Teorije matematičkog obrazovanja. Prvi dio: RME – teorija.* Istraživanje matematičkog obrazovanja, *Vol. I, 1, 23-35.*
- Romano, D.A. (2013), Priroda matematičkog znanja koje nastavnici konstruišu u učionici; U (Nenad Vilović, UR.): METODIČKI ASPEKTI NASTAVE MATEMATIKE II, Zbornik radova sa drugog medjunarodnog naučnog skupa. Jagodina, 67-79.
- Rosenthal, R., Jacobson, L. (1986), Urban Rev., 3: 16.
  URL*: https://doi.org/10.1007/BF02322211*

- Rosić,V; Vrcelj,S; Mušanović,M. (2004), *Strategije razvoja darovitosti*. U : Zbornik radova sa 10. okruglog stola – *Strategije podsticanja darovitosti*, Scoala superioara pentru educatoare Varset i VŠZOV Vršac, 36-45.
- Ross, J. A., Bruce, C. D. (2007), *Effects of professional development on teacher efficacy: Results of a randomized filed trial.* Annual meeting of the American Educational Research Association, Chicago.
- Roth, H. (1971), Pädagogische Anthropologie. Band II, Entwicklung und Erziehung. Grundlage einer Enwicklungspädagogik. Hannover: Schroedel.
- *Salovey*, P. & *Mayer*, J. D. (*1990*). Emotional intelligence. Imagination, Cognition, and Personality, 9, 185-211.
- Schmitt, T. A. (2011). *Current Methodological Considerations in Exploratory and Confirmatory Factor Analysis*, Journal of Psychoeducational Assessment, 29(4), 304-321.
- Schon, D. (1990), Educating the Ref lective Practiti-oner. San Francisco: Josey-Bass.
- Schulz, W. (1994), Didaktika kao teorija poučavanja.U: H. Gudjons i sur. (ur.) Didaktičke teorije. Zagreb: Educa, str. 37-57.
- Scott, D., Weeks, P. (1998), Action Research as Reflective Collaboration. U: Atweh, B., Kemmis, S., Weeks, P. (ur.), Action Research in Practice: Partnership for Social Justice in Education. London: Routledge, str. 241- 325.
- Seels, B., & Glasgow, Z. (1998). Making instructional design decisions. Columbus, Ohio:Merrill Publishing Company.
- Senge, P., Scharmer, O. C., Jaworski, J., Flowers, B. S. (2007), Prisustvo. Ljudska svrha i polje budućnosti. Zagreb: Društvo za organizacijsko učenje Hrvatske.
- Sharma, M. (2001). *Matematika bez suza: Kako pomoći djetetu s teškoćama u učenju matematike*, Lekenik, Ostvarenje.
- Sherin, M., Jacobs, V., Philipp, R. (2011), *Mathematics teacher noticing; seeing through teachers eyes*, UK, Routledge.
- Sheffield, D., & Hunt, T. E. (2007). How does anxiety influence performance and what can we do about it? MSOR Connections, 6, 1-5
- Sherman, H. J. i Christian, M. (1999), *Mathematics attitudes and global self concept: An investigation of the relationship*, College Student Journal, 33 (1), 95-102.
- Sigel, I., Lisi, A. (2002). Parent beliefs are cognitions: The dynamic belief systems model. Handbook of parenting: Being and becoming a parent. 3.
- Sjöberg, G. (2006). *If it isn't dyscalculia –then what is it? A multi-method study of the pupil with mathematics problems from a longitudinal perspective*. Department of Mathematics Technology and Science Education, Umeå University.
- Sloan, T. R. (2010), A quantitative and qualitative study of math anxiety among pre-service teachers. *The Educational Forum*, 74(3), 242-256.

- Smith, J.L., White, P.H. (2002). An Examination of Implicitly Activated, Explicitly Activated, and Nullified Stereotypes on Mathematical Performance: It's Not Just a Woman's Issue. *Sex Roles* 47, 179–191. https://doi.org/10.1023/A:1021051223441.
- Sriraman, B. (2005), *Are Giftedness and Creativity Synonyms in Mathematics?,* The Journal of Secondary Gifted Education, Vol. XVII, No. 1, 20-36.
- Sriraman, B., English, L. (2005). Theories of Mathematics Education: A global survey of theoretical frameworks/trends in mathematics education research. ZDM. 37. 10.1007/BF02655853.
- Statistički ljetopis Republike Hrvatske (2018), Zagreb, Državni zavod za statistiku Republike Hrvatske.
- Statistički izvješće o visokom obrazovanju u 2017. godini (2018), Zagreb, Državni zavod za statistiku Republike Hrvatske.
- Statistički izvješće o visokom obrazovanju u 2016. godini (2017), Zagreb, Državni zavod za statistiku Republike Hrvatske.
- Stein, M. K., & Wang, M. C. (1988). Teacher develop-ment and school improvement: The process of t eacher change. American Education ResearchJournal, 4(2), 171–187.
- Sternberg, R.J. (2001), *Giftedness as Developing Expertise*: *A theory of inteface between high abilities and achieved exelence*. High Ability Studies, 12,2,159-179.
- Stevenson, H. W., Lee, S. Y., Stigler, J. W. (1986). *Mathematics achievement of Chinese, Japanese, and American children. Science, 231, 693-699.*
- Straesser, R. (2007), Didactics of mathematics: more than mathematics and school*! ZDM Mathematics Education*, 39: 165-171.
- Struyf, Elke & Adriaensens, Stefanie & Meynen, Karen. (2011). Are beginning teachers ready for the job? The development and validation of an instrument to measure the basic skills of beginning secondary teachers. Assessment & Evaluation in Higher Education. 36. 429-449. 10.1080/02602938.2011.581748.
- *Students not to Engage in Learning Mathematics in School is Deliberate*. Educational Studies in Mathematics, 62(1), 81–99.
- Sullivan, P., Tobias, S.; McDonough, A. (2006). *Perhaps the Decision of Some*
- Swanson, H.L. (2000). *Issues facing the field of learning disabilities*. Learning Disability Quarterly, 23, 37-49.
- Šagud, M. (2006): Odgajatelj kao refleksivni praktičar. Petrinja: Visoka učiteljska škola u Petrinji.
- Šimić, S., Sorić, I. (2004), Osobine ličnosti i stavovi nastavnika u relaciji s njihovim načinom ocjenjivanja. *Suvremena psihologija, 7(1): 109-128.*
- Tabachnick, B. G., & Fidell, L. S. (2007). *Using multivariate statistics* (5th ed.). Upper Saddle River, NJ: Pearson Allyn & Bacon.

- Tannenbaum,A.J.(1983.) *Gifted children: psychological and educational perspectives*. New York:Macmillan.
- Tschannen-Moran, m., Hoy, W. K.., Hoy, A. W. (1998), *Teacher Efficacy: Its Meaning and Measure*. Review of Educational Research, 68(2): 202-248.
- Temple, C. M., Sherwood, S. (2002). *Representation and retrieval of arithmetical facts: developmental difficulties*. Exp Psychol. 55A:733–752.
- Terhart, E. (2001), Metode poučavanja i učenja. Educa, Zagreb.
- Thompson, J. (2016), *Vodič za rad s djecom i učenicima s posebnim odgojno-obrazovnim potrebama*, Zagreb: Educa.
- Tirri, K. (2008), *Who should teach gifted students?*, Revista Espanola de Pedagogia, 240, 315-324.
- Tocci, J. M., Engelhard, G. J. (1991), *Achievement, Parental Support and Gender Differences in Attitudes Toward Mathematics.* The Journal of Educational Research, 280-287.
- Treffers, A.: 1978,Wiskobas Doelgericht, IOWO, Utrecht, The Netherlands.
- Tschannen-Moran, M., Woolfolk Hoy, A., Hoy, W. K. (1998). Teacher efficacy: Its meaning and measure. *Review of Educational Research, 68, 202-248.*
- Turner, J. C., Meyer, D. K., Anderman, E. M., Midgley, C., Gheen, M., et al. (2002), The classroom environment and students` reports of avoidance strategies in mathematics: A multimethod study. *Journal of Educational Psychology*, 94(1), 88.
- Turner, J. C., Warzon, K. B., Criestensen, A. (2011), Motivating mathematics learning: Changes in teachers practices and beliefs during a nine-month collaboration. *American Educational Research Journal, 48, 718-762.*
- Turnuklu, E. B., Yesildere, S. (2007), The Pedagogical Content Knowledge in Mathematics: Pre-Service Primary Mathematics Teachers' Perspectives in Turkey. *International Electronic Journal of Mathematics Education*, 6(1), 40-59.
- Tyler, R. W. (1949), *Basic principles of curriculum and instruction.*
- Usiskin, Z. (2000). The development into the mathematically talented. Journal of Secondary Gifted Education, 11, 152–162.
- Van Nieuwenhoven, C., Grégoire, J., Noël, M.-P. (2001). Le TEDI-MATH. Test Diagnostique des compétences de base en mathématiques. *Paris: ECPA.*
- Velicer, W. F., Eaton, C. A., & Fava, J. L. (2000). Construct explication through factor or component analysis: A review and evaluation of alternative procedures for determining the number of factors or components. In R. D. Goffin & E. Helmes (Eds.), Problems and solutions in human assessment: Honoring Douglas N. Jackson at seventy (pp. 41-71). Boston: Kluwer Academic Publishers.
- Vican, D., Bognar, L., Previšić, V. (2007). *Hrvatski nacionalni kurikulum,* U: Previšić, V. (ur.), Kurikulum- Teorije, metodologija, sadržaj, struktura. *Zagreb*: Zavod za pedagogiju Filozofskog fakulteta u *Zagrebu* i Školska knjiga, 157-204.

- Vinson, B. M. (2001), A comparison of pre-service teachers` mathematics anxiety before and after a methods class emphasizing manipulatives. *Early Childhood Education Journal*, 29(2), 89-94.

- Vizek- Vidović, V., Vlahović- Štetić, V. Arambašić, L. (1997.), *Konativne i emocionalne karakteristike matematički nadarene i prosječno sposobne djece*, Društveno istraživanje Zagreb/godina 6, broj 4-5, 619-634.

- Vlahović-Štetić,V.(2005.) *Teorijski pristupi darovitosti*.U:Vlahović-Štetić,V.(ur.) *Daroviti učenici: teorijski pristupi i primjena u školi*, Zagreb:Institut za društvena istraživanja.

- Vlahović-Štetić, V. (2007.) *Mathematically gifted children: what can we teach them and what can we learn?* U: Pavleković,M.(ur). *Mathematics and children - how to teach and learn mathematics*, International Scientific Colloquium, 45-57.

- Waks, L. (1999), Reflective practice in the design studio and teacher education. J. Curriculum studies, 31 (3): 303- 316.

- Watkins, M. W. (2000). Monte Carlo PCA for Parallel Analysis (Computer Software). State College, PA: Ed & Psych Associates.

- Weiner, B. (1985.). Human motivation. Springer-Verlag, New York.

- Weinert, F. E. (2001), Concept of Competence: A Conceptual Clarification. U: Rychen, D. S. i Salganik, L. H. (ur.), Defining and Selecting Key Competencies. Göttingen: Hogrefe & Huber.

- Widmer, C. C., Chavez, A. (1982). Math anxiety and elementary school teachers. Education, 102(3), 272-276.

- Wieczerkowski,W; Cropley, A. J; Prado,T.M., (2000), *Nurturing talent/gifts in mathematics*. U:Heller, K. A; Monks, F. J. ;Sternberg, R. J. ;Subotnik, R. F. (ur.), International handbook of giftedness and talent.Oxford:Elsevier Science Ltd.

- Wigfield, A.; Meece, Judith L (1988). ,Math anxiety in elementary and secondary school students. Journal of Educational Psychology, Vol 80(2), 210-216.

- Wigfield, A., Eccles, J., Yoon, K. S., Harold, R., Arbreton, A., Freedman-Doan, C., Blumenfeld, P. (1997), Change in Children's Competence Beliefs and Subjective Task Values Across the Elementary School Years: A 3-Year Study. Journal of Educational Psychology. 89. 451-469.

- Wigfield, A., Eccles, J. S. (2000), *Expectancy- value theory of achievement motivation*. Contemporary Educational Psychology, 25, 68-81.

- Wilkinson, S. C. (1993), *WISC-R profiles of children with superior intellectual ability*. Gifted Child Quarterly,37,84-91.

- Williams, B., Onsman, A., & Brown, T. (2010), Exploratory Factor Analysis: A Five-Step Guide for Novices. Australasian Journal of Paramedicine, 8, 1-13.

- Winkel, R. (1978), *Zur Theorie und Praxis der Unterrichtsmethoden.* In Die Deutsche Schule, 70(11), 669-683.
- World Health Organisation (2001). *International Classification of the Functioning, Disability and Health (ICF),* Geneva.
- Xin Ma (1999), *A meta-analysis of the relationship between anxiety toward mathematics and achievement in mathematics*, Journal of Research in Mathematics Education, 30 (5), 520-540.
- Yong, G. A., Pearce, S. (2013), *A Begginers Guide to Factor Analysis: Focusing on Exploratory Factor Analysis.* Tutorials in Quantiatitve Methods for Psccholog, Vol. 9(2), p. 79-94.
- Yoon, J. S. (2002), Teachers characteristics as predictors of teacher-student relationships: Stress, negative affect, and self efficacy. *Social Behavior and Personality, 30(5): 485-494.*
- Zazkis, R. (2017). Lesson Play tasks as a creative venture for teach-ers and teacher educators. ZDM Mathematics Education.

.

7. POPIS TABLICA

Tablica 1. 1 Struktura sudionika istraživanja prema godinama radnog staža 152
Tablica 1. 2: *Struktura sudionika istraživanja prema završenom inicijalnom obrazovanju* 152
Tablica 1. 3: *Struktura sudionika istraživanja prema radnom mjestu* 153
Tablica 1. 4: *Stečena dodatna naobrazba/napredovanje u zvanju* 153
Tablica 1. 5: *Broj ispitanika po županijama* 154
Tablica 1. 6: *Struktura nastavnika po radnom mjestu s obzirom na inicijalno obrazovanje* 155
Tablica 1. 7: *Struktura nastavnika po stečenoj dodatnoj naobrazbi s obzirom na inicijalno obrazovanje* 155
Tablica 1. 8: *Struktura nastavnika po spolu s obzirom na inicijalno obrazovanje* 156
Tablica 1. 9: *Struktura nastavnika na radnom mjestu s obzirom na spol* 156
Tablica 1. 10: *Struktura nastavnika u stečenoj dodatnoj naobrazbi s obzirom na spol* 156

Tablica 2. 1: *Ljestvica uvjerenja nastavnika o nastavi i obrazovanju općenito te o specifičnostima određenih područja matematičkog obrazovanja* 158
Tablica 2. 2: *Izdvojene tvrdnje s najvišim razinama slaganja nastavnika* 160
Tablica 2. 3: *Svladavanje matematičkih sadržaja potrebno je kako bi učenici mogli logički razmišljati i zaključivati u različitim situacijama iz svakodnevice.* 161
Tablica 2. 4: *Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi* 162
Tablica 2. 5: *Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u prirodoslovno-matematičkoj gimnaziji“* 162
Tablica 2. 6: *Učenik koji ima problema s usvajanjem tablice množenja može imati ocjenu odličan u prirodoslovno-matematičkoj gimnaziji* 163
Tablica 2. 7: *Matematički daroviti učenici imat će uspješnu karijeru u matematici bez obzira na potporu okoline.* 164
Tablica 2. 8: *Učenici nisu bolji matematičari od učenica.* 165
Tablica 2. 9: *Razlike u stavovima i uvjerenjima s obzirom na spol nastavnika (analiza varijance)* 166
Tablica 2. 10: *Korištenje didaktičkih materijala i pomagala potrebno je zbog unaprjeđenja kvalitete procesa učenja i poučavanja matematike.* 167
Tablica 2. 11: *Svladavanje matematičkih sadržaja potrebno je kako bi učenici mogli logički razmišljati i zaključivati u različitim situacijama iz svakodnevice* 167
Tablica 2. 12: *Nastavni proces treba se planirati prema smjernicama Nacionalnog okvirnog kurikuluma* 168
Tablica 2. 13: *Ostvarivanje korelacija matematičkih sadržaja sa svakodnevnim životom podiže kvalitetu usvojenih znanja* 168
Tablica 2. 14: *Korelacije matematike s ostalim predmetima i disciplinama nužne su za podizanje kvalitete učenja* 169
Tablica 2. 15: *Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi* 169
Tablica 2. 16: *U kojoj mjeri se slažete kako je bitno da nastavnik matematike smatra kako učenici moraju voljeti matematiku da bi bili uspješni u njoj* 170

Tablica 2. 17: *Struktura sudionika istraživanja prema završenom inicijalnom obrazovanju* 171
Tablica 2. 18: *Analiza varijance za uvjerenja nastavnika s obzirom na inicijalno obrazovanje* 171
Tablica 2. 19: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na incijalno obrazovanje ispitanika* 172
Tablica 2. 20: *Razlike s obzirom na inicijalno obrazovanje u tvrdnji 1.1* 173
Tablica 2. 21: *Razlike s obzirom na inicijalno obrazovanje u tvrdnji 1.5* 173
Tablica 2. 22: *Razlike s obzirom na inicijalno obrazovanje i godine radnog stažu u tvrdnji 1.5* 174
Tablica 2. 23: *Razlike s obzirom na inicijalno obrazovanje nastavnika u tvrdnji 1.9* 175
Tablica 2. 24: *Razlike s obzirom na inicijalno obrazovanje i radni staž nastavnika u tvrdnji 1.9* 176
Tablica 2. 25: *Razlike s obzirom na inicijalno obrazovanje nastavnika u tvrdnji 1.10* 176
Tablica 2. 26: *Razlike s obzirom na inicijalno obrazovanje nastavnika u tvrdnji 1.12* 177
Tablica 2. 27: *Razlike s obzirom na inicijalno obrazovanje nastavnika u tvrdnji 1.28* 178
Tablica 2. 28: *Razlike s obzirom na inicijalno obrazovanje i radni staž nastavnika u tvrdnji 1.28* 178
Tablica 2. 29: *Struktura ispitanika prema godinama radnog staža* 179
Tablica 2. 30: *Analiza varijance za uvjerenja nastavnika s obzirom na radni staž* 180
Tablica 2. 31: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na radni staž ispitanika* 180
Tablica 2. 32: *Razlike s obzirom na godine radnog staža u tvrdnji 1.1* 181
Tablica 2. 33: *Razlike s obzirom na godine radnog staža u tvrdnji 1.3* 182
Tablica 2. 34: *Razlike s obzirom na godine radnog staža u tvrdnji 1.4* 182
Tablica 2. 35: *Razlike s obzirom na godine radnog staža u tvrdnji 1.8* 183
Tablica 2. 36: *Razlike s obzirom na godine radnog staža u tvrdnji 1.30* 183
Tablica 2. 37: *Razlike s obzirom na godine radnog staža u tvrdnji 1.10* 184
Tablica 2. 38: *Razlike s obzirom na godine radnog staža u tvrdnji 1.17* 184
Tablica 2. 39: *Razlike s obzirom na godine radnog staža u tvrdnji 1.20* 185
Tablica 2. 40: *Struktura ispitanika s obzirom na stečenu dodatnu naobrazbu* 186
Tablica 2. 41: *Struktura ispitanika s obzirom na radno mjesto* 186
Tablica 2. 42: *Analiza varijance za uvjerenja nastavnika s obzirom na radno mjesto* 187
Tablica 2. 43: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na radno mjesto ispitanika* 188
Tablica 2. 44: *Razlike s obzirom na radno mjesto u tvrdnji 1.2* 189
Tablica 2. 45: *Razlike s obzirom na radno mjesto u tvrdnji 1.13* 190
Tablica 2. 46: *Uvjerenja nastavnika o stereotipima o matematičkim sposobnostima* 191
Tablica 2. 47: *Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi.* 192
Tablica 2. 48: *Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u prirodoslovno-matematičkoj gimnaziji* 193
Tablica 2. 49: *Odnos između tvrdnji 1.13 i 1.14: Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi/prirodoslovno-matematičkoj gimnaziji* 193
Tablica 2. 50*: Učenik koji ima problema s računanjem (tablicom množenja) ne može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji.“* 194
Tablica 2. 51: odnos tvrdnji 1.14: *Učenik prosječnih sposobnosti može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji.* i 1.15*: Učenik koji ima problema s računanjem (tablicom množenja) ne može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji* 196

Tablica 2. 52: odnos tvrdnji 1.15*: Učenik koji ima problema s računanjem (tablicom množenja) ne može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji*. i 2.14 *Znam prepoznati učenika koji ima diskalkuliju.* 196
Tablica 2. 53: *Uvjerenja o radnim navikama i motivaciji darovitih učenika* 197
Tablica 2. 54: *Uvjerenja o uspjehu darovitih učenika* 198
Tablica 2. 55: Tvrdnja 1.17: *Povezanost radnih navika i motivacije s uspjehom na matematičkim natjecanjima* 198
Tablica 2. 56: *Uvjerenja o motivaciji darovitih učenika* 199
Tablica 2. 57: *Deskriptivni parametri percepcije rodnih stereotipa* 199
Tablica 2. 58: *Deskriptivni parametri percepcije rodnih stereotipa* 199
Tablica 2. 59: *Deskriptivni parametri ljestvice percipirane kompetentnosti i samoefikasnosti* 200
Tablica 2. 60: *Analiza varijance za procjenu samoefikasnosti nastavnika s obzirom spol* 202
Tablica 2. 61: *Razlike s obzirom na spol u tvrdnji 2.1* 203
Tablica 2. 62: *Razlike s obzirom na spol u tvrdnji 2.3* 203
Tablica 2. 63: *Razlike s obzirom na spol u tvrdnji 2.6* 204
Tablica 2. 64: *Razlike s obzirom na spol u tvrdnji 2.17* 205
Tablica 2. 65: *Analiza varijance u samoprocjenama nastavnika s obzirom na inicijalno obrazovanje* 206
Tablica 2. 66: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na inicijalno obrazovanje ispitanika* 206
Tablica 2. 67: *Razlike u samoprocjenama nastavnika s obzirom na inicijalno obrazovanje u tvrdnji 2.1* 207
Tablica 2. 68: *Analiza varijance u samoprocjenama nastavnika s obzirom na radni staž* 208
Tablica 2. 69: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama nastavnika u samoprocjenama s obzirom na radni staž* 208
Tablica 2. 70: *Razlike među nastavnicima s obzirom na radni staž u tvrdnji 2.5* 209
Tablica 2. 71: *Razlike među nastavnicima s obzirom na radni staž u tvrdnji 2.17* 209
Tablica 2. 72: *Razlike među nastavnicima u samoprocjenama kompetnenosti i samoefikasnosti s obzirom na radni staž* 210
Tablica 2. 73: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na stečenu dodatnu naobrazbu ispitanika* 211
Tablica 2. 74: *Razlike u samoprocjenama nastavnika s obzirom na stečenu dodatnu naobrazbu u tvrdnji 2.1* 212
Tablica 2. 75: *Razlike u samoprocjenama nastavnika s obzirom na stečenu dodatnu naobrazbu u tvrdnji 2.2* 212
Tablica 2. 76: *Razlike u samoprocjenama nastavnika s obzirom na stečenu dodatnu naobrazbu u tvrdnji 2.4* 213
Tablica 2. 77: *Razlike u samoprocjenama nastavnika s obzirom na stečenu dodatnu naobrazbu u tvrdnji 2.5* 213
Tablica 2. 78: *Razlike u samoprocjenama nastavnika s obzirom na stečenu dodatnu naobrazbu u tvrdnji 2.17* 214
Tablica 2. 79: *Razlike u samoprocjenama nastavnika s obzirom na stečenu dodatnu naobrazbu u tvrdnji 2.15* 215
Tablica 2. 80: *Analiza varijance za samoprocjene nastavnika s obzirom na radno mjesto* 216
Tablica 2. 81: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na radno mjesto nastavnika* 216

Tablica 2. 82: *Razlike u samoprocjenama nastavnika s obzirom radno mjesto u tvrdnji 2.14* 218
Tablica 2. 83: *Osnovni deskriptivni parametri ljestvice učestalosti nastavnih i izvannastavnih praksi* 219
Tablica 2. 84: *Analiza varijance ljestvice učestalosti nastavnih i izvannastavnih praksi s obzirom na spol nastavnika* 221
Tablica 2. 85: *Razlike u učestalosti nastavnih i izvannastavnih praksi nastavnika u tvrdnji 2.39* 223
Tablica 2. 86: *Razlike u učestalosti nastavnih i izvannastavnih praksi nastavnika u tvrdnji 2.40* 224
Tablica 2. 87: *Razlike u učestalosti nastavnih i izvannastavnih praksi nastavnika u tvrdnji 2.41* 224
Tablica 2. 88: *Analiza varijance ljestvice učestalosti nastavnih i izvannastavnih praksi s obzirom na inicijalno obrazovanje nastavnika* 225
Tablica 2. 89: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na radno mjesto nastavnika* 225
Tablica 2. 90: *Analiza varijance ljestvice učestalosti nastavnih i izvannastavnih praksi s obzirom na radni staž* 227
Tablica 2. 91: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na radni staž ispitanika* 228
Tablica 2. 92: *Analiza varijance ljestvice učestalosti nastavnih i izvannastavnih praksi s obzirom na stečenu dodatnu naobrazbu* 229
Tablica 2. 93: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na stečenu dodatnu naobrazbu nastavnika* 230
Tablica 2. 94: *Razlike s obzirom na stečenu dodatnu naobrazbu nastavnika u tvrdnji 2.35* 231
Tablica 2. 95: *Analiza varijance ljestvice učestalosti nastavnih i izvannastavnih praksi s obzirom na radno mjesto nastavnika* 233
Tablica 2. 96: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na radno mjesto nastavnika* 234

Tablica 3. 1: *Prikaz svojstvenih vektora i udjela varijance po faktorima dobivenih metodom analize glavnih komponenti* 239
Tablica 3. 2: *Ekstrahirani faktori, varijable i faktorska opterećenja dobiveni provedbom eksplorativne faktorske analize temeljene na analizi glavnih komponenti* 240
Tablica 3. 3: *Faktorska struktura i udio varijance po faktorima i kumulativni udio varijance za prikazanu strukturu* 241
Tablica 3. 4**:** *Osnovne deskriptivne vrijednosti faktorske strukture prvog dijela istraživačkog instrumenta* 242
Tablica 3. 5: *Rezultati analize varijance ljestvice uvjerenja s obzirom na spol nastavnika* 243
Tablica 3. 6: *Analiza varijance ljestvice uvjerenja s obzirom na spol nastavnika* 244
Tablica 3. 7: *Analiza varijance ljestvice uvjerenja s obzirom na radni staž nastavnika* 245
Tablica 3. 8: *Analiza varijance ljestvice učestalosti nastavnih i izvannastavnih praksi s obzirom na spol nastavnika* 246
Tablica 3. 9: *Analiza varijance ljestvice uvjerenja nastavnika s obzirom na spol* 247
Tablica 3. 10: *Prikaz svojstvenih vektora i udjela varijance po faktorima dobivenih metodom analize glavnih komponenti* 248
Tablica 3. 11: *Ekstrahirani faktori samoprocjena nastavnika, varijable i faktorska opterećenja dobiveni provedbom eksplorativne faktorske analize temeljene na analizi glavnih komponenti* 249

Tablica 3. 12: *Matrica korelacija (Pearsonov koeficijent korelacije) između faktora dobivenih iz ljestvice samoprocjena nastavnika* 251
Tablica 3. 13: *Analiza varijance u dimenzijama samoprocjena nastavnika s obzirom na spol* 252
Tablica 3. 14: *Analiza varijance u dimenzijama samoprocjena nastavnika s obzirom na inicijalno obrazovanje* 253
Tablica 3. 15: *Analiza varijance u dimenzijama samoprocjena nastavnika s obzirom na radni staž* .. 254
Tablica 3. 16: *Rezultati post-hoc Scheffe testa višestrukih usporedbi među grupama nastavnika s obzirom na radni staž* 254
Tablica 3. 17: *Analiza varijance u dimenzijama samoprocjena nastavnika s obzirom na stečenu dodatnu naobrazbu* 255
Tablica 3. 18: *Analiza varijance u dimenzijama samoprocjena nastavnika s obzirom na radno mjesto* 256
Tablica 3. 19: *Prikaz deskriptivnih parametara u samoprocjenama među grupama nastavnika s obzirom na radno mjesto ispitanika* 256
Tablica 3. 20: *Prikaz svojstvenih vektora i udjela varijance po faktorima dobivenih metodom analize glavnih komponenti* 257
Tablica 3. 21: *Ekstrahirani faktori nastavnih praksi nastavnika, varijable i faktorska opterećenja dobiveni provedbom eksplorativne faktorske analize temeljene na analizi glavnih komponenti* 258
Tablica 3. 22: *Matrica korelacija (Pearsonov koeficijent korelacije) između faktora dobivenih iz ljestvice nastavnih praksi nastavnika* 261
Tablica 3. 23: *Analiza varijance u dimenzijama nastavnih praksi nastavnika s obzirom na spol* 262
Tablica 3. 24: *Analiza varijance u dimenzijama nastavnih praksi nastavnika s obzirom na inicijalno obrazovanje* 263
Tablica 3. 25: *Analiza varijance u dimenzijama nastavnih praksi nastavnika s obzirom na radni staž* 264
Tablica 3. 26: *Post-hoc Scheffe analiza višestrukih usporedbi među grupama s obzirom na radni staž ispitanika* 264
Tablica 3. 27: *Analiza varijance u dimenzijama nastavnih praksi nastavnika s obzirom na stečenu dodatnu naobrazbu* 265
Tablica 3. 28: *Analiza varijance u dimenzijama nastavnih praksi nastavnika s obzirom na radno mjesto* 266

Tablica 4. 1: *Matrica korelacija između faktora dobivenih iz ljestvice uvjerenja nastavnika* 267
Tablica 4. 2: *Matrica korelacija između faktora dobivenih iz ljestvice samoprocjena nastavnika* 268
Tablica 4. 3: *Matrica korelacija između faktora dobivenih iz ljestvice nastavnih praksi nastavnika* .. 269
Tablica 4. 4: *Korelacije između dimenzija uvjerenja i samoprocjena nastavnika* 271
Tablica 4. 5: *Korelacije između dimenzija uvjerenja te nastavnih i izvannastavnih aktivnosti nastavnika* 272
Tablica 4. 6: *Korelacije između dimenzija samoprocjena te nastavnih i izvannastavnih aktivnosti nastavnika* 274
Tablica 4. 7: *Sažetak regresijskih analiza sa sociodemografskim podatcima i profesionalnim profilom nastavnika kao prediktorskim te sa stavovima i uvjerenjima kao kriterijskim varijablama* 278
Tablica 4. 8: *Sažetak regresijskih analiza sa sociodemografskim podatcima i profesionalnim profilom nastavnika kao prediktorskim te sa samoprocjenama nastavnika kao kriterijskim varijablama* 281

Tablica 4. 9: *Sažetak regresijskih analiza sa sociodemografskim podatcima i profesionalnim profilom nastavnika kao prediktorskim te s učestalošću nastavnih i izvannastavnih praksi kao kriterijskim varijablama*..... 284
Tablica 4. 10*: Sažetak regresijskih analiza sa sociodemografskim podatcima, profesionalnim profilom te uvjerenjima nastavnika kao prediktorima samoprocjena kompetencija nastavnika* 287
Tablica 4. 11: *Sažetak regresijskih analiza sa sociodemografskim podatcima, profesionalnim profilom te uvjerenjima i samoprocjenama nastavnika kao prediktorima nastavnih i izvannastavnih praksi nastavnika* 291

8. PRILOZI

Prilog 1 (Sociodemografski i osobni podatci nastavnika)

SPOL: M Ž DOB: _____ GODINE RADNOGA STAŽA: _____
1. Inicijalno obrazovanje: a) PMF (nastavnički smjer) b) PMF (inženjerski smjer) c) Učiteljski fakultet d) ništa od navedenog
2. Stečena dodatna naobrazba i profesionalno usavršavanje: a) profesor/učitelj mentor b) profesor/učitelj savjetnik c) magisterij ili doktorat znanosti d) ništa od navedenoga
3. Županija u kojoj radim je _____
4. Radim u: a) osnovnoj školi (razredna nastava) b) osnovnoj školi (predmetna nastava) c) srednjoj strukovnoj školi d) gimnaziji e) visoko učilište ili fakultet

Prilog 2 (Ljestvica uvjerenja nastavnika o nastavi i obrazovanju općenito te o specifičnostima i problematičnim područjima matematičkog obrazovanja**)**

U priloženoj tablici nalaze se tvrdnje koje se odnose na stavove o kompetencijama nastavnika matematike te o nastavi matematike. Zaokružite broj koji najbolje izražava Vaše mišljenje: (1 = uopće se ne slažem; 2 = ne slažem se; 3 = niti se slažem niti se ne slažem; 4 = slažem se; 5 = u potpunosti se slažem)

1.1 Nastava matematike trebala bi se više temeljiti na rješavanju problemskih zadataka nego na standardnim proceduralnim zadatcima.	1 2 3 4 5
1.2 Korištenje didaktičkih materijala i pomagala potrebno je zbog unaprjeđenja kvalitete procesa učenja i poučavanja matematike.	1 2 3 4 5
1.3 Prostorna organizacija razrednog odjela utječe na kvalitetu učenja i poučavanja.	1 2 3 4 5
1.4 Matematički način razmišljanja ima veću obrazovnu vrijednost od usvojenosti pojedinih matematičkih sadržaja.	1 2 3 4 5

1.5 Grupnim oblicima rada postižu se kvalitetniji odgojni ishodi nego frontalnim oblikom rada.	1 2 3 4 5
1.6 Grupnim oblicima rada postižu se kvalitetniji obrazovni ishodi nego frontalnim oblikom rada.	1 2 3 4 5
1.7 Svladavanje matematičkih sadržaja potrebno je kako bi učenici mogli logički razmišljati i zaključivati u različitim situacijama iz svakodnevice.	1 2 3 4 5
1.8 Nastavni proces treba se planirati prema smjernicama iz Nacionalnog okvirnog kurikuluma.	1 2 3 4 5
1.9 Primjenjivost matematičkih znanja unutar matematike ima prioritet nad primjenjivošću u svakodnevnim situacijama.	1 2 3 4 5
1.10 Ostvarivanje korelacija matematičkih sadržaja sa svakodnevnim životom podiže kvalitetu usvojenih znanja.	1 2 3 4 5
1.11 Korelacije matematike s ostalim predmetima i disciplinama nužne su za podizanje kvalitete učenja.	1 2 3 4 5
1.12 Povijesni razvoj matematike nedovoljno je zastupljen u nastavi matematike.	1 2 3 4 5
1.13 Učenik prosječnih sposobnosti može imati ocjenu „odličan“ iz matematike u osnovnoj školi.	1 2 3 4 5
1.14 Učenik prosječnih sposobnosti može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji.	1 2 3 4 5
1.15 Učenik koji ima problema s računanjem- tablicom množenja ne može imati ocjenu „odličan“ u prirodoslovno-matematičkoj gimnaziji.	1 2 3 4 5
1.16 Matematički daroviti učenici imati će uspješnu karijeru u matematici bez obzira na potporu okoline.	1 2 3 4 5
1.17 Razvijene radne navike i motivacija dovoljni su za visoke uspjehe u matematičkim natjecanjima.	1 2 3 4 5
1.18 Matematički daroviti učenici motiviraniji su za učenje matematike od ostalih učenika.	1 2 3 4 5
1.19 Učenici nisu bolji matematičari od učenica.	1 2 3 4 5
1.20 Komunikacija između nastavnika utječe na kvalitetu njihova rada s učenicima.	1 2 3 4 5

U kojoj se mjeri slažete kako je za kvalitetnu nastavu matematike potrebno da nastavnik: (1 = uopće se ne slažem; 2 = ne slažem se; 3 = niti se slažem niti se ne slažem; 4 = slažem se; 5 = u potpunosti se slažem)

1.21 Uvažava individualne razlike pri ocjenjivanju i očekivanjima koje postavlja pred učenike.	1 2 3 4 5
1.22 Daje učenicima anonimni evaluacijski upitnik kako bi iznijeli svoje kritike, mišljenja i prijedloge o aktivnostima te načinima rada u nastavi.	1 2 3 4 5
1.23 Poznaje socio-kulturni i ekonomski status učenika i njihovih roditelja.	1 2 3 4 5
1.24 Posjeduje visoko razvijene komunikacijske vještine.	1 2 3 4 5
1.25 Koristi humor u poučavanju matematike.	1 2 3 4 5
1.26 Potiče pozitivne stavove prema učenju matematike.	1 2 3 4 5
1.27 Zna kako ukloniti i prevenirati negativne stavove i uvjerenja učenika u kontekstu nastave matematike.	1 2 3 4 5
1.28 Smatra kako svaki učenik može zavoljeti matematiku.	1 2 3 4 5
1.29 Smatra kako učenici moraju voljeti matematiku da bi bili uspješni u njoj.	1 2 3 4 5
1.30 Razumije opće i specifične ciljeve Nacionalnog okvirnog kurikuluma.	1 2 3 4 5
1.31 Razumije temeljne smjernice koncepta cjeloživotnog učenja.	1 2 3 4 5
1.32 Razumije odgojno-obrazovne ciljeve i učenička postignuća po svim obrazovnim ciklusima matematičkog područja.	1 2 3 4 5

Prilog 3 (Ljestvica samoefikasnosti nastavnika**)**

U priloženoj se tabeli nalaze tvrdnje koje se odnose na vaš odgojno-obrazovni rad. Zaokružite broj koji najbolje opisuje vaša znanja te način na koji radite: (1 = uopće se ne slažem; 2 = ne slažem se; 3 = niti se slažem niti se ne slažem; 4 = slažem se; 5 = u potpunosti se slažem)

2.1 Posjedujem znanja o naprednim matematičkim temama koje nisu dio školske matematike.	1 2 3 4 5
2.2 Razumijem povijesnu i društvenu ulogu matematike u znanosti, kulturi, umjetnosti i tehnologiji te njezin potencijal za budućnost društva.	1 2 3 4 5
2.3 Razumijem prednosti i nedostatke pojedinih oblika i načina poučavanja kojima se koristim u nastavi.	1 2 3 4 5
2.4 Imam duboko razvijena konceptualna znanja matematike.	1 2 3 4 5
2.5 Osjećam se kompetentnim za pripremu nadarenih učenika za državno natjecanje.	1 2 3 4 5
2.6 Razumijem temeljna načela alternativnih pedagoških koncepata i njihove primjene u nastavi matematike.	1 2 3 4 5
2.7 Posjedujem znanja o interesima svojih učenika.	1 2 3 4 5
2.8 Upoznat sam sa socio-kulturnim i ekonomskim statusom svojih učenika.	1 2 3 4 5
2.9 Uvažavam socijalne i kulturne razlike učenika u nastavnim aktivnostima kao i kod ocjenjivanja i očekivanjima koje postavljam pred njih.	1 2 3 4 5
2.10 Uočavam odnose učenika u razredu te kako oni utječu na njihovu aktivnost u nastavi matematike	1 2 3 4 5
2.11 Razumijem prirodu i vrste specifičnih teškoća s kojima se učenici suočavaju u nastavi matematike.	1 2 3 4 5
2.12 Svjestan sam motivacije kojom moji učenici pristupaju matematici.	1 2 3 4 5
2.13 U nastavi uočavam tempo kojim učenici svladavaju matematičke sadržaje.	1 2 3 4 5
2.14 Znam prepoznati učenika koji ima diskalkuliju.	1 2 3 4 5
2.15 Znam kako ukloniti i prevenirati probleme u učenju matematike.	1 2 3 4 5
2.16 Uočavam emocije učenika u nastavnim aktivnostima.	1 2 3 4 5
2.17 Razumijem osnovna načela u radu s nadarenim učenicima.	1 2 3 4 5
2.18 Razumijem temeljne smjernice koncepta cjeloživotnog učenja te ulogu matematičkog područja u tom kontekstu.	1 2 3 4 5
2.19 Razumijem opće i specifične ciljeve te smjernice Nacionalnog okvirnog kurikuluma.	1 2 3 4 5

2.20 Nastavni proces organiziram prema odgojno-obrazovnim ciljevima pojedinih područja matematike zadanih Nacionalnim okvirnim kurikulumom.	1 2 3 4 5

Prilog 4 (Ljestvica učestalosti nastavnih praksi te učešće u profesionalnom razvoju i usavršavanju**)**

Za sljedeći niz pitanja odaberite broj koji opisuje učestalost vaših nastavnih aktivnosti, metoda te aktivnosti u profesionalnom razvoju i usavršavanju:
(1= nikad/gotovo nikad; 2 = rijetko; 3 = ponekad; 4 = često; 5 = uvijek/gotovo uvijek)

2.21 Pohađam stručno-metodičke skupove i (među)županijska vijeća.	1 2 3 4 5
2.22 Sudjelujem u projektima mobilnosti nastavnika.	1 2 3 4 5
2.23 Sudjelujem u projektima kolegijalnog opažanja zajedno s drugim nastavnicima.	1 2 3 4 5
2.24 Uspješnost svog rada evaluiram prema ciljevima iz Nacionalnog okvirnog kurikuluma.	1 2 3 4 5
2.25 Evaluiram i procjenjujem uspješnost svojeg poučavanja na kraju sata.	1 2 3 4 5
2.26 Sudjelujem u akcijskom istraživanju zajedno s kolegama i učenicima.	1 2 3 4 5
2.27 Učenicima dajem anonimni evaluacijski upitnik kako bi iznijeli svoje kritike, mišljenja i prijedloge o aktivnostima te načinima unapređenja nastavnog procesa.	1 2 3 4 5
2.28 U nastavi ističem da svaki učenik može biti uspješan u matematici.	1 2 3 4 5
2.29 Ukazujem na važnost upornosti i radnih navika za uspjeh u matematici.	1 2 3 4 5
2.30 Potičem pozitivne stavove prema učenju matematike kod slabijih učenika.	1 2 3 4 5
2.31 U poučavanju matematike koristim se humorom.	1 2 3 4 5
2.32 Individualno radim s učenicima koji sporije usvajaju sadržaje.	1 2 3 4 5
2.33 Preventivno djelujem i pomažem učenicima koji imaju negativne stavove prema učenju matematike.	1 2 3 4 5
2.34 Uočavam specifične reakcije kada učenici ne razumiju pojedine sadržaje.	1 2 3 4 5
2.35 Koristim informatičke i komunikacijske tehnologije u poučavanju matematike.	1 2 3 4 5
2.36 Pratim znanstvene inovacije u matematici.	1 2 3 4 5
2.37 Koristim stvarne životne situacije kao polazište za učenje i poučavanje.	1 2 3 4 5

2.38 U nastavi rješavam problemske zadatke povezane sa svakodnevicom.	1 2 3 4 5
2.39 Odgojno-obrazovne aktivnosti temeljim na frontalnom obliku rada.	1 2 3 4 5
2.40 Učenike uključujem u nastavne aktivnosti formiranjem u grupe i timove.	1 2 3 4 5
2.41 Učenici usvajaju matematičke sadržaje radom u paru.	1 2 3 4 5
2.42 Ostvarujem korelacije matematike s ostalim predmetima i disciplinama.	1 2 3 4 5
2.43 Objašnjavam matematičke sadržaje, koncepte i procese jednostavnim jezikom koji učenici razumiju.	1 2 3 4 5
2.44 Prilagođavam metode poučavanja tipičnim greškama i teškoćama učenika.	1 2 3 4 5
2.45 Dajem učenicima da sami odaberu aktivnosti i način rada u nastavi.	1 2 3 4 5

9. ŽIVOTOPIS

Zoran Horvat rođen je 23. kolovoza 1986. godine u Varaždinu. Osnovnu školu i prirodoslovno-matematičku gimnaziju završio je u Varaždinu. Studij matematike na Prirodoslovno-matematičkom fakultetu u Zagrebu završio je 2011. godine, te je stekao titulu magistra edukacije matematike. Poslijediplomski doktorski studij pedagogije na Filozofskom fakultetu Sveučilišta u Zagrebu upisao je 2012. godine. Od 2011. do 2018. godine radio je kao nastavnik matematike u srednjoj školi. Od 2016. godine radio je kao vanjski suradnik Centra za obrazovanje nastavnika, a od 2017. godine kao vanjski suradnik Odsjeka za pedagogiju Filozofskog fakulteta Sveučilišta u Zagrebu. Od 2018. godine zaposlen je kao asistent na Odsjeku za pedagogiju Filozofskog fakulteta Sveučilišta u Zagrebu na katedri za sistematsku pedagogiju. Područja njegova interesa su: didaktika, područje matematičkog obrazovanja te statistika i metodologija pedagogijskih istraživanja.

Popis radova i predavanja

[1.] Horvat, Z. (2013), *Pedagoške kompetencije nastavnika matematike*, Deseti susret pedagoga Hrvatske- znanstveno-stručni skup s temom „Pedagoške kompetencije u suvremenom kurikulumu“, Zadar, (predavanje).

[2.] Horvat, Z. (2014), *Kompetencije suvremenog nastavnika matematike, 6.* Kongres nastavnika i učitelja matematike, Zagreb.
(objavljeni sažetak u zborniku radova)

[3.] Horvat, Z., Kolak, A. (2014), *Teaching mathematics and mathematically gifted students*, TEACHER International Journal of Education, University „St. Kliment Ohridski“ Faculty of Education, Bitola, Vol. 7, 262-271 (objavljeni rad s međunarodnom recenzijom).

[4.] Horvat, Z. (2015), *Issues in contemporary teaching of mathematics and teacher competencies*, International Scientific Colloquium Mathematics and Children (Higher goals in mathematics education), Osijek, 176-187.
(predavanje i objavljeni rad s međunarodnom recenzijom).

[5.] Horvat, Z. (2015), *Emocije učenika u nastavi matematike*, Doktorska konferencija za studente poslijediplomskih doktorskih studija pedagogije i obrazovnih znanosti, DOKON, Filozofski fakultet u Rijeci.
(Predavanje i objavljeni sažetak s recenzijom).

[6.] Horvat, Z. (2016), *Didaktičko-metodička vrijednost video-instrukcija u nastavi matematike*, Didaktički izazovi II- Je li novo staro?, Osijek.
(predavanje i objavljeni sažetak)

[7.] Horvat, Z. (2016), *Motivacija u suvremenoj nastavi matematike*, Kongres nastavnika i učitelja matematike, Zagreb.
(dva održana predavanja za srednje i osnovne škole te objavljeni sažetak)

[8.] Horvat, Z. (2017), *Standardization of learning outcomes in teaching mathematics*, International Scientific Colloquium Mathematics and Children (Teaching and Learning Mathematics), Osijek.
(predavanje i objavljeni rad s međunarodnom recenzijom)

[9.] Horvat, Z. (2018), *Motivacija u suvremenoj nastavi matematike*, Poučak: časopis za metodiku i nastavu matematike, Zagreb.

[10.] Horvat, Z. (2018), *Pedagoške kompetencije nastavnika matematike*, 8. Kongres nastavnika i učitelja matematike, Zagreb.
(predavanje i objavljeni sažetak u zborniku radova)

[11.] Horvat, Z. (2018), *Problem darovitosti i obrazovanosti- distinktivnost STEM područja i implikacije na odgojno-obrazovnu praksu*. U: Vladimir Džinović, V. i Grbić, S: (ur.), *Kvalitativna istraživanja u društvenim naukama: od ličnog iskustva do socijalnih praksi*. XXIII naučna konferencija „Pedagoška istraživanja i školska praksa", zbornik radova. Filozofski fakultet Univerziteta u Beogradu.konferencija Pedagoška istraživanja i školska praksa", zbornik radova. Filozofski fakultet Univerziteta u Beogradu.
(predavanje i objavljeni rad s međunarodnom recenzijom)

[12.] Horvat, Z. (2019), *Special Needs in Mathematics Education,* Lena Lindenskov (ur.), 2016. Poučak: časopis za metodiku i nastavu matematike, Zagreb. (prikaz)

[13.] Horvat, Z. (2019), *Pedagoško savjetovanje i obrazovne perspektive učenika.* U: Knjiga sažetaka Konferencije Suvremene teme u odgoju i obrazovanju- STOO. Zagreb, Hrvatska.

[14.] Horvat, Z. (2019), *Razredni odjel kao referentna točka stavova i uvjerenja učenika u nastavi matematike.* U: Knjiga sažetaka Konferencije Suvremene teme u odgoju i obrazovanju- STOO. Zagreb, Hrvatska.