Kauzalne povezanosti informatičkih i matematičkih kompetencija u osnovnoj školi

Paić, Gordana

Doctoral thesis / Disertacija

2020

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:131:631478

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

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI



Sveučilište u Zagrebu

Filozofski fakultet

Gordana Paić

KAUZALNE POVEZANOSTI INFORMATIČKIH I MATEMATIČKIH KOMPETENCIJA U OSNOVNOJ ŠKOLI

DOKTORSKI RAD

Zagreb, 2020.



Sveučilište u Zagrebu

Filozofski fakultet

Gordana Paić

KAUZALNE POVEZANOSTI INFORMATIČKIH I MATEMATIČKIH KOMPETENCIJA U OSNOVNOJ ŠKOLI

DOKTORSKI RAD

Mentor: izv. prof. dr. sc. Krešimir Pavlina

Zagreb, 2020.



University of Zagreb

Faculty of Humanities and Social Sciences

Gordana Paić

CAUSAL INTERCONNECTION BETWEEN INFORMATICAL AND MATHEMATICAL COMPETENCES IN ELEMENTARY EDUCATION

DOCTORAL THESIS

Supervisor: Krešimir Pavlina, PhD - associate professor

Zagreb, 2020

INFORMACIJE O MENTORU

dr.sc. Krešimir Pavlina, izv. prof.

Životopis

Krešimir Pavlina rođen je u Zadru. Osnovnu školu i gimnaziju završio je u Zagrebu. Studij informatologije i pedagogije na Filozofskom fakultetu Sveučilišta u Zagrebu upisao je 2000. godine, a diplomirao je 2004. godine obranivši rad s područja opće informatologije. Godine 2008. obranio je doktorski rad na temu "Interoperabilnost sustava za elektroničko obrazovanje". Od prosinca 2009. godine zaposlen je kao docent na Odsjeku za informacijske znanosti Filozofskog fakulteta, a 2015. godine izabran je u znanstveno-nastavno zvanje izvanrednog profesora. Nositelj je kolegija Programiranje baze podataka, Projektiranje informacijskih sustava i Informacijske tehnologije u obrazovanju. Znanstveno proučava područja baza podataka, bibliometrije, elektroničkog učenja i metodike nastave informatike. Autor je dvadesetak znanstvenih i stručnih radova iz područja informacijskih znanosti. Aktivni sudionik dvadesetak međunarodnih znanstveno-stručnih skupova. Trenutno obnaša dužnost voditelja Centra za obrazovanje nastavnika pri Filozofskom fakultetu Sveučilišta u Zagrebu.

Popis radova u Hrvatskoj znanstvenoj bibliografiji (CROSBI)

Izvadak iz bibliografije:

1.Krešimir Pavlina, Gordana Paić, Božidar Tepeš, *MARKOV MODEL OF MATHEMATICAL COMPETENCES IN ELEMENTARY EDUCATION*, **Hrvatska udruga za informacijsku i komunikacijsku tehnologiju, elektroniku i mikroelektroniku - MIPRO**, Opatija, 2016.

2.Pavlina, Krešimir, Lasić-Lazić, Jadranka;; Pongrac, Ana, **Teaching Quality – Student perspective**
// ***Proceedings of papers from MIPRO 2010 / Čičin-Šain, Marina ; Uroda, Ivan ; Turčić Prstačić, Ivana ; Sluganović, Ivanka (ur.)***, Opatija : MIPRO, 2010., pp. 56 - 58

3.Krešimir Pavlina, Mihaela Banek Zorica, Ana Pongrac, **Student perception of teaching quality in higher education**, Procedia - Social and Behavioral Sciences (ISSN 1877-0428), Volume 15, 2011., pp. 2288 - 2292

4.Lasić-Lazić, Jadranka; Pavlina, Krešimir; Pongrac, Ana, **Software simulation as educational tool** // ***34th International Convention MIPRO 2011: Computers in Education / Čičin-Šain, Marina ; Uroda, Ivan ; Turčić Prstačić, Ivana ; Sluganović, Ivanka (ur.)***, Rijeka : Hrvatska udruga za informacijsku i komunikacijsku tehnologiju, elektroniku i mikroelektroniku, 2011., pp. 197 - 199

ZAHVALE

Zahvaljujem svojemu mentoru dr.sc. Krešimiru Pavlini, izv. prof.**,** koji mi je pomogao osmisliti i uobličiti temu mojega doktorskog rada te imao strpljenja i volje pratiti njegovo nastajanje.

Zahvaljujem svojim kolegicama, profesoricama i profesorima Matematike i Informatike, kao i administratorima e-imenika, koji su mi nesebično pomagali u provedbi istraživanja.

SAŽETAK

U suvremeno bi doba nastavni programi trebali biti usklađeni prema uzročno posljedičnim povezanostima srodnih predmeta, osobito predmeta iz STEM (Science, Technology, Engineering i Mathematics) područja. Kauzalna povezanost informatičkih i matematičkih kompetencija nije dosad posebno ispitivana, a posebno ne kod učenika osnovne škole u Republici Hrvatskoj.

Cilj je doktorskog istraživanja izrada kauzalnog modela povezanosti informatičkih i matematičkih sadržaja u osnovnoj školi što će pridonijeti ususatvljivanju potrebitih kompetencija kod učenika. Svrha je tako izrađenog modela stvoriti pretpostavke za izradu programa informatičkih i matematičkih sadržaja u osnovnoj školi, slijedeći jedni druge logički i razvojno. Model će također omogućiti uspoređivanje kvalitete usvojenosti matematičkih i informatičkih kompetencija učenika, kao i njihove povezanosti s ostalim kompetencijama učenika osnovne škole.

Očekivani znanstveni doprinos unutar informacijskih i komunikacijskih znanosti jest izrada kauzalnog modela povezanosti informatičkih i matematičkih kompetencija u osnovnoj školi koji može imati veliki značaj pri oblikovanju budućih nastavnih programa i može unaprijediti obrazovni proces u nastavi Informatike i Matematike. Ovaj će model omogućiti kauzalnu povezanost s IKT standardima u osnovnoj školi što je nastojanje onih obrazovnih sustava u svijetu koji nemaju nastavni predmet Informatika u osnovnoj školi.

Ključne riječi: *kauzalna povezanost, matematičke kompetencije, informatičke kompetencije, Bayesov model, kauzalni efekt*

ABSTRACT

Contemporary educational programs should be aligned with causal relations between school subjects, especially STEM subjects (Science, Technology, Engineering and Mathematics). So far, there has not been a separate research on causality between competence in computer science and competence in mathematics. This research attempts to help systematize the aforementioned competencies and provide the causality model illustrating the connection between computer science and mathematics. The causality model will enable the comparison of competence levels and contribute to developing educational programs for computer science and mathematics in primary school.

The research, along with the causality model illustrating the connection between computer science and mathematics, attempts to help systematize the aforementioned competencies.

The scientific contribution of this research to information and communication science can be seen in development of the model of causality between informatical competence and mathematical competence in primary school. This model can also have a significant role in developing future educational programs and improving the educational process.

'Informatics' is a concept which has been first suggested by Karl Steinbuch in 1957. At the time the concept has been often translated into English under the term 'computer/computing' science. Nowadays the concept itself as well as its variations have been in use, broadening as well as focusing on specific aspects of the scientific field (e.g. informatics, information technology, information-communication technology, computing science). Europe explains the Informatics concept in the following way: „the concept of informatics depends on the country which is using it“. However, the variety and richness of both definitions and contexts has given rise to difficulties in studies comparison.

Informatics in the context of primary education in the Republic of Croatia can also be studied through the expected and achieved informatics competences, which are defined by the National Curriculum Framework.

With regard to mathematics within the context of primary education worldwide in comparison to that in the Republic of Croatia, the situation is clearer. Stern and Döbrich (1999) emphasise three types of mathematical competences: 1) strategies used for arithmetic problem solving, 2) strategies used for arithmetic word problem solving and 3) proportional thinking (Stern & Döbrich, 1999). Preschool mathematical competencies not only have an impact on the competences which the children will exhibit in elementary school but can also serve as predictors of either well-developed competences or difficulties (Aunola et al, 2004; Bailey et al, 2014; Claessens i Engel, 2013; Claessens et al., 2009; Duncan et al., 2007; Jordan et al., 2009; Watts et al., 2014). Furthermore, taking into consideration that the development of mathematical competences and skills is hierarchical, Andersson (2008) emphasises eight mathematical fields with appropriate competences: 1) arithmetic fact retrieval, 2) written multidigit arithmetic calculation, 3) approximate arithmetic, 4) place value, 5) calculation principles, 6) one-step mathematic word problems, 7) complex multistep mathematic word problems and 8) time telling which competences have been outlined because the Author argues one competence implies another and that a much broader spectrum of competences need to be examined in order to have a clearer picture (Andersson, 2008).

On the other hand, the picture with informatics competences is not so clear. One of the concepts often used in this context is digital literacy. Erstad (2010) argues that the concept of digital literacy is too limited for modern age and should be expanded to media literacy, with the following media literacy aspects parts of school curriculum: 1) basic skills, 2) media as a focus of analysis, 3) knowledge gathered within specific domains i.e. school subjects, 4) cultural competence (Erstad, 2010). Literacy skills of the 21st century is another concept which is in use, which Jenkins et al (2006) explain through its aspects: play, performance, simulation, appropriation, multitasking, disturbed cognition, collective intelligence, judgement, transmedia navigation, networking and negotiation (Jenkins et al, 2006). Furthermore, digital competencies are mentioned as one of the eight key competencies in the document 'Key competences for Lifelong learning' issued by the European Union in 2010, which is defined in the following way: "digital competence includes confident and critical use of the ICT for work, fun and communication. It is supported by the basic ICT skills: the use of computers in order to gather information, evaluate it, store, present and exchange information, communicate and participate in networks (European Union, 2010).

One of the questions which arises from the study of informatics and mathematical competences within the context of primary education is how the two of them are connected, which mathematical competences imply informatics competences and lastly, what all of this means for primary education? It can be said that logical thinking, formal writing and mathematical logic are very important for informatics, just as the use of mathematical software in classrooms can improve deeper understanding of mathematical concepts as well as offer the pupils a tool for learning through experimentation. Problem-solving as a mathematical competence is closely related to computational thinking (Wing, 2011), whereas some authors consider that even though computational thinking is closely related to elements of engineering, mathematics and other natural sciences, it is different due to its focus on information processing (Denning & Freeman, 2009; pg. 30). Joint Research Centre, which is a part of the European Committee for science and knowledge emphasises the need to integrate computational thinking into primary education. The authors outline several basic skills of which the parts of computational thinking are: subtraction, algorithmic thinking, automation, decomposition and generalisation (Bocconi et al., 2016).

Given all the research done on informatics and mathematical competences the implication would be to create models which would graphically represent their interconnectedness as well as which competences imply which. In 2010 Cartelli, Dagiene and Futschek created a model in order to assess digital literacy as a part of the Bebras contest (an IT/ICT contest for children). The authors developed a questionnaire which they called 'digital literacy assessment', focusing on the following areas: 1) recognising possible solutions to technological problems and choosing the appropriate one, as well as differentiating between real and virtual phenomena, 2) working with text, data organisation, choosing and interpreting text as well as assess relevance and reliability of information, 3) respect toward others within the virtual community and understanding of social and technological differences (Cartelli et al, 2010). Haspekian and Bruillard (2010) on the other hand, focused, within the scope of DidaTab (spreadsheet didactics), on examining the connection between the use of spreadsheets and mathematics and the pupils' competences. Comparing the elements of algebra and the elements found in work with spreadsheets (such as e.g. MS Excel) the authors outline several equivalents: 1) objects: unknowns and equations/variables and formulae, 2) pragmatic potential: problem solving tools/generalisation tools, 3) solving process: the

application of algebraic rules/arithmetic process of trial and error and 4) the nature of solution: correct solutions/correct or approximate solutions. The sample consisted of 13 pupils aged 17 attending vocational school and the authors administered a test to be done on computers with the aim to assess the pupils' abilities to work with spreadsheets. After analysing the results, the authors came to the conclusion that there was a lack of understanding of algebraic concepts because the use of formulae in spreadsheets requires understanding of the sheer concept of a variable within the same environment (Haspekian & Bruillard, 2010). Similarly, Haspekian did a research within the scope of which he presented introduction to algebra through the use of spreadsheets to a sample of 7^{th} grade elementary school pupils. He outlined the following difficulties: understanding formulae and the increment tool (sequence continuation). The author argued that algebraic i.e. mathematical concepts were kept within the frames of traditional mathematics education and that the concepts themselves are not explained nor analysed in depth which is clearly observable on the pupils' inability to apply them in a different environment (i.e. a spreadsheet) (Haspekian, 2005).

In statistics nowadays the use of the term causality is being used more and more often as a tool for explaining interconnectedness. Causality can be described as a difference between actual results and results which did not occur (Clemens, 2017). By studying causal connection between variables we arrive to a causal structure, which is defined as an oriented graph on which each edge between e.g. variables X and Y, oriented as X->Y represents a causal connection between variable X as cause and Y as effect. Simplified research which studies causality demands having a sample, which needs to be big enough as well as meet the conditions to be representative of population, divided into control and experimental group. A randomised experiment demands of the variables to be directly observable, that it is possible to intervene and that the sample is large enough in order to correctly show the effect of opposite action.

When it is impossible to intervene or change variables, but which are observable, statistics resorts to the concept of correlation which determines whether two variables within a data set are behaving in a similar way, but correlation does not imply causality (Clemens, 2017).

One of statistical models often in use is Bayes' model. Bayes' classifiers predict the probability of belonging to a certain class, with one of the reasons for their popularity having a high accuracy percentage as well as speed when applied to large data sets. Bayes' networks are graphic models which enable the representation of dependence between attribute subsets, but which, at the same time ,can be used for classification. They enable creating a graphic model of causal connections (Han, Pei & Kamber, 2011). The advantage of Bayes' concepts and methods are that they can include prior information and technical concepts without appropriate data and enable studying the cause and effect connections, apart from the simple studying of correlation (Wang & Amrhein, 2018). During the past thirty years researchers have used Bayes' networks in order to uncover causal structures within the mass of statistical data, contrary to the presumption that this is feasible only within the environment of carefully controlled experiments (Pearl & Verma, 1995; Spirites et al, 2000; Pearl, 2003).

The sample for our research comprised of 21 elementary schools in the Republic of Croatia, with 9 from the rural and 12 from urban areas. The participants were 1000 pupils attending 5^{th}, 6^{th}, 7^{th} and 8^{th} grades, under the presumption that there were at least 10-15 pupils within a school per each generation attending informatics as an elective subject. The pupils were 10-11 years old (5^{th} grade), 11-12 years old (6^{th} grade), 12-13 years old (7^{th} grade) and 13-14 years old (8^{th} grade) of both genders. Background questionnaire has been administered among teachers in spring 2018 for the school year 2016/2017, which consisted of socio-demographic data (age, gender, rural/urban school), final grades in all subjects, average final grades, grades achieved on mathematical and informatics tests in 5-6 individual topics according to the National Plan and Programme for the subject mathematics and elective subject informatics. The basic research aim has been to measure the frequency, interdependency, dependence and interconnectedness between informatics and mathematical competences. The hypotheses were: 1) to examine whether a statistically significant correlation between final grades in informatics and mathematics within each grade exists, 2) to examine whether a statistically significant correlation between grades in specific mathematics and informatics topics within each grade exists, 3) to examine whether statistically significant difference between the final grade in mathematics and final grade in informatics exists as well as correlation between the final grade in mathematics and final grades in other subjects and average final grade exist within each grade, 4) to examine whether causal connection between a) informatics and mathematics grade within each grade exists, b) mathematics grade and average final grade

within each grade exists, c) informatics and average final grade within each grade exists and d) specific topics within the mathematics and informatics curriculum exists.

The pupils achieve statistically significantly higher average grades in educational compulsory subjects, with average higher grades in informatics following. No correlation between the final grades in informatics and mathematics in each grade has been found. Furthermore, the hypothesis ‘correlation between final mathematics and informatics grades is statistically significantly higher than the correlation between the final mathematics grade and final grades in other subjects, as well as average final grade’ has not been corroborated. In fifth grade, no correlation has been found between average final grade and final grade in informatics, but has been found between average final grade and final grades in other subjects. In sixth, seventh and eighth grade correlation has been found between average final grade and final grade in informatics.

With regard to correlations between acheivements in chosen topics in mathematics and informatics, a positive correlation between grades in ‘drawing with the help of computer’ and ‘natural numbers’ in fifth grade as well as a small but negative correlation between the grades in ‘text processing’ and ‘linear equations with one unknown’ in sixth grade. Therefore the hypothesis that a statistically significant correlation between grades in specific topics in informatics and mathematics exists has not been corroborated. Statistically significant difference in average grade in informatcs has been found in fifth grade which is higher in rural schools.

Comparing the created causal model for chosen topics in informatics and the school curriculum, several discrepancies have been found. In fifth grade, discrepancies have been found with regard to the following causal connection: basic 2D geometry -> drawing with the help of computer, decimal numbers (mathematics) -> programming (LOGO) (informatics), basic 2D geometry -> first steps in working with computers, basic 2D geometry -> storage and computer equipment. In sixth grade, only one discrepancy has been found: quadrangle -> multimedia, whereas in seventh grade the following discrepancies have been found: linear equations systems -> programming (LOGO), similarities and polygons -> programming (LOGO), proportionality and inverse proportionality -> programming (LOGO), similarity and polygons -> coordinate system, linear functions -> spreadsheets and linear functions -> linear

equation systems. And finally, in eighth grade, discrepancies with regard to the following causal connections have been found: presentations -> basic 3D geometry, real numbers -> programming (LOGO), isometry -> programming (LOGO), internet -> databases, Pythagorean theorem -> fundamentals of informatics, geometrical bodies -> programming and isometry -> programming.

Scientific contribution of this doctoral thesis is the creation of the causal model for the chosen topics from the curriculum for mathematics and informatics, which contributes to theoretical understanding of the mutual connection between school topics, as well as enabling a better logical and organisational structuring of school topics within the subjects of mathematics and informatics during macro (school curriculum) or micro (specific topics within the school subjects) planning. Furthermore, the created causal model offers specific examples of discrepancies between certain school topics between the subjects of mathematics and informatics, but also within the subjects of mathematics and informatics, which has been shown by the causal models.

Similar causal models can be created for other school subjects, which would guarantee exact criteria for checking quality of the created curriculum which would be more adapted to the pupils' age as well as their cognitive abilities, but also expose the need to remove some topics from the curriculum because they bring connection with other topics into question and to structure the topics via micro and macro planning. This is especially important for introducing new information into the educational system in order to check the connection with other topics by creating causal models, as well as testing the mutual connection of topics and information. The information science therefore gain a new instrument – causal model, in order to ensure the quality of planning and information structuring as well as context within the educational process.

Keywords: *causality, mathematical competences, informatics competences, Bayes' model, causal effect*

SADRŽAJ

UVOD 1

1 POVEZANOST KOMPETENCIJA U INFORMATICI I MATEMATICI UNUTAR PRIMARNOG OBRAZOVANJA 3

1.1 Različite definicije koncepata informatike, računarstva i informacijsko-komunikacijske tehnologije te njihova konvergencija 3

1.2 Matematičke kompetencije u primarnom obrazovanju 8

1.3 Informatičke kompetencije (digitalne kompetencije, računalna pismenost) 27

1.4 Matematičke kompetencije kao implikacija digitalno/informatičkih 30

2 MATEMATIČKE I INFORMATIČKE KOMPETENCIJE TE NASTAVA MATEMATIKE I INFORMATIKE U PRIMARNOM OBRAZOVANJU U REPUBLICI HRVATSKOJ 344

2.1 Definicija i opis informatičkih i matematičkih kompetencija za više razrede osnovne škole prema Nacionalnom okvirnom kurikulumu 344

2.1.1 Uvod 34

2.2 Matematičke i informatičke kompetencije opisane u Nacionalnom okvirnom kurikulumu 35

2.2.1 Prikažimo grafički kompetencije koje se pojavljuju u oba ciklusa: 36

2.3 Nastavni plan i program za predmete Matematika i Informatika u osnovnoj školi 36

3 MODELI KOMPETENCIJA 37

3.1 Uvod 37

3.2 Relevantne studije modela kompetencija 40

4 METODOLOGIJA ISTRAŽIVANJA 45

4.1 Uzorak istraživanja 45

4.2 Mjerni instrumenti 47

4.3 Postupak istraživanja 48

4.4 Cilj istraživanja 49

4.5 Problemi i hipoteze istraživanja 49

5 REZULTATI ISTRAŽIVANJA 53

5.1 Deskriptivna statistika mjerenih varijabli 53

5.1.1 Pojedinačni predmeti 53

5.1.2 Područja unutar Matematike i Informatike 83

5.1.2.1 Peti razred 85

5.1.2.2 Šesti razred 100

5.1.2.3 Sedmi razred 115

5.1.2.4 Osmi razred 130
5.2 Povezanosti između završnih ocjena iz Informatike i Matematike 150
5.3 Povezanosti između završnih ocjena pojedinih gradiva Informatike i Matematike 159
5.4 Povezanosti između završnih ocjena iz Informatike i Matematike u odnosu na povezanost završnih ocjena iz Matematike i ostalih predmeta 161
5.5 Kauzalna povezanost obrazovnih postignuća učenika viših razreda osnovne škole 161
5.5.1 Peti razred 162
5.5.2 Šesti razred 165
5.5.3 Sedmi razred 167
5.5.4 Osmi razred 170
5.6 Razlike po spolu 173
5.6.1 Peti razred 174
5.6.2 Šesti razred 175
5.6.3 Sedmi razred 176
5.6.4 Osmi razred 177
5.7 Razlike po vrsti škole 179
5.7.1 Peti razred 180
5.7.2 Šesti razred 181
5.7.3 Sedmi razred 182
5.7.4 Osmi razred 183
6 DISKUSIJA 185
6.1 Provjera hipoteza 186
6.1.1 Prva hipoteza (H1) 186
6.1.2 Druga hipoteza (H2) 187
6.1.3 Treća hipoteza (H3) 188
6.1.4 Četvrta hipoteza (H4) 190
ZAKLJUČAK 196
Znanstveni doprinos 197
LITERATURA 198
PRILOG A Matematičke kompetencije opisane u NOK-u 210
PRILOG B Informatičke kompetencije opisane u NOK-u 216
PRILOG C Nastavni plan i program za predmet Matematika u višim razredima 220
PRILOG D Nastavni plan i program za predmet Informatika u višim razredima 231
ŽIVOTOPIS AUTORA S POPISOM OBJAVLJENIH DJELA 239

UVOD

Cilj je ovoga doktorskog rada ukratko ispitati povezanosti između matematičkih i informatičkih kompetencija učenika petog do osmog razreda osnovne škole (u daljnjem tekstu: viši razredi) te kreirati kauzalni model povezanosti specifičnih tema iz nastave Informatike i Matematike za više razrede.

U prvom će se poglavlju ovog doktorskog rada izložiti različite definicije samih pojmova Informatike i Matematike, počevši s definicijama tih, ali i njima sličnih, pojmova koji se upotrebljavaju u svijetu. Zatim će se ispitati pojmovi matematičkih te informatičkih kompetencija kako u Republici Hrvatskoj tako i u svijetu, te slične pojmove upotrebljavane unutar konteksta primarnog obrazovanja. Na kraju će se poglavlja razmotriti međusobna povezanost matematičkih i informatičkih kompetencija te dati pregled relevantnih istraživanja i studija vezanih uz spomenutu tematiku.

U drugom će se poglavlju izložiti te analizirati za ovaj doktorski rad relevantne kurikulume, a to su Nacionalni okvirni kurikulum te Nastavni plan i program za više razrede osnovne škole, koji su izabrani kao dobna skupina i uzorak provedenog istraživanja. Cilj je ovog poglavlja kratko izložiti opisane matematičke i informatičke kompetencije koje su navedene kao cilj matematičkog i informatičkog obrazovanja za svaki viši razred te izložiti pojedine teme koje se prema nastavnom planu i programu obrađuju u svakom pojedinom razredu, što je od važnosti za analizu dobivene deskriptivne statistike, ali i kreiranog kauzalnog modela.

Treće se poglavlje fokusira na izlaganje različitih modela kompetencija stvorenih unutar studija i istraživanja u svijetu, te dobivenih rezultata.

U četvrtom će se poglavlju izložiti sama metodologija provedenog istraživanja te će se navesti uzorak istraživanja, upotrebljavani mjerni instrumenti, postupak istraživanja te problemi i hipoteze istraživanja.

Peto poglavlje je detaljan pregled rezultata istraživanja. U prvom je potpoglavlju deskriptivna statistika mjerenih varijabli i pregled deskriptivne statistike po pojedinačnim predmetima, područjima (odabranim nastavnim temama) unutar predmeta Matematika i informatika za svaki pojedini razred. Nadalje, drugo je potpoglavlje istraživanje povezanosti između završnih ocjena iz Matematike i informatike, u trećem potpoglavlju povezanosti između završnih ocjena pojedinih tema iz Matematike i informatike te u četvrtom potpoglavlju povezanosti između završnih ocjena iz informatike i Matematike u odnosu na povezanost završnih ocjena iz Matematike i ostalih predmeta. U petom su potpoglavlju opisi modela kauzalnih povezanosti između odabranih tema iz Matematike i informatike za svaki pojedini viši razred te su dobiveni kauzalni modeli detaljno analizirani /uspoređivani s nastavnim planom i programom. Nadalje, u šestom je potpoglavlju pregled razlika po spolu za svaki pojedini razred, a u sedmom potpoglavlju pregled razlika po pohađanoj školi (urbana ili ruralna).

U šestom je poglavlju analiza dobivenih rezultata te pregled hipoteza i argumenata za njihovo prihvaćanje ili odbacivanje.

Zaključak predstavlja analizu provedenog istraživanja te mogućnosti za njegovo proširivanje i poboljšanje, zaključno s izlaganjem znanstvenog doprinosa ovog doktorskog rada te opisanog istraživanja.

Na kraju je naveden popis literature upotrebljavane tijekom pisanja ovog doktorskog rada, kratki životopis autora, zajedno s popisom znanstvenih i stručnih radova, te relevantnijih autorskih bibliografskih jedinica.

1 POVEZANOST KOMPETENCIJA U INFORMATICI I MATEMATICI UNUTAR PRIMARNOG OBRAZOVANJA

1.1 Različite definicije koncepata informatike, računarstva i informacijsko-komunikacijske tehnologije te njihova konvergencija

Prije nego što se okrenemo samim definicijama kompetencija u poljima informatike i matematike te njihovoj međusobnoj povezanosti, valjalo bi dati kratki pregled samih definicija informatike i računarstva. Iako je posve jasno da ta dva koncepta nisu sinonimi, definicije i njihove domene variraju u svijetu. Također je jasno, da u nekim slučajevima nije moguće povući jasnu liniju između njih, kao što je to vrlo često slučaj između grana znanosti koje su srodne. No, je li upotreba jednog ili drugog termina problem s njihovim samim definicijama ili problem leži u lingvističkim zaprekama?

Informatika *(eng. informatics*) je prvotno bio termin koji je, godine 1957., predložio njemački znanstvenik Karl Steinbuch u njegovom radu pod naslovom 'Informatika: automatsko procesuiranje informacija' (u originalu: *Informatik: Automatische Informationsverarbeitung*). Termin 'informatika' je s njemačkog jezika u to vrijeme često bio prevođen na engleski kao 'computer science' ili 'computing science'. Godine 1958. Steinbuch je osnovao Institut za procesuiranje informacija na Fakultetu u Karlsruhe (Institut für Nachrichtenverabeitung) gdje se nastavlja baviti područjem informatike. (karl-steinbuch.org).

Kako se termin 'informatika' internacionalno često slobodno prevodi, dolazi do zamjena s terminom 'računarstva' (*computer science*). Neke zemlje također skeptično gledaju na termin 'computer science' zbog nejasnoća oko prave domene njenih aspekata. Nadalje, Coy (1997) piše: „Dok su računarsko inženjerstvo (*computer engineering*) i informacijska znanost (*information science*) kao termini prilično jasni u svojoj definiciji, termin 'računarstvo' (*computer science*) pomalo je zbunjujući. Na što se fokusira ta znanost, na hardware ili samo računalo? Kakva je onda razlika između računarstva i računarskog inženjerstva? Koja je razlika između računarstva i informatike? Philippe Dreyfus je 1962. godine uveo francuski termin 'informatique' ili 'électronique'. U Njemačkoj, tvrtka Standard Elektrik Lorenz, je već upotrebljavala termin 'Informatik' tijekom kasnih pedesetih godina te je dala ime

proizvođačkom pogonu Informatik-Werk (informatičko postrojenje), iako je ovaj naziv kasnije napušten. U Francuskoj se termin *informatique* upotrebljavao u francuskoj štampi kao generičko ime koje se povezivalo s računalima i automatikom.“ (Coy, 1997.)

S obzirom na njemačko govorno područje, razlike u definicijama i često zamjenjivanje termina računarstva i informatike, ponekad su još uvijek vidljive. Dok njemački fakulteti upotrebljavaju 'Informatik' i *computer science* kao sinonime (npr. Fakultät für Informatik se prevodi kao Faculty for Computer Science na Fakultetu Bonn, Magdeburg, TU Dresden), neki fakulteti u njemačkom govornom području prevode Informatik kao informatics (npr. TU Vienna, Karlsruhe Institute of Technology).

U vezi s etimološkim problemima i razlikama u definicijama, pogledajmo kako UNESCO/IFIP Kurikulum 2000 definira informacijsko-komunikacijsku tehnologiju (dalje: IKT), informatiku i računarstvo:

- 'informatika' (*computing science*): znanost koja se bavi s dizajnom, realizacijom, evaluacijom, upotrebom i održavanjem sustava informacijskog procesuiranja: uključujući hardware, software, organizacijske i ljudske aspekte te industrijske, komercijalne i političke implikacije (UNESCO/IBI),
- 'informacijska tehnologija': tehnološka primjena informatike u društvu,
- IKT: kombinacija informatičke tehnologije s drugim, povezanim tehnologijama, specifično komunikacijskim tehnologijama“ (van Weert i Tinsley, 2000).

Bez obzira na definicije termina dolazi do njihove konvergencije u kasnijem tekstu: „ove definicije se na kraju spajaju u jednu, sve-uključivu definiciju IKT. To implicira da će termin IKT biti upotrebljavan, primjenjivan i integriran u aktivnosti rada i učenja koji se baziraju na konceptualnom shvaćanju i metodama informatike“ (van Weert i Tinsley, 2000).

Rechenberg (2010) pristupa etimološkom problemu na sljedeći način: „Kada pitamo što je subjekt studija informatike, kojega ona proučava, kod prirodnih znanosti je to prilično jednostavno: fizika proučava neživu prirodu, kemija proučava kemijske promjene, biologija proučava živu prirodu. No, što proučava informatika?“ (Rechenberg, 2010).

Ako kažemo da je predmet proučavanja informatike sama informacija, pronalazimo ovdje bezbrojne primjene te izjave. Norveški informatičar Nygaard piše: „Informatika je znanost čiji su predmeti proučavanja informacijski procesi i srodni fenomeni u tehničkim produktima, društvu i prirodi“ (prema: Rechenberg, 2010.)

Kako bi dobili kompletniju sliku o kompleksnosti određivanja domene informatike te različitih definicija samoga koncepta, promotrimo gledišta njenih aspekata. Tehnička informatika definira informatiku kao kompjutersku tehniku, dok ju praktična informatika vidi kao tehniku programiranja. Teoretska ju informatika, s druge strane, vidi kao znanost o strojnom procesuiranju simbola. Korisnik, koji je fokusiran na tehničku stranu, vidi je kao tehniku automatizacije i simulacije uz pomoć računala, dok korisnik koji je fokusiran na komercijalnu stranu informatike vidi je kao procesuiranje podataka. I, na kraju, umjetna ju inteligencija vidi kao znanost o mehanizaciji razmišljanja. Integrirajući ove definicije i različite načine definiranja samog pojma informatike kao znanosti, Rechenberg (2010) dolazi do sljedećih definicija: „informatika je metoda automatizacije uz upotrebu računala“ i „informatika se bavi automatizacijom uz pomoć računala“ (Rechenberg, 2010).

Spomenimo još i pojam 'informatike u kontekstu'. Sam je pojam nemoguće spomenuti bez osvrtanja na pojam didaktike informatike, pri čemu se cijela tematika mora gledati kroz prizmu edukacije i nastave. Na kraju 1970-ih, pojam informatike u kontekstu pojavio se u sklopu kritike algoritamskog pristupa te potrebe da se uključi kontekst u informatiku. Koerber, jedan od zastupnika ovog pristupa, piše: „Ne bi se trebalo raditi o prikupljanju struktura, nego o orijentaciji na praksu. Time bi kontekst postao dijelom nastave.“ (Engbring i Pasternak, 2010)

Govoreći o konceptu informatike u kontekstu moramo govoriti o primjeni. Cilj je rješavanje problema kroz izgradnju modela i na kraju, programiranje, no, pri tome pristup koji zagovara primjenu, također cilja na programiranje zajedničkih poveznica primjene. Poanta integracije informatike u kontekstu u širu definiciju bio bi: ne problematizirati i odvajati društvene i algoritamske aspekte, nego ih u zajedničkoj izgradnji modela zbližiti i objediniti (Engbring i Pasternak, 2010). Forneck (1992) nadalje podsjeća da sami proces informatičkog rješavanja određenog problema i njegova implementacija zapravo uključuje i cijeli tim stručnjaka koji se ne sastoje samo od programera i informatičara, nego i od poslovnih ekonomista, medicinskih

stručnjaka, psihologa, pravnika itd., koji svi doprinose efektivnom rješavanju problema. Edukacijski je gledano stoga kontekst nastave informatike i njeno izvođenje nužno gledati u svjetlu primjene informatike u cijeloj svojoj kompleksnosti (Forneck, 1992).

Na tragu konvergencije same terminologije koncepta informatike i njenih podgrana, spomenimo i Informatics Europe, zajednicu koja zastupa akademske i istraživačke zajednice u Europi i susjednim zemljama. Između ostalih članova, članovi su ove organizacije u Republici Hrvatskoj: Fakultet elektrotehnike i računarstva u Zagrebu (FER) te Sveučilište u Rijeci, Odjel za informatiku. Informatics Europe, sa sjedištem u Zürichu, Švicarska, kao zajednica ima ciljeve:

- njegovati kvalitetu istraživanja u informatici,
- njegovati kvalitetu edukacije u informatici,
- njegovati prijenos znanja između akademskog svijeta i industrije i društva,
- sudjelovati zajedno s društvom u prirodi i utjecaju informatike,
- promovirati kvalitetne standarde i najbolje prakse u istraživanju, edukaciji i prijenosu znanja,
- održavati odnose između akademskog svijeta i vlade te javnih institucija,
- održavati kooperaciju s organizacijama koje imaju slične ciljeve.

No, Informatics Europe, koja prepoznaje kompleksnost tematike te različitih definicija samog pojma informatike, objašnjava ga na sljedeći način: „koncept informatike ovisi o zemlji koja ga upotrebljava, računarstvo, računarski inženjering, informacijske tehnologije (IT), IKT“ (http://www.informatics-europe.org/).

Okrenimo se sada pojmu računarstva (computer science, computing science). Donald Knuth 1974. godine u svojoj knjizi 'Računarstvo i njena povezanost s Matematikom' piše da je „računarstvo studija algoritama“. Algoritam se sastoji iz niza precizno definiranih pravila koji određuju kako proizvesti određene izlazne informacije sa zadanim ulaznim informacijama kroz konačni broj koraka“. Prema autoru, računarstvo je postojalo davno prije izuma računala – način algoritamskog razmišljanja je duboko ukorijenjen u antropologiju. No, dok računala nisu bila izumljena, potencijalno bogatstvo algoritamskog razmišljanja i njihovog proučavanja nije moglo biti realizirano, iz jednostavnog razloga jer ljudi nisu dovoljno precizni niti brzi.

Sedamdesetih godina Donald Knuth izjednačuje koncepte računarstva i informatike na različitim jezicima, tako navodeći francusku riječ informatique kao ekvivalent riječi računarstvo, njemačku Informatik te dansku Datalogi, argumentirajući navedene termine raznolikošću tematike s kojom se bavi računarstvo (Knuth, 1974.).

Godine 1985. Abelson i Sussman definiraju računarstvo kao „disciplinu konstruiranja odgovarajućih deskriptivnih jezika“ (Forbus, 1985.), dok izvještaj iz 1988., „Računarstvo kao disciplina“, definira polje računarstva na sljedeći način: „Disciplina računarstva je sistematska studija algoritamskih procesa koji opisuju i transformiraju informacije: njihova teorija, analiza, dizajn, efikasnost, implementacija i primjena. Fundamentalno pitanje koje se tiče cijelog računarstva jest: što se može efikasno automatizirati?“ (Denning et al, 1988., str. 12). Denning (2003) razgrađuje predmete proučavanja računarstva na mehaničke komponente (računanje, komunikacija, koordinacija, automatizacija i skupljanje podataka), principe dizajna (jednostavnost, performansa, pouzdanost, mogućnost nadogradnje i sigurnost) te praktične komponente (programiranje, inženjerski sustavi, modeliranje i validacija, inovacija i primjena) (Denning, 2003.). Tucker i suradnici (2003) računarstvo definiraju kao „proučavanje računala i algoritamskih procesa, uključujući i njihove principe, hardverski i softverski dizajn, njihovu implementaciju i utjecaj na društvo“ (Tucker et al, 2003., str. 6).

Unutar okvira obrazovanja, spomenimo i pojam 'digitalne pismenosti'. BECTA (*British Educational Communications and Technology Agency*) je 2010. izdala dokument u kojem definira pojam digitalne pismenosti te iznosi njenu važnost za djecu. Digitalnu pismenost definira kao „kombinaciju vještina, znanja i razumijevanja koje mladi ljudi trebaju naučiti kako bi mogli sigurno i potpuno sudjelovati u digitalnom svijetu koji uzima maha. Ova mreža vještina, znanja i razumijevanja je ključna komponenta u kurikulima primarnog i sekundarnog obrazovanja te bi trebala biti uključena u podučavanje svih predmeta na svim razinama“ (http://itte.org.uk).

Etimološke diskusije te različite definicije koje ne ovise samo o zemlji u kojoj se spominju, nego i o vremenu u kojem se pojavljuju, nužno vode do konvergencije terminologije. Naravno, za znanstvene i edukacijske potrebe nužno je povlačenje granica između znanstvenih područja i grana, no, znanstvenici će to precizno i točno pokušati učiniti, pogotovo sa znanstvenim područjima čije se granice, mogućnosti i saznanja tako brzo mijenjaju, evoluiraju i nadograđuju kao što su to informatika i računarstvo. Ti se pokušaji nerijetko svode ne na

razgradnju njihovih različitih aspekata i područja djelovanja, nego na fokusiranje na konkretne predmete njihovog proučavanja.

Time logički dolazimo do sjedinjavanja različitih područja u jedno veće, u kojem međusobna miješanja i prelijevanja predmeta proučavanja nisu problem. Spomenimo dakle za kraj ovog poglavlja akronim STEM (Science, Technology, Engineering and Mathematics) koji se danas toliko često upotrebljava kao konvergentni produkt slijevanja srodnih znanstvenih grana u jednu da se pojavljuje kao ključna riječ u znanstvenim radovima i istraživanjima diljem svijeta. U Republici Hrvatskoj ne postoji ekvivalentni termin jednostavno zbog lingvističkih prepreka. Naime riječ 'science' se u zemljama engleskog govornog područja koristi i za npr. biologiju i kemiju, dok, u hrvatskom školstvu ne postoji ekvivalentni predmet, a time niti termin koji bi ga opisao. Osim STEM, nalazimo slične akronime kao npr. STEAM (Science, Technology, Engineering and Applied Mathematics) ili STREAM (Science, Technology, Robotics, Engineering, Arts and Mathematics).

1.2 Matematičke kompetencije u primarnom obrazovanju

Govoriti o kompetencijama bilo kakve vrste nemoguće je bez barem površnog doticanja s psihologijom. Kako psihologija nije područje fokusa ovoga rada, dublje ulaženje u različite teorije nema smisla, no u svrhu konačnog argumentiranja zašto specifične kompetencije u matematici i informatici povlače barem u većini aspekata jedna drugu, nužno je dati barem površni pregled faktora koji utječu na njihov razvitak.

Strukturalistički pristup kojeg je razvio Piaget (1950), Case (1985) i nedavno Halford (1992) upotrebljavaju matematičke probleme koji zahtijevaju proporcionalno razmišljanje kako bi demonstrirali napredak u općenitoj produktivnosti procesuiranja informacija. Međutim, nativističke teorije očekuju od novorođenčeta da razumije određene izvore informacija te zagovaraju stav da je matematičko znanje urođeno, argumentirajući da aspekti koji utječu na kardinalno razumijevanje brojeva kao npr. brojenje je sposobnost koja je urođena (Gelman, 1990; Wynn, 1990.). Ovim argumentom se stoga objašnjava zašto djeca predškolske dobi lako usvajaju osnovne principe matematike bez upotrebe sistematskih uputa. (Stern i Döbrich, 1999.)

Naprednija Matematika zahtijeva sposobnost apstraktnog razmišljanja te restrukturiranje rano naučenog kardinalnog razumijevanja te stoga njeno razumijevanje mora biti produkt sistematskog poučavanja (Gelman, 1991; Resnick, 1989.). Stern i Döbrich (1999.) izoliraju tri tipa matematičkih kompetencija:

- *Strategije koje se upotrebljavaju u rješavanju aritmetičkih problema*: rješavanje kompleksnijih aritmetičkih problema, primjerice, 7 + 3 − 3 =, može se bitno pojednostaviti upotrebljavajući pravila komutacije i neutralnog elementa, pri čemu primjena pravila, kako bi se stvorila svojevrsna metoda kratice, zahtijeva fleksibilnost pri baratanju s kvantitativnim simbolima umjesto metode direktnog računanja.
- *Strategija rješavanja aritmetičkih zadataka riječima*: rješavanje aritmetičkih zadataka riječima zahtijeva sposobnost modeliranja životnih situacija uz pomoć matematičkih simbola. Npr. izjave koje opisuju odnose između skupova poput „Petar ima 5 pikula više nego Ivan“, zahtijevaju shvaćanje da je funkcija brojeva više od samog brojenja (Stern, 1998).
- *Proporcionalno razmišljanje*: ako zadatak ili problemska situacija uključuje razmatranje najmanje dvije različite jedinice, principe koji vrijede kod brojenja treba ignorirati. Iako u pravilu veći broj implicira veću kvantitetu, samo odnosi između brojeva trebaju implicirati zaključke o veličini kvantiteta za proporcionalne jedinice (Stern i Döbrich, 1999.).

Spajajući teorije kognitivnog razvoja i psihometričkih teorija znači razvijati teoriju koja može zapravo objasniti i individualne razlike i razlike unutar starosnih grupa. Anderson (1992) je razvio teoriju prema kojoj kompetencije dolaze od specifičnih modula koji se razvojem dalje restrukturiraju. Npr. prema autoru, individualne razlike, koje se pojavljuju pri razumijevanju racionalnih brojeva, uzrokovane su individualnim razlikama u brzini restrukturiranja konceptualno jednostavnijih matematičkih saznanja u naprednije i apstraktnije strukture znanja. Slično, za razlike unutar skupina djece iste dobi odgovorne su urođene razlike u općenitoj brzini procesuiranja informacija, što u prijašnjem kontekstu implicira da se djeca razlikuju u brzini kojom razgrađuju kardinalne brojeve u apstraktnije, numeričke koncepte (Stern i Döbrich, 1999.).

No, što uzrokuje longitudinalno gledano, individualne razlike u usvajanju naprednijih matematičkih kompetencija unutar skupina djece iste dobi?

Stern i Döbrich (1999.) su napravili studiju koja se fokusira na usvajanje matematičkih kompetencija koje zahtijevaju apstraktnije numeričko razumijevanje od samog kardinalnog shvaćanja brojeva, pri čemu su prezentirali tri tipa zadataka: 1) zadatke riječima koji zahtijevaju usporedbu između skupova, 2) numeričke zadatke koji zahtijevaju razvijanje strategija za njihovo rješavanje, 3) zadatke koji se fokusiraju na odnose između veličina. Studija je napravljena na uzorku od 110 - 120 ispitanika unutar LOGIC studije (Munich Longitudinal Study on the Ontogenesis of Individual Competencies, 20-godišnju longitudinalnu studiju ljudskog razvoja od 6. godine do 23. godine života). Autori su se fokusirali na sljedeća pitanja:

1. *Utjecaj razina razvoja koje su povezane s dobi ispitanika na matematičke kompetencije*: Utječu li općenite kognitivne kompetencije, koje se usvajaju u određenoj dobi, na sposobnosti u različitim kompetencijama, kao što to strukturalistička teorija sugerira? Ili je postignuće u određenoj domeni određeno usvajanjem i restrukturiranjem određenog znanja?

2. *Utjecaj sposobnosti u predškolskoj dobi na kasnije matematičke kompetencije*: imaju li općenite ili specifične kompetencije utjecaj na kasniji uspjeh u matematici?

3. *Utjecaj kompetencija usvojenih u osnovnoj školi na proporcionalno razmišljanje:* Individualne se razlike u proporcionalnom razmišljanju u višim razredima osnovne škole smatraju određenima razlikama u performansi u znanju koje je specifično za domenu. Nadalje, što se prije te kompetencije usvoje, to se prije mogu restrukturirati, jer je naprednije matematičko znanje produkt restrukturiranja osnovnih kompetencija. No, strukturalističke teorije sugeriraju kako su napredne kognitivne sposobnosti nužan preduvjet za proporcionalno razmišljanje.

4. *Utjecaj širih sposobnosti na postignuća u matematici*: Smatra se da sposobnosti kao brzina procesuiranja informacija kao i metakognitivne sposobnosti imaju utjecaj na matematičke kompetencije. Štoviše, studije također sugeriraju da pored općenitih

kompetencija i visoko razvijene spacijalne sposobnosti imaju utjecaj na matematičku performansu (Stern i Döbrich, 1999.).

Autori sažimlju rezultate studije na sljedeći način:

1. *utjecaj dobi na matematičke kompetencije*: rezultati ne podupiru razvojne modele niti individualne razlike koje naglašavaju utjecaj općenitih sposobnosti na matematičke kompetencije.

2. *utjecaj predškolskih postignuća na kasnije matematičke kompetencije*: rezultati sugeriraju da općenite sposobnosti, mjerene verbalnom i neverbalnom inteligencijom, također doprinose matematičkoj sposobnosti. Nadalje, rezultati sugeriraju kako rane kompetencije koje su usvojene bez sistematskog poučavanja imaju utjecaj na usvajanje matematičkih kompetencija u osnovnoj školi.

3. *utjecaj kompetencija u osnovnoj školi na proporcionalno razmišljanje*: rezultati pokazuju utjecaj kompetencija koje su specifične za određene domene, npr. dobra su postignuća u rješavanju zadataka riječima prije dvije godine imala veći utjecaj na proporcionalno razmišljanje od visoko razvijenih sposobnosti u istoj vremenskoj točki mjerenja. Rezultati, nadalje, naglašavaju važnost usvajanja znanja kroz dulje razdoblje.

4. *utjecaj širih sposobnosti na matematička postignuća* rezultati sugeriraju da performansa u verbalnim i neverbalnim testovima inteligencije za sve starosne grupe ima jasni utjecaj na matematičke kompetencije, iako rezultati ne podupiru utjecaj općenite sposobnosti procesuiranja informacija (Stern i Döbrich, 1999.).

Ako je razvitak matematičkih kompetencija u predškolskoj dobi koreliran s kasnijim uspjehom u usvajanju daljnjih matematičkih kompetencija u sklopu primarnog obrazovanja, ima također i smisla stupanj razvitka matematičkih kompetencija u predškolskoj dobi smatrati svojevrsnim prediktorom kasnijih matematičkih kompetencija (Aunola et al, 2004; Bailey et al, 2014; Claessens i Engel, 2013; Claessens et al., 2009; Duncan et al., 2007; Jordan et al., 2009; Watt et al., 2014). Nadalje, ukoliko je dovoljno pažnje usmjereno na razvitak kompetencija prije ulaska u primarni školski sustav, logički slijedi da time ulažemo i u bolje razvijene kompetencije u osnovnoj školi te time i preveniramo da djeca koja su u rizičnoj skupini ne zaostaju previše za svojim vršnjacima u usvajanju matematičkog znanja (Gersten et al., 2005). Procjenjivanje i mjerenje matematičkih kompetencija u predškolskoj dobi ima i

dva dodatna razloga i benefita: 1) njihovom se evaluacijom mogu lakše identificirati djeca za koju postoji vjerojatnost da će kasnije imati problema s razvitkom matematičkih kompetencija te im posvetiti više pažnje, 2) ukoliko postoje vještine koje možemo smatrati prediktorima kasnijih matematičkih kompetencija, možemo razviti metode kako ih podučiti i razviti (Nguyen et al, 2016.).

U Ujedinjenim Državama su izdani dokumenti koji se fokusiraju na nužne matematičke kompetencije djece u predškolskoj dobi kao npr. *Nacionalno istraživačko vijeće za učenje Matematike u ranoj dobi: putevi prema izvrsnosti i pravednosti* (*National Research Council Mathematics Learning in Early Childhood: Paths Toward Excellence and Equity*) (NRC, 2009), *Principi i standardi za Matematiku poučavanu u školi* (*Principles and Standards for School Mathematics*) (NCTM, 2000.) te *Matematika u ranoj dobi: potičući dobre početke* (*Early Childhood Mathematics: Promoting Good Beginnings*) (NAEYC & NCTM, 2002). Iako se radi o različitim dokumentima, paralele se mogu povući na sljedeće kompetencije: brojevi i operacije, geometrija i spacijalne sposobnosti, mjerenje, zapažanje ponavljajućih uzoraka, algebarsko razmišljanje, prezentiranje i analiziranje podataka (Nguyen et al, 2016.).

1. *rane kompetencije brojenja*

Kompetencija se brojenja definira kao sposobnost prepoznati da brojevi predstavljaju količinu i imaju veličinu, prepoznati principe bijekcije, uređeni poredak (npr. da su imena brojeva i sami brojevi poredani na fiksni način) te kardinalnost (tj. da je zadnji broj koji je spomenut veličina skupa), (Clements & Sarama, 2014; Gelman & Gallistel, 1986). Jedno je od pomagala pri usvajanju kompetencije brojenja svakako brojenje 'na prste', koje pri uvođenju kompleksnijih matematičkih sadržaja postaje manje korisno i kada se primjenjuju druge metode kao npr. brojenje s kardinalnosti, brojenje unaprijed ili unatrag od određenog broja (Clements, 1999; Sarnecka & Carey, 2008; Secada et al., 1983), no dokazano je i da se djeca često oslanjaju na već naučene strategije (Siegler i Shipley, 1995). Na primjer, matematički problem 2 + 3 se može riješiti samim brojenjem, tj. postavljanjem dvaju predmeta kojima se pridodaju još tri. Naprednija bi metoda uključivala počimanje brojenja od broja 2 dok bi još efektivnija metoda bila izabiranje većeg od dva broja, tj. 3 te brojenje za dva od toga broja, i ta metoda uključuje manje posla (Geary i Brown, 1991; Gersten et al., 2005; Saxe, 1979; Siegler, 1987). No ovakve napredne metode brojenja djeca često usvajaju tek kasnije u

osnovnoj školi (Carpenter et al., 1982; Carpenter i Moser, 1984; Secada et al., 1983; Steffe et al., 1976).

2. *geometrija i spacijalne sposobnosti*

Razumijevanje matematike zahtijeva velikim dijelom posjedovanje spacijalnih sposobnosti, jer one podupiru logičko razmišljanje i rješavanje problema, što kasnije vodi prema razvijanju sposobnosti donošenja zaključaka (Clements i Sarama, 2011; Clements et al., 2008.). Nadalje, razvitak spacijalnog razmišljanja omogućuje djeci razumijevanje spacijalnog svijeta i druge matematičke teme, te se smatra da su spacijalne kompetencije vrlo bitne za razvitak matematičkih kompetencija, s empirijski dokazanim korelacijama između spacijalnih sposobnosti i uspjeha djece u matematici (Ansari et al., 2003; Casey et al., 1995; Grouws, 2006.; Verdine et al., 2014).

3. *mjerenje, prezentiranje i analiza podataka*

Prva iskustva djece s mjerenjem počinju s primjerima i razlikama u visini, težini i dužini različitih objekata. Atributi objekata te predispozicija djece da sortiraju stavke po atributima se smatraju ključnim elementom za sposobnost prezentacije, analize i interpretacije matematičkih podataka (Ginsburg et al., 2008).

4. *zapažanje ponavljajućih uzoraka i algebarsko razmišljanje*

Istraživanje uzoraka koji se ponavljaju u predškolskoj dobi smatra se važnim konstruktom matematike kao discipline (Steen, 1988), i preduvjetom za uvođenje formalne algebre (Copley, 2000; Kaput, 1999; Lannin, 2005; Orton i Orton, 1999), zato što rad s uzorcima vodi prema sposobnosti generalizacije, koja je baza algebarskog razmišljanja.

U ranijem tekstu, govoreći o kompetencijama koje se razvijaju u predškolskoj dobi te koje se smatraju prediktorima matematičkih kompetencija u osnovnoj školi, izostavilo se spomenuti matematičke kompetencije te njihov razvitak kod djece s problemima u učenju matematike. Dok se većina istraživanja i studija fokusirala na proučavanje osnovnih kompetencija kod djece s problemima u učenju (Geary et al., 2000; Geary et al., 1999; Ostad, 1997, 1998), Andersson (2008) je proširio domenu proučavanih kompetencija kako bi dobio kompletniju

sliku. Postoji, naime, mišljenje da dok djeca s poteškoćama u učenju koja pokazuju normalne razine vještina u nekim područjima matematike, u nekima pokazuju vrlo nisko razvijene kompetencije (Dowker, 2005; Ginsburg, 1997). Ako smatramo da nisko razvijene kompetencije u određenom matematičkom području nužno povlače nisko razvijene kompetencije u drugom području koji su međusobno povezani na način da su kompetencije u jednom nužno potrebne i u drugom (kao npr. problemi s pamćenjem aritmetičkih podataka povlače probleme pri izvođenju operacija s višeznamenkastim brojevima), za dokazivanje je naših tvrdnji nužno propitivanje punog šireg spektra matematičkih kompetencija te njihove međusobne povezanosti (Andresson, 2008).

Uz pretpostavku da je razvijanje matematičkih kompetencija i vještina hijerarhijsko, tj. da su npr. uspoređivanje veće/manje i brojenje preduvjeti za rješavanje osnovnih aritmetičkih problema (kao npr. zbrajanje jednoznamenkastih brojeva), u početku samim brojenjem, a kasnije i uz primjenu naučenih aritmetičkih pravila (Baroody i Wilkins, 1999; Geary et al., 2000; Mazzocco i Thompson, 2005), Andersson je izolirao osam matematičkih područja i pripadajuće kompetencije:

- pamćenje aritmetičkih podataka,
- pisano aritmetičko računanje,
- procjenjivanje,
- dekadske jedinice,
- principi računanja,
- zadaci riječima koji se rješavaju u jednom koraku,
- zadaci riječima koji se rješavaju u više koraka,
- određivanje vremena.

Ova su područja odabrana, ne samo zbog prije spomenutih argumenata da jedna kompetencija povlači drugu, nego i zbog samog uzorka kojeg je autor odabrao, a to su bila djeca trećeg i četvrtog razreda osnovne škole, u kojima su zahtjevi na ove kompetencije jasno vidljivi (Andresson, 2008).

1. *Osnovne aritmetičke vještine*

Studije fokusirane na proučavanje ove specifične kompetencije pokazuju da su djeca koja imaju poteškoće u matematici i ona koja imaju komorbidne poteškoće u matematici i čitanju, sporija, rade puno više grešaka te upotrebljavaju ili brojenje na prste ili verbalno brojenje

(Geary et al., 1999, 2000; Hanich et al., 2001; Russell i Ginsburg, 1984). Nadalje, zapaženo je i da takva djeca ne pokazuju pomak s proceduralnih strategija rješavanja zadataka na strategije rješavanja zadataka iz pamćenja, što sve ukazuje na činjenicu da imaju proceduralne probleme i probleme s uspostavljanjem veze u memoriji između problema i rješenja jednostavnih aritmetičkih problema (Ashcraft, 1992; Geary, 1993), što kasnije može dovesti do problema u razvijanju vještine automatizacije koja je potrebna za kasnije rješavanje kompleksnih, višeznamenkastih zadataka (Ashcraft, 1992). Andersson (2008) napominje da su se studije većinom fokusirale na zadatke koji su uključivali zbrajanje i u nekoj mjeri oduzimanje, dok zadatke s množenjem gotovo uopće nisu upotrebljavale. Autor, nadalje, smatra da bi sposobnost pamćenja podataka pri množenju također trebala biti uključena u studije, zbog pretpostavke da bi sposobnosti djece mogle varirati kod izvođenja različitih matematičkih operacija (Andersson, 2008).

2. *Rješavanje zadataka riječima*

Studije fokusirane na kompetencije rješavanja zadataka riječima kod djece s matematičkim poteškoćama su se većinom fokusirale na zadatke riječima koji se rješavaju u jednom koraku (Hanich et al., 2001; Jordan i Hanich, 2000; Jordan, Hanich i Kaplan, 2003; Jordan i Montani, 1997) te je dokazano da djeca s matematičkim poteškoćama kao i djeca s poteškoćama u matematici i čitanju imaju velike poteškoće pri rješavanju zadataka ovog tipa (Hanich et al., 2001; Jordan i Hanich, 2000; Jordan, Hanich i Kaplan, 2003; Jordan i Montani, 1997). Andersson (2008) smatra da se studije, koje pokazuju da djeca s matematičkim poteškoćama imaju bolje rezultate pri rješavanju zadataka riječima od djece s komorbidnim poteškoćama u matematici i čitanju do određenje mjere uzrokovane poteškoćama u čitanju, trebaju proširiti s dodatnim kompleksnijim zadacima (Andersson, 2008).

3. *Dekadske jedinice i operacije s višeznamenkastim brojevima*

Mali se broj studija bavio mjerenjem sposobnosti djece pri baratanju s dekadskim jedinicama, što bi trebao biti preduvjet za razumijevanje operacija s višeznamenkastim brojevima. Rezultati studija pokazuju da djeca s poteškoćama u matematici i čitanju imaju znatno manje rezultate kod operacija s višeznamenkastim brojevima (Hanich et al., 2001; Jordan i Hanich, 2000; Jordan, Hanich i Kaplan, 2003; Russell i Ginsburg, 1984), dok djeca koja imaju samo poteškoće u čitanju imaju bolje rezultate od djece s komorbidnim poteškoćama u matematici i

čitanju (Jordan i Hanich, 2000; Hanich et al, 2001). Zbog malog broja provedenih istraživanja koji se fokusiraju na ovo područje ne mogu se povući konkretni zaključci, no postoji indikacija da lošije razumijevanje koncepta dekadskih jedinica može imati negativni efekt na razvijanje sposobnosti provođenja operacija s višeznamenkastim brojevima (Jordan, Hanich i Kaplan, 2003).

4. *Principi računanja (odnosi između aritmetičkih operacija)*

Razumijevanje odnosa unutar i između različitih aritmetičkih operacija je preduvjet za točno izvođenje operacija s višeznamenkastim brojevima te rješavanje zadataka riječima (Geary, 1994; Jordan, Hanich i Uberti, 2003). Istraživanja pokazuju da djeca s matematičkim poteškoćama u drugom i trećem razredu imaju primjetnih problema kod razumijevanja principa računanja (Hanich et al., 2001; Jordan, Hanich, i Kaplan, 2003) dok druga studija pokazuje da djeca u trećem razredu koja imaju komorbidne poteškoće u matematici i čitanju imaju slabije razumijevanje principa računanja u usporedbi s djecom koja imaju samo matematičke poteškoće (Jordan, Hanich i Kaplan, 2003)

5. *Procjenjivanje*

Studije sugeriraju da se procjenjivanje rezultata određenog aritmetičkog problema oslanja na vizualne spacijalne sposobnosti i da su lingvistički neovisne (Dehaene et al., 1999; Hanich et al., 2001; Jordan, Hanich, & Kaplan, 2003). No empirijska je slika situacije nepotpuna zbog kontradiktornih rezultata (Andersson, 2008).

6. *Određivanje vremena*

Određivanje vremena slično je osnovnim aritmetičkim operacijama (brojenje i pamćenje aritmetičkih podataka), pa nam je, također, interesantno. Istraživanja pokazuju da djeca upotrebljavaju mješavinu proceduralnih i memorijskih strategija kada određuju vrijeme (Case et al., 1986; Friedman i Laycock, 1989; Siegler i McGilly, 1989; Vakali, 1991). Određivanje vremena uz pomoć analognog sata djeca izvode uz pomoć memorijskih tehnika, pristupanjem prijašnjem odgovoru iz pamćenja, što dalje sugerira da djeca razvijaju memorijske povezanosti između određenih konfiguracija i vremenskih imena (Friedman i Laycock, 1989; Siegler i McGilly, 1989).

Niss i Jensen (2002) definiraju matematičke kompetencije kao „dobro informiranu spremnost na odgovarajuće djelovanje u situacijama koje uključuju određenu vrstu matematičkog izazova“ (Niss i Jensen, 2002). Niss (1999) je izložio prijedlog primjene matematičkih kompetencija kao alat za poboljšanje matematičkog obrazovanja (Niss, 1999). Kao posljedica je prijedloga proveden KOM projekt u Danskoj od 2000. do 2002. godine, koji je imao za cilj razvoj i razradu ove ideje na svim edukacijskim razinama (osnovnoškolske do fakultetske razine) (Niss, 2003.) Kao posljedica ciljeva ovog projekta, razvijena je matrična struktura kompetencija zajedno sa matematičkim područjima interesa: matematičko razmišljanje, pristup problemima, modeliranje, zaključivanje, prikazivanje, jezik simbola, komunikacija, pomoćni alati. Napredak se i poticaj u razvijanju kompetencije matematičkog modeliranja opisuju kroz tri dimenzije: 1. stupanj pokrivenosti, ovisno o dijelu procesa modeliranja s kojim učenici rade te razinom njihovog sudjelovanja, 2. tehnička razina, ovisno o tipu matematike koju učenici upotrebljavaju te stupnju njihove fleksibilnosti u primjeni matematičkog znanja i 3. radijus djelovanja, ovisno o domeni situacije u kojoj su učenici sposobni izvršiti matematičko modeliranje. Matrična je struktura kompetencija uzeta kao središte kurikuluma, pružajući poveznicu između općenitih ciljeva podučavanja i samog silabusa. Nakon što su učenici shvatili prirodu i srž elemenata određenih kompetencija u pitanju, mogli su odlučiti (nakon međusobne rasprave te rasprave s nastavnikom) koji bi izbori bili u skladu s edukacijskim fokusom i s njihovim osobnim interesima (Bloomhoj i Jensen, 2007.)

PISA (PISA – Programme for International Student Assessment, *Matematička pismenost*, NCVVO, 2018., (http://www.pisa.hr/index.php/matematicka-pismenost) definira matematičku pismenost kao sposobnost formuliranja, primjenjivanja i tumačenja matematike u različitim kontekstima. Ona obuhvaća matematičko zaključivanje i primjenu matematičkih koncepata, postupaka, činjenica i alata potrebnih za opisivanje, objašnjavanje i predviđanje pojava. Ona pomaže pojedincu da prepozna ulogu koju matematika ima u svijetu i da donosi dobro utemeljene odluke i prosudbe koje su mu potrebne kao konstruktivnom, zainteresiranom i promišljajućem građaninu.

Matematička pismenost usredotočena je na sposobnost učenika da analiziraju, logički zaključuju i učinkovito iznose svoje ideje dok postavljaju, formuliraju, rješavaju i interpretiraju rješenja matematičkih problema u različitim situacijama. Da bi se ta definicija prevela u procjenu matematičke pismenosti, utvrđene su tri široke dimenzije:

- ***Matematički procesi***: svrstani u tri kategorije (matematičko formuliranje situacija, primjenjivanje matematičkih koncepata, činjenica, postupaka i zaključivanja te tumačenje, primjenjivanje i vrednovanje matematičkih rezultata) opisuju što pojedinci rade da bi povezali kontekst problema s matematikom i tako riješili taj problem. Svaki od tih procesa temeljen je na sedam osnovnih matematičkih sposobnosti (komuniciranje, matematiziranje, prikazivanje, zaključivanje i argumentiranje, razvijanje strategija za rješavanje problema, korištenje simboličkog, formalnog i tehničkog jezika i operacija te korištenje matematičkih alata) od kojih se svaka zatim temelji na matematičkom znanju pojedinca i pojedinim matematičkim temama.
- ***Matematički sadržaji***: definirani s obzirom na četiri sveobuhvatne ideje *(prostor i oblik, promjena i odnosi, količina te neizvjesnost)* koje se odnose na poznate cjeline kao što su brojevi, algebra i geometrija.
- ***Matematički konteksti***: definirani prema aspektu svijeta pojedinca u koji su smješteni problemi. Korištena su četiri konteksta*: osobni, obrazovni, društveni i znanstveni.*

• **Matematički procesi** definirani općim matematičkim kompetencijama. One obuhvaćaju korištenje matematičkog jezika, modeliranje i vještine rješavanja problema. Međutim, cilj nije razdvojiti ove vještine u različita ispitna pitanja, budući da se pretpostavlja da će za rješavanje bilo kojeg matematičkog zadatka biti potreban širok raspon kompetencija. Umjesto toga, pitanja su organizirana s obzirom na tri skupine kompetencija koje definiraju tip potrebne vještine mišljenja:

1) Prva skupina matematičkih kompetencija (reprodukcija, definicije i računanje) obuhvaća procese koji se najčešće procjenjuju u konvencionalnim matematičkim testovima. Riječ je o poznavanju činjenica, izvođenju jednostavnih računskih radnji, prisjećanju definicija, primjeni standardnih algoritama ili prepoznavanju ekvivalenata.

2) Procesi druge skupine kompetencija (povezivanje i integracija za rješavanje problema) započinju stvaranjem veza između različitih grana i područja matematike i integriraju podatke da bi se riješili jednostavni problemi. Unutar ove skupine kompetencija od učenika se očekuje da se uspješno snalaze s različitim aspektima prikazivanja, da su sposobni razlikovati i

povezivati različite iskaze kao što su definicije, tvrdnje i dokazi, da uspješno dekodiraju i tumače simbolički i formalni jezik te da razumiju njegov odnos s prirodnim jezikom.

3) Treća skupina kompetencija ("matematizacija", matematičko mišljenje, uopćavanje i uvid) sastoji se od matematičkog mišljenja, uopćavanja i razumijevanja, a zahtijeva od učenika da "matematiziraju" situacije, odnosno da prepoznaju i "izvuku" matematiku ugrađenu u situaciju te da koriste matematiku kako bi riješili problem, analizirali, tumačili, razvijali vlastite modele i strategije te proizveli matematičke argumente, uključujući dokaze i uopćavanje.

Ti procesi uključuju kritičko mišljenje, analizu i promišljanje.

• Matematički sadržaj, definiran uglavnom s obzirom na opće matematičke pojmove na kojima se zasniva matematičko mišljenje (kao što su vjerojatnosti, promjena i rast, prostor i oblici, logičko zaključivanje, odnosi neizvjesnosti i ovisnosti), te samo sporedno vezano uz nastavne sadržaje (kao što su brojevi, algebra i geometrija). PISA organizira matematički sadržaj na temelju fenomenološkog pristupa opisujući sadržaj s obzirom na fenomen i vrste problema za koji je stvoren pod nazivom „sveobuhvatni pojmovi". Izvršen je odabir "sveobuhvatnih pojmova" koji će obuhvaćati dostatnu raznovrsnost i dubinu da se pokaže neophodnost matematike te koji će istovremeno predstavljati ili obuhvaćati konvencionalne matematičke kurikulumske cjeline na prihvatljiv način. Sljedeći "sveobuhvatni pojmovi" zadovoljili su taj preduvjet: promjena i odnosi, prostor i oblici, količina te neizvjesnost.

• Kontekst (situacije u kojima se matematika koristi) - Važan aspekt definicije matematičke pismenosti jest korištenje i primjena matematike u mnoštvu situacija, uključujući privatni (osobni) život, školski život, rad i slobodno vrijeme, lokalnu zajednicu i društvo. Svaka situacija nalazi se na određenoj udaljenosti od učenika. Najbliži je privatni život (svakodnevnica), zatim školski život, posao i sport, iza čega slijede lokalna zajednica i društvo, a najudaljeniji su znanstveni konteksti. Bez obzira na to koliko su učenicima situacije strane, cilj PISA procjene jest osigurati da se zadaci temelje na autentičnim kontekstima koji se mogu susresti u stvarnom životnom okruženju. Međutim, time se ne isključuju umjetni izmišljeni konteksti, zasnovani na stiliziranom prikazu problema kao što je prometna situacija u nepostojećem gradu.

Program za međunarodno vrednovanje učenika (PISA), koji nadgledava rezultate edukacijskih sustava kroz propitivanje učeničkih postignuća definira koncept 'matematičke pismenosti' kao „sposobnost identificirati i razumjeti ulogu koju matematika igra u svijetu, donositi dobro utemeljene zaključke te upotrebljavati matematiku na način koji odgovara individualnim potrebama kao konstruktivni i odgovorni građanin“ (Schleicher et al, 2009).

U samom se dokumentu proces koji učenici upotrebljavaju kako bi riješili probleme iz stvarnog života naziva 'matematizacija'. Učenik koji je uključen u proces matematizacije treba posjedovati više matematičkih kompetencija, svaka od kojih može biti razvijena na drugačijoj razini. Nadalje, PISA opisuje osam karakterističnih matematičkih kompetencija koje se oslanjaju na radove Nissa (1999):

1. *razmišljanje i zaključivanje*: uključuje postavljanje pitanja koja su karakteristična za matematiku, znajući koje vrste odgovora matematika može ponuditi; razlikovanje izjava kao npr. teorema, definicija, hipoteza te primjera; shvaćanje i baratanje s dometom matematičkih pojmova,

2. *argumentacija*: uključuje znanje o matematičkim dokazima te kako se oni razlikuju od druge vrste matematičkog zaključivanja; praćenje i procjenjivanje niza matematičkih argumenata različitih tipova; shvaćanje pojma heuristike; stvaranje i izražavanje matematičkih argumenata,

3. *komunikacija*: uključuje izražavanje unutar matematičkog sadržaja, usmeno i pisano, te razumijevanje tuđeg izražavanja unutar matematičkog sadržaja,

4. *modeliranje*: uključuje strukturiranje područja ili situacije koja zahtijeva modeliranje; prevođenje realnosti u matematičku strukturu; interpretiranje matematičkih modela u realnom svijetu; rad sa matematičkim modelima; provjeravati modele; promišljati te analizirati modele te dati kritiku i rezultate modela; nadgledati i kontrolirati proces modeliranja,

5. *postavljanje problema te njegovo rješavanje*: uključuje postavljanje, formuliranje te definiranje različitih vrsta matematičkih problema te rješavanje matematičkih problema na više načina,

6. *prikaz*: uključuje dekodiranje i kodiranje, prevođenje, tumačenje te razlikovanje između različitih oblika reprezentacije matematičkih objekata i situacija; međusobne povezanosti između različitih vrsta prikaza; biranje i mijenjanje sustava prikazivanja prema situacijama te svrsi,

7. *upotreba simboličkog, formalnog te tehničkog jezika te operacija*: uključuje dekodiranje i interpretaciju simboličkog i formalnog jezika te shvaćanje njene povezanosti s prirodnim jezikom; prevođenje s prirodnog jezika u simbolički jezik; baratanje izjavama i izrazima koji sadrže simbole te formule; uporaba varijabli, rješavanje jednadžbi te provođenje izračuna,

8. *upotreba pomoći i alata:* uključuje znanje i sposobnost upotrebe različitih vrsta pomoći i alata, uključujući IKT koje mogu biti korisne pri matematičkim aktivnostima te znanje o njihovoj ograničenosti (Schleicher et al, 2009).

Matematički procesi matematičkoga područja kurikuluma

Matematički procesi su prepoznati u ciljevima, značajni su na svim razinama obrazovanja te prožimaju sve domene matematičkoga područja kurikuluma. (Prijedlog kurikuluma matematičkog područja, Cjelovita kurikularna reforma, 2016.) Organizirani su u pet skupina:

1. Prikazivanje i komunikacija,
2. Povezivanje,
3. Logičko mišljenje, argumentiranje i zaključivanje,
4. Rješavanje problema i matematičko modeliranje,
5. Primjena tehnologije.

Prikazivanje i komunikacija

Učenici smisleno prikazuju matematičke objekte, obrazlažu rezultate, objašnjavaju svoje ideje i bilježe postupke koje provode. Pri tome koriste različite prikaze: riječi, crteže, makete, dijagrame, grafove, liste, tablice, brojeve, simbole i slično. U danoj situaciji odabiru prikladan prikaz, povezuju različite prikaze i prelaze iz jednog na drugi. Prikupljaju i tumače informacije iz raznovrsnih izvora.

Razvijanjem sposobnosti komuniciranja u i o matematici učenici rabe jasan matematički jezik, razumiju njegov odnos prema govornom jeziku, slušaju i razumiju matematičke opise i

objašnjenja drugih te razmjenjuju i sučeljavaju svoje ideje, mišljenja i stavove. Uspješna komunikacija doprinosi lakšem i bržem usvajanju novih sadržaja kako matematičkog, tako i drugih područja kurikuluma.

Povezivanje

Učenici uspostavljaju i razumiju veze i odnose među matematičkim objektima, idejama, pojmovima, prikazima i postupcima te oblikuju cjeline njihovim nadovezivanjem. Uspoređuju, grupiraju i klasificiraju objekte i pojave prema zadanom ili izabranom kriteriju. Povezuju matematiku s vlastitim iskustvom, prepoznaju ju u primjerima iz okoline i primjenjuju u drugim područjima kurikuluma. Time ostvaruju jasnoću, pozitivan stav i otvorenost prema matematici te povezuju matematiku sa svim područjima kurikuluma i životom tijekom procesa cjeloživotnog učenja.

Logičko mišljenje, argumentiranje i zaključivanje

Učenje matematike karakterizira razvoj i njegovanje logičkog i apstraktnog mišljenja. Poučavanjem i učenjem matematičkoga područja učenici se suočavaju s izazovnim problemima koji ih potiču na promišljanje, argumentiranje i dokazivanje te donošenje samostalnih zaključaka. Učenici postavljaju matematici svojstvena pitanja te stvaraju i istražuju na njima zasnovane matematičke pretpostavke, uočene pravilnosti i odnose. Stvaraju i vrednuju lance matematičkih argumenata, zaključuju indukcijom i dedukcijom, analiziraju te primjenjuju analogiju, generalizaciju i specijalizaciju. Primjenjuju poznato u nepoznatim situacijama i prenose učenje iz jednog konteksta u drugi. Razvijaju kritičko mišljenje te prepoznaju utjecaj ljudskih čimbenika i vlastitih uvjerenja na zaključivanje. Proces mišljenja razvijen nastavom matematike učinkovito koriste u svom svakodnevnom životu.

Rješavanje problema i matematičko modeliranje

Učenici analiziraju problemsku situaciju, prepoznaju elemente koji se mogu matematički prikazati i planiraju pristup za njezino rješavanje odabirom odgovarajućih matematičkih pojmova i postupaka. Biraju, osmišljavaju i primjenjuju razne strategije, rješavaju problem, promišljaju i vrednuju rješenje te ga prikazuju na prikladan način. Razvojem ovog procesa, osim primjene matematičkih znanja, učenici razvijaju upornost, hrabrost i otvorenost u suočavanju s novim i nepoznatim situacijama.

Primjena tehnologije

Korištenje alata i tehnologije pomaže učenicima u matematičkim aktivnostima u kojima su u središtu zanimanja matematičke ideje, pri provjeravanju pretpostavki, pri obradi i razmjeni podataka i informacija te za rješavanje problema i modeliranje. Učenici uočavaju i razumiju prednosti i nedostatke tehnologije. Na taj se način prirodno otvaraju mogućnosti za nove ideje, za dublja i drugačija matematička promišljanja, kao i za nove oblike učenja i poučavanja. (Prijedlog kurikuluma matematičkog područja, Cjelovita kurikularna reforma, 2016.)

Domene matematičkoga područja kurikuluma

Matematičko obrazovanje podrazumijeva poznavanje i razumijevanje određenih matematičkih koncepata. Koncepti koji se uče u općem obrazovanju važni su za razumijevanje svijeta oko nas te za razumijevanje informacija, procesa i pojava koje nas okružuju. Klasificirani su u veće cjeline koje nazivamo domenama matematičkoga područja. One su osmišljene tako da se svaki koncept učenja može smjestiti u određenu domenu. Logički grupiraju srodne koncepte i u potpunosti pokrivaju matematičke sadržaje koje učenik tijekom školovanja treba usvojiti. Odabrane su na način da omogućuju nadogradnju složenijih matematičkih struktura i razvoj matematičkih procesa te prilagođene razvojnim mogućnostima učenika. Grupiranjem u domene želi se osigurati kontinuitet učenja u vertikali matematičkoga obrazovanja.

Obrazovanje u matematičkom području temelji se na ideji da se iste domene poučavaju i uče u svim ciklusima te na taj način usmjeravaju učenje prema istim konceptima koji se kroz cikluse razvijaju i nadopunjuju. Udio pojedinih domena nije jednak u svim ciklusima pa neke domene dominiraju u nižim ciklusima, a neke u višim. Osim vertikalne povezanosti, postoje i horizontalne veze među domenama tako da se svaki koncept iz jedne domene može lako povezati s drugim domenama. (Prijedlog kurikuluma matematičkog područja, Cjelovita kurikularna reforma, 2016.)

Matematičko područje kurikuluma organizirano je u pet domena:

1. Brojevi
2. Algebra i funkcije
3. Oblik i prostor
4. Mjerenje
5. Podatci, statistika i vjerojatnost.

Brojevi

Broj je osnovni matematički pojam kojim počinje razvoj matematike i predstavlja jedan od prvih učenikovih doživljaja matematike. Poznavanje brojeva i računskih operacija nužno je svakom čovjeku. Stoga je domena Brojevi temelj matematičke pismenosti i učenje ove domene od velike je važnosti.

Početnim usvajanjem pojma prirodnog broja i skupa prirodnih brojeva, uz primjenu osnovnih računskih operacija, učenici postupno i sustavno otkrivaju potrebu proširivanja toga skupa na skup cijelih, racionalnih, realnih i kompleksnih brojeva. Analiziraju i tumače svojstva i odnose među brojevima, koriste različite načine zapisivanja i prikazivanja brojeva te usvajaju i primjenjuju sve složenije računske operacije. Razvijaju vještine mentalnog računanja i pisanog računanja te se učinkovito služe tehnologijom. Procjenjuju smislenost i točnost rezultata računanja.

Domena Brojevi usko je povezana sa svim ostalim domenama. Primjena brojeva je sveprisutna i neizbježna u svim područjima ljudske djelatnosti, što povezuje ovu domenu s ostalim područjima kurikuluma i svakodnevnim životom. (Prijedlog kurikuluma matematičkog područja, Cjelovita kurikularna reforma, 2016.)

Algebra i funkcije

Algebra čini osnovu za učenje matematičkoga jezika proučavajući pravilnosti i rabeći simbole umjesto brojeva, a funkcije omogućavaju istraživanje promjena. Algebra je jezik za opisivanje pravilnosti u kojem slova i simboli predstavljaju brojeve, količine i operacije, a varijable se koriste pri rješavanju matematičkih problema.

U domeni Algebra i funkcije učenici prikazuju i analiziraju matematička svojstva, veze i odnose među brojevima, podatcima, oblicima i mjerama. Generaliziraju pronađene pravilnosti. Uočene matematičke veze među veličinama prikazuju riječima, simbolima, tablično i grafički. Koriste jednadžbe i nejednadžbe u rješavanju problema te proučavajući funkcije istražuju i opisuju promjenu i brzinu promjene u različitim kontekstima.

Domena Algebra i funkcije omogućava jednostavnije izražavanje mnogih pojmova, matematičkih zakonitost i ili pravila, opisivanje promjena te rješavanje složenih problema, što je povezuje sa svim ostalim domenama. Primjena matematičkih metoda u znanosti čvrsto je povezuje s prirodoslovnim područjem kurikuluma. Zbog svoje složenosti ova je domena zastupljenija u višim ciklusima obrazovanja. (Prijedlog kurikuluma matematičkog područja, Cjelovita kurikularna reforma, 2016.)

Oblik i prostor

U domeni Oblik i prostor učenici otkrivaju i analiziraju obilježja, svojstva i odnose geometrijskih oblika. Određuju položaj oblika i opisuju prostorne veze rabeći koordinatni sustav te primjenjuju transformacije i simetriju. Razvijaju vizualizaciju i prostorno mišljenje te rabe modeliranje za rješavanje problema. Pritom skiciraju, crtaju, konstruiraju i izrađuju geometrijske oblike. Prostorni zor je intuitivni osjećaj za oblike i odnose među njima, a zajedno s geometrijskim rasuđivanjem razvija sposobnost misaone predodžbe objekta i prostornih odnosa.

Domena je usko povezana s domenama Mjerenje i Brojevi pri određivanju i izračunavanju mjerivih obilježja oblika. Algebarski izrazi i funkcije su važni za transformacije objekata i određivanje njihovih svojstava, prikaz u koordinatnom sustavu te pri rješavanju problema geometrijskim modeliranjem.

Povezana s doživljavanjem prirode i svijeta oko nas, domena Oblik i prostor našla je svoje mjesto u temelju mnogih prirodnih i tehničkih znanosti, a posebice je kreativno primjenjuje umjetnost. Domena Oblik i prostor ostvaruje veze između matematike i prirodoslovnog, tehničkog i informatičkog te umjetničkog područja kurikuluma. (Prijedlog kurikuluma matematičkog područja, Cjelovita kurikularna reforma, 2016.)

Mjerenje

U životu se neprestano susrećemo s mjerenjem i mjernim jedinicama. Mjerenjem određujemo duljinu, površinu, volumen, vrijeme, temperaturu, brzinu te brojne druge veličine. Novac je također vrsta mjere kojom se iskazuje vrijednost robe ili usluga.

Domena Mjerenje osposobljava učenike za procjenjivanje, mjerenje ili izračunavanje veličina. Učenicima omogućava razumjeti i rabiti mjeriva svojstva, mjerne jedinice i postupke mjerenja uz pravilnu primjenu mjernih alata i matematičkih procedura. Ova domena vježbom te primjenom znanja i vještina doprinosi razumijevanju matematičkih koncepata.

Usko je povezana s domenama Brojevi, Oblik i prostor te Podatci, statistika i vjerojatnost. Mjere su svuda oko nas pa se ovom domenom matematika povezuje sa stvarnim životom. Koncepte mjerenja koriste sve znanosti, a domena Mjerenje posebno je važna poveznica matematike s prirodoslovnim, tehničkim i informatičkim te društveno-humanističkim područjem kurikuluma. (Prijedlog kurikuluma matematičkog područja, Cjelovita kurikularna reforma, 2016.)

Učenici će mjerenjem povezati matematiku s drugim odgojno-obrazovnim područjima, s vlastitim iskustvom, svakodnevnim životom u kući i zajednici te na radnomu mjestu i prepoznati mjeriva obilježja ravninskih i prostornih oblika u umjetnosti te ih upotrebljavati za opis i analizu svijeta oko sebe. (Kurikulum predmeta Matematika, Cjelovita kurikularna reforma, 2016.)

Podatci, statistika i vjerojatnost

Svaki pojedinac treba pravilno tumačiti podatke i njihov statistički prikaz kako bi predviđao i procjenjivao rizike te donosio utemeljene odluke.

Grafički prikazi, analize podataka i procjena vjerojatnosti susreću se svakodnevno, na primjer u reklamiranju, procjeni javnoga mišljenja, procjeni zdravstvenoga rizika ili vremenskoj prognozi. Domena Podatci, statistika i vjerojatnost omogućava učenicima prikupljati podatke, organizirati ih i prikazivati na različite načine, prema potrebi uz pomoć tehnologije. Podatke čitaju iz različitih prikaza te ih analiziraju kako bi otkrili veze među njima i donijeli utemeljene zaključke i predviđanja. Promatraju slučajne događaje te procjenjuju i računaju njihovu vjerojatnost.

Ova je domena usko povezana s domenama Brojevi i Mjerenje prilikom prikupljanja podataka, Algebra i funkcije pri analizi te Oblik i prostor prilikom prikazivanja podataka. Statistika i vjerojatnost imaju važnu primjenu u drugim znanostima pa se ovom domenom matematika povezuje s ostalim područjima kurikuluma, posebno s prirodoslovnim i društveno-humanističkim. Statističke elemente učenici susreću u neposrednoj okolini, što omogućava snažne poveznice između matematike i stvarnoga života. (Prijedlog kurikuluma matematičkog područja, Cjelovita kurikularna reforma, 2016.)

Biccard i Wessels su 2011. godine proveli istraživanje na uzorku učenika 7. razreda kroz period od 12 tjedana. Fokus je istraživanja bio razvoj kompetencija matematičkog modeliranja. Učenicima su se kroz period od 12 tjedana davali zadaci za koje su autori htjeli pokazati da doprinose razvoju kompetencija matematičkog modeliranja. Na početku istraživanja su autori zabilježili slabo razvijene kompetencije u svim područjima matematičkog modeliranja. Kompetencije su matematizacije u velikoj mjeri ovisile o razumijevanju i sposobnosti pojednostavljivanja zadanog problema, dok je sposobnost pojednostavljivanja bila međusobno ovisna o matematizaciji. Njihov je napredak kao grupe u matematičkom radu uključivao fleksibilnost u radu s decimalnim brojevima, bolje sposobnosti procjenjivanja, više pregovaranja oko samog značenja te preciznijeg mjerenja s boljim

razumijevanjem. Grupne su kompetencije interpretacije te provjere ostale na niskoj razini kroz istraživanje. Autori objašnjavaju da je tradicionalni način podučavanja vjerojatni uzrok za nisku razinu razvijenosti ovih kompetencija. Također, zaključeno je da kontekst zadataka utječe na razvoj kompetencija. Neki konteksti pružaju poticajne platforme za kompetencije, dok s drugima to nije slučaj. Ovakvi su zadaci zahtijevali dosta čitanja stoga je postalo jasno da su učeničke sposobnosti čitanja te razumijevanja teksta igrale važnu ulogu u samom razumijevanju zadatka. Zaključeno je da bi bilo poticajno uključiti učenike u zadatke modeliranja unutar domene matematičkog konteksta te konteksta stvarnog života kako bi se potakao razvoj šireg spektra matematičkih kompetencija (Biccard i Wessels, 2011).

PRILOG A ovomu radu opširnije opisuje matematičke kompetencije prema NOK-u (Nacionalni okvirni kurikulum za predškolski odgoj i obrazovanje te opće obvezno i srednjoškolsko obrazovanje, Zagreb, 2010.)

1.3 Informatičke kompetencije (digitalne kompetencije, računalna pismenost)

Započnimo odjeljak s pojmom digitalne pismenosti kao kompetencije i njenom važnosti te ulogom u primarnom obrazovanju. U dokumentu *Digital Literacy* (digitalna pismenost) BECTA naglašava, iako je većina mladih ljudi samopouzdana pri upotrebi tehnologije, to se ne može shvatiti kompetencijom. Dok se u današnjem svijetu tehnologija smatra vratima za budućnost za sudjelovanje u novim vrstama učenja i društvenim i poslovnim aktivnostima, mladi bi ljudi trebali biti educirani kako donositi odluke na temelju informacije, biti svjesni komercijalnih strategija u medijima te kako sigurno digitalno sudjelovati u svijetu. Također se smatra da je potrebno educirati mlade ljude u upotrebi tehnologije kako bi ju mogli koristiti efektivno te iskoristiti njen potpun potencijal. Jedan od načina kako to ostvariti smatra se, ne samo edukacija o samoj upotrebi tehnologije, nego i njena inkorporacija u svaki predmet koji se poučava, pri čemu svaki nastavnik može dati svoju perspektivu kako primjena tehnologije može dati novu vrijednost predmetu kojeg poučava (http://itte.org.uk).

Erstad (2010) proširuje pojam digitalne pismenosti na medijsku pismenost te naglašava da bi sljedeći aspekti medijske pismenosti trebali biti dio školskog kurikuluma:

- osnovne vještine,
- mediji kao predmeti analize,

- znanje prikupljeno unutar određenih domena tj. predmeta,
- strategije učenja,
- kulturna kompetencija (Erstad, 2010).

Pored pojma digitalne pismenosti nailazimo i na pojam 'vještine pismenosti za 21. stoljeće', za koje Jenkins i sur. (2006) pišu da se sastoje od sljedećih aspekata:

- *igra* (sposobnost eksperimentiranja s okruženjem kao oblik strategije rješavanja problema),
- *performansa* (sposobnost preuzimanja drugačijih identiteta u svrhu improvizacije te istraživanja),
- *simulacija* (sposobnost reprezentacije stvarnih situacija uz pomoć dinamičkih modela te njihova interpretacija),
- *raspodjela* (sposobnost smislenog sortiranja sadržaja te povezivanja određenih aspekata),
- *multitasking* (sposobnost registriranja svega u okolini i promjena fokusa),
- *promijenjena kognicija* (sposobnost baratanja alatima koji šire mentalne sposobnosti),
- *kolektivna inteligencija* (sposobnost stavljanja informacija na hrpu te uspoređivanje s informacijama koje su drugi sakupili u svrhu postizanja određenog zajedničkog cilja),
- *prosuđivanje* (sposobnost procjene pouzdanosti drugačijih izvora informacija),
- *navigacija kroz medije* (sposobnost praćenja tijeka priče i tok informacija kroz različite perspektive),
- *Networking* (sposobnost traženja, stvaranja i širenja informacija),
- *pregovaranje* (sposobnost kretanja u različitim zajednicama, prihvaćajući i poštujući različite perspektive) (Jenkins et al., 2006).

Nadalje, digitalne se kompetencije spominju kao jedna od osam ključnih kompetencija navedenih u dokumentu Europskog parlamenta 'Ključne kompetencije za cjeloživotno učenje' (Key Competencies for Lifelong Learning), (European Union, 2010), u kojemu se sam koncept digitalne kompetencije definira na sljedeći način: „Digitalna kompetencija uključuje samopouzdanu i kritičku upotrebu 'tehnologije informacijskog društva' (Information Society Technology - IST) za rad, zabavu i komunikaciju. Podupiru ju osnovne ICT vještine: upotreba

računala kako bi došli do informacija, procijenili ih, pohranili, stvorili te prezentirali i razmijenili informacije, komunicirali i sudjelovali u suradničkim mrežama uz pomoć interneta.“ (European Union, 2010).

Prema dokumentu, digitalne bi kompetencije trebale biti evidentne u svakodnevnom životu, kako poslovnom tako i privatnom, što uključuje vješto baratanje MS Officeom ili sličnim inačicama, spremanje i baratanje podacima i razumijevanje dobrobiti i rizika korištenja interneta, te komunikacije elektroničkim putem. Također se očekuje svjesnost što se tiče pouzdanosti informacija te pravnih i etičkih principa koji su uključeni u upotrebu IKT-a. U digitalne kompetencije, također, ubraja se i sposobnost traženja, sakupljanja te obrađivanja podataka, pristupajući tome kritički i sistematično (European Union, 2010).

Uvidom u dostupnu literaturu uočava se konvergencija terminologije, vidljiva među konceptima 'digitalne kompetencije', 'digitalne pismenosti', IKT kompetencija' te 'informacijskih kompetencija', što je produkt ne samo različitih definicija i problema povlačenja granica između različitih koncepata, nego i lingvističkih barijera i okvira postavljenih unutar određene zemlje i nivoa na kojem se tehnologija upotrebljava na dnevnoj bazi. Tome doprinosi i brzina kojom se razvija nova tehnologija te sama konvergencija tehnologije (različiti tehnološki proizvodi koji su se u određenoj vremenskoj točki koristili za različite stvari konvergiraju u jedan jedini tehnološki produkt koji zamjenjuje sve prethodne svojom multipraktikalnosti), pa se definicije kompetencija mijenjaju ubrzano. Tome je i svjedok sama upotreba riječi 'pismenosti' zajedno s riječima 'digitalno' i 'informacijski', iz čega je vidljivo da su digitalne/informatičke kompetencije prerasle ne samo u kompetencije limitirane određenim predmetom ili znanstvenim poljem, nego u oblik pismenosti koji društvo znanja zahtijeva od svojih građana.

Zbog svih su navedenih razloga istraživanja u domeni digitalnih/informatičkih kompetencija raspršena na svoje različite aspekte ili definicije te su dodatno izolirana svojom provedbom unutar specifičnih istraživanja, uzoraka i metoda sakupljanja podataka (van Deursen i van Dijik, 2009).

PRILOG B ovomu radu opširnije opisuje informatičke kompetencije prema NOK-u (Nacionalni okvirni kurikulum za predškolski odgoj i obrazovanje te opće obvezno i srednjoškolsko obrazovanje, Zagreb, 2010.)

1.4 Matematičke kompetencije kao implikacija digitalno/informatičkih

„Informatika kao znanost sistematske, najčešće automatske obrade podataka je nezamisliva bez matematičkog načina razmišljanja i matematičkih tehnika. Bez obzira na to radi li se o formulaciji i istraživanju algoritama ili konstrukciji i razumijevanje IKT, matematičke metode, apstraktni modeli i formalni opisi igraju centralnu ulogu.“ (Meinel, 2011., str 11)

Na početku ovog odjeljka bacimo pogled nakratko u matematičku teoriju računarstva te pitanje koje su znanstvenici postavljali 1930-ih: 'što su bazične sposobnosti i ograničenja računala'? Od tada do danas proteklo je puno vremena, a gledajući tehnološki razvitak i puno više, uzevši u obzir brzinu kojom se razvijaju i revolucionaliziraju tehnološka oruđa i saznanja u računarstvu/informatici.

Teorija je računanja bio jedan od odgovora na postavljeno pitanje, kojom su se u prvom dijelu dvadesetog stoljeća bavili matematičari kao što su to Gödel, Turing te Church, koji su došli do zaključka da određeni problemi ne mogu biti riješeni uz pomoć računala. Jedan od primjera takvog problema jest dokaz je li određena matematička izjava točna ili netočna (true/false).

Druga se tematika odnosi na teoriju automata, koja se bavi definicijama i svojstvima matematičkih modela računanja. Model se konačnih automata npr. koristi u današnjem softveru koji procesuira tekst (eng.word processing), kod kompajlera te samog hardverskog dizajna. Kontekstno-slobodne gramatike (eng. Context free grammars) koriste se u programskim jezicima te kod umjetne inteligencije. Teorija automata uključuje formalne definicije računanja, pri čemu koristi matematičke pojmove i alate kao što su to npr. skupovi, redovi, n-torke, funkcije i relacije, grafovi, Booleova algebra itd. (Sipser, 2012., str. 1-16).

Bez potrebe da dublje ulazimo u literaturu, kratki pogled u matematičku teoriju računarstva bio je ponuđen kao ilustracija činjenice da računarstvo počiva na čvrstim matematičkim temeljima. Meinel (2008) u svojoj knjizi 'Matematički temelji informatike' objašnjava matematičke pojmove, tehnike i strukture koje smatra nužnim za informatičare koji žele biti uspješni u svojem polju. Nadalje, Meinel piše:“ uvod u matematičke pojmove, matematički način razmišljanja i zapisivanja, temeljni je dio obrazovanja za bilo koga tko aktivno i uspješno želi koncipirati ili administrirati računalne sustave koji procesuiraju informacije i računalne mreže, razvijati novi software ili dizajnirati i implementirati nove aplikacije“ (Meinel, 2008, str. 11).

Naizgled je prilično jasno da su logičko razmišljanje, formalno zapisivanje te matematička logika vrlo bitne za informatiku/računarstvo, na bilo kojoj razini. Isto tako možemo reći kako je upotreba matematičkog softvera unaprijedila nastavu Matematike te da je matematički softver često upotrebljavan kao oruđe de-apstraktizacije određenih matematičkih pojmova, kao pripomoć kod vizualizacije geometrijskih situacija i oruđe pomoću kojega učenici mogu metodom eksperimenta istraživati različite matematičke pojmove, pa tako brže učiti te dublje i kvalitetnije usvojiti matematičko znanje.

U kontekstu primarnog obrazovanja i razinama znanja i kompetencija u računarstvu/informatike koje se očekuju od učenika, nailazimo na pojam 'računarskog razmišljanja' (computational thinking) koji se pojavljuje kao odgovor na diskusije oko definicija srodnih područja te koji nudi jasnu primjenu i sliku kompetencija. Tako Wing (2006) piše da „računarsko razmišljanje uključuje rješavanje problema, dizajniranje sustava te razumijevanje ljudskog ponašanja kroz koncepte koji su osnova računarstva“ (Wing, 2006, str. 33) te da je „računarsko razmišljanje proces razmišljanja koji je uključen u formulaciju problema i njihovih rješenja kako bi se rješenja mogla predstaviti u obliku u kojemu ih informacijsko-procesni agent može izvršiti“ (Wing, 2011). Autori koji podupiru ovakvu klasifikaciju ističu da iako tako definirana kompetencija sadrži matematičke i inženjerske, pa čak i elemente dizajna, također se i oslanja na svako od tih područja na jedinstveni način (Lee et al., 2011). Denning i Freeman (2009), s druge strane, smatraju da iako računarsko razmišljanje odražava elemente inženjerstva, Matematike i drugih prirodnih znanosti, drugačije je zbog usmjeravanja Matematike na procesuiranje informacija (Denning i Freeman, 2009, str 30).

U izvještaju Zajedničkog istraživačkog centra (Joint Research Centre), koji je dio službe Europskog povjereništva za znanost i znanje, navodi se potreba da se računarsko razmišljanje integrira u primarno obrazovanje (Bocconi et al., 2016). Primarni su ciljevi CompuThink projekta, za kojeg je pisan izvještaj, bili: 1) stvoriti opširnu sliku o računarskom razmišljanju kod djece, u svjetlu nedavnih istraživanja, 2) stvoriti bolje razumijevanje koncepata i atributa računarskog razmišljanja te njegovog potencijala u primarnom obrazovanju. Izvještaj sadrži naputke za integraciju računarskog razmišljanja u primarno obrazovanje, jer se ono smatra ključnom kompetencijom za djecu osnovnoškolske dobi (Bocconi et al., 2016).

Navedimo nadalje definicije osnovnih vještina računarskog razmišljanja:

1. *oduzimanje*: proces uklanjanja nepotrebnih detalja kako bi se određeni koncept učinio bolje razumljivim. Bitna vještina koja je potrebna za oduzimanje, jest sposobnost prepoznati što je bitno, a što nije krucijalno za samu definiciju koncepta u pitanju (Csizmadia et al., 2015, str. 7).
2. *algoritamsko razmišljanje*: način razmišljanja koji kroz određeni broj jasno definiranih koraka vodi do rješenja problema (Csizmadia et al., 2015, str. 7).

3. *automatizacija:* računalu dajemo instrukcije te zadatke koje treba izvršiti, pri čemu računalo to čini puno brže i učinkovitije od ljudi (Lee et al., 2011, str. 33).

4. *dekompozicija*: način razmišljanja u kojem artefakte razlažemo u komponente, koje se onda zasebno mogu analizirati, procjenjivati i rješavati, što čini rješavanje kompleksnih problema puno jednostavnijim, shvaćanje novih situacija brže i učinkovitijim te dizajn velikih sustava lakšim (Csizmadia et al., 2015, p. 8).

5. *generalizacija*: lociranje ponavljajućih uzoraka, sličnosti i međusobnu povezanost. Također se odnosi na sposobnost rješavanja problema bazirajući skicu svoga rješenja na prijašnjim, sposobnost koja se ovdje navodi kao ključna, svodi se na prepoznavanje sličnosti i ponavljajućih uzoraka između podataka koji se upotrebljavaju kao i procesima te strategijama koji se upotrebljavaju (Csizmadia et al., 2015, p. 8).

Na tragu preispitivanja mogućih prediktora te međusobnih povezanosti između različitih kompetencija spomenimo longitudinalno istraživanje SMPY (Study of Mathematically Precocious Youth). Ovaj je ekstenzivan projekt izolirao intelektualno talentiranu djecu upotrebljavajući SAT-M i SAT-V (Scholastic Assessment Test-mathematics i Scholastic Assessment Test-verbal) test, kojega djeca pišu s 12-13 godina starosti, kao empirijsko oruđe. Projekt je kasnije pratio njihovo obrazovanje te karijere do odrasle dobi i sakupljao podatke (Benbow i Arjmand, 1990.).

Djeca koja su imala visoke rezultate na ovim testovima s 12 godina u kasnijim godinama života odlučili su se za karijeru u prirodnim znanostima, pri čemu su SAT testovi, kao jedino takvo empirijsko oruđe, pokazali kako su se 52% svih muških i 44% svih ženskih ispitanika 10 godina kasnije odlučili za karijere u prirodnim znanostima i medicini. K tomu su autori izolirali faktore za koje se pretpostavljalo da bi mogli biti prediktori visokog ili niskog postignuća u područjima prirodnih znanosti i medicine. Obiteljska pozadina i pozitivni poticaj pokazali su se kao važan utjecaj na visoka postignuća. S druge strane popularno vjerovanje da vrlo talentirani učenici uspiju radeći sami, pokazano je ovim istraživanjem kao pogrešno, tj. rezultati sugeriraju da razlike u školskim programima imaju veliki utjecaj na uspjeh i postignuće, što jasno implicira da čak i talentirana djeca neće dospjeti tako daleko kako bi došla da su imala odgovarajuće obrazovne mogućnosti (Benbow i Arjmand, 1990.).

2 MATEMATIČKE I INFORMATIČKE KOMPETENCIJE TE NASTAVA MATEMATIKE I INFORMATIKE U PRIMARNOM OBRAZOVANJU U REPUBLICI HRVATSKOJ

2.1 Definicija i opis informatičkih i matematičkih kompetencija za više razrede osnovne škole prema Nacionalom okvirnom kurikulumu

2.1.1 Uvod

Nacionalni okvirni kurikulum (NOK) je dokument koji je jedan od produkta promjena u hrvatskoj obrazovnoj politici. Godine 2005. je Ministarstvo znanosti, obrazovanja i sporta započelo s projektom pod imenom Hrvatski nacionalni obrazovni standard, koji je za fokus imao kvalitativne promjene u obrazovnom sustavu. Temeljna su promjena i obilježje Nacionalnog okvirnog kurikuluma prelazak na sustav kompetencija te postignuća učenika, dok je do izdavanja tog dokumenta fokus bio samo na sadržaj predmeta. U tom su dokumentu definirane „temeljne odgojno-obrazovne vrijednosti, ciljevi odgoja i obrazovanja, zatim ciljevi odgoja i obrazovanja, načela i ciljevi odgojno-obrazovnih područja, vrjednovanje učeničkih postignuća te vrjednovanje i samovrjednovanje ostvarivanja nacionalnoga kurikuluma. Ukratko su opisane i međupredmetne teme i njihovi ciljevi. Određena su očekivana učenička postignuća za odgojno-obrazovna područja po ciklusima“ (Fuchs et al, 2011.)

Republika Hrvatska prihvatila je osam temeljnih kompetencija za cjeloživotno obrazovanje, opisane u dokumentu Ključne kompetencije za cjeloživotno učenje (European Union, 2010):

- komunikacija na materinskomu jeziku,
- komunikacija na stranim jezicima,
- matematička kompetencija i osnovne kompetencije u prirodoslovlju i tehnologiji,
- digitalna kompetencija,
- učiti kako učiti,
- socijalna i građanska kompetencija,
- inicijativnost i poduzetnost,
- kulturna svijest i izražavanje.

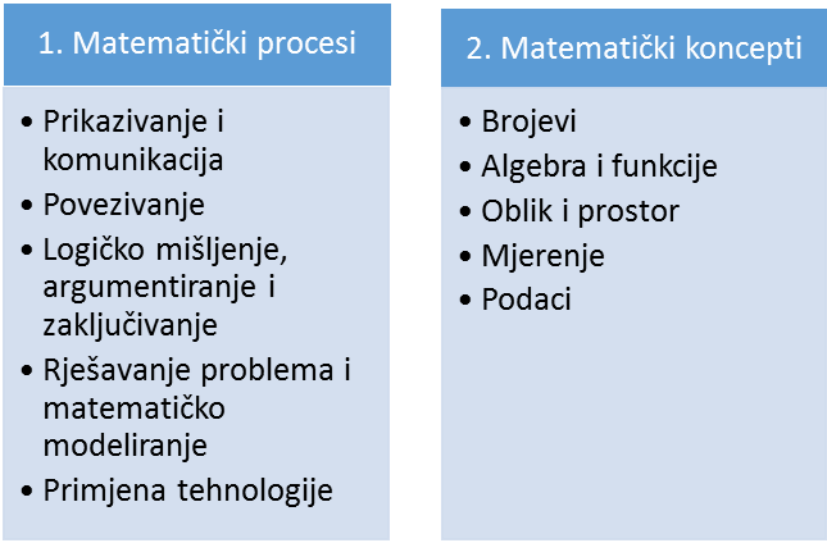
Digitalna kompetencija opisuje se kao „osposobljenost za sigurnu i kritičku upotrebu informacijsko-komunikacijske tehnologije za rad, u osobnomu i društvenomu životu te u komunikaciji. Njezini su ključni elementi osnovne informacijsko-komunikacijske vještine i sposobnosti: upotreba računala za pronalaženje, procjenu, pohranjivanje, stvaranje, prikazivanje i razmjenu informacija te razvijanje suradničkih mreža putem interneta.“ (European Union, 2010)

Matematička kompetencija i osnovne kompetencije u prirodoslovlju i tehnologiji opisuje se kao „matematička se kompetencija odnosi na osposobljenost učenika za razvijanje i primjenu matematičkoga mišljenja u rješavanju problema u nizu različitih svakodnevnih situacija; prirodoslovna se kompetencija odnosi na osposobljenost za uporabu znanja i metodologije kojima se objašnjava svijet prirode radi postavljanje pitanja i zaključivanja na temelju činjenica; tehnološka kompetencija shvaćena je kao osposobljenost za primjenu prirodoslovnoga znanja i metodologije kao odgovor na ljudske potrebe i želje. Osnovne kompetencije u prirodoslovlju i tehnologiji, također, uključuju razumijevanje promjena uzrokovanih ljudskom djelatnošću te odgovornost pojedinca kao građanina.“ (European Union, 2010)

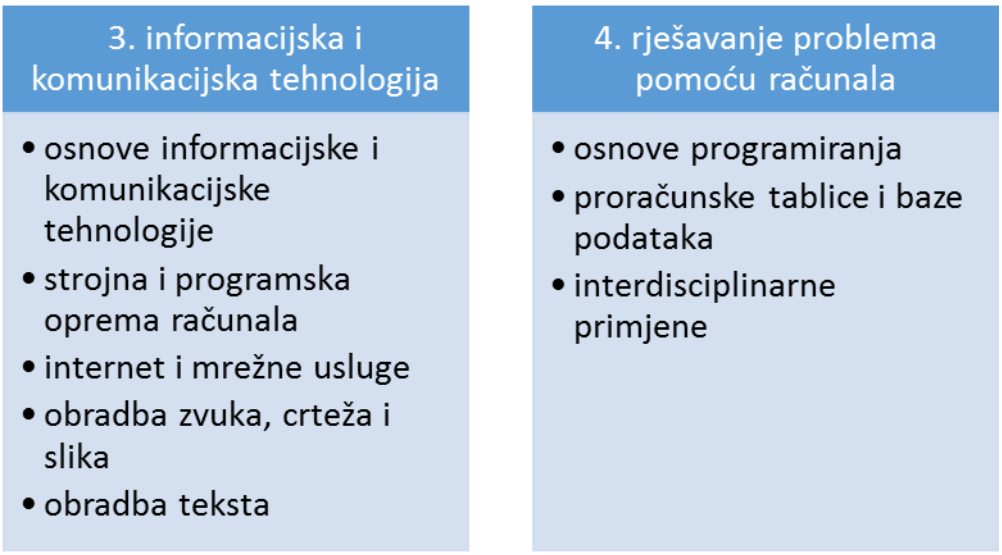
2.2 Matematičke i informatičke kompetencije opisane u Nacionalnom okvirnom kurikulumu

Budući da je predmet studije u ovom radu predmetna nastava u primarnom obrazovanju, iznijet ćemo kompetencije opisane u 2. i 3. odgojno-obrazovnom ciklusu Nacionalnog okvirnog kurikuluma, gdje 2. ciklus predstavlja obrazovni period petog i šestog razreda, a 3. ciklus, sedmog i osmog razreda.

2.2.1 Prikažimo grafički kompetencije koje se pojavljuju u oba ciklusa:



Slika 1. Grafički prikaz matematičkih kompetencija opisanih u NOK-u



Slika 2. Grafički prikaz informatičkih kompetencija opisanih u NOK-u

2.3 Nastavni plan i program za predmete Matematika i Informatika u osnovnoj školi

Eksperimentalni nastavni plan i program obveznih i izbornih nastavnih predmeta od prvog do osmog razreda osnovne škole ostvaren je tijekom školske godine 2005./2006. U dokumentu objavljenom u Narodnim novinama (NN 102/2006) definiraju se nastavni planovi i programi prema elementima Hrvatskog nacionalnog obrazovnog standarda (Milanović i Vican, 2006.).

3 MODELI KOMPETENCIJA

3.1 Uvod

Kauzalnost možemo opisati kao razliku između stvarnih rezultata i rezultata koji se nisu dogodili. Iako znanstvene tvrdnje često uključuju eksplicitno znanje o kauzalnosti i što je to, sam pojam često ostaje u sjeni definicije da djelovanje na varijablu prouzrokuje promjene u drugoj varijabli. Fizika, geometrija, formalna logika te teorija vjerojatnosti koriste kauzalnost bez spominjanja njene definicije, nego samo ukazuju na djelovanje kauzalnosti. Zbog same kompleksnosti kauzalnosti dolazi i do pojednostavljivanja procesa i situacija kako bi se jasnije vidjeli uzrok i posljedica (Clemens, 2017).

Promotrimo varijable *X, Y* i *Z*. Kako bi naznačili kauzalnu povezanost između npr. varijabli *X* i *Y*, pišemo $X \rightarrow Y$. Nadalje, pretpostavimo da želimo odrediti kauzalnu povezanost između varijabli *X, Y i Z*. Koeficijent parcijalne korelacije mjeri uvjetnu nezavisnost ili nepovezanost varijabli mjerenja. Parcijalnu korelaciju između varijabli X i Y uz dani skup varijabli čiji utjecaj kontroliramo, $Z = \{Z_1, \dots, Z_n\}$ označavamo sa $\rho_{XY|Z}$. Ukoliko je $\rho_{XY|Z} > \varepsilon$, $\varepsilon > 0$, gdje je ε parametar na temelju kojeg određujemo stupanj kauzalne povezanosti, možemo zaključiti da varijable *X i Y* nisu nezavisne uz poznavanje povezanosti s varijablom *Z*. Ovakvu povezanost zapisujemo $X \rightarrow Z \leftarrow Y$ te ju nazivamo V-strukturom. Ukoliko je $\rho_{XY|Z} \leq \varepsilon$, vrijedi $X \rightarrow Z \rightarrow Y$, $X \leftarrow Z \leftarrow Y$ ili $X \leftarrow Z \rightarrow Y$ (Tepeš, 2017).

Nastavimo li definirati kauzalnu povezanost naših varijabli dolazimo do kauzalne strukture koja prikazuje kauzalnu povezanost. Kauzalnu strukturu definiramo kao orijentirani graf, pri čemu brid između npr. varijabli X i Y orijentiran kao $X \rightarrow Y$ predstavlja kauzalnu povezanost varijable X kao uzroka i varijable Y kao posljedice. Pri uspostavljanju kauzalne strukture pretpostavljamo V-strukturu te acikličnost grafa. Nadalje, u kauzalnom modelu svakoj povezanosti $X \rightarrow Y$ pridružujemo $p_{XY} = P(Y|X)$ ili uvjetnu vjerojatnost (Tepeš, 2017).

Pojednostavljeno istraživanje u kojemu se proučava kauzalnost, zahtijeva uzimanje uzorka na dijelu kojeg se mjeri djelovanje te uključuje kontrolnu i eksperimentalnu grupu. Pod uvjetom da je uzorak dovoljno velik može se pretpostaviti da eksperimentalna i kontrolna grupa

predstavljaju populaciju te se može mjeriti prosječni kauzalni efekt. Potpuno randomizirani eksperiment zahtijeva de se varijable mogu direktno promatrati, da ih je moguće promijeniti (intervenirati) te da je uzorak dovoljno velik kako bi točno prikazao efekt suprotnog djelovanja. No, problem koji se javlja pri tome je da često nije moguće intervenirati ili da se događaji ne mogu pratiti, a povlači se i pitanje kako zaključiti da se radi o kauzalnoj povezanosti ako postoje varijable koje nisu mjerene, a koje utječu na događaje. Kada je nemoguće intervenirati ili mijenjati varijable, no one se mogu promatrati, statistika se okreće pojmu korelacije, koja je jednostavno statističko oruđe koje uspoređuje ponašaju li se dvije varijable u skupu podataka slično, no korelacija ne povlači kauzalnost (Clemens, 2017).

Dok podaci dobiveni istraživanjima na velikim uzorcima nam mogu dati potpuniju sliku o temi istraživanja, alati poput statističkih modela idu korak dublje u tematiku te nam nude dodatnu dimenziju. U modernoj se teoriji vjerojatnosti procesi slučajnosti gledaju kroz prošle događaje koji su zabilježeni, koji, naravno, imaju utjecaj na predviđanje budućih događaja.

Jedan od alata koji se nude su svakako Markovljevi lanci, koji nam omogućuju razumijevanje naizgled nasumičnih događaja te stvaranje modela. Markovljevi se lanci u primjeni mogu pronaći u npr. meteorologiji (svakodnevno predviđanje kiše), biologiji (dinamika razvoja populacije), kemiji (kemijske reakcije) ili informatičkoj tehnologiji (prepoznavanje govora) (Gagniuc, 2017; str 1-8). Prethodnikom Markovljevog modela smatra se Bernoullijev model, u kojem se smatra da je rezultat prijašnjih događaja neovisan o rezultatu budućih događaja. Nadovezujući se na to, Nekrasov, jedan od Markovljevih kolega, iskazao je pretpostavku da je neovisnost uvjet za zakon velikih brojeva. Polazeći od Bernoullijevog modela te uzimajući Nekrasovu pretpostavku u obzir, Markov je stvorio pretpostavku da zakon velikih brojeva također vrijedi u slučaju zavisnih varijabli. Godine 1906. počinje razvijati teoriju o lancima povezanih vjerojatnosti te godinu kasnije dokazuje da neovisnost nasumičnih varijabli nije preduvjet za validnost slabog zakona velikih brojeva - Teorem centralnog limesa (Gagniuc, 2017; str 1-8).

Markovljev proces u svojoj je najjednostavnijoj formi diskretni, konačni prostor, tj. Markovljev lanac, koji se sastoji od skupa čvorova, pri čemu grafovi mogu uključivati cikluse pa čak i petlje. Počinjemo u određenom stanju A, nasumičnim odabirom biramo luk koji vodi od stanja u kojem se trenutno nalazimo, dok je vjerojatnost da izaberemo određeni luk

naznačena brojem na luku, što na kraju stvara niz stanja koji je nastao nasumično. Dakle, grafička reprezentacija Markovljevog procesa je općeniti graf koji predstavlja distribuciju na nizu čvorova grafa. Prednostima upotrebe Markovljeve teorije smatra se njena jednostavnost te činjenica da nam omogućuje pregled promjena kroz određeni period vremena. No Markovljeva teorija nam nudi relativno pojednostavljeni model kompleksnog procesa.

S time u vezi, spomenimo i strukturalno-jednadžbeno modeliranje (eng. Structural-equation modelling, SEM). SEM se smatra metodologijom čiji je prvenstveni cilj testirati teorije iz empirijskih podataka. SEM je sustav linearnih jednadžbi koji sadrži promatrane i nepromatrane varijable. Sam se model sastoji iz dvaju dijelova: strukturalnog dijela koji povezuje konstrukte jedan s drugime te mjereni dio koji povezuje konstrukte s promatranim ili zabilježenim mjerenjima. Jedna od osobina modela jest to što se može predočiti grafički te se na taj način analizirati i donositi zaključke (Peterson et al, 2010).

Nadalje, jedan od čestih modela u upotrebi je Bayesov model. Bayesovi klasifikatori predviđaju vjerojatnosti pripadanju određenom razredu u obliku pripadanja određene n-torke određenom razredu. Razlog za njihovu popularnost leži u činjenici da su Bayesovi klasifikatori pokazali visoku točnost i brzinu u primjeni na velike skupove podataka. Jednostavni Bayesovi klasifikatori polaze od pretpostavke da je efekt vrijednosti atributa na zadanom razredu neovisan o vrijednostima drugih atributa, koja svakako pojednostavljuje račun te otuda naziv 'naivni klasifikatori' (Han, Pei i Kamber, 2011).

S druge je strane vjerojatnije u praksi pronaći ovisnost između varijabla, gdje na scenu stupaju Bayesove mreže. Bayesova mreža je usmjereni aciklički graf koji predstavlja faktorizaciju određene zajedničke distribucije vjerojatnosti, koja uzima u obzir uvjetnu neovisnost između nekih od varijabli s ciljem pojednostavljivanja grafa i smanjivanja broja parametara koji su nužni za procjenu zajedničke vjerojatnosti distribucije. Radi se o grafičkim modelima koji omogućuju reprezentaciju zavisnosti između podskupova atributa, no koji se istovremeno također mogu koristiti za klasifikaciju. Oni specificiraju zajedničke distribucije zavisne vjerojatnosti te omogućuju definiranje uvjetne neovisnosti razreda između podskupova varijabli. Također, omogućuju stvaranje grafičkog modela kauzalnih povezanosti te se sastoje od usmjerenog acikličkog grafa i skupa tablica zavisnih vjerojatnosti. Pri tome svaki čvor u grafu predstavlja nasumičnu varijablu, koja može biti ili diskretne ili kontinuiranih

vrijednosti. Mogu odgovarati stvarnim atributima ili 'skrivenim varijablama' za koje postoji pretpostavka da tvore povezanost, kao što je npr. slučaj s medicinskim podacima u kojima takva skrivena varijabla može odgovarati sindromu koji, nadalje, upućuje na određenu bolest (Han, Pei i Kamber, 2011).

Prednosti Bayesovih koncepata i metoda su da one mogu uključivati prijašnje informacije i stručne pojmove bez odgovarajućih podataka te da omogućuju proučavanje uzročno-posljedičnih povezanosti pored samog proučavanja korelacija. No, kritike naglašavaju ponekad subjektivnu prirodu što se tiče inicijalnih podataka, koja ponekad može imati jaki utjecaj na posteriornu distribuciju (Wang i Amrhein, 2018).

Tijekom zadnjih trideset godina istraživači su postavili pitanje mogu li se Bayesove mreže upotrijebiti kako bi se otkrile kauzalne strukture u masi statističkih podataka kao suprotnost pretpostavki da je to izvedivo samo u okruženju kontroliranih eksperimenata (Pearl i Verma, 1995; Spirites et al, 2000; Pearl, 2003). Određeni su uzorci zavisnosti (bez vremenske dimenzije) konceptualno karakteristični za određene kauzalne usmjerenosti, no nisu za druge, pa se takvi uzorci zajedno mogu upotrijebiti kako bi se utvrdila kauzalna struktura unutar grubih statističkih podataka. Štoviše, na taj način možemo dobiti i stupanj sigurnosti da će lagane fluktuacije u parametrima uzrokovati nekompatibilnost i strukture s podacima (Pearl, 2011).

Danas Bayesovi modeli u modernoj znanosti nalaze široku primjenu u smislu proučavanja međuovisnosti te predviđanja trendova. Dok ga neki znanstvenici koriste kako bi dobili potpuniju sliku o stanju te uz pomoć modela otkrili varijable koje imaju utjecaj na proučavano stanje, a koje su prošle nedetektirane, Bayesov model nailazi i na popularnost u financijskom modeliranju (predviđanje kretanja dionica), u modeliranju stanja vremenskih prilika te u psihologiji.

3.2 Relevantne studije modela kompetencija

Godine 2010. Cartelli, Dagiene i Futschek (2010) stvorili su model za procjenu digitalne pismenosti kao dio Bebras natjecanja. Bebras natjecanje (IT/IKT) je sagrađeno na temeljima Matematičke olimpijade, Informatičke olimpijade i natjecanja Klokan, s fokusom na sljedeće:

1) stavljanje naglaska na utjecaj IT/IKT na kulturu i jezik, 2) poticaj da učenici upotrebljavaju IT na kreativni način i 3) poticanje učenika da kroz razmišljanje o efektivnoj upotrebi IT/IKT u svakodnevnom životu osjećaju zadovoljstvo (Cartelli et al, 2010).

Okvirni je model za procjenu digitalne pismenosti kreiran bazirajući se na tri različite dimenzije: 1) tehnološka: sposobnost istraživanja i fleksibilni pristup novom tehnološkom kontekstu te problemima, 2) kognitivna: sposobnost pronaći važne i pouzdane informacije kroz čitanje, odabiranje, interpretiranje te procjenu podataka, 3) etička: odgovorna te konstruktivna interakcija s drugima kroz upotrebu tehnologije. Uzimajući opisani okvirni model kao početnu točku, autori su razvili upitnik kojeg su nazvali 'procjena digitalne pismenosti' koji se fokusirao na sljedeća područja unutar tri već spomenute dimenzije: 1) propoznavanje okruženja i sučelja: prepoznavanje mogućih rješenja tehnoloških problema te biranje odgovarajućeg, rad s logičkim operatorima i operacijama, iscrtavanje procesa, razlikovanje između stvarnih i virtualnih fenomena, 2) rad s tekstom, organizacija podataka, biranje i interpretiranje teksta kao i procjena relevantnosti i pouzdanosti informacija, 3) odnos poštovanja prema drugima u online okruženju te razumijevanje društvenih i tehnoloških različitosti (Cartelli et al, 2010).

Upitnik je primijenjen na učenicima različitih dobi te su se njihovi odgovori iskoristili za podešavanje strukture upitnika (neka od pitanja su uklonjena zbog neproduciranja relevantih informacija). Podešena i ispravljena verzija upitnika je potom ponovno primijenjena te je prvotno kreiran okvirni model digitalne pismenosti preoblikovan u sljedeće tri dimenzije: 1) kognitivna, 2) afektivna, 3) društveno-odnosna. Kognitivna dimenzija u podešenom modelu spaja kognitivne i tehnološke dimenzije prijašnjeg modela te elementi koji određuju procjenu ove kategorije odgovaraju Bloomovim kategorijama: znanje, shvaćanje, primjena, analiza, sinteza, procjena (Bloom et al, 1956). Spomenuti elementi ovise o verbalno-ligvističkim i logičko-matematičkim kompetencijama (tipovi inteligencija prema Gardneru) te sposobnostima koje imaju korijen u konstrukciji i manipulaciji vremensko-prostornih i uzročnih koncepata (iz Piagetove teorije).

Nadalje, taksonomija koju je moguće primijeniti na afektivnu dimenziju jest Krathwohlova (Krathwohl et al, 1973), koja se prema autoru sastoji iz primanja fenomena, odgovaranje na fenomen, procjene, organizacije i internalizacije fenomena. Iako nema već gotove

taksonomije koja bi mogla biti primijenjena na treću dimenziju, u trenutku stvaranja modela digitalne pismenosti, autori smatraju da je primjenjiv te da društveno-odnosna dimenzija stoji pod utjecajem intrapersonalne i interpersonalne inteligencije (Gardner, 1993), (Cartelli et al, 2010).

DidaTab (didaktika računalnih tablica) bio je projekt kojeg je započelo Ministarstvo za znanost u Francuskoj, kojemu je cilj bio ispitati upotrebu računalnih tablica (kao npr. MS Excel). Projekt je trajao od 2005. do 2007. te se sastojao od primjene upitnika, razgovora s učenicima i učiteljima, promatranje rada u učionici, testova te komparativne analize s rezultatima drugih zemalja.

Haspekian i Bruillard (2010) su se unutar tog opsežnog projekta fokusirali na povezanost između upotrebe računalnih tablica i Matematike.

Uspoređujući elemente koje nalazimo u algebri i pri radu s računalnim tablicama na računalu, autori navode parove ekvivalenata: 1) objekti: nepoznanice i jednadžbe – varijable i formule, 2) pragmatični potencijal: alat za riješavanje problema – alat generalizacije, 3) proces rješavanja: primjena algebarskih pravila – aritmetički proces pokušaja i podešavanja i 4) priroda rješenja: točna rješenja – točna ili približna rješenja (Haspekian i Bruillard, 2010).

Uzorak studije autora se sastojao od 13 učenika u stručnoj školi u dobi od sedamnaest godina. Najprije je primijenjen test na računalu koji je za cilj imao ocijeniti sposobnosti ispitanika u radu s računalnim tablicama. Nadalje, autori su nakon analize rezultata testa zaključili sljedeće: 1) sposobnosti su bile puno niže nego što je bilo očekivano, 2) učitelj je precijenio sposobnosti svojih učenika pri zadavanju zadataka, 3) vrlo loši rezultati postignuti u kategoriji upotrebe formula u računalnim tablicama povlače pitanje o povezanosti s algebrom (Haspekian i Bruillard, 2010).

Provedeni je test, prema autorima, pokazao manjak razumijevanja algebarskih koncepata kod učenika, iz razloga što upotreba formule unutar računalnih tablica zahtijeva razumijevanje koncepta varijable unutar istog okruženja (ćelije). Haspekian (2005) je na uzorku učenika 7. razreda proveo studiju u kojoj je prezentiran uvod u algebru kroz upotrebu računalnih tablica. Tijekom studije je zahtijevano od učenika da pišu, interpretiraju i transformiraju formule u računalnim tablicama. Autor je pri tome zabilježio sljedeće poteškoće: 1) shvaćanje formula i

2) alata nastavljanja niza (inkrement) (Haspekian, 2005). Zaključci su autora pri završetku studije bili da se u obrazovanju algebarski i općenito matematički koncepti drže unutar čvrstih okvira tradicionalne nastave Matematike te se sami koncepti ne razrađuju u dubinu njihovog značenja, što se jasno vidi na nemogućnosti njihove primjene od strane učenika (Haspekian, 2005).

Jedno od relevantnih studija vezanih za temu modela kompetencija bila je studija provedena u Zagrebu. Autori, Tepeš B., Lešin, Hrkač i Tepeš K. (2016a), su za cilj istraživanja uzeli kreiranje kauzalnog Bayesovog modela matematičkih kompetencija predškolske djece. Uzorak se sastojao od 59 djece u dobi između 65 do 85 mjeseci. Mjerene varijable su bili zadaci koji su davani djeci te procijenjeni rezultati tih zadataka, pri čemu su se kompetencije mjerile u područjima aritmetike i geometrije. Varijable iz područja geometrije su u istraživanju bile: odnosi lijevo/desno, odnosi ispred/iza, odnosi iznad/ispod, prepoznavanje trokuta i prepoznavanje pravokutnika. Varijable iz područja aritmetike su bile: brojenje do 30, razumijevanje brojeva do 10, brojenje na prste, razlikovanje brojeva i slova, dodavanje jedinice, dodavanje dvojke, oduzimanje jedinice i oduzimanje dvojke (Tepeš et al, 2016a).

Za potrebe istraživanja autori su upotrijebili freeware software Tetrad. Upotrebljavan alat softwarea Tetrad, Bayesov procjenitelj, daje odnose između kauzalnih kompetencija i posljedičnih kompetencija. Nakon analize, autori su podijelili kompetencije na pet razina kauzalnih struktura. Na prvoj razini su se nalazile kompetencije: razumijevanje brojeva do 10, dodavanje jedinice, prepoznavanje trokuta, oduzimanje jedinice te razumijevanje odnosa ispred/iza. Prvu razinu kompetencija autori smatraju fundamentalnom za ostale razine kompetencija. Na drugoj su se razini nalazile kompetencije: prepoznavanje pravokutnika i razumijevanje odnosa lijevo/desno, koje su posljedica kompetencija s prve razine. Na trećoj su se razini nalazile kompetencije: dodavanje dvojke, oduzimanje dvojke te brojenje na prste. Na četvrtoj su se razini nalazile kompetencije razumijevanja odnosa iznad/ispod i razlikovanje brojeva i slova, dok se na petoj razini nalazila kompetencija brojenja do 30. Na temelju dobivenih rezultata zaključeno je da je Bayesov model zadovoljavajući u svrhu stvaranja modela odnosa između matematičkih kompetencija djece predškolske dobi (Tepeš et al, 2016a).

Nadalje, stvaranje SEM modela matematičkih kompetencija bio je cilj studije provedene iste godine kojoj su autori Tepeš B., Mrkonjić, Paić i Tepeš K. (2016b). Ispitanici su bili 48 učenika 7. razreda osnovne škole (27 muških i 21 ženskih ispitanika) dok je samo testiranje bilo provedeno kao dio uobičajenog testiranja kompetencija djece što je dio školskog kurikuluma, pri čemu su mjerene kompetencije i varijable iz sljedećih područja: 1) algebra i funkcije (omjer i proporcije, proporcionalnost, obrnuta proporcionalnost, metoda supstitucije, metoda eliminacije i graf linearne funkcije), 2) oblik i prostor (koordinatni sustav, sličnost trokuta i poligoni), 3) mjerenje (opseg i površina sličnih trokuta, obodni i središnji kut, opseg i površina kruga), 4) organizacija podataka (postoci, statistika i vjerojatnost).

Dobiveni se model sastojao od osam razina kauzalne strukture:

1. Proporcionalnost
2. Opseg i površina kruga, poligoni
3. Obodni i središnji kut, obrnuta proporcionalnost
4. Postoci, koordinatni sustav
5. Sličnost trokuta, metoda supstitucije
6. Metoda eliminacije, omjer i proporcije
7. Statistika, grafiranje linearnih funkcija, opseg i površina sličnih trokuta
8. Vjerojatnost

Dobiveni model implicira poredak u kojem se matematičke kompetencije usvajaju te nam daje jasnu sliku o njihovoj međupovezanosti (Tepeš et al, 2016b).

4 METODOLOGIJA ISTRAŽIVANJA

Unutar poglavlja metodologije istraživanja detaljno ćemo opisati uzorak istraživanja, korištene mjerne instrumente, postupak istraživanja, kao i glavni istraživački cilj te probleme i pripadajuće hipoteze.

4.1 Uzorak istraživanja

Istraživanje je obuhvatilo ukupno 1 000 sudionika i provedeno je na ciljanom, strukturiranom uzorku 250 učenika po generaciji iz 21 osnovne škole, ruralnih i urbanih sredina (9 iz ruralnih područja te 12 iz urbanih), koji su završili svaki od razreda predmetne nastave (peti, šesti, sedmi i osmi razred) osnovne škole i pohađali Informatiku kao izborni predmet.

Kriteriji za izbor škola su bili da škola ima Informatiku kao izborni predmet u višim razredima, od petog do osmog razreda te da u uzorak uđu škole iz ruralnoga i urbanoga područja u podjednakom omjeru broja sudionika (učenika).

Bila je odabrana 21 osnovna škola, od kojih je 9 bilo iz ruralnog područja a 12 iz urbanog područja, pod pretpostavkom da postoji barem 10 - 15 učenika unutar jedne škole u svakoj generaciji po razredu koji pohađaju Informatiku kao izborni predmet. U uzorku su bili učenici dobi 10 - 11 godina - za peti razred, 11 - 12 godina - za šesti razred, 12 - 13 godina - za sedmi razred i 13 - 14 godina - za osmi razred, s time da se ravnopravno uključuju i učenici i učenice.

Prikupljeni su podaci o uspjehu učenika iz svih predmeta, te općeg uspjeha, i ocjena na pismenim ispitima iz svih nastavnih tema iz Matematike i Informatike, a broj je učenika bio neujednačen po školama i razredima. Stoga su određena dva osnovna kriterija za formiranje uzorka, a to su: spol učenika (muško ili žensko), te pripadnost ruralnoj ili gradskoj školi. Kako bi ove četiri skupine učenika bile ravnopravno zastupljene u uzorku, bez obzira na stvarnu situaciju u Republici Hrvatskoj, uzeto je po svakoj kategoriji po 250 učenika

(sveukupno 1000), kako bi po svakoj kategoriji i svakom razredu bio jednak broj učenika u istraživanju. Ovih je 250 učenika izabrano tako što ih se uzimalo točno redom kako su pristizali, ali se niz prekinuo kada ih je u uzorak ušlo točno 250, a prema gore navedenim kriterijima.

U sljedećoj tablici nalaze se deskriptivna obilježja uzorka sudionika istraživanja.

Tablica 1. Deskriptivna obilježja uzorka sudionika istraživanja

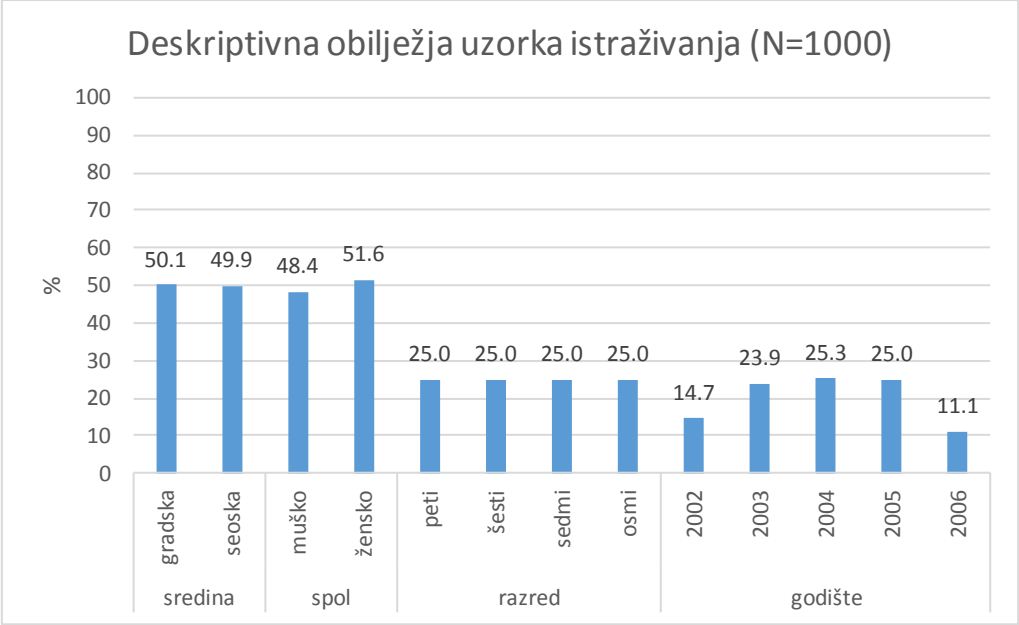
VARIJABLA	RAZINA	N	%
Sredina	Gradska	501	50.1
	Seoska	499	49.9
Spol	Muško	484	48.4
	Žensko	516	51.6
Razred	Peti	250	25.0
	Šesti	250	25.0
	Sedmi	250	25.0
	Osmi	250	25.0
Godište	2002.	147	14.7
	2003.	239	23.9
	2004.	253	25.3
	2005.	250	25.0
	2006.	111	11.1

LEGENDA:
N – broj sudionika
% - postotak sudionika

Iz rezultata u Tablici 1. vidi se da u uzorku od 1000 sudionika uključenih u istraživanje imamo podjednako učenika iz gradskih (50.1%) i ruralnih (49.9%) osnovnih škola te da je

podjednak postotak učenika (48.4%) i učenica (51.6%). U uzorku je obuhvaćeno po 250 (25%) učenika u svakom pojedinom višem razredu od petog do osmog razreda gdje je bila zastupljena uglavnom četvrtina učenika 2003. (23.9%), 2004. (25.3%) i 2005. (25.0%) godišta, 14.7% učenika koji su 2002. godište te 11.1% koji su 2006. godište.

Zorniji prikaz uzorka istraživanja nalazi se na sljedećoj slici.



Slika 3. Prikaz uzorka istraživanja

4.2 Mjerni instrumenti

Upitnik se sastojao od socio-demografskih podataka o učenicima (dob i spol učenika), završne ocjene iz svih predmeta, prosječne ocjene općeg uspjeha, ocjene iz 5-6 pojedinačnih tema iz Matematike te 6 pojedinačnih tema iz Informatike prema Nastavnom planu i programu predmeta Matematika i izbornog predmeta Informatika za svaki ispitivani razred u predmetnoj nastavi u osnovnoj školi.

Tablice za upitnik sadržavale su inicijale učenika, oznaku R ili U (ruralna ili urbana škola), spol i godinu rođenja, opći uspjeh (zaokruženo na dvije decimale), ocjene iz svih predmeta (Hrvatski jezik, Engleski jezik, Likovna kultura, Glazbena kultura, Priroda/Biologija,

Povijest, Geografija, Kemija, Fizika, Tehnička kultura, Tjelesno-zdravstvena kultura, Matematika, Informatika); ocjene iz pojedinih tema iz Informatike i to kako slijedi:

1. za 5. razred: prvi koraci u radu s računalom, spremnici računala i programska oprema, crtanje pomoću računala, programiranje (LOGO), naučimo pisati, internet;
2. za 6. razred: osnove informatike, programiranje (LOGO), obrada teksta, računala u mreži, multimedija, izrada prezentacija;
3. za 7. razred: programiranje (LOGO), proračunske tablice, prezentacije, izrada mrežnih stranica, internet, izrada prezentacija;
4. za 8. razred: osnove informatike, programiranje (LOGO), baze podataka, prezentacije, internet, izrada mrežnih stranica.

ocjene iz pojedinih tema iz Matematike i to:

1. za 5. razred: prirodni brojevi, djeljivost prirodnih brojeva, skupovi točaka u ravnini, razlomci, decimalni brojevi;
2. za 6. razred: operacije s razlomcima, trokut, cijeli brojevi, racionalni brojevi, linearne jednadžbe s jednom nepoznanicom, četverokut;
3. za 7. razred: koordinatni sustav, proporcionalnost i obrnuta proporcionalnost, sličnost i mnogokuti, krug i kružnica, sustavi linearnih jednadžbi, linearna funkcija i jednadžba pravca;
4. za 8. razred: kvadriranje i korjenovanje, Pitagorin poučak, realni brojevi, preslikavanja ravnine; točke, pravci i ravnine u prostoru, geometrijska tijela.

4.3 Postupak istraživanja

Upitnike su ispunili predmetni nastavnici Matematike/Informatike te su upitnici bili anonimni, odnosno nisu sadržavali podatke koji bi upućivali na informacije o kojem se učeniku radi. Istraživanje je provedeno u proljeće 2018. godine kada su predmetni učitelji ispunili upitnike s podatcima s kraja nastavne godine 2016./2017.

4.4 Cilj istraživanja

Osnovni je zadatak bio izmjeriti frekventnost, međuodnos, uvjetovanost, obilježenost i povezanost informatičkih i matematičkih kompetencija u osnovnom obrazovanju i provesti istraživanje o vrednovanju tih znanja u svakome razredu.

Temeljna je hipoteza ovog istraživanja da informatičke i matematičke kompetencije nisu nezavisne, nego uzročno-posljedično povezane, a s time je i cilj dokazati kauzalnu povezanost informatičkih i matematičkih kompetencija učenika viših razreda osnovne škole, te izraditi model njihove kauzalne povezanosti.

4.5 Problemi i hipoteze istraživanja

Prva hipoteza (H1)

H1: Provjeriti postoji li statistički značajna povezanost između završnih ocjena iz Informatike i Matematike kod učenika nakon završenih pojedinih razreda osnovne škole.

a) Provjeriti postoji li statistički značajna povezanost između završnih ocjena iz Informatike i Matematike kod učenika nakon završenog petog razreda osnovne škole,
b) Provjeriti postoji li statistički značajna povezanost između završnih ocjena iz Informatike i Matematike kod učenika nakon završenog šestog razreda osnovne škole,
c) Provjeriti postoji li statistički značajna povezanost između završnih ocjena iz Informatike i Matematike kod učenika nakon završenog sedmog razreda osnovne škole,
d) Provjeriti postoji li statistički značajna povezanost između završnih ocjena iz Informatike i Matematike kod učenika nakon završenog osmog razreda osnovne škole.

Druga hipoteza (H2)

H2: Provjeriti postoji li statistički značajna povezanost između ocjena pojedinih tema iz Informatike i Matematike kod učenika nakon završenih pojedinih razreda osnovne škole.

a) Provjeriti postoji li statistički značajna povezanost između ocjena pojedinih tema iz Informatike i Matematike kod učenika nakon završenog petog razreda osnovne škole,
b) Provjeriti postoji li statistički značajna povezanost između ocjena pojedinih tema iz Informatike i Matematike kod učenika nakon završenog šestog razreda osnovne škole,
c) Provjeriti postoji li statistički značajna povezanost između ocjena pojedinih tema iz Informatike i Matematike kod učenika nakon završenog sedmog razreda osnovne škole,
d) Provjeriti postoji li statistički značajna povezanost između ocjena pojedinih tema iz Informatike i Matematike kod učenika nakon završenog osmog razreda osnovne škole.

Treća hipoteza (H3)

H3: Provjeriti postoji li statistički značajna razlika u povezanosti između završne ocjene iz Matematike i Informatike te povezanosti između završne ocjene iz Matematike i završne ocjene iz ostalih predmeta te općeg uspjeha nakon završenih pojedinih razreda osnovne škole.

a) Provjeriti postoji li statistički značajna razlika u povezanosti između završne ocjene iz Matematike i Informatike te povezanosti između završne ocjene iz Matematike i završne ocjene iz ostalih predmeta te općeg uspjeha nakon završenog petog razreda osnovne škole.
b) Provjeriti postoji li statistički značajna razlika u povezanosti između završne ocjene iz Matematike i Informatike te povezanosti između završne ocjene iz Matematike i

završne ocjene iz ostalih predmeta te općeg uspjeha nakon završenog šestog razreda osnovne škole.

c) Provjeriti postoji li statistički značajna razlika u povezanosti između završne ocjene iz Matematike i Informatike te povezanosti između završne ocjene iz Matematike i završne ocjene iz ostalih predmeta te općeg uspjeha nakon završenog sedmog razreda osnovne škole.
d) Provjeriti postoji li statistički značajna razlika u povezanosti između završne ocjene iz Matematike i Informatike te povezanosti između završne ocjene iz Matematike i završne ocjene iz ostalih predmeta te općeg uspjeha nakon završenog osmog razreda osnovne škole.

Četvrta hipoteza (H4)

H4: Provjeriti postoji li kauzalna povezanost obrazovnih postignuća učenika viših razreda osnovne škole između pojedinih tematskih nastavnih sadržaja Informatike i Matematike.

Temeljem korelacijskih analiza pokušat ćemo odgovoriti na prva četiri postavljena problema i provjeriti naše hipoteze da:

1. postoji statistički značajna pozitivna povezanost i u završnim ocjenama između Informatike i Matematike u svim višim razredima osnovne škole odnosno da s povećanjem ocjene u matematici raste i ocjena u informatici (kao i obrnuto).
2. postoji statistički značajna pozitivna povezanost ocjena pojedinih tema između Informatike i Matematike u svim višim razredima osnovne škole odnosno da s povećanjem ocjene u temama iz Matematike raste i ocjena u temama iz Informatike (kao i obrnuto).
3. postoji statistički značajna razlika u povezanosti između završne ocjene iz Matematike i Informatike te povezanosti između završne ocjene iz Matematike i završne ocjene iz ostalih predmeta te općeg uspjeha nakon završenih pojedinih razreda osnovne škole. Razlika ide u smjeru da je povezanost u završnoj ocjeni iz Matematike i Informatike statistički značajno veća od povezanosti između završne ocjene iz Matematike i završne ocjene iz ostalih predmeta te općeg uspjeha.

Uz standardne statističke alate koji utvrđuju korelaciju, kauzalnu povezanost ćemo propitivati uz pomoć već opisanog Bayesovog modela. Na kraju istraživanja sintetizirat će se rezultati istraživačkoga rada te izvesti zaključci o povezanosti informatičko-matematičkih kompetencija za svaki razred. Primjenom Bayesovog modela će se dokazati uzročno-posljedična povezanost pojedinih informatičko-matematičkih kompetencija.

5 REZULTATI ISTRAŽIVANJA

Rezultati će istraživanja biti prikazani prema postavljenim problemima, a prije prikaza rezultata vezanih uz istraživačke probleme prikazat će se deskriptivna statistika mjerenih varijabli.

5.1 Deskriptivna statistika mjerenih varijabli

Deskriptivna je statistika posebno napravljena za pojedinačne predmete, a posebno za pojedine teme unutar Matematike i Informatike. Ovo je prikazano u poglavljima koja slijede.

5.1.1 Pojedinačni predmeti

U sljedećoj tablici su prikazane srednje vrijednosti i pripadajuća raspršenja za ocjene iz svih predmeta koje su prikupljene tijekom istraživanja.

Tablica 2. Srednje vrijednosti i pripadajuća raspršenja ocjena svih predmeta prikupljenih u istraživanju

PREDMET	N	M	σ	C	D	min	maks
Opći uspjeh	1000	3.94	0.279	3.92	4.00	3.15	4.82
Hrvatski jezik	1000	3.75	1.072	4.00	5.00	2.00	5.00
Likovna kultura	1000	4.50	0.500	5.00	5.00	4.00	5.00
Glazbena kultura	1000	4.49	0.500	4.00	4.00	4.00	5.00
Engleski jezik	1000	3.52	1.132	4.00	5.00	2.00	5.00
Priroda	500	3.54	1.100	4.00	3.00	2.00	5.00
Biologija	500	3.57	1.119	4.00	5.00	2.00	5.00
Kemija	500	3.56	1.110	4.00	5.00	2.00	5.00

Fizika	500	3.47	1.149	3.00	2.00	2.00	5.00
Povijest	1000	3.54	1.093	4.00	4.00	2.00	5.00
Geografija	1000	3.55	1.116	4.00	5.00	2.00	5.00
Tehnička kultura	1000	4.50	0.500	4.00	4.00	4.00	5.00
Tjelesna i zdravstvena kultura	1000	4.49	0.500	4.00	4.00	4.00	5.00
Matematika	1000	3.74	1.002	4.00	4.00	2.00	5.00
Informatika	1000	4.12	0.798	4.00	5.00	3.00	5.00

LEGENDA:

N – broj sudionika

M – aritmetička sredina

σ – standardna devijacija

C – centralna vrijednost

D – dominantna vrijednost

min – najmanja ocjena

maks – najveća ocjena

Pregled srednjih vrijednosti u gornjoj tablici donosi informacije da učenici najviše ocjene imaju iz odgojnih predmeta: Likovne (*M* = 4.50), Tehničke (*M* = 4.50), Glazbene (*M* = 4.49), te Tjelesne i zdravstvene kulture (*M* = 4.50).

Slijedi detaljna deskriptivna statistika za svaki predmet i razred, počevši s Hrvatskim jezikom.

Tablica 3. Deskriptivna statistika za predmet Hrvatski jezik

Razred	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
5	Gradska	M	64	2	5	4,08	,948	4,0	3,0	5,0
		Ž	60	2	5	3,85	1,039	4,0	3,0	5,0
		Ukupno	**124**	**2**	**5**	**3,97**	**,995**	**4,0**	**3,0**	**5,0**
	Seoska	M	60	2	5	4,05	,999	4,0	3,0	5,0
		Ž	66	2	5	4,09	,924	4,0	3,0	5,0
		Ukupno	**126**	**2**	**5**	**4,07**	**,956**	**4,0**	**3,0**	**5,0**
	Ukupno	M	124	2	5	4,06	,969	4,0	3,0	5,0
		Ž	126	2	5	3,98	,984	4,0	3,0	5,0

		Ukupno	**250**	**2**	**5**	**4,02**	**,975**	**4,0**	**3,0**	**5,0**
6	Gradska	M	50	2	5	3,64	1,005	4,0	3,0	4,0
		Ž	65	2	5	3,63	1,098	4,0	3,0	5,0
		Ukupno	**115**	**2**	**5**	**3,63**	**1,054**	**4,0**	**3,0**	**5,0**
	Seoska	M	60	2	5	3,63	1,041	4,0	3,0	4,0
		Ž	75	2	5	3,69	1,052	4,0	3,0	5,0
		Ukupno	**135**	**2**	**5**	**3,67**	**1,044**	**4,0**	**3,0**	**5,0**
	Ukupno	M	110	2	5	3,64	1,020	4,0	3,0	4,0
		Ž	140	2	5	3,66	1,070	4,0	3,0	5,0
		Ukupno	**250**	**2**	**5**	**3,65**	**1,047**	**4,0**	**3,0**	**5,0**
7	Gradska	M	69	2	5	3,64	1,150	4,0	3,0	5,0
		Ž	63	2	5	3,51	1,134	4,0	2,0	5,0
		Ukupno	**132**	**2**	**5**	**3,58**	**1,140**	**4,0**	**3,0**	**5,0**
	Seoska	M	61	2	5	3,74	1,047	4,0	3,0	5,0
		Ž	57	2	5	3,72	1,082	4,0	3,0	5,0
		Ukupno	**118**	**2**	**5**	**3,73**	**1,059**	**4,0**	**3,0**	**5,0**
	Ukupno	M	130	2	5	3,68	1,100	4,0	3,0	5,0
		Ž	120	2	5	3,61	1,110	4,0	3,0	5,0
		Ukupno	**250**	**2**	**5**	**3,65**	**1,103**	**4,0**	**3,0**	**5,0**
8	Gradska	M	55	2	5	3,65	1,142	4,0	3,0	5,0
		Ž	75	2	5	3,65	1,133	4,0	3,0	5,0
		Ukupno	**130**	**2**	**5**	**3,65**	**1,132**	**4,0**	**3,0**	**5,0**
	Seoska	M	65	2	5	3,60	1,087	4,0	3,0	4,0
		Ž	55	2	5	3,82	1,124	4,0	3,0	5,0
		Ukupno	**120**	**2**	**5**	**3,70**	**1,105**	**4,0**	**3,0**	**5,0**
	Ukupno	M	120	2	5	3,63	1,108	4,0	3,0	5,0
		Ž	130	2	5	3,72	1,128	4,0	3,0	5,0
		Ukupno	**250**	**2**	**5**	**3,68**	**1,117**	**4,0**	**3,0**	**5,0**
Ukupno	Gradska	M	238	2	5	3,76	1,078	4,0	3,0	5,0
		Ž	263	2	5	3,66	1,104	4,0	3,0	5,0
		Ukupno	**501**	**2**	**5**	**3,71**	**1,092**	**4,0**	**3,0**	**5,0**
	Seoska	M	246	2	5	3,75	1,053	4,0	3,0	5,0
		Ž	253	2	5	3,83	1,050	4,0	3,0	5,0
		Ukupno	**499**	**2**	**5**	**3,79**	**1,051**	**4,0**	**3,0**	**5,0**
	Ukupno	M	484	2	5	3,76	1,064	4,0	3,0	5,0
		Ž	516	2	5	3,74	1,080	4,0	3,0	5,0
		Ukupno	**1000**	**2**	**5**	**3,75**	**1,072**	**4,0**	**3,0**	**5,0**

Iz tablice se vidi vrlo mala, ali konstantna razlika u prosječnim ocjenama u korist ruralnih škola. Promotrimo deskriptivnu statistiku za predmet Likovna kultura.

Tablica 4. Deskriptivna statistika za predmet Likovna kultura

Razred	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
5	Gradska	M	64	4	5	4,53	,503	5,0	4,0	5,0
		Ž	60	4	5	4,45	,502	4,0	4,0	5,0
		Ukupno	**124**	**4**	**5**	**4,49**	**,502**	**4,0**	**4,0**	**5,0**
	Seoska	M	60	4	5	4,48	,504	4,0	4,0	5,0
		Ž	66	4	5	4,38	,489	4,0	4,0	5,0
		Ukupno	**126**	**4**	**5**	**4,43**	**,497**	**4,0**	**4,0**	**5,0**
	Ukupno	M	124	4	5	4,51	,502	5,0	4,0	5,0
		Ž	126	4	5	4,41	,494	4,0	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,46**	**,499**	**4,0**	**4,0**	**5,0**
6	Gradska	M	50	4	5	4,58	,499	5,0	4,0	5,0
		Ž	65	4	5	4,52	,503	5,0	4,0	5,0
		Ukupno	**115**	**4**	**5**	**4,55**	**,500**	**5,0**	**4,0**	**5,0**
	Seoska	M	60	4	5	4,55	,502	5,0	4,0	5,0
		Ž	75	4	5	4,52	,503	5,0	4,0	5,0
		Ukupno	**135**	**4**	**5**	**4,53**	**,501**	**5,0**	**4,0**	**5,0**
	Ukupno	M	110	4	5	4,56	,498	5,0	4,0	5,0
		Ž	140	4	5	4,52	,501	5,0	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,54**	**,499**	**5,0**	**4,0**	**5,0**
7	Gradska	M	69	4	5	4,52	,503	5,0	4,0	5,0
		Ž	63	4	5	4,49	,504	4,0	4,0	5,0
		Ukupno	**132**	**4**	**5**	**4,51**	**,502**	**5,0**	**4,0**	**5,0**
	Seoska	M	61	4	5	4,48	,504	4,0	4,0	5,0
		Ž	57	4	5	4,51	,504	5,0	4,0	5,0
		Ukupno	**118**	**4**	**5**	**4,49**	**,502**	**4,0**	**4,0**	**5,0**
	Ukupno	M	130	4	5	4,50	,502	4,5	4,0	5,0
		Ž	120	4	5	4,50	,502	4,5	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,50**	**,501**	**4,5**	**4,0**	**5,0**
8	Gradska	M	55	4	5	4,58	,498	5,0	4,0	5,0
		Ž	75	4	5	4,57	,498	5,0	4,0	5,0
		Ukupno	**130**	**4**	**5**	**4,58**	**,496**	**5,0**	**4,0**	**5,0**
	Seoska	M	65	4	5	4,46	,502	4,0	4,0	5,0

		Ž	55	4	5	4,44	,501	4,0	4,0	5,0
		Ukupno	**120**	**4**	**5**	**4,45**	**,500**	**4,0**	**4,0**	**5,0**
	Ukupno	M	120	4	5	4,52	,502	5,0	4,0	5,0
		Ž	130	4	5	4,52	,502	5,0	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,52**	**,501**	**5,0**	**4,0**	**5,0**
Ukupno	Gradska	M	238	4	5	4,55	,498	5,0	4,0	5,0
		Ž	263	4	5	4,51	,501	5,0	4,0	5,0
		Ukupno	**501**	**4**	**5**	**4,53**	**,500**	**5,0**	**4,0**	**5,0**
	Seoska	M	246	4	5	4,49	,501	4,0	4,0	5,0
		Ž	253	4	5	4,46	,500	4,0	4,0	5,0
		Ukupno	**499**	**4**	**5**	**4,48**	**,500**	**4,0**	**4,0**	**5,0**
	Ukupno	M	484	4	5	4,52	,500	5,0	4,0	5,0
		Ž	516	4	5	4,49	,500	4,0	4,0	5,0
		Ukupno	**1000**	**4**	**5**	**4,50**	**,500**	**5,0**	**4,0**	**5,0**

Iz priložene tablice vidimo da je za predmet Likovna kultura na čitavom uzorku minimalna ocjena bila 4, pa su prosječne vrijednosti vrlo slične, što vidimo i u sljedećim tablicama u kojima je dana deskriptivna statistika za predmete Glazbena kultura, Tehnička kultura i Tjelesna i zdravstvena kultura.

Tablica 5. Deskriptivna statistika za predmet Glazbena kultura

Razred	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
5	Gradska	M	64	4	5	4,50	,504	4,5	4,0	5,0
		Ž	60	4	5	4,47	,503	4,0	4,0	5,0
		Ukupno	**124**	**4**	**5**	**4,48**	**,502**	**4,0**	**4,0**	**5,0**
	Seoska	M	60	4	5	4,45	,502	4,0	4,0	5,0
		Ž	66	4	5	4,52	,504	5,0	4,0	5,0
		Ukupno	**126**	**4**	**5**	**4,48**	**,502**	**4,0**	**4,0**	**5,0**
	Ukupno	M	124	4	5	4,48	,501	4,0	4,0	5,0
		Ž	126	4	5	4,49	,502	4,0	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,48**	**,501**	**4,0**	**4,0**	**5,0**
6	Gradska	M	50	4	5	4,40	,495	4,0	4,0	5,0
		Ž	65	4	5	4,46	,502	4,0	4,0	5,0
		Ukupno	**115**	**4**	**5**	**4,43**	**,498**	**4,0**	**4,0**	**5,0**
	Seoska	M	60	4	5	4,53	,503	5,0	4,0	5,0
		Ž	75	4	5	4,61	,490	5,0	4,0	5,0

		Ukupno	**135**	**4**	**5**	**4,58**	**,496**	**5,0**	**4,0**	**5,0**
	Ukupno	M	110	4	5	4,47	,502	4,0	4,0	5,0
		Ž	140	4	5	4,54	,500	5,0	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,51**	**,501**	**5,0**	**4,0**	**5,0**
7	Gradska	M	69	4	5	4,52	,503	5,0	4,0	5,0
		Ž	63	4	5	4,48	,503	4,0	4,0	5,0
		Ukupno	**132**	**4**	**5**	**4,50**	**,502**	**4,5**	**4,0**	**5,0**
	Seoska	M	61	4	5	4,48	,504	4,0	4,0	5,0
		Ž	57	4	5	4,46	,503	4,0	4,0	5,0
		Ukupno	**118**	**4**	**5**	**4,47**	**,501**	**4,0**	**4,0**	**5,0**
	Ukupno	M	130	4	5	4,50	,502	4,5	4,0	5,0
		Ž	120	4	5	4,47	,501	4,0	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,48**	**,501**	**4,0**	**4,0**	**5,0**
8	Gradska	M	55	4	5	4,60	,494	5,0	4,0	5,0
		Ž	75	4	5	4,45	,501	4,0	4,0	5,0
		Ukupno	**130**	**4**	**5**	**4,52**	**,502**	**5,0**	**4,0**	**5,0**
	Seoska	M	65	4	5	4,42	,497	4,0	4,0	5,0
		Ž	55	4	5	4,51	,505	5,0	4,0	5,0
		Ukupno	**120**	**4**	**5**	**4,46**	**,500**	**4,0**	**4,0**	**5,0**
	Ukupno	M	120	4	5	4,50	,502	4,5	4,0	5,0
		Ž	130	4	5	4,48	,501	4,0	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,49**	**,501**	**4,0**	**4,0**	**5,0**
Ukupno	Gradska	M	238	4	5	4,51	,501	5,0	4,0	5,0
		Ž	263	4	5	4,46	,500	4,0	4,0	5,0
		Ukupno	**501**	**4**	**5**	**4,49**	**,500**	**4,0**	**4,0**	**5,0**
	Seoska	M	246	4	5	4,47	,500	4,0	4,0	5,0
		Ž	253	4	5	4,53	,500	5,0	4,0	5,0
		Ukupno	**499**	**4**	**5**	**4,50**	**,501**	**4,0**	**4,0**	**5,0**
	Ukupno	M	484	4	5	4,49	,500	4,0	4,0	5,0
		Ž	516	4	5	4,50	,500	4,0	4,0	5,0
		Ukupno	**1000**	**4**	**5**	**4,49**	**,500**	**4,0**	**4,0**	**5,0**

Tablica 6. Deskriptivna statistika za predmet Tehnička kultura

Razred	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
5	Gradska	M	64	4	5	4,48	,504	4,0	4,0	5,0
		Ž	60	4	5	4,48	,504	4,0	4,0	5,0
		Ukupno	**124**	**4**	**5**	**4,48**	**,502**	**4,0**	**4,0**	**5,0**
	Seoska	M	60	4	5	4,47	,503	4,0	4,0	5,0
		Ž	66	4	5	4,47	,503	4,0	4,0	5,0
		Ukupno	**126**	**4**	**5**	**4,47**	**,501**	**4,0**	**4,0**	**5,0**
	Ukupno	M	124	4	5	4,48	,501	4,0	4,0	5,0
		Ž	126	4	5	4,48	,501	4,0	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,48**	**,500**	**4,0**	**4,0**	**5,0**
6	Gradska	M	50	4	5	4,46	,503	4,0	4,0	5,0
		Ž	65	4	5	4,51	,504	5,0	4,0	5,0
		Ukupno	**115**	**4**	**5**	**4,49**	**,502**	**4,0**	**4,0**	**5,0**
	Seoska	M	60	4	5	4,48	,504	4,0	4,0	5,0
		Ž	75	4	5	4,52	,503	5,0	4,0	5,0
		Ukupno	**135**	**4**	**5**	**4,50**	**,502**	**5,0**	**4,0**	**5,0**
	Ukupno	M	110	4	5	4,47	,502	4,0	4,0	5,0
		Ž	140	4	5	4,51	,502	5,0	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,50**	**,501**	**4,0**	**4,0**	**5,0**
7	Gradska	M	69	4	5	4,57	,499	5,0	4,0	5,0
		Ž	63	4	5	4,51	,504	5,0	4,0	5,0
		Ukupno	**132**	**4**	**5**	**4,54**	**,500**	**5,0**	**4,0**	**5,0**
	Seoska	M	61	4	5	4,49	,504	4,0	4,0	5,0
		Ž	57	4	5	4,44	,501	4,0	4,0	5,0
		Ukupno	**118**	**4**	**5**	**4,47**	**,501**	**4,0**	**4,0**	**5,0**
	Ukupno	M	130	4	5	4,53	,501	5,0	4,0	5,0
		Ž	120	4	5	4,48	,501	4,0	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,50**	**,501**	**5,0**	**4,0**	**5,0**
8	Gradska	M	55	4	5	4,56	,501	5,0	4,0	5,0
		Ž	75	4	5	4,49	,503	4,0	4,0	5,0
		Ukupno	**130**	**4**	**5**	**4,52**	**,501**	**5,0**	**4,0**	**5,0**
	Seoska	M	65	4	5	4,48	,503	4,0	4,0	5,0
		Ž	55	4	5	4,51	,505	5,0	4,0	5,0
		Ukupno	**120**	**4**	**5**	**4,49**	**,502**	**4,0**	**4,0**	**5,0**
	Ukupno	M	120	4	5	4,52	,502	5,0	4,0	5,0
		Ž	130	4	5	4,50	,502	4,5	4,0	5,0

		Ukupno	**250**	**4**	**5**	**4,51**	**,501**	**5,0**	**4,0**	**5,0**
Ukupno	Gradska	M	238	4	5	4,52	,501	5,0	4,0	5,0
		Ž	263	4	5	4,50	,501	4,0	4,0	5,0
		Ukupno	**501**	**4**	**5**	**4,51**	**,500**	**5,0**	**4,0**	**5,0**
	Seoska	M	246	4	5	4,48	,501	4,0	4,0	5,0
		Ž	253	4	5	4,49	,501	4,0	4,0	5,0
		Ukupno	**499**	**4**	**5**	**4,48**	**,500**	**4,0**	**4,0**	**5,0**
	Ukupno	M	484	4	5	4,50	,501	4,5	4,0	5,0
		Ž	516	4	5	4,49	,500	4,0	4,0	5,0
		Ukupno	**1000**	**4**	**5**	**4,50**	**,500**	**4,0**	**4,0**	**5,0**

Tablica 7. Deskriptivna statistika za predmet Tjelesna i zdravstvena kultura

Razred	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
5	Gradska	M	64	4	5	4,53	,503	5,0	4,0	5,0
		Ž	60	4	5	4,53	,503	5,0	4,0	5,0
		Ukupno	**124**	**4**	**5**	**4,53**	**,501**	**5,0**	**4,0**	**5,0**
	Seoska	M	60	4	5	4,42	,497	4,0	4,0	5,0
		Ž	66	4	5	4,42	,498	4,0	4,0	5,0
		Ukupno	**126**	**4**	**5**	**4,42**	**,496**	**4,0**	**4,0**	**5,0**
	Ukupno	M	124	4	5	4,48	,501	4,0	4,0	5,0
		Ž	126	4	5	4,48	,501	4,0	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,48**	**,500**	**4,0**	**4,0**	**5,0**
6	Gradska	M	50	4	5	4,56	,501	5,0	4,0	5,0
		Ž	65	4	5	4,48	,503	4,0	4,0	5,0
		Ukupno	**115**	**4**	**5**	**4,51**	**,502**	**5,0**	**4,0**	**5,0**
	Seoska	M	60	4	5	4,58	,497	5,0	4,0	5,0
		Ž	75	4	5	4,41	,496	4,0	4,0	5,0
		Ukupno	**135**	**4**	**5**	**4,49**	**,502**	**4,0**	**4,0**	**5,0**
	Ukupno	M	110	4	5	4,57	,497	5,0	4,0	5,0
		Ž	140	4	5	4,44	,499	4,0	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,50**	**,501**	**4,5**	**4,0**	**5,0**
7	Gradska	M	69	4	5	4,48	,503	4,0	4,0	5,0
		Ž	63	4	5	4,48	,503	4,0	4,0	5,0
		Ukupno	**132**	**4**	**5**	**4,48**	**,501**	**4,0**	**4,0**	**5,0**
	Seoska	M	61	4	5	4,59	,496	5,0	4,0	5,0
		Ž	57	4	5	4,54	,503	5,0	4,0	5,0

		Ukupno	**118**	**4**	**5**	**4,57**	**,497**	**5,0**	**4,0**	**5,0**
	Ukupno	M	130	4	5	4,53	,501	5,0	4,0	5,0
		Ž	120	4	5	4,51	,502	5,0	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,52**	**,501**	**5,0**	**4,0**	**5,0**
8	Gradska	M	55	4	5	4,40	,494	4,0	4,0	5,0
		Ž	75	4	5	4,47	,502	4,0	4,0	5,0
		Ukupno	**130**	**4**	**5**	**4,44**	**,498**	**4,0**	**4,0**	**5,0**
	Seoska	M	65	4	5	4,42	,497	4,0	4,0	5,0
		Ž	55	4	5	4,55	,503	5,0	4,0	5,0
		Ukupno	**120**	**4**	**5**	**4,48**	**,501**	**4,0**	**4,0**	**5,0**
	Ukupno	M	120	4	5	4,41	,494	4,0	4,0	5,0
		Ž	130	4	5	4,50	,502	4,5	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,46**	**,499**	**4,0**	**4,0**	**5,0**
Ukupno	Gradska	M	238	4	5	4,49	,501	4,0	4,0	5,0
		Ž	263	4	5	4,49	,501	4,0	4,0	5,0
		Ukupno	**501**	**4**	**5**	**4,49**	**,500**	**4,0**	**4,0**	**5,0**
	Seoska	M	246	4	5	4,50	,501	4,5	4,0	5,0
		Ž	253	4	5	4,47	,500	4,0	4,0	5,0
		Ukupno	**499**	**4**	**5**	**4,49**	**,500**	**4,0**	**4,0**	**5,0**
	Ukupno	M	484	4	5	4,50	,501	4,0	4,0	5,0
		Ž	516	4	5	4,48	,500	4,0	4,0	5,0
		Ukupno	**1000**	**4**	**5**	**4,49**	**,500**	**4,0**	**4,0**	**5,0**

Tablica 8. Deskriptivna statistika za predmet Engleski jezik

Razred	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
5	Gradska	M	64	2	5	3,59	1,137	4,0	2,5	5,0
		Ž	60	2	5	3,27	1,133	3,0	2,0	4,0
		Ukupno	124	2	5	3,44	1,142	4,0	2,0	4,0
	Seoska	M	60	2	5	3,78	1,106	4,0	3,0	5,0
		Ž	66	2	5	3,45	1,205	3,5	2,0	5,0
		Ukupno	126	2	5	3,61	1,166	4,0	2,0	5,0
	Ukupno	M	124	2	5	3,69	1,122	4,0	3,0	5,0
		Ž	126	2	5	3,37	1,170	3,0	2,0	4,0
		Ukupno	**250**	**2**	**5**	**3,52**	**1,155**	**4,0**	**2,0**	**5,0**
6	Gradska	M	50	2	5	3,56	1,198	4,0	2,0	5,0
		Ž	65	2	5	3,68	1,062	4,0	3,0	5,0

		Ukupno	**115**	**2**	**5**	**3,63**	**1,120**	**4,0**	**3,0**	**5,0**
	Seoska	M	60	2	5	3,58	1,046	4,0	3,0	4,0
		Ž	75	2	5	3,60	1,040	4,0	3,0	4,0
		Ukupno	**135**	**2**	**5**	**3,59**	**1,039**	**4,0**	**3,0**	**4,0**
	Ukupno	M	110	2	5	3,57	1,113	4,0	3,0	5,0
		Ž	140	2	5	3,64	1,047	4,0	3,0	5,0
		Ukupno	**250**	**2**	**5**	**3,61**	**1,075**	**4,0**	**3,0**	**5,0**
7	Gradska	M	69	2	5	3,51	1,171	4,0	2,0	5,0
		Ž	63	2	5	3,41	1,227	3,0	2,0	5,0
		Ukupno	**132**	**2**	**5**	**3,46**	**1,194**	**3,0**	**2,0**	**5,0**
	Seoska	M	61	2	5	3,57	1,117	3,0	3,0	5,0
		Ž	57	2	5	3,23	1,069	3,0	2,0	4,0
		Ukupno	**118**	**2**	**5**	**3,41**	**1,104**	**3,0**	**3,0**	**4,0**
	Ukupno	M	130	2	5	3,54	1,142	3,0	3,0	5,0
		Ž	120	2	5	3,33	1,153	3,0	2,0	4,0
		Ukupno	**250**	**2**	**5**	**3,44**	**1,150**	**3,0**	**2,0**	**5,0**
8	Gradska	M	55	2	5	3,58	1,150	3,0	3,0	5,0
		Ž	75	2	5	3,49	1,167	3,0	2,0	5,0
		Ukupno	**130**	**2**	**5**	**3,53**	**1,156**	**3,0**	**3,0**	**5,0**
	Seoska	M	65	2	5	3,48	1,147	4,0	2,0	4,0
		Ž	55	2	5	3,49	1,136	3,0	2,0	5,0
		Ukupno	**120**	**2**	**5**	**3,48**	**1,137**	**3,5**	**2,0**	**4,5**
	Ukupno	M	120	2	5	3,53	1,145	3,0	3,0	5,0
		Ž	130	2	5	3,49	1,150	3,0	2,0	5,0
		Ukupno	**250**	**2**	**5**	**3,51**	**1,145**	**3,0**	**2,0**	**5,0**
Ukupno	Gradska	M	238	2	5	3,56	1,156	4,0	2,0	5,0
		Ž	263	2	5	3,47	1,152	3,0	2,0	5,0
		Ukupno	**501**	**2**	**5**	**3,51**	**1,153**	**3,0**	**2,0**	**5,0**
	Seoska	M	246	2	5	3,60	1,105	4,0	3,0	5,0
		Ž	253	2	5	3,45	1,114	3,0	2,0	4,0
		Ukupno	**499**	**2**	**5**	**3,53**	**1,111**	**4,0**	**3,0**	**5,0**
	Ukupno	M	484	2	5	3,58	1,129	4,0	3,0	5,0
		Ž	516	2	5	3,46	1,132	3,0	2,0	4,5
		Ukupno	**1000**	**2**	**5**	**3,52**	**1,132**	**4,0**	**3,0**	**5,0**

Iz prethodne se tablice ne vidi razlika prosječnih ocjena iz Engleskog jezika za ruralno i urbano područje, kao niti u sljedećoj tablici, koja daje deskriptivnu statistiku za predmet Priroda, kojega učenici pohađaju do šestog razreda.

Tablica 9. Deskriptivna statistika za predmet Priroda

Razred	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
5	Gradska	M	64	2	5	3,52	1,195	3,0	2,0	5,0
		Ž	60	2	5	3,62	1,195	4,0	2,5	5,0
		Ukupno	**124**	**2**	**5**	**3,56**	**1,191**	**3,5**	**2,0**	**5,0**
	Seoska	M	60	2	5	3,65	1,117	4,0	3,0	5,0
		Ž	66	2	5	3,47	,964	3,0	3,0	4,0
		Ukupno	**126**	**2**	**5**	**3,56**	**1,040**	**4,0**	**3,0**	**4,0**
	Ukupno	M	124	2	5	3,58	1,155	4,0	3,0	5,0
		Ž	126	2	5	3,54	1,078	3,5	3,0	4,0
		Ukupno	**250**	**2**	**5**	**3,56**	**1,115**	**4,0**	**3,0**	**5,0**
6	Gradska	M	50	2	5	3,46	1,092	3,0	3,0	4,0
		Ž	65	2	5	3,68	1,047	4,0	3,0	5,0
		Ukupno	**115**	**2**	**5**	**3,58**	**1,068**	**4,0**	**3,0**	**5,0**
	Seoska	M	60	2	5	3,45	1,171	3,0	2,0	5,0
		Ž	75	2	5	3,51	1,057	4,0	3,0	4,0
		Ukupno	**135**	**2**	**5**	**3,48**	**1,105**	**3,0**	**3,0**	**4,0**
	Ukupno	M	110	2	5	3,45	1,130	3,0	2,0	5,0
		Ž	140	2	5	3,59	1,052	4,0	3,0	4,0
		Ukupno	**250**	**2**	**5**	**3,53**	**1,087**	**3,0**	**3,0**	**4,0**
Ukupno	Gradska	M	238	2	5	3,49	1,146	3,0	3,0	5,0
		Ž	263	2	5	3,65	1,116	4,0	3,0	5,0
		Ukupno	**501**	**2**	**5**	**3,57**	**1,131**	**4,0**	**3,0**	**5,0**
	Seoska	M	246	2	5	3,55	1,144	4,0	2,5	5,0
		Ž	253	2	5	3,49	1,011	3,0	3,0	4,0
		Ukupno	**499**	**2**	**5**	**3,52**	**1,073**	**4,0**	**3,0**	**4,0**
	Ukupno	M	484	2	5	3,52	1,143	3,0	3,0	5,0
		Ž	516	2	5	3,56	1,063	4,0	3,0	4,0
		Ukupno	**1000**	**2**	**5**	**3,54**	**1,100**	**4,0**	**3,0**	**5,0**

Slijedi tablica deskriptivne statistike za predmet Povijest.

Tablica 10. Deskriptivna statistika za predmet Povijest

Razred	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
5	Gradska	M	64	2	5	3,73	1,087	4,0	3,0	5,0
		Ž	60	2	5	3,58	1,078	4,0	3,0	4,0
		Ukupno	**124**	**2**	**5**	**3,66**	**1,081**	**4,0**	**3,0**	**5,0**
	Seoska	M	60	2	5	3,43	1,031	3,5	3,0	4,0
		Ž	66	2	5	3,67	1,128	4,0	3,0	5,0
		Ukupno	**126**	**2**	**5**	**3,56**	**1,085**	**4,0**	**3,0**	**4,0**
	Ukupno	M	124	2	5	3,59	1,067	4,0	3,0	4,0
		Ž	126	2	5	3,63	1,101	4,0	3,0	5,0
		Ukupno	**250**	**2**	**5**	**3,61**	**1,082**	**4,0**	**3,0**	**5,0**
6	Gradska	M	50	2	5	3,42	1,197	3,0	2,0	5,0
		Ž	65	2	5	3,58	1,088	4,0	3,0	5,0
		Ukupno	**115**	**2**	**5**	**3,51**	**1,135**	**4,0**	**2,0**	**5,0**
	Seoska	M	60	2	5	3,42	1,183	3,0	2,0	5,0
		Ž	75	2	5	3,32	1,055	3,0	2,0	4,0
		Ukupno	**135**	**2**	**5**	**3,36**	**1,110**	**3,0**	**2,0**	**4,0**
	Ukupno	M	110	2	5	3,42	1,184	3,0	2,0	5,0
		Ž	140	2	5	3,44	1,075	3,0	3,0	4,0
		Ukupno	**250**	**2**	**5**	**3,43**	**1,122**	**3,0**	**2,0**	**4,0**
7	Gradska	M	69	2	5	3,59	1,129	4,0	3,0	5,0
		Ž	63	2	5	3,46	1,090	4,0	2,0	4,0
		Ukupno	**132**	**2**	**5**	**3,53**	**1,108**	**4,0**	**3,0**	**4,5**
	Seoska	M	61	2	5	3,64	,984	4,0	3,0	4,0
		Ž	57	2	5	3,63	1,096	4,0	3,0	5,0
		Ukupno	**118**	**2**	**5**	**3,64**	**1,035**	**4,0**	**3,0**	**5,0**
	Ukupno	M	130	2	5	3,62	1,059	4,0	3,0	5,0
		Ž	120	2	5	3,54	1,092	4,0	3,0	4,0
		Ukupno	**250**	**2**	**5**	**3,58**	**1,073**	**4,0**	**3,0**	**5,0**
8	Gradska	M	55	2	5	3,44	1,118	4,0	2,0	4,0
		Ž	75	2	5	3,57	1,042	4,0	3,0	4,0
		Ukupno	**130**	**2**	**5**	**3,52**	**1,073**	**4,0**	**3,0**	**4,0**
	Seoska	M	65	2	5	3,54	1,119	4,0	3,0	5,0
		Ž	55	2	5	3,58	1,117	4,0	3,0	5,0
		Ukupno	**120**	**2**	**5**	**3,56**	**1,114**	**4,0**	**3,0**	**5,0**
	Ukupno	M	120	2	5	3,49	1,115	4,0	2,0	4,0
		Ž	130	2	5	3,58	1,070	4,0	3,0	5,0

		Ukupno	**250**	**2**	**5**	**3,54**	**1,091**	**4,0**	**3,0**	**4,0**
Ukupno	Gradska	M	238	2	5	3,56	1,130	4,0	3,0	5,0
		Ž	263	2	5	3,55	1,068	4,0	3,0	4,0
		Ukupno	**501**	**2**	**5**	**3,55**	**1,097**	**4,0**	**3,0**	**4,0**
	Seoska	M	246	2	5	3,51	1,079	3,5	3,0	4,0
		Ž	253	2	5	3,54	1,100	4,0	3,0	4,0
		Ukupno	**499**	**2**	**5**	**3,52**	**1,089**	**4,0**	**3,0**	**4,0**
	Ukupno	M	484	2	5	3,53	1,104	4,0	3,0	4,0
		Ž	516	2	5	3,54	1,083	4,0	3,0	4,0
		Ukupno	**1000**	**2**	**5**	**3,54**	**1,093**	**4,0**	**3,0**	**4,0**

Iz prethodne tablice nisu vidljive neke veće razlike niti po vrsti škole (ruralna ili urbana) niti po nekom drugom obilježju, što vrijedi i za predmete Geografija, Matematika i Informatika, čije su detaljne deskriptivne statistike predočene u sljedećim tablicama.

Tablica 11. Deskriptivna statistika za predmet Geografija

Razred	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
5	Gradska	M	64	2	5	3,64	1,187	4,0	2,5	5,0
		Ž	60	2	5	3,35	1,132	3,0	2,0	4,0
		Ukupno	**124**	**2**	**5**	**3,50**	**1,165**	**4,0**	**2,0**	**5,0**
	Seoska	M	60	2	5	3,53	1,142	3,0	3,0	5,0
		Ž	66	2	5	3,61	1,080	4,0	3,0	5,0
		Ukupno	**126**	**2**	**5**	**3,57**	**1,106**	**4,0**	**3,0**	**5,0**
	Ukupno	M	124	2	5	3,59	1,162	4,0	3,0	5,0
		Ž	126	2	5	3,48	1,108	4,0	2,0	4,0
		Ukupno	**250**	**2**	**5**	**3,54**	**1,134**	**4,0**	**3,0**	**5,0**
6	Gradska	M	50	2	5	3,62	1,159	4,0	3,0	5,0
		Ž	65	2	5	3,42	1,102	3,0	2,0	4,0
		Ukupno	**115**	**2**	**5**	**3,50**	**1,127**	**3,0**	**3,0**	**5,0**
	Seoska	M	60	2	5	3,48	1,081	3,5	3,0	4,0
		Ž	75	2	5	3,49	1,045	3,0	3,0	4,0
		Ukupno	**135**	**2**	**5**	**3,49**	**1,057**	**3,0**	**3,0**	**4,0**
	Ukupno	M	110	2	5	3,55	1,114	4,0	3,0	5,0
		Ž	140	2	5	3,46	1,069	3,0	3,0	4,0
		Ukupno	**250**	**2**	**5**	**3,50**	**1,088**	**3,0**	**3,0**	**4,0**
7	Gradska	M	69	2	5	3,22	1,069	3,0	2,0	4,0

		Ž	63	2	5	3,71	1,156	4,0	3,0	5,0
		Ukupno	**132**	**2**	**5**	**3,45**	**1,135**	**3,0**	**2,0**	**4,0**
	Seoska	M	61	2	5	3,67	1,221	4,0	2,0	5,0
		Ž	57	2	5	3,72	1,130	4,0	3,0	5,0
		Ukupno	**118**	**2**	**5**	**3,69**	**1,173**	**4,0**	**3,0**	**5,0**
	Ukupno	M	130	2	5	3,43	1,161	3,0	2,0	5,0
		Ž	120	2	5	3,72	1,139	4,0	3,0	5,0
		Ukupno	**250**	**2**	**5**	**3,57**	**1,157**	**4,0**	**2,0**	**5,0**
8	Gradska	M	55	2	5	3,62	,991	4,0	3,0	4,0
		Ž	75	2	5	3,60	1,090	4,0	3,0	5,0
		Ukupno	**130**	**2**	**5**	**3,61**	**1,045**	**4,0**	**3,0**	**4,0**
	Seoska	M	65	2	5	3,65	1,110	4,0	3,0	5,0
		Ž	55	2	5	3,53	1,168	4,0	2,0	5,0
		Ukupno	**120**	**2**	**5**	**3,59**	**1,134**	**4,0**	**3,0**	**5,0**
	Ukupno	M	120	2	5	3,63	1,053	4,0	3,0	4,5
		Ž	130	2	5	3,57	1,120	4,0	3,0	5,0
		Ukupno	**250**	**2**	**5**	**3,60**	**1,087**	**4,0**	**3,0**	**5,0**
Ukupno	Gradska	M	238	2	5	3,51	1,113	4,0	3,0	4,0
		Ž	263	2	5	3,52	1,122	4,0	3,0	5,0
		Ukupno	**501**	**2**	**5**	**3,52**	**1,116**	**4,0**	**3,0**	**5,0**
	Seoska	M	246	2	5	3,59	1,135	4,0	3,0	5,0
		Ž	253	2	5	3,58	1,098	4,0	3,0	5,0
		Ukupno	**499**	**2**	**5**	**3,58**	**1,115**	**4,0**	**3,0**	**5,0**
	Ukupno	M	484	2	5	3,55	1,124	4,0	3,0	5,0
		Ž	516	2	5	3,55	1,109	4,0	3,0	5,0
		Ukupno	**1000**	**2**	**5**	**3,55**	**1,116**	**4,0**	**3,0**	**5,0**

Tablica 12. Deskriptivna statistika za predmet Matematika

Razred	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
5	Gradska	M	64	2	5	3,75	,926	4,0	3,0	4,5
		Ž	60	2	5	3,72	,976	4,0	3,0	4,0
		Ukupno	**124**	**2**	**5**	**3,73**	**,947**	**4,0**	**3,0**	**4,0**
	Seoska	M	60	2	5	3,98	,911	4,0	3,0	5,0
		Ž	66	2	5	3,71	,957	4,0	3,0	4,0
		Ukupno	**126**	**2**	**5**	**3,84**	**,942**	**4,0**	**3,0**	**5,0**
	Ukupno	M	124	2	5	3,86	,922	4,0	3,0	5,0

		Ž	126	2	5	3,71	,962	4,0	3,0	4,0
		Ukupno	**250**	**2**	**5**	**3,79**	**,944**	**4,0**	**3,0**	**5,0**
6	Gradska	M	50	2	5	3,56	,884	3,5	3,0	4,0
		Ž	65	2	5	3,94	,998	4,0	3,0	5,0
		Ukupno	**115**	**2**	**5**	**3,77**	**,965**	**4,0**	**3,0**	**5,0**
	Seoska	M	60	2	5	3,87	,812	4,0	3,0	4,0
		Ž	75	2	5	3,96	1,032	4,0	3,0	5,0
		Ukupno	**135**	**2**	**5**	**3,92**	**,939**	**4,0**	**3,0**	**5,0**
	Ukupno	M	110	2	5	3,73	,856	4,0	3,0	4,0
		Ž	140	2	5	3,95	1,013	4,0	3,0	5,0
		Ukupno	**250**	**2**	**5**	**3,85**	**,952**	**4,0**	**3,0**	**5,0**
7	Gradska	M	69	2	5	3,84	,885	4,0	3,0	5,0
		Ž	63	2	5	3,49	1,014	3,0	3,0	4,0
		Ukupno	**132**	**2**	**5**	**3,67**	**,961**	**4,0**	**3,0**	**4,0**
	Seoska	M	61	2	5	3,38	1,019	3,0	3,0	4,0
		Ž	57	2	5	3,77	1,069	4,0	3,0	5,0
		Ukupno	**118**	**2**	**5**	**3,57**	**1,058**	**3,0**	**3,0**	**5,0**
	Ukupno	M	130	2	5	3,62	,975	4,0	3,0	4,0
		Ž	120	2	5	3,63	1,046	3,5	3,0	5,0
		Ukupno	**250**	**2**	**5**	**3,62**	**1,007**	**4,0**	**3,0**	**4,0**
8	Gradska	M	55	2	5	3,65	1,126	4,0	3,0	5,0
		Ž	75	2	5	3,71	1,050	4,0	3,0	5,0
		Ukupno	**130**	**2**	**5**	**3,68**	**1,079**	**4,0**	**3,0**	**5,0**
	Seoska	M	65	2	5	3,78	,992	4,0	3,0	5,0
		Ž	55	2	5	3,65	1,236	4,0	2,0	5,0
		Ukupno	**120**	**2**	**5**	**3,73**	**1,107**	**4,0**	**3,0**	**5,0**
	Ukupno	M	120	2	5	3,73	1,053	4,0	3,0	5,0
		Ž	130	2	5	3,68	1,128	4,0	3,0	5,0
		Ukupno	**250**	**2**	**5**	**3,70**	**1,090**	**4,0**	**3,0**	**5,0**
Ukupno	Gradska	M	238	2	5	3,71	,956	4,0	3,0	4,0
		Ž	263	2	5	3,71	1,018	4,0	3,0	5,0
		Ukupno	**501**	**2**	**5**	**3,71**	**,988**	**4,0**	**3,0**	**5,0**
	Seoska	M	246	2	5	3,75	,960	4,0	3,0	5,0
		Ž	253	2	5	3,79	1,070	4,0	3,0	5,0
		Ukupno	**499**	**2**	**5**	**3,77**	**1,016**	**4,0**	**3,0**	**5,0**
	Ukupno	M	484	2	5	3,73	,957	4,0	3,0	4,5
		Ž	516	2	5	3,75	1,043	4,0	3,0	5,0

		Ukupno	**1000**	**2**	**5**	**3,74**	**1,002**	**4,0**	**3,0**	**5,0**

Tablica 13. Deskriptivna statistika za predmet Informatika

Razred	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
5	Gradska	M	64	4	5	4,44	,500	4,0	4,0	5,0
		Ž	60	4	5	4,52	,504	5,0	4,0	5,0
		Ukupno	**124**	**4**	**5**	**4,48**	**,501**	**4,0**	**4,0**	**5,0**
	Seoska	M	60	4	5	4,68	,469	5,0	4,0	5,0
		Ž	66	4	5	4,61	,492	5,0	4,0	5,0
		Ukupno	**126**	**4**	**5**	**4,64**	**,481**	**5,0**	**4,0**	**5,0**
	Ukupno	M	124	4	5	4,56	,499	5,0	4,0	5,0
		Ž	126	4	5	4,56	,498	5,0	4,0	5,0
		Ukupno	**250**	**4**	**5**	**4,56**	**,497**	**5,0**	**4,0**	**5,0**
6	Gradska	M	50	3	5	3,82	,774	4,0	3,0	4,0
		Ž	65	3	5	4,00	,829	4,0	3,0	5,0
		Ukupno	**115**	**3**	**5**	**3,92**	**,807**	**4,0**	**3,0**	**5,0**
	Seoska	M	60	3	5	3,72	,825	3,0	3,0	4,0
		Ž	75	3	5	4,04	,861	4,0	3,0	5,0
		Ukupno	**135**	**3**	**5**	**3,90**	**,858**	**4,0**	**3,0**	**5,0**
	Ukupno	M	110	3	5	3,76	,801	4,0	3,0	4,0
		Ž	140	3	5	4,02	,844	4,0	3,0	5,0
		Ukupno	**250**	**3**	**5**	**3,91**	**,833**	**4,0**	**3,0**	**5,0**
7	Gradska	M	69	3	5	4,01	,776	4,0	3,0	5,0
		Ž	63	3	5	3,86	,800	4,0	3,0	5,0
		Ukupno	**132**	**3**	**5**	**3,94**	**,789**	**4,0**	**3,0**	**5,0**
	Seoska	M	61	3	5	4,07	,892	4,0	3,0	5,0
		Ž	57	3	5	4,11	,772	4,0	4,0	5,0
		Ukupno	**118**	**3**	**5**	**4,08**	**,833**	**4,0**	**3,0**	**5,0**
	Ukupno	M	130	3	5	4,04	,830	4,0	3,0	5,0
		Ž	120	3	5	3,98	,793	4,0	3,0	5,0
		Ukupno	**250**	**3**	**5**	**4,01**	**,812**	**4,0**	**3,0**	**5,0**
8	Gradska	M	55	3	5	4,04	,838	4,0	3,0	5,0
		Ž	75	3	5	4,04	,761	4,0	3,0	5,0
		Ukupno	**130**	**3**	**5**	**4,04**	**,791**	**4,0**	**3,0**	**5,0**
	Seoska	M	65	3	5	3,92	,889	4,0	3,0	5,0
		Ž	55	3	5	4,00	,861	4,0	3,0	5,0

		Ukupno	**120**	**3**	**5**	**3,96**	**,873**	**4,0**	**3,0**	**5,0**
	Ukupno	M	120	3	5	3,98	,864	4,0	3,0	5,0
		Ž	130	3	5	4,02	,802	4,0	3,0	5,0
		Ukupno	**250**	**3**	**5**	**4,00**	**,831**	**4,0**	**3,0**	**5,0**
Ukupno	Gradska	M	238	3	5	4,09	,757	4,0	4,0	5,0
		Ž	263	3	5	4,10	,773	4,0	3,0	5,0
		Ukupno	**501**	**3**	**5**	**4,09**	**,765**	**4,0**	**4,0**	**5,0**
	Seoska	M	246	3	5	4,09	,864	4,0	3,0	5,0
		Ž	253	3	5	4,19	,796	4,0	4,0	5,0
		Ukupno	**499**	**3**	**5**	**4,14**	**,831**	**4,0**	**3,0**	**5,0**
	Ukupno	M	484	3	5	4,09	,812	4,0	3,0	5,0
		Ž	516	3	5	4,14	,785	4,0	4,0	5,0
		Ukupno	**1000**	**3**	**5**	**4,12**	**,798**	**4,0**	**3,0**	**5,0**

Tablica 14. Deskriptivna statistika za predmet Biologija

Razred	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
7	Gradska	M	69	2	5	3,64	1,163	3,0	3,0	5,0
		Ž	63	2	5	3,57	1,118	3,0	3,0	5,0
		Ukupno	**132**	**2**	**5**	**3,61**	**1,138**	**3,0**	**3,0**	**5,0**
	Seoska	M	61	2	5	3,62	1,113	4,0	3,0	5,0
		Ž	57	2	5	3,56	1,180	4,0	2,0	5,0
		Ukupno	**118**	**2**	**5**	**3,59**	**1,142**	**4,0**	**3,0**	**5,0**
	Ukupno	M	130	2	5	3,63	1,135	4,0	3,0	5,0
		Ž	120	2	5	3,57	1,143	4,0	3,0	5,0
		Ukupno	**250**	**2**	**5**	**3,60**	**1,137**	**4,0**	**3,0**	**5,0**
8	Gradska	M	55	2	5	3,65	1,142	4,0	3,0	5,0
		Ž	75	2	5	3,37	1,075	3,0	2,0	4,0
		Ukupno	**130**	**2**	**5**	**3,49**	**1,108**	**3,0**	**3,0**	**4,0**
	Seoska	M	65	2	5	3,60	1,101	4,0	3,0	5,0
		Ž	55	2	5	3,60	1,099	4,0	3,0	5,0
		Ukupno	**120**	**2**	**5**	**3,60**	**1,095**	**4,0**	**3,0**	**5,0**
	Ukupno	M	120	2	5	3,63	1,116	4,0	3,0	5,0
		Ž	130	2	5	3,47	1,087	3,0	3,0	4,0
		Ukupno	**250**	**2**	**5**	**3,54**	**1,101**	**4,0**	**3,0**	**5,0**
Ukupno	Gradska	M	238	2	5	3,65	1,149	4,0	3,0	5,0
		Ž	263	2	5	3,46	1,095	3,0	3,0	4,0

		Ukupno	**501**	**2**	**5**	**3,55**	**1,122**	**3,0**	**3,0**	**5,0**
	Seoska	M	246	2	5	3,61	1,103	4,0	3,0	5,0
		Ž	253	2	5	3,58	1,136	4,0	3,0	5,0
		Ukupno	**499**	**2**	**5**	**3,60**	**1,116**	**4,0**	**3,0**	**5,0**
	Ukupno	M	484	2	5	3,63	1,124	4,0	3,0	5,0
		Ž	516	2	5	3,52	1,113	4,0	3,0	5,0
		Ukupno	**1000**	**2**	**5**	**3,57**	**1,119**	**4,0**	**3,0**	**5,0**

Iz prethodne se tablice vidi lagani trend većih prosječnih ocjena kod muških učenika na oba područja, ruralnom i urbanom.

Tablica 15. Deskriptivna statistika za predmet Kemija

Razred	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
7	Gradska	M	69	2	5	3,71	1,139	4,0	3,0	5,0
		Ž	63	2	5	3,76	1,058	4,0	3,0	5,0
		Ukupno	**132**	**2**	**5**	**3,73**	**1,097**	**4,0**	**3,0**	**5,0**
	Seoska	M	61	2	5	3,67	1,136	4,0	3,0	5,0
		Ž	57	2	5	3,46	1,119	4,0	2,0	4,0
		Ukupno	**118**	**2**	**5**	**3,57**	**1,128**	**4,0**	**3,0**	**5,0**
	Ukupno	M	130	2	5	3,69	1,133	4,0	3,0	5,0
		Ž	120	2	5	3,62	1,094	4,0	3,0	5,0
		Ukupno	**250**	**2**	**5**	**3,66**	**1,113**	**4,0**	**3,0**	**5,0**
8	Gradska	M	55	2	5	3,53	1,200	3,0	2,0	5,0
		Ž	75	2	5	3,41	1,079	3,0	2,0	4,0
		Ukupno	**130**	**2**	**5**	**3,46**	**1,129**	**3,0**	**2,0**	**4,0**
	Seoska	M	65	2	5	3,43	1,118	3,0	2,0	4,0
		Ž	55	2	5	3,53	1,034	3,0	3,0	4,0
		Ukupno	**120**	**2**	**5**	**3,48**	**1,077**	**3,0**	**3,0**	**4,0**
	Ukupno	M	120	2	5	3,48	1,152	3,0	2,0	5,0
		Ž	130	2	5	3,46	1,058	3,0	3,0	4,0
		Ukupno	**250**	**2**	**5**	**3,47**	**1,102**	**3,0**	**3,0**	**4,0**
Ukupno	Gradska	M	238	2	5	3,63	1,165	4,0	3,0	5,0
		Ž	263	2	5	3,57	1,080	4,0	3,0	4,0
		Ukupno	**501**	**2**	**5**	**3,60**	**1,119**	**4,0**	**3,0**	**5,0**
	Seoska	M	246	2	5	3,55	1,129	3,5	3,0	5,0
		Ž	253	2	5	3,49	1,074	4,0	3,0	4,0

		Ukupno	**499**	**2**	**5**	**3,52**	**1,101**	**4,0**	**3,0**	**4,0**
	Ukupno	M	484	2	5	3,59	1,145	4,0	3,0	5,0
		Ž	516	2	5	3,54	1,076	4,0	3,0	4,0
		Ukupno	**1000**	**2**	**5**	**3,56**	**1,110**	**4,0**	**3,0**	**5,0**

Tablica 16. Deskriptivna statistika za predmet Fizika

Razred	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
7	Gradska	M	69	2	5	3,30	1,102	3,0	2,0	4,0
		Ž	63	2	5	3,79	1,019	4,0	3,0	5,0
		Ukupno	**132**	**2**	**5**	**3,54**	**1,087**	**4,0**	**3,0**	**4,0**
	Seoska	M	61	2	5	3,33	1,136	3,0	2,0	4,0
		Ž	57	2	5	3,67	1,230	4,0	2,0	5,0
		Ukupno	**118**	**2**	**5**	**3,49**	**1,189**	**3,0**	**2,0**	**5,0**
	Ukupno	M	130	2	5	3,32	1,114	3,0	2,0	4,0
		Ž	120	2	5	3,73	1,121	4,0	3,0	5,0
		Ukupno	**250**	**2**	**5**	**3,52**	**1,134**	**4,0**	**2,0**	**5,0**
8	Gradska	M	55	2	5	3,38	1,063	3,0	2,0	4,0
		Ž	75	2	5	3,43	1,176	3,0	2,0	5,0
		Ukupno	**130**	**2**	**5**	**3,41**	**1,125**	**3,0**	**2,0**	**4,0**
	Seoska	M	65	2	5	3,46	1,238	3,0	2,0	5,0
		Ž	55	2	5	3,40	1,180	3,0	2,0	5,0
		Ukupno	**120**	**2**	**5**	**3,43**	**1,207**	**3,0**	**2,0**	**5,0**
	Ukupno	M	120	2	5	3,43	1,157	3,0	2,0	5,0
		Ž	130	2	5	3,42	1,173	3,0	2,0	5,0
		Ukupno	**250**	**2**	**5**	**3,42**	**1,163**	**3,0**	**2,0**	**5,0**
Ukupno	Gradska	M	238	2	5	3,34	1,081	3,0	2,0	4,0
		Ž	263	2	5	3,59	1,118	4,0	3,0	5,0
		Ukupno	**501**	**2**	**5**	**3,47**	**1,106**	**3,5**	**2,0**	**4,0**
	Seoska	M	246	2	5	3,40	1,187	3,0	2,0	5,0
		Ž	253	2	5	3,54	1,208	4,0	2,0	5,0
		Ukupno	**499**	**2**	**5**	**3,46**	**1,196**	**3,0**	**2,0**	**5,0**
	Ukupno	M	484	2	5	3,37	1,134	3,0	2,0	4,0
		Ž	516	2	5	3,57	1,157	4,0	3,0	5,0
		Ukupno	**1000**	**2**	**5**	**3,47**	**1,149**	**3,0**	**2,0**	**5,0**

U prethodnim tablicama s detaljnom deskriptivnom statistikom za predmete Kemija i Fizika ne postoje značajnije razlike niti po jednom obilježju.

Nadalje smo željeli provjeriti normalitete distribucija ocjena iz pojedinih predmeta kako bismo odredili daljnju obradu podataka. U tablici 29 nalaze se rezultati Kolmogorov Smirnov testa za testiranje normaliteta distribucija.

Tablica 4. Rezultati Kolmogorov Smirnov testa pri testiranju normaliteta distribucija ocjena

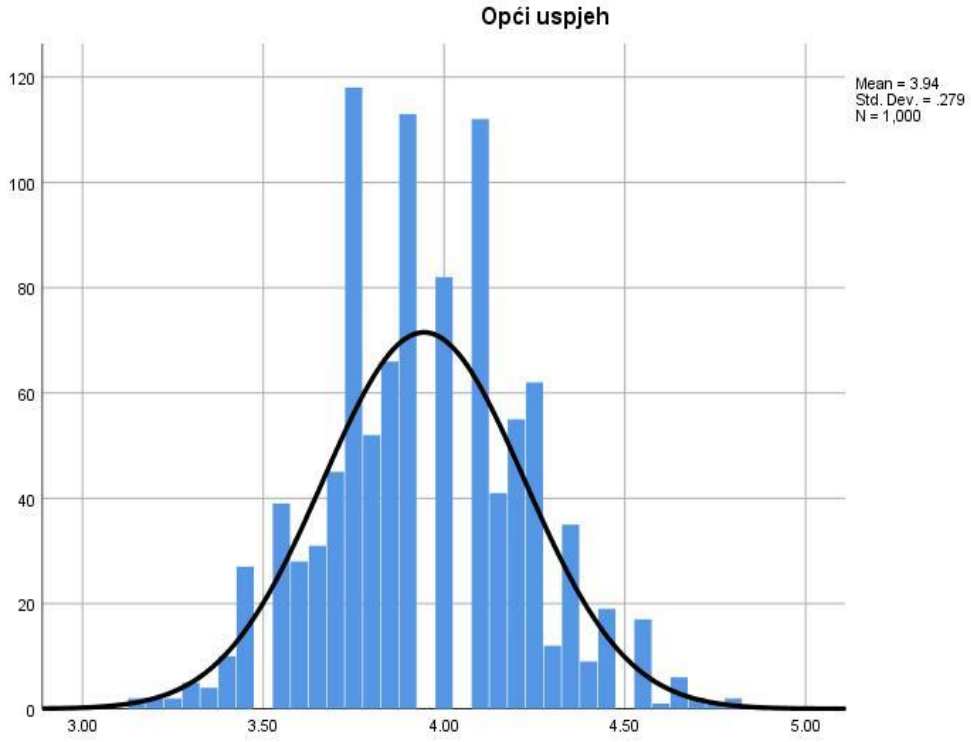
PREDMET	N	Z
Opći uspjeh	1000	2.48**
Hrvatski jezik	1000	6.25**
Likovna kultura	1000	10.86**
Glazbena kultura	1000	10.92**
Engleski jezik	1000	5.53**
Priroda	500	4.15**
Biologija	500	4.06**
Kemija	500	4.01**
Fizika	500	4.03**
Povijest	1000	5.83**
Geografija	1000	5.59**
Tehnička kultura	1000	10.86**
Tjelesna i zdravstvena kultura	1000	10.99**
Matematika	1000	6.12**
Informatika	1000	7.91**

LEGENDA:

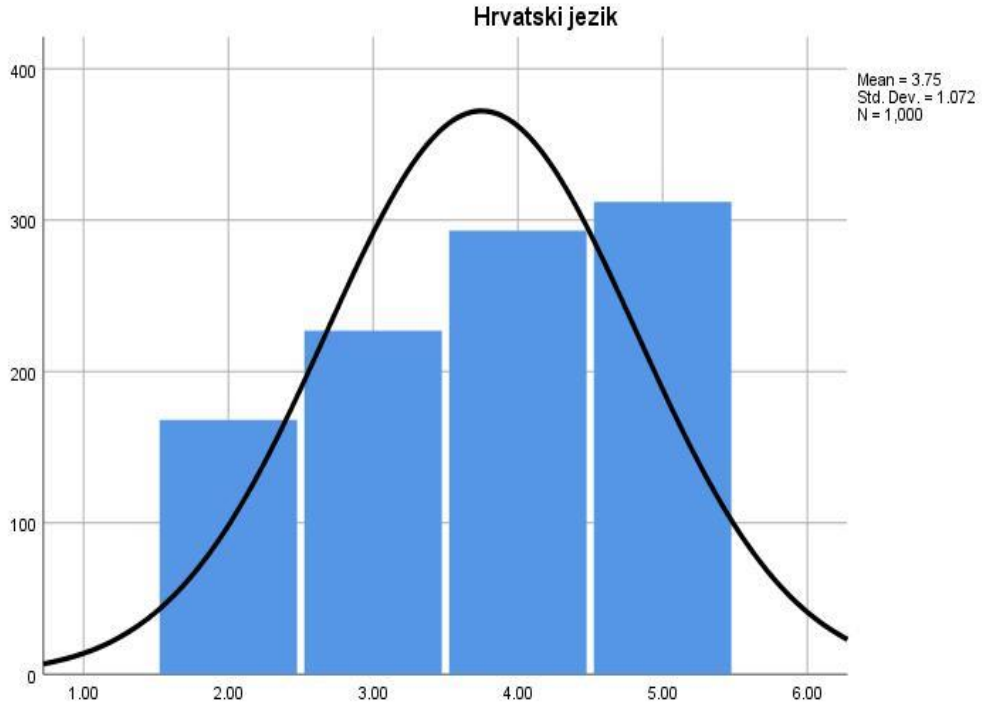
Z – vrijednost Kolmogorov Smirnov testa pri testiranju normaliteta distribucija

** – značajno uz 1% rizika

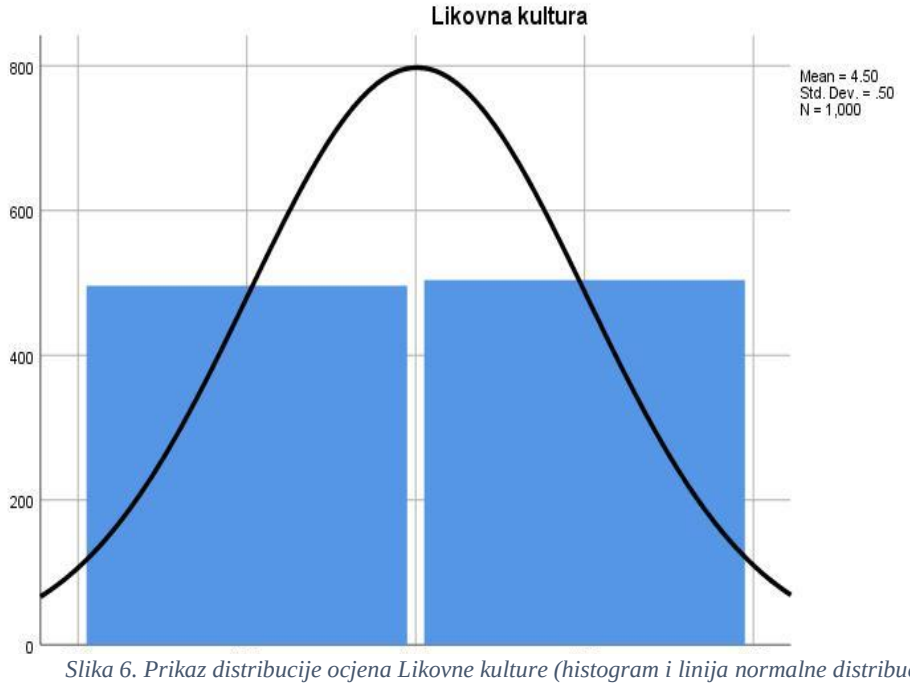
Kao što se iz tablice vidi, distribucija školskih ocjena niti iz jednog predmeta ne slijedi normalnu raspodjelu. Distribucije su prikazane i grafički putem histograma.



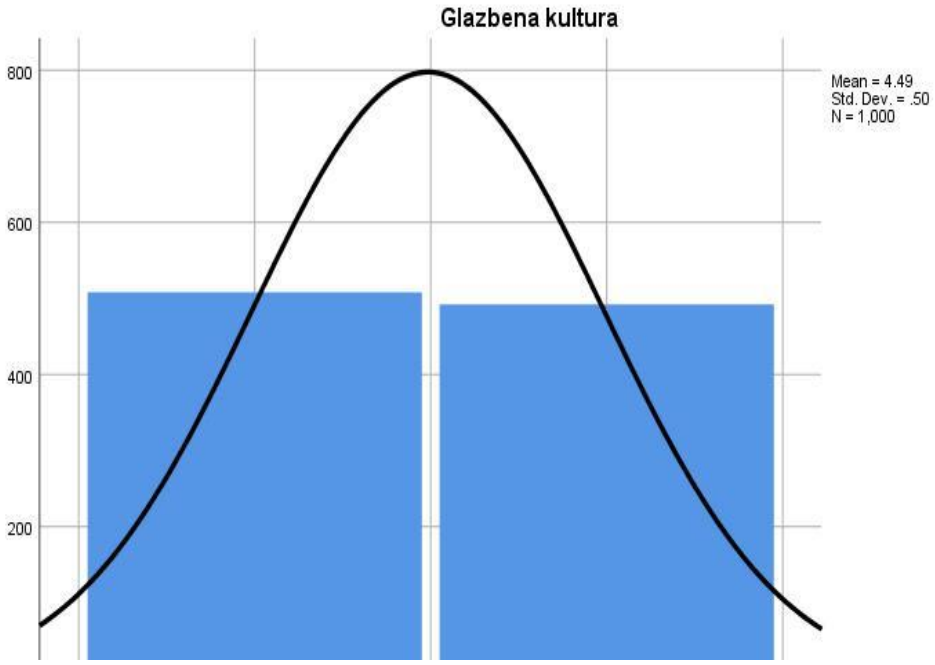
Slika 4. Prikaz distribucije ocjena općeg uspjeha (histogram i linija normalne distribucije)



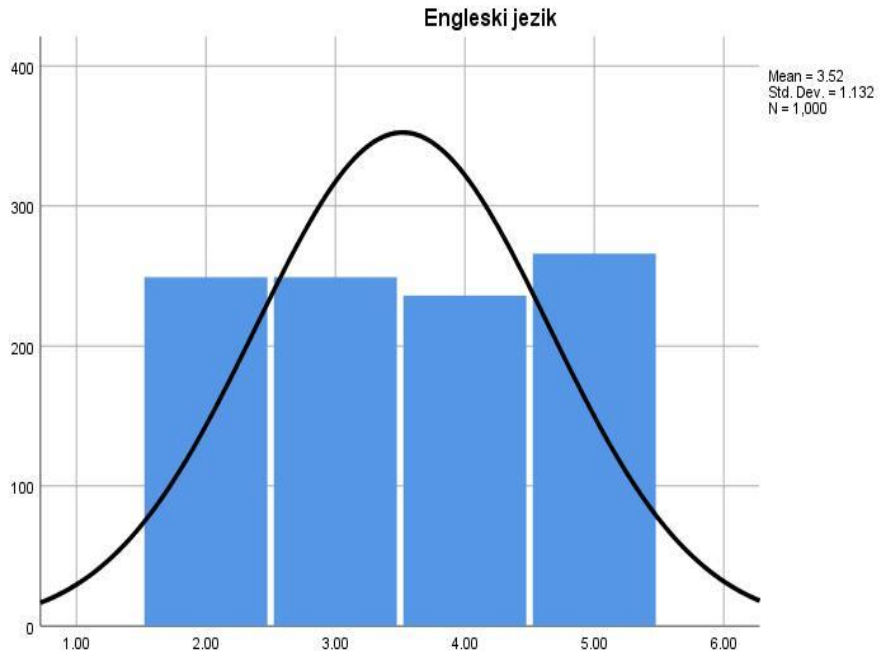
Slika 5. Prikaz distribucije ocjena Hrvatskog jezika (histogram i linija normalne distribucije)



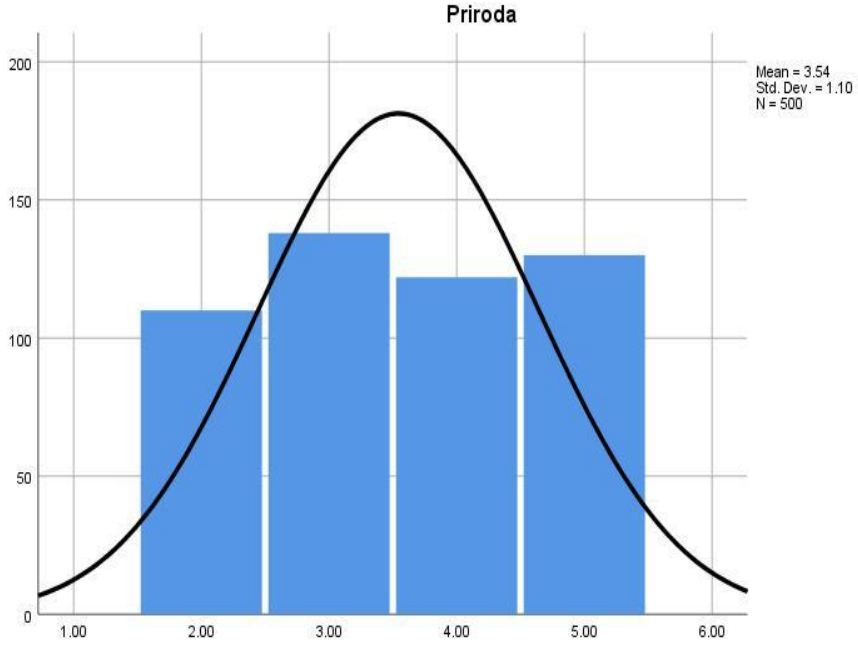
Slika 6. Prikaz distribucije ocjena Likovne kulture (histogram i linija normalne distribucije)



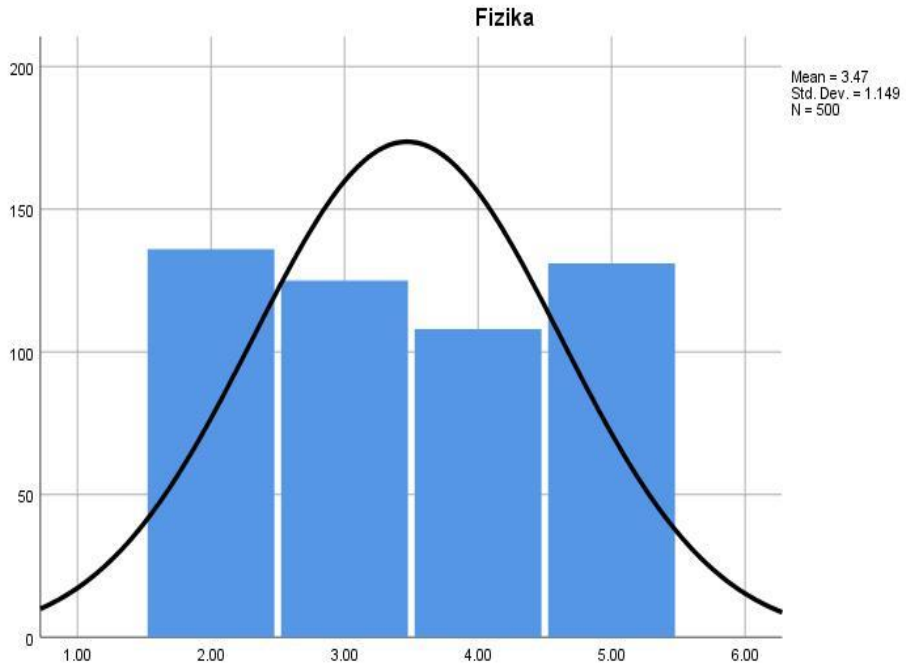
Slika 7. Prikaz distribucije ocjena Glazbene kulture (histogram i linija normalne distribucije)



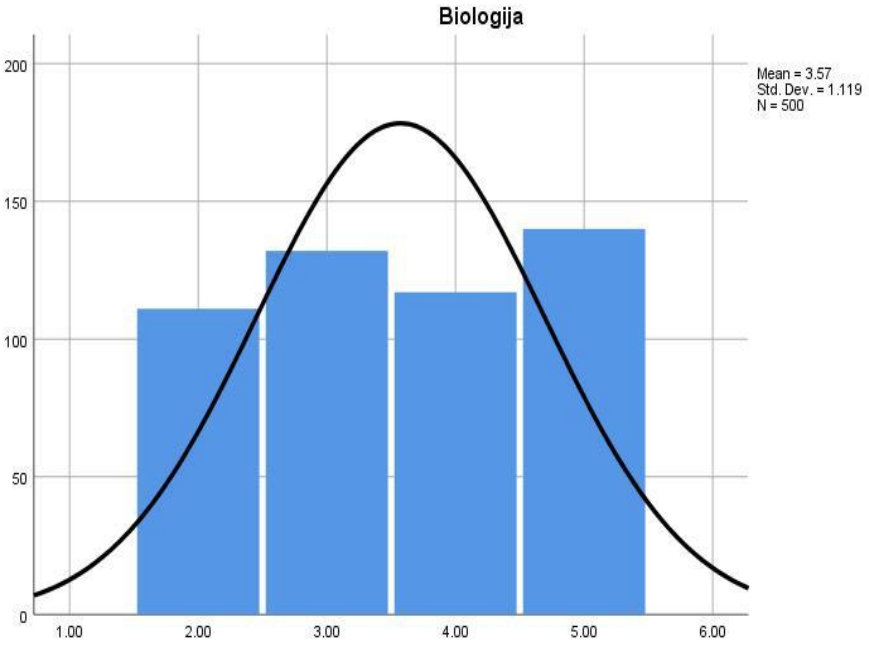
Slika 8. Prikaz distribucije ocjena Engleskog jezika (histogram i linija normalne distribucije)



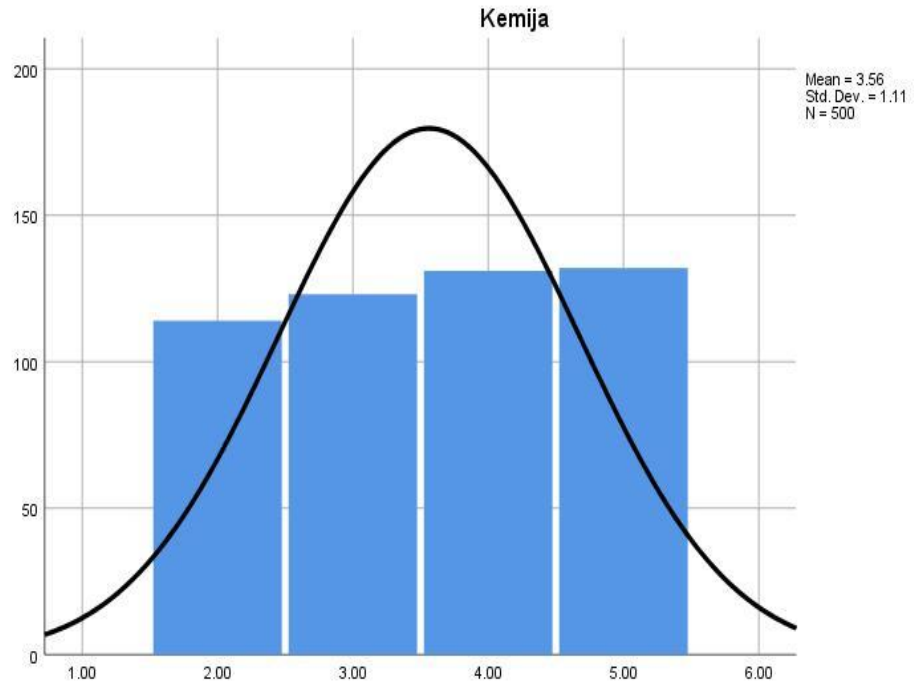
Slika 9. Prikaz distribucije ocjena Prirode (histogram i linija normalne distribucije)



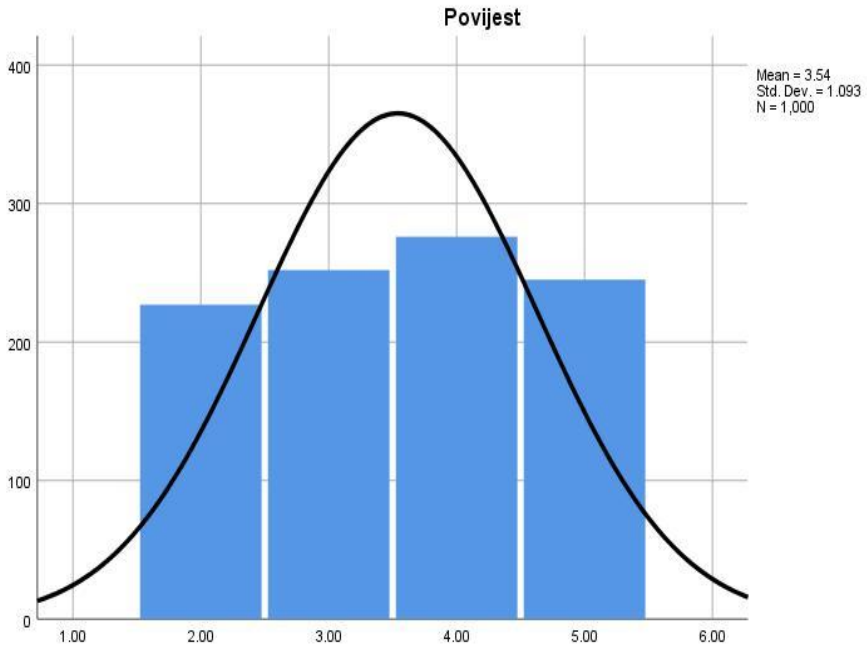
Slika 10. Prikaz distribucije ocjena Fizike (histogram i linija normalne distribucije)



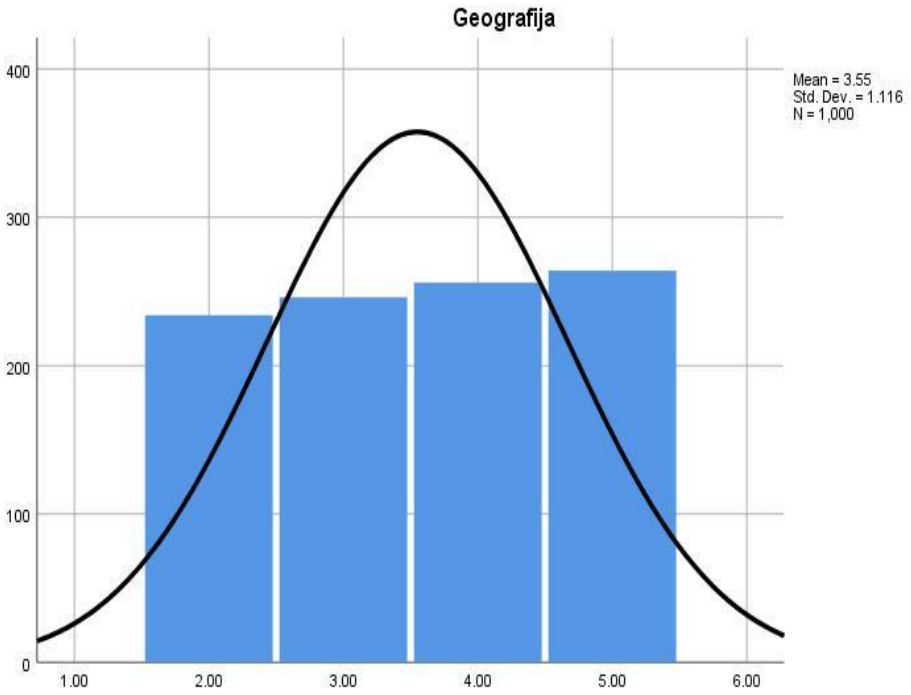
Slika 11. Prikaz distribucije ocjena Biologije (histogram i linija normalne distribucije)



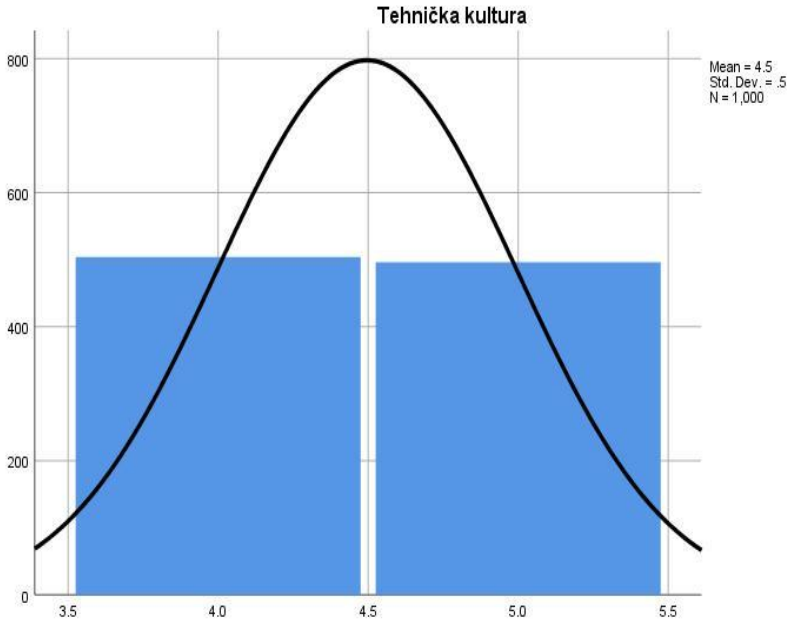
Slika 12. Prikaz distribucije ocjena Kemije (histogram i linija normalne distribucije)



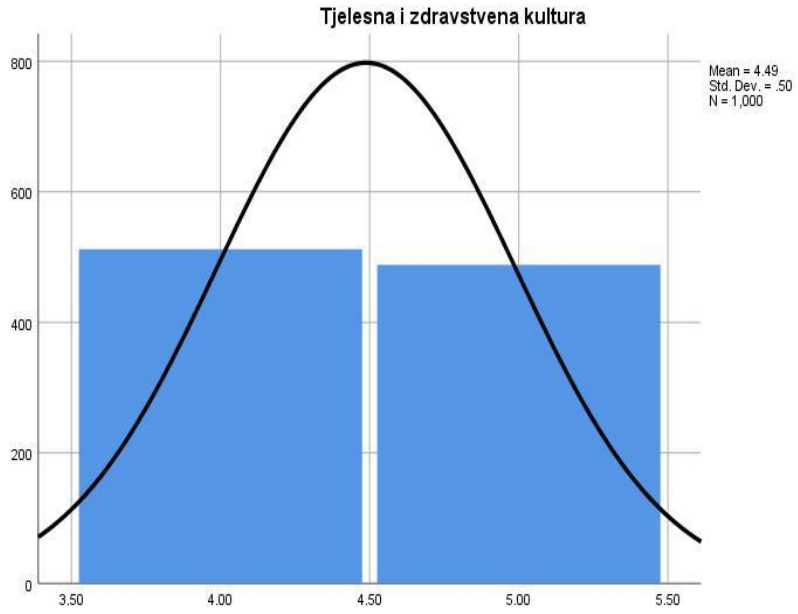
Slika 13. Prikaz distribucije ocjena Povijesti (histogram i linija normalne distribucije)



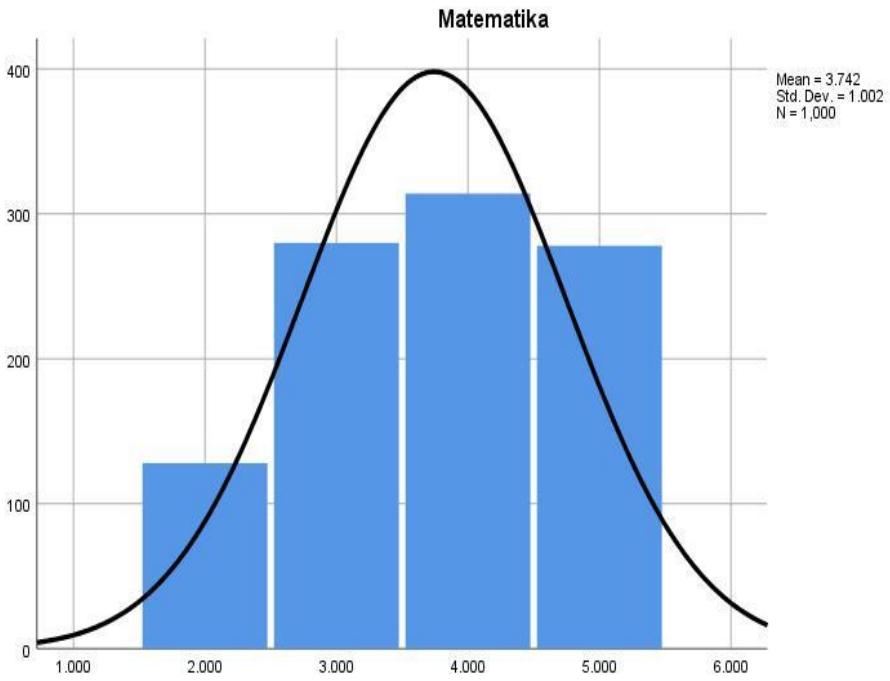
Slika 14. Prikaz distribucije ocjena Geografije (histogram i linija normalne distribucije)



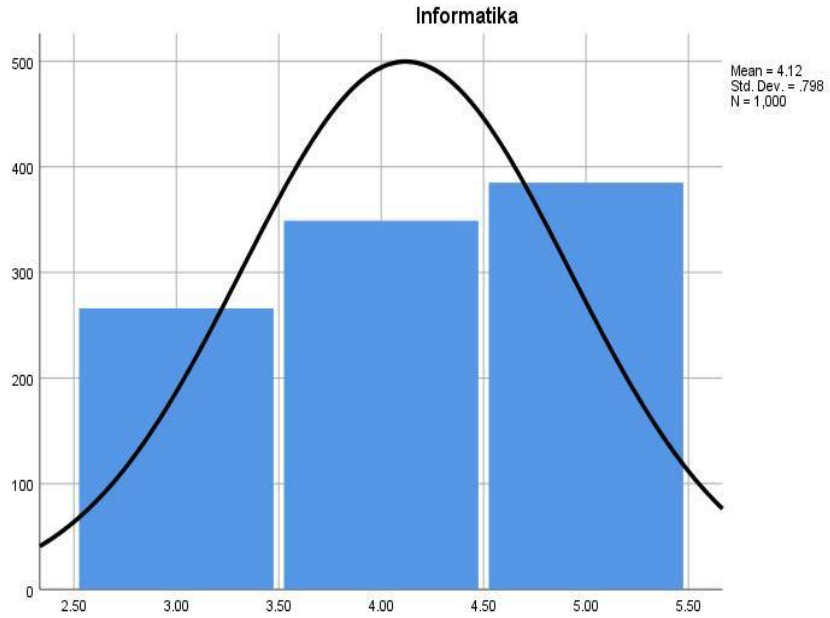
Slika 15. Prikaz distribucije ocjena iz Tehničke kulture



Slika 17. Prikaz distribucije ocjena Tjelesne i zdravstvene kulture (histogram i linija normalne distribucije)



Slika 18. Prikaz distribucije ocjena Matematika (histogram i linija normalne distribucije)



Slika 20. Prikaz distribucije ocjena Informatike (histogram i linija normalne distribucije)

Iako distribucije ocjena iz pojedinih predmeta ne slijede normalnu raspodjelu, već su neke pozitivno asimetrične, a neke kvadratične, Petz (2004) navodi kako je moguće koristiti parametrijsku statistiku kada su distribucije donekle pravilne odnosno ako nisu bimodalne ili u-distribucije. U tim slučajevima, kada distribucije rezultata nisu normalne, moramo imati dovoljno veliki uzorak te uzorke jednake ili slične veličine (Petz, 2004). Kako se ovo istraživanje provodi na dosta velikom uzorku od 500 -1 000 sudionika (ovisno o predmetu) i sve su distribucije pomaknute u istom smjeru, koristit ćemo parametrijske analize u onim obradama podataka kada nam one donose veću korist od neparametrijskih postupaka.

U ovom nas je dijelu zanimalo i postoje li statistički značajne razlike u prosječnim ocjenama iz pojedinih predmeta. U tu svrhu provedena je jednostavna zavisna analiza varijance (repeated measures). Kako u 5. i 6. razredu učenici imaju Prirodu, koje nema u 7. i 8., kada se pojavljuju Biologija, Kemija i Fizika, analize su posebno napravljene za 5. i 6. razred te za 7. i 8. razred. U sljedećoj se tablici nalaze analize značajnosti razlika u prosječnim ocjenama po pojedinim predmetima u 5. i 6. razredu.

Tablica 5. Rezultati testiranja razlika u prosječnim ocjenama u 5. i 6. razredu

	Predmet	HRV	LK	GLA	ENG	PRI	POV	GEO	TEH	TZK	MAT	INF
Predmet	M	3.84	4.50	4.50	3.57	3.54	3.52	3.52	4.49	4.49	3.82	4.23
HRV	3.84		**	**	**	**	**	**	**	**		**
LK	4.50				**	**	**	**			**	**
GLA	4.50				**	**	**	**			**	**
ENG	3.57								**	**	**	**
PRI	3.54								**	**	**	**
POV	3.52								**	**	**	**
GEO	3.52								**	**	**	**
TEH	4.49										**	**
TZK	4.49										**	**
MAT	3.82											**
INF	4.23											

LEGENDA:

M – aritmetička sredina

** - statistički značajna razlika uz 1% rizika

Značajno viša M u odnosu na predmet u stupcu

Značajno niža M u odnosu na predmet u stupcu

Nema razlike

Rezultati u gornjoj tablici donose informaciju da su najviše i statistički značajno više prosječne ocjene od ostalih predmeta te međusobno podjednake ocjene iz odgojnih predmeta: Likovne, Glazbene, Tehničke i Tjelesno zdravstvene kulture. Znači, prosječne ocjene svih ostalih predmeta su statistički značajno niže. Na sljedećem mjestu, odmah iza odgojnih predmeta je ocjena iz Informatike koja je statistički značajno viša od svih predmeta osim odgojnih. Slijede prosječne ocjene iz Matematike i Hrvatskog jezika koje su podjednake i statistički značajno više od prosječnih ocjena Engleskog jezika, Prirode, Povijesti i Geografije. Zadnje mjesto dijele prosječne ocjene iz Engleskog jezika, Prirode, Povijesti i Geografije koje su najniže od svih ostalih i međusobno statistički podjednake.

Rezultati ovakve analize za 7. i 8. razred nalaze se u sljedećoj tablici.

Tablica 6. Rezultati testiranja razlika u prosječnim ocjenama u 7. i 8. razredu

	Pred	HRV	LIK	GLA	ENG	BIO	KEM	FIZ	POV	GEO	TEH	TJE	MAT	INF
Pred	M	3.66	4.51	4.49	3.47	3.57	3.56	3.47	3.56	3.58	4.51	4.49	3.66	4.00
HRV	3.66		**	**	**			**			**	**		**
LIK	4.51				**	**	**	**	**	**			**	**
GLA	4.49				**	**	**	**	**	**			**	**
ENG	3.47										**	**	**	**
BIO	3.57										**	**		**
KEM	3.56										**	**		**
FIZ	3.47										**	**	**	**
POV	3.56										**	**		**
GEO	3.58										**	**		**
TEH	4.51												**	**
TJE	4.49												**	**
MAT	3.66													**
INF	4.00													

LEGENDA:

M – aritmetička sredina

** - statistički značajna razlika uz 1% rizika

Značajno viša M u odnosu na predmet u stupcu

Značajno niža M u odnosu na predmet u stupcu

Nema razlike

Rezultati u gornjoj tablici ponovo donose informaciju da su najviše i statistički značajno više prosječne ocjena od ostalih predmeta te međusobno podjednake ocjene iz odgojnih predmeta: Likovne, Glazbene, Tehničke i Tjelesno zdravstvene kulture. Znači, prosječne ocjene svih ostalih predmeta su statistički značajno niže. Na slijedećem mjestu, odmah iza odgojnih predmeta je ocjena iz Informatike koja je statistički značajno viša od svih predmeta osim odgojnih. Slijede prosječne ocjene iz Matematike, Biologije, Kemije, Povijesti, Geografije i Hrvatskog jezika koje su podjednake. Prosječne ocjene iz Hrvatskog i Matematike su i statistički značajno više od prosječnih ocjena iz Engleskog jezika i Fizike, dok ocjene iz ostalih nabrojanih predmeta (Biologija, Kemija, Povijest i Geografija) nisu. Zadnje mjesto dijele prosječne ocjene iz Engleskog jezika i Fizike koje su najniže od svih ostalih i međusobno statistički podjednake.

5.1.2 Područja unutar Matematike i Informatike

Odabrane teme iz Matematike i Informatike nalaze se u sljedećoj tablici.

Tablica 7. Srednje vrijednosti i pripadajuća raspršenja ocjena svih područja iz Matematike i Informatike prikupljenih u istraživanju

RAZRED	PODRUČJE	N	M	σ	C	D	min	maks
peti	Prirodni brojevi	250	3.54	1.137	4.00	5.00	2	5
peti	Djeljivost prirodnih brojeva	250	3.44	1.151	3.00	2.00	2	5
peti	Skupovi točaka u ravnini	250	3.58	1.114	4.00	4.00	2	5
peti	Razlomci	250	3.51	1.109	4.00	4.00	2	5
peti	Decimalni brojevi	250	3.40	1.134	3.00	2.00	2	5
peti	Prvi koraci u radu s računalom	250	3.49	1.152	3.00	5.00	2	5
peti	Spremnici računala i progr. oprema	250	3.53	1.148	4.00	5.00	2	5
peti	Crtanje pomoću računala	250	3.68	1.124	4.00	5.00	2	5
peti	Programiranje (LOGO)	250	3.43	1.096	3.00	3.00	2	5
peti	Naučimo pisati	250	3.37	1.102	3.00	2.00	2	5

peti	Internet	250	3.61	1.119	4.00	5.00	2	5
šesti	Operacije s razlomcima	250	3.53	1.116	4.00	4.00	2	5
šesti	Trokut	250	3.50	1.109	4.00	4.00	2	5
šesti	Cijeli brojevi	250	3.52	1.120	4.00	4.00	2	5
šesti	Racionalni brojevi	250	3.43	1.089	3.00	3.00	2	5
šesti	Linearne jednadžbe s 1 nepoznanicom	250	3.55	1.119	4.00	4.00	2	5
šesti	Četverokut	250	3.46	1.130	3.00	3.00	2	5
šesti	Osnove informatike	250	3.50	1.084	4.00	4.00	2	5
šesti	Programiranje (LOGO)	250	3.50	1.135	3.00	5.00	2	5
šesti	Obrada teksta	250	3.54	1.119	4.00	5.00	2	5
šesti	Računala u mreži	250	3.45	1.154	3.00	2.00	2	5
šesti	Multimedija	250	3.49	1.088	3.00	3.00	2	5
šesti	Izrada prezentacija	250	3.49	1.095	3.50	4.00	2	5
sedmi	Koordinatni sustav	250	3.49	1.117	3.00	3.00	2	5
sedmi	Proporcionalnost i obrnuta prop.	250	3.56	1.100	4.00	3.00	2	5
sedmi	Sličnost i mnogokuti	250	3.51	1.120	3.00	3.00	2	5
sedmi	Krug i kružnica	250	3.52	1.134	4.00	4.00	2	5
sedmi	Sustavi linearnih jednadžbi	250	3.47	1.065	4.00	4.00	2	5
sedmi	Linearna funkcija i jednadžba pravca	250	3.52	1.080	3.00	3.00	2	5
sedmi	Programiranje (LOGO)	250	3.42	1.100	3.00	4.00	2	5
sedmi	Proračunske tablice	250	3.50	1.058	3.00	3.00	2	5
sedmi	Prezentacije	250	3.51	1.109	4.00	4.00	2	5
sedmi	Izrada mrežnih stranica	250	3.48	1.065	4.00	4.00	2	5
sedmi	Internet	250	3.56	1.147	4.00	5.00	2	5
sedmi	Izrada prezentacija	250	3.74	1.084	4.00	5.00	2	5
osmi	Kvadriranje i korjenovanje	250	3.52	1.095	4.00	4.00	2	5
osmi	Pitagorin poučak	250	3.40	1.098	3.00	3.00	2	5
osmi	Realni brojevi	250	3.47	1.172	3.00	5.00	2	5
osmi	Preslikavanje ravnine	250	3.50	1.124	4.00	2.00	2	5
osmi	Točke, pravci i ravnine u prostoru	250	3.50	1.080	4.00	4.00	2	5
osmi	Geometrijska tijela	250	3.59	1.113	4.00	5.00	2	5
osmi	Osnove informatike	250	3.61	1.143	4.00	5.00	2	5
osmi	Programiranje (LOGO)	250	3.58	1.032	4.00	4.00	2	5
osmi	Baze podataka	250	3.49	1.046	4.00	4.00	2	5
osmi	Prezentacije	250	3.46	1.102	4.00	4.00	2	5

osmi	Internet	250	3.45	1.112	3.50	4.00	2	5
osmi	Izrada mrežnih stranica	250	3.64	1.130	4.00	5.00	2	5

LEGENDA:

N – broj sudionika

M – aritmetička sredina

σ – standardna devijacija

C – centralna vrijednost

D – dominantna vrijednost

min – najmanja ocjena

maks – najveća ocjena

U sljedećim tablicama prikazat ćemo detaljnu deskriptivnu statistiku odabranih tema iz Matematike i Informatike te analizirati rezultate.

5.1.2.1 Peti razred

Tablica 8. Deskriptivna statistika odabranih tema iz Matematike za peti razred

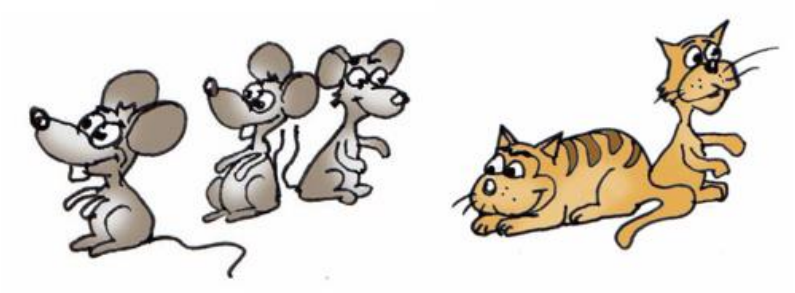
Gradivo	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
Prirodni brojevi	Gradska	M	64	2	5	3,39	1,107	3,0	2,0	4,0
		Ž	60	2	5	3,60	1,153	4,0	2,5	5,0
		Ukupno	124	2	5	3,49	1,130	3,5	2,0	4,5
	Seoska	M	60	2	5	3,37	1,134	3,0	2,0	4,0
		Ž	66	2	5	3,80	1,126	4,0	3,0	5,0
		Ukupno	126	2	5	3,60	1,147	4,0	3,0	5,0
	Ukupno	M	124	2	5	3,38	1,116	3,0	2,0	4,0
		Ž	126	2	5	3,71	1,139	4,0	3,0	5,0
		Ukupno	250	2	5	3,54	1,137	4,0	3,0	5,0
Djeljivost prirodnih brojeva	Gradska	M	64	2	5	3,42	1,152	3,0	2,0	4,5
		Ž	60	2	5	3,30	1,154	3,0	2,0	4,0
		Ukupno	124	2	5	3,36	1,150	3,0	2,0	4,0
	Seoska	M	60	2	5	3,53	1,186	4,0	2,0	5,0
		Ž	66	2	5	3,52	1,126	3,5	3,0	5,0
		Ukupno	126	2	5	3,52	1,150	4,0	2,0	5,0
	Ukupno	M	124	2	5	3,48	1,165	3,0	2,0	5,0

		Ž	126	2	5	3,41	1,140	3,0	2,0	4,0
		Ukupno	250	2	5	3,44	1,151	3,0	2,0	5,0
Skupovi točaka u ravnini	Gradska	M	64	2	5	3,70	1,136	4,0	3,0	5,0
		Ž	60	2	5	3,50	1,081	4,0	3,0	4,0
		Ukupno	124	2	5	3,60	1,110	4,0	3,0	5,0
	Seoska	M	60	2	5	3,67	1,188	4,0	2,5	5,0
		Ž	66	2	5	3,45	1,055	3,0	3,0	4,0
		Ukupno	126	2	5	3,56	1,121	4,0	3,0	5,0
	Ukupno	M	124	2	5	3,69	1,157	4,0	3,0	5,0
		Ž	126	2	5	3,48	1,064	3,5	3,0	4,0
		Ukupno	250	2	5	3,58	1,114	4,0	3,0	5,0
Razlomci	Gradska	M	64	2	5	3,52	1,098	4,0	3,0	4,0
		Ž	60	2	5	3,62	1,121	4,0	3,0	5,0
		Ukupno	124	2	5	3,56	1,106	4,0	3,0	4,5
	Seoska	M	60	2	5	3,33	1,068	3,0	2,5	4,0
		Ž	66	2	5	3,58	1,151	4,0	2,0	5,0
		Ukupno	126	2	5	3,46	1,115	3,0	2,0	4,0
	Ukupno	M	124	2	5	3,43	1,083	3,0	3,0	4,0
		Ž	126	2	5	3,60	1,133	4,0	3,0	5,0
		Ukupno	250	2	5	3,51	1,109	4,0	3,0	4,0
Decimalni brojevi	Gradska	M	64	2	5	3,30	1,191	3,0	2,0	4,5
		Ž	60	2	5	3,42	1,139	3,5	2,0	4,0
		Ukupno	124	2	5	3,35	1,163	3,0	2,0	4,0
	Seoska	M	60	2	5	3,37	1,119	3,0	2,0	4,0
		Ž	66	2	5	3,53	1,099	4,0	3,0	4,0
		Ukupno	126	2	5	3,45	1,107	3,0	3,0	4,0
	Ukupno	M	124	2	5	3,33	1,153	3,0	2,0	4,0
		Ž	126	2	5	3,48	1,115	4,0	2,0	4,0
		Ukupno	250	2	5	3,40	1,134	3,0	2,0	4,0

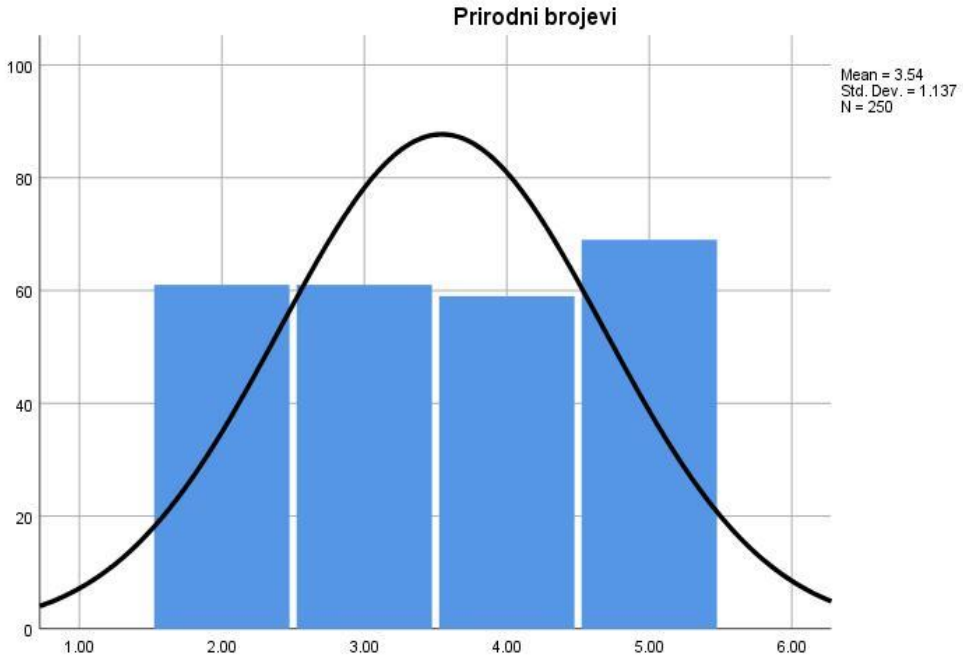
Iz prethodne tablice vidljive su blage razlike između prosječnih ocjena za pojedine teme s obzirom na vrstu škole. Djeca iz ruralnih škola općenito imaju više prosječne ocjene u nastavnim temama iz Matematike koje su egzaktne, kao što su to prirodni brojevi (ruralna 3,60; urbana 3,49), djeljivost prirodnih brojeva (ruralna 3,52; urbana 3,36) i decimalni brojevi (ruralna 3,45; urbana 3,35), dok u temama koje spadaju u kategoriju geometrije kao što je to tema skupovi točaka u ravnini (urbana 3,60; ruralna 3,56) vidi se lagana razlika u korist urbanih škola. Interesantno je primijetiti da je razlika za temu razlomci gotovo neznatna (urbana 3,56; ruralna 3,46).

Prirodni brojevi

U ulici je 5 kuća. U svakoj su kući dvije mačke. Svaka mačka ulovi 3 miša u jednom danu. Koliko su miševa u toj ulici ulovile u mjesecu lipnju?



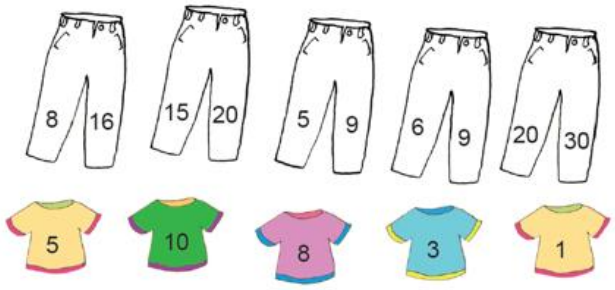
Slika 21. Primjer zadatka za temu prirodni brojevi. Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 5



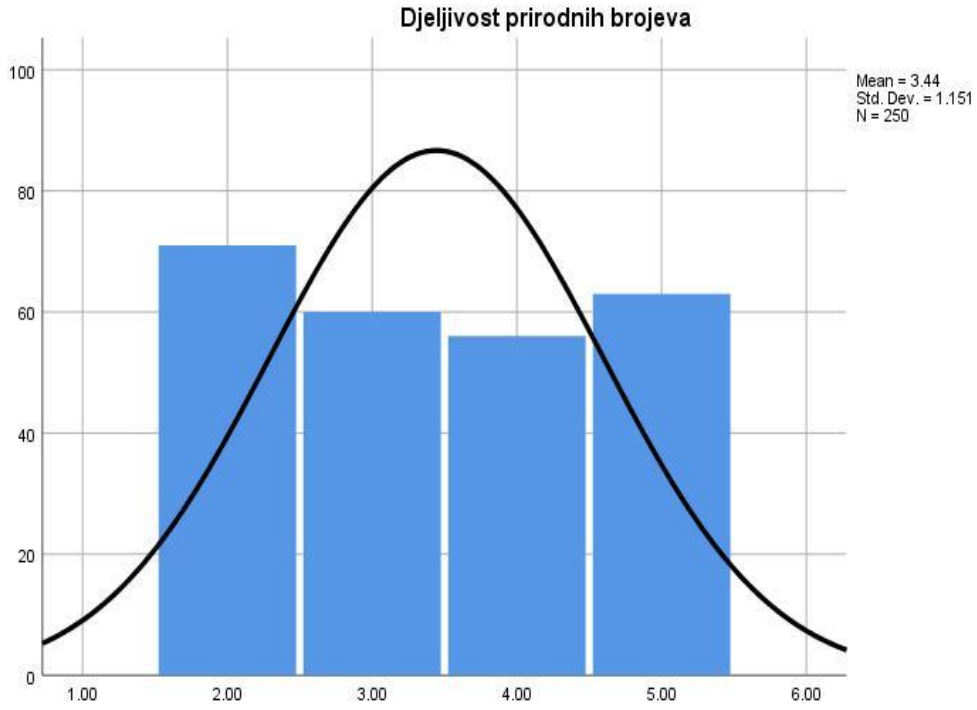
Slika 22. Normalitet distribucija za temu prirodni brojevi (peti razred)

Djeljivost

Spoji hlače s majicom tako da broj na majici bude najveći zajednički djelitelj brojeva s nogavica hlača.



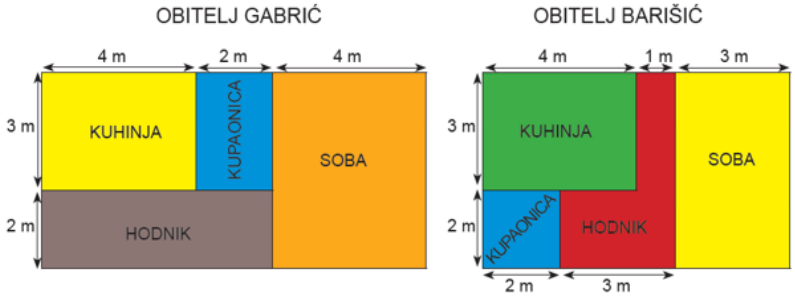
Slika 23. Primjer zadatka za temu djeljivost prirodnih brojeva. Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 5



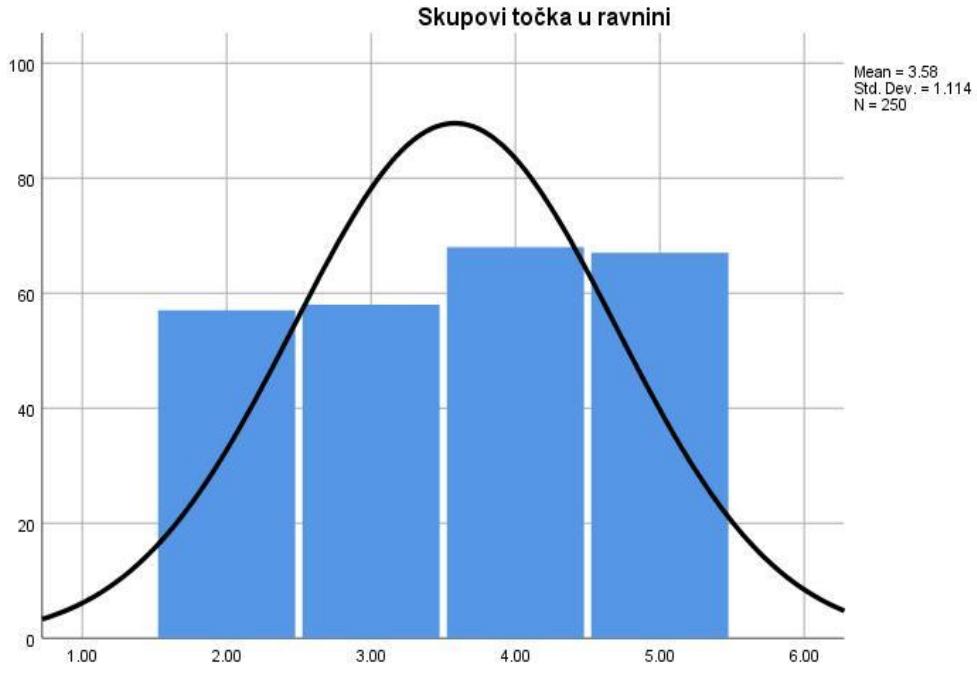
Slika 24. Normalitet distribucija za temu djeljivost prirodnih brojeva (peti razred)

Skupovi točaka u ravnini

Dani su tlocrti dviju obitelji.
a) Tko ima veću kuhinju? Za koliko?
b) Tko ima veći hodnik? Za koliko?
c) Je li neka od prostorija u obliku kvadrata?
d) Koje prostorije imaju oblik pravokutnika?
e) Tko ima veći stan? Za koliko?



Slika 25. Primjer zadatka za temu skupovi točaka u ravnini. Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 5



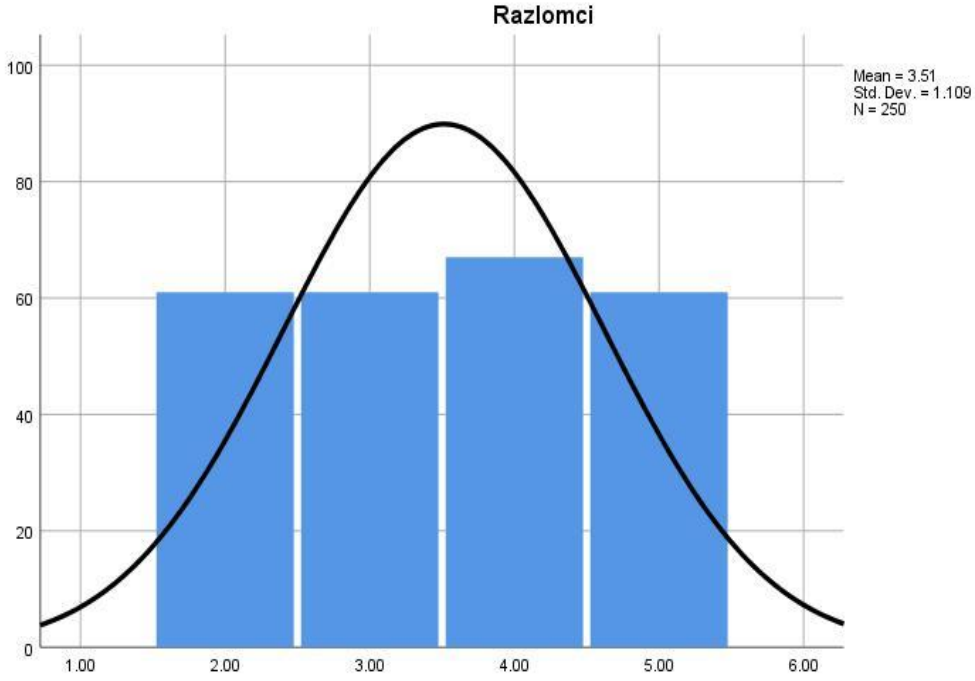
Slika 26. Normalitet distribucija za temu skupovi točaka u ravnini (peti razred)

Razlomci

Maca Crtka ima 10 mačića, od kojih je 6 potpuno bijelih, ostali su crni. Prikaži razlomkom broj crnih mačića.



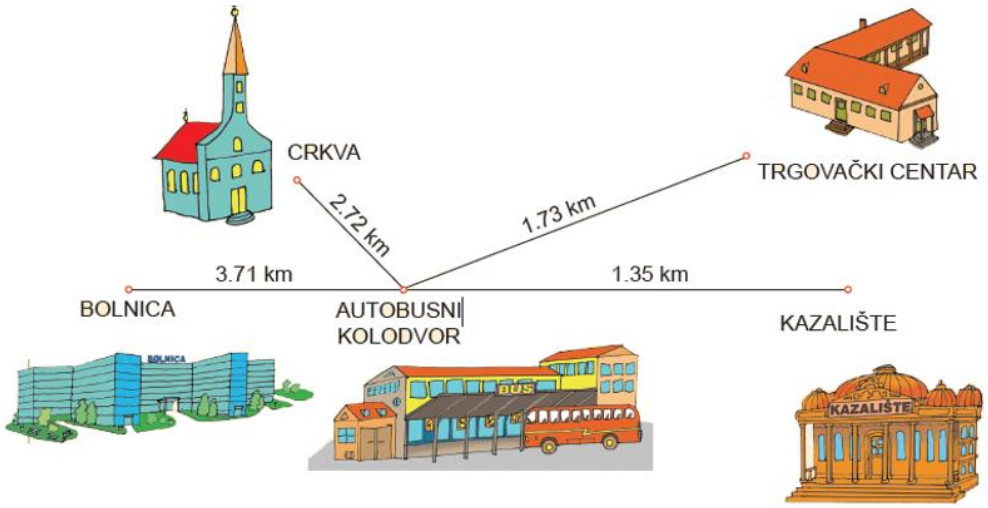
Slika 27. Primjer zadatka za temu razlomci. Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 5



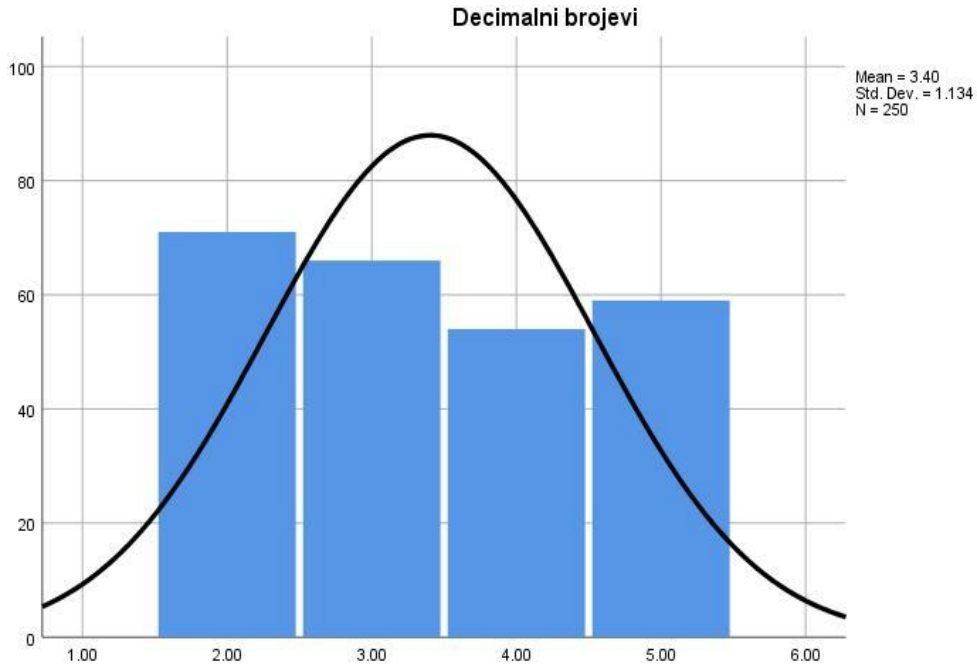
Slika 28. Normalitet distribucija za temu razlomci (peti razred)

Decimalni brojevi

Na slici su udaljenosti između autobusnog kolodvora i drugih objekata prikazane u umanjenom mjerilu. Međutim, duljine su izmiješane. Napravi tablicu s točnim udaljenostima imajući na umu da dulja dužina označava veću udaljenost.



Slika 29. Primjer zadatka za temu decimalni brojevi. Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 5



Slika 30. Normalitet distribucija za temu decimalni brojevi (peti razred)

Promotrimo deskriptivnu statistiku tema za isti razred za predmet Informatika.

Tablica 9. Deskriptivna statistika odabranih tema iz Informatike za peti razred

Gradivo	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
Prvi koraci u radu s računalom	Gradska	M	64	2	5	3,50	1,182	3,5	2,0	5,0
		Ž	60	2	5	3,60	1,196	3,0	3,0	5,0
		Ukupno	124	2	5	3,55	1,185	3,0	2,0	5,0
	Seoska	M	60	2	5	3,52	1,157	4,0	2,0	5,0
		Ž	66	2	5	3,36	1,090	3,0	2,0	4,0
		Ukupno	126	2	5	3,44	1,121	3,0	2,0	4,0
	Ukupno	M	124	2	5	3,51	1,165	4,0	2,0	5,0
		Ž	126	2	5	3,48	1,143	3,0	2,0	5,0
		Ukupno	250	2	5	3,49	1,152	3,0	2,0	5,0
Spremnici računala i programska oprema	Gradska	M	64	2	5	3,45	1,140	3,0	2,0	4,5
		Ž	60	2	5	3,45	1,185	3,0	2,0	5,0
		Ukupno	124	2	5	3,45	1,157	3,0	2,0	5,0
	Seoska	M	60	2	5	3,65	1,176	4,0	2,5	5,0
		Ž	66	2	5	3,56	1,111	3,5	3,0	5,0
		Ukupno	126	2	5	3,60	1,139	4,0	3,0	5,0
	Ukupno	M	124	2	5	3,55	1,157	4,0	2,0	5,0
		Ž	126	2	5	3,51	1,144	3,0	2,0	5,0
		Ukupno	250	2	5	3,53	1,148	4,0	2,0	5,0
Crtanje pomoću računala	Gradska	M	64	2	5	3,66	1,101	4,0	3,0	5,0
		Ž	60	2	5	3,55	1,156	3,0	3,0	5,0
		Ukupno	124	2	5	3,60	1,125	4,0	3,0	5,0
	Seoska	M	60	2	5	3,92	1,062	4,0	3,0	5,0
		Ž	66	2	5	3,61	1,162	4,0	3,0	5,0
		Ukupno	126	2	5	3,75	1,122	4,0	3,0	5,0
	Ukupno	M	124	2	5	3,78	1,086	4,0	3,0	5,0
		Ž	126	2	5	3,58	1,155	4,0	3,0	5,0
		Ukupno	250	2	5	3,68	1,124	4,0	3,0	5,0
Programiranje (LOGO)	Gradska	M	64	2	5	3,41	1,050	3,0	3,0	4,0
		Ž	60	2	5	3,27	1,103	3,0	2,0	4,0
		Ukupno	124	2	5	3,34	1,074	3,0	2,0	4,0
	Seoska	M	60	2	5	3,47	1,142	3,0	2,0	4,5
		Ž	66	2	5	3,56	1,097	4,0	3,0	4,0
		Ukupno	126	2	5	3,52	1,115	4,0	3,0	4,0
	Ukupno	M	124	2	5	3,44	1,091	3,0	2,5	4,0
		Ž	126	2	5	3,42	1,105	3,0	2,0	4,0
		Ukupno	250	2	5	3,43	1,096	3,0	2,0	4,0
Naučimo pisati	Gradska	M	64	2	5	3,39	1,048	3,0	3,0	4,0
		Ž	60	2	5	3,18	1,033	3,0	2,0	4,0
		Ukupno	124	2	5	3,29	1,042	3,0	2,0	4,0
	Seoska	M	60	2	5	3,27	1,148	3,0	2,0	4,0

		Ž	66	2	5	3,62	1,147	4,0	3,0	5,0
		Ukupno	126	2	5	3,45	1,157	3,5	2,0	4,0
	Ukupno	M	124	2	5	3,33	1,095	3,0	2,0	4,0
		Ž	126	2	5	3,41	1,112	3,0	2,0	4,0
		Ukupno	250	2	5	3,37	1,102	3,0	2,0	4,0
Internet	Gradska	M	64	2	5	3,48	1,054	3,0	3,0	4,0
		Ž	60	2	5	3,50	1,172	4,0	2,0	5,0
		Ukupno	124	2	5	3,49	1,108	3,0	3,0	4,0
	Seoska	M	60	2	5	3,73	1,056	4,0	3,0	5,0
		Ž	66	2	5	3,71	1,187	4,0	3,0	5,0
		Ukupno	126	2	5	3,72	1,122	4,0	3,0	5,0
	Ukupno	M	124	2	5	3,60	1,058	4,0	3,0	4,5
		Ž	126	2	5	3,61	1,180	4,0	2,0	5,0
		Ukupno	250	2	5	3,61	1,119	4,0	3,0	5,0

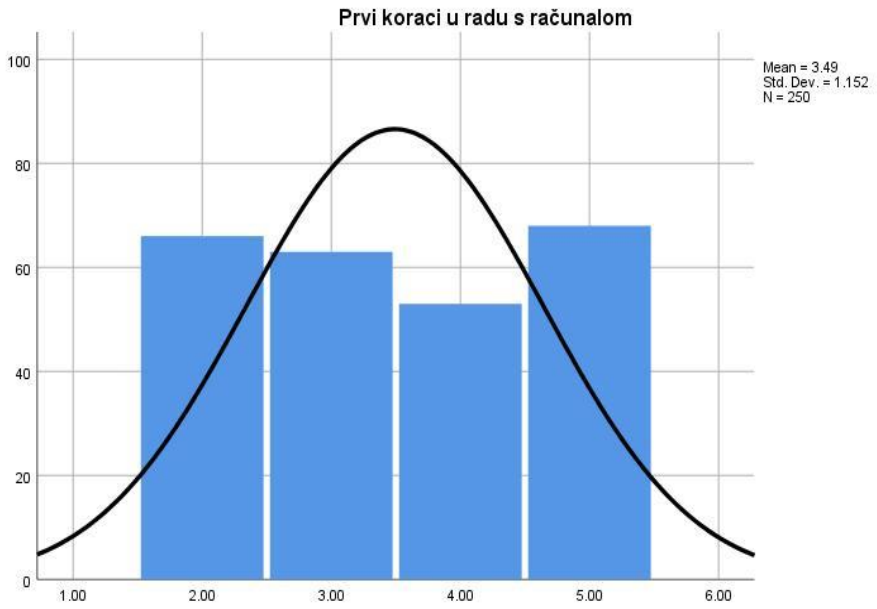
Iz prethodne su tablice vidljive blage razlike u prosječnim ocjenama u pojedinim temama iz predmeta Informatika s obzirom na vrstu škole, velikom većinom u korist ruralnih škola: spremnici računala i programska oprema (urbana 3,45; ruralna 3,60), crtanje pomoću računala (urbana 3,60; ruralna 3,75), programiranje (LOGO) (urbana 3,34; ruralna 3,52), naučimo pisati (urbana 3,29; ruralna 3,45) i internet (urbana 3,49; ruralna 3,72). Jedina nastavna tema u kojoj urbane škole imaju višu prosječnu ocjenu od ruralnih jest: prvi koraci u radu s računalom (urbana 3,55; ruralna 3,44), što se može objasniti pretpostavkom da su djeca iz urbanih područja češće okružena računalima i IKT pa im je već podosta toga poznato.

Prvi koraci u radu s računalom

Upiši svoje ime u gornji redak tablice, pa služeći se tablicom ASCII koda kodiraj svoje ime.

SLOVO	DEKADSKI KÔD	BINARNI ZAPIS	KRAĆI ZAPIS	SLOVO	DEKADSKI KÔD	BINARNI ZAPIS	KRAĆI ZAPIS
A	65	01000001	41	a	97	1100001	61
B	66	01000010	42	b	98	1100010	62
C	67	01000011	43	c	99	1100011	63
D	68	01000100	44	d	100	1100100	64
E	69	01000101	45	e	101	1100101	65
F	70	01000110	46	f	102	1100110	66
G	71	01000111	47	g	103	1100111	67
H	72	01001000	48	h	104	1101000	68
I	73	01001001	49	i	105	1101001	69
J	74	01001010	4A	j	106	1101010	6A
K	75	01001011	4B	k	107	1101011	6B
L	76	01001100	4C	l	108	1101100	6C
M	77	01001101	4D	m	109	1101101	6D
N	78	01001110	4E	n	110	1101110	6E
O	79	01001111	4F	o	111	1101111	6F
P	80	01010000	50	p	112	1110000	70

Slika 31. Primjer zadatka za temu prvi koraci u radu s računalom. Izvor: https://www.e-sfera.hr/dodatni-digitalni-sadrzaji/d9126cd5-5e1c-4195-a3be-003a67ec66ef/



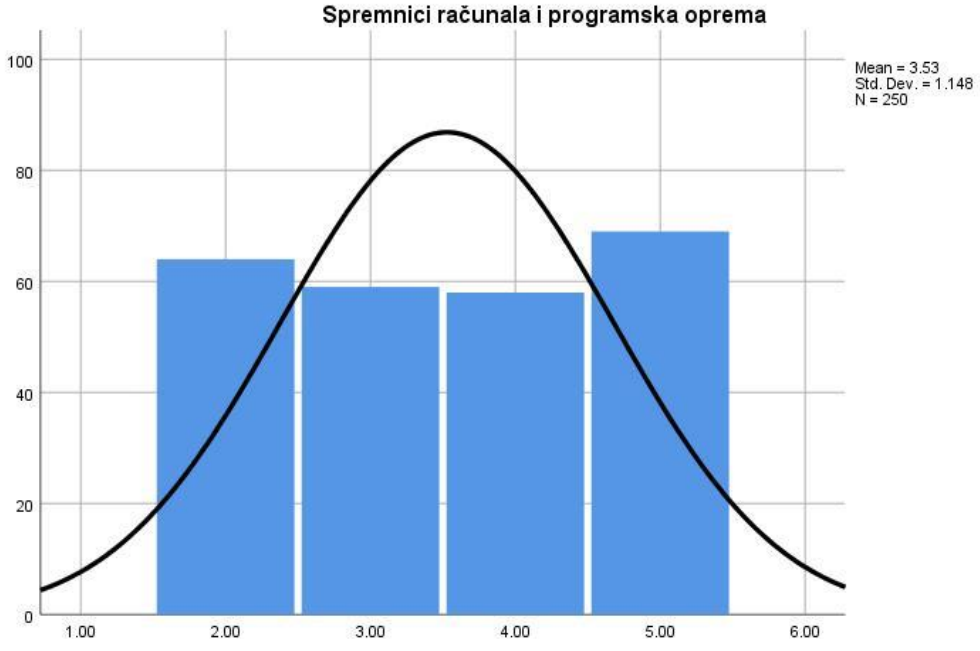
Slika 32. Normalitet distribucija za temu prvi koraci u radu s računalom (peti razred)

Spremnici računala i programska oprema

Čitajući svojstva spremnika, označi pripadnost određenog svojstva vrsti spremnika (neka nabrojena svojstva vrijede za više uređaja).



Slika 34. Primjer zadatka za temu spremnici računala i programska oprema. Izvor:http://os-mejasi-st.skole.hr/nastava/predmeti/spremnici_i_datoteke



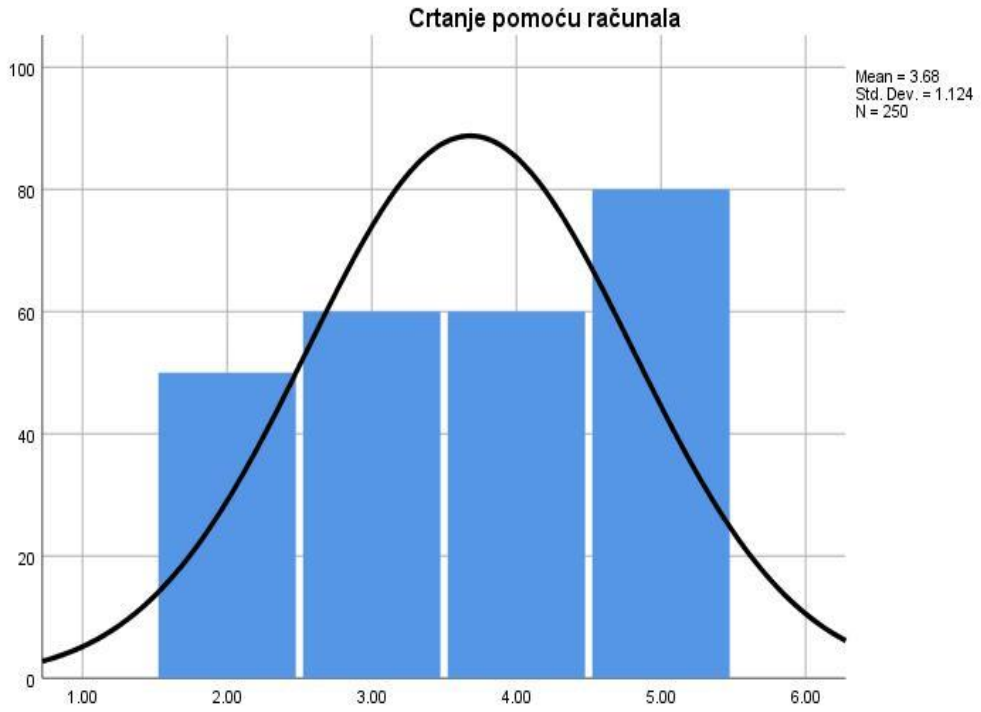
Slika 35. Normalitet distribucija za temu spremnici računala i programska oprema (peti razred)

Crtanje pomoću računala

Nacrtaj strip s ekološkom temom. Stripu dodaj tekst.



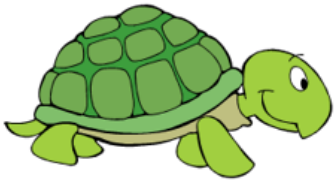
Slika 36. Primjer zadatka za temu crtanje pomoću računala. Izvor: http://logos.wikia.com/wiki/Microsoft_Paint



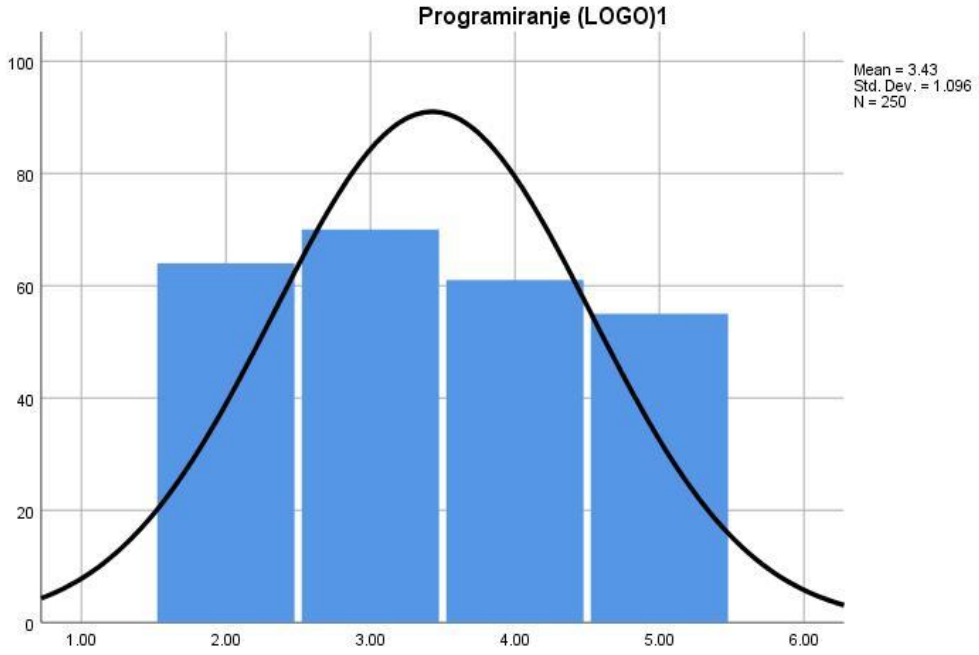
Slika 37. Normalitet distribucija za temu crtanje pomoću računala (peti razred)

Programiranje (LOGO)

Primjenom naredbi za kretanje kornjače nacrtaj po volji crteže u interaktivnom sučelju.



Slika 38. Primjer zadatka za temu programiranje (LOGO). Izvor: https://sites.google.com/a/aiesec.net/nastava-Informatike/5-razred/logo



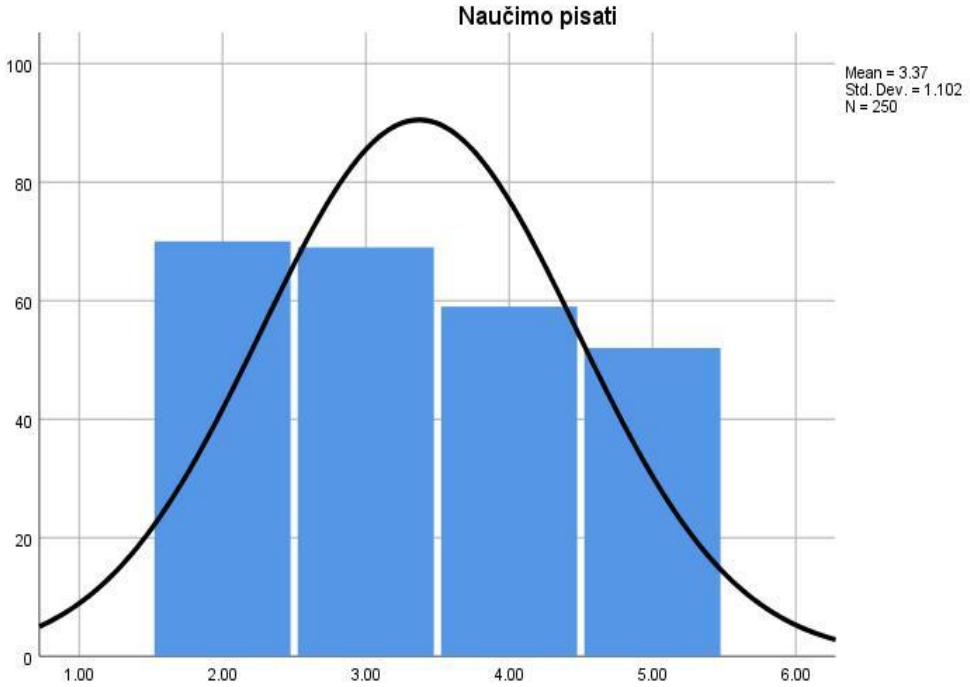
Slika 39. Normalitet distribucija za temu programiranje (LOGO) (peti razred)

Naučimo pisati

Otvori novi dokument u programu Word i kopiraj tekst o Nikoli Tesli s Interneta. Napisani tekst oblikuj na sljedeći način: naslov mora imati tekstni efekt po izboru s veličinom 20, tekst mora biti napisan fontom Georgia veličine 14, godine oblikuj tako da budu ukošene, podcrtane i podebljane. Dokument spremi u svoju mapu.



Slika 40. Primjer zadatka za temu naučimo pisati.
Izvor:https://commons.wikimedia.org/wiki/File:Microsoft_Word_2013_logo.svg



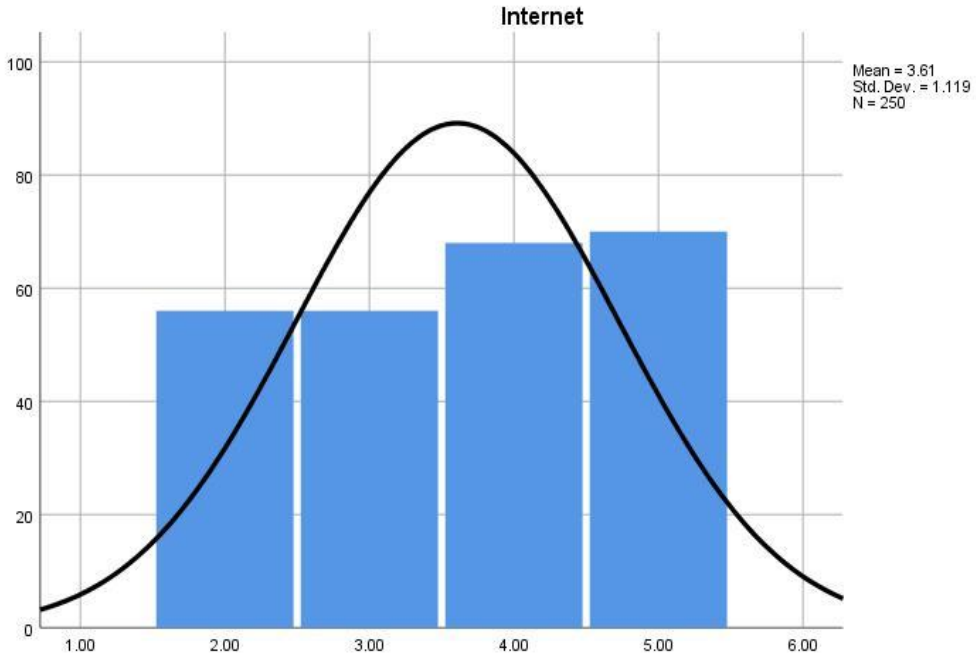
Slika 41. Normalitet distribucija za temu naučimo pisati (peti razred)

Internet

Zamisli da šalješ poruku prijateljici ili prijatelju iz razreda. Na odgovarajuća mjesta napiši primateljevu adresu, naslov poruke, dodaj prilog te napiši tekst poštujući pravila za pisanje e-poruka.



Slika 42. Primjer zadatka za temu internet. Izvor: https://www.hackster.io/gulyasal/make-a-mail-server-out-of-your-rpi3-5829f0



Slika 43. Normalitet distribucija za temu internet (peti razred)

5.1.2.2 Šesti razred

Tablica 10. Deskriptivna statistika odabranih tema iz Matematike za šesti razred

Gradivo	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
Operacije s razlomcima	Gradska	M	50	2	5	3,74	1,065	4,0	3,0	5,0
		Ž	65	2	5	3,55	1,118	3,0	3,0	5,0
		Ukupno	115	2	5	3,63	1,095	4,0	3,0	5,0
	Seoska	M	60	2	5	3,58	1,094	4,0	3,0	4,5
		Ž	75	2	5	3,33	1,155	3,0	2,0	4,0
		Ukupno	135	2	5	3,44	1,131	3,0	2,0	4,0
	Ukupno	M	110	2	5	3,65	1,079	4,0	3,0	5,0
		Ž	140	2	5	3,44	1,139	3,0	2,0	4,5
		Ukupno	250	2	5	3,53	1,116	4,0	3,0	5,0
Trokut	Gradska	M	50	2	5	3,38	1,048	4,0	2,0	4,0
		Ž	65	2	5	3,74	1,108	4,0	3,0	5,0
		Ukupno	115	2	5	3,58	1,092	4,0	3,0	4,0
	Seoska	M	60	2	5	3,43	1,125	3,0	2,0	4,0
		Ž	75	2	5	3,41	1,128	3,0	2,0	4,0
		Ukupno	135	2	5	3,42	1,123	3,0	2,0	4,0
	Ukupno	M	110	2	5	3,41	1,086	3,0	2,0	4,0
		Ž	140	2	5	3,56	1,127	4,0	3,0	5,0
		Ukupno	250	2	5	3,50	1,109	4,0	2,0	4,0
Cijeli brojevi	Gradska	M	50	2	5	3,50	1,129	4,0	2,0	4,0
		Ž	65	2	5	3,51	1,134	3,0	3,0	5,0
		Ukupno	115	2	5	3,50	1,127	3,0	3,0	5,0
	Seoska	M	60	2	5	3,43	1,170	3,0	2,0	4,5
		Ž	75	2	5	3,63	1,075	4,0	3,0	5,0
		Ukupno	135	2	5	3,54	1,118	4,0	3,0	5,0
	Ukupno	M	110	2	5	3,46	1,147	3,5	2,0	4,0
		Ž	140	2	5	3,57	1,100	4,0	3,0	5,0
		Ukupno	250	2	5	3,52	1,120	4,0	3,0	5,0
Racionalni brojevi	Gradska	M	50	2	5	3,52	1,182	3,0	2,0	5,0
		Ž	65	2	5	3,45	1,173	3,0	2,0	5,0
		Ukupno	115	2	5	3,48	1,172	3,0	2,0	5,0
	Seoska	M	60	2	5	3,28	1,010	3,0	3,0	4,0
		Ž	75	2	5	3,47	1,018	3,0	3,0	4,0
		Ukupno	135	2	5	3,39	1,015	3,0	3,0	4,0
	Ukupno	M	110	2	5	3,39	1,093	3,0	3,0	4,0
		Ž	140	2	5	3,46	1,089	3,0	3,0	4,0
		Ukupno	250	2	5	3,43	1,089	3,0	3,0	4,0
Linearne jednadžbe s	Gradska	M	50	2	5	3,34	1,189	3,0	2,0	4,0

jednom nepoznanicom		Ž	65	2	5	3,68	1,077	4,0	3,0	5,0
		Ukupno	115	2	5	3,53	1,134	4,0	2,0	5,0
	Seoska	M	60	2	5	3,45	1,185	3,0	2,0	5,0
		Ž	75	2	5	3,67	1,044	4,0	3,0	4,0
		Ukupno	135	2	5	3,57	1,110	4,0	2,0	4,0
	Ukupno	M	110	2	5	3,40	1,182	3,0	2,0	4,0
		Ž	140	2	5	3,67	1,056	4,0	3,0	4,5
		Ukupno	250	2	5	3,55	1,119	4,0	2,0	4,0
Četverokut	Gradska	M	50	2	5	3,22	1,112	3,0	2,0	4,0
		Ž	65	2	5	3,69	1,172	4,0	3,0	5,0
		Ukupno	115	2	5	3,49	1,165	3,0	2,0	5,0
	Seoska	M	60	2	5	3,45	1,048	3,0	3,0	4,0
		Ž	75	2	5	3,44	1,154	3,0	2,0	5,0
		Ukupno	135	2	5	3,44	1,104	3,0	3,0	4,0
	Ukupno	M	110	2	5	3,35	1,079	3,0	2,0	4,0
		Ž	140	2	5	3,56	1,165	3,0	3,0	5,0
		Ukupno	250	2	5	3,46	1,130	3,0	2,0	5,0

Iz prethodne tablice ponovo je vidljiva blaga razlika s obzirom na vrstu škole za teme iz geometrije: trokut (urbana 3,58; ruralna 3,42), iako je razlika u sličnoj temi gotovo neznatna: četverokut (urbana 3,49; ruralna 3,44). Jedno objašnjenje za zadnje navedene podatke bi mogla biti činjenica da tema četverokut dolazi na samom kraju šestog razreda.

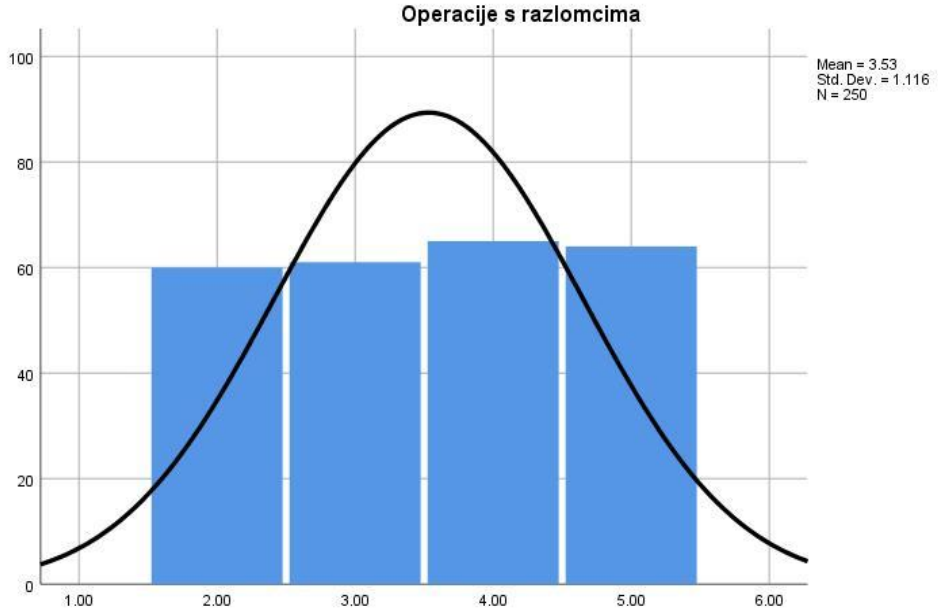
Razlomci

Na općinskim izborima u Slavonskom Brodu glasalo je ukupno 3600 birača. Za stranku „Mi smo najbolji“ glasalo je je ⅖ birača, za stranku „Mi smo najljepši“ ¼ birača, a ostali glasači su glasali za stranku „Dam-daš“. Koliko je glasova dobila svaka stranka?



Slika 44. Primjer zadatka za temu operacije s razlomcima.

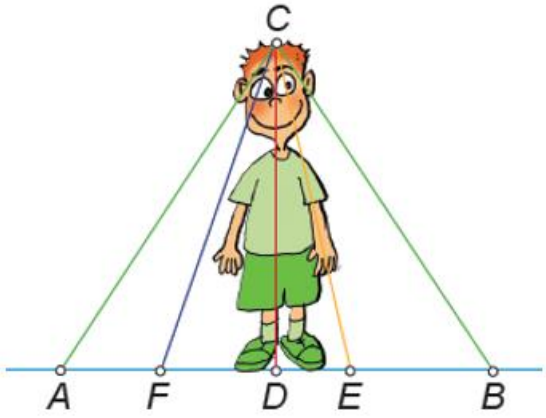
Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 6



Slika 45. Normalitet distribucija za temu operacije s razlomcima (šesti razred)

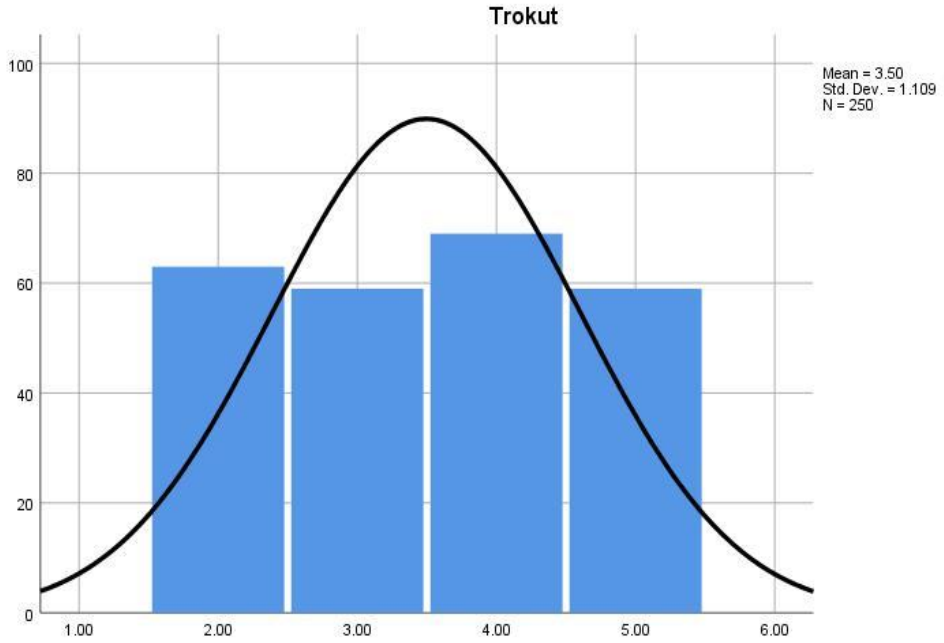
Trokut

Koja je od dužina na slici visina dječaka?



Slika 46. Primjer zadatka za temu trokut.

Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 6



Slika 47. Normalitet distribucija za temu trokut (šesti razred)

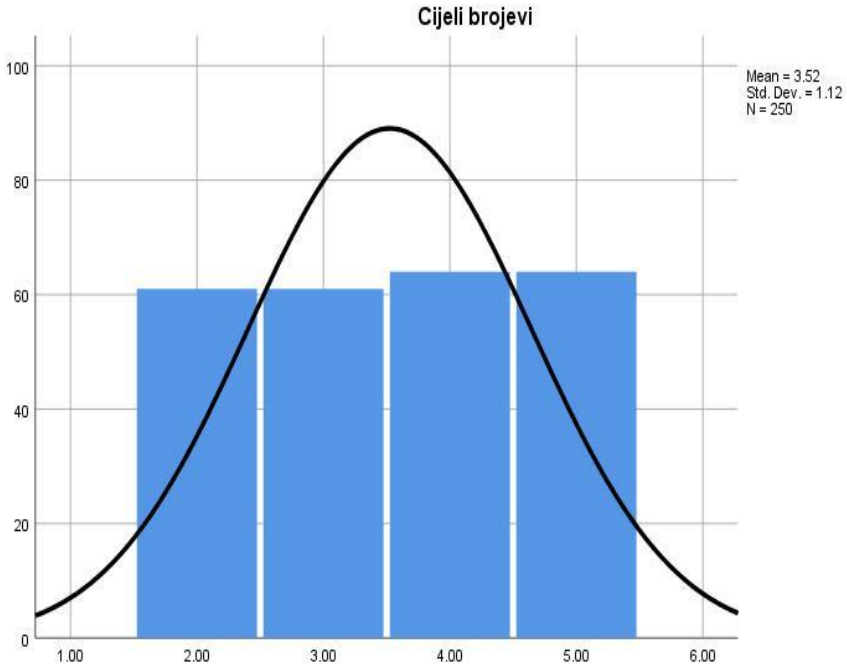
Cijeli brojevi

Obitelj Novak početkom mjeseca imala je stanje na tekućem računu –5 000 kn, znači banci su bili dužni 5 000 kn. Srećom, isti dan sjela im je plaća, +4 000 kn. Kakvo je sada stanje na njihovu tekućem računu?



Slika 48. Primjer zadatka za temu cijeli brojevi.

Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 6



Slika 49. Normalitet distribucija za temu cijeli brojevi (šesti razred)

Racionalni brojevi

Pet dana u tjednu pacijentu je u bolnici Ozdravite sami *mjerena temperatura. Podaci se nalaze u tablici.*

Ponedjeljak	Utorak	Srijeda	Četvrtak	Petak
36.8°C	38.5°C	37.1°C	39.2°C	37.6°C

a) Izračunaj srednju vrijednost temperature:

1. zbroji vrijednosti svih podataka

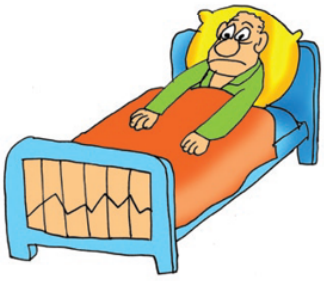
2. dobiveni zbroj podijeli ukupnim brojem podataka.

b) Izračunaj odstupanja pojedinih vrijednosti

od srednje vrijednosti temperature.

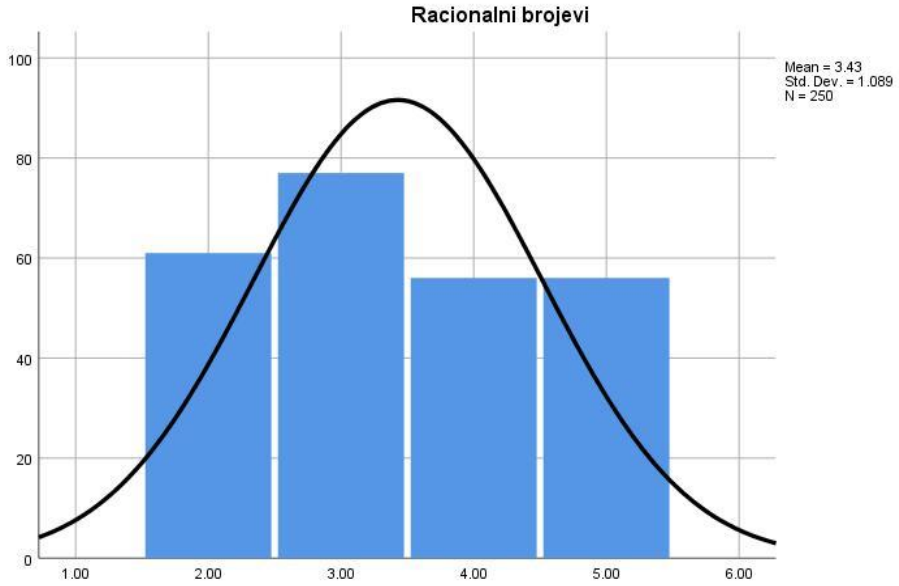
c) Odstupanje iz zadatka b) napiši kao

pozitivne ili negativne racionalne brojeve.



Slika 50. Primjer zadatka za temu racionalni brojevi.

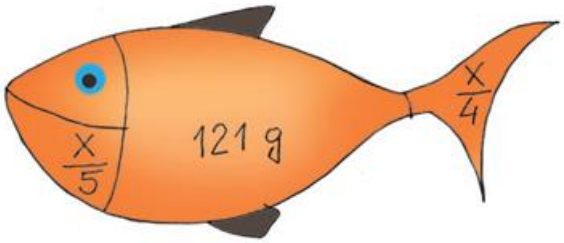
Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 6



Slika 51. Normalitet distribucija za temu racionalni brojevi (šesti razred)

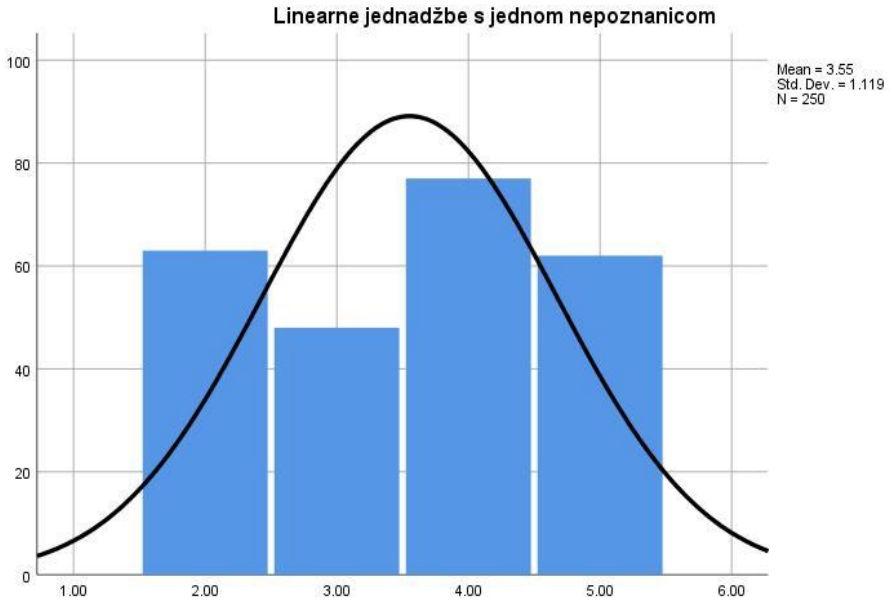
Linearne jednadžbe s jednom nepoznanicom

Iz stare arapske računice:
Petina ribe otpada na glavu, četvrtina na rep, a sredina ima 121 g. Kolika je masa cijele ribe?



Slika 52. Primjer zadatka za temu linearne jednadžbe s jednom nepoznanicom.

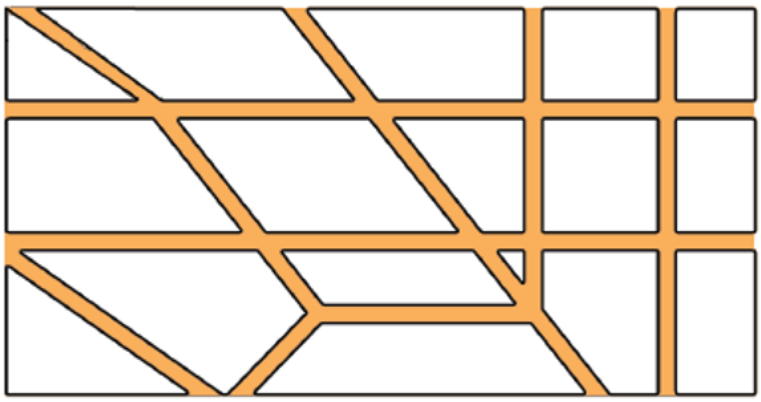
Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 6



Slika 53. Normalitet distribucija za temu linearne jednadžbe s jednom nepoznanicom (šesti razred)

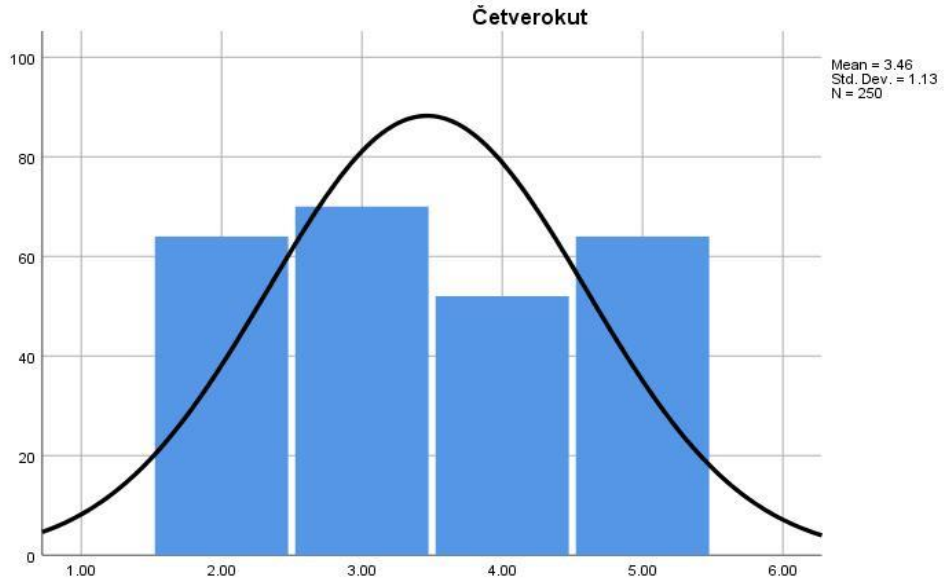
Četverokut

Urbanisti grada Karlovca napravili su tlocrt za industrijsku zonu. Zemljišta su različitih geometrijskih oblika. Plavom bojom oboji četverokute, a crvenom bojom trokute.



Slika 54. Primjer zadatka za temu četverokut.

Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 6



Slika 55. Normalitet distribucija za temu četverokut (šesti razred)

Promotrimo deskriptivnu statistiku tema za isti razred za predmet Informatika.

Tablica 11. Deskriptivna statistika odabranih tema iz Informatike za šesti razred

Gradivo	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
Osnove informatike	Gradska	M	50	2	5	3,42	1,180	3,0	2,0	5,0
		Ž	65	2	5	3,58	1,044	4,0	3,0	4,0
		Ukupno	115	2	5	3,51	1,103	4,0	3,0	4,0
	Seoska	M	60	2	5	3,43	,998	3,0	3,0	4,0
		Ž	75	2	5	3,53	1,131	4,0	2,0	5,0
		Ukupno	135	2	5	3,49	1,071	4,0	3,0	4,0
	Ukupno	M	110	2	5	3,43	1,079	3,0	3,0	4,0
		Ž	140	2	5	3,56	1,088	4,0	3,0	4,0
		Ukupno	250	2	5	3,50	1,084	4,0	3,0	4,0
Programiranje (LOGO)	Gradska	M	50	2	5	3,48	1,182	3,0	2,0	5,0
		Ž	65	2	5	3,55	1,061	3,0	3,0	5,0
		Ukupno	115	2	5	3,52	1,111	3,0	3,0	5,0
	Seoska	M	60	2	5	3,25	1,099	3,0	2,0	4,0
		Ž	75	2	5	3,67	1,178	4,0	2,0	5,0
		Ukupno	135	2	5	3,48	1,158	4,0	2,0	5,0

	Ukupno	M	110	2	5	3,35	1,138	3,0	2,0	4,0
		Ž	140	2	5	3,61	1,123	4,0	3,0	5,0
		Ukupno	250	2	5	3,50	1,135	3,0	2,0	5,0
Obrada teksta	Gradska	M	50	2	5	3,38	1,048	3,0	3,0	4,0
		Ž	65	2	5	3,42	1,158	3,0	2,0	4,0
		Ukupno	115	2	5	3,40	1,107	3,0	2,0	4,0
	Seoska	M	60	2	5	3,65	1,117	4,0	3,0	5,0
		Ž	75	2	5	3,68	1,129	4,0	3,0	5,0
		Ukupno	135	2	5	3,67	1,120	4,0	3,0	5,0
	Ukupno	M	110	2	5	3,53	1,090	3,5	3,0	4,0
		Ž	140	2	5	3,56	1,146	4,0	3,0	5,0
		Ukupno	250	2	5	3,54	1,119	4,0	3,0	5,0
Računala u mreži	Gradska	M	50	2	5	3,34	1,206	3,0	2,0	5,0
		Ž	65	2	5	3,51	1,077	4,0	3,0	4,0
		Ukupno	115	2	5	3,43	1,133	3,0	2,0	4,0
	Seoska	M	60	2	5	3,37	1,134	3,0	2,0	4,0
		Ž	75	2	5	3,53	1,212	4,0	2,0	5,0
		Ukupno	135	2	5	3,46	1,177	3,0	2,0	5,0
	Ukupno	M	110	2	5	3,35	1,162	3,0	2,0	4,0
		Ž	140	2	5	3,52	1,147	4,0	2,0	5,0
		Ukupno	250	2	5	3,45	1,154	3,0	2,0	5,0
Multimedija	Gradska	M	50	2	5	3,48	1,074	3,0	3,0	4,0
		Ž	65	2	5	3,49	1,120	3,0	3,0	4,0
		Ukupno	115	2	5	3,49	1,095	3,0	3,0	4,0
	Seoska	M	60	2	5	3,42	1,109	3,0	2,0	4,0
		Ž	75	2	5	3,56	1,068	3,0	3,0	5,0
		Ukupno	135	2	5	3,50	1,085	3,0	3,0	4,0
	Ukupno	M	110	2	5	3,45	1,089	3,0	3,0	4,0
		Ž	140	2	5	3,53	1,089	3,0	3,0	4,5
		Ukupno	250	2	5	3,49	1,088	3,0	3,0	4,0
Izrada prezentacija	Gradska	M	50	2	5	3,58	1,108	4,0	3,0	5,0
		Ž	65	2	5	3,54	1,105	4,0	3,0	4,0
		Ukupno	115	2	5	3,56	1,102	4,0	3,0	4,0
	Seoska	M	60	2	5	3,45	1,064	3,0	3,0	4,0
		Ž	75	2	5	3,43	1,117	3,0	2,0	4,0
		Ukupno	135	2	5	3,44	1,090	3,0	3,0	4,0
	Ukupno	M	110	2	5	3,51	1,081	4,0	3,0	4,0
		Ž	140	2	5	3,48	1,109	3,0	2,5	4,0
		Ukupno	250	2	5	3,49	1,095	3,5	3,0	4,0

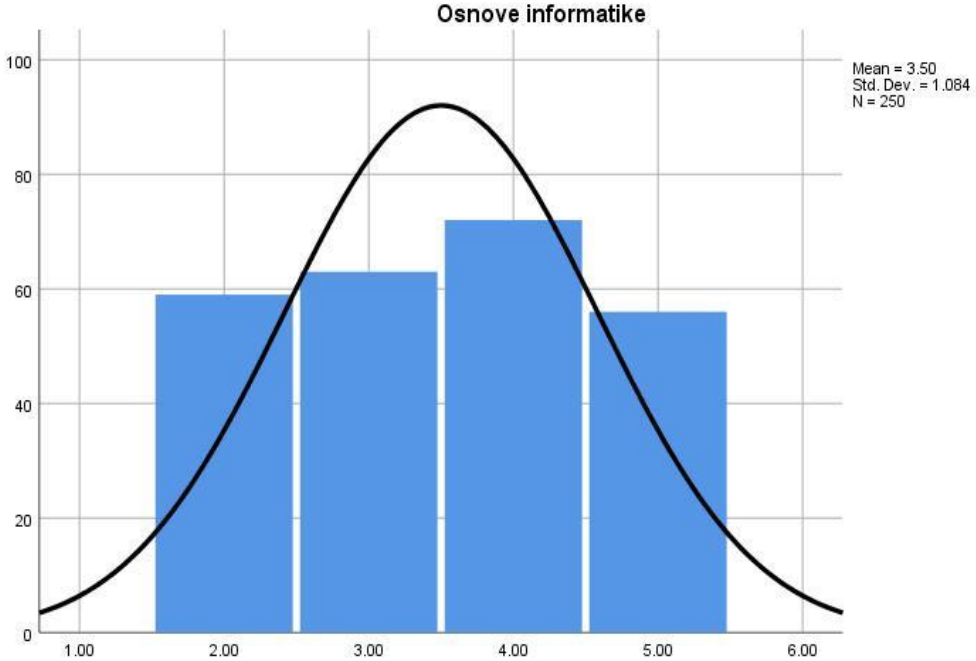
Iz prethodne su tablice vidljive razlike s obzirom na jednu nastavnu temu iz predmeta Informatika u korist ruralnih škola: obrada teksta (urbana 3,40; ruralna 3,67), dok je za većinu ostalih tema razlika neznatna: osnove informatike (urbana 3,51; ruralna 3,49), programiranje (LOGO) (urbana 3,52; ruralna 3,50), računala u mreži (urbana 3,43; ruralna 3,46) i multimedija (urbana 3,49; ruralna 3,50). Zanimljivo je primijetiti da je nešto viša razlika koja se pojavljuje u korist urbanih škola u temi izrada prezentacija (urbana 3,56; ruralna 3,44), koja tema zahtijeva kreativnost i sposobnost vizualizacije.

Osnove informatike

Na zamišljenom monitoru od 5 x 5 piksela nacrtaj neki lik i to tako da crnom bojom popuniš obrise lika, odnosno odgovarajuće kvadratiće. Pretvori zapis s monitora u prikaz bitova tako da crni kvadratić bude jedinica, a bijeli nula.



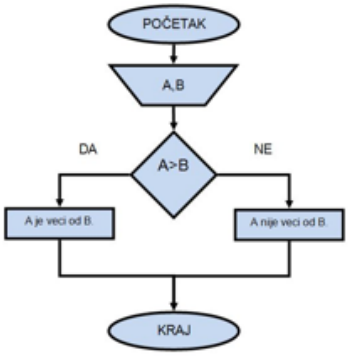
Slika 56. Primjer zadatka za temu osnove informatike. Izvor: profil-klett.hr



Slika 57. Normalitet distribucija za temu osnove informatike (šesti razred)

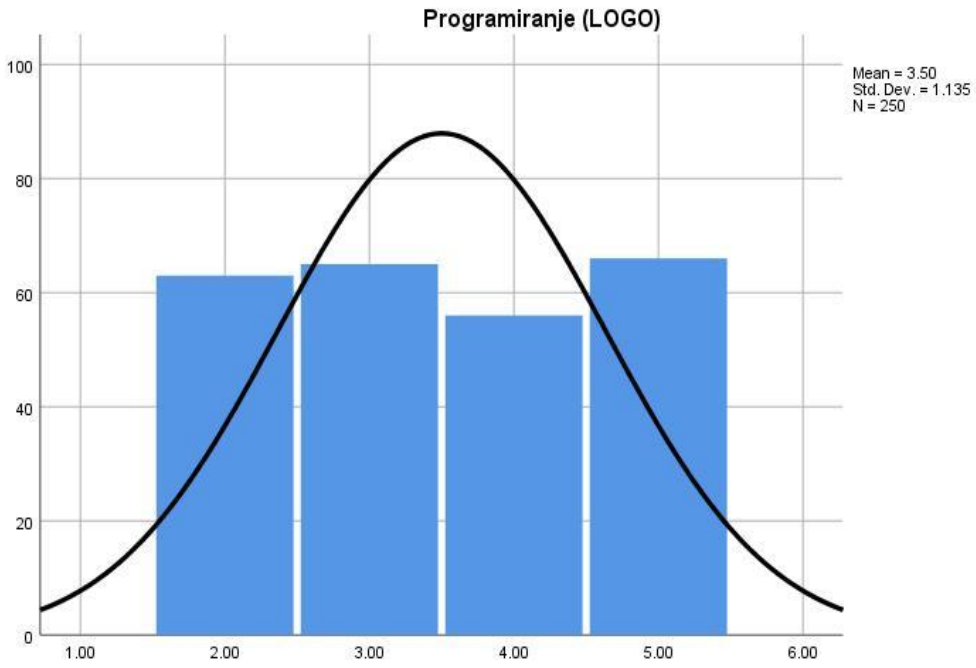
Programiranje (LOGO)

Opiši što će se ispisati kao rezultat ako se izvrši dijagram toka kao na slici.



Slika 58. Primjer zadatka za temu programiranje (LOGO). Izvor:

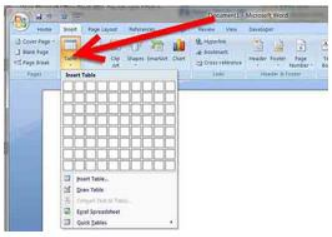
http://www.oblakznanja.com/2015/10/primjena-naredbi-grananja-primjeri-i-zadaci/dijagram-tijeka-odluka-if-then-else/



Slika 59. Normalitet distribucija za temu programiranje (LOGO) (šesti razred)

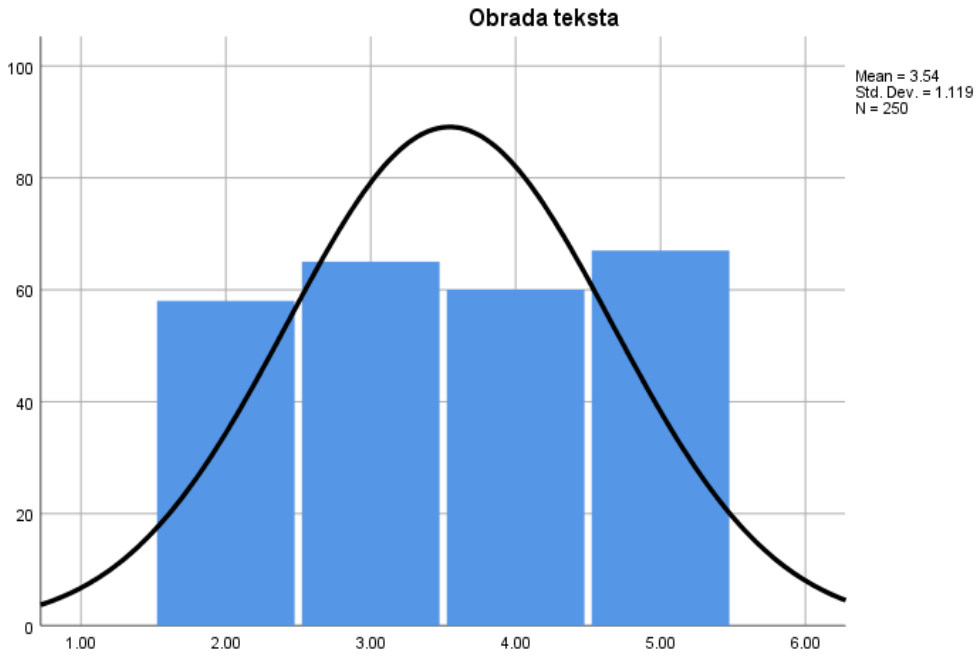
Obrada teksta

Umetni tablicu s 4 stupca i 5 redova. U prvi stupac upiši imena četvero učenika iz razreda. U drugi stupac upiši njihova prezimena, u treći datume rođenja, a u četvrti ulicu u kojima žive. Tablici dodaj još jedan redak i to na vrhu. U njega upiši u prvi stupac Ime, u drugi Prezime, zatim Datum rođenja i Adresu. Podesi širinu stupca tako da tablica zauzme cijeli papir.



Slika 60. Primjer zadatka za temu obrada teksta. Izvor:

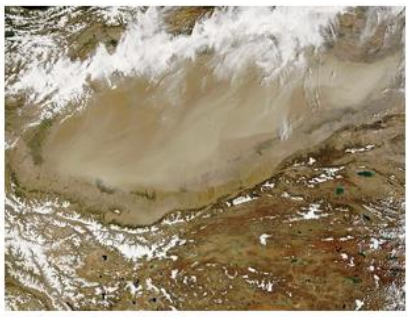
(http://interest-hr.cikavo.in.ua/ra-unala-i-elektronika/office-softver/31820-kako-napraviti-jednostavnu-tablicu-u-microsoft.html



Slika 61. Normalitet distribucija za temu obrada teksta (šesti razred)

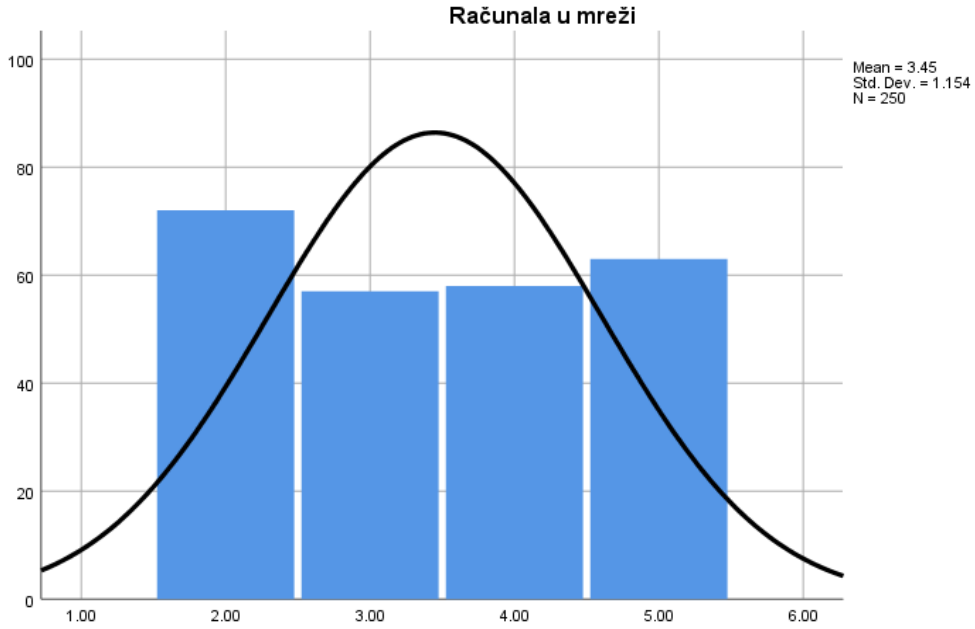
Računala u mreži

Pustinja Takla Makan je smještena u zapadnoj Kini i jedna je od najvećih pješčanih pustinja na svijetu. Preko tražilice saznaj što su to oaze. Koje se dvije oaze nalaze u pustinji Takla Makan i otkriti pet pustinja koje su po svojoj površini najveće na svijetu.



Slika 62. Primjer zadatka za temu računala u mreži.

Izvor: https://hr.wikipedia.org/wiki/Takla_Makan



Slika 63. Normalitet distribucije za temu računala u mreži (šesti razred)

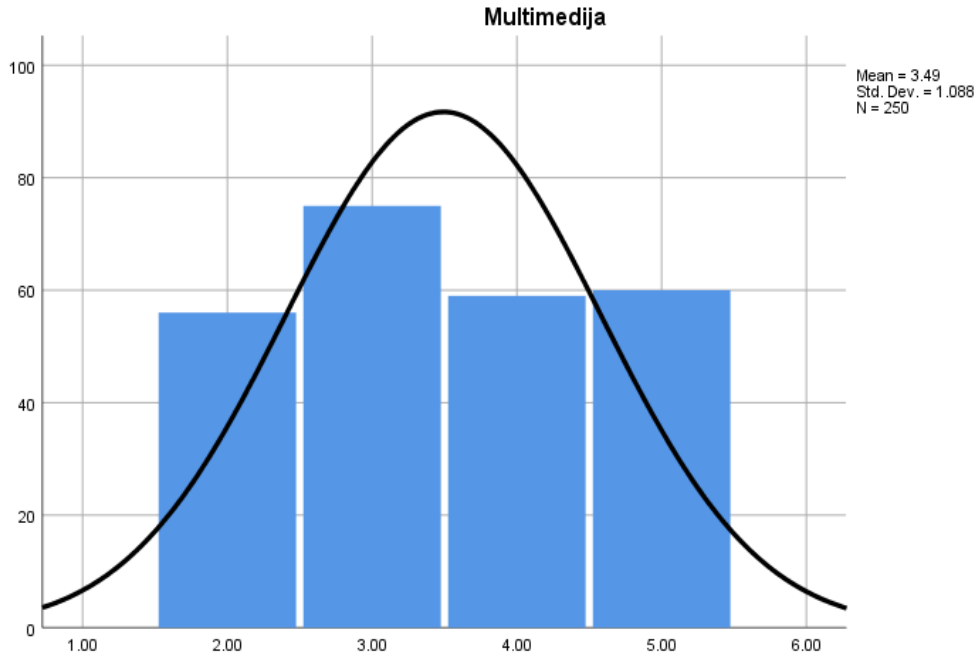
Multimedija

Pronađi nekoliko snimljenih videozapisa fotoaparatom ili kamerom i smjesti ih u mapu pod nazivom Film. Pokreni program Windows Movie Maker i u izborniku odaberi opciju otvaranja novog projekta. Izvrši grubo izrezivanje dijelova videozapisa koji nisu potrebni za daljnji rad, a preostale video isječke pokušaj redom prevući u raku za video montažu.



Slika 64. Primjer zadatka za temu multimedija. Izvor:

http://logos.wikia.com/wiki/File:Windows-movie-maker-2012-08-535x5351.png



Slika 65. Normalitet distribucije za temu multimedija (šesti razred)

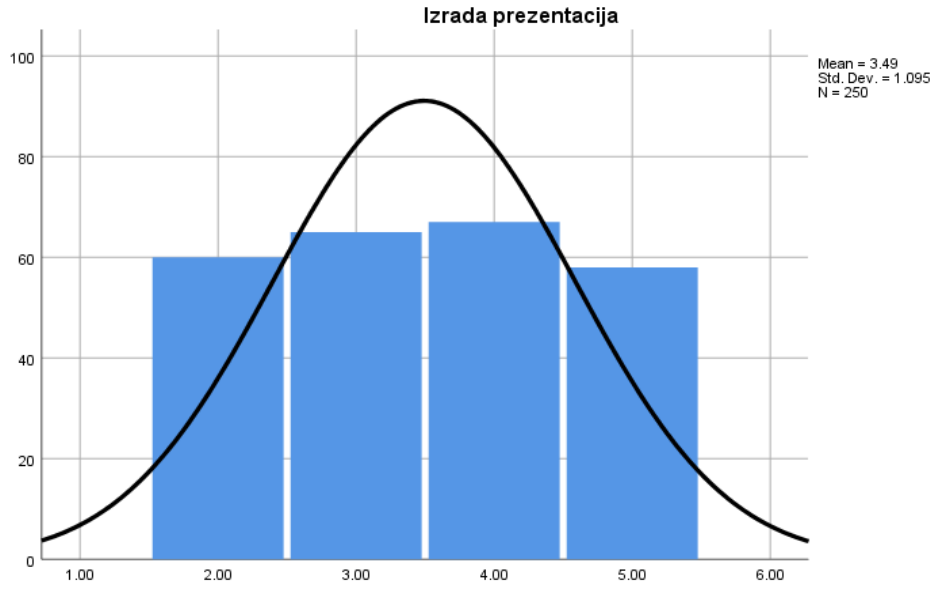
Izrada prezentacija

Odaberi dizajnirani predložak i primijeni ga na prezentaciju na temu o vlastitom gradu.



Slika 66. Primjer zadatka za temu izrada prezentacija.

Izvor: https://support.office.com/hr-hr/article/stvaranje-i-spremanje-predlo%C5%A1ka-programa-powerpoint-ee4429ad-2a74-4100-82f7-50f8169c8aca



Slika 67. Normalitet distribucije za temu izrada prezentacija (šesti razred)

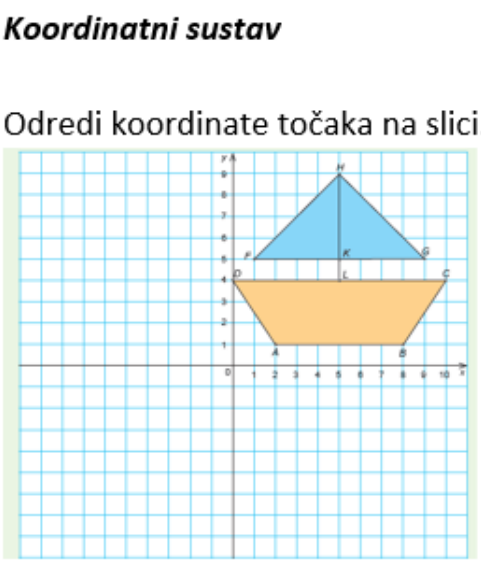
5.1.2.3 Sedmi razred

Tablica 12. Deskriptivna statistika odabranih tema iz Matematike za sedmi razred

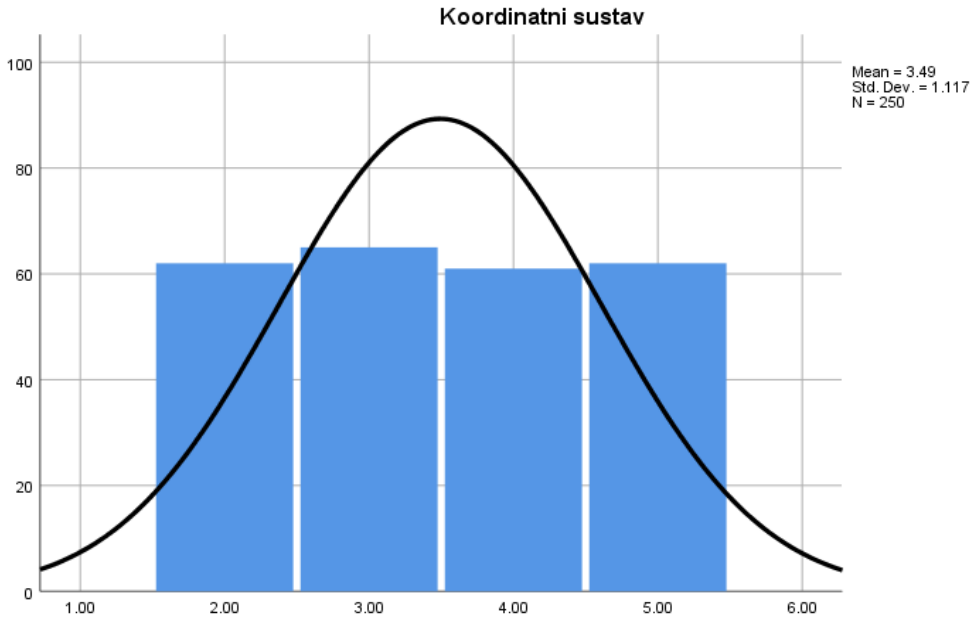
Gradivo	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
Koordinatni sustav	Gradska	M	69	2	5	3,39	1,140	3,0	2,0	4,0
		Ž	63	2	5	3,57	1,132	4,0	3,0	5,0
		Ukupno	132	2	5	3,48	1,136	3,0	2,0	4,5
	Seoska	M	61	2	5	3,61	1,005	4,0	3,0	4,0
		Ž	57	2	5	3,40	1,193	3,0	2,0	5,0
		Ukupno	118	2	5	3,51	1,100	3,0	3,0	4,0
	Ukupno	M	130	2	5	3,49	1,080	3,5	3,0	4,0
		Ž	120	2	5	3,49	1,160	3,0	2,0	5,0
		Ukupno	250	2	5	3,49	1,117	3,0	3,0	4,0
Proporcionalnost i obrnuta proporcionalnost	Gradska	M	69	2	5	3,32	1,131	3,0	2,0	4,0
		Ž	63	2	5	3,67	1,150	4,0	3,0	5,0
		Ukupno	132	2	5	3,48	1,149	3,0	2,0	5,0
	Seoska	M	61	2	5	3,77	,990	4,0	3,0	5,0
		Ž	57	2	5	3,53	1,087	3,0	3,0	4,0
		Ukupno	118	2	5	3,65	1,041	4,0	3,0	5,0
	Ukupno	M	130	2	5	3,53	1,087	4,0	3,0	4,0
		Ž	120	2	5	3,60	1,118	4,0	3,0	5,0
		Ukupno	250	2	5	3,56	1,100	4,0	3,0	5,0
Sličnost i mnogokuti	Gradska	M	69	2	5	3,42	1,143	3,0	2,0	4,0
		Ž	63	2	5	3,60	1,158	4,0	3,0	5,0
		Ukupno	132	2	5	3,51	1,149	3,0	2,0	5,0
	Seoska	M	61	2	5	3,51	1,074	3,0	3,0	4,0
		Ž	57	2	5	3,53	1,120	3,0	3,0	5,0
		Ukupno	118	2	5	3,52	1,092	3,0	3,0	4,0
	Ukupno	M	130	2	5	3,46	1,108	3,0	3,0	4,0
		Ž	120	2	5	3,57	1,136	4,0	3,0	5,0
		Ukupno	250	2	5	3,51	1,120	3,0	3,0	5,0
Krug i kružnica	Gradska	M	69	2	5	3,30	1,192	3,0	2,0	4,0
		Ž	63	2	5	3,57	1,132	4,0	3,0	5,0
		Ukupno	132	2	5	3,43	1,167	3,0	2,0	4,5
	Seoska	M	61	2	5	3,72	1,097	4,0	3,0	5,0
		Ž	57	2	5	3,53	1,087	4,0	3,0	4,0
		Ukupno	118	2	5	3,63	1,092	4,0	3,0	5,0
	Ukupno	M	130	2	5	3,50	1,163	3,0	2,0	5,0
		Ž	120	2	5	3,55	1,107	4,0	3,0	4,0
		Ukupno	250	2	5	3,52	1,134	4,0	2,0	5,0
Sustavi linearnih jednadžbi	Gradska	M	69	2	5	3,45	1,170	4,0	2,0	4,0
		Ž	63	2	5	3,46	1,060	3,0	3,0	4,0

		Ukupno	132	2	5	3,45	1,115	4,0	2,0	4,0
	Seoska	M	61	2	5	3,41	1,006	4,0	3,0	4,0
		Ž	57	2	5	3,58	1,017	4,0	3,0	4,0
		Ukupno	118	2	5	3,49	1,011	4,0	3,0	4,0
	Ukupno	M	130	2	5	3,43	1,092	4,0	2,0	4,0
		Ž	120	2	5	3,52	1,037	4,0	3,0	4,0
		Ukupno	250	2	5	3,47	1,065	4,0	3,0	4,0
Linearna funkcija i jednadžba pravca	Gradska	M	69	2	5	3,33	1,053	3,0	3,0	4,0
		Ž	63	2	5	3,46	1,060	4,0	3,0	4,0
		Ukupno	132	2	5	3,39	1,054	3,0	3,0	4,0
	Seoska	M	61	2	5	3,67	1,044	4,0	3,0	5,0
		Ž	57	2	5	3,65	1,157	3,0	3,0	5,0
		Ukupno	118	2	5	3,66	1,096	4,0	3,0	5,0
	Ukupno	M	130	2	5	3,49	1,058	3,0	3,0	4,0
		Ž	120	2	5	3,55	1,107	3,5	3,0	5,0
		Ukupno	250	2	5	3,52	1,080	3,0	3,0	5,0

U sedmom razredu nam podaci s obzirom na nastavne teme iz područja geometrije pokazuju drugačiju sliku. Tako za temu krug i kružnica vidi se razlika u korist ruralnih škola (urbana 3,43; ruralna 3,63), dok su za teme: koordinatni sustav (urbana 3,48; ruralna 3,51) te sličnost i mnogokuti (urbana 3,51; ruralna 3,52) razlike gotovo neznatne. S obzirom na nastavne teme koje su egzaktnije vidimo kao i prije razlike u korist ruralnih škola: proporcionalnost i obrnuta proporcionalnost (urbana 3,48; ruralna 3,65), linearna funkcija i jednadžba pravca (urbana 3,39; ruralna 3,66) i sustavi linearnih jednadžbi (urbana 3,45; ruralna 3,49).



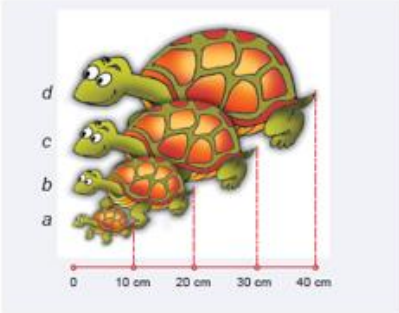
Slika 68. Primjer zadataka za temu koordinatni sustav. Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 7



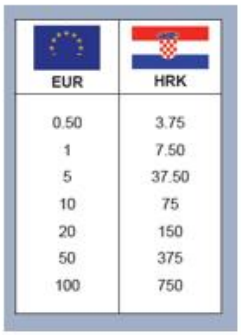
Slika 69. Normalitet distribucije za temu koordinatni sustav (sedmi razred)

Proporcionalnost i obrnuta proporcionalnost

U kojem su omjeru nacrtane kornjače? (Slika 1)
Koristeći se tablicom, odredi koliko ćeš kuna dobiti za 200 Eura? (Slika 2)



Slika 1

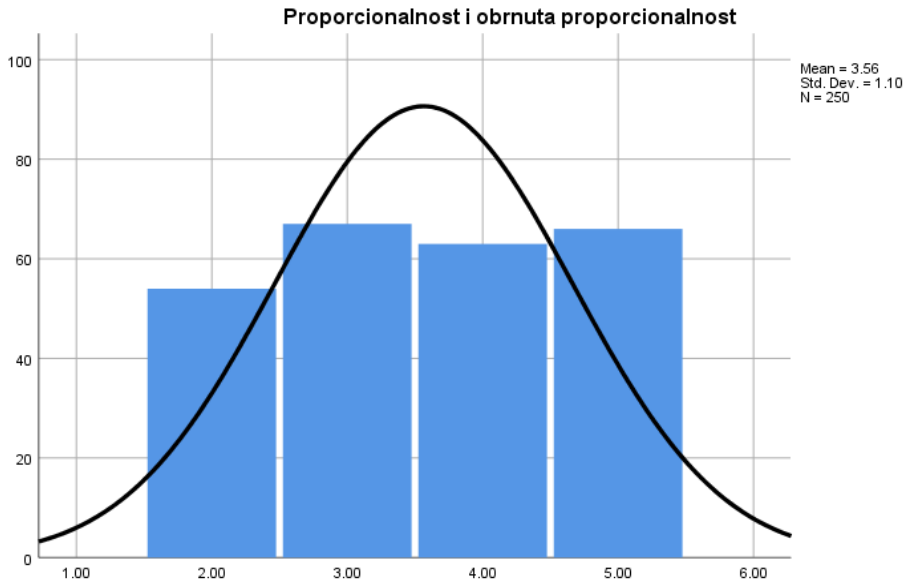


EUR	HRK
0.50	3.75
1	7.50
5	37.50
10	75
20	150
50	375
100	750

Slika 2

Slika 70. Primjer zadatka za temu proporcionalnost i obrnuta proporcionalnost.

Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 7

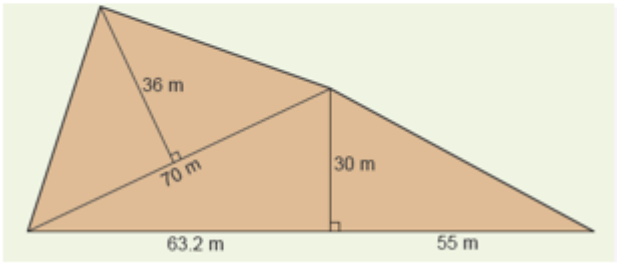


Slika 71. Normalitet distribucije za temu proporcionalnost i obrnuta proporcionalnost (sedmi razred)

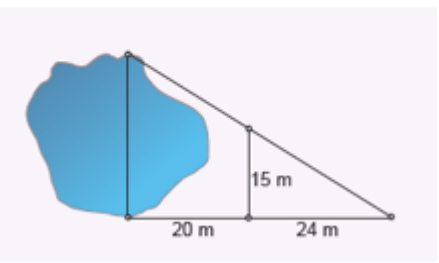
Sličnost i mnogokuti

Odredi širinu jezera na slici.
(Slika 2)

Odredi površinu mnogokuta na slici.
(Slika 1)

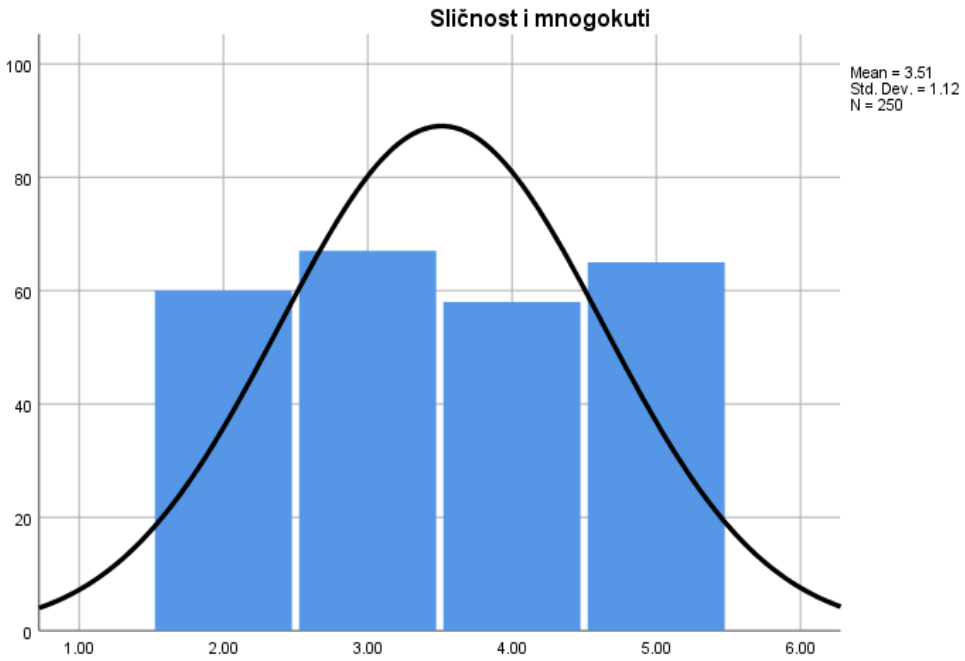


Slika 1



Slika 2

Slika 72. Primjer zadatka za temu sličnost i mnogokuti. Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 7



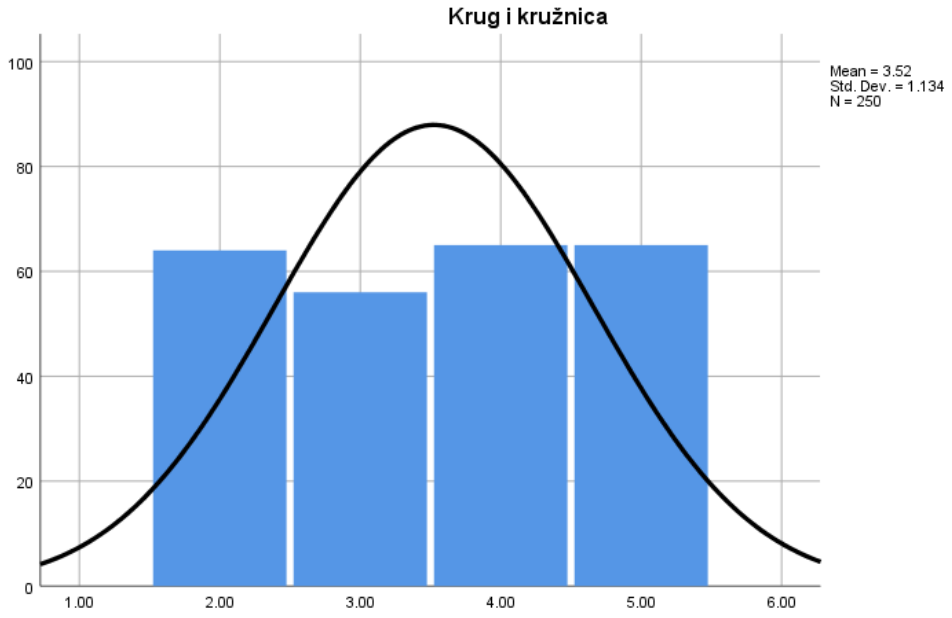
Slika 73. Normalitet distribucije za temu sličnost i mnogokuti (sedmi razred)

Krug i kružnica

Odredi površinu zadanih krugova.



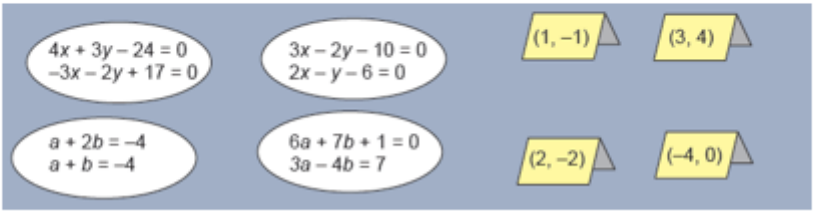
Slika 74. Primjer zadatka za temu krug i kružnica. Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 7



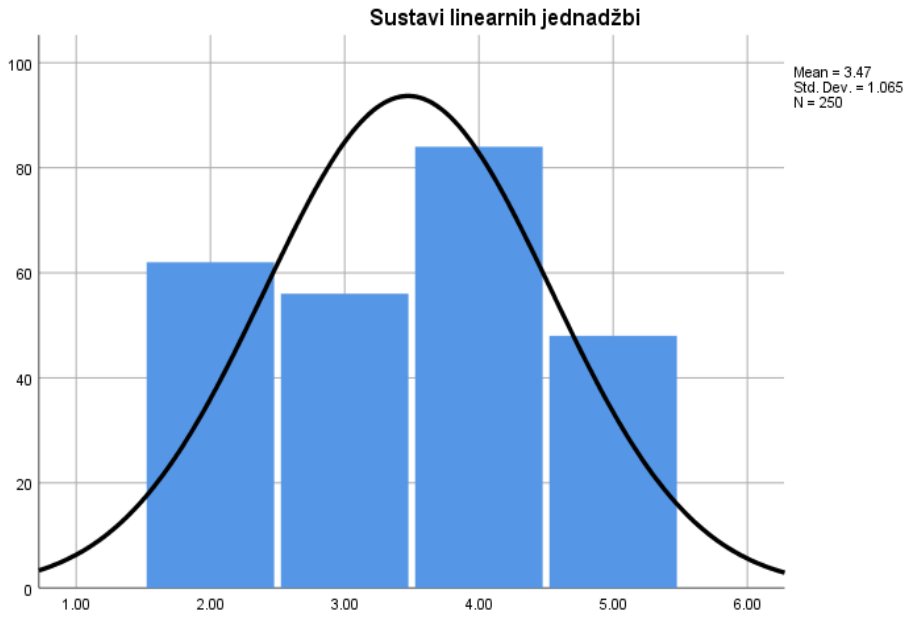
Slika 75. Normalitet distribucija za temu krug i kružnica (sedmi razred)

Sustavi linearnih jednadžbi

Riješi sustav dviju linearnih jednadžbi s dvije nepoznanice koristeći: a) metodu supstitucije, b) metodu suprotnih koeficijenata.



Slika 76. Primjer zadatka za temu sustavi linearnih jednadžbi. Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 7



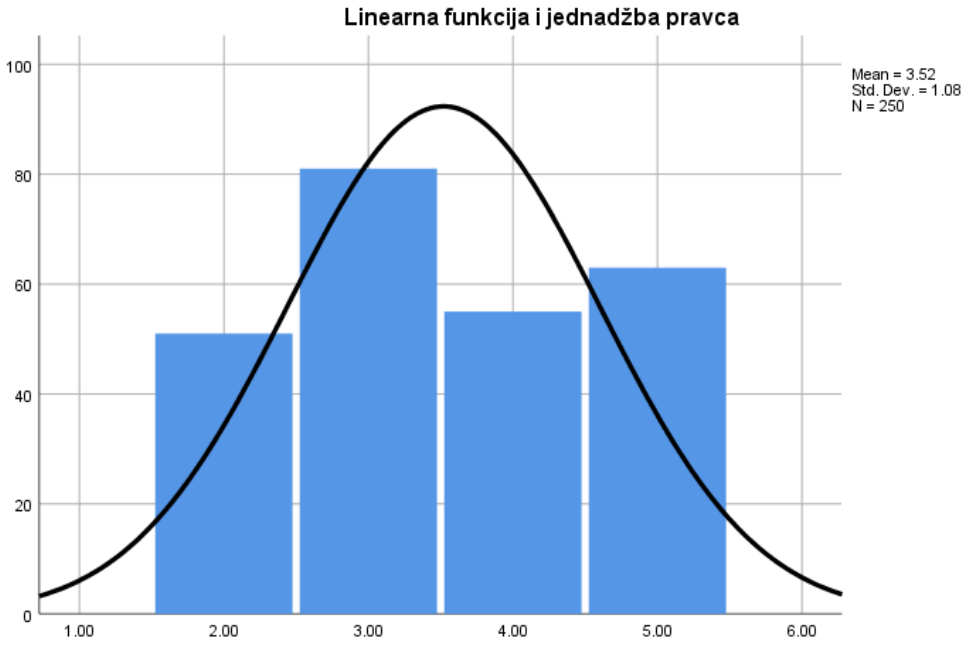
Slika 77. Normalitet distribucije za temu sustavi linearnih jednadžbi (sedmi razred)

Linearna funkcija

Promotri dijagram temperatura pa odgovori: Koji je dan u tjednu bio najtopliji?



Slika 78. Primjer zadatka za temu linearna funkcija. Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 7



Slika 79. Normalitet distribucije za temu linearna funkcija i jednadžba pravca (sedmi razred)

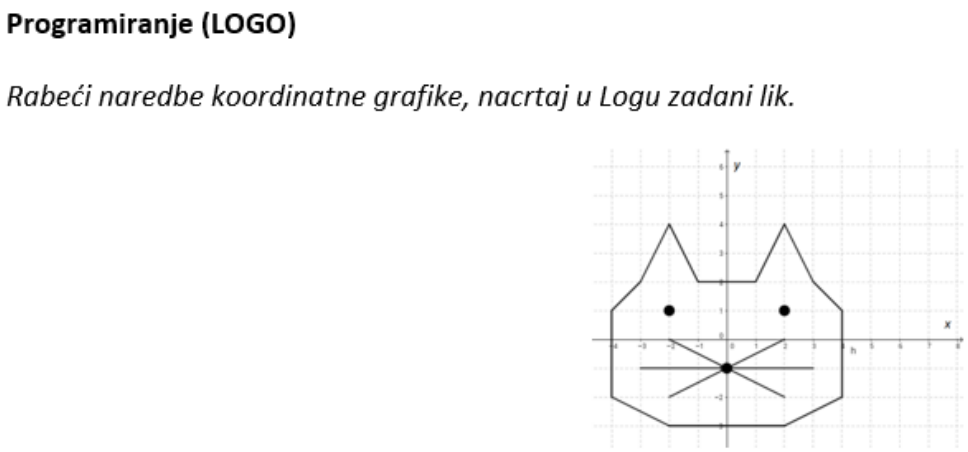
Promotrimo deskriptivnu statistiku tema za isti razred za predmet Informatika.

Tablica 13. Deskriptivna statistika odabranih tema iz Informatike za sedmi razred

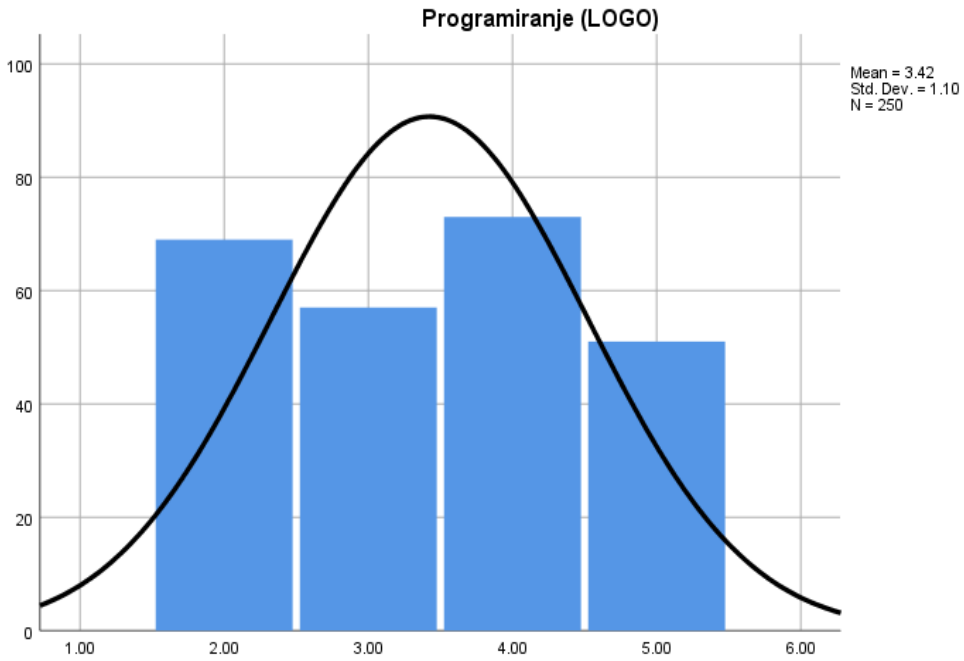
Gradivo	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
Programiranje (LOGO)	Gradska	M	69	2	5	3,54	1,079	4,0	3,0	4,0
		Ž	63	2	5	3,30	1,057	3,0	2,0	4,0
		Ukupno	132	2	5	3,42	1,071	4,0	2,0	4,0
	Seoska	M	61	2	5	3,26	1,182	3,0	2,0	4,0
		Ž	57	2	5	3,60	1,067	4,0	3,0	4,0
		Ukupno	118	2	5	3,42	1,135	3,0	2,0	4,0
	Ukupno	M	130	2	5	3,41	1,132	3,0	2,0	4,0
		Ž	120	2	5	3,44	1,067	3,5	2,5	4,0
		Ukupno	250	2	5	3,42	1,100	3,0	2,0	4,0
Proračunske tablice	Gradska	M	69	2	5	3,65	1,122	4,0	3,0	5,0
		Ž	63	2	5	3,43	1,058	3,0	3,0	4,0
		Ukupno	132	2	5	3,55	1,094	3,0	3,0	5,0

	Seoska	M	61	2	5	3,49	,994	4,0	3,0	4,0
		Ž	57	2	5	3,40	1,050	3,0	3,0	4,0
		Ukupno	118	2	5	3,45	1,018	3,5	3,0	4,0
	Ukupno	M	130	2	5	3,58	1,063	4,0	3,0	4,0
		Ž	120	2	5	3,42	1,050	3,0	3,0	4,0
		Ukupno	250	2	5	3,50	1,058	3,0	3,0	4,0
Prezentacije	Gradska	M	69	2	5	3,55	1,051	4,0	3,0	4,0
		Ž	63	2	5	3,52	1,148	4,0	2,0	5,0
		Ukupno	132	2	5	3,54	1,094	4,0	3,0	4,0
	Seoska	M	61	2	5	3,41	1,146	3,0	2,0	4,0
		Ž	57	2	5	3,54	1,119	4,0	3,0	4,0
		Ukupno	118	2	5	3,47	1,130	3,0	2,0	4,0
	Ukupno	M	130	2	5	3,48	1,094	4,0	3,0	4,0
		Ž	120	2	5	3,53	1,130	4,0	2,0	4,5
		Ukupno	250	2	5	3,51	1,109	4,0	2,0	4,0
Izrada mrežnih stranica	Gradska	M	69	2	5	3,72	1,083	4,0	3,0	5,0
		Ž	63	2	5	3,38	1,023	3,0	2,0	4,0
		Ukupno	132	2	5	3,56	1,065	4,0	3,0	4,0
	Seoska	M	61	2	5	3,33	1,076	3,0	2,0	4,0
		Ž	57	2	5	3,46	1,053	3,0	3,0	4,0
		Ukupno	118	2	5	3,39	1,062	3,0	2,0	4,0
	Ukupno	M	130	2	5	3,54	1,094	4,0	3,0	4,0
		Ž	120	2	5	3,42	1,034	3,0	3,0	4,0
		Ukupno	250	2	5	3,48	1,065	4,0	3,0	4,0
Internet	Gradska	M	69	2	5	3,52	1,244	3,0	2,0	5,0
		Ž	63	2	5	3,51	1,134	4,0	2,0	5,0
		Ukupno	132	2	5	3,52	1,188	3,5	2,0	5,0
	Seoska	M	61	2	5	3,70	1,145	4,0	3,0	5,0
		Ž	57	2	5	3,53	1,054	4,0	3,0	4,0
		Ukupno	118	2	5	3,62	1,101	4,0	3,0	5,0
	Ukupno	M	130	2	5	3,61	1,198	4,0	2,0	5,0
		Ž	120	2	5	3,52	1,092	4,0	3,0	4,0
		Ukupno	250	2	5	3,56	1,147	4,0	2,0	5,0
Izrada prezentacija	Gradska	M	69	2	5	3,75	1,090	4,0	3,0	5,0
		Ž	63	2	5	3,95	1,038	4,0	3,0	5,0
		Ukupno	132	2	5	3,85	1,066	4,0	3,0	5,0
	Seoska	M	61	2	5	3,66	1,078	4,0	3,0	5,0
		Ž	57	2	5	3,56	1,118	4,0	3,0	5,0
		Ukupno	118	2	5	3,61	1,094	4,0	3,0	5,0
	Ukupno	M	130	2	5	3,71	1,082	4,0	3,0	5,0
		Ž	120	2	5	3,77	1,090	4,0	3,0	5,0
		Ukupno	250	2	5	3,74	1,084	4,0	3,0	5,0

Razlike u korist urbanih škola u prosječnim ocjenama iz odabranih tema za predmet Informatika vide se za teme: proračunske tablice (urbana 3,55; ruralna 3,45), prezentacije (urbana 3,54; ruralna 3,47), izrada mrežnih stranica (urbana 3,56; ruralna 3,39), izrada prezentacija (urbana 3,85; ruralna 3,61). Zanimljivo je primijetiti da ruralne škole ponovo u temama koje zahtijevaju kreativnost i sposobnost vizualizacije kao što su to teme prezentacije, izrada prezentacija i izrada mrežnih stranica postižu lošije prosječne ocjene, dok za temu internet, ruralne škole imaju veću prosječnu ocjenu internet (urbana 3,52; ruralna 3,62). Što se tiče teme programiranje (LOGO), situacija je izjednačena (urbana 3,42; ruralna 3,42).



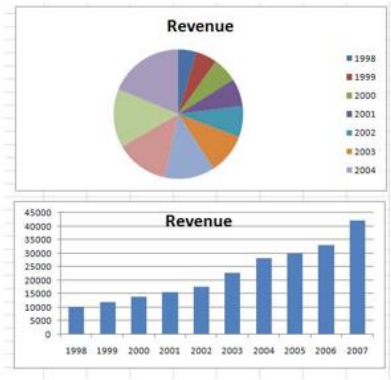
Slika 80. Primjer zadatka za temu programiranje (LOGO). Izvor: https://edutorij.e-skole.hr/share/proxy/alfresco-noauth/edutorij/api/proxy-guest/b504e46e-b7a7-4770-bcae-f6b108769a03/html/1207_Aktivnosti_za_samostalno_ucenje.html



Slika 81. Normalitet distribucije za temu programiranje (LOGO) (sedmi razred)

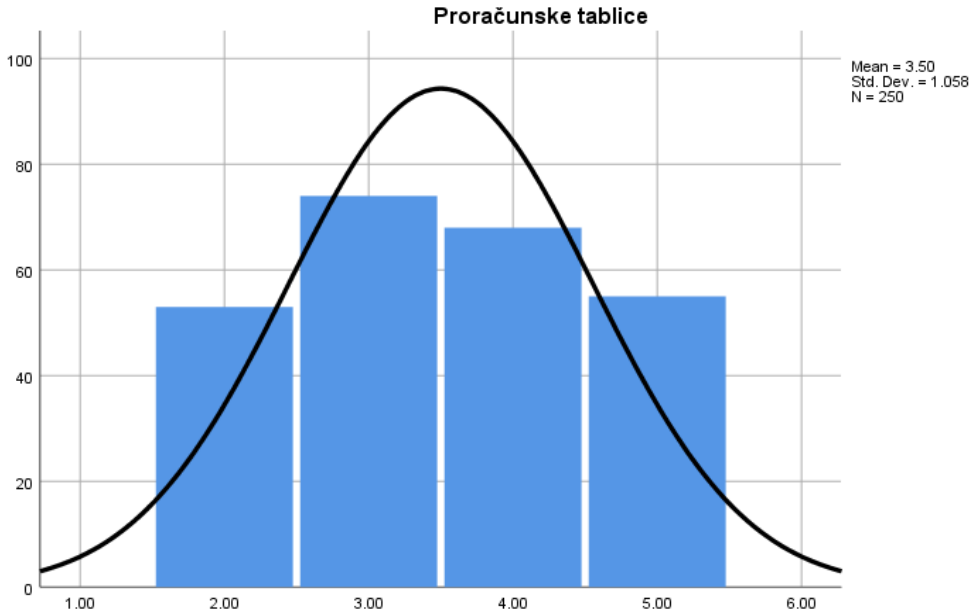
Proračunske tablice

Napravite anketu u razredu o omiljenim filmovima. Podatke ubacite u tablice u Excel te napravite stupčasti i kružni dijagram.



Slika 82. Primjer zadatka za temu proračunske tablice.

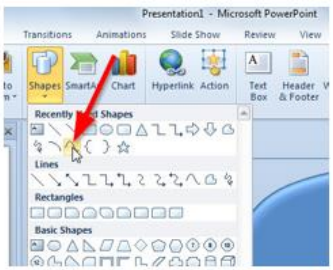
Izvor: https://www.mrexcel.com/tech-tv/excel-pie-chart-secrets/



Slika 83. Normalitet distribucije za temu proračunske tablice (sedmi razred)

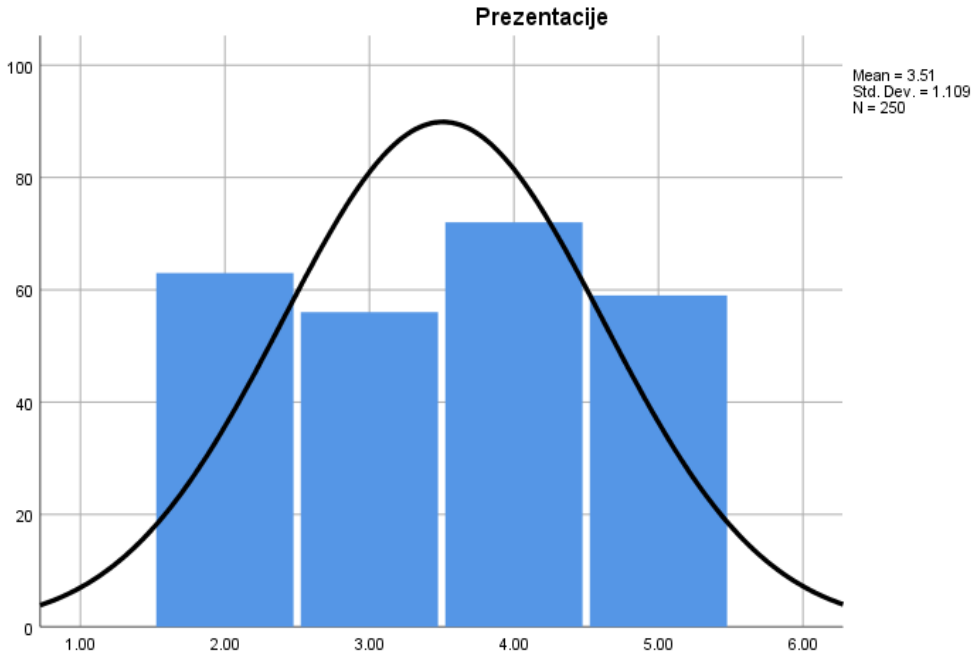
Prezentacije

Započnite novu prezentaciju i rabeći Oblike nacrtajte biciklista i bicikl. U crtanju likova koristite krug, zaobljeni pravokutnik i crte.



Slika 84. Primjer zadatka za temu prezentacije.

Izvor: https://www.free-power-point-templates.com/articles/simple-splashes-of-paint-background-in-powerpoint-using-shapes/irregular-shape-powerpoint-jpg/



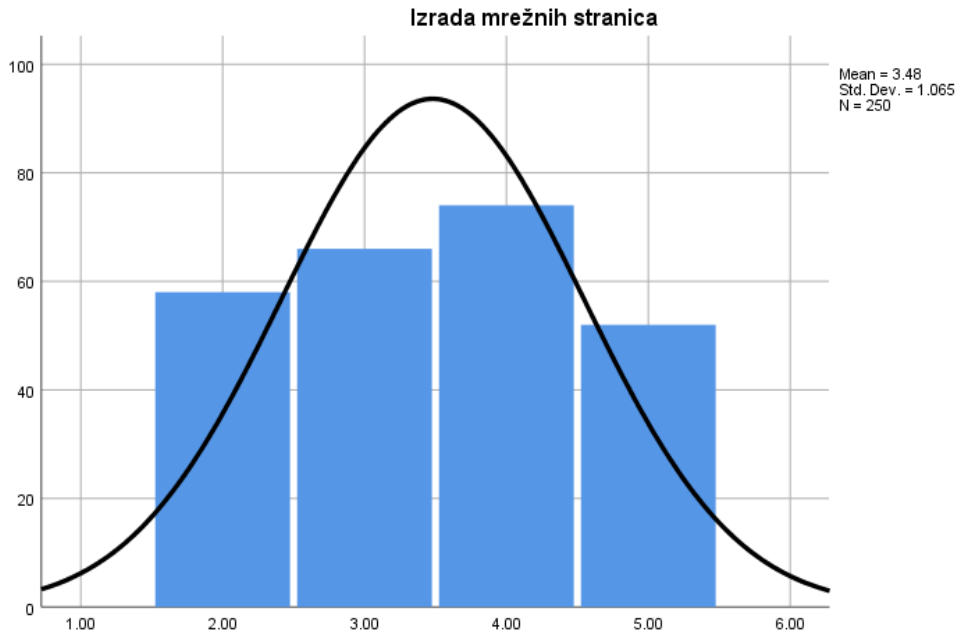
Slika 85. Normalitet distribucija za temu prezentacije (sedmi razred)

Izrada mrežnih stranica

Pokrenite Microsoft Expression Web i uredite jednu stranicu o izmišljenom sportskom klubu, dodajte i uredite tekst i nekoliko slika. U svojstvima web-stranice postavite pozadinsku boju i jezik stranice.



Slika 86. Primjer zadatka za temu izrada mrežnih stranica. Izvor: http://logos.wikia.com/wiki/File:Expression_Web_Logo.jpg



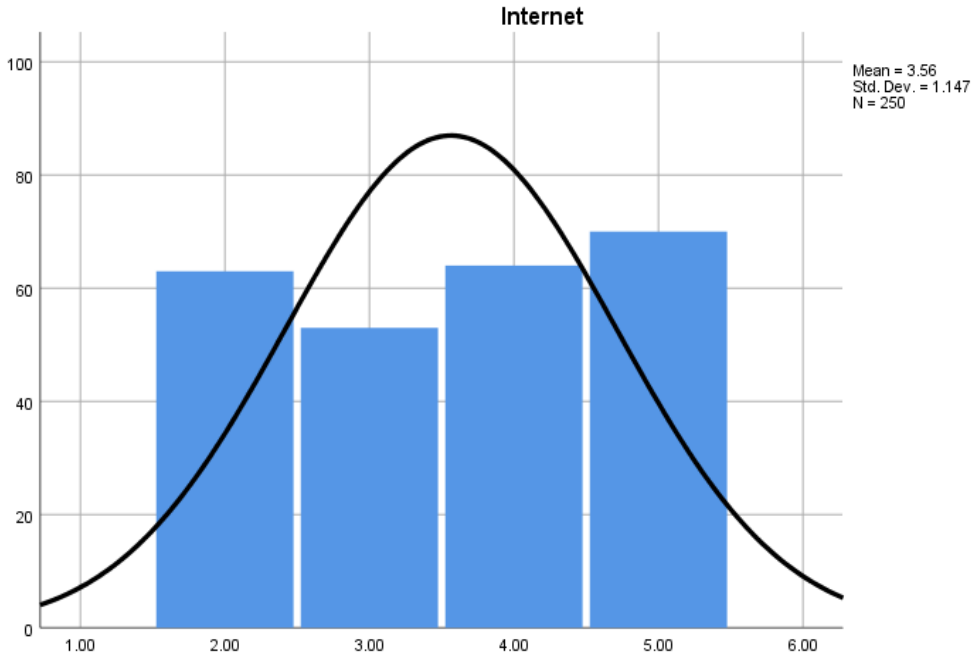
Slika 87. Normalitet distribucije za temu izrada mrežnih stranica (sedmi razred)

Internet

Objasni što je Nettiquette.



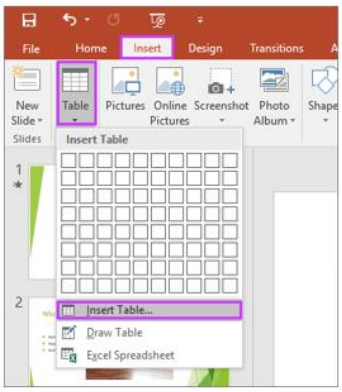
Slika 88. Primjer zadatka za temu internet. Izvor: https://elearningindustry.com/10-netiquette-tips-online-discussions



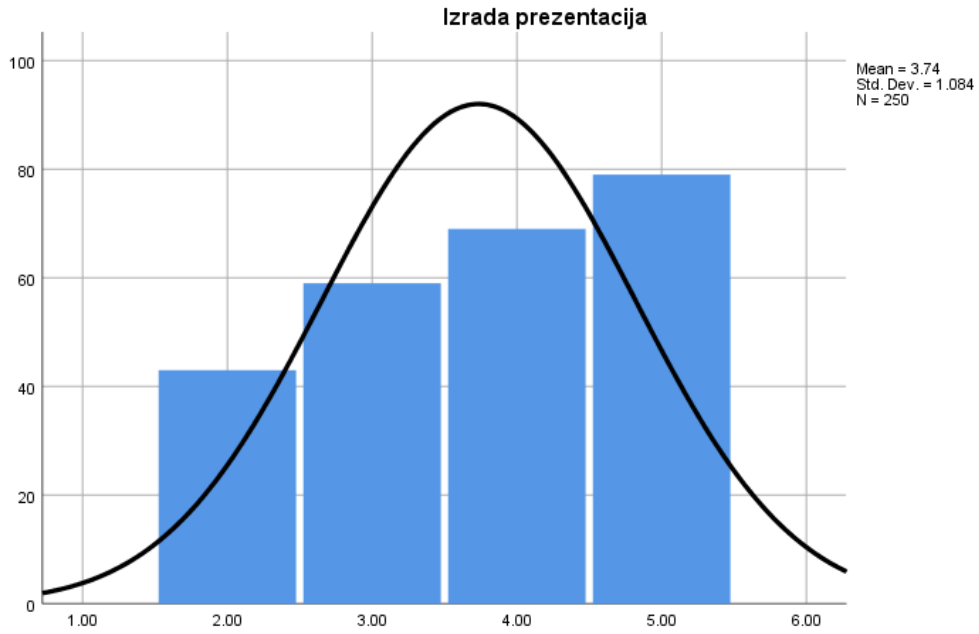
Slika 89. Normalitet distribucije za temu internet (sedmi razred)

Izrada prezentacija

Započnite novu prezentaciju o biciklističkom natjecanju i dodajte tablicu s natjecateljima i prikazom rezultata. Rezultate prikažite grafički.



Slika 90. Primjer za temu izrada prezentacija. Izvor: https://support.office.com/en-us/article/add-a-table-to-a-slide-34f106c9-5320-4b89-9129-806e64b258ac



Slika 91. Normalitet distribucije za temu izrada prezentacije (sedmi razred)

5.1.2.4 Osmi razred

Tablica 14. Deskriptivna statistika odabranih tema iz Matematike za osmi razred

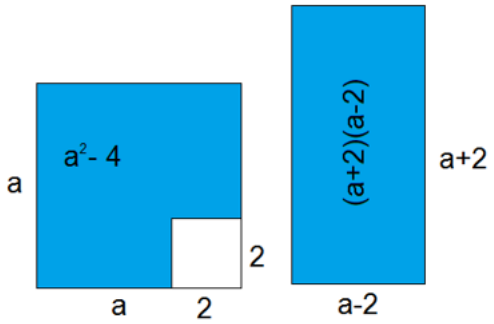
Gradivo	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
Kvadriranje i korjenovanje	Gradska	M	55	2	5	3,75	1,092	4,0	3,0	5,0
		Ž	75	2	5	3,45	1,142	4,0	2,0	4,0
		Ukupno	130	2	5	3,58	1,127	4,0	2,0	5,0
	Seoska	M	65	2	5	3,51	1,033	4,0	3,0	4,0
		Ž	55	2	5	3,42	1,100	3,0	2,0	4,0
		Ukupno	120	2	5	3,47	1,061	3,0	3,0	4,0
	Ukupno	M	120	2	5	3,62	1,063	4,0	3,0	4,0
		Ž	130	2	5	3,44	1,121	3,0	2,0	4,0
		Ukupno	250	2	5	3,52	1,095	4,0	3,0	4,0
Pitagorin poučak	Gradska	M	55	2	5	3,56	1,032	4,0	3,0	4,0
		Ž	75	2	5	3,41	1,092	3,0	2,0	4,0
		Ukupno	130	2	5	3,48	1,065	3,0	3,0	4,0
	Seoska	M	65	2	5	3,32	1,120	3,0	2,0	4,0
		Ž	55	2	5	3,33	1,156	3,0	2,0	4,0
		Ukupno	120	2	5	3,33	1,131	3,0	2,0	4,0
	Ukupno	M	120	2	5	3,43	1,083	3,0	2,5	4,0

		Ž	130	2	5	3,38	1,116	3,0	2,0	4,0
		Ukupno	250	2	5	3,40	1,098	3,0	2,0	4,0
Realni brojevi	Gradska	M	55	2	5	3,42	1,182	3,0	2,0	5,0
		Ž	75	2	5	3,48	1,107	3,0	3,0	4,0
		Ukupno	130	2	5	3,45	1,135	3,0	2,0	5,0
	Seoska	M	65	2	5	3,46	1,288	3,0	2,0	5,0
		Ž	55	2	5	3,53	1,136	3,0	3,0	5,0
		Ukupno	120	2	5	3,49	1,216	3,0	2,0	5,0
	Ukupno	M	120	2	5	3,44	1,235	3,0	2,0	5,0
		Ž	130	2	5	3,50	1,115	3,0	3,0	5,0
		Ukupno	250	2	5	3,47	1,172	3,0	2,0	5,0
Preslikavanje ravnine	Gradska	M	55	2	5	3,42	1,117	3,0	2,0	4,0
		Ž	75	2	5	3,51	1,107	4,0	3,0	4,0
		Ukupno	130	2	5	3,47	1,108	3,0	2,0	4,0
	Seoska	M	65	2	5	3,37	1,126	3,0	2,0	4,0
		Ž	55	2	5	3,71	1,149	4,0	3,0	5,0
		Ukupno	120	2	5	3,53	1,145	4,0	2,0	5,0
	Ukupno	M	120	2	5	3,39	1,117	3,0	2,0	4,0
		Ž	130	2	5	3,59	1,125	4,0	3,0	5,0
		Ukupno	250	2	5	3,50	1,124	4,0	2,0	4,0
Točke, pravci i ravnine u prostoru	Gradska	M	55	2	5	3,38	1,045	4,0	2,0	4,0
		Ž	75	2	5	3,53	1,082	4,0	3,0	4,0
		Ukupno	130	2	5	3,47	1,065	4,0	3,0	4,0
	Seoska	M	65	2	5	3,52	1,120	4,0	3,0	4,0
		Ž	55	2	5	3,53	1,086	4,0	3,0	4,0
		Ukupno	120	2	5	3,53	1,100	4,0	3,0	4,0
	Ukupno	M	120	2	5	3,46	1,084	4,0	2,0	4,0
		Ž	130	2	5	3,53	1,080	4,0	3,0	4,0
		Ukupno	250	2	5	3,50	1,080	4,0	3,0	4,0
Geometrijska tijela	Gradska	M	55	2	5	3,58	1,066	4,0	3,0	5,0
		Ž	75	2	5	3,63	1,136	4,0	3,0	5,0
		Ukupno	130	2	5	3,61	1,103	4,0	3,0	5,0
	Seoska	M	65	2	5	3,58	1,144	4,0	3,0	5,0
		Ž	55	2	5	3,56	1,118	4,0	3,0	5,0
		Ukupno	120	2	5	3,58	1,128	4,0	3,0	5,0
	Ukupno	M	120	2	5	3,58	1,104	4,0	3,0	5,0
		Ž	130	2	5	3,60	1,125	4,0	3,0	5,0
		Ukupno	250	2	5	3,59	1,113	4,0	3,0	5,0

Nastavne teme iz područja geometrije u kojima ruralne škole lagano zaostaju za urbanima, pronalazimo razlike u sljedećim temama: Pitagorin poučak (urbana 3,48; ruralna 3,33) i geometrijska tijela (urbana 3,61; ruralne 3,58), dok za temu točke, pravci i ravnine u prostoru nema razlike (urbane 3,53; ruralne 3,53). Zanimljivo je primijetiti da razliku u korist ruralnih škola, a odnosi se na temu iz geometrije, pronalazimo u temi preslikavanje ravnine (urbana 3,47; ruralna 3,53). U temi koja je malo egzaktnija, a to je tema realni brojevi, pronalazimo laganu razliku u korist ruralnih škola (urbana 3,45; ruralna 3,49).

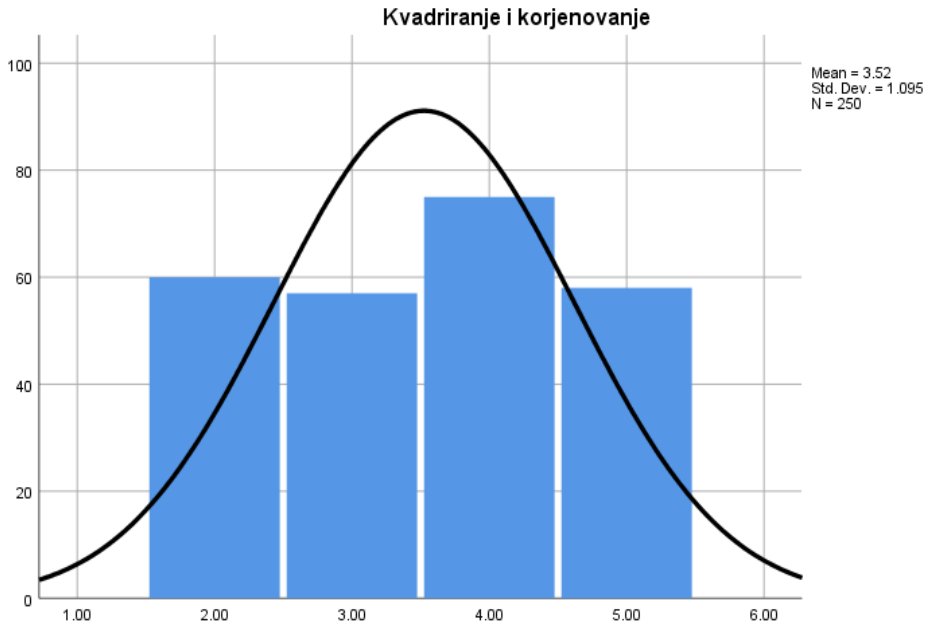
Kvadriranje i korjenovanje

Obitelj Bazenko želi na svom dvorištu izgraditi bazen. Arhitekt im je nacrtao nacrt bazena koji ima kvadratni oblik s duljinom stranice a. Mama je zaželjela da duljinu bazena produlje za 2 metra, a širinu skrate za 2 metra. Hoće li se površina bazena smanjiti ili povećati nakon ovih promjena?



Slika 92. Primjer zadatka za temu kvadriranje i korjenovanje.

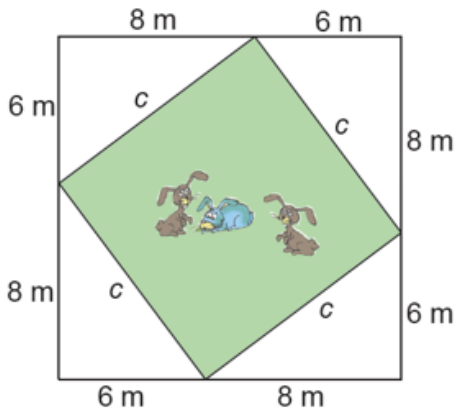
Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 8



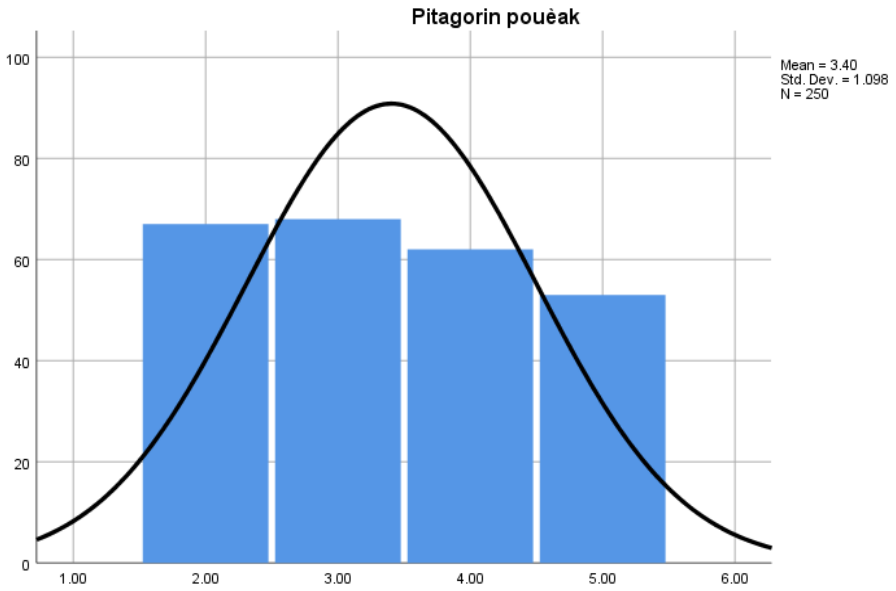
Slika 93. Normalitet distribucije za temu kvadriranje i korjenovanje (osmi razred)

Pitagorin poučak

Koliku travnatu površinu imaju na raspolaganju zečevi koji su ograđeni u vrtu kao na slici?



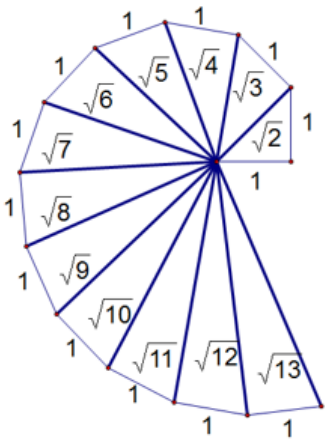
Slika 94. Primjer zadatka za temu Pitagorin poučak. Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 8



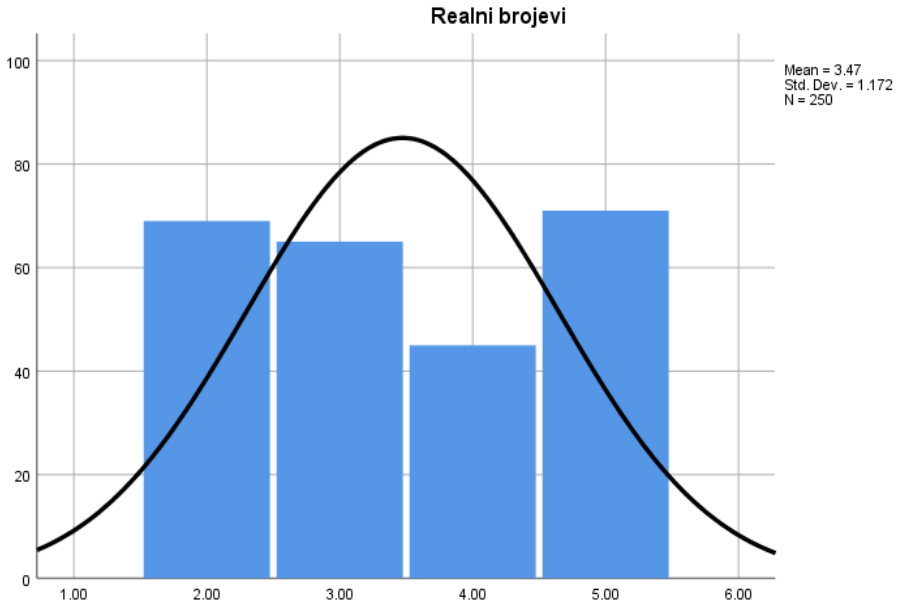
Slika 95. Normalitet distribucije za temu Pitagorin poučak (osmi razred)

Realni brojevi

Korijenska spirala



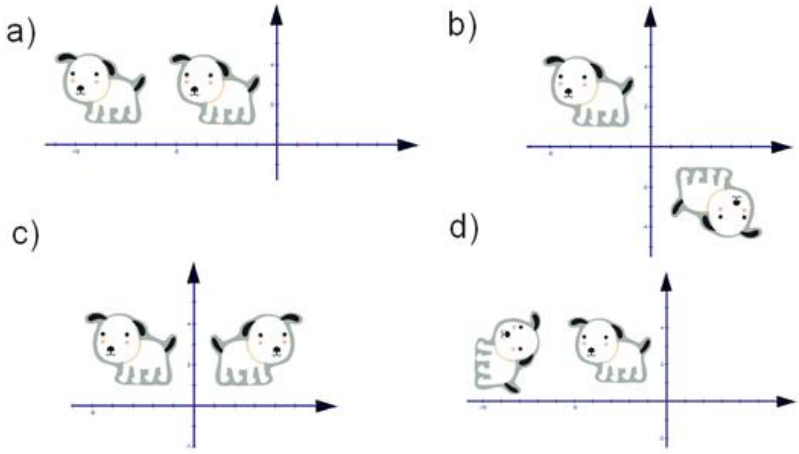
Slika 96. Primjer zadatka za temu realni brojevi. Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 8



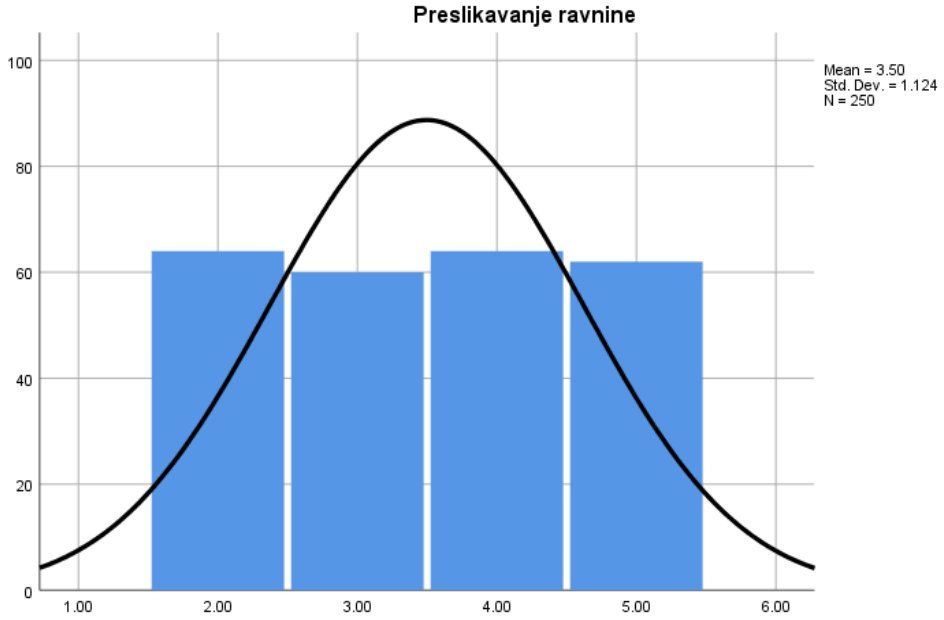
Slika 97. Normalitet distribucije za temu realni brojevi (osmi razred)

Preslikavanje ravnine

Navedi koje preslikavanje je prikazano na slici.



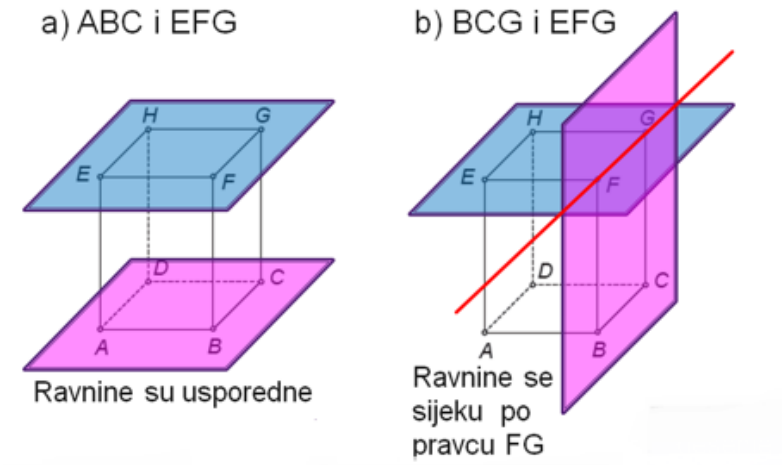
Slika 98. Primjer zadatka za temu presikavanje ravnine. Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 8



Slika 99. Normalitet distribucije za temu preslikavanje ravnine (osmi razred)

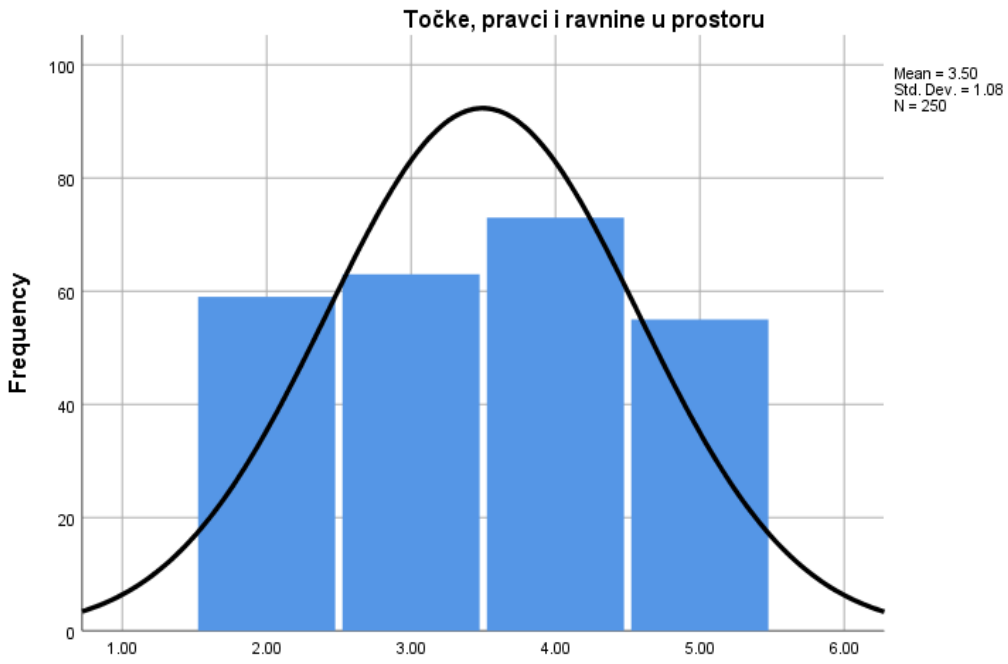
Točke, pravci i ravnine u prostoru

Nacrtaj kvadar ABCDEFGH. U kojem su međusobnom položaju ravnine:



Slika 100. Primjer zadatka za temu točke, pravci i ravnine u prostoru.

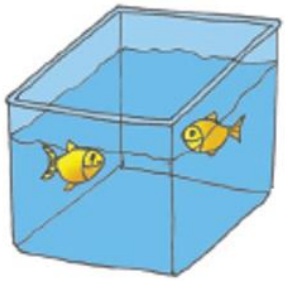
Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 8



Slika 101. Normalitet distribucije za temu točke, pravci i ravnine u prostoru (osmi razred)

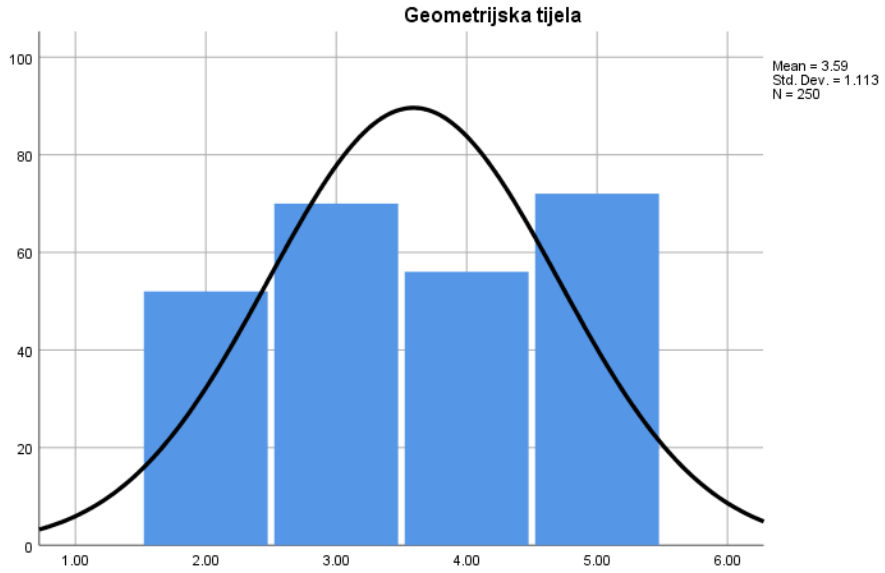
Geometrijska tijela

Gospođa Bazenko zamolila je svoga supruga da joj akvarij napuni vodom. U akvarij stane 75 l vode. Suprug je donio dvije posude pune vode. Obujam jedne posude iznosi 23 412 cm^3, a druge 51 dm^3 88 cm^3. Je li akvarij pun ako je svu donesenu vodu izlio u njega?



Slika 102. Primjer zadatka za temu geometrijska tijela.

Iz: Paić, G., Bošnjak, Ž., & Čulina, B. (2008). Matematički izazovi 8



Slika 103. Normalitet distribucije za temu geometrijska tijela (osmi razred)

Promotrimo deskriptivnu statistiku tema za isti razred za predmet Informatika.

Tablica 15. Deskriptivna statistika odabranih tema iz Informatike za osmi razred

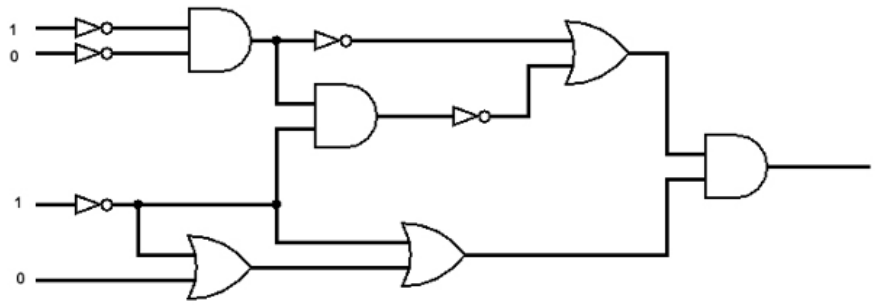
Gradivo	Škola	Spol	N	Min	Max	M	SD	C	Q1	Q3
Osnove informatike	Gradska	M	55	2	5	3,51	1,169	3,0	2,0	5,0
		Ž	75	2	5	3,61	1,184	4,0	2,0	5,0
		Ukupno	130	2	5	3,57	1,174	4,0	2,0	5,0
	Seoska	M	65	2	5	3,68	1,105	4,0	3,0	5,0
		Ž	55	2	5	3,62	1,130	4,0	3,0	5,0
		Ukupno	120	2	5	3,65	1,113	4,0	3,0	5,0
	Ukupno	M	120	2	5	3,60	1,133	4,0	3,0	5,0
		Ž	130	2	5	3,62	1,157	4,0	3,0	5,0
		Ukupno	250	2	5	3,61	1,143	4,0	3,0	5,0
Programiranje (LOGO)	Gradska	M	55	2	5	3,65	1,022	4,0	3,0	4,0
		Ž	75	2	5	3,60	1,027	4,0	3,0	4,0
		Ukupno	130	2	5	3,62	1,021	4,0	3,0	4,0
	Seoska	M	65	2	5	3,49	1,017	4,0	3,0	4,0
		Ž	55	2	5	3,56	1,085	4,0	3,0	5,0
		Ukupno	120	2	5	3,53	1,045	4,0	3,0	4,0
	Ukupno	M	120	2	5	3,57	1,019	4,0	3,0	4,0

		Ž	130	2	5	3,58	1,048	4,0	3,0	4,0
		Ukupno	250	2	5	3,58	1,032	4,0	3,0	4,0
Baze podataka	Gradska	M	55	2	5	3,56	1,050	4,0	3,0	4,0
		Ž	75	2	5	3,33	1,082	3,0	2,0	4,0
		Ukupno	130	2	5	3,43	1,071	4,0	2,0	4,0
	Seoska	M	65	2	5	3,45	1,076	3,0	3,0	4,0
		Ž	55	2	5	3,69	,940	4,0	3,0	4,0
		Ukupno	120	2	5	3,56	1,019	4,0	3,0	4,0
	Ukupno	M	120	2	5	3,50	1,061	3,5	3,0	4,0
		Ž	130	2	5	3,48	1,036	4,0	3,0	4,0
		Ukupno	250	2	5	3,49	1,046	4,0	3,0	4,0
Prezentacije	Gradska	M	55	2	5	3,56	1,050	4,0	3,0	4,0
		Ž	75	2	5	3,45	1,106	4,0	2,0	4,0
		Ukupno	130	2	5	3,50	1,080	4,0	3,0	4,0
	Seoska	M	65	2	5	3,32	1,062	3,0	2,0	4,0
		Ž	55	2	5	3,55	1,199	4,0	2,0	5,0
		Ukupno	120	2	5	3,43	1,128	3,5	2,0	4,0
	Ukupno	M	120	2	5	3,43	1,059	3,0	3,0	4,0
		Ž	130	2	5	3,49	1,143	4,0	2,0	4,0
		Ukupno	250	2	5	3,46	1,102	4,0	2,0	4,0
Internet	Gradska	M	55	2	5	3,36	1,176	3,0	2,0	4,0
		Ž	75	2	5	3,59	1,116	4,0	3,0	5,0
		Ukupno	130	2	5	3,49	1,143	4,0	2,0	4,0
	Seoska	M	65	2	5	3,46	1,032	4,0	3,0	4,0
		Ž	55	2	5	3,33	1,139	3,0	2,0	4,0
		Ukupno	120	2	5	3,40	1,080	3,0	2,0	4,0
	Ukupno	M	120	2	5	3,42	1,097	3,0	2,0	4,0
		Ž	130	2	5	3,48	1,129	4,0	2,0	4,0
		Ukupno	250	2	5	3,45	1,112	3,5	2,0	4,0
Izrada mrežnih stranica	Gradska	M	55	2	5	3,80	,989	4,0	3,0	5,0
		Ž	75	2	5	3,63	1,217	4,0	2,0	5,0
		Ukupno	130	2	5	3,70	1,125	4,0	3,0	5,0
	Seoska	M	65	2	5	3,65	1,124	4,0	3,0	5,0
		Ž	55	2	5	3,47	1,152	3,0	2,0	5,0
		Ukupno	120	2	5	3,57	1,136	4,0	2,5	5,0
	Ukupno	M	120	2	5	3,72	1,063	4,0	3,0	5,0
		Ž	130	2	5	3,56	1,188	4,0	2,0	5,0
		Ukupno	250	2	5	3,64	1,130	4,0	3,0	5,0

Razlike u korist ruralnih škola pronalazimo u sljedećim temama: osnove informatike (urbana 3,57; ruralna 3,65) i baze podataka (urbana 3,43; ruralna 3,56), dok razlike u korist urbanih škola pronalazimo u temama: programiranje (LOGO), (urbana 3,62; ruralna 3,53), prezentacije (urbana 3,50; ruralna 3,43), internet (urbana 3,49; ruralna 3,40) i izrada mrežnih stranica (urbana 3,70; ruralna 3,57). Ponovo nalazimo malo lošije prosječne rezultate za ruralne škole u temama koje zahtijevaju kreativnost i sposobnost vizualizacije, kao što su to teme prezentacije i izrada mrežnih stranica.

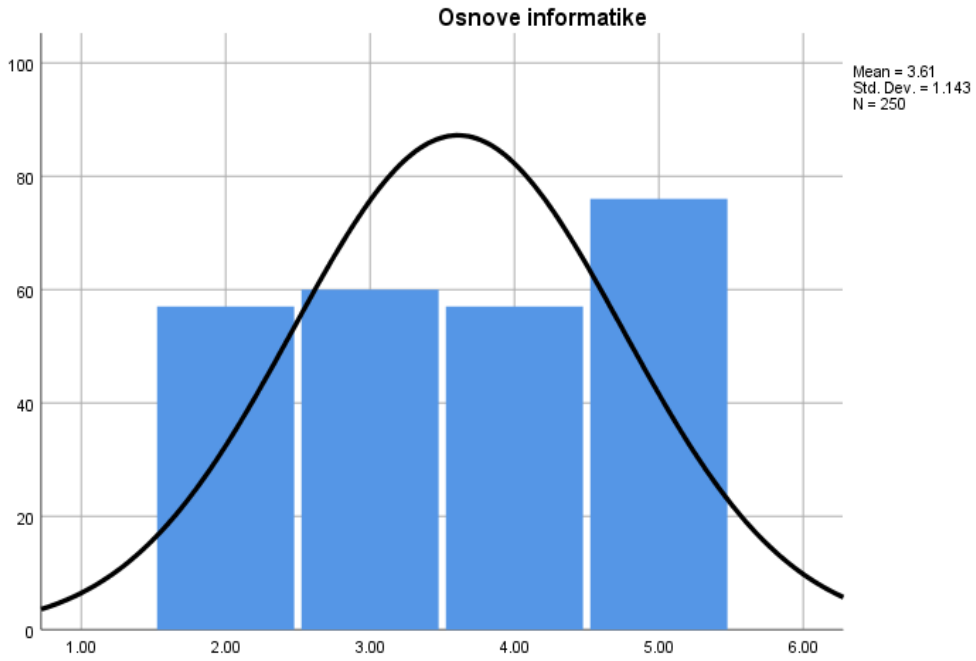
Osnove informatike

Na temelju vrijednosti ulaza prikazanog kombiniranog logičkog sklopa odredi stanje na njegovu izlazu.



Slika 104. Primjer zadatka za temu osnove informatike.

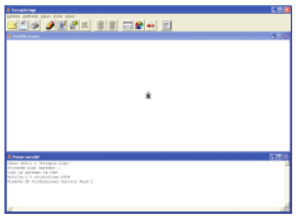
Izvor: http://os-vnazor-cepin.skole.hr/informatika/8?news_id=393



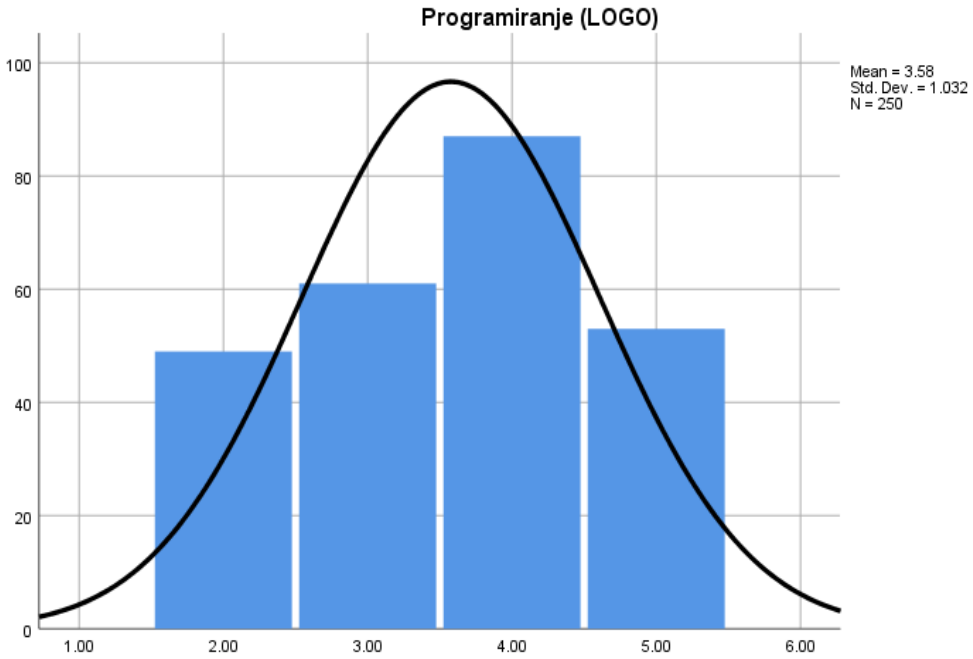
Slika 105. Normalitet distribucije za temu osnove informatike (osmi razred)

Programiranje (LOGO)

Nacrtaj spiralu u obliku kvadrata kojoj će duljina najveće stranice biti X. Duljina svake sljedeće stranice dvostruko manja, a duljina najmanje stranice spirale ne smije biti manja od 10.



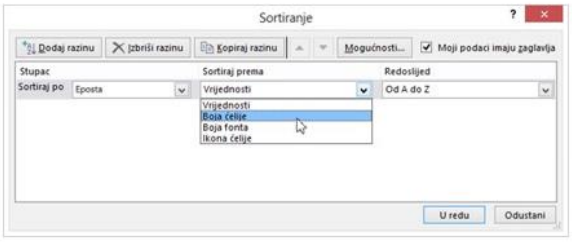
Slika 106. Primjer zadatka za temu programiranje (LOGO). Izvor: https://www.google.com/url?sa=i&rct=j&q=&esrc=s&source=images&cd=&cad=rja&uact=8&ved=2ahUKEwi3tPPzy6nfAhVR-aQKHYCWCKAQjB16BAgBEAM&url=http%3A%2F%2Fwww.udzbenici.com%2FU%2Fprof%2Fdodatno%2FTLogo_1-2_p



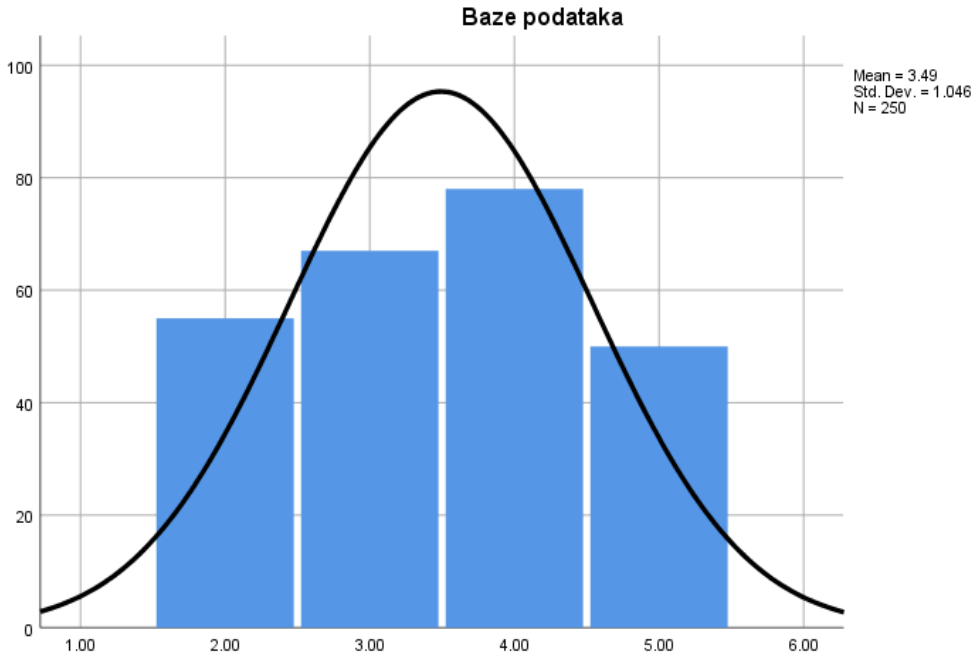
Slika 107. Normalitet distribucije za temu programiranje (LOGO) (osmi razred)

Baze podataka

Istraži pojam sortiranja te navedi nekoliko situacija iz svakodnevnog života u kojima se primjenom postupka sortiranja omogućila bolja dostupnost informacija, npr. brže pronalaženje i uočavanje potrebnih informacija, isticanje odabranih informacija itd.



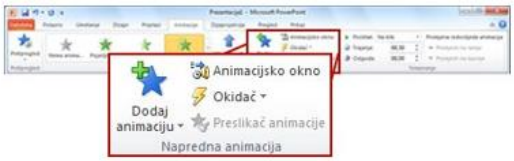
Slika 108. Primjer zadatka za temu baze podataka. Izvor: https://support.office.com/hr-hr/article/sortiranje-podataka-u-rasponu-ili-tablici-62d0b95d-2a90-4610-a6ae-2e545c4a4654



Slika 109. Normalitet distribucija za temu baze podataka (osmi razred)

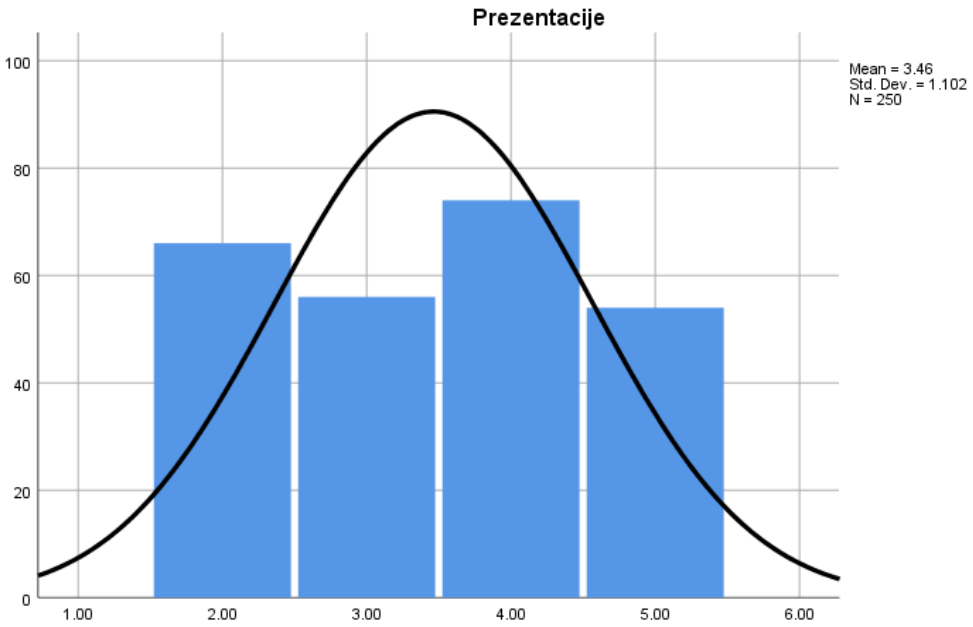
Prezentacije

Započnite novu prezentaciju te pomoću animacije napravite kratki film na temu poznatih filmskih scena.



Slika 110. Primjer zadatka za temu prezentacije.

Izvor: https://support.office.com/hr-hr/article/animacija-teksta-ili-objekata-305a1c94-83b1-4778-8df5-fcf7a9b7b7c6



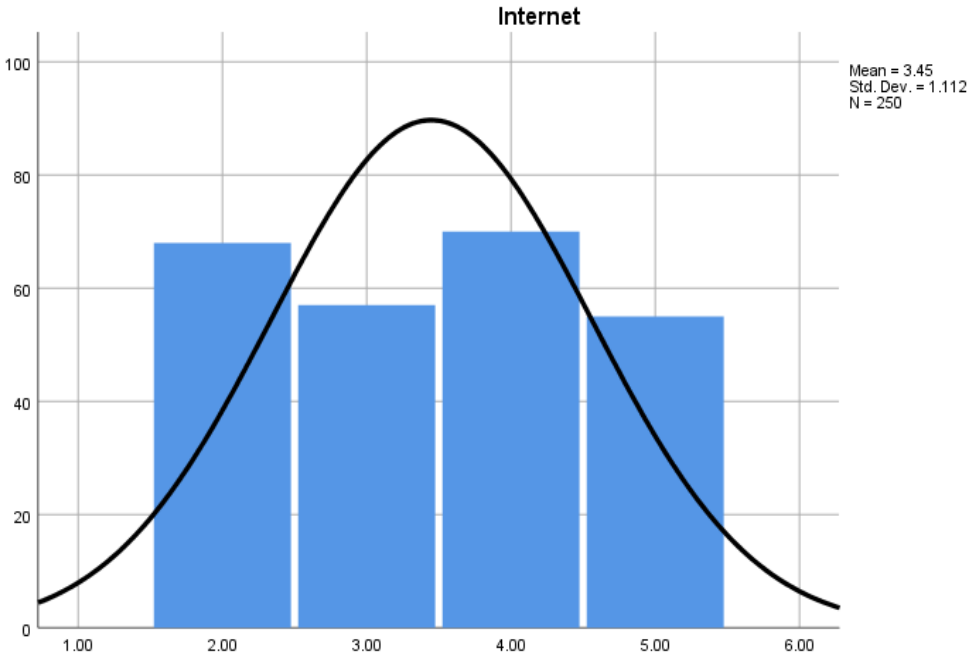
Slika 111. Normalitet distribucije za temu prezentacije (osmi razred)

Internet

Tvoje osnovnoškolsko obrazovanje bliži se kraju i sigurno već razmišljaš o izboru budućeg zanimanja. Kako bi se upisao/upisala u željenu srednju školu, potrebno je dobro upoznati sustav Upisi.hr. Istraži i prouči postupak prijave u sustav za upise, prouči korisničke upute i skupi sve potrebne informacije koristeći se dostupnim publikacijama.

Upisi.hr

Slika 112. Prijer zadatka za temu internet. Izvor: https://www.upisi.hr/upisi/



Slika 113. Normalitet distribucije za temu internet (osmi razred)

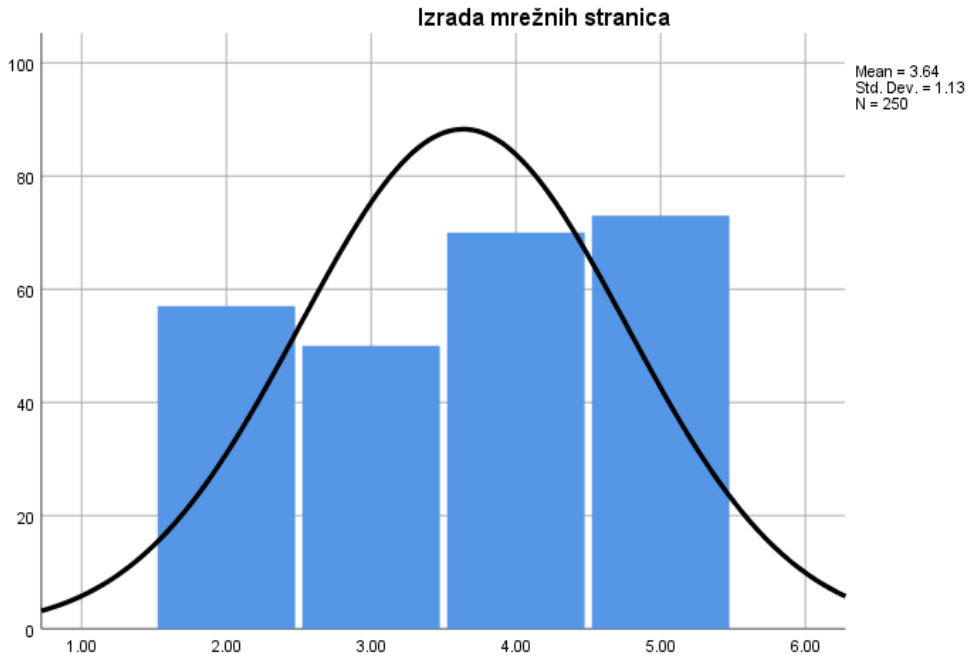
Izrada mrežnih stranica

Izradi jednostavne mrežne stranice na jednom od mrežnih servisa (WordPress, CARNet Library) na neku od predloženih tema iz područja umjetne inteligencije ili robotike.



Slika 114. Primjer zadatka za temu izrada mrežnih stranica.

Izvor: https://www.dreamhost.com/blog/wordpress-differences-beginners-guide/



Slika 115. Normalitet distribucije za temu izrada mrežnih stranica (osmi razred)

Iz analize možemo zaključiti da ruralne škole većinom imaju niže prosječne rezultate u temama koje pripadaju području geometrije (osim sedmog razreda) i temama iz Informatike koje zahtijevaju kreativnost i sposobnost vizualizacije (prezentacije, izrada prezentacija, izrada mrežnih stranica). Ruralne škole općenito postižu više rezultate na temama iz Matematike koje možemo smatrati egzaktnima (prirodni brojevi, djeljivost prirodnih brojeva, decimalni brojevi, proporcionalnost i obrnuta proporcionalnost itd.)

Pregled pojedinačnih ocjena iz određenih područja po razredima će se bolje moći analizirati nakon izračuna statistički značajne razlike u prosječnim ocjenama pojedinih područja unutar svakog razreda što će biti analizirani nakon pregleda normaliteta distribucija za sva mjerena područja.

Tablica 16. Rezultati Kolmogorov Smirnov testa pri testiranju normaliteta distribucija za sva ispitivana područja unutar Matematike i Informatike

RAZRED	PODRUČJE	N	Z
peti	Prirodni brojevi	250	2.78**
peti	Djeljivost prirodnih brojeva	250	2.83**
peti	Skupovi točaka u ravnini	250	2.96**
peti	Razlomci	250	2.88**
peti	Decimalni brojevi	250	2.96**
peti	Prvi koraci u radu s računalom	250	2.87**
peti	Spremnici računala i progr. oprema	250	2.78**
peti	Crtanje pomoću računala	250	3.16**
peti	Programiranje (LOGO)	250	2.97**
peti	Naučimo pisati	250	2.97**
peti	Internet	250	2.99**
šesti	Operacije s razlomcima	250	2.82**
šesti	Trokut	250	2.96**
šesti	Cijeli brojevi	250	2.79**
šesti	Racionalni brojevi	250	3.24**
šesti	Linearne jednadžbe s 1 nepoznanicom	250	3.34**
šesti	Četverokut	250	3.09**
šesti	Osnove informatike	250	3.00**
šesti	Programiranje (LOGO)	250	2.88**
šesti	Obrada teksta	250	2.82**
šesti	Računala u mreži	250	2.90**
šesti	Multimedija	250	3.14**
šesti	Izrada prezentacija	250	2.83**
sedmi	Koordinatni sustav	250	2.82**
sedmi	Proporcionalnost i obrnuta prop.	250	2.84**
sedmi	Sličnost i mnogokuti	250	2.91**
sedmi	Krug i kružnica	250	2.89**
sedmi	Sustavi linearnih jednadžbi	250	3.45**
sedmi	Linearna funkcija i jednadžba pravca	250	3.37**
sedmi	Programiranje (LOGO)	250	3.10**
sedmi	Proračunske tablice	250	3.00**
sedmi	Prezentacije	250	3.09**

sedmi	Izrada mrežnih stranica	250	3.03**
sedmi	Internet	250	2.91**
sedmi	Izrada prezentacija	250	3.07**
osmi	Kvadriranje i korjenovanje	250	3.16**
osmi	Pitagorin poučak	250	2.90**
osmi	Realni brojevi	250	3.04**
osmi	Preslikavanje ravnine	250	2.80**
osmi	Točke, pravci i ravnine u prostoru	250	3.03**
osmi	Geometrijska tijela	250	3.01**
osmi	Osnove informatike	250	3.04**
osmi	Programiranje (LOGO)	250	3.47**
osmi	Baze podataka	250	3.14**
osmi	Prezentacije	250	3.14**
osmi	Internet	250	3.01**
osmi	Izrada mrežnih stranica	250	3.14**

LEGENDA:

Z – vrijednost Kolmogorov Smirnov testa pri testiranju normaliteta distribucija

** – značajno uz 1% rizika

Rezultati pokazuju da se sve distribucije rezultata statistički značajno razlikuju od normalne raspodjele, no kako su distribucije vrlo nepravilne te neke od njih imaju oblik sličan U-distribuciji te bimodalnoj distribuciji, nije opravdano koristiti parametrijsku statistiku. Čak niti prikazane aritmetičke sredine nisu pravi pokazatelji stanja, a zasigurno se ne mogu računati razlike u ocjenama iz pojedinih vrsta gradiva putem jednostavne analize varijance za ponovljena mjerenja.

Stoga ćemo samo okvirno analizirati srednje vrijednosti ocjena po područjima Matematike i Informatike u pojedinim razredima.

Uočavamo da se u petom razredu dobivaju najviše ocjene u prosjeku od 3.37 do 3.68, odnosno prilično podjednake. Najniža ocjena (M = 3.37, C = 3.00, D = 2.00) iz Informatike dobiva se iz gradiva „naučimo pisati“ dok je iz Matematike najnižom prosječnom ocjenom (M

= 3.40, *C* = 3.00, *D* = 2.00) ocijenjeno gradivo „decimalni brojevi“. Također je nisku prosječnu ocjenu moguće primijetiti i kod gradiva „djeljivost prirodnih brojeva“ (*M* = 3.44, *C* = 3.00, *D* = 2.00). Najviše ocjene imaju „crtanje pomoću računala“ (*M* = 3.68, *C* = 4.00, *D* = 5.00), „Internet“ (*M* = 3.61, *C* = 4.00, *D* = 5.00) i „Spremnici računala i progr. oprema„ (*M* = 3.53, *C* = 4.00, *D* = 5.00) iz Informatike te „skupovi točaka u ravnini„ (*M* = 3.58, *C* = 4.00, *D* = 4.00) i „prirodni brojevi“ (*M* = 3.54, *C* = 4.00, *D* = 5.00) iz Matematike.

U šestom se razredu prosječne ocjene kreću u relativno uskom rasponu od 3.43 do 3.55. Najniže su prosječne ocjene u Informatici dobivene iz gradiva „računala u mreži“ (*M* = 3.45, *C* = 3.00, *D* = 2.00), a u Matematici iz „racionalnih brojeva“ (*M* = 3.43, *C* = 3.00, *D* = 3.00) i „četverokuta“ (*M* = 3.46, *C* = 3.00, *D* = 3.00). Najviše prosječne ocjene, u Informatici su iz “obrade teksta“ (*M* = 3.54, *C* = 4.00, *D* = 5.00), a u Matematici „linearne jednadžbe s jednom nepoznanicom“ (*M* = 3.55, *C* = 4.00, *D* = 4.00).

Tijekom sedmog razreda prosječne ocjene iz pojedinih gradiva kreću se od 3.42 do 3.74. Najviša je prosječna ocjena u Informatici u sedmom razredu dobivena iz „izrade prezentacija“ (*M* = 3.74, *C* = 4.00, *D* = 5.00), a u Matematici iz gradiva „proporcionalnost i obrnuta proporcionalnost“ (*M* = 3.56, *C* = 4.00, *D* = 3.00). Najniža je ocjena u Informatici postignuta kod gradiva „programiranje“ (*M* = 3.42, *C* = 3.00, *D* = 4.00), a u Matematici kod gradiva „koordinatni sustav“ (*M* = 3.49, *C* = 3.00, *D* = 3.00).

U osmom se razredu prosječne ocjene kreću od 3.40 do 3.64. Najviša je prosječna ocjena u Informatici postignuta iz „izrade mrežnih stranica“ (*M* = 3.64, *C* = 4.00, *D* = 5.00) i „osnova informatike“ (*M* = 3.61, *C* = 4.00, *D* = 5.00) a u Matematici iz gradiva „geometrijska tijela“ (*M* = 3.59, *C* = 4.00, *D* = 5.00). Najniže ocjene u Informatici u prosjeku dobiva gradivo „Internet“ (*M* = 3.45, *C* = 3.50, *D* = 4.00), a u Matematici „Pitagorin poučak“ (*M* = 3.40, *C* = 3.00, *D* = 3.00)

5.2 Povezanosti između završnih ocjena iz Informatike i Matematike

Kako bismo odgovorili na prvi problem istraživanja, odnosno, provjerili postoji li statistički značajna povezanost između završnih ocjena iz Informatike i Matematike kod učenika nakon završenih pojedinih razreda osnovne škole, izračunali smo Spearmanove koeficijente korelacije.

Napravljena je zasebna obrada za svaki od pojedinih razreda s ciljem provjere postojanja statistički značajne povezanosti između završnih ocjena iz Informatike i Matematike kod učenika nakon završenog petog, šestog, sedmog i osmog razreda osnovne škole.

U sljedećoj tablici ćemo prikazati korelacije za peti razred osnovne škole.

Tablica 17. Spearmanovi koeficijenti korelacije između završnih ocjena pojedinih predmeta u petom razredu osnovne škole

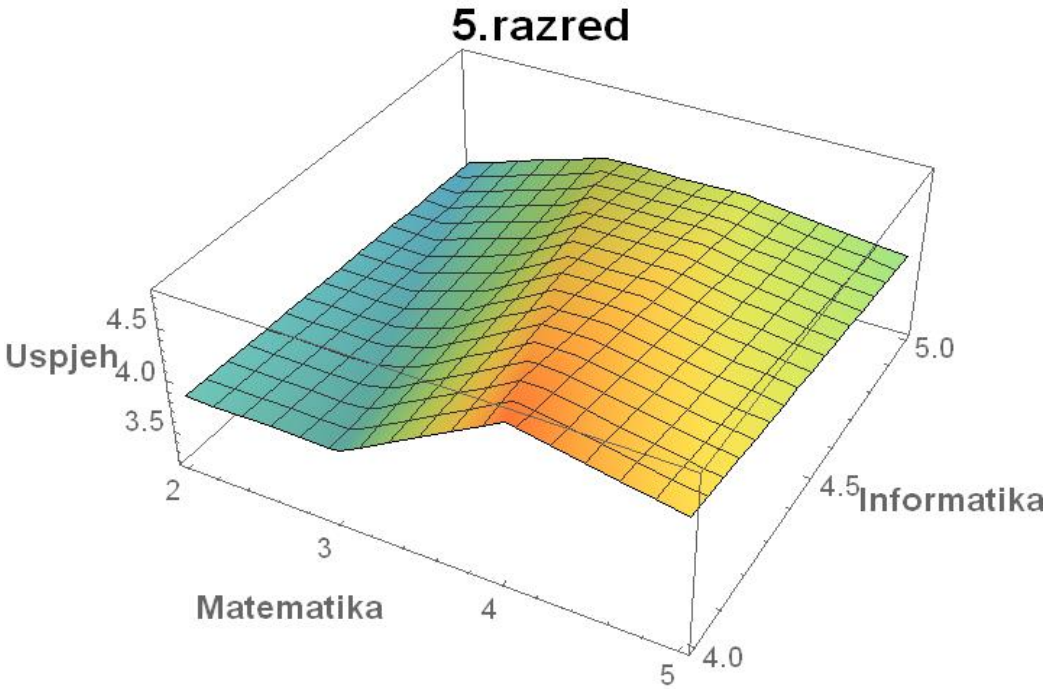
PRED	INF	OPĆI	HRV	LIK	GLA	ENG	PRI	POV	GEO	TEH	TJE	MAT
INF		0.07	-0.02	-0.02	-0.03	0.00	0.00	-0.10	-0.11	0.01	0.09	-0.03
OPĆI			0.38**	0.18**	0.10	0.39**	0.44**	0.43**	0.42**	0.31**	0.19**	0.38**
HRV				-0.04	0.03	0.03	0.12	0.02	0.00	0.05	-0.03	0.08
LIK					-0.04	0.11	0.03	0.00	0.00	0.08	-0.03	0.04
GLA						0.02	-0.01	0.01	-0.13	-0.04	-0.06	0.02
ENG							-0.04	0.06	-0.01	-0.01	0.04	-0.08
PRI								0.00	0.08	0.07	-0.03	0.07
POV									0.06	0.16**	0.02	0.05
GEO										0.09	0.05	0.07
TEH											0.09	0.05
TJE												-0.03
MAT												

LEGENDA:

** - statistički značajna razlika uz 1% rizika

H1a: Provjeriti postoji li statistički značajna povezanost između završnih ocjena iz Informatike i Matematike kod učenika nakon završenog petog razreda osnovne škole.

Hipoteza H1a za peti razred nije potvrđena, jer Spearmanove korelacije dobivene u petom razredu osnovne škole pokazuju da nema statistički značajne povezanosti u završnim ocjenama između Matematike i Informatike ($r = -0.03$; $p > 0.05$).



Slika 116. Grafički prikaz ocjena iz Matematike, Informatike te općeg uspjeha za peti razred

Što se tiče ostalih povezanosti pokazalo se da je opći uspjeh statistički značajno, uz 1% rizika, pozitivno povezan sa svim završnim ocjenama osim sa završnom ocjenom iz Informatike ($r = -0.07$; $p > 0.05$) i glazbenog odgoja ($r = -0.10$; $p > 0.05$). Odnosno, s porastom pojedinih ocjena dolazi i do porasta općeg uspjeha, osim kod Informatike i Glazbene kulture.

Od ostalih povezanosti pronađena je statistički značajna pozitivna povezanost, uz 1% rizika, u završnoj ocjeni iz Tehničke kulture i Povijesti. Ostale povezanosti nisu pronađene.

U sljedećoj su tablici prikazane korelacije za šesti razred osnovne škole.

Tablica 18. Spearmanovi koeficijenti korelacije između završnih ocjena pojedinih predmeta u šestom razredu osnovne škole

PRED	INF	OPĆI	HRV	LIK	GLA	ENG	PRI	POV	GEO	TEH	TJE	MAT
INF		0.37**	0.04	-0.04	0.01	0.09	0.18*	0.00	-0.02	0.01	-0.13	0.09
OPĆI			0.49**	0.17**	0.09	0.42**	0.42**	0.29**	0.30**	0.05	0.12	0.40**
HRV				-0.02	-0.08	0.16**	0.15	0.06	0.04	-0.13	-0.03	0.11
LIK					-0.03	0.05	0.03	-0.03	-0.07	0.10	0.09	0.04
GLA						-0.05	0.01	-0.09	0.04	0.07	0.02	-0.06
ENG							-0.03	-0.11	0.11	-0.05	-0.05	0.08
PRI								0.06	-0.13	-0.03	-0.01	0.00
POV									-0.10	-0.09	0.04	-0.02
GEO										0.01	-0.04	0.01
TEH											0.00	-0.07
TJE												0.03
MAT												

LEGENDA:

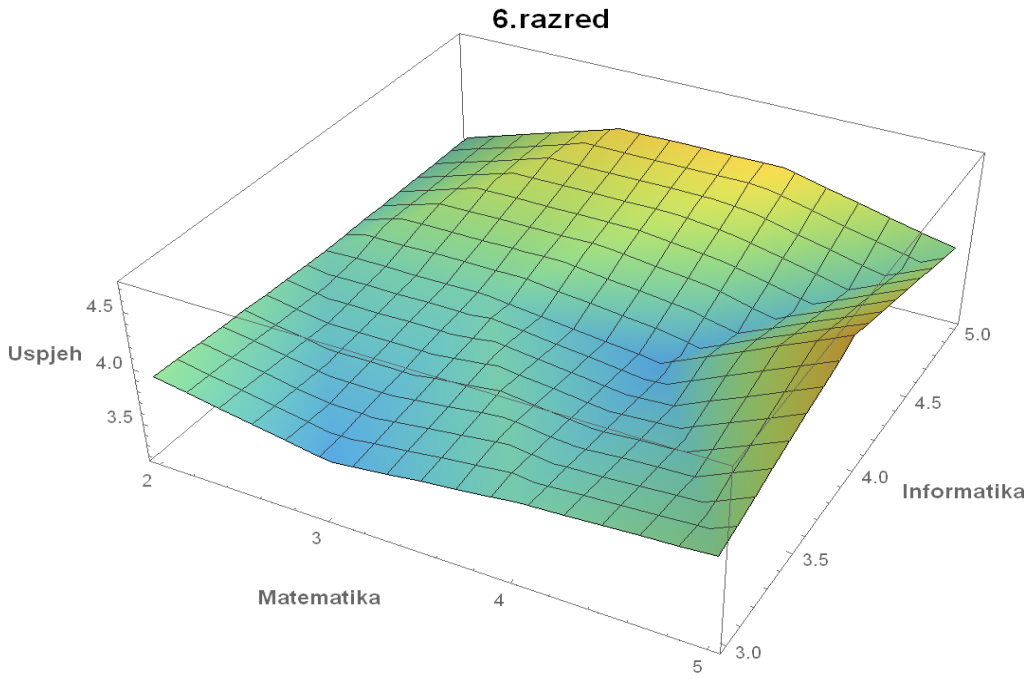
** - statistički značajna razlika uz 1% rizika

H1b: Provjeriti postoji li statistički značajna povezanost između završnih ocjena iz Informatike i Matematike kod učenika nakon završenog šestog razreda osnovne škole.

Hipoteza H1b za šesti razred nije potvrđena, jer Spearmanove korelacije dobivene u šestom razredu osnovne škole pokazuju da nema statistički značajne povezanosti u završnim ocjenama između Matematike i Informatike ($r = -0.09$; $p > 0.05$).

Što se tiče ostalih povezanosti pokazalo se da je opći uspjeh statistički značajno, uz 1% rizika, pozitivno povezan sa svim završnim ocjenama osim sa završnom ocjenom iz Tehničke kulture ($r = 0.05$; $p > 0.05$), Glazbene kulture ($r = 0.09$; $p > 0.05$) i Tjelesno – zdravstvene kulture ($r = -0.12$; $p > 0.05$). Korelacija između općeg uspjeha i završne ocjene iz Informatike iznosi ($r = 0.37$; $p < 0.01$). Dakle, s porastom pojedinih ocjena dolazi i do porasta općeg uspjeha.

Od ostalih povezanosti pronađena je statistički značajna pozitivna povezanost, uz 1% rizika, u završnoj ocjeni iz Hrvatskog jezika i Engleskog jezika. Ostale povezanosti nisu pronađene. S porastom ocjene iz Hrvatskog jezika raste i ocjena iz Engleskog jezika.



Slika 117. Grafički prikaz ocjena iz Matematike. Informatike i općeg uspjeha za šesti razred

Slijede povezanosti za sedmi razred osnovne škole.

Tablica 19. Spearmanovi koeficijenti korelacije između završnih ocjena pojedinih predmeta u sedmom razredu osnovne škole

PRED	INF	OPĆI	HRV	LIK	GLA	ENG	BIO	KEM	FIZ	POV	GEO	TEH	TJE	MAT
INF		0.17**	-0.19**	0.03	0.02	0.04	-0.04	0.00	-0.05	0.10	-0.05	-0.02	-0.10	0.09
OPĆI			0.39**	0.04	0.27**	0.30**	0.36**	0.27**	0.42**	0.38**	0.26**	0.03	0.15**	0.32**
HRV				-0.13	0.00	-0.01	0.13	0.07	0.09	0.13	0.04	-0.03	0.04	0.04
LIK					0.01	0.07	-0.01	0.03	-0.09	-0.01	-0.12	-0.08	0.02	0.00
GLA						0.07	0.08	-0.11	0.15	0.09	0.05	-0.03	0.11	0.01
ENG							-0.03	-0.09	0.00	0.02	-0.02	-0.06	-0.07	0.04
BIO								0.06	0.02	0.05	-0.08	0.04	-0.07	0.04
KEM									0.07	-0.15	-0.05	0.00	-0.04	-0.02
FIZ										0.05	0.08	-0.04	0.07	-0.09
POV											0.03	-0.06	-0.03	0.03
GEO												-0.10	0.00	0.01
TEH													0.04	0.01
TJE														0.05
MAT														

LEGENDA:

** - statistički značajna razlika uz 1% rizika

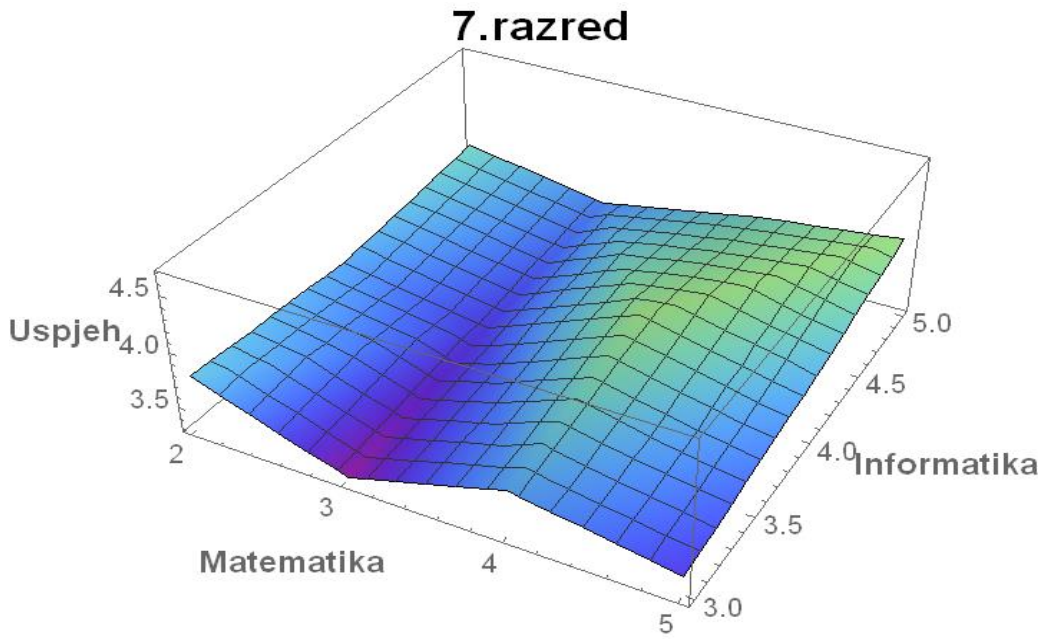
H1c: Provjeriti postoji li statistički značajna povezanost između završnih ocjena iz Informatike i Matematike kod učenika nakon završenog sedmog razreda osnovne škole.

Hipoteza H1c za sedmi razred nije potvrđena, jer Spearmanove korelacije dobivene u sedmom razredu osnovne škole pokazuju da nema statistički značajne povezanosti u završnim ocjenama između Matematike i Informatike ($r = -0.09$; $p > 0.05$).

Što se tiče ostalih povezanosti pokazalo se da je opći uspjeh statistički značajno, uz 1% rizika, pozitivno povezan sa svim završnim ocjenama osim sa završnom ocjenom iz Tehničke kulture ($r = 0.03$; $p > 0.05$) i Likovne kulture ($r = 0.04$; $p > 0.05$). Korelacija između općeg uspjeha i

završne ocjene iz Informatike iznosi ($r = 0.17$; $p < 0.01$). Dakle, s porastom pojedinih ocjena dolazi i do porasta općeg uspjeha.

Od ostalih povezanosti pronađena je statistički značajna negativna povezanost, uz 1% rizika, u završnoj ocjeni iz Hrvatskog jezika i Informatike. Ostale povezanosti nisu pronađene. S porastom ocjene iz Informatike smanjuje se ocjena iz Hrvatskog jezika.



Slika 118. Grafički prikaz ocjena iz Matematike, Informatike i općeg uspjeha za sedmi razred

Slijede povezanosti za osmi razred osnovne škole.

Tablica 20. Spearmanovi koeficijenti korelacije između završnih ocjena pojedinih predmeta u osmom razredu osnovne škole

PRED	INF	OPĆI	HRV	LIK	GLA	ENG	BIO	KEM	FIZ	POV	GEO	TEH	TJE	MAT
INF		0.29**	-0.07	-0.03	0.02	0.09	0.01	-0.06	0.04	0.08	0.04	0.00	0.06	0.05
OPĆI			0.46**	0.12	0.06	0.41**	0.20**	0.30**	0.27**	0.27**	0.30**	0.14	0.10	0.37**
HRV				0.05	-0.10	0.17**	0.07	0.06	0.06	-0.05	0.02	0.07	0.08	0.07
LIK					0.05	-0.05	-0.04	-0.07	0.06	0.07	-0.09	-0.07	-0.03	0.00
GLA						-0.06	-0.08	-0.04	-0.01	-0.02	0.07	-0.03	-0.14	-0.04
ENG							-0.11	-0.06	0.00	-0.02	0.09	-0.09	-0.05	0.16**
BIO								-0.01	-0.07	0.01	-0.01	0.03	0.00	-0.09
KEM									-0.03	-0.03	0.00	0.11	0.04	0.03
FIZ										0.01	-0.06	-0.08	0.02	-0.06
POV											-0.08	-0.04	-0.05	0.03
GEO												0.05	-0.14	0.01
TEH													-0.05	-0.05
TJE														0.00
MAT														

LEGENDA:

** - statistički značajna razlika uz 1% rizika

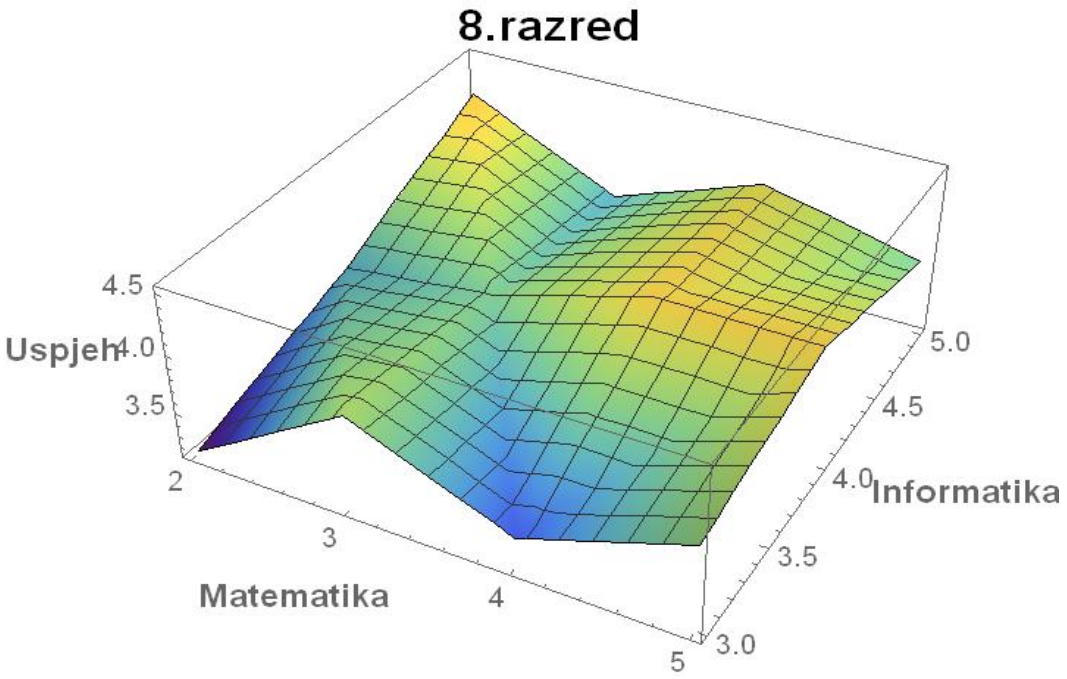
H1d: Provjeriti postoji li statistički značajna povezanost između završnih ocjena iz Informatike i Matematike kod učenika nakon završenog osmog razreda osnovne škole.

Hipoteza H1d za osmi razred nije potvrđena, jer Spearmanove korelacije dobivene u osmom razredu osnovne škole pokazuju da nema statistički značajne povezanosti u završnim ocjenama između Matematike i Informatike ($r = -0.05$; $p > 0.05$).

Što se tiče ostalih povezanosti, pokazalo se da je opći uspjeh statistički značajno, uz 1% rizika, pozitivno povezan sa svim završnim ocjenama osim sa završnom ocjenom iz Glazbene kulture ($r = 0.06$; $p > 0.05$), Tjelesno-zdravstvene kulture ($r = 0.10$; $p > 0.05$), Likovne kulture ($r = 0.12$; $p > 0.05$) i Tehničke kulture ($r = 0.14$; $p > 0.05$). Korelacija između općeg

uspjeha i završne ocjene iz Informatike iznosi (r = 0.29; p < 0.01). Dakle, s porastom pojedinih ocjena dolazi i do porasta općeg uspjeha.

Od ostalih povezanosti pronađena je statistički značajna pozitivna povezanost, uz 1% rizika, u završnoj ocjeni iz Engleskog jezika i Hrvatskog jezika te Matematike. Ostale povezanosti nisu pronađene. S porastom ocjene iz Engleskog jezika rastu i ocjene iz Hrvatskog jezika te Matematike.



Slika 119. Grafički prikaz ocjena iz Matematike, Informatike i općeg uspjeha za osmi razred

Kako **hipoteze nisu potvrđene**, a i inače nisu dobivene pojedinačne korelacije među predmetima svi razredi su spojeni zajedno i napravljena je skupna analiza gdje smo proučavali povezanosti između završnih ocjena na svih 1 000 sudionika (osim kod Prirode, Kemije, Fizike i Biologije na 500 sudionika s obzirom na to što su ti nastavni predmeti prisutni samo u dvama razredima osnovne škole). Dobiveni su rezultati prikazani u sljedećoj tablici.

Tablica 21. Spearmanovi koeficijenti korelacije između završnih ocjena pojedinih predmeta u višim razredima osnovne škole

PRED	INF	OPĆI	HRV	LIK	GLA	ENG	PRI	BIO	KEM	FIZ	POV	GEO	TEH	TJE	MAT
INF		0.28**	-0.02	-0.03	0.00	0.05	0.09	-0.02	-0.04	-0.01	0.04	-0.02	-0.01	-0.03	0.05
OPĆI			0.45**	0.12**	0.13**	0.37**	0.43**	0.28**	0.29**	0.34**	0.34**	0.31**	0.12**	0.13**	0.36**
HRV				-0.04	-0.04	0.09**	0.14**	0.10	0.07	0.07	0.05	0.02	-0.01	0.01	0.08**
LIK					0.00	0.04	0.03	-0.03	-0.02	-0.02	0.01	-0.07	0.01	0.01	0.02
GLA						0.00	0.00	0.00	-0.07	0.07	-0.01	0.01	-0.01	-0.02	-0.02
ENG							-0.03	-0.07	-0.07	0.00	-0.01	0.03	-0.06	-0.03	0.06
PRI											0.03	-0.02	0.02	-0.02	0.03
BIO									0.03	-0.02	0.03	-0.05	0.03	-0.03	-0.03
KEM										0.03	-0.08	-0.03	0.05	0.00	0.00
FIZ											0.03	0.01	-0.06	0.05	-0.07
POV												-0.02	-0.01	0.00	0.01
GEO													0.01	-0.03	0.02
TEH														0.02	-0.02
TJE															0.01
MAT															

LEGENDA:

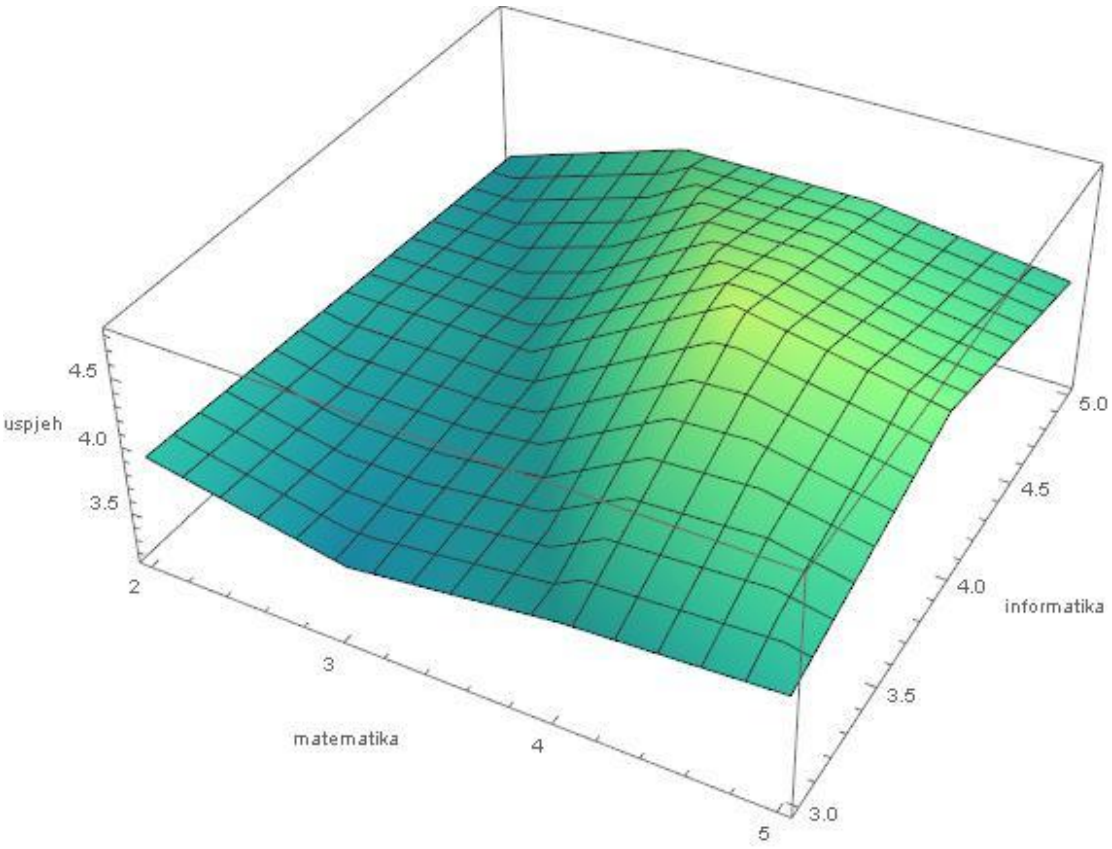
** - statistički značajna razlika uz 1% rizika

I ovdje Spearmanove korelacije pokazuju da nema statistički značajne povezanosti u završnim ocjenama između Matematike i Informatike ($r = -0.05$; $p > 0.05$).

Što se tiče ostalih povezanosti, pokazalo se da je opći uspjeh statistički značajno, uz 1% rizika, pozitivno povezan sa svim završnim ocjenama. Korelacija između općeg uspjeha i završne ocjene iz Informatike iznosi ($r = 0.28$; $p < 0.01$). Dakle, s porastom pojedinih ocjena dolazi i do porasta općeg uspjeha.

Od ostalih povezanosti pronađena je statistički značajna pozitivna povezanost, uz 1% rizika, u završnoj ocjeni iz Hrvatskog jezika i Prirode, Engleskog jezika te Matematike. Ostale

povezanosti nisu pronađene. S porastom ocjene iz Hrvatskog jezika rastu i ocjene iz Prirode, Engleskog jezika te Matematike.



Slika 120. Grafički prikaz ocjena iz Matematike, Informatike i općeg uspjeha za sve više razrede

5.3 Povezanosti između završnih ocjena pojedinih gradiva Informatike i Matematike

Kako bismo odgovorili na drugi problem istraživanja odnosno provjerili postoji li statistički značajna povezanost između završnih ocjena pojedinih tema iz Informatike i Matematike kod učenika nakon završenih pojedinih razreda osnovne škole izračunali smo Spearmanove koeficijente korelacije.

H2a: Provjeriti postoji li statistički značajna povezanost između ocjena pojedinih tema iz Informatike i Matematike kod učenika nakon završenog petog razreda osnovne škole.

U petom razredu osnovne škole pronađena je jedna pozitivna, iako ne baš visoka, povezanost i to između ocjene iz crtanja pomoću računala i ocjene iz prirodnih brojeva ($r = 0.16$; $p<0.01$) odnosno s porastom ocjene iz crtanja pomoću računala raste i ocjena iz prirodnih brojeva.

H2b: Provjeriti postoji li statistički značajna povezanost između ocjena pojedinih tema iz Informatike i Matematike kod učenika nakon završenog šestog razreda osnovne škole.

U šestom je razredu pronađena jedna mala, ali negativna, korelacija i to između ocjene iz obrade teksta i linearne jednadžbe s jednom nepoznanicom ($r = -0.17$; $p < 0.01$), odnosno, s porastom ocjene iz obrade teksta pada ocjena iz linearnih jednadžbi s jednom nepoznanicom.

H2c: Provjeriti postoji li statistički značajna povezanost između ocjena pojedinih tema iz Informatike i Matematike kod učenika nakon završenog sedmog razreda osnovne škole.

H2d: Provjeriti postoji li statistički značajna povezanost između ocjena pojedinih tema iz Informatike i Matematike kod učenika nakon završenog osmog razreda osnovne škole.

U sedmom i osmom razredu nije pronađena niti jedna značajna povezanost u ocjenama iz pojedinih tema Matematike i Informatike.

H2: Provjeriti postoji li statistički značajna povezanost između ocjena pojedinih tema iz Informatike i Matematike kod učenika nakon završenih pojedinih razreda osnovne škole.

Ovime **nismo potvrdili hipotezu** o postojanju statistički značajne pozitivne povezanosti ocjena pojedinih tema između Informatike i Matematike u svim višim razredima osnovne škole, odnosno, da s povećanjem ocjene u temama iz Matematike raste i ocjena u temama iz Informatike (kao i obrnuto).

5.4 Povezanosti između završnih ocjena iz Informatike i Matematike u odnosu na povezanost završnih ocjena iz Matematike i ostalih predmeta

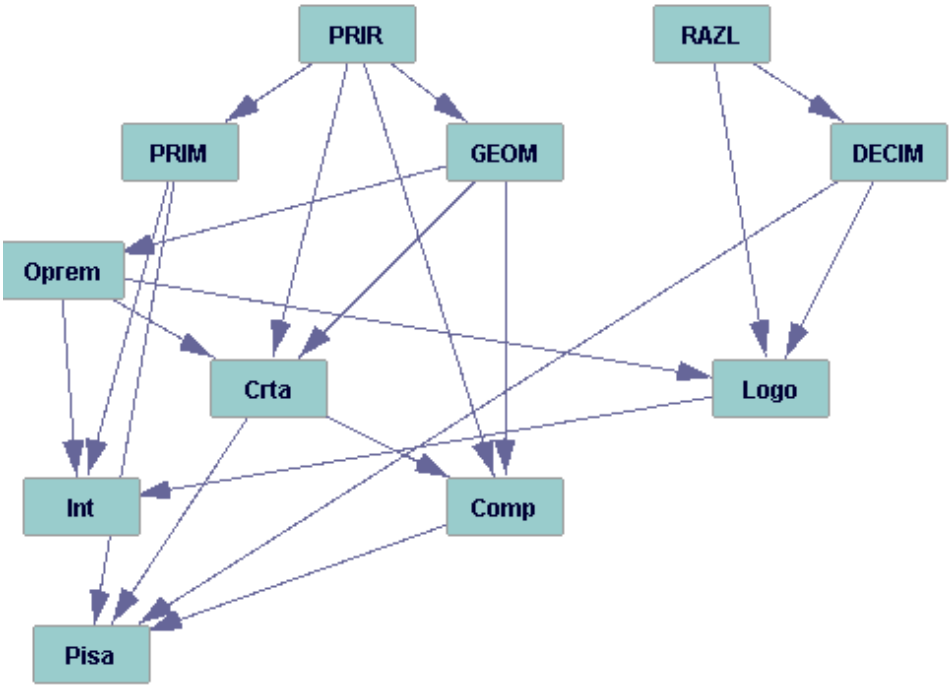
H3: Provjeriti postoji li statistički značajna razlika u povezanosti između završne ocjene iz Matematike i Informatike te povezanosti između završne ocjene iz Matematike i završne ocjene iz ostalih predmeta te općeg uspjeha nakon završenih pojedinih razreda osnovne škole.

Kako nismo potvrdili postojanje povezanosti između završnih ocjena Informatike i Matematike jasno je da **nismo potvrdili** niti **treću hipotezu** našeg istraživanja da je povezanost u završnoj ocjeni iz Matematike i Informatike statistički značajno veća od povezanosti između završne ocjene iz Matematike i završne ocjene iz ostalih predmeta te općeg uspjeha.

5.5 Kauzalna povezanost obrazovnih postignuća učenika viših razreda osnovne škole

U svrhu propitivanja kauzalnih povezanosti koristili smo software Tetrad, koji stvara, procjenjuje, predviđa te traži kauzalne i statističke modele. Tetrad je freeware te ima jednostavno sučelje koje nudi sve funkcije i alate koji su potrebni za propitivanje kauzalnosti. Software je napravljen na Sveučilištu Carnegie Mellon, Odjel za filozofiju u Pittsburghu, SAD (http://www.phil.cmu.edu/tetrad/index.html).

5.5.1 Peti razred



Matematika		Informatika	
PRIR	prirodni brojevi	Comp	prvi koraci u radu s računalom
PRIM	djeljivost prirodnih brojeva	Oprem	spremnici računala i programska oprema
GEOM	skupovi točaka u ravnini	Crta	crtanje pomoću računala
RAZL	razlomci	Logo	programiranje (LOGO)
DECI	decimalni brojevi	Pisa	naučimo pisati
		Int	internet

Slika 121. Kauzalne povezanosti između odabranih tema iz Matematike i informatike u petom razredu

Mjerene kompetencije su nakon analize u Tetradu podijeljene na šest razina, kao što je prikazano prethodnom slikom.

Na prvoj su se razini nalazile kompetencije:

- Prirodni brojevi (Matematika)
- Razlomci (Matematika)

Druga razina:

- Djeljivost prirodnih brojeva (Matematika)
- Decimalni brojevi (Matematika)
- Skupovi točaka u ravnini (Matematika)

Treća razina:

- Spremnici računala i programska oprema (Informatika)

Četvrta razina:

- Crtanje pomoću računala (Informatika)
- Programiranje (LOGO) (Informatika)

Peta razina:

- Prvi koraci u radu s računalom (Informatika)
- Internet (Informatika)

Šesta razina:

- Naučimo pisati (Informatika)

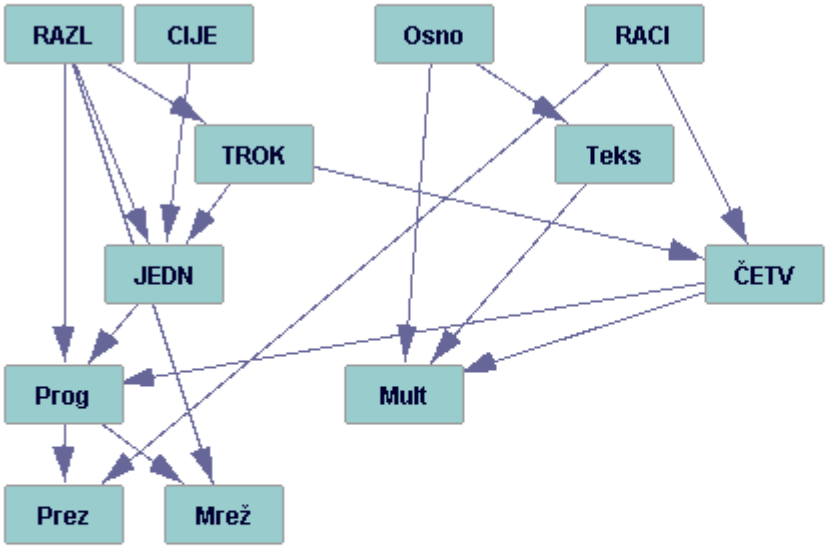
Promotrimo kauzalnu povezanost između tema razlomci, decimalni brojevi te programiranje (LOGO). Tema razlomci, koja se nalazi na prvoj razini, kauzalno povlači temu decimalni brojevi (druga razina), koja se i u planu i programu obrađuje tim redoslijedom (razlomci: teme 25-28, decimalni brojevi: teme 28-36). Tema programiranje (LOGO), koja se nalazi na četvrtoj razini, se međutim obrađuje puno ranije, tijekom teme 14. Jer je pronađena kauzalna povezanost između tema razlomci i programiranje, te između tema decimalni brojevi i programiranje, zaključujemo da je tema programiranje prerano obrađivana u programu.

Tema prirodni brojevi se obrađuje na samome početku petog razreda (1-9) pa je kauzalna povezanost između tema prirodni brojevi koja se nalazi na prvoj razini te teme skupovi točaka u ravnini (17-24) koja se nalazi na drugoj razini razumljiva. Slična je situacija i s temama prirodni brojevi (1-9) i djeljivost prirodnih brojeva (10-16), koja se nalazi na drugoj razini. No dođemo li do kauzalne povezanosti između tema skupovi točaka u ravnini, crtanje pomoću

računala, spremnici računala i programska oprema te prvi koraci u radu s računalom situacija se mijenja. Kauzalna povezanost između tema prirodni brojevi i crtanje pomoću računala je razumljiva, jer se navedena informatička tema obrađuje puno kasnije (9-13) od teme prirodni brojevi, koja se obrađuje na samome početku školske godine. No teme skupovi točaka u ravnini (17-24) i crtanje pomoću računala (9-13) obrađuju se otprilike u slično vrijeme, što naravno uvelike ovisi o zaostacima u gradivu te ostalim faktorima. Bez obzira na stvarnu situaciju, opišimo redoslijed obrade navedenih tema upitnim. Nastavimo s temama skupovi točaka u ravnini, koja se nalazi na drugoj razini, te prvi koraci u radu s računalom. Tema prvi koraci u radu s računalom se obrađuje na samome početku školske godine, dok tema skupovi točaka u ravnini dolazi puno kasnije. Pronađena kauzalna povezanost u obrnutom smjeru, tj. da kompetencije u temi skupovi točaka u ravnini kauzalno povlače kompetencije u temi prvi koraci u radu s računalom implicira na pogrešni poredak u obrađivanim temama. Sličnu, iako ne tako drastičnu, situaciju pronalazimo kod kauzalne povezanosti između tema skupovi točaka u ravnini te spremnici računala i programska oprema, koja tema se obrađuje odmah nakon teme prvi koraci u radu s računalom (5-8). Pronađena kauzalna povezanost u obrnutom smjeru, tj. da kompetencije u temi skupovi točaka u ravnini, koja se nalazi na drugoj razini, kauzalno povlače kompetencije u temi spremnici računala i programska oprema, koja se nalazi na trećoj razini, implicira pogrešni poredak u obrađivanim temama.

Kauzalne povezanosti između tema djeljivost prirodnih brojeva i internet, spremnici računala i programska oprema te crtanje pomoću računala, spremnici računala i programska oprema i internet su potpuno jasne, ako ih usporedimo s poretkom u kojem su prema programu obrađivane te time zaključujemo da je poredak potpuno opravdan. Slična je situacija i s povezanostima spremnici računala i programska oprema -> programiranje te programiranje -> internet. Sve navedene teme se prema programu obrađuju redoslijedom u kojem su i pronađene kauzalne povezanosti. Situaciju s temom naučimo pisati, koja se nalazi na šestoj razini, nije nužno niti analizirati. Ova tema se obrađuje odmah prije teme internet, te sve teme koje impliciraju kauzalnu povezanost s temom naučimo pisati opravdavaju redoslijed obrade u nastavnom programu.

5.5.2 Šesti razred



Matematika		Informatika	
RAZL	operacije s razlomcima	Osno	osnove informatike
TROK	trokut	Prog	programiranje (LOGO)
CIJE	cijeli brojevi	Teks	obrada teksta
RACI	racionalni brojevi	Mrež	računala u mreži
JEDN	linearne jednadžbe s jednom nepoznanicom	Mult	multimedija
ČETV	četverokut	Prez	izrada prezentacija

Slika 122. Kauzalne povezanosti između odabranih tema iz Matematike i informatike u šestom razredu

Mjerene kompetencije u odabranim temama podijeljene su na pet razina. Na prvoj su se razini nalazile sljedeće teme:

- Operacije s razlomcima (Matematika)
- Cijeli brojevi (Matematika)
- Osnove informatike (Informatika)
- Racionalni brojevi (Matematika)

Druga razina:

- Trokut (Matematika)
- Obrada teksta (Informatika)

Treća razina:

- Linearne jednadžbe s jednom nepoznanicom (Matematika)
- Četverokut (Matematika)

Četvrta razina:

- Programiranje (Informatika)
- Multimedija (Informatika)

Peta razina:

- Izrada prezentacija (Informatika)
- Računala u mreži (Informatika)

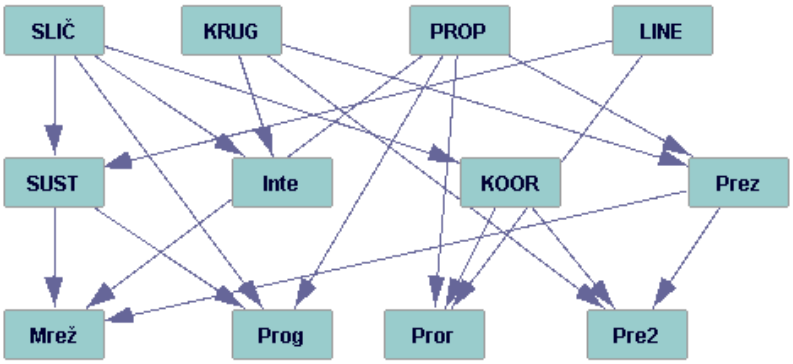
Započnimo razmatranje s kauzalnim povezanostima: operacije s razlomcima (prva razina) -> linearne jednadžbe s jednom nepoznanicom (treća razina), operacije s razlomcima (prva razina) -> trokut (druga razina), operacije s razlomcima (prva razina) -> programiranje (četvrta razina) i cijeli brojevi (prva razina) -> linearne jednadžbe s jednom nepoznanicom (treća razina). Jer se operacije s razlomcima kao tema obrađuju na samome početku školske godine, sve navedene kauzalne povezanosti između matematičkih tema koje proizlaze iz te teme opravdavaju poredak u kojem se obrađuju one teme koje su implicirane. Što se tiče povezanosti operacije s razlomcima -> programiranje, ta se tema obrađuje kao treća po redu pa se, opet ovisno o organizacijskim faktorima, ona nadovezuje na matematičku temu operacije s razlomcima.

Zadnje dvije teme koje pronalazimo na prvoj razini su osnove informatike i racionalni brojevi. Kauzalne povezanosti tema osnove informatike (1-2) -> multimedija (13-18) te osnove informatike -> obrada teksta (7-9) prilično su jasne. Slično je i s povezanosti u matematičkom sadržaju, racionalni brojevi (25-29) -> četverokut (32-35). No s kauzalnom povezanosti četverokut (32-35) -> multimedija (13-18) situacija je malo drugačija. Četverokut kao tema se obrađuje na samome kraju školske godine dok multimedija prethodi temi izrada prezentacija. Pošto je kauzalna povezanost usmjerena od teme četverokut prema temi multimedija, možemo zaključiti da je njihov poredak u nastavnom programu upitan. Dodajmo još samo

povezanost trokut (druga razina) -> četverokut (treća razina). Po nastavnom planu se trokut kao tema obrađuje puno prije teme četverokut pa njihova kauzalna povezanost ima smisla.

Na kraju, navedimo kauzalne povezanosti koje su prilično jasne kada se usporede s poretkom u kojem se teme obrađuju prema nastavnom programu: operacije s razlomcima (prva razina) -> računala u mreži (peta razina), programiranje (četvrta razina) -> izrada prezentacija (peta razina), racionalni brojevi (prva razina) -> izrada prezentacija (peta razina), programiranje (četvrta razina) -> računala u mreži (peta razina). Tema operacije s razlomcima radi se na samom početku školske godine, dok se tema računala u mreži radi puno kasnije pa je povezanost operacije s razlomcima (1-6) -> računala u mreži (10-12) prilično jasna. Slična situacija je i s povezanosti racionalni brojevi (25-29) -> izrada prezentacija (19-24). Tema izrada prezentacija se radi na samome kraju školske godine, dok tema racionalni brojevi po programu dolazi puno ranije. Programiranje se po programu radi prije tema izrada prezentacije i računala u mreži, pa su povezanosti programiranje -> izrada prezentacija te programiranje -> računala u mreži jasne.

5.5.3 Sedmi razred



Matematika		Informatika	
KOOR	koordinatni sustav	Prog	programiranje (LOGO)
PROP	proporcionalnost i obrnuta proporcionalnost	Pror	proračunske tablice
SLIČ	sličnost i mnogokuti	Prez	prezentacije
KRUG	krug i kružnica	Mrež	izrada mrežnih stranica
SUST	sustavi linearnih jednadžbi	Inte	internet
LINE	linearna funkcija	Pre2	izrada prezentacija

Slika 123. Kauzalne povezanosti između odabranih tema iz Matematike i Informatike u sedmom razredu

Mjerene kompetencije u odabranim temama su podijeljene na četiri razine. Na prvoj su se razini nalazile sljedeće teme:

- Sličnost i mnogokuti (Matematika)
- Krug i kružnica (Matematika)
- Proporcionalnost i obrnuta proporcionalnost (Matematika)
- Linearna funkcija (Matematika)

Druga razina:

- Sustavi linearnih jednadžbi (Matematika)
- Internet (Informatika)
- Koordinatni sustav (Matematika)
- Prezentacije (Informatika)

Treća razina:

- Izrada mrežnih stranica (Informatika)
- Programiranje (LOGO) (Informatika)
- Proračunske tablice (Informatika)
- Izrada prezentacija (Informatika)

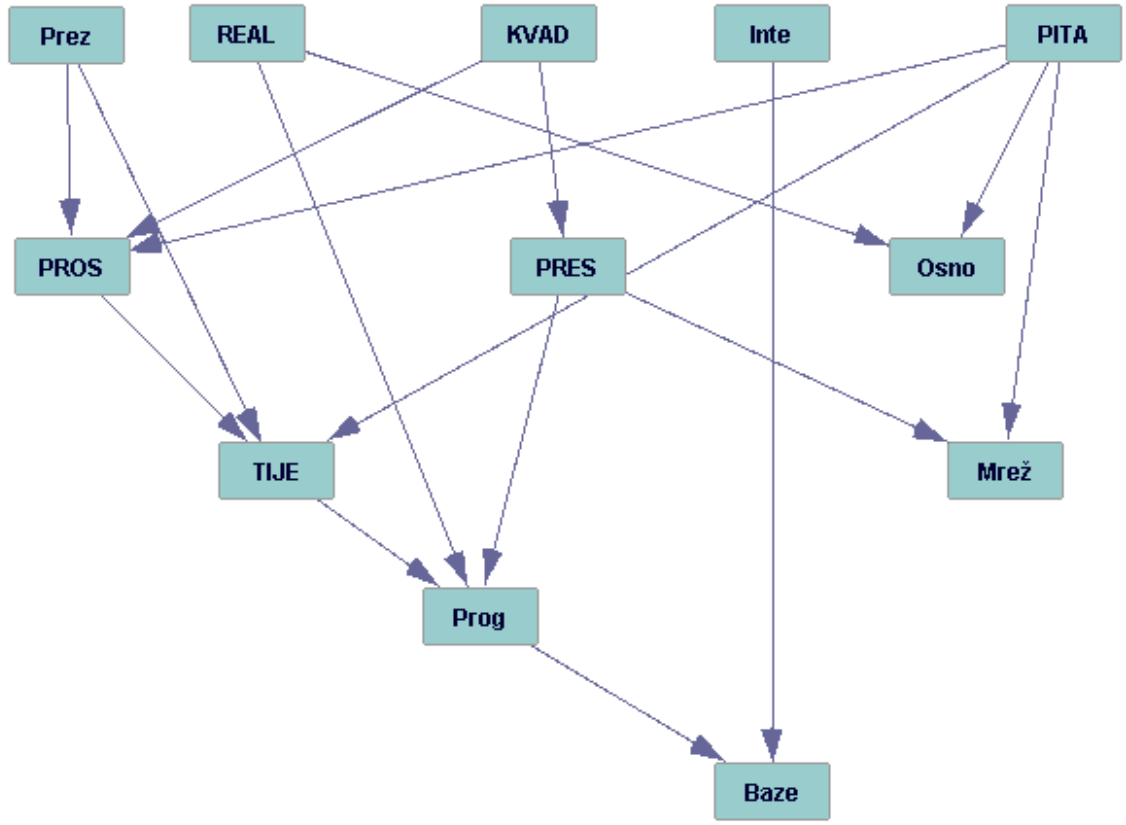
Promotrimo sljedeće kauzalne povezanosti: sličnost i mnogokuti (prva razina) -> sustavi linearnih jednadžbi (druga razina), sustavi linearnih jednadžbi (druga razina) -> izrada mrežnih stranica (treća razina), sustavi linearnih jednadžbi (druga razina) -> programiranje (treća razina), sličnost i mnogokuti (prva razina) -> programiranje (treća razina), sličnost i mnogokuti (prva razina) -> internet (druga razina) i krug i kružnica (prva razina) -> internet (druga razina). Kauzalne povezanosti sličnost i mnogokuti (13-16) -> sustavi linearnih jednadžbi (23-26), sličnost i mnogokuti (13-16) -> internet (22-25) te krug i kružnica (17-22) -> internet (22-25) razumljive su, jer slijed obrade u nastavnom programu odgovara smjeru kauzalnih povezanosti. Kauzalna povezanost sustavi linearnih jednadžbi (23-26) -> izrada mrežnih stranica (16-21) upitna je jer se usporedbom poretka u kojem se ove teme obrađuju u programu dolazi do zaključka da se obrada odvija gotovo paralelno. Kauzalne povezanosti koje možemo označiti kao problematične su: sustavi linearnih jednadžbi (23-26) -> programiranje (1-3) te sličnost i mnogokuti (13-16) -> programiranje (1-3), jer se tema

programiranje obrađuje na samome početku školske godine, a druge dvije matematičke teme puno kasnije.

Nadalje, promotrimo kauzalne povezanosti: sličnost i mnogokuti (prva razina) -> koordinatni sustav (druga razina), krug i kružnica (prva razina) -> prezentacije (druga razina), proporcionalnost i obrnuta proporcionalnost (prva razina) -> prezentacije (druga razina), proporcionalnost i obrnuta proporcionalnost (prva razina) -> izrada mrežnih stranica (treća razina), proporcionalnost i obrnuta proporcionalnost (prva razina) -> programiranje (treća razina), proporcionalnost i obrnuta proporcionalnost (prva razina) -> proračunske tablice (treća razina) i koordinatni sustav (druga razina) -> proračunske tablice (treća razina). Povezanosti proporcionalnost i obrnuta proporcionalnost (3-7) -> prezentacije (13-14), proporcionalnost i obrnuta proporcionalnost (3-7) -> proračunske tablice (4-12), proporcionalnost i obrnuta proporcionalnost (3-7) -> izrada mrežnih stranica (16-21) te koordinatni sustav (1-2) -> proračunske tablice (4-12) su u skladu s poretkom zadanom u nastavnom programu. Kauzalna povezanost koja je malo upitna jest krug i kružnica (17-22) -> prezentacije (13-14), dok su povezanosti proporcionalnost i obrnuta proporcionalnost (3-7) -> programiranje (1-3) te sličnost i mnogokuti (13-16) -> koordinatni sustav (1-2) problematične, zbog očite kolizije između poretka obrade tema i kauzalnosti.

I na kraju su nam ostale sljedeće kauzalne povezanosti: linearna funkcija (prva razina) -> sustavi linearnih jednadžbi (druga razina), linearna funkcija (prva razina) -> proračunske tablice (treća razina), prezentacije (druga razina) -> izrada mrežnih stranica (treća razina), koordinatni sustav (druga razina) -> izrada prezentacija (treća razina), krug i kružnica (prva razina) -> izrada prezentacija (treća razina) te prezentacije (druga razina) -> izrada prezentacija (treća razina). Dok je povezanost prezentacije (13-14) -> izrada mrežnih stranica (16-21) razumljiva, povezanosti linearna funkcija (27-29) -> proračunske tablice (4-12) te linearna funkcija (27-29) -> sustavi linearnih jednadžbi (23-26) su očito problematične. Kauzalne povezanosti krug i kružnica (17-22) -> izrada prezentacija (15), koordinatni sustav (1-2) -> izrada prezentacija (15) te prezentacije (13-14) -> izrada prezentacija (15) su razumljive.

5.5.4 Osmi razred



Matematika		Informatika	
KVAD	kvadriranje i korjenovanje	Osno	osnove informatike
PITA	Pitagorin poučak	Prog	programiranje (LOGO)
REAL	realni brojevi	Baze	baze podataka
PRES	preslikavanja ravnine	Prez	prezentacije
PROS	točke, pravci i ravnine u prostoru	Inte	internet
TIJE	geometrijska tijela	Mrež	izrada mrežnih stranica.

Slika 124. Kauzalne povezanosti između odabranih tema iz Matematike i Informatike u osmom razredu

Mjerene kompetencije u odabranim temama su podijeljene na pet razina. Na prvoj razini su se nalazile sljedeće teme:

- Prezentacije
- Realni brojevi
- Kvadriranje i korjenovanje
- Internet
- Pitagorin poučak

Druga razina:

- Točke, pravci i ravnine u prostoru
- Preslikavanja ravnine
- Osnove informatike

Treća razina:

- Geometrijska tijela
- Izrada mrežnih stranica

Četvrta razina:

- Programiranje (LOGO)

Peta razina:

- Baze podataka

Promotrimo kauzalne povezanosti prezentacije (prva razina) -> geometrijska tijela (treća razina), prezentacije (prva razina) -> točke, pravci i ravnine u prostoru (druga razina) te točke, pravci i ravnine u prostoru (druga razina) -> geometrijska tijela (treća razina). Geometrijska tijela kao nastavna tema obrađuje se na samome kraju školske godine, dok se prezentacije obrađuju puno ranije, pa je povezanost prezentacije (12-14) -> geometrijska tijela (24-30) jasna. Slično je i s povezanosti točke, pravci i ravnine u prostoru (20-23) -> geometrijska tijela (24-30). No situacija s povezanosti prezentacije (12-14) -> točke, pravci i ravnine u prostoru (20-23) je drugačija. Dolazi li do preklapanja u izvođenju ili se izvođenje događa paralelno, poredak u kojem se prije spomenute nastavne teme obrađuju je upitan.

Sljedeće dvije teme koje imamo na prvoj razini su realni brojevi i kvadriranje i korjenovanje, koje povlače sljedeće kauzalne povezanosti: realni brojevi (prva razina) -> programiranje (LOGO) (četvrta razina), kvadriranje i korjenovanje (prva razina) -> točke, pravci i ravnine u prostoru (druga razina), kvadriranje i korjenovanje (prva razina) -> preslikavanja ravnine

(druga razina), preslikavanja ravnine (druga razina) -> programiranje (LOGO), (četvrta razina). Kauzalne povezanosti kvadriranje i korjenovanje (1-6) -> točke, pravci i ravnine u prostoru (20-23) te kvadriranje i korjenovanje (1-6) -> preslikavanja ravnine (16-19) jasne su. Tema kvadriranje i korjenovanje prethodi drugim dvjema navedenim temama pa je poredak u kojem se one obrađuju opravdan. Povezanost realni brojevi (11-13) -> programiranje (LOGO), (5-9) je malo upitna, zbog toga što poredak u kojem se nastavne teme obrađuju implicira gotovo paralelno ili preklapajuće izvođenje. Kauzalna povezanost preslikavanja ravnine (16-19) -> programiranje (LOGO) (5-9) problematična je iz jednostavnog razloga što se programiranje kao tema obrađuje puno ranije od teme preslikavanje ravnine. Naravno, možemo uzeti u obzir i to što u osmom razredu djeca već imaju predznanje te usvojene potpomagajuće kompetencije iz drugih područja, što bi opravdalo kauzalnost, no svejedno, označimo ovu povezanost kao problematičnu.

Zadnje teme na prvoj razini su internet i Pitagorin poučak. U vezi s njima, promotriti ćemo sljedeće kauzalne povezanosti: internet (prva razina) -> baze podataka (peta razina), Pitagorin poučak (prva razina) -> točke, pravci i ravnine u prostoru (druga razina), Pitagorin poučak (prva razina) -> geometrijska tijela (treća razina), Pitagorin poučak (prva razina) -> Osnove informatike (druga razina) te Pitagorin poučak (prva razina) -> izrada mrežnih stranica (treća razina). Okrenimo se povezanostima između matematičkih sadržaja. Povezanosti Pitagorin poučak (7-10) -> točke, pravci i ravnine u prostoru (20-23) te Pitagorin poučak (7-10) -> geometrijska tijela (24-30) su jasne. Teme točke, pravci i ravnine u prostoru te geometrijska tijela se obrađuju nakon teme Pitagorin poučak. Kauzalna povezanost internet (15-19) -> baze podataka (10-11) jes kontradiktorna. Jer u ovome slučaju nemamo otvorena pitanja o organizaciji niti kojom brzinom se matematički i informatički sadržaj obrađuje, implikacija je jasna – dobivena kauzalnost sugerira pogrešni poredak u obradi tema. Slična je situacija i s kauzalnosti Pitagorin poučak (7-10) -> osnove informatike (1-4). Osnove informatike kao tema se obrađuje na samome početku školske godine, dok se Pitagorin poučak obrađuje puno kasnije. Povezanost Pitagorin poučak (7-10) -> izrada mrežnih stranica (20-21) je jasna, jer se izrada mrežnih stranica kao tema obrađuje na samome kraju školske godine.

Na kraju, promotrimo sljedeće kauzalne povezanosti: geometrijska tijela (treća razina) -> programiranje (četvrta razina), preslikavanja ravnine (druga razina) -> programiranje (četvrta razina), preslikavanja ravnine (druga razina) -> izrada mrežnih stranica (peta razina) te programiranje (četvrta razina) -> baze podataka. Kauzalnost informatičkih tema

programiranje (5-9) -> baze podataka (10-11) je jasna. Slično je i s kauzalnosti preslikavanja ravnine (16-19) -> izrada mrežnih stranica (20-21), jer je informatička tema izrada mrežnih stranica obrađuje na samome kraju godine, dok se tema preslikavanja ravnine obrađuje puno ranije. Dvije kauzalne povezanosti koje možemo označiti kao problematične su geometrijska tijela (24-30) -> programiranje (5-9) te preslikavanja ravnine (16-19) -> programiranje (5-9). Tema geometrijska tijela se obrađuje na samom kraju godine, dok se tema programiranje obrađuje puno ranije, a slično je iako ne tako drastično s temom preslikavanja ravnine.

5.6 Razlike po spolu

Osim odgovora na postavljene probleme istraživanja, dodatno smo provjerili neke razlike među pojedinim skupinama sudionika.

Provjerili smo T-testom postojanje statistički značajne razlike u ocjeni iz pojedinih predmeta ovisno o spolu sudionika i pokazalo se da nema statistički značajne razlike u prosječnim ocjenama iz pojedinih predmeta ovisno o spolu učenika.

Tablica 22. Vrijednosti t-testa pri testiranju razlike u prosječnoj ocjeni pojedinih predmeta ovisno o spolu učenika

PREDMET	N	t
Opći uspjeh	1000	0.18
Hrvatski jezik	1000	0.21
Likovna kultura	1000	1.02
Glazbena kultura	1000	-0.27
Engleski jezik	1000	1.67
Priroda	500	-0.43
Biologija	500	1.12
Kemija	500	0.52

Fizika	500	-1.95
Povijest	1000	-0.17
Geografija	1000	-0.07
Tehnička kultura	1000	0.24
Tjelesna i zdravstvena kultura	1000	0.48
Matematika	1000	-0.26
Informatika	1000	-1.00

LEGENDA:

N – broj sudionika

t – vrijednost t-testa

Također su analizirane i razlike po spolu u prosječnim ocjenama zasebno u svakom pojedinom razredu.

5.6.1 Peti razred

Tablica 23. Razlike u prosječnim ocjenama pojedinih predmeta ovisno o spolu ispitanika u petom razredu

Varijabla	Spol	N	M	SD	t	df	p
Opći uspjeh	M	124	4,1	0,29	1,89	248	0,060
	Ž	126	4,0	0,27			
Hrvatski jezik	M	124	4,1	0,97	0,72	248	0,475
	Ž	126	4,0	0,98			
Likovna kultura	M	124	4,5	0,50	1,51	248	0,131
	Ž	126	4,4	0,49			
Glazbena kultura	M	124	4,5	0,50	-0,26	248	0,798
	Ž	126	4,5	0,50			
Engleski jezik	M	124	3,7	1,12	2,21	248	0,028
	Ž	126	3,4	1,17			
Priroda	M	124	3,6	1,16	0,29	248	0,772

	Ž	126	3,5	1,08			
Povijest	M	124	3,6	1,07	-0,28	248	0,780
	Ž	126	3,6	1,10			
Geografija	M	124	3,6	1,16	0,73	248	0,467
	Ž	126	3,5	1,11			
Tehnička kultura	M	124	4,5	0,50	-0,01	248	0,995
	Ž	126	4,5	0,50			
Tjelesna i zdravstvena kultura	M	124	4,5	0,50	-0,01	248	0,995
	Ž	126	4,5	0,50			
Matematika	M	124	3,9	0,92	1,25	248	0,214
	Ž	126	3,7	0,96			
Informatika	M	124	4,6	0,50	-0,11	248	0,911
	Ž	126	4,6	0,50			

Rezultati su pokazali da u petom razredu postoji statistički značajna razlika u prosječnoj ocjeni (t = 2.21, p < 0.01) iz Engleskog jezika koja je viša kod dječaka (M = 3.7) nego li kod djevojčica (M = 3.4).

5.6.2 Šesti razred

Tablica 24. Razlike u prosječnim ocjenama pojedinih predmeta ovisno o spolu ispitanika u šestom razredu

Varijabla	Spol	N	M	SD	t	df	p
Opći uspjeh	M	110	3,9	0,29	-1,50	248	0,134
	Ž	140	4,0	0,26			
Hrvatski jezik	M	110	3,6	1,02	-0,21	248	0,835
	Ž	140	3,7	1,07			
Likovna kultura	M	110	4,6	0,50	0,66	248	0,508
	Ž	140	4,5	0,50			
Glazbena kultura	M	110	4,5	0,50	-1,10	248	0,273
	Ž	140	4,5	0,50			
Engleski jezik	M	110	3,6	1,11	-0,46	248	0,646
	Ž	140	3,6	1,05			

Priroda	M	110	3,5	1,13	-0,95	248	0,345
	Ž	140	3,6	1,05			
Povijest	M	110	3,4	1,18	-0,17	248	0,863
	Ž	140	3,4	1,07			
Geografija	M	110	3,5	1,11	0,64	248	0,525
	Ž	140	3,5	1,07			
Tehnička kultura	M	110	4,5	0,50	-0,65	248	0,516
	Ž	140	4,5	0,50			
Tjelesna i zdravstvena kultura	M	110	4,6	0,50	2,05	248	0,042
	Ž	140	4,4	0,50			
Matematika	M	110	3,7	0,86	-1,85	248	0,066
	Ž	140	4,0	1,01			
Informatika	M	110	3,8	0,80	-2,45	248	0,015
	Ž	140	4,0	0,84			

Iz prethodne tablice vidimo da u šestom razredu dječaci (M = 4.6) postižu statistički značajno višu prosječnu ocjenu (t = 2.05, p < 0.05) iz Tjelesno – zdravstveno kulture, nego li djevojčice (M = 4.5) te statistički značajno nižu (t = -2.45, p <0.05) iz informatike (M = 3.8) nego djevojčice (M = 4.0).

5.6.3 Sedmi razred

Tablica 25. Razlike u prosječnim ocjenama pojedinih predmeta ovisno o spolu ispitanika u sedmom razredu

Varijabla	Spol	N	M	SD	t	df	p
Opći uspjeh	M	130	3,9	0,27	-0,07	248	0,943
	Ž	120	3,9	0,27			
Hrvatski jezik	M	130	3,7	1,10	0,55	248	0,586
	Ž	120	3,6	1,11			
Likovna kultura	M	130	4,5	0,50	0,00	248	1,000
	Ž	120	4,5	0,50			
Glazbena kultura	M	130	4,5	0,50	0,53	248	0,600
	Ž	120	4,5	0,50			

Engleski jezik	M	130	3,5	1,14	1,47	248	0,143
	Ž	120	3,3	1,15			
Povijest	M	130	3,6	1,06	0,54	248	0,588
	Ž	120	3,5	1,09			
Geografija	M	130	3,4	1,16	-1,96	248	0,051
	Ž	120	3,7	1,14			
Tehnička kultura	M	130	4,5	0,50	0,88	248	0,380
	Ž	120	4,5	0,50			
Tjelesna i zdravstvena kultura	M	130	4,5	0,50	0,35	248	0,724
	Ž	120	4,5	0,50			
Matematika	M	130	3,6	0,97	-0,02	248	0,988
	Ž	120	3,6	1,05			
Informatika	M	130	4,0	0,83	0,62	248	0,538
	Ž	120	4,0	0,79			
Biologija	M	130	3,6	1,14	0,44	248	0,657
	Ž	120	3,6	1,14			
Kemija	M	130	3,7	1,13	0,54	248	0,592
	Ž	120	3,6	1,09			
Fizika	M	130	3,3	1,11	-2,96	248	0,003
	Ž	120	3,7	1,12			

U sedmom se razredu pokazalo da djevojčice (M = 3.7) postižu statistički značajno višu (t = 2.96, p < 0.01) ocjenu iz Fizike nego li dječaci (M = 3.3).

5.6.4 Osmi razred

Tablica 26. Razlike u prosječnim ocjenama pojedinih predmeta ovisno o spolu ispitanika u osmom razredu

Varijabla	Spol	N	M	SD	t	df	p
Opći uspjeh	M	120	3,9	0,27	0,08	248	0,936
	Ž	130	3,9	0,25			
Hrvatski jezik	M	120	3,6	1,11	-0,69	248	0,489
	Ž	130	3,7	1,13			

Likovna kultura	M	120	4,5	0,50	0,02	248	0,984
	Ž	130	4,5	0,50			
Glazbena kultura	M	120	4,5	0,50	0,36	248	0,717
	Ž	130	4,5	0,50			
Engleski jezik	M	120	3,5	1,14	0,23	248	0,822
	Ž	130	3,5	1,15			
Povijest	M	120	3,5	1,12	-0,62	248	0,538
	Ž	130	3,6	1,07			
Geografija	M	120	3,6	1,05	0,47	248	0,642
	Ž	130	3,6	1,12			
Tehnička kultura	M	120	4,5	0,50	0,26	248	0,793
	Ž	130	4,5	0,50			
Tjelesna i zdravstvena kultura	M	120	4,4	0,49	-1,46	247,00	0,147
	Ž	130	4,5	0,50			
Matematika	M	120	3,7	1,05	0,29	248	0,771
	Ž	130	3,7	1,13			
Informatika	M	120	4,0	0,86	-0,46	248	0,649
	Ž	130	4,0	0,80			
Biologija	M	120	3,6	1,12	1,12	248	0,265
	Ž	130	3,5	1,09			
Kemija	M	120	3,5	1,15	0,10	248	0,923
	Ž	130	3,5	1,06			
Fizika	M	120	3,4	1,16	0,07	248	0,948
	Ž	130	3,4	1,17			

U osmom razredu nisu pronađene razlike po spolu.

Obzirom na oblike distribucija razlike u ocjenama iz pojedinih tema provjerene su neparametrijskim Mann-Whitney U testom. I ovdje se pokazalo da nema razlike ovisno o spolu učenika.

5.7 Razlike po vrsti škole

Nadalje, provjereno je postojanje razlike u prosječnim završnim ocjenama ovisno o tome radi li se o seoskoj ili gradskoj školi. Nije se pokazalo postojanje statistički značajnih razlika.

Tablica 27. Vrijednosti t-testa pri testiranju razlike u prosječnoj ocjeni pojedinih predmeta ovisno o školi (urbanoj ili ruralnoj)

PREDMET	N	t
Opći uspjeh	1000	-0.77
Hrvatski jezik	1000	-1.25
Likovna kultura	1000	1.71
Glazbena kultura	1000	-0.44
Engleski jezik	1000	-0.22
Priroda	500	0.57
Biologija	500	-0.47
Kemija	500	0.79
Fizika	500	0.11
Povijest	1000	0.46
Geografija	1000	-0.94
Tehnička kultura	1000	0.82
Tjelesna i zdravstvena kultura	1000	0.06
Matematika	1000	-0.87
Informatika	1000	-1.00

LEGENDA:
N – broj sudionika
t – vrijednost t-testa

Također su analizirane i razlike po vrsti škole u prosječnim ocjenama zasebno u svakom pojedinom razredu.

5.7.1 Peti razred

Tablica 28. Razlike u prosječnim ocjenama pojedinih predmeta u petom razredu ovisno o vrsti škole

Varijabla	Škola	N	M	SD	t	df	p
Opći uspjeh	Gradska	124	4,0	0,29	-0,81	248	0,417
	Seoska	126	4,1	0,27			
Hrvatski jezik	Gradska	124	4,0	1,00	-0,84	248	0,402
	Seoska	126	4,1	0,96			
Likovna kultura	Gradska	124	4,5	0,50	1,00	248	0,317
	Seoska	126	4,4	0,50			
Glazbena kultura	Gradska	124	4,5	0,50	0,00	248	0,997
	Seoska	126	4,5	0,50			
Engleski jezik	Gradska	124	3,4	1,14	-1,20	248	0,230
	Seoska	126	3,6	1,17			
Priroda	Gradska	124	3,6	1,19	0,06	242,47	0,950
	Seoska	126	3,6	1,04			
Povijest	Gradska	124	3,7	1,08	0,77	248	0,441
	Seoska	126	3,6	1,08			
Geografija	Gradska	124	3,5	1,17	-0,50	248	0,619
	Seoska	126	3,6	1,11			
Tehnička kultura	Gradska	124	4,5	0,50	0,25	248	0,806
	Seoska	126	4,5	0,50			
Tjelesna i zdravstvena kultura	Gradska	124	4,5	0,50	1,77	248	0,078
	Seoska	126	4,4	0,50			
Matematika	Gradska	124	3,7	0,95	-0,90	248	0,369
	Seoska	126	3,8	0,94			
Informatika	Gradska	124	4,5	0,50	-2,69	247,18	0,008
	Seoska	126	4,6	0,48			

Rezultati su pokazali da u petom razredu postoji statistički značajna razlika u prosječnoj ocjeni (t = 2.69, p < 0.01) iz Informatike koja je viša u seoskim školama (M = 4.6) nego li u gradskim školama (M = 3.5).

5.7.2 Šesti razred

Tablica 29. Razlike u prosječnim ocjenama pojedinih predmeta u šestom razredu ovisno o vrsti škole

Varijabla	Škola	N	M	SD	t	df	p
Opći uspjeh	Gradska	115	4,0	0,29	0,06	248	0,950
	Seoska	135	4,0	0,26			
Hrvatski jezik	Gradska	115	3,6	1,05	-0,24	248	0,811
	Seoska	135	3,7	1,04			
Likovna kultura	Gradska	115	4,5	0,50	0,23	248	0,820
	Seoska	135	4,5	0,50			
Glazbena kultura	Gradska	115	4,4	0,50	-2,27	248	0,024
	Seoska	135	4,6	0,50			
Engleski jezik	Gradska	115	3,6	1,12	0,25	248	0,807
	Seoska	135	3,6	1,04			
Priroda	Gradska	115	3,6	1,07	0,73	248	0,465
	Seoska	135	3,5	1,11			
Povijest	Gradska	115	3,5	1,13	1,05	248	0,293
	Seoska	135	3,4	1,11			
Geografija	Gradska	115	3,5	1,13	0,11	248	0,911
	Seoska	135	3,5	1,06			
Tehnička kultura	Gradska	115	4,5	0,50	-0,26	248	0,793
	Seoska	135	4,5	0,50			
Tjelesna i zdravstvena kultura	Gradska	115	4,5	0,50	0,38	248	0,705
	Seoska	135	4,5	0,50			
Matematika	Gradska	115	3,8	0,96	-1,20	248	0,232
	Seoska	135	3,9	0,94			
Informatika	Gradska	115	3,9	0,81	0,24	248	0,810

	135	3,9	0,86				

U šestom se razredu u seoskim školama (M = 4.6) postiže statistički značajno višu prosječnu ocjenu (t = 2.27, p < 0.05) iz Glazbene kulture nego li u gradskim školama (M = 4.4).

5.7.3 Sedmi razred

Tablica 30. Razlike u prosječnim ocjenama pojedinih predmeta u sedmom razredu ovisno o vrsti škole

Varijabla	Škola	N	M	SD	t	df	p
Opći uspjeh	Gradska	132	3,9	0,27	-0,50	248	0,617
	Seoska	118	3,9	0,26			
Hrvatski jezik	Gradska	132	3,6	1,14	-1,10	248	0,274
	Seoska	118	3,7	1,06			
Likovna kultura	Gradska	132	4,5	0,50	0,25	248	0,801
	Seoska	118	4,5	0,50			
Glazbena kultura	Gradska	132	4,5	0,50	0,53	248	0,594
	Seoska	118	4,5	0,50			
Engleski jezik	Gradska	132	3,5	1,19	0,38	248	0,705
	Seoska	118	3,4	1,10			
Povijest	Gradska	132	3,5	1,11	-0,77	248	0,440
	Seoska	118	3,6	1,03			
Geografija	Gradska	132	3,5	1,13	-1,65	248	0,101
	Seoska	118	3,7	1,17			
Tehnička kultura	Gradska	132	4,5	0,50	1,13	248	0,259
	Seoska	118	4,5	0,50			
Tjelesna i zdravstvena kultura	Gradska	132	4,5	0,50	-1,43	248	0,154
	Seoska	118	4,6	0,50			
Matematika	Gradska	132	3,7	0,96	0,83	248	0,405
	Seoska	118	3,6	1,06			
Informatika	Gradska	132	3,9	0,79	-1,42	248	0,158
	Seoska	118	4,1	0,83			
Biologija	Gradska	132	3,6	1,14	0,09	248	0,929

	Seoska	118	3,6	1,14			
Kemija	Gradska	132	3,7	1,10	1,19	248	0,237
	Seoska	118	3,6	1,13			
Fizika	Gradska	132	3,5	1,09	0,32	248	0,748
	Seoska	118	3,5	1,19			

U sedmom razredu nisu pronađene razlike po vrsti škole.

5.7.4 Osmi razred

Tablica 31. Razlike u prosječnim ocjenama pojedinih predmeta u osmom razredu ovisno o vrsti škole

Varijabla	Škola	N	M	SD	t	df	p
Opći uspjeh	Gradska	130	3,9	0,26	0,12	248	0,902
	Seoska	120	3,9	0,27			
Hrvatski jezik	Gradska	130	3,7	1,13	-0,33	248	0,745
	Seoska	120	3,7	1,10			
Likovna kultura	Gradska	130	4,6	0,50	2,01	248	0,045
	Seoska	120	4,4	0,50			
Glazbena kultura	Gradska	130	4,5	0,50	0,90	248	0,369
	Seoska	120	4,5	0,50			
Engleski jezik	Gradska	130	3,5	1,16	0,33	248	0,744
	Seoska	120	3,5	1,14			
Povijest	Gradska	130	3,5	1,07	-0,31	248	0,756
	Seoska	120	3,6	1,11			
Geografija	Gradska	130	3,6	1,05	0,12	248	0,908
	Seoska	120	3,6	1,13			
Tehnička kultura	Gradska	130	4,5	0,50	0,49	248	0,621
	Seoska	120	4,5	0,50			
Tjelesna i zdravstvena kultura	Gradska	130	4,4	0,50	-0,58	248	0,564
	Seoska	120	4,5	0,50			
Matematika	Gradska	130	3,7	1,08	-0,29	248	0,771

	Seoska	120	3,7	1,11			
Informatika	Gradska	130	4,0	0,79	0,76	240,37	0,449
	Seoska	120	4,0	0,87			
Biologija	Gradska	130	3,5	1,11	-0,77	248	0,441
	Seoska	120	3,6	1,10			
Kemija	Gradska	130	3,5	1,13	-0,10	248	0,923
	Seoska	120	3,5	1,08			
Fizika	Gradska	130	3,4	1,13	-0,17	248	0,862
	Seoska	120	3,4	1,21			

I na kraju, u osmom razredu učenici gradskih škola (M = 4.6) postižu statistički značajno višu prosječnu ocjenu iz Likovne kulture (t = 2.01, $p < 0.05$) nego li oni iz seoskih škola (M = 4.4).

Također među ovim skupinama učenika nije pronađena niti razlika u ocjenama iz pojedinih tema u Matematici i Informatici.

I na kraju, provjerena je povezanost dobi (razreda) učenika s ocjenama iz pojedinih predmeta. Pokazalo se da s porastom dobi (razreda) učenika dolazi i do porasta u općem uspjehu (r = 0.20; $p < 0.01$), ocjeni iz Hrvatskog jezika (r = 0.11; $p < 0.01$) te ocjeni iz Informatike (r = 0.19; $p < 0.01$).

6 DISKUSIJA

Rezultati koje smo dobili našim istraživanjem ponajprije pokazuju da učenici postižu najbolje prosječne ocjene iz odgojnih predmeta te da su te ocjene statistički značajno više nego ocjene iz svih ostalih predmeta. Na sljedećem mjestu, odmah iza odgojnih predmeta je ocjena iz Informatike koja je statistički značajno viša od svih predmeta osim odgojnih.

Već u tom prvom preliminarnom pregledu i analizi podataka uočavamo bliskost Informatike s odgojnim predmetima. Pretpostavljamo da je ovo posljedica toga što je Informatika u doba mjerenja bila izborni predmet te vjerojatno radi toga ima nešto više prosječne ocjene. Nije nužno da su profesori blaži u ocjenjivanju kada se radi o izbornom predmetu, već je moguće i vjerojatno da izborni predmet odabiru upravo ona djeca koju taj predmet i interesira. Ta su djeca možda motiviranija i nadarenija te stoga postižu više prosječne ocjene. Svakako, već sada vidimo da bi ovo istraživanje valjalo ponoviti za nekoliko godina kada se Informatika stabilizira kao obavezan predmet u osnovnom školstvu.

Prikupljeni su podaci o uspjehu učenika iz svih predmeta, te općeg uspjeha, i ocjena na pismenim ispitima iz svih nastavnih tema iz Matematike i Informatike, a broj je učenika bio neujednačen po školama i razredima. Stoga su određena dva osnovna kriterija za formiranje uzorka, a to su: spol učenika (muško ili žensko), te pripadnost ruralnoj ili gradskoj školi. Kako bi ove četiri skupine učenika bile ravnopravno zastupljene u uzorku, bez obzira na stvarnu situaciju u Republici Hrvatskoj, uzeto je po svakoj kategoriji po 250 učenika (sveukupno 1000), kako bi po svakoj kategoriji i svakom razredu bio jednak broj učenika u istraživanju. Ovih je 250 učenika izabrano tako što ih se uzimalo točno redom kako su pristizali, ali se niz prekinuo kada ih je u uzorak ušlo točno 250, a prema gore navedenim kriterijima.

Prije nego prijeđemo na provjeru hipoteza, spomenimo i da je dodatnom obradom razlika ovisno o sredini ustanovljeno da u petom razredu postoji statistički značajna razlika u prosječnoj ocjeni iz Informatike koja je viša u seoskim školama nego u gradskim. Također je ustanovljeno da s porastom dobi (razreda) učenika dolazi i do porasta u općem uspjehu, ocjeni iz Hrvatskog jezika te ocjeni iz Informatike.

Pearsonov koeficijent korelacije koristi se u slučajevima kada između varijabli promatranog modela postoji linearna povezanost i neprekidna normalna distribucija. Pearsonov koeficijent korelacije bazira se na usporedbi stvarnog utjecaja promatranih varijabli jedne na drugu u odnosu na maksimalni mogući utjecaj dviju varijabli.

Spearmanov koeficijent korelacije (produkt rang korelacije) koristi se za mjerenje povezanosti između varijabli u slučajevima kada nije moguće primjeniti Pearsonov koeficijent korelacije. Bazira se na tome da se izmjeri dosljednost povezanosti između poredanih varijabli, a oblik povezanosti (npr. linearni oblik koji je preduvjet za korištenje Pearsonovog koeficijenta) nije bitan. Među varijablama u ovom istraživanju ne postoji linearna povezanost i to je slučaj u kojem se koristi Spearmanov koficijent korelacije.

6.1. Provjera hipoteza

6.1.2. *Prva hipoteza (H1)*

Prva hipoteza (H1) glasi: Postoji statistički značajna povezanost između završnih ocjena iz Informatike i Matematike kod učenika nakon završenih pojedinih viših razreda osnovne škole.

H1a – H1d Provjeriti postoji li statistički značajna povezanost između završnih ocjena iz Informatike i Matematike kod učenika nakon završenog petog - osmog razreda osnovne škole

Obrazloženje: Podhipoteze H1a – H1d za peti - osmi razred nisu potvrđene, jer Spearmanove korelacije dobivene u petom - osmom razredu osnovne škole pokazuju da nema statistički značajne povezanosti u završnim ocjenama između Matematike i Informatike:

- peti razred ($r = -0.03$; $p > 0.05$) (Tablica 42),
- šesti razred ($r = -0.09$; $p > 0.05$) (Tablica 43),
- sedmi razred ($r = -0.09$; $p > 0.05$) (Tablica 44),
- osmi razred ($r = -0.05$; $p > 0.05$) (Tablica 45).

Testiranjem prvog problema istraživanja o povezanosti između završnih ocjena iz Informatike i Matematike kod učenika nakon završenih pojedinih viših razreda osnovne škole nisu potvrđene hipoteze jer se pokazalo da nema statistički značajne povezanosti u završnim ocjenama između Matematike i Informatike niti u jednom od četiriju viša razreda.

6.1.2. Druga hipoteza (H2)

H2: Postoji statistički značajna povezanost između ocjena pojedinih tema iz Informatike i Matematike kod učenika nakon završenih pojedinih razreda osnovne škole.

H2a – H2d Provjeriti postoji li statistički značajna povezanost između ocjena pojedinih tema iz Informatike i Matematike kod učenika nakon završenog petog-osmog razreda osnovne škole

Obrazloženje: Podhipoteze H2a – H2d za peti - osmi razred nisu potvrđene, jer Spearmanove korelacije dobivene u petom - osmom razredu osnovne škole pokazuju da nema statistički značajne povezanosti između ocjena pojedinih tema iz Informatike i Matematike nakon završenog petog – osmog razreda osnovne škole.

Podhipoteza H2a nije potvrđena, jer je jedina korelacija koja je pronađena u petom razredu osnovne škole pozitivna iako ne baš visoka povezanost i to između ocjene iz crtanja pomoću računala i ocjene iz prirodnih brojeva ($r = 0.16$; $p < 0.01$), odnosno s porastom ocjene iz crtanja pomoću računala raste i ocjena iz prirodnih brojeva.

Podhipoteza H2b nije potvrđena, jer je jedina korelacija koja je pronađena u šestom razredu mala ali negativna korelacija i to između ocjene iz obrade teksta i linearne jednadžbe s jednom nepoznanicom ($r = -0.17$; $p < 0.01$), odnosno s

porastom ocjene iz obrade teksta pada ocjena iz linearnih jednadžbi s jednom nepoznanicom.

Podhipoteze H2c i H2d nisu potvrđene, jer ni u sedmom ni u osmom razredu nije pronađena niti jedna značajna povezanost u ocjenama iz pojedinih tema Matematike i Informatike.

Drugim se problemom željelo provjeriti postoji li statistički značajna povezanost između završnih ocjena pojedinih tema iz Informatike i Matematike kod učenika nakon završenih pojedinih razreda osnovne škole te su dobivene svega dvije značajne povezanosti: u petom razredu osnovne škole pronađena je jedna pozitivna povezanost između ocjene iz crtanja pomoću računala i ocjene iz prirodnih brojeva odnosno s porastom ocjene iz crtanja pomoću računala raste i ocjena iz prirodnih brojeva, a u šestom je razredu pronađena jedna negativna korelacija između ocjene iz obrade teksta i linearne jednadžbe s jednom nepoznanicom odnosno s porastom ocjene iz obrade teksta pada ocjena iz linearnih jednadžbi s jednom nepoznanicom. Kako bi se odgovorilo na drugi problem istraživanja odnosno provjerilo postoji li statistički značajna povezanost između završnih ocjena pojedinih tema iz Informatike i Matematike kod učenika nakon završenih pojedinih razreda osnovne škole izračunati su Spearmanovi koeficijenti korelacije koji nisu pokazali statistički značajnu povezanost.

6.1.4. Treća hipoteza (H3)

H3: Provjeriti postoji li statistički značajna razlika u povezanosti između završne ocjene iz Matematike i Informatike te povezanosti između završne ocjene iz Matematike i završne ocjene iz ostalih predmeta te općeg uspjeha nakon završenih pojedinih razreda osnovne škole.

H3a – H3d Provjeriti postoji li statistički značajna razlika u povezanosti između završne ocjene iz Matematike i Informatike te povezanosti između završne ocjene iz Matematike i završne ocjene iz ostalih predmeta te općeg uspjeha nakon završenog petog - osmog razreda osnovne škole.

Obrazloženje: Nije potvrđeno postojanje povezanosti između završnih ocjena Informatike i Matematike u petom – osmom razredu, t.j. povezanost u završnoj ocjeni iz Matematike i Informatike statistički je značajno veća od povezanosti između završne ocjene iz Matematike i završne ocjene iz ostalih predmeta te općeg uspjeha. Podhipoteze H3a – H3d nisu potvrđene.

Nije potvrđena niti treća hipoteza istraživanja da je povezanost u završnoj ocjeni iz Matematike i Informatike statistički značajno veća od povezanosti između završne ocjene iz Matematike i završne ocjene iz ostalih predmeta te općeg uspjeha. Također se pokazalo da u petom razredu nema povezanosti između općeg uspjeha i Informatike te glazbenog odgoja dok postoji povezanost općeg uspjeha s svim ostalim završnim ocjenama. U šestom, sedmom i osmom razredu se pronalazi pozitivna korelacija između općeg uspjeha i završne ocjene iz Informatike odnosno s porastom ocjene iz Informatike dolazi i do porasta općeg uspjeha kao i kod većine predmeta. Ove povezanosti izostaju samo ponekad kod odgojnih predmeta.

Kada bi hipoteze bile postavljne u negativnom obliku (nul - hipoteze) tada bi doktorsko istraživanje potvrdilo ove tri hipoteze: da nema statistički značajne povezanosti između ispitivanih varijabli (nema povezanosti između ocjena između Informatike i Matematike, da nema povezanosti između pojedinih tema iz ovih dvaju predmeta, te da nema povezanosti niti s općim uspjehom učenika. Ali, bez obzira kako se hipoteze postave, afirmativno ili u negativnom obliku, statistički značajne korelacije nisu nađene.

Također je važno napomenuti da je korišten Spearmanov koeficijent korelacije (rang korelacija između dva niza varijabli) iz razloga što se Peasonov koeficijent korelacije koristi za linearne povezanosti, a ovdje je bila pretpostavka da između istraživanih varijabli nema linearne povezanosti (primjerice, ocjena iz Matematike i Informatike). Linearne povezanosti između istraživanih varijabli nema, pretpostavlja se, iz više razloga: jer je Informatika izborni predmet, jer se na njega javljaju izrazito motivirana djeca, dok je Matematika obvezni predmet i ne baš, nažalost, omiljen među učenicima, zatim, nastavnici Informatike su vjerojatno subjetivno blaži u ocjenjivanju Informatike radi izbornosti predmeta, pa je tu i čimbenik stručnosti nastavnika, gdje ipak u značajnoj većini slučajeva Matematiku predaju nastavnici matematike, dok za Informatiku nema uvijek adekvatnog stručnog kadra.

6.1.4. Četvrta hipoteza (H4)

H4: Postoji kauzalna povezanost obrazovnih postignuća učenika viših razreda osnovne škole između pojedinih tematskih nastavnih sadržaja Informatike i Matematike.

Kako svaka školska godina u pojedinom razredu od petog do osmog u osnovnoj školi ima različiti broj nastavnih tema iz Matematike (više od 30) i Informatike (više od 20), nije bilo moguće uspoređivati teme međusobno jer bi Matematika prevladavala brojnošću tema, pa je iz tog razloga odlučeno da će se pristupiti nasumičnom izboru jednakog broja tema za svaki razred i svaki predmet, bez obzira na ukupan broj nastavnih tema u pojedinom predmetu ili razredu. Tako je odlučeno da po šest tema nasumično odaberemo i iz Matematike i iz Informatike, za usporedbu u istom razredu. Statističkim metodama nije dobivena nikakava povezanost (koeficijenti korelacija ocjena učenika iz matematike i informatike, i iz pojedinih nastavnih tema informatike i matematike, bili su neznatno iznad nule), pa tako niti statistički značajna razlika, što se moglo vidjeti na ispitivanju prvih triju hipoteza.

Nakon upotrebe statističkih metoda, kauzalnost je ispitivana matematičkim, Bayesovim modelom, kako bi se ipak utvrdila uzročno - posljedična povezanost između postignutih ocjena na nasumično odabranim temama iz matematike i informatike, a u svrhu otkrivanja kauzaliteta u kompetencijama iz Informatike i Matematike kod učenika osnovnih škola (viših razreda), na pismenim testovima iz nasumično odabranih po šest tema iz svakog navedenog nastavnog predmeta i svakog razreda od petog do osmog.

Od ukupno 36 tema u programu za Matematiku za peti razred nasumično je odabrano 6 tema (13,89%), dok je od ukupnih 26 tema u programu za Informatiku za peti razred nasumično odabrano 6 tema (23,08%). Od ukupno 35 tema u programu za Matematiku za šesti razred nasumično je odabrano 6 tema (17,14%), dok je od ukupno 24 teme u programu za Informatiku za šesti razred nasumično odabrano 6 tema (25,00%). Od ukupno 30 tema u programu za Matematiku za sedmi razred nasumično je odabrano 6 tema (20,00%), dok je od ukupnih 25 tema u programu za Informatiku za sedmi razred nasumično odabrano 6 tema (24,00%). Od ukupno 30 tema u programu za Matematiku za osmi razred nasumično je odabrano 6 tema (20,00%), dok je od ukupno 21 teme u programu za Informatiku za osmi razred nasumično odabrano 6 tema (28,57%).

Dobiveni kauzalni model za odabrane teme iz Matematike i Informatike **u petom razredu** sastojao se od šest razina: 1) prirodni brojevi i razlomci, 2) djeljivost prirodnih brojeva, decimalni brojevi i skupovi točaka u ravnini, 3) spremnici računala i programska oprema, 4) crtanje pomoću računala; programiranje (LOGO), 5) prvi koraci u radu s računalom; internet i 6) naučimo pisati. Dobivene kauzalne povezanosti su uspoređene s poretkom danom u nastavnom programu za Matematiku i Informatiku u petom razredu. Kauzalna povezanost decimalni brojevi -> programiranje (LOGO) sugerira da je tema programiranje obrađivana prerano. Poredak obrade tema skupovi točaka u ravnini te crtanje pomoću računala je upitan, zbog toga što se ove teme obrađuju otprilike u isto vrijeme, iako je pronađena kauzalna povezanost skupovi točaka u ravnini -> crtanje pomoću računala. Nadalje, kauzalna povezanost skupovi točaka u ravnini -> prvi koraci u radu s računalom sugerira pogrešni poredak obrade sadržaja, jer se tema prvi koraci u radu s računalom obrađuje na početku školske godine a tema skupovi točaka u ravnini puno ranije. Na sličnu situaciju naišlo se u povezanosti skupova točaka u ravnini -> spremnici računala i programska oprema.

Kauzalni model za odabrane teme iz Matematike i Informatike **u šestom razredu** se sastojao od pet razina: 1) operacije s razlomcima, cijeli brojevi, osnove Informatike i racionalni brojevi, 2) trokut i obrada teksta, 3) linearne jednadžbe s jednom nepoznanicom; četverokut, 4) programiranje; multimedija i 5) izrada prezentacija; računala u mreži. Usporedbom dobivenog modela s nastavnim planom dobili smo samo jednu kauzalnu povezanost koja je u suprotnosti s poretkom u planu. Kauzalna povezanost četverokut -> multimedija je upitna, jer se četverokut kao tema obrađuje na samome kraju školske godine dok multimedija prethodi temi izrada prezentacija.

Nadalje, kauzalni model za odabrane teme **u sedmom razredu** sastojao se od tri razine: 1) sličnosti i mnogokuti; krug i kružnica; proporcionalnost i obrnuta proporcionalnost; linearna funkcija, 2) sustavi linearnih jednadžbi; internet; koordinatni sustav; prezentacije te 3) izrada mrežnih stranica; programiranje (LOGO); proračunske tablice; izrada prezentacija. Kauzalna povezanost sustavi linearnih jednadžbi -> izrada mrežnih stranica je lagano upitna jer se usporedbom poretka u kojem se ove teme obrađuju u programu dolazi do zaključka da se obrada odvija gotovo paralelno. Kauzalne povezanosti koje su označene kao problematične su: sustavi linearnih jednadžbi -> programiranje te sličnost i mnogokuti -> programiranje, jer se tema programiranje obrađuje na samome početku školske godine a druge dvije

matematičke teme puno kasnije. Kauzalna povezanost koja je malo upitna jest krug i kružnica -> prezentacije, dok su povezanosti proporcionalnost i obrnuta proporcionalnost -> programiranje te sličnost i mnogokuti -> koordinatni sustav problematične, zbog očite kolizije između poretka obrade tema i kauzalnosti. Slična je situacija i s povezanostima linearna funkcija -> proračunske tablice te linearna funkcija -> sustavi linearnih jednadžbi.

I na kraju, kauzalni model **za osmi razred** sastojao se od pet razina: 1) prezentacije, realni brojevi; kvadriranje i korjenovanje; internet; Pitagorin poučak, 2) točke, pravci i ravnine u prostoru; preslikavanja ravnine; osnove Informatike, 3) geometrijska tijela; izrada mrežnih stranica, 4) programiranje (LOGO) i 5) baze podataka. Pronađeno je više tema čija kauzalna povezanost, uspoređena s poretkom u nastavnom planu, jest označena kao upitna ili problematična. Povezanost prezentacije –> točke, pravci i ravnine u prostoru jest označena kao upitna, jer se navedene teme obrađuju gotovo paralelno. Slično je i s povezanosti realni brojevi -> programiranje (LOGO). Povezanost preslikavanja ravnine -> programiranje (LOGO) je označena kao problematična, jer se programiranje kao tema obrađuje puno ranije od teme preslikavanje ravnine. Problematične su i kauzalna povezanosti internet -> baze podataka, jer se tema baze podataka obrađuje puno prije teme internet, te Pitagorin poučak -> osnove Informatike, jer se tema osnove Informatike obrađuje na samome početku godine a Pitagorin poučak kasnije. Nadalje, pronađene su i kauzalnosti geometrijska tijela -> programiranje te preslikavanja ravnine -> programiranje (5-9). Tema geometrijska tijela se obrađuje na samom kraju nastavne godine, dok se tema programiranje obrađuje puno ranije, a slično je, iako ne tako drastično, s temom preslikavanja ravnine.

Od ukupno 20 dobivenih kauzalnosti u kauzalnom modelu odabranih tema iz Informatike i Matematike **za peti razred**, pronađeno je 4 kauzalne povezanosti (20,00% od odabranih tema) između nastavnih sadržaja koji se prema nastavnom programu ili odvijaju gotovo paralelno ili u obrnutom poretku, dakle nastavna tema koja kauzalno implicira drugu temu je obrađivana nakon nje (decimalni brojevi -> programiranje (LOGO), skupovi točaka u ravnini -> crtanje pomoću računala, skupovi točaka u ravnini -> prvi koraci u radu s računalom, skupovi točaka u ravnini -> spremnici računala i programska oprema).

Od ukupno 17 dobivenih kauzalnosti u kauzalnom modelu odabranih tema iz Informatike i Matematike **za šesti razred**, pronađena je jedna kauzalna povezanost (5,88% od odabranih

tema) između nastavnih sadržaja koji se obrađuju u suprotnosti s dobivenom kauzalnom povezanosti (četverokut -> multimedija).

Od ukupno 19 dobivenih kauzalnosti u kauzalnom modelu odabranih tema iz Informatike i Matematike **za sedmi razred**, pronađeno je 7 kauzalnih povezanosti (36,84%) između nastavnih sadržaja koji se odvijaju gotovo paralelno ili u obrnutom poretku (sustavi linearnih jednadžbi -> izrada mrežnih stranica; sustavi linearnih jednadžbi -> programiranje; sličnost i mnogokuti -> programiranje; krug i kružnica -> prezentacije; proporcionalnost i obrnuta proporcionalnost -> programiranje; sličnost i mnogokuti -> koordinatni sustav; linearna funkcija -> proračunske tablice; linearna funkcija -> sustavi linearnih jednadžbi).

Od ukupno 16 dobivenih kauzalnosti u kauzalnom modelu odabranih tema iz Informatike i Matematike **za osmi razred**, pronađeno je 7 kauzalnih povezanosti (43,75%) između nastavnih sadržaja koji se odvijaju gotovo paralelno ili u obrnutom poretku (prezentacije –> točke, pravci i ravnine u prostoru; realni brojevi -> programiranje (LOGO); preslikavanja ravnine -> programiranje (LOGO); Internet -> baze podataka; Pitagorin poučak -> osnove Informatike; geometrijska tijela -> programiranje; preslikavanja ravnine -> programiranje).

Dakle, pretpostavka je bila da Informatika i Matematika imaju kauzalnu povezanost s obzirom na prirodu samih sadržaja nastavnih predmeta, to jest, da neke sadržaje iz Informatike učenici ne mogu razumjeti ako nisu prethodno savladali u Matematici neke teme (primjerice: rješavanje problema linearnom jednadžbom – Matematika, nužno je za razumijevanje algoritama u programiranju - Informatika). Matematičke i informatičke kompetencije su također i kauzalno povezane, što je ovim istraživanjem djelomično potvrđeno u sedmom (36,84%) i osmom razredu (43,75%), dok su u petom (20,00%) i šestom (5,88%) razredu kauzalnosti još niže. Zašto nema više kauzalnosti među ocjenama pojedinih tema Informatike i Matematike u petom i šestom razredu? Razlog tomu je najvjerojatnije nikakvo predznanje u Informatici, jer je to tek prva godina učenja, a predznanje je neujednačeno jer neki učenici ponešto od informatike nauče samostalno, dok neki (pogotovo u seoskim školama) uopće ne znaju ništa, pa treba vremena (dvije godine) da se njihove kompetencije ujednače i stabiliziraju na određenoj razini. Dok u matematici petog razreda, matematičke su kompetencije one koje su učenici stjecali tijekom nižih razreda osnovne škole, a tek se nakon dvije godine matematičke kompetencije pokažu značajnije razvijenima.

H4: Na temelju dobivenih kauzalnih povezanosti između nasumično odabranih nastavnih tema iz Matematike i Informatike u višim razredima osnovne škole može se zaključiti da je četvrta hipoteza (H4) djelomično potvrđena (kauzalitet se kreće od 6% do 44%).

Kako bi se provjerio kauzalitet među kompetencijama učenika viših razreda osnovne škole iz nastavnih predmeta informatike i matematike, što je tema ove doktorske disertacije, odabrane varijable bile su ocjene učenika iz ovih dvaju nastavnih predmeta, te ocjene iz pisanih ispita pojedinih nasumično odabranih tema iz ovih dvaju nastavnih predmeta, te općeg uspjeha učenika.

Međutim, pokazalo se nemogućim uspoređivati ocjene učenika (nisu nađene nikakve korelacije, vidi hipoteze H1 - H3) iz više razloga: Informatika je lošije kadrovski pokrivena nego Matematika u osnovnim školama Republike Hrvatske i to posebno u ruralnim školama; tehnička opremljenost škola loša je i nedovoljno ujednačena; u vrijeme istraživanja informatika je još uvijek bila izborni predmet što je značajno utjecalo na kriterije ocjenjivanja učenika koji su u izbornom predmetu uvijek nešto niži nego u obveznim predmetima, osobito u Matematici i Hrvatskom jeziku. Pored subjektivnosti nastavnika svi ovi razlozi su utjecali da se statističkim metodama nije pronašla nikakva povezanost među uspoređivanim varijablama. Stoga se pristupilo primjeni matematičkog Bayesovog modela, koji daleko sofisticiranije ulazi u kauzalne odnose uspoređivanih varijabli, pa je tako ipak pronađen kauzalitet u sedmom i osmom razredu.

Budući da je tema doktorskog rada bila povezanost matematičkih i informatičkih kompetencija kod učenika viših razreda osnovnih škola, nije se moglo uzeti ništa drugo doli ocjene učenika, a one su uglavnom subjektivno izražene od strane nastavnika, jer nisu ujednačeni kriteriji pisanih ispita, niti razdiobe bodova, a niti bodovne skale, a niti pitanja po pojedinom ispitu nisu bila na istoj razini usvojenosti. Bilo bi svakako daleko objektivnije i vjerojatno bi se pojavile pozitivne ili negativne korelacije među ocjenama učenika, kada bi se provelo vanjsko vrednovanje znanja, sposobnosti i vještina učenika na istoj obrazovnoj razini (isti razred), a to bi jedino bilo moguće u okviru projekta Ministarstva znanosti i obrazovanja ili Nacionalnog centra za vanjsko vrednovanje obrazovanja za sve učenike viših razreda osnovnih škola u Republici Hrvatskoj.

Bayesov model za detektiranje kauzaliteta, sigurno se može u obrazovanju primijeniti i na mnoge druge načine kao na primjer, za kauzalnu povezanost nastavnih tema među različitim nastavnim predmetima i unutar istog nastavnog predmeta u Nacionalnom okvirnom

kurikulumu. Njegova primjena u obrazovnom sustavu je i daleko šira, o čemu govore neka dosadašnja istraživanja u svijetu i kod nas, kao na primjer: digitalne kompetencije, rješavanje problema i programiranje, predškolske matematičke kompetencije.
Bilo bi korisno ponoviti ovo istraživanje nakon dvije godine tijekom kojih Informatika bude obvezan nastavni predmet u petom i šestom razredu osnovne škole, kako bi se utvrdilo jesu li povezanosti više izražene i jesu li statistički značajne, bez obzira na subjektivnost ocjenjivanja, koja je ista za sve učenike i nastavne predmete, što se trenutačno ne može izbjeći.

Sugestije za daljnja istraživanja u području kauzaliteta korištenjem Bayesovog matematičkog modela mogle bi ići u smjeru kauzaliteta između učenikovih mogućnosti i odgovarajućih obrazovnih tema za učenike s teškoćama u razvoju, ali, isto tako, i za određivanje obrazovnih sadržaja prema nadarenosti učenika. Bayesov matematički model mogao bi poslužiti stručnim službama škola za ujednačenije formiranje razrednog odjela prema različitim kriterijima, detektiranje „najboljeg“ razrednog učitelja za pojedini razredni odjel itd.

ZAKLJUČAK

Bez obzira na činjenicu što nastavni plan i program koji određuje poredak obrade određenih nastavnih tema u praksi ne izgleda točno tako zbog različitih faktora, dobivene kauzalne povezanosti u kojima se teme ili odvijaju gotovo paralelno ili tema koja kauzalno implicira drugu temu obrađivana je prema nastavnom programu nakon nje, a trebala je biti obrađena prije, ukazuju na probleme u samom nastavnom planu i programu te specifično govore o neusklađenosti tema iz Matematike i Informatike. Dobivene nelogičnosti u poretku obrade tema mogu poslužiti kao sugestije što i kako bi se trebalo mijenjati u nastavnom planu i programu kako bi on bio usklađeniji te kako bi učenje o jednoj temi učenicima kasnije pomagalo pri učenju u drugoj temi, pri čemu ne govorimo samo o povezanosti između tema iz Informatike i Matematike, već i o povezanosti tema unutar samih predmeta Matematika i Informatika, jer su problematične kauzalne povezanosti pronađene i unutar samo jednog nastavnog predmeta.

Sama činjenica kako nije pronađena statistički značajna korelacija između završnih ocjena iz Matematike i Informatike povlači niz pitanja, iz razloga što empirijski dokazi drugih studija potvrđuju korelacije. Kao što je navedeno u drugom poglavlju, sama definicija 'Informatike' kao predmeta u primarnom obrazovanju nije jednoznačna u svim zemljama svijeta, čak ni na teritoriju Europe pa se usporedba s drugim sličnim studijama dovodi u pitanje. Višeznačnost samog pojma Informatike se jednim dijelom može izbjeći studijom korelacija samo nastavnih cjelina, no usporedba s ovakvim studijama može također biti otežana uzmemo li u obzir vrlo mali broj takvih studija.

Može se postaviti pitanje sadržaja znanja i postignuća koje se mjerilo. Isto tako, postavlja se i pitanje je li doista ocjena mjerilo znanja ili postignuća? Zbog toga što statistika koristi egzaktne i precizne podatke, završna ocjena kao podatak se većinom koristi kao empirijsko oruđe. U skladu sa svime navedenim, nameće se zaključak kvalitativne studije koja bi imala sličnu svrhu kao i ovo doktorsko istraživanje. Daleko od toga da u kvalitativnim studijama ne postoje problemi kod analize i interpretacije podataka – upravo iz tog razloga se koriste objektivno mjerljivi podaci u empirijskim studijama na velikim uzorcima kako bi se zbog velikog broja ispitanika nadoknadila nepreciznost otvorenih pitanja i eventualne drugačije interpretacije kao što je spomenuto. No kvalitativne studije donose sa sobom dubinu i

višeslojnost, puno više vremena i resursa, što u nekim slučajevima donosi i puno više kvalitetnih zaključaka.

Znanstveni doprinos

Znanstveni doprinos ovog doktorskog rada jest u izradi modela kauzalne povezanosti odabranih tema kurikula Informatike i Matematike što doprinosi boljemu teorijskom shvaćanju povezanosti nastavnih sadržaja, te omogućavanju kvalitetnijeg logičkog i vremenskog strukturiranja nastavnih sadržaja Informatike i Matematike prilikom makro (nastavni programi) ili mikro planiranja (pojedine nastavne jedinice). Nadalje, stvoreni kauzalni model nudi konkretne primjere neusklađenosti određenih nastavnih sadržaja iz Matematike i Informatike, ali i unutar samih predmeta Matematike i Informatike, što je pokazano testiranjma kauzalnim modelima.

Slični kauzalni modeli mogu se izraditi i za druge nastavne predmete, čime bi se osigurali egzaktni kriteriji provjere kvalitete izrade kurikula primjerenijih dobi učenika te njihovim kognitivinim sposobnostima, ali i potrebi da se neke teme izbace iz kurikula jer otežavaju učenicima povezivanje s drugim temama, te da se predvidivo strukturiraju nastavni sadržaji u makro i mikro planiranju. Ovo je posebice značajno u budućnosti za uvođenje novih informacija u obrazovni sustav da se njihova povezanost i utjecaj na druge teme provjeri izradom kauzalnog modela, te testiranjem međudjelovanja tema i informacija.

Informacijske i komunikacijske znanosti dobivaju novi instrument-kauzalni model za osiguranje kvalitete planiranja i strukturiranja informacija i sadržaja u procesu obrazovanja.

LITERATURA

Anderson, M. (1992). *Intelligence and development: A cognitive theory*. Blackwell Publishing.

Andersson, U. (2008). Mathematical competencies in children with different types of learning difficulties. *Journal of Educational Psychology*, *100*(1), 48.

Ansari, D., Donlan, C., Thomas, M. S., Ewing, S. A., Peen, T., & Karmiloff-Smith, A. (2003). What makes counting count? Verbal and visuo-spatial contributions to typical and atypical number development. *Journal of Experimental Child Psychology*, *85*(1), 50-62.

Ashcraft, M. H. (1992). Cognitive arithmetic: A review of data and theory. *Cognition, 44,* 75–106.

Aunola, K., Leskinen, E., Lerkkanen, M. K., & Nurmi, J. E. (2004). Developmental dynamics of math performance from preschool to grade 2. *Journal of educational psychology*, *96*(4), 699.

Bailey, D. H., Siegler, R. S., & Geary, D. C. (2014). Early predictors of middle school fraction knowledge. *Developmental science, 17*(5), 775-785.

Baroody, A. J., & Wilkins, J. L. (1999). The development of informal counting, number, and arithmetic skills and concepts. In J. V. Copley (Ed.), *Mathematics in the early years* (pp. 48–65). Washington, DC: National Association for the Education of Young Children.

Benbow, C. P., & Arjmand, O. (1990). Predictors of high academic achievement in mathematics and science by mathematically talented students: A longitudinal study. *Journal of Educational Psychology*, *82*(3), 430.

Biccard, P., & Wessels, D. C. (2011). Documenting the development of modelling competencies of grade 7 mathematics students. In *Trends in teaching and learning of mathematical modelling* (pp. 375-383). Springer, Dordrecht.

Bloom, B. S. (1956). *Taxonomy of educational objectives: Handbook I: The cognitive domain*. New York: David McKay Co. Inc.

Bloomhoj, M., & Jensen, T. H. (2007). What's all the fuss about competencies? Experiences with using a competence perspective on mathematics education to develop the teaching of mathematical modelling. *Modelling and applications in mathematics education. The 14th ICMI study*, 45-56

Bocconi, S., Chioccariello, A., Dettori, G., Ferrari, A., Engelhardt, K., Kampylis, P., & Punie, Y. (2016). Developing computational thinking in compulsory education. *European Commission, JRC Science for Policy Report*.

Carpenter, T. P., & Moser, J. M. (1984). The acquisition of addition and subtraction concepts in grades one through three. *Journal for research in Mathematics Education*, 179-202.

Carpenter, T. P., Moser, J. M., & Romberg, T. A. (Eds.). (1982). *Addition and subtraction: A cognitive perspective*. Lawrence Erlbaum Associates.

Cartelli, A., Dagiene, V., & Futschek, G. (2010). Bebras contest and digital competence assessment: analysis of frameworks. *International Journal of Digital Literacy and Digital Competence (IJDLDC)*, *1*(1), 24-39.

Case, R. (1978). Intellectual development from birth to adulthood: A neo-Piagetian interpretation. *Children's thinking: What develops*, 37-71.

Case, R., Sandieson, R., & Dennis, S. (1986). Two cognitive developmental approaches to the design of remedial instruction. *Cognitive Development, 1*, 293–333.

Casey, M. B., Nuttall, R., Pezaris, E., & Benbow, C. P. (1995). The influence of spatial ability on gender differences in mathematics college entrance test scores across diverse samples. *Developmental Psychology*, *31*(4), 697.

Claesens, A., & Engel, M. (2013). How important is where you start? Early mathematics knowledge and later school success. *Teachers College Record*.

Claessens, A., Duncan, G., & Engel, M. (2009). Kindergarten skills and fifth-grade achievement: Evidence from the ECLS-K. *Economics of Education Review*, *28*(4), 415-427.

Clemens, C. (2017). A causal model of writing competence (Master's thesis). Preuzeto 24.09.2018. s *https://dt.athabascau.ca/jspui/handle/10791/233*

Clements, D. H. (1999). Subitizing: What is it? Why teach it?. *Teaching children mathematics*, *5*, 400-405.

Clements, D. H., & Sarama, J. (2011). Early childhood teacher education: The case of geometry. *Journal of mathematics teacher education*, *14*(2), 133-148.

Clements, D. H., & Sarama, J. (2014). *Learning and teaching early math: The learning trajectories approach*. Routledge.

Clements, D. H., Sarama, J. H., & Liu, X. H. (2008). Development of a measure of early mathematics achievement using the Rasch model: the Research‐Based Early Maths Assessment. *Educational Psychology*, *28*(4), 457-482.

Copley, J. V. (2000). *The young child and mathematics*. National Association for the Education of Young Children, 1509 16th Street, NW, Washington, DC 20036-1426.

Coy, W. (1997). Defining discipline. In *Foundations of Computer Science* (pp. 21-35). Springer, Berlin, Heidelberg.

Csizmadia, A., Curzon, P., Dorling, M., Humphreys, S., Ng, T., Selby, C., & Woollard, J. (2015). Computational thinking A guide for teachers. Computing at School.

Dehaene, S., Spelke, E., Pinel, P., Stanescu, R., & Tsivkin, S. (1999, May 7). Sources of mathematical thinking: Behavioral and brain-imaging evidence. *Science, 284*, 970–974.

De Lange, J. (2003). Mathematics for literacy. *Quantitative literacy: Why numeracy matters for schools and colleges*, *80*, 75-89.

Denning, P. J. (2003). Great principles of computing. *Communications of the ACM*, *46*(11), 15-20.

Denning, P., & Freeman, P. (2009). Computing's paradigm. *Communications of the ACM, 52*(12), 28–30.

Denning, P., Comer, D. E., Gries, D., Mulder, M. C., Tucker, A. B., Turner, A. J., & Young, P. R. (1988). Computing as a discipline: preliminary report of the ACM task force on the core of computer science. *ACM SIGCSE Bulletin*, *20*(1), 41-41.

Dowker, A. (2005). *Individual differences in arithmetic: Implications for psychology, neuroscience and education.* Hove, England: Psychology Press.

Duncan, G. J., Dowsett, C. J., Claessens, A., Magnuson, K., Huston, A. C., Klebanov, P., ... & Sexton, H. (2007). School readiness and later achievement. *Developmental psychology*, *43*(6), 1428.

Engbring, D., & Pasternak, A. (2010). IniK–Versuch einer Begriffsbestimmung.

Erstad, O. (2010). Educating the Digital Generation. *Nordic Journal of Digital Literacy*, 1, 56–70.

European Union (2010). 2010 joint progress report of the Council and the Commission on the implementation of the 'Education and Training 2010 work programme'. *Official Journal of the European Union,* (2010/C 117/01) Preuzeto 12.07.2018. s http://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=OJ:C:2010:117:0001:0007:EN:PDF

Fei Wang, F. i Amrhein, J. (2018). *Bayesian Networks for Causal Analysis.* Preuzeto 11.09.2018. sa: https://www.sas.com/content/dam/SAS/support/en/sas-global-forum-proceedings/2018/2776-2018.pdf

Forbus, K. D. (1985). Structure and interpretation of computer programs: H. Abelson and GJ Sussman with J. Sussman,(MIT, Cambridge, 1985); 503 pages.

Forneck, H. J. (1992). *Bildung im informationstechnischen Zeitalter: Untersuchung der fachdidaktischen Entwicklung der informationstechnischen Bildung*. Sauerländer.

Friedman, W. J., & Laycock, F. (1989). Children's analog and digital clock knowledge. *Child Development, 60,* 357–371.

Fuchs, R., Vican, D., & Milanović Litre, I. (2011). Nacionalni okvirni kurikulum za predškolski odgoj i obrazovanje te opće obvezno i srednjoškolsko obrazovanje. *Zagreb: Printera Grupa*.

Gagniuc, P. A. (2017). *Markov Chains: From Theory to Implementation and Experimentation*. John Wiley & Sons.

Gardner, H. (1993). *Multiple intelligences: The theory in practice*. New York: Basic Books.

Geary, D. C. (1993). Mathematical disabilities: Cognitive, neuropsychological and genetic components. *Psychological Bulletin, 114,* 345–362.

Geary, D. C. (1994). *Children's mathematical development: Research and applications.* Washington, DC: American Psychological Association.

Geary, D. C., & Brown, S. C. (1991). Cognitive addition: Strategy choice and speed-of-processing differences in gifted, normal, and mathematically disabled children. *Developmental psychology*, *27*(3), 398.

Geary, D. C., Hamson, C. O., & Hoard, M. K. (2000). Numerical and arithmetical cognition: A longitudinal study of process and concept deficits in children with learning disability. *Journal of Experimental Child Psychology, 77,* 236–263.

Geary, D. C., Hoard, M. K., & Hamson, C. O. (1999). Numerical and arithmetical cognition: Patterns of functions and deficits in children at risk for a mathematical disability. *Journal of Experimental Child Psychology, 74,* 213–239.

Gelman, R. (1990). First principles organize attention to and learning about relevant data: Number and the animate‐inanimate distinction as examples. *Cognitive science*, *14*(1), 79-106.

Gelman, R. (1991). Epigenetic foundations of knowledge structures: Initial and transcendent constructions. *The epigenesis of mind: Essays on biology and cognition*, 293-322.

Gelman, R., & Gallistel, C. R. (1986). *The child's understanding of number*. Harvard University Press.

Gersten, R., Jordan, N. C., & Flojo, J. R. (2005). Early identification and interventions for students with mathematics difficulties. *Journal of learning disabilities*, *38*(4), 293-304.

Ginsburg, H. P. (1997). Mathematics learning disabilities: A view from developmental psychology. *Journal of Learning Disabilities, 30,* 20–33.

Ginsburg, H. P., Lee, J. S., & Boyd, J. S. (2008). Mathematics Education for Young Children: What It Is and How to Promote It. Social Policy Report. Volume 22, Number 1. *Society for Research in Child Development*.

Grouws, D. (Ed.). (2006). *Handbook of Research on Mathematics Teaching and Learning:(A Project of the National Council of Teachers of Mathematics)* (Vol. 1). IAP.

Halford, G. S. (1992). Analogical reasoning and conceptual complexity in cognitive development. *Human Development*, *35*(4), 193-217.

Han, J., Pei, J., & Kamber, M. (2011). *Data mining: concepts and techniques*. Elsevier.

Hanich, L. B., Jordan, N. C., Kaplan, D., & Dick, J. (2001). Performance across different areas of mathematical cognition in children with learning disabilities. *Journal of Educational Psychology, 93,* 615–626.

Haspekian, M. (2005) *An "instrumental approach" to study the integration of a computer tool into mathematics teaching: the case of spreadsheets*. IJCML, 10(2), 109--141.

Haspekian, M., & Bruillard, E. (2010). Behind students'spreadsheet competencies: their achievement in algebra? A case study in a french vocational school. *CERME 6–WORKING GROUP 4*, 519.

http://itte.org.uk, pristupljeno dana 11.07.2018.

http://www.informatics-europe.org/, pristupljeno dana 03.07.2018.

Hubwieser, P., Armoni, M., Brinda, T., Dagiene, V., Diethelm, I., Giannakos, M. N., ... & Schubert, S. (2011, June). Computer science/informatics in secondary education. In *Proceedings of the 16th annual conference reports on Innovation and technology in computer science education-working group reports*(pp. 19-38). ACM.

Jenkins, H., Clinton, K., Purushotma, P., Robinson, AJ., & Weigel, M, (2006). Confronting the Challenges of Participatory Culture: Media Education for the 21st Century, the John D and Catherine T MacArthur Foundation. Preuzeto 12.07.2018. sa http://www.digitallearning.macfound.org/atf/cf/%7B7E45C7E0-A3E0-4B89-AC9C-E807E1B0AE4E%7D/JENKINS_WHITE_PAPER.PDF

Jordan, N. C., & Hanich, L. B. (2000). Mathematical thinking in second grade children with different forms of LD. *Journal of Learning Disabilities, 33,* 567–578.

Jordan, N. C., & Montani, T. O. (1997). Cognitive arithmetic and problem solving: A comparison of children with specific and general mathematics difficulties. *Journal of Learning Disabilities, 30,* 624–634, 648.

Jordan, N. C., Hanich, L. B., & Kaplan, D. (2003). A longitudinal study of mathematical competencies in children with specific mathematics difficulties versus children with comorbid mathematics and reading difficulties. *Child Development, 74,* 834–850.

Jordan, N. C., Hanich, L. B., & Uberti, H. Z. (2003). Mathematical thinking and learning difficulties. In A. J. Baroody & A. Dowker (Eds.), *The development of arithmetic concepts and skills: Constructing adaptive expertise* (pp. 359–383). Mahwah, NJ: Erlbaum.

Jordan, N. C., Kaplan, D., Ramineni, C., & Locuniak, M. N. (2009). Early math matters: Kindergarten number competence and later mathematics outcomes. *Developmental psychology*, *45*(3), 850.

Kaput, J. J. (1999). Teaching and learning a new algebra. In *Mathematics classrooms that promote understanding* (pp. 145-168). Routledge.

Knuth, D. E. (1974). Computer science and its relation to mathematics. *The American Mathematical Monthly*, *81*(4), 323-343.

Krathwohl, D. R., Bloom, B. S., & Masia, B. B. (1973). *Taxonomy of educational objectives, the classification of educational goals. Handbook II: Affective domain*. New York: David McKay Co.

Lannin, J. K. (2005). Generalization and justification: The challenge of introducing algebraic reasoning through patterning activities. *Mathematical Thinking and learning, 7*(3), 231-258.

Lee, I., Martin, F., Denner, J., Coulter, B., Allan, W., Erickson, J.,. . .Werner, L. (2011). Computational thinking for youth in practice. *ACM Inroads, 2,* 32–37.

Mazzocco, M. M. M., & Thompson, R. E. (2005). Kindergarten predictors of math learning disability. *Learning Disabilities Research & Practice, 20,* 142–155.

Meinel, M. M. C., & Mundhenk, M. (2011). *Mathematische Grundlagen der Informatik*. Vieweg+ Teubner Verlag S.

Milanović Litre, I., & Vican, D. (2006). Nastavni plan i program za osnovnu školu. *MZOŠ, Zagreb*.

Nacionalni okvirni kurikulum za predškolski odgoj i obrazovanje te opće obvezno i srednjoškolsko obrazovanje, (2010). Zagreb

National Association for the Education of Young Children & National Council of Teachers of Mathematics (2002). *Early childhood mathematics: Promoting good beginnings*. Joint position statement. Washington, DC: NAEYC; Reston, VA: NCTM.

National Council of Teachers of Mathematics (2000.). *Principles and Standards for School Mathematics*. 1. Vol. 1. Reston, VA: National Council of Teachers of Mathematics.

National Research Council (2009). *Mathematics in early childhood: Learning paths toward excellence and equity*. Washington, DC: National Academy Press.

Nguyen, T., Watts, T. W., Duncan, G. J., Clements, D. H., Sarama, J. S., Wolfe, C., & Spitler, M. E. (2016). Which preschool mathematics competencies are most predictive of fifth grade achievement?. *Early childhood research quarterly*, *36*, 550-560.

Niss, M. (1999). Kompetencer og uddannelsesbeskrivelse. *Uddannelse* 9. Copenhagen, Denmark: The Ministry of Education, 21-29.

Niss, M. (2003). Mathematical competencies and the learning of mathematics: The danish KOM project. In Gagatsis, A., & Papastavridis, S. (Eds.), *3rd Mediterranean Conference on Mathematical Education*, (pp. 115-124). Athens, Greece: Hellenic Mathematical Society and Cyprus Mathematical Society.

Niss, M. & Jensen, T. H. (Eds.). (2002). Kompetencer og matematiklæring—Ideer og inspiration til udvikling af matematikundervisning i Danmark. Undervisningsministeriet. Uddannelsesstyrelsens temahæfteserie nr. 18. English translation of title: Competencies and Learning of Mathematics—Ideas and Inspiration for the Development of Mathematics Education in Denmark

Orton, A., & Orton, J. (1999). Pattern and the approach to algebra.

Ostad, S. A. (1997). Developmental differences in addition strategies: A comparison of mathematically disabled and mathematically normal children. *British Journal of Educational Psychology, 67,* 345–357.

Ostad, S. A. (1998). Developmental differences in solving simple arithmetic word problems and simple number-fact problems: A comparison of mathematically normal and mathematically disabled children. *Mathematical Cognition, 4*, 1–19.

Paić, G., Tepeš, B., & Pavlina, K. (2016, May). Markov model of mathematical competences in elementary education. In *Information and Communication Technology, Electronics and Microelectronics (MIPRO), 2016 39th International Convention on* (pp. 934-939). IEEE.

Paić, G., Bošnjak, Ž., Čulina, B. (2016). Matematički izazovi 5, udžbenik iz Matematike za peti razred. Alfa, Zagreb.

Paić, G., Bošnjak, Ž., Čulina, B. (2016). Matematički izazovi 6, udžbenik iz Matematike za šesti razred. Alfa, Zagreb.

Paić, G., Bošnjak, Ž., Čulina, B. (2016). Matematički izazovi 7, udžbenik iz Matematike za sedmi razred. Alfa, Zagreb.

Paić, G., Bošnjak, Ž., Čulina, B. (2016). Matematički izazovi 8, udžbenik iz Matematike za osmi razred. Alfa, Zagreb.

Pearl, J. (2003). Causality: models, reasoning, and inference. *Econometric Theory*, *19*(675-685), 46.

Pearl, J. (2011). Bayesian networks.

Pearl, J., & Verma, T. S. (1995). A theory of inferred causation. U: *Studies in Logic and the Foundations of Mathematics* (Vol. 134, pp. 789-811). Elsevier.

Peterson, P., Baker, E., & McGaw, B. (2010). *International encyclopedia of education*. Elsevier Ltd.

Petz, B. (2004). *Osnovne statističke metode za nematematičare*. Jastrebarsko: Naklada Slap.

Piaget, J. (1950). *The psychology of intelligence.* London: Routledge & Kegan Paul.

PISA (PISA – Programme for International Student Assessment, *Matematička pismenost*, NCVVO, 2018., https://pisa.ncvvo.hr/sto-pisa-ispituje/matematicka-pismenost/ , pristupljeno dana 21.03.2020.

Prijedlog kurikuluma matematičkog područja, (2016.), *Cjelovita kurikularna reforma - CKR*, MZO, Zagreb, 4-6.

Rechenberg, P. (2010). Was ist Informatik?. *Informatik-Spektrum*, *33*(1), 54-60.

Resnick, L. B. (1989). Developing mathematical knowledge. *American Psychologist*, *44*(2), 162.

Russell, R. L., & Ginsburg, H. P. (1984). Cognitive analysis of children's mathematical difficulties. C*ognition and Instruction, 1*, 217–244.

Sarnecka, B. W., & Carey, S. (2008). How counting represents number: What children must learn and when they learn it. *Cognition*, *108*(3), 662-674.

Saxe, G. B. (1979). Developmental relations between notational counting and number conservation. *Child Development*, 180-187.

Schleicher, A., Zimmer, K., Evans, J., & Clements, N. (2009). PISA 2009 Assessment Framework: Key Competencies in Reading, Mathematics and Science. *OECD Publishing (NJ1)*.

Secada, W. G., Fuson, K. C., & Hall, J. W. (1983). The transition from counting-all to counting-on in addition. *Journal for Research in Mathematics Education*, 47-57.

Siegler, R. S. (1987). The perils of averaging data over strategies: An example from children's addition. *Journal of Experimental Psychology: General*, *116*(3), 250.

Siegler, R. S., & McGilly, K. (1989). Strategy choices in children's time-telling. In I. Levin & D. Zakay (Eds.), *Time and human cognition: A life-span perspective* (pp. 185–218). Oxford, England: North-Holland.

Siegler, R. S., & Shipley, C. (1995). Variation, selection, and cognitive change. *Developing cognitive competence: New approaches to process modeling*, 31-76.

Sipser, M. (2012). *Introduction to the Theory of Computation*. Cengage Learning.

Spirtes, P., Glymour, C. N., Scheines, R., Heckerman, D., Meek, C., Cooper, G., & Richardson, T. (2000). *Causation, prediction, and search*. MIT press.

Steen, L. A. (1988). The science of patterns. *Science*, *240*(4852), 611-616.

Steffe, L. P., Hirstein, J., & Spikes, C. (1976). *Quantitative comparison and class inclusion as readiness variables for learning first grade arithmetic content*. Technical Report No. 9. ERIC Document Reproduction Service No. ED144808. Project for Mathematical Development of Children, Tallahassee, FL.

Stern, E. (1998). *Die Entwicklung des mathematischen Verständnisses im Kindesalter*. Lengerich: Pabst.

Stern, E., & Döbrich, L. (1999). Development of mathematical competencies. *Individual development from*, *3*, 154-170.

Tepeš, B., Lešin, G., Hrkač, A., & Tepeš, K. (2016a). Causal Bayes Model of Mathematical Competence in Kindergarten. *Journal of systemics, cybernetics and informatics*, *14*(3), 14-17.

Tepeš, B., Mrkonjić, I., Paić, G., Tepeš K. (2016b). Causal SEM of mathematical competences in elementary education.101-108

Tepeš, K. (2017). *Prognostički model cestovnih prometnih nesreća za urbana područja.* Doktorska disertacija. Preuzeto dana 10.10.2018. sa: https://dr.nsk.hr/islandora/object/fpz%3A848/datastream/PDF/view

Tucker, A. (2003). A Model Curriculum for K--12 Computer Science: Final Report of the ACM K--12 Task Force Curriculum Committee.

Vakali, M. (1991). Clock time in seven to ten year-old children. *European Journal of Psychology of Education*, *6*, 325–336.

van Deursen, A. J. A. M., & van Dijk, J. A. G. M. (2009). Using the internet: Skill related problems in users' online behavior. *Interacting with Computers*, *21*(5), 393–402.

Van Weert, T., & Tinsley, D. (2000). Information and Communication Technology in Secondary Education. *A Curriculum for Schools, Genf*.

Verdine, B. N., Irwin, C. M., Golinkoff, R. M., & Hirsh-Pasek, K. (2014). Contributions of executive function and spatial skills to preschool mathematics achievement. *Journal of Experimental Child Psychology*, *126*, 37-51.

Watts, T. W., Duncan, G. J., Siegler, R. S., & Davis-Kean, P. E. (2014). What's past is prologue: Relations between early mathematics knowledge and high school achievement. *Educational Researcher*, *43*(7), 352-360.

Wing, J. (2006). Computational thinking. *Communications of the ACM*, *49*(3), 33–36.

Wing, J. (2011). Research notebook: Computational thinking—What and why? *The Link Magazine*, Spring. Carnegie Mellon University, Pittsburgh. Preuzeto 18.7.2018. sa http://link.cs.cmu.edu/article.php?a=600

www.karl-steinbuch.org , pristupljeno dana 03.07.2018.

Wynn, K. (1990). Children's understanding of counting. *Cognition*, *36*(2), 155-193.

PRILOG A

Matematičke kompetencije opisane u NOK-u

Drugi ciklus

Tablica 32. Matematičke kompetencije prema NOK-u tijekom drugog ciklusa obrazovanja

I. MATEMATIČKI PROCESI	
1. Prikazivanje i komunikacija	Učenici će: • prikazati matematičke objekte, ideje, postupke i rješenja riječima, slikama, crtežima, didaktičkim materijalima, dijagramima, grafovima, tablicama, brojevima, simbolima i misaono • odabrati i primijeniti prikladan prikaz u skladu s razmatranom situacijom, povezati različite prikaze i prelaziti s jednih na druge • samostalno se služiti obveznom matematičkom literaturom • izraziti ideje i rezultate govornim i matematičkim jezikom, u skladu s dobi, različitim načinima (usmeno, pisano, vizualno i slično) • saslušati i razmjenjivati matematičke ideje i objašnjenja te suradnički raditi u skupinama.
2. Povezivanje	Učenici će: • uspostaviti veze i odnose među matematičkim objektima, idejama, pojmovima, prikazima i postupcima te oblikovati cjeline njihovim nadovezivanjem • povezati Matematiku s vlastitim iskustvom, svakodnevnim životom i drugim odgojno obrazovnim područjima • usporediti, grupirati i klasificirati objekte i pojave prema određenom kriteriju.
3. Logičko mišljenje, argumentiranje i zaključivanje	Učenici će: • postavljati matematici svojstvena pitanja (Postoji li...? Koliko ima...? Što je poznato? Što trebamo odrediti? Kako ćemo odrediti? Zbog čega? Ima li rješenje smisla? Postoji li više rješenja? i slična) te stvarati i istraživati pretpostavke o matematičkim objektima, pravilnostima i odnosima • obrazložiti odabir matematičkih postupaka i utvrditi smislenost dobivenoga rezultata • zaključivati nepotpunom indukcijom i neformalnom dedukcijom s malim brojem koraka.
4. Rješavanje problema i matematičko modeliranje	Učenici će: • postaviti i analizirati jednostavniji problem, isplanirati njegovo rješavanje odabirom odgovarajućih matematičkih pojmova i postupaka, riješiti ga te protumačiti i vrjednovati rješenje i postupak • primijeniti matematičke pojmove i postupke u različitim kontekstima • izgrađivati novo matematičko znanje rješavanjem problema.
5. Primjena	Učenici će:

tehnologije	• istraživati i učiti Matematiku pomoću džepnih računala i primjerenih računalnih programa • rabiti tehnologiju za crtanje, za prikupljanje, organiziranje i prikazivanje podataka i informacija te u situacijama kojima su u središtu zanimanja matematičke ideje (radi rasterećivanja od računanja).
II. MATEMATIČKI KONCEPTI	
1. Brojevi	Učenici će: • sigurno i učinkovito uspoređivati, zbrajati, oduzimati, množiti i dijeliti prirodne brojeve primjenjujući osnovna svojstva i međusobne veze računskih operacija • primijeniti osnovna svojstva prirodnih brojeva i pravila djeljivosti te rastaviti prirodni broj na proste faktore • pročitati, zapisati i usporediti cijele brojeve, razlomke, decimalne brojeve i postotke te ih prikazati ekvivalentnim zapisima • zbrajati, oduzimati, množiti i dijeliti (napamet, metodama pisanoga računa i uz pomoć džepnoga računala) racionalne brojeve zapisane u obliku razlomaka i decimalnih brojeva te primjenjivati osnovna svojstva i međusobne veze računskih operacija • zaokružiti decimalni broj na potreban broj decimala i procijeniti rezultat računa • primijeniti pozitivne racionalne brojeve i njihove zapise, cijele brojeve te računske operacije u jednostavnim svakodnevnim situacijama.
2. Algebra i funkcije	Učenici će: • na brojevnom pravcu s prikladnom jediničnom dužinom prikazati cijele brojeve i jednostavnije racionalne brojeve zapisane kao razlomak ili decimalni broj • uočiti pravilnosti u svezi s brojevima, njihovim zapisima i računskim operacijama i primjenjivati ih • rabiti opće brojeve (slova) u zapisivanju jednostavnih formula i izraza te umjesto njih uvrstiti konkretne vrijednosti • riješiti jednostavne linearne jednadžbe i uvrštavanjem provjeriti točnost dobivenog rješenja • riješiti jednostavni problemski zadatak zadan riječima upotrebom algebarskih simbola (brojevna rečenica, formula, linearna jednadžba) • prepoznati proporcionalne veličine te primjenjivati omjere i proporcionalnost u jednostavnim svakodnevnim situacijama.
3. Oblik i prostor	Učenici će: • služiti se geografskim kartama i jednostavnim koordinatama u ravnini (kvadratna mreža) te odrediti udaljenost dviju točaka na brojevnom pravcu • prepoznati, imenovati, izgraditi, usporediti i klasificirati ravninske i prostorne geometrijske oblike te istražiti, uočiti, opisati i primijeniti njihova geometrijska svojstva

	• skicirati jednostavne ravninske oblike te ih nacrtati i konstruirati pomoću geometrijskog pribora i jednostavnoga računalnoga programa za crtanje • nacrtati i konstruirati osnosimetričnu i centralnosimetričnu sliku jednostavnih ravninskih likova te prepoznati sukladne trokute, centralnosimetrične i osnosimetrične likove • istražiti i predvidjeti ishode sastavljanja i rastavljanja složenijih ravninskih i prostornih oblika rabeći stvarne materijale • rabeći makete te kvadratne i trokutaste mreže točaka, skicirati prostorne oblike sastavljene od kocaka i njihove tlocrte, nacrte i bokocrte • prepoznati geometrijske oblike, sukladnost i simetriju u svijetu oko sebe te ih primjenjivati.
4. Mjerenje	Učenici će: • usporediti, procijeniti i izmjeriti duljinu, obujam, masu, vrijeme, temperaturu i kut • preračunati standardne mjerne jedinice za duljinu, površinu, obujam, masu, vrijeme, temperaturu i kut te ih primijeniti u svakodnevnomu životu • računati s novcem u svakodnevnim situacijama • približno i točno odrediti udaljenost dviju točaka, površinu likova i obujam jednostavnih tijela brojanjem jediničnih dužina, kvadrata i kocaka te prelijevanjem tekućine • neizravno izmjeriti duljinu koristeći se proporcionalnošću (mjerilo karte) • primijeniti formule za opseg, površinu i zbroj unutarnjih kutova trokuta i četverokuta te obujam kocke i kvadra • odrediti mjeriva obilježja objekta ili pojave u svakodnevnim situacijama i primijeniti mjerenje pri rješavanju problema.
5. Podatci	Učenici će: • prikupiti, razvrstati i organizirati podatke te ih na prikladan način prikazati tablicom, tablicom frekvencija, piktogramom, stupčastim i kružnim dijagramom te sustavnom listom • pročitati i protumačiti podatke prikazane tablicama, slikama, listama te različitim grafovima i dijagramima • odrediti broj svih mogućih i, za dani događaj, povoljnih ishoda u jednostavnim situacijama • primjenjivati jezik vjerojatnosti (ishod, događaj, suprotan događaj, slučajni pokus, moguć, nemoguć, siguran, slučajan, nasumičan, vjerojatan, šansa, vjerojatnost i dr.) • procijeniti i izračunati vjerojatnost događaja u jednostavnim situacijama te ju prikazati u obliku razlomka, decimalnoga broja i postotka.

Treći ciklus

Tablica 33. Matematičke kompetencije prema NOK-u tijekom trećeg ciklusa obrazovanja

I. MATEMATIČKI PROCESI	
1. Prikazivanje i komunikacija	Učenici će: • organizirano prikazati matematičke objekte, ideje, postupke i rješenja riječima, slikama, crtežima, maketama, dijagramima, grafovima, listama, tablicama, brojevima, simbolima i misaono • odabrati i primijeniti prikladan prikaz u skladu sa situacijom i namjerom, povezati različite prikaze i prelaziti s jednih na druge • prikupiti i tumačiti informacije primjerena matematičkoga sadržaja iz raznovrsnih izvora • izraziti ideje, rezultate i znanje jasnim govornim i matematičkim jezikom različitim načinima (usmeno, pisano, vizualno i dr.) • raditi u skupinama uz razmjenu i sučeljavanje ideja, mišljenja i stavova.
2. Povezivanje	Učenici će: • uspostaviti i razumjeti veze i odnose među matematičkim objektima, idejama, pojmovima, prikazima i postupcima te oblikovati cjeline njihovim nadovezivanjem • povezati Matematiku s vlastitim iskustvom, svakodnevnim životom u kući i zajednici te drugim odgojno-obrazovnim područjima • usporediti, grupirati i klasificirati objekte i pojave prema zadanomu ili izabranomu kriteriju.
3. Logičko mišljenje, argumentiranje i zaključivanje	Učenici će: • postavljati matematici svojstvena pitanja (Postoji li? Ako postoji, koliko? Kako ćemo ih pronaći? Zbog čega? i slična) te stvarati i istraživati na njima zasnovane matematičke pretpostavke • obrazložiti odabir matematičkih postupaka i utvrditi smislenost dobivenoga rezultata • pratiti i stvarati kraće lance matematičkih argumenata, zaključivati nepotpunom indukcijom i neformalnom dedukcijom te primjenjivati analogiju, generalizaciju i specijalizaciju u jednostavnim situacijama.
4. Rješavanje problema i matematičko modeliranje	Učenici će: • postaviti i analizirati jednostavniji problem, isplanirati njegovo rješavanje odabirom odgovarajućih matematičkih pojmova i postupaka, riješiti ga te protumačiti i vrjednovati rješenje i postupak • primijeniti matematičke pojmove i postupke u različitim kontekstima • izgrađivati novo matematičko znanje rješavanjem problema i modeliranjem situacija.

5. Primjena tehnologije	Učenici će: • istraživati i analizirati matematičke ideje, eksperimentirati s njima te provjeravati pretpostavke pomoću džepnih računala i raznovrsnih računalnih programa, osobito programa dinamične geometrije i programa za izradu proračunskih tablica • razložno i učinkovito rabiti tehnologiju za prikupljanje, organiziranje, prikazivanje, predstavljanje i razmjenu podataka i informacija, za rješavanje problema i modeliranje te u situacijama kojima su u središtu zanimanja matematičke ideje (radi rasterećivanja od računanja i grafičkoga prikazivanja) • razumjeti prednosti i nedostatke primjene tehnologije.
II. MATEMATIČKI KONCEPTI	
1. Brojevi	Učenici će: • sigurno i učinkovito uspoređivati, zaokruživati, zbrajati, oduzimati, množiti, dijeliti, kvadrirati i korjenovati realne brojeve zapisane u decimalnomu zapisu i u obliku razlomka • pretvoriti razlomak u decimalni zapis s danom preciznošću • računati s cjelobrojnim potencijama broja 10 i rabiti znanstveni zapis • odabrati prikladan način računanja (napamet, metodama pisanoga računa i uz pomoć džepnoga računala) • procijeniti smislenost i točnost rezultata računanja • primijeniti realne brojeve, njihove zapise i računske operacije u rješavanju jednostavnih matematičkih problema i problema u svakodnevnomu životu.
2. Algebra i funkcije	Učenici će: • primijeniti postotke i postotni račun u konkretnim situacijama • uvrstiti konkretne vrijednosti u formulu i izračunati vrijednost preostale veličine • prepoznati i primijeniti proporcionalnost i obrnutu proporcionalnost u jednostavnim situacijama • prikazati jednostavnu ovisnost dviju veličina (linearna, čista kvadratna, drugi korijen) riječima, tablicom pridruženih vrijednosti, formulom i grafički, opisati takve prikaze te ih prevesti s jednoga na drugi • riješiti linearne jednadžbe i jednostavne sustave dviju linearnih jednadžbi s dvije nepoznanice te uvrštavanjem provjeriti točnost dobivenoga rješenja • prevesti jednostavan problem u algebarske simbole (brojevna rečenica, linearna jednadžba, sustav dviju linearnih jednadžbi), isplanirati njegovo rješavanje, riješiti ga i utvrditi smislenost dobivenoga rješenja.
3. Oblik i prostor	Učenici će: • nacrtati u pravokutnom koordinatnom sustavu u ravnini točku zadanu koordinatama i pravac zadan jednadžbom te očitati koordinate točke • prepoznati, imenovati, izgraditi i klasificirati ravninske i prostorne geometrijske

	oblike te istražiti, uočiti i precizno opisati njihova geometrijska svojstva • primijeniti osnovne odnose i zakonitosti u svezi s ravninskim i prostornim geometrijskim oblicima, uključujući sukladnost i sličnost trokuta • skicirati ravninske oblike te jednostavnije među njima nacrtati i konstruirati pomoću geometrijskoga pribora i računalnoga programa dinamične geometrije • skicirati i nacrtati tlocrte, nacrte, bokocrte i mreže prostornih oblika te izgraditi prostorne oblike na temelju njihovih ravninskih prikaza • osnosimetrično i centralnosimetrično preslikati, translatirati i rotirati jednostavne likove, povećati i smanjiti jednostavni lik u zadanu omjeru rabeći geometrijski pribor i računalni program dinamične geometrije • prepoznati ravninske i prostorne oblike te sukladnost, sličnost i simetriju u svakodnevnomu okružju i umjetnosti te ih upotrijebiti za opis i analizu svijeta oko sebe.
4. Mjerenje	Učenici će: • usporediti, procijeniti i izmjeriti duljinu, obujam, masu, vrijeme, temperaturu i kut te izračunati površinu i prosječnu brzinu • preračunati standardne mjerne jedinice za duljinu, površinu, obujam, masu, vrijeme, temperaturu, kut i prosječnu brzinu te ih primijeniti u svakodnevnomu životu • neizravno izmjeriti duljinu primjenjujući proporcionalnost i sličnost • primijeniti Pitagorin poučak i druge osnovne formule u svezi s mjerivim obilježjima jednostavnih likova i tijela • odrediti mjeriva obilježja objekta ili pojave u svakodnevnim situacijama, odabrati primjerene mjerne jedinice i mjerne uređaje te primijeniti mjerenje pri rješavanju problema.
5. Podatci	Učenici će: • prikupiti, klasificirati i organizirati podatke te ih na prikladan način, pomoću računala i bez njega, prikazati sustavnom listom, tablicom, tablicom frekvencija, linijskim, stupčastim i kružnim dijagramom, grafikonom, „brkatom kutijom“ („box and whiskers” dijagram) i grafom • pročitati, tumačiti i analizirati podatke prikazane na različite načine • odrediti i primijeniti frekvenciju i relativnu frekvenciju za dane podatke te aritmetičku sredinu, medijan, kvartile, mod, raspon i interkvartilni raspon niza numeričkih podataka • argumentirano i učinkovito odrediti broj mogućih i povoljnih ishoda u jednostavnim situacijama i izračunati vjerojatnost • procijeniti vjerojatnost konkretnog slučajnog događaja tumačeći ju kao relativnu frekvenciju.

PRILOG B

Informatičke kompetencije opisane u NOK-u

Drugi ciklus

Tablica 34. Informatičke komptencije opisane u NOK-u tijekom drugog ciklusa obrazovanja

III. INFORMACIJSKA I KOMUNIKACIJSKA TEHNOLOGIJA	
1. Osnove informacijske i komunikacijske tehnologije	Učenici će: • obrazložiti razliku između pojmova: znanje, informacija i podatak • opisati načine pohranjivanja i prenošenje podataka u bližoj i daljnjoj prošlosti • opisati da se današnja tehnologije za pohranjivanje i prijenos podataka zasniva na prikazivanju svih oblika podataka u digitalnomu obliku nizom bitova.
2. Strojna i programska oprema računala	Učenici će: • imenovati osnovne sklopovske dijelove računala (središnji ili radni spremnik, procesor, pomoćni spremnici, ulazno-izlazne naprave) • protumačiti da je operacijski sustav osnovni program koji osigurava skladno djelovanje svih dijelova računala • zaključiti da se svi programi i svi podatci, koje treba trajno pohraniti, moraju nalaziti pohranjeni u datotekama smještenima na vanjskim memorijama • upotrebljavati grafičko sučelje za organizirano pohranjivanje i dohvat datoteka te razlikovati vrste datoteka prema sadržaju • opisati da računala komuniciraju tako da se sadržaji spremnika jednog računala prenose u spremnik drugoga računala prijenosnim putovima, i tako nastaju računalne mreže • zaključiti da je u svjetskim razmjerima dogovoren normirani način prijenosa zasebnih podatkovnih cjelina.
3. Internet i mrežne usluge	Učenici će: • rabiti programska pomagala (preglednike) za pretragu sadržaja na mrežnim stranicama smještenima na kojemu od računala priključena na Internet • pregledavati sadržaje dobavljenih stranica i kretati se poveznicama u srodnomu skupu stranica • rabiti programska pomagala za pripremanje i slanje poruka elektroničkom poštom • poštivati etička načela pri korištenju elektroničke i društvenih mreža.
4. Obradba zvuka, crteža i slika	Učenici će: • koristiti se programima za crtanje i pomoću njih oblikovati vlastite crteže

	koristeći se programskim alatima za odabir debljine kista i izbor boja • stvarati nove crteže sklapanjem i sastavljanjem (kombiniranjem) dijelova ranije pohranjenih crteža • uporabom mikrofona povezana sa zvučnom karticom snimati i pohranjivati zvučne zapise • stvoriti zbirku (album) audiozapisa i prenijeti ju na koju napravu za reprodukciju zvuka • stvoriti zbirku videozapisa i izvoditi video zapise kojim od programa za izvođenje.
5.Obradba teksta	Učenici će: • rabiti napredni program za obradu teksta te se koristiti različitim raspoloživim postupcima za uređivanje teksta • oblikovati izgled stranice mijenjanjem širina rubnica te umetanjem simbola, broja stranica, zaglavlja i podnožja • pripremati tekst raspoređen u više stupaca, s umetanjem crteža i tablica • pisačem ispisivati pripremljeni tekst.
IV. RJEŠAVANJE PROBLEMA POMOĆU RAČUNALA	
1. Osnove programiranja	Učenici će: • upotrebljavati naprednije naredbe i programske oblike kornjačine grafike za rješavanje složenijih zadataka uz primjenu znanja iz Matematike • stvarati jednostavne programe koji će se sastojati od naredbi ulaznoga dijela kojim se unose podatci, naredbi središnjega dijela u kojemu se obavlja računanje i naredbi izlaznoga dijela u kojemu se ishod izračunavanja predočuje čovjeku • upotrijebiti interaktivni programski jezik za pisanje i ispitivanje jednostavnih slijednih programa • prepoznati da se niz naredbi, koje se češće pojavljuju u programu, može pripremiti kao potprogram koji se pokreće (poziva) kada je potrebno • utvrditi da se svaki program mora ispitati kako bi se utvrdila njegova ispravnost.

Treći ciklus

Tablica 35. Informatičke kompetencije opisane u NOK-u tijekom trećeg ciklusa obrazovanja

III. INFORMACIJSKA I KOMUNIKACIJSKA TEHNOLOGIJA	
1. Osnove informacijske i komunikacijske tehnologije	Učenici će: • otkriti da informacijski i komunikacijski sustavi omogućuju razmjenjivanje informacija između ljudi, između ljudi i strojeva te između samih strojeva • protumačiti da se komunikacijski sustav sastoji od izvorišta, prijenosnoga puta i odredišta, • prepoznati da se informacije moraju prikladno kodirati i prenositi po dogovorenim pravilima, tzv. protokolima.
2. Strojna i programska oprema računala	Učenici će: • prepoznati da su komponente računala sastavljene od digitalnih mikroelektroničkih sklopova • vrjednovati svojstva računala međusobno ih uspoređujući (brzina rada procesora, broj i duljina registara, veličina spremnika, kapacitet diskova, brzina prijenosa između pojedinih dijelova računala i slično) • ocijeniti veličinu diskovnoga potrebnoga prostora za smještanje multimedijskih sadržaja te potrebne brzine za njihov prijenos u stvarnomu vremenu.
3. Internet i mrežne usluge	Učenici će: • prepoznati strukturu Interneta te načine i brzine komuniciranja u njemu • vrjednovati kakvoću sadržaja te obrađivati sadržaje pribavljene Internetom • objasniti načine usluga kupovanja roba i usluga posredstvom Interneta.
4. Izradba računalnih prezentacija	Učenici će: • programskim pomagalom za pripremanje prezentacije izrađivati slajdove s tekstom, vlastitim crtežima i crtežima i slikama iz galerija, te audio i video zapisima • dodavati animacijske efekte na slajdove • pripremiti prezentaciju za izvođenje i ostvariti ju.
5. Izradba mrežnih stranica	Učenici će: • pripremati jednostavne mrežne stranice s tekstovima i grafičkim sadržajima služeći se programskim pomagalom za pripremu • objavljivati pripremljene stranice • povezivati stranice poveznicama.
IV. RJEŠAVANJE PROBLEMA POMOĆU RAČUNALA	
1. Osnove programiranja	Učenici će:

	• koristiti se programskim strukturama za donošenje odluka i ostvarenje grananja u programima • upotrebljavati programske petlje u kojima se isti niz naredbi ponavlja do ispunjenja zadana uvjeta • prepoznati da potprogrami mogu pozivati druge potprograme te da je za rješavanje određenih problema korisno da pozivaju i sami sebe.
2. Proračunske tablice i baze podataka	Učenici će: • prepoznati osnovne elemente prozora koji se koristi kao radna površina programskoga pomagala za tablično računanje • oblikovati tablice (mijenjati dimenzije redaka i stupaca, mijenjati veličine i oblike znakova, obrubljivati tablice) • upotrebljavati prikladne formate brojeva • obavljati tablična izračunavanja uporabom formula • upotrebljavati tablice za različite primjene.
3. Interdisciplinarne primjene	Učenici će: • pripremiti svoje vlastite programe u kojima će rješavati jednostavne matematičke zadatke odnosno primijeniti znanja stečena u matematici • pripremiti programe koji pokazuju primjenu računala za rješavanje jednostavnih zadataka u nastavi fizike, kemije, biologije i ostalih predmeta.

PRILOG C

Nastavni plan i program za predmet Matematika u višim razredima

5. RAZRED

Tablica 36. Nastavni plan za predmet Matematika za peti razred

Tema	***Obrazovna postignuća***
1. Prirodni brojevi	zapisivati i čitati prirodne brojeve i veće od 1 000 000; usvojiti svojstva prirodnih brojeva: broj 1 najmanji je prirodni broj, broj nula nije prirodni broj, ne postoji najveći prirodni broj.
2. Uspoređivanje prirodnih brojeva	usporediti dva prirodna broja; usvojiti postupak zaokruživanja zadanih prirodnih brojeva do zadane dekadske jedinice.
3. Zbrajanje prirodnih brojeva	usvojiti postupak zbrajanja prirodnih brojeva uz uporabu procjene, postupak i svojstva zbrajanja znati primijeniti u zadatcima iz životnih situacija.
4. Oduzimanje prirodnih brojeva	usvojiti postupak oduzimanja prirodnih brojeva uz uporabu procjene.
5. Množenje prirodnih brojeva	usvojiti postupak pisanoga množenja prirodnih brojeva uz uporabu procjene; množenje s 10, 100, 1000.
6. Osnovna svojstva množenja	razumjeti i primjenjivati komutativnost, asocijativnost i distributivnost množenja; uočiti kada je primjenom tih svojstava postupak računanja kraći, lakši i jednostavniji.
7. Dijeljenje prirodnih brojeva	usvojiti postupak dijeljenja s dvoznamenkastim brojem; znati upotrebljavati vezu između množenja i dijeljenja uz procjenu rezultata; uočiti problem broja nule pri dijeljenju.
8. Izvođenje više računskih radnji	uvježbati računske radnje s prirodnim brojevima uz poštovanje redoslijeda računskih radnji i prioriteta zagrada; uključiti zadatke s pretvaranjem mjernih jedinica; primjenjivati stečena znanja u zadatcima iz životnih situacija
9. Uporaba džepnoga računala	osposobiti učenike za uporabu standardiziranoga džepnog računala u jednostavnim računima uz uporabu procjene rezultata.
10. Djelitelj i višekratnik	razlikovati pojmove višekratnik, djelitelj, biti djeljiv i znati za zadani prirodni broj manji od 1000 odrediti djelitelje i nabrojiti nekoliko višekratnika
11. Svojstva djeljivosti	uočiti djeljivost zbroja (razlike) brojeva brojem kojim je djeljiv svaki od tih brojeva; uočiti djeljivost umnoška zadanih faktora brojem kojim je djeljiv barem jedan od faktora.
12. Djeljivost s 10, 5, 2, 3, 9	usvojiti i primjenjivati pravila djeljivosti s 10, 5, 2, 3 i 9.
13. Prosti i složeni brojevi	razlikovati proste i složene brojeve; odrediti je li zadani broj prost ili složen.

14. Rastavljanje broja na proste faktore	zadani broj rastaviti na proste faktore
15. Zajednički djelitelji. Najveći zajednički djelitelj	usvojiti postupak određivanja zajedničkih djelitelja, najvećega zajedničkoga djelitelja i prepoznavati relativno proste brojeve.
16. Zajednički višekratnici. Najmanji zajednički višekratnik	usvojiti postupak određivanja zajedničkih višekratnika i najmanjega zajedničkog višekratnika za dva zadana broja.
17. Pravac, polupravac, dužina	crtati i označavati dužinu, polupravac i pravac, istražiti međusobni položaj dvaju pravaca; razviti sposobnost mjerenja duljine dužine, preračunavati mjerne jedinice za duljinu i procjenjivati mjere; primjenjivati stečeno znanje; crtati okomite i usporedne pravce s pomoću dvaju trokuta; crtati prugu.
18. Simetrala dužine	crtati i definirati simetralu dužine i polovište dužine; razumjeti, analizirati i primjenjivati svojstva simetrale dužine.
19. Kružnica i krug	crtati, označivati i definirati kružnicu i krug, te njihov polumjer, promjer, tetivu, kružni luk, polukrug, kružni isječak i odsječak te kružni vijenac.
20. Paralelogram	definirati, crtati paralelogram te mu označivati vrhove, stranice i kutove; na osnovi uočenoga svojstva stranica paralelograma i veličina njegovih kutova definirati kvadrat, pravokutnik i romb; primjenjivati stečena znanja na zadatcima iz životnih situacija; izračunavati opseg paralelograma, opseg i površinu pravokutnika i kvadrata; preračunavati mjerne jedinice za površinu.
21. Kut. Mjerenje kutova	crtati različite kutove s pomoću kutomjera, isticati ih i označivati; mjeriti veličine kutova; uočavati razlike između različitih vrsta kutova.
22. Sukuti i vršni kutovi	: prepoznavati i crtati sukute i vršne kutove te izračunavati mjeru kuta ako je poznata mjera sukuta.
23. Trokut i vrste trokuta	crtati trokut, pravilno ga označivati; razlikovati i imenovati vrste trokuta; crtati jednakokračni i jednakostranični trokut te pravokutni trokut s pomoću dvaju trokuta; konstruirati trokutu opisanu kružnicu; izračunavati opseg trokuta.
24. Osnosimetrični likovi	uočavati i razlikovati osnosimetrične likove na crtežu i u našem okruženju.
25. Razlomci	vizualizirati pojam razlomka; uočavati ekvivalenciju između dijeljenja i razlomka; usvojiti način zapisivanja i čitanja razlomka te značenje brojnika i nazivnika; usvojiti način zapisivanja i čitanja razlomka u obliku mješovitoga broja; pretvarati razlomak u mješoviti broj i obratno.
26. Uspoređivanje, zbrajanje i oduzimanje	istražiti koji je od dvaju razlomaka jednakih nazivnika veći; znati je li zadani razlomak veći ili manji od 1; usvojiti postupak zbrajanja i oduzimanja razlomaka jednakih nazivnika.

razlomaka jednakih nazivnika	
27. Proširivanje i skraćivanje razlomaka	usvojiti postupak proširivanja razlomka zadanim brojem te uočavati koji je razlomak skrativ; usvojiti postupak skraćivanja razlomka do neskrativoga razlomka; primjenjivati stečeno znanje u rješavanju zadataka u životnim situacijama.
28. Decimalni razlomci	istražiti i usvojiti pojam decimalnoga broja; usvojiti postupak za pretvaranje zadanoga decimalnoga broja u decimalni razlomak i obratno; uvježbati čitanje i pisanje decimalnih brojeva.
29. Prikazivanje decimalnih brojeva na pravcu	smještati decimalne brojeve s jednom decimalom na brojevni pravac.
30. Uspoređivanje decimalnih brojeva	istražiti koji je od dvaju decimalnih brojeva veći; poredati tri ili više decimalnih brojeva po veličini.
31. Zaokruživanje decimalnih brojeva	zaokruživati decimalne brojeve do zadanoga broja decimala, procjenjivati rezultat.
32. Zbrajanje i oduzimanje decimalnih brojeva	usvojiti postupak zbrajanja i oduzimanja decimalnih brojeva; rabiti računanje i procjenu u rješavanju zadataka iz svakidašnjice.
33. Množenje i dijeljenje decimalnih brojeva dekadskim jedinicama	usvojiti postupke množenja i dijeljenja decimalnih brojeva dekadskim jedinicama; rabiti procjenu rješenja prije računanja; primjenjivati stečeno znanje na preračunavanje mjernih jedinica.
34. Množenje decimalnih brojeva	usvojiti postupak množenja decimalnih brojeva na jednostavnijim brojevima, te nakon izvođenja operacije rezultat usporediti s procjenom rezultata i rezultatom dobivenim džepnim računalom.
35. Dijeljenje decimalnih brojeva prirodnim brojevima	usvojiti postupak dijeljenja decimalnoga broja prirodnim brojem te dobiveni rezultat usporediti s procjenom rješenja; usvojiti postupak prikazivanja razlomaka u obliku decimalnoga broja; rabiti pisano računanje, računanje džepnim računalom i procjenu za rješavanje zadataka iz svakidašnjice.
36. Dijeljenje decimalnih brojeva decimalnim brojevima	usvojiti postupak dijeljenja decimalnoga broja decimalnim brojem te dobiveni rezultat usporediti s procjenom rješenja; rabiti pisano računanje, računanje džepnim računalom i procjenu za rješavanje zadataka iz svakidašnjice

6. RAZRED

Tablica 37. Nastavni plan za predmet Matematika za šesti razred

Tema	***Obrazovna postignuća***
1. Svođenje razlomaka na zajednički nazivnik	usvojiti postupak svođenja dvaju razlomaka na najmanji zajednički nazivnik i primjenjivati stečeno znanje pri rješavanju zadataka.
2. Uspoređivanje razlomaka	poredati po veličini i uspoređivati razlomke s različitim nazivnicima (do 100).
3. Brojevni pravac	organizirati brojevni pravac, procijeniti i odrediti između kojih se dvaju prirodnih brojeva nalazi zadani razlomak; na brojevni pravac smještati točke pridružene zadanim razlomcima s nazivnikom manjim od 10.
4. Zbrajanje i oduzimanje razlomaka	usvojiti postupak zbrajanja i oduzimanja razlomaka različitih nazivnika; izračunavati jednostavnije brojevne izraze; stečena znanja razumjeti i primjenjivati na rješavanje zadataka iz svakidašnjice.
5. Množenje razlomaka	razumjeti i usvojiti postupak množenja razlomaka; stečeno znanje primjenjivati; snalažljivo i točno računati koristeći svojstva množenja.
6. Dijeljenje razlomaka	uvesti pojam recipročnoga broja; razumjeti i usvojiti postupak dijeljenja razlomaka; rabiti pisano računanje, računanje džepnim računalom i procjenu rješenja zadataka iz svakidašnjice.
7. Kutovi uz presječnicu usporednih pravaca	definirati pojam presječnice; prepoznati kutove uz presječnicu i njihova svojstva te stečeno znanje primjenjivati na rješavanju zadataka.
8. Kutovi s usporednim i okomitim kracima	prepoznavati, uspoređivati i uspostavljati veze među kutovima s usporednim ili okomitim kracima.
9. Trokut. Odnos stranica i kutova trokuta	razlikovati vrste trokuta; istražiti i primjenjivati pravilo odnosa kutova i stranica u trokutu.
10. Zbroj kutova trokuta	dokazati i usvojiti tvrdnju da je zbroj mjera (veličina) kutova u trokutu 180°; izračunavati veličinu nepoznatoga kuta trokuta.
11. Simetrala kuta	usvojiti pojam simetrale kuta; konstruirati simetralu te istražiti njezina svojstva; konstruirati trokutu upisanu kružnicu.
12. Konstrukcija kutova od 60°, 30°, 90°, 45°	konstruirati kutove primjenjujući svojstva simetrale kuta; prenositi zadane kutove.
13. Sukladnost trokuta	istražiti i usvojiti pojam sukladnosti trokuta; usvojiti simbol sukladnosti; znati riješiti jednostavnije zadatke primjenom znanja o sukladnosti trokuta.
14. Tri osnovne konstrukcije trokuta	skicirati, analizirati i konstruirati trokut te raspraviti rješenje

15. Površina trokuta	usvojiti pojam visine trokuta i crtati visine kod svih vrsta trokuta; koristeći znanje o površini pravokutnika, zornim prikazom doći do formule za površinu trokuta; izračunavati površinu trokuta ako mu je poznata duljina stranice i duljina visine na tu stranicu; stečeno znanje primjenjivati u zadatcima iz svakidašnjice.
16. Cijeli brojevi	razlikovati pozitivne i negativne cijele brojeve i prepoznavati ih u primjerima iz svakidašnjice.
17. Prikazivanje cijelih brojeva na pravcu	smještati cijele brojeve na brojevni pravac.
18. Suprotni brojevi. Apsolutna vrijednost	razumjeti pojam suprotni broj; određivati apsolutnu vrijednost cijeloga broja; određivati cijele brojeve ako je zadana njihova apsolutna vrijednost.
19. Uspoređivanje cijelih brojeva	zadane cijele brojeve poredati po veličini.
20. Zbrajanje cijelih brojeva	usvojiti postupak zbrajanja cijelih brojeva, postupak i svojstva zbrajanja primjenjivati u zadatcima iz životnih situacija.
21. Oduzimanje cijelih brojeva	usvojiti postupak oduzimanja cijelih brojeva, primjenjivati znanje pri rješavanju jednostavnijih zadataka.
22. Rad sa zagradama	ovladati postupkom izračunavanja izraza sa zagradama.
23. Množenje cijelih brojeva	odrediti umnožak cijelih brojeva; prepoznavati zajednički faktor u jednostavnijim zadatcima i izlučiti ga; primjenjivati stečeno znanje u rješavanju zadataka iz svakidašnjice.
24. Dijeljenje cijelih brojeva	odrediti količnik dvaju cijelih brojeva; rabiti pisano računanje, računanje džepnim računalom i procjenu pri rješavanju zadataka iz svakidašnjice.
25. Pozitivni i negativni racionalni brojevi	prepoznati i razlikovati pozitivne i negativne racionalne brojeve; zapisivati racionalne brojeve (u obliku razlomka i decimalnog broja).
26. Prikazivanje racionalnih brojeva na pravcu	organizirati brojevni pravac, procjenjivati i određivati između kojih se dvaju cijelih brojeva nalazi zadani racionalni broj; na brojevni pravac smještati točke pridružene zadanim racionalnim brojevima s nazivnikom manjim od 10.
27. Uspoređivanje racionalnih brojeva	uspoređivati racionalne brojeve zapisane u obliku razlomaka ili decimalnoga broja i primjenjivati stečeno znanje na primjerima iz svakidašnjice
28. Zbrajanje i oduzimanje racionalnih brojeva	usvojiti postupke zbrajanja i oduzimanja racionalnih brojeva; izračunavati jednostavnije brojevne izraze; postupak, svojstva zbrajanja i procjenu primijeniti u zadatcima iz životnih situacija.
29. Množenje i dijeljenje racionalnih brojeva	usvojiti postupke za množenje i dijeljenje racionalnih brojeva; upotrebljavati i primjenjivati stečeno znanje.
30. Jednadžba oblika ax + b = 0	rješavati jednadžbe oblika $ax + b = 0$ i jednostavnije jednadžbe koje se mogu svesti na taj oblik; usvojiti pojam rješenja jednadžbe; provjere rješenja; objasniti postupak

	rješavanja.
31. Primjena linearne jednadžbe	razvijati razumijevanje i analiziranje problemskih zadataka; upotrebljavati usvojeno znanje i moći zapisati jednostavnije probleme u obliku linearne jednadžbe s jednom nepoznanicom
32. Četverokut	prepoznavati, crtati i pravilno označivati četverokut; crtati dijagonale četverokuta; razlikovati vrste četverokuta; analizirati njihova svojstva; prepoznavati ih u okolini.
33. Zbroj kutova u četverokutu	usvojiti i objasniti tvrdnju da je zbroj veličina (mjera) kutova u četverokutu 360°; izračunavati veličinu nepoznatoga kuta.
34. Konstrukcije paralelograma	primjenjujući svojstva paralelograma, skicirati, analizirati i crtati ili konstruirati paralelogram te raspraviti rješenje.
35. Površina paralelograma i trapeza	zornim prikazom, koristeći znanje o površini trokuta i pravokutnika, doći do formule za površinu paralelograma i trapeza; procjenjivati i izračunavati površinu paralelograma i trapeza u jednostavnijim zadatcima iz svakidašnjice.

7. RAZRED

Tablica 38. Nastavni plan za predmet Matematika za sedmi razred

Tema	***Obrazovna postignuća***
1. Koordinatni sustav na pravcu	znati racionalnim brojevima pridruživati točke brojevnoga pravca.
2. Pravokutni koordinatni sustav u ravnini	određivati točke koordinatne ravnine ako su im zadane koordinate i obratno; očitati koordinate zadane točke.
3. Omjer i proporcija (razmjer)	određivati bilo koji nepoznati član proporcije koristeći osnovno svojstvo proporcije.
4. Proporcionalne veličine	prepoznavati proporcionalne veličine u zadatcima iz svakidašnjice.
5. Primjena proporcionalnosti na rješavanje problema iz svakidašnjice	primjenjivati matematički postupak na zadatke iz svakidašnjice.
6. Grafički prikaz proporcionalnosti	grafički prikazivati proporcionalnost; iz zadanoga grafičkog prikaza očitavati vrijednosti, tj. koordinate točke.
7. Obrnuta proporcionalnost	prepoznavati obrnuto proporcionalne veličine na primjerima iz svakidašnjice; određivati razmjerom i formulom nepoznate veličine u zadatcima
8. Postotak. Računanje s postotcima	računati s postotcima te ih primjenjivati na zadatke iz znanosti i svakodnevnoga života.
9. Jednostavni kamatni račun	određivati kamate i primjenjivati ih na zadatke iz svakidašnjice.
10. Prikazivanje i analiza podataka	prepoznati obilježje skupa objekata, određivati vrijednosti tog obilježja; prikazivati prikupljene podatke o tom obilježju s pomoću tablice frekvencija i relativnih frekvencija te grafički s pomoću stupčastoga dijagrama i kružnoga dijagrama; izračunavati aritmetičku sredinu te interpretirati dobivene podatke
11. Vjerojatnost slučajnoga događaja	navesti elementarne događaje, prepoznavati koji su elementarni događaji povoljni za zadani događaj, izračunavati vjerojatnost događaja.
12. Dijeljenje dužine na jednake dijelove i u zadanom omjeru	dijeliti dužinu na jednake dijelove i u zadanom omjeru.
13. Sličnost trokuta i primjena	usvojiti pojam sličnosti trokuta; znati poučke o sličnosti trokuta; izračunavati duljine stranica sličnih trokuta; izračunavati opseg i površinu sličnih trokuta.
14. Mnogokut	usvojiti pojam mnogokuta i crtati mnogokut; određivati ukupni broj dijagonala

	mnogokuta; određivati zbroj veličina kutova mnogokuta.
15. Pravilni mnogokuti	istaknuti karakteristični trokut u pravilnom mnogokutu, konstruirati pravilne mnogokute sa 6, 8 i 12 stranica; crtati pravilni peterokut s pomoću karakterističnoga trokuta služeći se kutomjerom.
16. Opseg i površina mnogokuta	izračunavati opseg i površinu mnogokuta.
17. Kružnica i krug	razlikovati pojmove kružnice i kruga; znati da je kružnica određena trima točkama koje nisu na istom pravcu; određivati međusobni položaj dviju kružnica.
18. Odnos središnjega i obodnoga kuta. Talesov poučak.	znati da je obodni kut jednak polovini pripadnoga središnjega kuta; usvojiti činjenicu da je svaki obodni kut nad promjerom kružnice pravi kut
19. Pravac i kružnica	usvojiti da pravac i kružnica mogu imati dvije zajedničke točke, jednu zajedničku točku ili da nemaju nijednu zajedničku točku; konstruirati tangente kružnice u njezinoj točki.
20. Opseg kruga	izračunavati opseg kruga i primjenjivati znanje na zadatke iz svakidašnjice.
21. Kružni luk	izračunavati duljinu kružnoga luka
22. Površina kruga	izračunavati površinu kruga; primjenjivati znanje na rješavanje zadataka iz svakidašnjice; izračunavati površinu kružnoga isječka.
23. Sustav linearnih jednadžbi	provjeravati je li zadani uređeni par rješenje sustava
24. Metoda supstitucije	usvojiti metodu supstitucije; načiniti provjeru rješenja.
25. Metoda suprotnih koeficijenata	usvojiti postupak metode suprotnih koeficijenata; načiniti provjeru rješenja.
26. Primjena sustava linearnih jednadžbi	u zadanim primjerima samostalno odrediti koja od dviju metoda dovodi do jednostavnijega načina rješavanja; svoditi problemske zadatke na rješavanje sustava dviju jednadžbi; izreći, zapisivati i provjeravati rješenje te ga po potrebi raspraviti.
27. Linearna funkcija	usvojiti način zapisivanja funkcije; izračunavati vrijednosti funkcije; primjenjivati znanje na rješavanje zadataka iz svakidašnjice.
28. Graf linearne funkcije, jednadžba pravca	crtati graf linearne funkcije i iz nacrtanoga grafa iščitavati vrijednost funkcije; procjenjivati i provjeravati (računski i grafički) pripada li zadana točka grafu funkcije; određivati nultočke zadane linearne funkcije računski i grafički; opisivati ovisnost dviju veličina s pomoću tablice i grafa
29. Tok linearne funkcije	usvojiti značenje nagiba pravca i odsječka na osi y i njihovu geometrijsku interpretaciju; ispitivati rast ili pad linearne funkcije prema nagibu pravca.
30. Grafičko rješavanje sustava linearnih jednadžbi	iskazivati uvjet usporednosti dvaju pravaca; iz jednadžbi pravaca odrediti jesu li pravci usporedni, poklapaju li se ili se sijeku; rješavati sustav linearnih jednadžbi grafički i računskim putem; provjeriti rješenje; odrediti grafičkom

	metodom ima li sustav dviju linearnih jednadžbi jedno, nijedno ili beskonačno mnogo rješenja.

8. RAZRED

Tablica 39. Nastavni plan za predmet Matematika za osmi razred

Tema	***Obrazovna postignuća***
1. Kvadriranje racionalnih brojeva	kvadrirati racionalne brojeve i procjenjivati vrijednosti kvadrata.
2. Kvadriranje umnoška i količnika	kvadrirati umnožak i količnik te transformirati umnožak kvadrata i količnik kvadrata.
3. Kvadrat zbroja i razlike. Razlika kvadrata	kvadrirati zbroj i razliku dvaju brojeva; prepoznati u algebarskim izrazima kvadrat zbroja i kvadrat razlike; rastaviti razliku kvadrata na faktore.
4. Potencije s bazom 10	potencirati broj 10 prirodnim eksponentom; potencirati broj 10 cjelobrojnim eksponentom; računati s potencijama s bazom 10.
5. Drugi korijen	procjenjivati vrijednosti drugoga korijena pozitivnoga racionalnog broja; procjenjivati cjelobrojni dio vrijednosti drugoga korijena; izračunavati i približno određivati drugi korijen uporabom džepnoga računala.
6. Računanje s korijenima	računati s korijenima; djelomično korjenovati; racionalizirati nazivnik.
7. Pitagorin poučak	znati izreku, smisao i zorni dokaz Pitagorina poučka; izreći obrat Pitagorina poučka te izračunavati duljinu jedne stranice pravokutnoga trokuta ako su zadane duljine ostalih stranica.
8. Primjena Pitagorina poučka na kvadrat i pravokutnik	izračunavati duljinu dijagonale kvadrata i pravokutnika.
9. Primjena Pitagorina poučka na jednakostranični i jednakokračni trokut	rješavati zadatke koji povezuju visinu i stranicu jednakostraničnoga trokuta, odnosno osnovicu, krak i visinu na osnovicu jednakokračnoga trokuta.
10. Primjena Pitagorina poučka na romb i trapez	izračunavati duljine dijagonala romba; izračunavati duljinu visine jednakokračnog trapeza.
11. Realni brojevi	zapisivati racionalne brojeve u obliku decimalnoga broja; razlikovati racionalne i iracionalne brojeve; odrediti odnose između skupova N, Z, Q, I i R.
12. Realni brojevi i brojevni pravac	konstruirati dužine duljina $\sqrt{2}$ i $\sqrt{3}$; prikazivati na brojevnom pravcu točke pridružene realnim brojevima
13. Grafovi funkcija $y=x^2$ i $y=\sqrt{x}$	izračunavati vrijednost funkcije za određene vrijednosti argumenta x; rješavati jednadžbu $x^2 = a$; crtati grafove funkcija $y=x^2$ i $y=\sqrt{x}$; odrediti ili procijeniti koordinate točaka na grafu.
14. Vektori	crtati zadane vektore, prepoznati i crtati jednake i suprotne vektore.

15. Zbrajanje i oduzimanje vektora	zbrajati i oduzimati vektore primjenom pravila trokuta
16. Translacija	translatirati točku, dužinu, pravac, trokut i kružnicu; prepoznati lik koji je nastao translacijom drugoga.
17. Osna simetrija	određivati osnosimetričnu sliku točke, dužine, pravca, trokuta i kružnice; prepoznati osnosimetričan lik; konstruirati simetralu dužine i simetralu kuta.
18. Centralna simetrija	određivati centralnosimetričnu sliku točke, dužine, pravca, trokuta i kružnice; prepoznati centralnosimetrični lik; određivati centar simetrije.
19. Rotacija	rotirati zadani lik ako je zadano središte rotacije i njezin kut
20. Točke, pravci i ravnine u prostoru	znati da je ravnina određena s tri nekolinearne točke; odrediti ravninu ako su joj zadane neke točke; odrediti (na modelu kvadra) pripada li neka točka nekoj ravnini.
21. Međusobni položaji pravaca i ravnina	na modelu kvadra određivati međusobne položaje pravaca i ravnina; znati sustavno prebrojiti sve pravce određene danim točkama koji su usporedni, odnosno koji nisu usporedni s danom ravninom
22. Okomitost pravca i ravnine. Okomitost dviju ravnina	na modelu kvadra prepoznati je li zadani pravac okomit na ravninu ili nije; prepoznati jesu li zadane ravnine okomite ili nisu; brojiti pravce određene danim točkama koji su okomiti na danu ravninu; prebrojiti ravnine koje su okomite na danu ravninu.
23. Ortogonalna projekcija točke na ravninu. Udaljenost točke od ravnine	odrediti ortogonalnu projekciju točke i dužine na ravninu; odrediti udaljenost točke od ravnine.
24. Prizma	prepoznati i opisivati prizme; određivati broj vrhova, bridova i strana prizme; crtati skice piramida i njihove mreže.
25. Oplošje i obujam prizme	određivati oplošje i obujam prizme
26. Piramida	prepoznati i opisivati piramide; određivati broj vrhova, bridova i strana piramida; crtati skice piramida i njihove mreže.
27. Oplošje i obujam piramide	određivati obujam i oplošje piramide.
28. Valjak. Oplošje i obujam valjka	crtati skicu valjka i njegovu mrežu; izračunavati obujam i oplošje valjka.
29. Stožac. Oplošje i obujam stošca	crtati skicu stošca i njegovu mrežu; izračunavati obujam i oplošje stošca.
30. Kugla i sfera. Oplošje i obujam kugle	crtati skicu sfere i kugle; uočavati glavne kružnice; izračunavati oplošje i obujam kugle.

PRILOG D

Nastavni plan i program za predmet Informatika u višim razredima

5. RAZRED

Tablica 40. Nastavni plan za predmet Informatika za peti razred

Tema	***Obrazovna postignuća***
1. Bit	napisati sva moguća stanja za nizove od 2, 3 i 4 bita.
2. Brojevi zapisani četvorkom bitova	svojim riječima objasniti kako se nizom bitova može zapisati broj nula i ograničeni broj prirodnih brojeva (pri čemu je najveći broj za jedan manji od broja mogućih stanja niza bitova); kraće zapisivati vrijednosti četvorke bitova jednim simbolom.
3. Bajt	navesti koliko mogućih stanja može poprimiti jedan bajt; izračunavati težine binarnih mjesta uzastopnim množenjem s dva; zapisivati vrijednosti bitova dvjema vrijednostima četvorki.
4. Prikazivanje znakova nizom bitova jednog bajta	za zadani kratki tekst iz tablice pročitati kodne vrijednosti i zapisati ih na papiru.
5. Pohranjivanje niza znakova u spremnik računala, znakovna datoteka	objasniti kako se u računalima pohranjuju tekstovi; napisati višeznamenkaste brojeve kao kodne vrijednosti znamenki u potreban broj bajtova; napisati dvoznamenkasti broj kodnim vrijednostima u dva bajta i nakon toga vrijednost istog broja prikazati vrijednostima bitova jednog bajta.
6. Spremnici računala	svojim riječima opisati ulogu pojedinih spremnika.
7. Kako pokrećemo programe?	objasniti svojim riječima kako se računalo, kao univerzalni stroj, pokretanjem odgovarajućih primjenskih programa pretvara u namjenske strojeve.
8. Načini smještanja i pristup do datoteka u računalu	objasniti koje operacije nad datotekama obavlja operacijski sustav i kako primjenski programi djeluju na sadržaj datoteka; pronaći i pokrenuti zadani program ili podatkovnu datoteku; stvarati, preimenovati i premještati podatkovne datoteke.
9. Osnovni alati programa za crtanje	koristiti osnovne alate u jednostavnom programu za crtanje.
10. Rad s dijelovima crteža	kopirati izreske crteža.
11. Kombiniranje crteža iz dviju datoteka	rabiti međuspremnik za prenošenje dijelova crteža.
12. Pogled na sliku	brisati osnovni element crteža (piksel).
13. Svojstva crteža	mijenjati veličine crteža i dubinu boja crteža i ocjenjivati njegovu kakvoću.
14. (A) Osnovne naredbe	upotrebljavati nove naredbe u programskom jeziku u rješavanju jednostavnijih

programskog jezika	zadataka; programom crtati kvadrat, trokut, pravokutnik i šesterokut.
15. (A) Ponavljanje niza naredbi	crtati kvadrat, trokut i šesterokut pomoću petlje.
16. (A) Uporaba petlje za crtanje niza likova	nacrtati niz kvadrata ako je zadan broj kvadrata i duljina stranice kvadrata.
17. (A) Ulazne vrijednosti procedura	pisati programe koji crtaju kvadrate, trokute ili šesterokute promjenljivih duljina stranice.
18. (A) Uporaba više ulaznih vrijednosti	pisati programe koji koriste dvije ili više ulaznih vrijednosti (crtanje pravokutnika kojem su duljina i širina ulazne vrijednosti, crtanje paralelograma kojem su ulazne vrijednosti duljine stranica i kut između dviju susjednih stranica).
19. (A) Odluke u programu	upotrebljavati naredbu odluke u jednostavnijim zadacima (uspoređivanje dvaju brojeva, ispitivanje je li ulazna vrijednost veća ili manja od zadanog broja, provjeravanje nalazi li se ulazna vrijednost između dva zadana broja).
14. (B) Pojam algoritma	napisati algoritam za izvođenje računske operacije, napisati algoritam za određivanje manjeg od dva zadana broja.
15. (B) Dijagram tijeka	nacrtati dijagram tijeka za zbrajanje (oduzimanje, množenje ili dijeljenje) dva broja, nacrtati dijagram tijeka za uspoređivanje dva broja.
16. (B) Naredbe za ulaz i izlaz podataka	napisati program za izvođenje jedne računske operacije s dva učitana broja.
20. Oblikovanje teksta	oblikovati tekst umetanjem simbola, slike, obruba i ostalih efekata.
21. Ispis dokumenta	pregledati i ispraviti postavke dokumenta prije ispisa; ispisati dokument
22. Dodavanje zaglavlja i podnožja, pisanje u više stupaca	umetanje zaglavlja i podnožja u dokument i njihovo popunjavanje sadržajima; preslagivanje teksta u odabrani broj stupaca.
23. Osnovne usluge interneta	razumijevanje interneta kao skupa usluga.
24. WWW preglednik	uporaba web preglednika za jednostavan pregled stranica.
25. Moja prva pretraga	tražiti zadani pojam na internetu.
26. Uporaba web pošte	pisati jednostavne poruke.

6. RAZRED

Tablica 41. Nastavni plan za predmet Informatika za šesti razred

Tema	***Obrazovna postignuća***
1. Vrste datoteka, dokumenti	objasniti u kojem se obliku svi sadržaji trajno čuvaju u računalu.
2. Prikaz slika na monitoru i pisaču	izraditi jednostavni crtež u bilježnici na rasteru malih dimenzija; na rasteru manjih dimenzija pokušati što točnije prikazati pravocrtnu spojnicu dvaju piksela.
3. (A) Crtanje kocke i kvadra	crtati prikaze kocke i kvadra.
4. (A) Višestruke kornjače	izraditi crtež s pomoću više kornjača.
5. (A) Tipovi podataka: numerički, znakovni, liste	preoblikovati znakovne nizove programom.
6. (A) Algoritmi koji koriste različite tipove podataka	raščlaniti problem na manje dijelove i rješavati ga korak po korak.
3. (B) Uporaba naredbi za grananje i bezuvjetni skok	napisati program za uspoređivanje dvaju brojeva.
4. (B) Algoritmi s uporabom petlje	sastaviti algoritam za ispis niza brojeva ili za ubrajanje niza brojeva.
5. (B) Uporaba naredbi za petlju bez logičkog uvjeta	napisati program za ispis niza brojeva i program za zbroj niza brojeva.
7. Izrada i oblikovanje tablica, kretanje u njima	umetnuti u tekst tablicu zadanog broja redova i stupaca te podesiti njihove veličine; unijeti podatke u tablicu.
8. Položaj i uokvirivanje tablice, razvrstavanje u tablici	umetnuti u tekst tablicu zadanog broja redova i stupaca, prilagoditi njihove veličine, unijeti podatke u tablicu te joj po potrebi mijenjati položaj; podatke razvrstati abecednim redom; tablicu ukrasiti dodavanjem obruba zadane debljine, vrste i boje linije.
9. Crtanje programom za obradbu teksta	nacrtati zadane (osnovne) objekte, obraditi ih linijama različitih boja i debljina te ih naredbom za grupiranje spojiti u jednu cjelinu.
10. Povezivanje računala	objasniti svrhu i potrebu povezivanja računala i pristupiti podatcima na drugome računalu.
11. Paketni prijenos podataka mrežom	svojim riječima objasniti paketni prijenos.
12. Sustavno prikupljanje sadržaja s weba	pretvarati web sadržaje u druge oblike.
13. Snimanje audio zapisa	snimati zvuk i pohraniti snimku u zvučnu datoteku, prepoznati zvučnu datoteku.
14. Oblikovanje audiozapisa	koristiti neki od multimedijskih svirača (media player).
15. Montaža videozapisa	stvoriti manji videozapis web kvalitete od nekoliko zasebnih videoklipova snimljenih digitalnim fotoaparatom.
16. Obrada videozapisa u	prilagoditi trajanje videouratka.

vremenu	
17. Umetanje datoteka u videozapis	umetati crteže u videodatoteku.
18. Završna obrada i pohrana videouratka	oblikovati i izgraditi jednostavniji video uradak.
19. Upoznavanje alata za izradbu prezentacije	prepoznati osnovno okruženje alata za izradbu prezentacija.
20. Oblikovanje prezentacije	kreirati jednostavnu prezentaciju.
21. Oblikovanje teksta na slajdovima	uređivati tekst na slajdu.
22. Umetanje ilustracija	postavljati sliku na slajd i pronalaziti odgovarajuće slike za vlastitu prezentaciju.
23. Uređivanje prezentacije	uređivati vlastite prezentacije i ispisivati prezentacije.
24. Animacijski učinci	dodavati animacijske efekte elementima na slajdu i koristiti tu vještinu pri izradbi vlastite prezentacije.

7. RAZRED

Tablica 42. Nastavni plan za predmet Informatika za sedmi razred

Tema	***Obrazovna postignuća***
1. (A) Koordinatna grafika	crtati likove zadane koordinatama vrhova te primijeniti naredbe i funkcije koordinatne grafike u zadatcima.
2. (A) Zadatci o pravilnim mnogokutima	rješavati matematičke probleme s pomoću računalnih programa
3. (A) Izrada grafičkog sučelja	opisati način programiranja grafičkih sučelja računalnih programa.
1. (B) Uporaba naredbe za petlju s logičkim uvjetom	napisati jednostavan program s uporabom petlje s logičkim uvjetom
2. (B) Crtanje ravnih linija i pravokutnika	nacrtati ravnu liniju sa zadanom početnom i završnom točkom zadane boje, nacrtati pravokutnik zadane duljine i širine, sa zadanom koordinatom jednog vrha.
3. (B) Crtanje kružnice	nacrtati kružnicu zadanog središta i polumjera.
4. Stvaranje radne bilježnice	otvoriti radnu bilježnicu, pokazivačem miša označavati redove, stupce, ćelije, očitati njihove oznake na radnom listu.
5. Unos podataka	pisati formule uporabom znaka jednakosti i navođenjem konstanti ili varijabli koje su u matematičkoj zavisnosti.
6. Uporaba radne bilježnice	kopirati i premještati te brisati sadržaje pojedinih ćelija, ubaciti red ili stupac u proračunsku tablicu, koristiti brzi izbornik
7. Uređivanje tablice	promijeniti dimenzije stupaca i redaka u proračunskoj tablici; promijeniti sadržaj i obrubiti ćelije.
8. Formati brojeva u ćelijama tablica	pretvarati jedan format broja u drugi
9. Nizovi podataka	nadopunjavati nizove raznovrsnim podatcima, pretvarati relativne adrese ćelija u apsolutne adrese te raditi jednostavne izračune pomoću njih
10. Grafikoni	izraditi grafikon na temelju zadane tablice i oblikovati njegove elemente.
11. Promjena prikaza i ispis radne bilježnice	postaviti trake za zamrzavanje na dugačkim radnim listovima kako bi značenje podataka bilo jasno i na udaljenim dijelovima tablice; postaviti zaglavlje i podnožje
12. Osnovne funkcije u programu za izradbu proračunskih tablica	koristiti osnovne funkcije i s pomoću njih napraviti potrebne izračune; pronaći prosječnu veličinu, maksimalnu i minimalnu vrijednost niza brojeva.
13. Grafički elementi	izraditi sheme i crteže na slajdu; izraditi vlastiti crtež koji će opisati zadanu temu.
14. Tekstni okviri	dodavati tekstne okvire i ukrasne tekstove na slajdove u vlastitoj prezentaciji.
15. Dodatni elementi u prezentaciji	dodavati različite elemente (tablice, grafikoni, organizacijski dijagrami) na slajd i uređivati ih.

16. Vizualni (grafički) HTML uređivači	izraditi jednostavnu osobnu web stranicu.
17. Poveznice (linkovi)	umetnuti slikovni element u stranicu i pretvoriti ga u poveznicu na drugu stranicu.
18. Elementi stranice	koristiti tablicu kao element na web stranicama
19. Jezik HTML	protumačiti jednostavni HTML opis stranice
20. Oznake i parametri HTML jeziku	znati dodavati parametre na osnovne oznake.
21. Uporaba vizualnog HTML uređivača za izradu osobne web stranice	uobličiti strukturu stranice.
22. Struktura interneta	znati objasniti načine komunikacije unutar interneta.
23. Ostale internetske usluge	opisati opisane usluge interneta.
24. Davatelj usluga na internetu	objasniti ulogu poslužitelja
25. Povezivanje na internet	objasniti potrebu za bržim internetskim vezama u budućnosti

8. RAZRED

Tablica 43. Nastavni plan za predmet Informatika za osmi razred

Tema	***Obrazovna postignuća***
1. Elektronički logički sklopovi i registri	objasniti kako se odvijaju osnovne funkcije računala na strojnoj razini, objasniti ulogu operacijskog sustava u djelovanju računala.
2. Paralelni i slijedni ulazno-izlazni pristupi računala	opisati neke primjere (primjerice, kućanski uređaji) gdje se ugrađena računala koriste u upravljačkim napravama.
3. Svojstva računala	nabrojati osnovna svojstva računala i mjere za njihovu usporedbu.
4. Pohranjivanje multimedijskih sadržaja, obrada zvuka	ocijeniti veličine datoteka za pohranjivanje multimedijskih sadržaja.
5. (A) Grafičke naredbe u programu	upotrijebiti osnovne grafičke naredbe grafičkim kontrolama.
6. (A) Procedure i programske funkcije	upotrebljavati u programima neke unaprijed pripremljene funkcije.
7. (B) Potprogrami	napisati jednostavniju proceduru (s parametrima ili bez njih) te ju pravilno pozvati u programu.
8. (A,B) Primjena programiranja u nastavi Matematike	upotrebljavati računalo kao pomagalo pri rješavanju jednostavnih geometrijskih zadataka.
9. (A,B) Primjena programiranja u fizici i kemiji	upotrebljavati računalo kao pomagalo za rješavanje zadataka iz fizike i kemije.
10. Baza podataka	stvoriti jednostavnu tablicu u nekom programu za upravljanje bazama podataka.
11. Upisni obrasci i pretraga	upisivati podatke u priređene baze podataka, pretraživati ih, ažurirati i brisati.
12. Uređivanje glavnog slajda	izraditi jednostavni glavni slajd s logotipom i podnožjem.
13. Veze između slajdova	postaviti hiperveze između slajdova; postaviti akcijske gumbe na slajd i odrediti njihova osnovna svojstva; postavljati veze između slajdova pri izradbi kviza i sl.
14. Prikazivanje prezentacije	pripremiti prezentaciju za izvođenje i obaviti njezino izvođenje.
15. Timska izrada web stranica razreda	surađivati u skupini.
16. Tehnike objavljivanja	znati objaviti vlastite web stranice.
17. Objavljivanje web mjesta	objaviti svoj web uradak.
18. Pokretni dijelovi stranica	izraditi animaciju i umetnuti ju na web stranicu.
19. Kritički odnos prema	ocjenjivati sadržaje dobavljene internetom.

internetu	
20. Sudjelovanje u internetskim projektima	prijaviti se i sudjelovati aktivno u internetskom projektu.
21. Školski internetski projekti	potaknuti stvaralačko predlaganje i kritiku.

ŽIVOTOPIS AUTORA S POPISOM OBJAVLJENIH DJELA

Gordana Paić rođena je 23. siječnja 1962. godine u Zagrebu, gdje je završila osnovnu i srednju školu. Magistra je edukacije Matematike, diplomirala na Matematičkom odjelu Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, smjer profesor Matematike, a nakon stjecanja diplome od 1986. radi na radnom mjestu učitelja Matematike u OŠ Dr. Ivan Merz u Zagrebu, promovirana je u učitelja savjetnika 2007. godine. Od 2010. godine vanjski je suradnik na Učiteljskom fakultetu Sveučilišta u Zagrebu, gdje drži metodičke vježbe iz kolegija vezanih uz metodiku Matematike, a tijekom 8 godina radila je i kao vanjski suradnik Filozofskog fakulteta Sveučilišta u Zagrebu držeći metodičke vježbe iz kolegija metodika nastave Informatike. Održala je brojna predavanja i mnoge radionice na županijskim aktivima razredne i predmetne nastave u Republici Hrvatskoj i BiH.

Područja njenog zanimanja su nastava Matematike u osnovnoj školi, matematički udžbenici te vanjska vrednovanja. Od 2007. do 2010., radi kao ocjenjivač državne mature za osnovnu i srednju školu. Autorica je ili koautorica stotinu udžbenika, knjiga i didaktičke literature za Matematiku u osnovnoj školi u Republici Hrvatskoj i Bosni i Hercegovini. Koautorica je znanstvenog članka u međunarodnom informatičkom časopisu, stručnoga rada za VI. Kongres nastavnika Matematike Republike Hrvatske (2014.) te 18 metodičkih priručnika za nastavu Matematike.

Popis znanstvenih i stručnih radova

Paić, G., Tepeš, B., Mrkonjić, I., & Tepeš, K. (2016). CAUSAL SEM OF MATHEMATICAL COMPETENCES IN ELEMENTARY EDUCATION. International Conference on Education in Mathematics, Science and Technology (ICEMST), Bodrum, Turska, 2016.

Paić, G., Čulina, B., & Bošnjak, Ž. (2017). JE LI NULA PRIRODAN BROJ? I JOŠ NEKA DOBRA PITANJA NA KOJA U NASTAVI MATEMATIKE NIJE DAN DOBAR ODGOVOR. *Poučak: časopis za metodiku i nastavu Matematike*, *18*(72), 34-37.

Paić, G., Tepeš, B., & Pavlina, K. (2016, May). MARKOV MODEL OF MATHEMATICAL COMPETENCES IN ELEMENTARY EDUCATION. In *Information and Communication*

Technology, Electronics and Microelectronics (MIPRO), 2016 39th International Convention on (pp. 934-939). IEEE.

Paić, G., Šredl, V., Bošnjak, Ž.: MATEMATIKA I GLAZBA. 11. međunarodna balkanska konferencija obrazovanja i znanosti, Poreč, Hrvatska, 2016

Paić, G., Čulina, B., & Bošnjak, Ž. (2016). POJAM SLIČNOSTI U NASTAVI MATEMATIKE U OSNOVNOJ ŠKOLI. *Poučak: časopis za metodiku i nastavu Matematike*, *17*(65), 47-51.

Paić, G., Dovedan, Z., & Seljan, S. (2005). FINAL AUTOMATA AND RIGHT-LINEAR GRAMMAR IFERENCE. In *Informacijske znanosti u procesu promjena*. Filozofski fakultet, Zavod za informacijske studije Odsjeka za informacijske znanosti.

Popis relevantnijih autorskih bibliografskih jedinica

1. - 4. Paić, Gordana i dr., (2004.), ***Metodički priručnik za učitelje (u prvom, drugom, trećem i četvrtom) razredu osnovne škole uz udžbenički komplet Matematičke zgode*** (Paić i dr.), Školska knjiga, Zagreb

5. – 7. Paić, Gordana i dr., (2002.), ***Metodički priručnik za učitelje (u drugom, trećem i četvrtom) razredu osnovne škole uz udžbenički komplet Matematika 2,3,4*** (Jagodić i dr.), Školska knjiga, Zagreb

8. Paić, Gordana i dr., (2003.), ***Metodički priručnik za učitelje Matematike u petom razredu osnovne škole uz udžbenički komplet Matematika 5*** (Jagodić i dr.), Školska knjiga, Zagreb

9. – 12. Paić, Gordana i dr. (2005.), ***Metodički priručnik za učitelje Matematike u petom razredu osnovne škole uz udžbenički komplet Matematičke zgode 5*** (Paić i dr.), Školska knjiga, Zagreb

13. – 16. Paić, Gordana i dr. (2006. i 2014.), ***Metodički priručnik za učitelje Matematike (u petom, šestom, sedmom i osmom razredu osnovne škole) uz udžbenički komplet Matematički izazovi*** (Paić i dr.), Alfa, Zagreb

17. Paić, Gordana (2014.), ***Metodički priručnik za učitelje u četvrtom razredu osnovne škole uz udžbenički komplet Matematičkim stazama 4*** (Paić i dr.), Školska knjiga, Zagreb

18. – 24. Paić, Gordana i dr., (2004.), ***Matematičke zgode 1***, udžbenički komplet (udžbenik, zbirka zadataka, CD, radna bilježnica, nastavni listići, listići za dodatnu nastavu, ispiti znanja) za Matematiku u prvom razredu osnovne škole, Školska knjiga, Zagreb

25. – 31. Paić, Gordana i dr., (2004.), ***Nove matematičke zgode 2***, udžbenički komplet (udžbenik, zbirka zadataka, CD, radna bilježnica, nastavni listići, listići za dodatnu nastavu, ispiti znanja) za Matematiku u drugom razredu osnovne škole, Školska knjiga, Zagreb

32. – 38. Paić, Gordana i dr., (2004.), ***Čudesne matematičke zgode 3***, udžbenički komplet (udžbenik, zbirka zadataka, CD, radna bilježnica, nastavni listići, listići za dodatnu nastavu, ispiti znanja) za Matematiku u trećem razredu osnovne škole, Školska knjiga, Zagreb

39. – 45. Paić, Gordana i dr., (2004.), ***Vesele matematičke zgode 4***, udžbenički komplet (udžbenik, zbirka zadataka, CD, radna bilježnica, nastavni listići, listići za dodatnu nastavu, ispiti znanja) za Matematiku u četvrtom razredu osnovne škole, Školska knjiga, Zagreb

46. – 49. Paić, Gordana i dr., (2004.), ***Priručnik za roditelje (u prvom, drugom, trećem i četvrtom) razredu osnovne škole uz udžbenički komplet Matematičke zgode*** (Paić i dr.), Školska knjiga, Zagreb

50. Paić, Gordana i dr., (2005.), ***Natjecateljske matematičke zgode***, Školska knjiga, Zagreb

51. – 55. Paić, Gordana i dr., (2005.), ***Matematičke zgode 5***, udžbenički komplet (udžbenik, zbirka zadataka, radna bilježnica, CD, ispiti znanja) za Matematiku u petom razredu osnovne škole, Školska knjiga, Zagreb

56. – 60. Paić, Gordana i dr., (2006.), ***Matematički izazovi 5***, udžbenički komplet (udžbenik sa zbirkom zadataka I. i II. dio, radna bilježnica, CD, ispiti znanja) za Matematiku u petom razredu osnovne škole, Alfa, Zagreb

61. – 65. Paić, Gordana i dr., (2006.), ***Matematički izazovi 6***, udžbenički komplet (udžbenik sa zbirkom zadataka I. i II. dio, radna bilježnica, CD, ispiti znanja) za Matematiku u šestom razredu osnovne škole, Alfa, Zagreb

66. – 70. Paić, Gordana i dr., (2006.), ***Matematički izazovi 7***, udžbenički komplet (udžbenik sa zbirkom zadataka I. i II. dio, radna bilježnica, CD, ispiti znanja) za Matematiku u sedmom razredu osnovne škole, Alfa, Zagreb

71. – 75. Paić, Gordana i dr., (2006.), ***Matematički izazovi 8***, udžbenički komplet (udžbenik sa zbirkom zadataka I. i II. dio, radna bilježnica, CD, ispiti znanja) za Matematiku u osmom razredu osnovne škole, Alfa, Zagreb

76. – 82. Paić, Gordana i dr., (2014.), ***Matematičkim stazama 1***, udžbenički komplet (udžbenik, zbirka zadataka, CD, radna bilježnica, nastavni listići, listići za dodatnu nastavu, ispiti znanja) za Matematiku u prvom razredu osnovne škole, Školska knjiga, Zagreb

83. – 89. Paić, Gordana i dr., (2014.), ***Matematičkim stazama 2***, udžbenički komplet (udžbenik, zbirka zadataka, CD, radna bilježnica, nastavni listići, listići za dodatnu nastavu, ispiti znanja) za Matematiku u drugom razredu osnovne škole, Školska knjiga, Zagreb

90. – 96. Paić, Gordana i dr., (2014.), ***Matematičkim stazama 3***, udžbenički komplet (udžbenik, zbirka zadataka, CD, radna bilježnica, nastavni listići, listići za dodatnu nastavu, ispiti znanja) za Matematiku u trećem razredu osnovne škole, Školska knjiga, Zagreb

97. – 103. Paić, Gordana i dr., (2014.), ***Matematičkim stazama 4***, udžbenički komplet (udžbenik, zbirka zadataka, CD, radna bilježnica, nastavni listići, listići za dodatnu nastavu, ispiti znanja) za Matematiku u četvrtom razredu osnovne škole, Školska knjiga, Zagreb