Konceptualni okvir igrifikacije hrvatskoga mrežnoga rječnika

Mihaljević, Josip

Doctoral thesis / Disertacija

2021

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

<https://doi.org/10.17234/diss.2021.265287>

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:131:046488>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2023-04-26**

Repository / Repozitorij:

[ODRAZ - open repository of the University of Zagreb
Faculty of Humanities and Social Sciences](#)

Sveučilište u Zagrebu

Filozofski fakultet

Josip Mihaljević

KONCEPTUALNI OKVIR IGRIFIKACIJE HRVATSKOGA MREŽNOGA RJEČNIKA

DOKTORSKI RAD

Zagreb, 2021.

Sveučilište u Zagrebu

Filozofski fakultet

Josip Mihaljević

KONCEPTUALNI OKVIR IGRIFIKACIJE HRVATSKOGA MREŽNOGA RJEČNIKA

DOKTORSKI RAD

Mentori:

dr. sc. Lana Hudeček
dr. sc. Petra Bago, doc.

Zagreb, 2021.

University of Zagreb

Faculty of Humanities and Social Sciences

Josip Mihaljević

CONCEPTUAL FRAMEWORK FOR GAMIFICATION OF A CROATIAN WEB DICTIONARY

DOCTORAL DISSERTATION

Supervisors:
Lana Hudeček, Ph.D.
Asst. Prof. Petra Bago, Ph.D.

Zagreb, 2021.

Podatci o mentorima

Doktorski rad izrađen je u sklopu poslijediplomskoga doktorskog studija Informacijske i komunikacijske znanosti. Doktorski rad izrađen je na istraživačkome projektu Instituta za hrvatski jezik i jezikoslovlje *Hrvatski mrežni rječnik – Mrežnik* (IP-2016-06-2141), koji u cijelosti financira Hrvatska zaklada za znanost. Voditeljica projekta Lana Hudeček prva je mentorica doktoranda. *Mrežnik* je prvi rječnik hrvatskoga jezika koji je izvorno napravljen za mrežu (engl. *born-digital*, *web-born*). On nije prostorno ograničen kao tiskani rječnici, pa nema ni ograničenja koja se odnose na količinu sadržaja koji se u njega mogu uvrstiti. Stoga će *Mrežnik* imati i multimedijske sadržaje kao što su slike i obrazovne igre. Doktorski rad obuhvaća područje hrvatske leksikografije i računalne leksikografije (primjena informatike u leksikografiji). Za hrvatsku leksikografiju kompetentna je prva mentorica dr. sc. Lana Hudeček, znanstvena savjetnica u trajnome zvanju, a za računalnu leksikografiju i informatiku kompetentna je druga mentorica dr. sc. Petra Bago, doc.

dr. sc. Lana Hudeček

Lana Hudeček rođena je 20. studenoga 1960. godine u Zagrebu. Završila je Osnovnu školu i XV. (matematičku) gimnaziju u Zagrebu. Diplomirala je na Filozofskome fakultetu u Zagrebu 1986. godine. Te je godine počela raditi kao pripravnik u Zavodu za jezik Instituta za filologiju i folkloristiku. Doktorirala je 2003. s temom *Izražavanje kategorije posvojnosti u hrvatskome jeziku do polovice 19. stoljeća* (mentor prof. dr. sc. Ivo Pranjković). Trenutačno je zaposlena u Institutu za hrvatski jezik i jezikoslovlje kao znanstvena savjetnica u trajnome zvanju u Odjelu za standardni jezik. Područje je njezina znanstvenoga bavljenja u prvome redu suvremena jezična norma i jezično planiranje, terminologija, leksikologija i leksikografija, jezik poslovne komunikacije, jezik medija te povijest jezika. Autorica je knjiga i mnogih radova iz tih područja. Suautorica je i suurednica temeljnih normativnih priručnika: *Hrvatskoga pravopisa*, *Školskoga rječnika hrvatskoga jezika*, *Hrvatske školske gramatike* i *Hrvatskoga jezičnog savjetnika*. Voditeljica je (s Milicom Mihaljević) institutskih projekata *Mali školski pravopis* i *Religijski pravopis* te voditeljica projekta Hrvatske zaklade za znanost *Hrvatski mrežni rječnik – Mrežnik*. Članica je međunarodnoga terminološkog komiteta *International Committee of Slavonic Scholars*, *Terminology Commission*, organizacijskoga odbora skupa *Hrvatski sintaktički dani*, *Savjeta za jezik i govor* HRT-a, bila je članica *Matičnoga odbora za filologiju* i *Upravnoga vijeća* Instituta za hrvatski jezik i jezikoslovlje. Sudjeluje u izvedbi nekoliko jezičnih kolegija

na studiju novinarstva na veleučilištu Vern. Urednica je znanstveno-popularnoga časopisa Instituta za hrvatski jezik i jezikoslovlje *Hrvatski jezik* i mrežnih stranica *Bolje je hrvatski*, *Hrvatski u školi* i *Jezični savjetnik*. Sudjelovala je u mnogim aktivnostima popularizacije znanosti. Za svoj rad dobila je nekoliko uglednih nagrada (Nagrada Grada Zagreba, Nagrada Ivan Filipović, Dr. Ivan Šreter).

dr. sc. Petra Bago, doc.

Petra Bago rođena je 18. studenoga 1982. godine u Zagrebu. Osnovnu školu pohađala je u Zagrebu, Bernu i Sofiji. V. gimnaziju završila je u Zagrebu. Godine 2003. upisala je Filozofski fakultet, smjer informacijskih znanosti te etnologije i kulturne antropologije. Od 2004. sudjeluje u nastavi kao demonstratorica na Odsjeku za informacijske i komunikacijske znanosti. Godine 2006. primila je Rektorovu nagradu za studentski znanstveni rad pod naslovom *Računalna priprema, obrada i prikaz sedmojezičnog rječnika Petera Lodereckera*. Diplomirala je na Odsjeku za informacijske i komunikacijske znanosti i Odsjeku za etnologiju i kulturnu antropologiju 2008. godine. Akademске godine 2008./2009. upisala je poslijediplomski doktorski studij na Odsjeku za informacijske znanosti. Godine 2009. na istome odsjeku zaposlila se kao znanstvena novakinja na projektu *Hrvatska rječnička baština i hrvatski europski identitet* pod vodstvom prof. dr. sc. Damira Borasa. Doktorirala je 2014. s radom *Model višerazinske prezentacije tekstova starijih hrvatskih rječnika* (mentori prof. dr. sc. Damir Boras i doc. dr. sc. Nikola Ljubešić). Područje je njezina znanstvenoga interesa računalna leksikografija, enciklopedika, kodiranje teksta, društveno-humanistička informatika – digitalna humanistika, statistička analiza i pretraživanje obavijesti. Autorica je mnogih radova iz tih područja. Urednica je zbornika *INFuture2019: Knowledge in the Digital Age* i organizatorica istoimenoga međunarodnog skupa. Sudjelovala je na mnogim međunarodnim znanstvenim skupovima, okruglim stolovima i stručnih tribinama te održala radionicu namijenjenu upoznavanju rada s XML-om i TEI-jem zaposlenicima Instituta za hrvatski jezik i jezikoslovlje unutar projekta RETROGRAM. Voditeljica je hrvatskoga tima u projektu koji financira Instrument za povezivanje Europe (Connecting Europe Facility, CEF) *PRINCIPLE – Providing Resources in Irish, Norwegian, Croatian and Icelandic for Purposes of Language Engineering* (Grant Agreement No. INEA/CEF/ICT/A2018/1761837; rujan 2019 – kolovoz 2021.) te je voditeljica hrvatskoga tima znanstvenoga Erasmus+ KA2 projekta *DigiLing – Trans-European e-Learning Hub for Digital Linguistics*. Suradnica je na projektima *Europe Engage – Developing a Culture of Civic Engagement through Service-Learning within Higher Education*

in Europe (Erasmus+ KA2 projekt), *MemAzija – Algoritmi za pamćenje i njihova primjena u azijskim jezicima* (projekt Europskoga strukturnog i investicijskog fonda), *Hrvatska rječnička baština i hrvatski europski identitet* (projekt koji financira Ministarstvo znanosti, obrazovanja i sporta), *Usklađivanje studijskih programa iz područja društvenih i humanističkih znanosti s potrebama tržišta rada* (projekt Europskoga socijalnog fonda unutar Operativnoga programa Učinkoviti ljudski potencijali) i koordinatorica projekta suradnje gospodarstva i znanstvenih institucija *Upravljanje znanjem*. Sudjeluje u izvedbi nekoliko kolegija na preddiplomskome i diplomskome studiju Informacijskih i komunikacijskih znanosti, koji se odnose na jezične baze podataka, računalnu obradu teksta, pretraživanje obavijesti, obradu prirodnoga jezika i leksikografiju. Pohađala je više tečajeva, ljetnih škola i europskih intenzivnih programa u zemlji i inozemstvu te sudjelovala u mnogim aktivnostima popularizacije znanosti.

Zahvale

Prije svega posebno zahvaljujem svojim mentoricama dr. sc. Lani Hudeček, znanstvenoj savjetnici u trajnome zvanju iz Instituta za hrvatski jezik i jezikoslovlje, i docentici dr. sc. Petri Bago s Odsjeka za informacijske i komunikacijske znanosti. Lana Hudeček, voditeljica projekta *Hrvatski mrežni rječnik – Mrežnik*, omogućila mi je da povežem obrazovne igre s mrežnim rječnicima tako što sam sudjelovao u svim fazama rada na *Mrežniku*, a posebno što sam radio na igrifikaciji *Mrežnika*. Profesorica Petra Bago pomogla mi je pri oblikovanju hipoteza i planiranju istraživanja na Croaticumu te me potaknula da se uključim u COST akciju *European Network for Combining Language Learning with Crowdsourcing Techniques (enetCollect)*. Zahvaljujem mentoricama i na svim primjedbama i prijedlozima za oblikovanje i poboljšanje ovoga rad.

Zahvaljujem i ostalim profesorima s Odsjeka za informacijske i komunikacijske znanosti na korisnim kolegijima na doktorske studiju te posebno profesorima koji su mi pomogli da proširim znanja koja su mi bila potrebna pri pisanju doktorskoga rada.

Također bih zahvalio voditeljici Croaticuma dr. sc. Milviji Gulešić Machati, s kojom je dogovoreno istraživanje na Croaticumu te su odabrane dvije skupine u kojima je provedeno istraživanje. Zahvaljujem nastavnicama Jeleni Cvitanušić Tvico i Ranki Đurđević u sklopu čijih je sati provedeno istraživanje te studentima koji su dobrovoljno sudjelovali u istraživanju. Posebno treba istaknuti da je planirano istraživanje provedeno na mreži u jeku epidemije bolesti COVID-19, pa dodatnu zahvalnost dugujem profesoricama i studentima što su nastavili surađivati sa mnom bez obzira na nepredviđene i otežane uvjete.

Zahvaljujem i svojim kolegama iz Instituta za hrvatski jezik i jezikoslovlje na podršci i pomoći pri osmišljavanju nekih igara. Zahvaljujem svojoj sestri Ani Mihaljević na lekturi ovoga rada. Također želim zahvaliti ostalim članovima svoje obitelji i prijateljima koji su mi bili podrška za vrijeme pisanja doktorskoga rada.

SAŽETAK

Tema je rada izgradnja konceptualnoga okvira igrifikacije hrvatskoga mrežnog rječnika. Istraživanje se provodi u okviru istraživanja projekta *Mrežnik*, koji u cijelosti financira Hrvatska zaklada za znanost. Projekt traje od 1. ožujka 2017. do 31. srpnja 2021. *Mrežnik* je prvi hrvatski mrežni rječnik koji se izrađuje isključivo za mrežu (engl. *born-digital*; *web-born*). *Mrežnik* ima tri modula. U prvoj četverogodišnjoj fazi planirana je obrada 10 000 natuknica u osnovnome modulu, 3000 natuknica u modulu za učenike nižih razreda osnovne škole, 1000 natuknica u modulu za osobe koje uče hrvatski kao strani i ini jezik. U strukturu obrade natuknica te na mrežne stranice *Mrežnika* uvrstit će se i igre izrađene na temelju sadržaja rječnika. Prije izrade igara za *Mrežnik* provedeno je istraživanje igara i igrifikacijskih elemenata koji su trenutačno prisutni na drugim stranicama rječnika, enciklopedija te informacijskih ustanova. Provedena analiza uključuje mrežne stranice 181 rječnika, 71 enciklopedije, 179 muzeja, 254 knjižnice i 21 arhiva. Od toga 26 rječnika, 10 enciklopedija, 11 muzeja, 18 knjižnica i 2 arhiva sadržavaju igre s igrifikacijskim elementima. Na temelju identificiranih igara te primjene igrifikacijskih elemenata izrađene su prve demoinačice igara za *Mrežnik*. Kako bi se testirala učinkovitost demoinačica koje bi se trebale implementirati u modul za neizvorne govornike, provedeno je testiranje sa studentima na Croaticumu. Studenti su bili podijeljeni u eksperimentalnu i kontrolnu skupinu. Eksperimentalna je skupina nove sadržaje usvajala i s pomoću igara, a kontrolna klasičnim metodama. Na kraju sata studenti su pisali posttest te nakon dva tjedna odgođeni posttest. Rezultati obaju testova uspoređeni su s predtestom, koji se pisao prije obrade novih nastavnih sadržaja kako bi se analizirao napredak obiju skupina. Glavna hipoteza bila je da će studenti eksperimentalne skupine ostvariti statistički značajno bolje rezultate od kontrolne skupine na posttestu i odgođenome posttestu. Ta hipoteza na kraju istraživanja nije dokazana, ali su studenti eksperimentalne skupine napredovali u oba posttesta u odnosu na predtest te su u upitniku dali pozitivne povratne informacije i prijedloge povezane s poboljšanjem igara. Na temelju provedenoga istraživanja, postojećih obrazovnih igara i igrifikacijskih elemenata te procesa izrade igara osmišljeno je sedam koraka koji čine konceptualni okvir igrifikacije mrežnoga rječnika: određivanje obrazovnih sadržaja i ciljeva igara, osmišljavanje igara i određivanje koji će se igrifikacijski elementi uključiti, izrada igara, testiranje i dorada igara, objava igara, promocija igara i praćenje zadovoljstva korisnika. Koraci koji su provedeni pri igrifikaciju *Mrežnika* prikazuju kako je taj konceptualni okvir moguće implementarni za mrežne rječnike te druga mrežna leksikografska izdanja.

Ključne riječi: igrifikacija, igrifikacijski elementi, konceptualni okvir, mrežni rječnici, obrazovne igre, razvoj igara, učenje utemeljeno na igri

ABSTRACT

This thesis focuses on creating a conceptual framework for the gamification of Croatian born-digital dictionaries. The conceptual framework is illustrated by examples from *Mrežnik*, a born-digital dictionary that is being created at the Institute of Croatian Language and Linguistics within the research project *Croatian Web Dictionary – Mrežnik* financed by the Croatian Science Foundation. The *Mrežnik* project aims at creating a free, monolingual, easily searchable, hypertextual, corpus-based, online dictionary of the Croatian standard language with 10,000 entries. These entries contain definitions, subentries, collocations, examples of usage, normative and pragmatic advice, idioms, references to other entries, and external links. *Mrežnik* is based on the *Croatian Web Repository* corpus and the *hrWaC – Croatian web corpus*. In addition to these sources, all other available print and web sources are taken into account in writing definitions and providing examples and meanings. *Mrežnik* is created using the TshwaneLex dictionary compilation software that allows the creation of the desired structure and fields for dictionary entries. *Mrežnik* consists of three modules. In the first phase of the project, the module for adult native speakers of Croatian will have 10,000 entries, the module for school-children will have 3,000 entries, and the module for non-native speakers will have 1,000 entries. Games based on the dictionary content for all three models are developed within the project. The conceptual framework of gamification of born-digital dictionaries takes into account the process of developing, testing, and implementing these games within the dictionary. At the end of the *Mrežnik* project, the online dictionary with its games will be publically available on the web site rjecnik.hr.

Gamification is a process in which game elements are implemented in non-gamelike situations to make them more fun. Gamification is used in many areas such as education and fitness. Many learning applications such as CodinGame for learning computer languages and Duolingo for foreign language learning use games (mostly quizzes) and gamification elements such as scoring, leaderboards, badges, and skill trees. A lot of research using games for learning purposes has been conducted but it does not focus on gamifying the dictionary content and testing it for learning purposes. Technology for creating games has progressed and now there are a lot of web services such as H5P, Quizlet, EclipseCrossword, etc. and free game codes with no copyright restrictions which are available on sites like CodePen and GitHub for creating educational games.

Before creating dictionary games for the *Mrežnik* dictionary, the types of educational games and gamification elements used on websites of lexicographic publications had to be identified. Hence, the first research question in this thesis is:

- RQ₁: *Which gamification elements are present in Croatian and foreign lexicographic e-publications?*

To answer this research question, an analysis of 181 web dictionaries and 71 encyclopedias was conducted. The websites were found on the *Wikipedia* list of lexicographic publications and academic search engines RefSeek and iSEEK. The research showed that only 26 web dictionaries and 10 web encyclopedias contain games or gamification elements. Games identified on these sites are quizzes, drag-n-drop games, puzzles, crosswords, fill in the blanks games, listening games (games for spelling of heard words), offline materials for games, games for finding words, memory, typing games, hangman, and unique games. The table below shows the number of game types in online dictionaries and encyclopedias.

Table 1. *Number of game types in online dictionaries and encyclopedias*

quiz	drag-n-drop game	puzzles	crosswords	fill in the blanks	games for the spelling of heard words
26	10	6	5	5	5
offline materials for games	unique games	memory	hangman	games for finding words	typing games
5	4	3	3	2	1

Within each of these games and on websites of online dictionaries and encyclopedias these gamification elements were identified: scoring, levels, time limit, leaderboards, avatar, badges or other award systems, and story with quests. The table below shows the number of gamification elements in online dictionaries and encyclopedias.

Table 2. *Number of gamification elements in online dictionaries and encyclopedias*

scoring	levels	time limit	leaderboards	avatar	badges or other award systems	story with quests
26	15	13	7	6	6	2

The tables above show that quizzes are currently the game type which appears most frequently, followed by drag-n-drop games. Most of these games feature gamification elements of scoring and some games have levels divided by content or game difficulty adjustment. Dictionaries,

unlike encyclopedias, do not have any unique games. A story with a quest is the least present gamification element in lexicographic games.

To get more data about educational game and gamification elements in addition to the previous research question the research was expanded with the next research question:

- RQ₂: *Which gamification elements are present on the library, archives, and museum websites?*

To answer that question 179 museum, 254 library, and 21 archive websites were analyzed. It was determined that only 18 libraries, 11 museums, and 2 archives contain games, links to games, or gamification elements. The table below shows the number of game types on archives, libraries, and museum websites.

Table 3. *Number of game types on archive, library, and museum websites*

quizzes	puzzles	drag-n-drop games	fill in the blanks	unique games	memory games	crosswords
27	23	18	15	5	3	1

Gamification elements identified within each of these games and on websites are shown in the table below.

Table 4. *Number of gamification elements on archive, library, and museum websites*

scoring	levels	story with quests	time limits	avatar	badges or other award systems
28	20	19	15	14	13

From the tables above, we can conclude that there are fewer game types identified on archive, library, and museum websites than on dictionary and encyclopedia websites (7 game types on archive, library, and museum websites compared to 12 game types identified for dictionaries and encyclopedias). Same as in dictionaries and encyclopedias on archive, library, and museum websites quizzes are the game type that occurs most frequently and scoring is the gamification element which occurs most often. Stories and quests are present more often on these websites because they are appropriate for presenting cultural and historic content as it is easier to tell a story through games.

On the bases of this analysis and the identification of game types and game elements from educational websites, the first demo versions of games for *Mrežnik* were created. The demo versions of these games were presented to schoolchildren and non-native speakers learning

Croatian as a foreign language. Their reactions were noted, analyzed, and taken into consideration for further development of games.

Games for *Mrežnik* were created using available free technology that had no copyright restriction. Most of the games were developed through available codes on Codpen and GitHub websites, and some games were developed through the H5P platform. The demo versions of the games were published online through GitHub and GitLab repositories. Currently, many different game types were developed such as quizzes, crosswords, typing games, fill in the blanks, drag-n-drop, memory, etc. and they implement mentioned gamification elements such as scoring, leaderboards, levels, time limits, and badges. The finished games organized by categories will be published on the address: rjecnik.hr/igre.

To test the effectiveness of these games, after getting the permission from the Ethics Committee for this research, the research was conducted on two groups of students who learn Croatian in Croaticum – Centre for Croatian as a Second and Foreign Language. The research was conducted in online classes during the pandemic of the COVID-19 disease (from 6th April to 22nd April 2020). The experimental group (9 students) used games published on GitHub during their class: <https://bornal2.github.io/croaticum/>. The control group (12 students) had the same lesson but did not use educational games in class. To compare their progress, the same vocabulary test was given to students in both classes. At the beginning of the first class, they wrote a pretest to analyze and compare their initial knowledge of the vocabulary that is to be learned in the lesson. The posttest, which is the same as the pretest but the questions are in a different order, was given to the students of both groups at the end of that class to see their progress after the class. After two weeks they wrote a delayed posttest, which was again the same as the previous two tests, to check their long-term vocabulary retention.

The results of all three tests were used to test the hypotheses:

- H_{a0} : *Students who learned Croatian as a foreign language and are going to use gamified materials did not achieve significantly different results in the pretest than students who are not going to use gamified materials.*
- H_{a1} : *Students who learned Croatian as a foreign language and are going to use gamified materials achieve significantly different results in the pretest than students who are not going to use gamified materials.*
- H_{b0} : *Students who learned Croatian as a foreign language and used gamified materials do not achieve significantly better results in Croatian vocabulary tests than students who have not used gamified materials.*

- *H_{b1}: Students who learned Croatian as a foreign language and used gamified materials achieve significantly better results in Croatian vocabulary tests than students who have not used gamified materials.*
- *H_{c0}: Students who learned Croatian as a foreign language and used gamified materials achieve significantly lower or equal progress in Croatian vocabulary tests compared to students who have not used gamified materials.*
- *H_{c1}: Students who learned Croatian as a foreign language and used gamified materials achieve significantly better progress in Croatian vocabulary tests compared to students who have not use gamified materials.*
- *H_{d0}: Students of Croatian as a foreign language after using gamified materials achieve significantly lower or equal results in Croatian vocabulary tests.*
- *H_{d1}: Students of Croatian as a foreign language after using gamified materials achieve significantly better results in Croatian vocabulary tests.*
- *H_{e0}: Students of Croatian as a foreign language who like electronic games did not achieve significantly different results in Croatian vocabulary tests from students who do not like electronic games or are neutral to them.*
- *H_{e1}: Students who learn Croatian as a foreign language and like electronic games achieve significantly different results in Croatian vocabulary tests from students that do not like electronic games or are neutral to them.*
- *H_{f0}: There is no significant correlation between students' results in Croatian vocabulary tests and their self-evaluation of their current knowledge of the Croatian language.*
- *H_{f1}: There is a significant correlation between students' results in Croatian vocabulary tests and their self-evaluation of their current knowledge of the Croatian language.*

Hypothesis H_f was tested with the Spearman correlation, hypotheses H_b and H_c were tested using a one-way Mann-Whitney U-test, hypotheses H_d was tested using Wilcoxon signed-rank test, and hypotheses H_a and H_e were tested using the two-way Mann-Whitney U-test. The calculation for all these tests was done using the programming language R. The power of each test was calculated using the programming language R or program G*Power to measure the power of the result given by the statistical test based on sample (n) and effect size (d). Based on the results of statistical and power tests alternative hypothesis in H_d was accepted that students achieve significantly better results after using gamified materials. For H_b only in the analysis of the delayed posttest, which analyses long-term memory, the null hypothesis was accepted that students who use gamified materials after two weeks achieve equal or worst

results than students who were not using gamified materials. For other hypotheses, null-hypothesis would be accepted if the power of the test was higher so no valid conclusion concerning these hypotheses could be made. However, based on descriptive statistics for H_c in the first posttest results and delayed posttest results, we can see that students from the experimental group have improved after the pretest, more than the control group.

Students from both groups also completed a short questionnaire after the first posttest. Most students (17) mention that they use a web dictionary for learning Croatian. Eleven students (six from the experimental group, five from the control group) said that they like playing electronic games, nine students are neutral to them and only one student does not like to play electronic games. Students from the experimental group also answered a question about the games used during their class. Eight out of nine students enjoyed learning through games. Those students agreed that these games are good, simple, and fun for learning the Croatian language. Two students commented that some games are maybe too simple for advanced learners and that more descriptive words and examples of word usage could be implemented.

The results of the conducted research implicate that games have the potential to help students in learning Croatian as a foreign (other) language. The methodology for conducted research can also be used for future research with a larger sample which could give more statistically significant results. Based on observation during class, research results, and students' feedback current games developed for the *Mrežnik* project were modified to allow more difficulty adjustments and have more examples of using a certain word or explaining a certain language rule. More adjectives were added to motivate the player.

The next hypothesis tests the possibility to create a conceptual framework for the gamification of a web dictionary based on previously identified gamification elements. To prove the hypothesis, we must take into consideration which educational game types and gamification elements are present on the dictionary and encyclopedia websites as well as on the websites of other educational institutions. We must also take into consideration how these games are created, tested, and implemented within born-digital dictionaries and how can we check whether they are successful with users. Based on that, seven steps of the conceptual framework of gamification of born-digital dictionaries were designed:

1. deciding on the educational contents and goals of the game;
2. designing game types and deciding which gamification elements to use;
3. game development;
4. game testing and updating;
5. game publishing;

6. game promoting;
7. monitoring user satisfaction.

The steps in the designed conceptual framework are mostly linear so when one step finishes the next step begins. However, game creators can return from step seven to step four to fix bugs or mistakes or update the game content based on user feedback.

When creating a conceptual framework for gamifying e-dictionaries, the first step consists of choosing dictionary content that the creator of games wants to gamify and selecting the targeted group for which the gamified content is developed (e.g. elementary school children, non-native speakers, university students). In *Mrežnik*, games based on dictionary content were categorized as spelling games, phonological games, morphological games, syntactic games, discourse games, lexical games, word formation games, and games for learning the elements of the Croatian culture. Within each of these categories, games for the three modules of *Mrežnik* (adult native speakers, school-children, and non-native speakers) were developed.

The starting point for the second step is to decide what type of games will be developed for the selected dictionary contents and for the targeted players selected in step one. When the game type is decided on the process of choosing which gamification elements can be implemented within the selected game types (timelimit, levels, badges, etc.) and which assignments created from dictionary content will be incorporated into the game. For this step, it is important to know which game types for educational games exist and what gamification elements can be used. This was analyzed in this thesis within the first two research questions. On the example of *Mrežnik*, many game types are presented with their gamification elements which are used for gamifying all categorized dictionary content.

When games and game elements have been selected the development of games can start (step three). For game development, first the adequate technology that can allow creating games based on decisions made for previous steps has to be chosen. Sometimes this technology, code, or program for developing games has to be tested to see if it allows game creation based on the concept for the desired game. If testing proves so, the selected technology can be used for final game development.

After the first version of the game is created, the process of testing the game, fixing bugs, and potentially updating game content can begin (step four). Game testing can be done by the game developer himself, but it is also recommended to have other users, that represent the targeted audience for the game, test the game, and give their feedback. If the game, after a few tests, is playable, has no major problems, and covers everything planed in the concept, it can be published. In the case of *Mrežnik*, games were created using available free technology and demo

versions of the games were presented and tested by the developer, his colleagues, and coworkers but also by some members of the target user groups to get feedback.

For publishing (step five), descriptive meta tags (description, keywords) that can help users on the internet find the game have to be added. Code for web platforms such as Google Analytics can also be implemented in the publishing process to follow user interaction with website games. At the end of the project, when implementing games into *Mrežnik*, a separate page for all games where the games are categorized will be created so the users can easily browse through them (on previously mentioned link rjecnik.hr/igre). Games have categories and subcategories on dictionary websites based on their content (these categories were decided on in step one). Games will also have tags to connect games of the same type (e.g. memory, quiz, etc.). A unique feature of *Mrežnik*, which was not found on any dictionary or encyclopedia websites, is that links to some games will be implemented into the entry structure by external links, i.e. certain dictionary entries will have links to games that cover the content of that entry. After the games are published, the next step is to promote them (step six). Promotion can easily and cheaply be done through social media where players can further share the game and even give direct feedback to the developer. In addition to social media, it is also good to have articles written about the games on website portals that are visited by potential players and to promote the games on certain TV shows, in newspapers, and magazines. Another way to promote educational games and also get instant feedback is to have workshops for learners or teachers. All those promotional methods are planned and have already been partly conducted for *Mrežnik*. The last step (step seven) focuses on monitoring user satisfaction. This can also be done through social media since the users can freely give their opinion. Google Analytics can also be used to check which games or parts of games are being played most often. Questionnaires can also be given to players. Player feedback can be used for creating new games or updating the existing ones and adding new content (which can lead back to step four).

Therefore, by explaining and giving examples for all seven steps and creating games based on the content of the born-digital dictionary *Mrežnik*, we can conclude that it is possible to create a conceptual framework for the gamification of a Croatian born-digital dictionary. The steps of this conceptual framework can also be used for gamifying other lexicographic works. This conceptual framework can also help in developing the methodology for gamifying language content in the digital environment and language games created for *Mrežnik* can help players in learning Croatian language and dictionary content.

The thesis opens further questions that require more research in the future such as:

- a) how to modify the conceptual framework for gamifying encyclopedias (and possibly archive, museum, and library content);
- b) how would results of using gamified dictionary content for learning purposes (possibly not online) with a larger sample and different groups (this includes not only doing research on non-native speakers) fair compared to current research results;
- c) how to implement crowdsourcing for further gamification of lexicographic works;
- d) with the development of the game industry, will there be a need to identify more educational game types and usable gamification elements in the future.

Keywords: conceptual framework, educational games, game development, game-based learning, gamification elements, gamification, web dictionary

Tablica sadržaja

1. UVOD	1
1.1. Cilj i hipoteze istraživanja	2
1.2. Metodologija	2
2. TERMINOLOŠKE NAPOMENE I RAZGRANIČENJA	5
2.1. Konceptualni okvir	5
2.2. Mrežni rječnik	6
2.3. Igrifikacija	7
2.3.1. Igra	9
2.3.2. Igrifikacijski elementi	10
2.3.3. Razgraničenje igrifikacije od ostalih srodnih pojmova	13
2.4. E-leksikografija	14
2.4.1. Podjela e-leksikografskih djela	17
2.4.2. Istraživanja utjecaja e-leksikografije na usvajanje jezičnih sadržaja	18
3. PRIMJENA IGRIFIKACIJE I ISTRAŽIVANJA O IGRIFIKACIJI	21
3.1. Primjena igrifikacije u tjelovježbi i sportu	21
3.2. Primjena igrifikacije u obrazovnim sustavima	24
3.2.1. Primjena igrifikacije u učenju jezika	28
3.3. Značajke igrificiranih aplikacija i sustava	33
3.4. Igrifikacija i <i>crowdsourcing</i>	35
3.5. Pregled dosadašnjih istraživanja o igrifikaciji	41
3.5.1. Istraživanja o obrazovnim igrama	42
3.5.2. Istraživanja o sustavima i aplikacijama za učenje i vježbanje	45
3.5.3. Istraživanja o negativnim utjecajima igrifikacije	48
4. PROJEKT <i>HRVATSKI MREŽNI RJEČNIK – MREŽNIK</i>	51
4.1. Dodatni sadržaji izrađeni za <i>Mrežnik</i>	55
4.1.1. Odostražni rječnik	55

4.1.2. Stranice projekta <i>Mrežnik</i>	57
4.1.3. Etnici i ktetici	60
4.1.4. Frazemi.....	60
4.2. Tehnologija rada na <i>Mrežniku</i>	62
4.2.1. Sketch Engine.....	62
4.2.2. TLex (TshwaneLex).....	67
4.3. Ostale dostupne tehnologije za izradu mrežnih rječnika.....	71
5. ZASTUPLJENOST IGRIFIKACIJSKIH ELEMENATA U LEKSIKOGRAFSKIM IZDANJIMA I INFORMACIJSKIM USTANOVAMA	74
5.1. Metodologija	76
5.2. Razredba leksikografskih djela	77
5.3. Analiza e-rječnika	78
5.3.1. Igre na stranicama e-rječnika	81
5.3.2. Analiza igrifikacijskih elementa igara e-rječnika.....	91
5.4. Analiza e-enciklopedija.....	95
5.4.1. Igre na stranicama e-enciklopedija.....	97
5.4.2. Analiza igrifikacijskih elementa igara e-enciklopedija.....	106
5.5. Zaključak analize o zastupljenosti igrifikacijskih elemenata u leksikografskim djelima	108
5.6. Igrifikacijski elementi na mrežnim stranicama informacijskih ustanova.....	111
5.6.1. Igrifikacija sadržaja muzeja.....	111
5.6.2. Igrifikacijski elementi na stranicama arhiva	118
5.6.3. Igrifikacijski elementi na stranicama knjižnica.....	123
5.6.4. Zaključak analize o zastupljenosti igrifikacijskih elemenata na mrežnim stranicama informacijskih ustanova	130
6. TIPOVI OBRAZOVNIH IGARA.....	132
6.1. Pedagoški aspekti igara	133
6.2. Tehnički aspekti igara	136

6.3. Rezultati analize	139
6.4. Razvoj obrazovnih igara.....	143
6.5. Zaključak	155
7. ISTRAŽIVANJE NA CROATICUMU	160
7.1. Hrvatski kao ini jezik	160
7.2. Plan istraživanja	162
7.3. Izrada igara za istraživanje na Croaticumu	166
7.4. Predtest, posttest i odgođeni posttest.....	170
7.5. Provedba nastave.....	171
7.6. Uzorak studenata	175
7.7. Zadovoljstvo igrama eksperimentalne skupine	182
7.8. Rezultati testova	185
7.8.1. Rezultati predtesta	185
7.8.2. Rezultati posttesta	188
7.8.3. Rezultati odgođenoga posttesta	191
7.8.4. Sociodemografske usporedbe rezultata	193
7.8.5. Metodologija	197
7.8.6. Provjera hipoteza.....	209
7.9. Zaključak istraživanja.....	226
8. KONCEPTUALNI OKVIR IGRIFIKACIJE MREŽNOGA RJEČNIKA.....	229
8.1. Koraci konceptualnoga okvira	230
8.1.1. Određivanje obrazovnih sadržaja i ciljeva igara	231
8.1.2. Osmišljavanje igara i određivanje koji će se igrifikacijski elementi uključiti	233
8.1.3. Izrada igara	263
8.1.4. Testiranje i dorada igara	264
8.1.5. Objava igre	266
8.1.6. Promocija igre	272

8.1.7. Praćenje zadovoljstva korisnika	274
8.2. Cjeloviti pregled konceptualnoga okvira	275
9. ZAKLJUČAK	278
10. POJMOVNIK.....	286
11. LITERATURA.....	299
11.1. Publikacije.....	299
11.2. Mrežni izvori.....	312
12. PRILOZI.....	343
12.1. PRILOG 1 – Rječnici za čije je mrežne sadržaje provjereno imaju li igrifikacijske elemente	343
12.2. PRILOG 2 – Enciklopedije za čije je mrežne sadržaje provjereno imaju li igrifikacijske elemente	346
12.3. PRILOG 3 – Hrvatski muzeji s interaktivnim sadržajima	348
12.4. PRILOG 4 – Najpopularniji strani muzeji za čije je mrežne sadržaje provjereno imaju li igrifikacijske elemente	356
12.5. PRILOG 5 – Pregled obrazovnih sadržaja na mrežnim stranicama 21 svjetskog arhiva	358
12.6. PRILOG 6 – Knjižnice za čije je mrežne sadržaje provjereno imaju li igrifikacijske elemente	360
12.7. PRILOG 7 – Test za studente s Croaticuma	367
12.8. PRILOG 8 – Upitnik za prikupljanje podataka o studentima s Croaticuma	376
12.9. PRILOG 9 – Upitnik za studente eksperimentalne skupine s Croaticuma povezan sa zadovoljstvom igrama	378
12.10. PRILOG 10 – Studenti po zemlji	380
12.11. PRILOG 11 – Rezultati studenata Croaticuma iz predtesta, posttesta i odgođenoga posttesta.....	381
12.12. PRILOG 12 – Napredak u broju bodova u posttestu i odgođene posttestu studenata Croaticuma	382
12.13. PRILOG 13 – Natuknice <i>Mrežnika</i> koje će sadržavati poveznice na igre	384

12.14. PRILOG 14 – Konceptualni okvir igrifikacije mrežnoga rječnika	385
13. POPIS SLIKA	387
14. POPIS TABLICA.....	391
15. POPIS GRAFIKONA	396
16. ŽIVOTOPIS S POPISOM RADOVA.....	398

1. UVOD

Tema je rada izgradnja konceptualnoga okvira igrifikacije hrvatskoga mrežnog rječnika. Istraživanje se provodi u sklopu istraživačkoga projekta *Hrvatski mrežni rječnik – Mrežnik* (IP-2016-06-2141), koji u cijelosti financira Hrvatska zaklada za znanost, a provodi se u Institutu za hrvatski jezik i jezikoslovlje. Voditeljica je projekta Lana Hudeček. Projekt traje od 1. ožujka 2017. do 31. srpnja 2021. Pristupnik je doktorand na tome projektu. *Mrežnik* je prvi hrvatski mrežni rječnik koji se izrađuje isključivo za mrežu (engl. *born-digital*, *web-born*). *Mrežnik* se sastoji od triju modula: osnovni modul, modul za učenike nižih razreda i modul za neizvorne govornike hrvatskoga jezika. Sadržaji svih triju modula *Mrežnika* bit će igrificirani s pomoću igara koje se koriste različitim igrifikacijskim elementima kako bi bile učinkovitije. Na stranicama *Mrežnika*¹ napraviti će se podstranica s igrama (predviđena je domena stranice rjecnik.hr/igre) te će igre biti kategorizirane po tipu i sadržaju. Usto će se pojedine natuknice povezivati s određenim obrazovnim igrama.

U svrhu izgradnje konceptualnoga okvira provedena je i analiza elemenata igrifikacije stranih rječnika i enciklopedija, posebno onih koji su namijenjeni djeci i/ili neizvornim govornicima. Također su analizirane igre te igrifikacijski elementi koji su prisutni na stranicama drugih informacijskih i obrazovnih ustanova: arhiva, muzeja i knjižnica. Analizom je obuhvaćena i primjena elemenata igrifikacije u poznatim mrežnim servisima (Duolingo, Codingame) i aplikacijama (Pokémon GO, Zombies, Run!).

U radu se provjerava koliko su određeni interaktivni sadržaji poput igara i kvizova učinkoviti kao medij za učenje jezičnih sadržaja. Poznavanje jezičnih sadržaja testirano je na dvije skupine neizvornih govornika koji uče hrvatski na Croaticumu – Centru za hrvatski kao drugi i strani jezik² koristeći se pretestom, posttestom i odgođenim posttestom. Cilj je takvoga istraživanja provjeriti poboljšavaju li igrificirani sadržaji rezultate pri usvajanju vokabulara. Temeljem rezultata provedenoga istraživanja modificirane su neke igre kako bi se postigli bolji rezultati u usvajanju gradiva.

U završnome dijelu rada prikazani su koraci konceptualnoga okvira igrifikacije mrežnoga rječnika.

¹ URL: <http://ihjj.hr/mreznik> (17. 1. 2020.)

² URL: <https://croaticum.ffzg.unizg.hr/?lang=hr> (17. 1. 2020.)

1.1. Cilj i hipoteze istraživanja

Cilj je ovoga rada izraditi konceptualni okvir igrifikacije e-rječnika s obzirom na njegovu vrstu i korisnike. U ovome radu to je jednojezični rječnik za neizvorne govornike hrvatskoga jezika koji uče hrvatski kao ini jezik. Da bi se izradio konceptualni okvir (prikupljanje podataka, obrada podataka, evaluacija rezultata), postavljeno je iduće istraživačko pitanje:

- IP₁: *Koji su igrifikacijski elementi zastupljeni u hrvatskim i stranim leksikografskim e-izdanjima?*

Nakon provedenoga istraživanja zaključeno je da će se zbog iscrpnijih rezultata to istraživačko pitanje proširiti i ovim pitanjem:

- IP₂: *Koji su igrifikacijski elementi zastupljeni na stranicama knjižnica, arhiva i muzeja?*

Rezultati provedenih istraživanja bili su polazište za izradu konceptualnoga okvira igrifikacije mrežnoga rječnika. Kako bi se izradio konceptualni okvir te povezali ključni koraci procesa igrifikacije, provedeno je istraživanje sa studentima koji uče hrvatski jezik na Croaticumu te je na temelju rezultata analize istraživanja modificiran uspostavljeni konceptualni okvir. U ovome će se radu stoga provjeriti te dvije glavne hipoteze (napomena H₁ u poglavlju *Istraživanje na Croaticumu* hipoteza je H_b jer se tijekom provedbe istraživanja dokazivalo više hipoteza):

- H₁: *Osobe koje uče hrvatski kao ini jezik, a koje se služe igrificiranim sadržajima, postižu statistički značajno bolje rezultate na testu usvajanja vokabulara od osoba koje se ne služe igrificiranim sadržajima.*
- H₂: *Moguće je izraditi konceptualni okvir igrifikacije mrežnoga rječnika na temelju identifikacije igrifikacijskih elemenata obrazovnih sadržaja.*

1.2. Metodologija

Metodologija je podređena predmetu istraživanja i analiziranomu problemu te se razlikuje za svaku navedenu hipotezu i istraživačko pitanje.

Za dobivanje odgovora na istraživačka pitanja upotrijebit će se komparativna analiza. Analiza se provodi prema unaprijed utvrđenim kriterijima i prikazuje u tablicama i grafikonima s pomoću kojih se analiziraju interaktivni obrazovni elementi leksikografskih e-izdanja te knjižnica, arhiva i muzeja. Analiza e-leksikografskih izdanja provodi se tako da su unaprijed određeni kriteriji analize koji se provjeravaju (i po potrebi dopunjavaju) za različita e-izdanja. U zaključku se uspoređuju tipovi igara (pamtalice, križaljke, slagalice, kvizovi, igre povezivanja itd.) i igrifikacijski elementi (bodovanje igrača, natjecanje među igračima, razine, prilagodba težine, vremensko ograničenje itd.) u stranim i hrvatskim e-leksikografskim izdanjima.

Dodatno su pregledane mrežne stranice i sustavi (posebno obrazovni sadržaji, svi elementi igre i multimedijškoga prikaza) različitih muzeja, knjižnica, arhiva, obrazovnih i izdavačkih ustanova te su utvrđeni elementi koji mogu biti korisni pri izgradnji konceptualnoga okvira igrifikacije i multimedijškoga prikaza sadržaja mrežnoga rječnika. Prikupljeni igrifikacijski elementi utječu na oblikovanje novih tipova igara i razvijanje konceptualnoga okvira igrifikacije mrežnoga rječnika.

Za provjeru prve hipoteze primjenjuje se metoda komparativne i statističke analize. U istraživanju provedenome s osobama koje uče hrvatski kao ini jezik u Centru za hrvatski kao drugi i strani jezik – Croaticumu provjerava se hipoteza da osobe koje se služe igrificiranim sadržajima pokazuju bolje rezultate i bolji napredak u provjerama znanja usvojenosti vokabulara od onih koji se njima ne služe. Istraživanje je provedeno s pomoću testova s eksperimentalnom i kontrolnom skupinom. Skupine čine studenti različiti po sociodemografskim podacima jer dolaze iz različitih dijelova svijeta. Skupine uglavnom sačinjavaju studenti između 20 i 40 godina. U dogovoru s voditeljicom Croaticuma odabrane su dvije skupine za koje je procijenjeno da su najujednačenije s obzirom na predznanje hrvatskoga jezika (razina znanja A2), broj polaznika, dob i sociodemografske podatke. Za studente obiju skupina prikupljeni su podaci o poznavanju drugih jezika osim materinskoga i hrvatskoga. Svi prikupljeni podaci upotrijebljeni su isključivo u svrhu provedenoga znanstvenog istraživanja. Identitet sudionika skupine znaju samo nastavnici koji rade s njima. Tijekom testiranja studenti su se koristili proizvoljno odabranim korisničkim imenima koja ne ukazuju na njihov identitet. Ispitivač ne zna ništa o studentima osim njihova korisničkoga imena, njihova materinskoga jezika te poznavanja drugih jezika osim hrvatskoga i materinskoga, zemlje podrijetla, dobi, njihova mišljenja o zadovoljstvu igrama te rezultata na testu. Nakon izlaganja gradiva (s igrificiranim sadržajem u eksperimentalnoj skupini) provjerilo se znanje sudionika istraživanja. S kontrolnom se skupinom radilo klasičnom metodom poučavanja, a s eksperimentalnom skupinom s igrificiranim sadržajima. Na kraju sata testirano je znanje obiju skupina. Dva tjedna nakon provedbe prvoga testiranja proveden je odgođeni posttest kako bi se provjerilo zadržavanje usvojenoga gradiva. Između prvoga i drugoga sata u istraživanju studenti na nastavi nisu ponavljali sadržaje iz predtesta te nisu imali pristup igrama. Valjanost prve hipoteze provjerila se s pomoću Mann-Whitneyjeva U-testa. Studenti eksperimentalne skupine nakon sata s igrificiranim sadržajem ispunili su upitnik o tome koji je njihov materinski jezik, na kojemu su se jeziku obrazovali, koje sve jezike znaju, kojim su se obrazovnim sustavima i igrama prije koristili te koliko su zadovoljni igrama kojima su se koristili na satu. Također su polaznici odgovorili na pitanje bi li se htjeli dalje služiti takvim igrama u učenju te što bi

promijenili u igrama u svrhu njihova poboljšanja. Detaljnije o istraživanju i rezultatima opisano je u poglavlju *Istraživanje na Croaticumu*.

Druga je hipoteza provjerena tako što je autor samostalno, ali uzimajući u obzir rezultate prve hipoteze te koristeći se različitim provedenim analizama, izradio konceptualni okvir igrifikacije hrvatskih mrežnih rječnika. Analize koje su uzete u obzir pri izradi konceptualnoga okvira jesu: analiza obrazovnih sadržaja koji su obuhvaćeni istraživačkim pitanjem i analiza obrazovnih sadržaja drugih obrazovnih i informacijskih ustanova (kao što su arhivi, muzeji, knjižnice itd.), obrada *Hrvatskoga mrežnog rječnika – Mrežnika* i vlastita istraživanja korištenjem metodom korpusne analize (Word Sketches) pri pripremi nekih igara, testiranje demoinačica igara s različitim skupinama učenika i studenata te opažanje reakcije učenika i studenata u razgovorima s nastavnicima. Da bi se provelo testiranje, bilo je potrebno razviti igre, ali su i rezultati istraživanja utjecali na prilagodbu i doradu konceptualnoga okvira.

2. TERMINOLOŠKE NAPOMENE I RAZGRANIČENJA

Cilj je ovoga poglavlja obraditi značenje ključnih naziva (i njima pridruženih pojmova i istovrijednica na engleskome jeziku) iz naslova ovoga rada. Takvo terminološko razgraničenje nužno je za preciznije određenje predmeta istraživanja. Osim naziva iz naslova rada odredit će se i značenje naziva *igrifikacijski element* jer je to ključni naziv za temu ovoga rada. Definicije drugih temeljnih naziva koji se upotrebljavaju u ovome radu nalaze se u pojmovniku u dodatku rada.

2.1. Konceptualni okvir

Konceptualni okvir struktura je s pomoću koje istraživač želi objasniti određeni fenomen koji proučava (Camp, 2001). Struktura se odnosi na elemente i procese koji su prikupljeni iz prethodnih istraživanja drugih istraživača i iz istraživačeva promatranja predmeta istraživanja (Patrick, 2015). Konceptualni okvir povezan je s konceptima, empirijskim istraživanjima i teorijama koje se primjenjuju za promoviranje i usustavljivanje znanja koje zagovaraju istraživači (Peshkin, 1993). On prikazuje moguća rješenja određenih problema koja su još u razvojnoj fazi (Liehr i Smith, 1999). Iz statističke perspektive konceptualni okvir opisuje odnos između glavnih koncepata istraživanja. Konceptualni okvir često se grafički prikazuje kako bi se prikazale jasne veze među novim konceptima u istraživanju (Grant i Osanloo, 2014). On olakšava istraživačima da odrede i definiraju pojmove i procese unutar svojega istraživanja te omogućuje drugim istraživačima da iz konceptualnoga okvira prouče te ponove metodologiju istraživanja (Luse, Mennecke i Townsend, 2012). Koraci su izrade konceptualnoga okvira sljedeći:

1. odrediti metodološki ključne korake istraživanja (npr. prikupljanje podataka, obrada podataka, evaluacija rezultata, razvoj aplikacije, testiranje aplikacije)
2. odrediti koliko su povezani koraci istraživanja (npr. jesu li koraci poput prikupljanja, obrade podataka te razvoja aplikacije i testiranja aplikacije napravljeni linearno ili usporedno)
3. pronaći temeljni element koji razvija i završava određeni ključni korak istraživanja (stoga svaki ključni korak ovoga istraživanja završava s kratkim zaključkom, uglavnom tablično prikazanim)
4. pronaći elemente koji povezuju jedan ključni korak s drugim
5. koristiti se strelicama ili drugim grafičkim oblicima kako bi se pokazale veze među koracima (Attia, 2018).

Na Slici 1 prikazan je primjer konceptualnoga okvira.

Slika 1. Primjer konceptualnoga okvira za izradu alata za analizu klimatskih promjena (Attia, 2018)

2.2. Mrežni rječnik

„Izvorno mrežni rječnik (engl. *born-digital dictionary*, *web-born dictionary*) rječnik je izvorno osmišljen kao mrežni sustav, što uključuje lakše međusobno povezivanje rječničkoga sadržaja (engl. *cross-referencing*) i rječničkoga sadržaja s drugim mrežnim sadržajima, unošenje u rječnik sadržaja poput audiozapisa i videozapisa te mogućnost komunikacije s korisnicima koji mogu biti i aktivni sudionici u stvaranju rječničkoga sadržaja.” (Hudeček i dr., 2018). Izvorno mrežni rječnik treba razlikovati od rječnika koji je izvorno osmišljen kao knjiga te postavljen na mrežu. Prednosti su mrežnoga rječnika povezane s ovom temom da on nije prostorno ograničen te da je moguće pretraživanje svih elemenata i povezivanje sadržaja mrežnoga rječnika s drugim mrežnim sadržajima. Ti sadržaji mogu obuhvaćati i igre, što će se pokazati u ovome radu.

2.3. Igrifikacija

Za engleski naziv *gamification* u hrvatskome se upotrebljavaju nazivi *gemifikacija*, *gamifikacija* i *igrifikacija*. S pomoću stranice Google trendovi³ može se utvrditi koliko se često riječ *gamification* pretražuje na Googleovoj tražilici u određenim vremenskim odsječcima. Rezultati pretraživanja pokazuju da je u cijelome svijetu popularnost igrifikacije od godine 2011. porasla, s time da je u posljednjih nekoliko godina (od 2014. do 2019.) čestoća pretraživanja ostala približno ista (oscilacije su male) (vidi sliku 2).

Slika 2. Prikaz pretraživanja riječi igrifikacija na Google tražilici od 2004. godine

Lovrenčić i dr. (2018: 1) s pomoću Googleove tražilice u srpnju 2018. provjerili su rezultate pretraživanja naziva *gemifikacija*, *gamifikacija* i *igrifikacija* na .hr domenama te utvrdili da je indeksirano 613 stranica koje se koriste nazivom *igrifikacija*, 464 stanica koje se koriste nazivom *gamifikacija* i 218 stranica koje se koriste nazivom *gemifikacija*. Kad su ograničili pretraživanje na PDF dokumente, što uglavnom uključuje znanstvene i stručne radove, prezentacije i priručnike, naziv *igrifikacija* bilo je zastupljen u 124 PDF dokumenta, naziv *gemifikacija* u 39 PDF dokumenata, a naziv *gamifikacija* u 29 PDF dokumenata. Autor je u siječnju 2020. provjerio koliko su se promijenili rezultati pretraživanja tih naziva na .hr domeni. Za izraz *igrifikacija* indeksirano je 2290 stranica, za izraz *gamifikacija* 706 stranica te za *gemifikacija* 377 stranica. Kod pretraživanja PDF dokumenata pronađen je 219 PDF dokumenata koji sadržavaju izraz *igrifikacija*, 76 dokumenata koji sadržavaju izraz *gamifikacija* te 51 PDF dokument koji sadržava izraz *gemifikacija*. Brojke pokazuju da je u

³ URL: <https://trends.google.com/trends/?geo=US> (18. 1. 2020.)

razdoblju od godinu dana i osam mjeseci u Hrvatskoj znatno porastao broj radova i mrežnih stranica koji se odnose na igrifikaciju. Također se vidi da je naziv *igrifikacija* sve bolje prihvaćen ta istiskuje nazive *gamifikacija* i *gemifikacija* (vidi tablicu 1).

Tablica 1. *Indeksirane stranice koje sadržavaju nazive gemifikacija, gamifikacija i igrifikacija*

	svibanj 2018.	siječanj 2020.
Broj stranica s .hr domenom koje sadržavaju naziv <i>igrifikacija</i>	613	2290
Broj PDF dokumenata na .hr domenama koje sadržavaju naziv <i>igrifikacija</i> :	124	219
Broj stranica s .hr domenom koje sadržavaju naziv <i>gamifikacija</i> :	464	706
Broj PDF dokumenata na .hr domeni koji sadržavaju naziv <i>gamifikacija</i> :	29	76
Broj stranica na .hr domeni koje sadržavaju naziv <i>gemifikacija</i> :	218	377
Broj PDF dokumenata na .hr domeni koji sadržavaju naziv <i>gemifikacija</i> :	39	51

Naziv *igrifikacija* preporučena je zamjena za *gamification* i na portalu *Bolje je hrvatski*.⁴ Instituta za hrvatski jezik i jezikoslovlje, pa se taj naziv dosljedno upotrebljava u ovome radu. Ne postoji jedinstvena definicija igrifikacije. Naziv *gamification* u značenju koje taj naziv ima i danas prvi je put spomenuo programer računalnih igara Nick Pelling 2002. godine i to u kontekstu oblikovanja korisničkih sučelja elektroničkih uređaja koja su slična sučeljima računalnih igara (Pelling, 2011). Jedan od najčešće citiranih radova o igrifikaciji *From Game Design Elements to Gamefulness: Defining 'Gamification* (Deterding i dr., 2011: 10) određuje igrifikaciju kao korištenje postojećim elementima igre u situacijama koje nisu igra ili se po svojoj prirodi ne smatraju igrivima.

Rječnici često definiraju igrifikaciju kao proces u kojemu se različite igre ili elementi igara ubacuju u svakodnevne procese kako bi se učinili zabavnijima i lakšima za izvođenje (Merriam-

⁴ URL: <http://bolje.hr/> (28. 5. 2019.)

Webster, 2019; Cambridge English Dictionary, 2019). „Temelji igrifikacije potječu iz teorije i industrije računalnih igara, digitalnih medija i dizajna korisničkih sučelja.” (Plantak Vukovac, Škara i Hajdin, 2018: 182). Stoga se razlikuju igrifikacijski elementi koji se izvode iz različitih računalnih igara, društvenih medija te drugih zabavnih programa i medija.

Da bismo precizno definirali igrifikaciju, potrebno je prvo definirati igru i elemente igre (koji se u daljnjemu tekstu nazivaju igrifikacijski elementi) te razgraničiti naziv *igrifikacija* od srodnih i bliskoznačnih naziva kao što su *e-učenje*, *učenje utemeljeno na igrama*, *obrazovne igre*, *ozbiljne igre* i *teorija igara*.

2.3.1. Igra

Igra je određena fizička ili mentalna aktivnost koja se smatra zabavnom i u kojoj sudjeluje jedna ili više osoba (Merriam-Webster, 2007). Igra je pojam koji se danas vrlo široko primjenjuje u društvenim i humanističkim znanostima (Hrvatska enciklopedija, 2013). U filozofiji igra ima metafizičko, ontologijsko i epistemološko značenje, ali se prije svega tiče antropologije i estetike. U psihologiji pojam igre najčešće označuje povremeno ponašanje djece ili životinjske mladunčad. U odraslih i u djece pojam igre najčešće označuje djelatnosti koje razveseljuju i opuštaju ili dovode do posebnoga uzbuđenja. U pedagogiji je igra određena kao oblik ljudske raznode, sredstvo odgoja i obrazovanja, djelatnost koja je slobodna, samomotivirajuća i nesvrhovita te u kojoj sredstva dominiraju nad ciljem. U računalnim znanostima igra je računalni program za zabavu (Ibid.).

Igra treba biti zabavna i sastoji se od pravila kojih se igrači moraju pridržavati da bi se ostvario cilj igre. U određenim igrama, poput sportskih, sudionici igre međusobno se natječu te se boduje izvršavanje njihovih aktivnosti. „Dobro osmišljena igra postaje aktivnost koja proces učenja čini zabavnim i učinkovitim te može biti zastupljena u nastavi. Igra stvara opuštenu atmosferu koja smanjuje stres te se time postižu idealni uvjeti za učenje (Deesri, 2002: 4).” (Lazić i Mihaljević, 2020: 122).

Analizom navedenih definicija možemo izdvojiti elemente igre bitne za temu ovoga rada: 1. djelatnost koja razveseljuje i opušta, 2. sredstvo odgoja i izobrazbe, 3. može biti povezana s računalima, 4. u prvome se redu odnosi na djecu, ali se može odnositi i na odrasle, 5. temelji se na pravilima kojih se igrači trebaju pridržavati da bi postigli cilj.

Obrazovna igra u prvome je redu izrađena u obrazovne svrhe ili dodatno ima određenu obrazovnu vrijednost (Meletiou-Mavrotheris i dr., 2015: 114). Svi se tipovi igara mogu upotrebljavati u obrazovanju. Obrazovne su igre, međutim, osmišljene kako bi igrači razvili određene vještine, proširili svoje znanje, usvojili znanja o ciljnim temama te se upoznali s

povijesnim ili kulturnim događajima (Huang i dr., 2013: 159). Tipovi su obrazovnih igara društvene igre, igre s kartama te videoigre. Interaktivnosti igre poučava igrača da slijedi pravila, prilagođava se određenim situacijama i rješava probleme da bi došao do cilja (Laganà, 2017: 89). Igre s pomoću kojih se uči pružaju zabavu, zadovoljstvo i uzbuđenje, mogu motivirati igrača i potaknuti ga da se bavi društvenom aktivnošću te povećati njegovu kreativnost (James, 2017). „Obrazovne igre počinju se sve više primjenjivati u obrazovnome okružju jer nastavnici, odgajatelji i vlada sve više razumiju psihološku potrebu i prednost koju igra može imati u procesu učenja (Prensky, 2001: 6).” (Lazić i Mihaljević, 2020: 122–123).

Obrazovne igre često se povezuju i s ozbiljnim igrama (engl. *serious games*), koje se definiraju kao igre kojima nije glavna svrha zabaviti igrače (Damien i dr., 2015: 1). Pridjev *ozbiljan* upotrebljava se za te igre jer su to igre koje se mogu upotrebljavati u područjima kao što su vojska, obrazovanje, znanost, zdravstvo, upravljanje resursima i ljudskim potencijalima, graditeljstvo, inženjerstvo i politika (Allbeck, 2010). Ozbiljnim je igrama svojstvena koncentracija na misaonu priču ili doticanje ozbiljnih tema u igri (Lugmayr i dr., 2016: 15707). Ozbiljne igre mogu uključiti tipične obrazovne igre poput kvizova, virtualne simulacije koja se primjenjuje u medicini, autoškolama i vojsci te čak određene komercijalne i *indie*-igre⁵.

2.3.2. Igrifikacijski elementi

Igrifikacijski elementi su preuzeti iz igre i dodani u situacije koje inače nisu igrive (popularni elementi prikazani su u tablici 2). Možemo ih podijeliti na one koji se odnose na mehaniku i dinamiku igre te one koji se odnose na dizajn igre (Ashaari i dr., 2016: 870).

Mehanika igre podrazumijeva načine interakcije koje korisnik može imati s objektima unutar igre. Igrifikacijski elementi povezani s mehanikom odnose se na načine igranja igre, koji mogu biti različiti ovisno o tipu i dinamici igre. Određeni tipovi igara poput kvizova, pamtilica i slagalica mogu na različite načine u igre uključiti multimedije, animacije, bodovanje, vremensko ograničenje za rješavanje zadataka, uporabu drugih izvora tijekom rješavanja zadataka, mogućnost igranja u paru ili sudjelovanja više igrača u igri, prilagodbu težine te izmjenjivu dinamiku igre koja se prilagođuje igraču. Mehanika igre izrađena je u skladu s dizajnom igre koji ograničuje ili proširuje mogućnosti igrača (Ashaari i dr., 2016: 869–870). Dizajn igre podrazumijeva zadane ciljeve u igri te pravila, mogućnosti i izazove unutar igre. Time se igrifikacijski elementi povezani s dizajnom odnose na priču, avatar igrača, razvoj

⁵ U industriji videoigara *indie*-igre naziv su za nezavisne igre koje najčešće radi jedna osoba ili manji tim razvijatelja igara bez financijske potpore velikoga izdavača (Gnade, 2010).

određenih vještina lika, razine u igri, napredak igrača, prikaz rezultata svih igrača u tablicama, nagrađivanje igrača za postizanje određenoga rezultata, natjecanje među igračima, dijeljenje sadržaja na društvenim mrežama itd. (Ibid.: 871). Neki igrifikacijski elementi ovise jedni o drugima poput tablice koja prati rezultate svih korisnika koja ne bi bila izvediva da nema elementa bodovanja. Rangaswami (2015: 460–461) spominje da je dizajn mrežnih igara dobar nacrt za uspješne radne uvjete koji bi mogli nastati u budućnosti jer su zadatci i ciljevi u igrama oblikovani tako da nagrađuju korisnike za ostvareni uspjeh te ih potiču na rad. Igre uspijevaju korisniku izravno dati povratnu informaciju za svaki njegov dobar i loš potez na temelju kojih on može poboljšati svoje znanje i radne rezultate. Na primjer, važno je proučiti kako se mehanike igara mogu povezati sa stvarnim svijetom te kako zaposlenici mogu dobiti pozitivne povratne informacije za svoj rad, što utječe na pozitivnu motivaciju (Deterding, 2018: 131). Osnovni igrifikacijski elementi definirani su u tablici 2.

Tablica 2. *Objašnjenje osnovnih igrifikacijskih elemenata (Figueroa, 2015: 39–40)*

igrifikacijski element	definicija	slikovni prikaz
bodovi (engl. <i>scores</i>)	brojčana vrijednost koja se dodjeljuje igraču za izvršavanje određenih aktivnosti	+50
značke (engl. <i>badges</i>)	grafički prikaz ostvarenoga uspjeha u igri koji se sprema na korisnikov profil
ljestvica poretka (engl. <i>leaderboards</i>)	prikaz poretka svih igrača u igri ili razini na temelju njihova rezultata
napredak igrača (engl. <i>progress bars/progression</i>)	prikaz napretka igrača kroz igru ili klasičnim učenjem

igrfikacijski element	definicija	slikovni prikaz
stablo igračevih vještina (engl. <i>skill tree</i>)	vizualna reprezentacija različitih vještina po kategorijama koje igrač ima ili će ih tek imati ako napreduje u igri
zadatci (engl. <i>quests</i>)	radnje koje igrač mora ostvariti kako bi dobio bodove i napredovao dalje u igri
razine (engl. <i>levels</i>)	sadržajni ili težinski dijelovi igre
priča (engl. <i>storyline</i>)	radnja igre otkriva se postupno dok korisnik prolazi kroz igru
avatar	virtualna reprezentacija igrača s pomoću koje se bilježe bodovi i napredak u igri
društveni elementi (engl. <i>social elements</i>)	moгуći odnosi koje igrači mogu imati u igri (igranje u paru ili skupini, razmjena virtualnih dobara)
vremensko ograničenje (engl. <i>timelimit</i>)	ograničenje koje je postavljeno igraču za izvršavanje određenoga zadatka

igrifikacijski element	definicija	slikovni prikaz
sustav nagrađivanja (engl. <i>rewards system</i>)	unaprijed zadani sustav po kojemu korisnik dobiva nagrade kad ostvari određeni broj bodova, prođe određene razine ili postigne određeni uspjeh u igri; primjenjuje se kako bi dodatno motivirao igrače

2.3.3. Razgraničenje igrifikacije od ostalih srodnih pojmova

E-učenje podrazumijeva bilo koji oblik učenja koji je podržan uporabom informacijsko-komunikacijske tehnologije. Cilj je metoda i tehnologija e-učenja da unaprijede kvalitetu nastave, ostvare bolju komunikaciju s polaznicima ili studentima, omoguće veću dostupnost obrazovnih materijala i slično (SRCE, 2016). Prednosti i nedostaci različitih kriterija e-učenja u odnosu na klasično učenje prikazani su u tablici 3.

Tablica 3. Prednosti i nedostaci e-učenja (prema Mihaljević, 2016b: 25 i Čubrić, 2021: 13)

kriterij	prednosti	nedostaci
dostupnost izvora	Izvori su lako i brzo dostupni. Predavanja se mogu snimiti i ponovno gledati.	Zbog preobilja podataka zahtijeva se dobra informatička i informacijska pismenost nastavnika i učenika kako bi se pronašlo i primjenjivalo najpouzdanije izvore na internetu.
mjesto	Obrazovni se proces može održavati bilo gdje. Nije potrebno putovati do mjesta održavanja nastave. Bolesni učenici i studenti od kuće mogu sudjelovati u radu.	Prostor u kojemu se pojedinci služe e-učenjem mora imati određene tehničke preduvjete (računalo, internetsku vezu, programsku podršku, kameru i mikrofona u nekim slučajevima). To dovodi do troškova za potrebnu tehnologiju.
priprema, izmjena i objava nastavnih materijala	Digitalni materijali lako se mogu objaviti, ažurirati i prilagoditi svakom učeniku.	Materijale treba zaštititi od neovlaštenoga preuzimanja, izmjena i distribucije.
vrijeme	Vrijeme učenja može se prilagoditi i uskladiti s mogućnostima svakoga učenika.	Potpuna sloboda planiranja vremena može dovesti do toga da učenici ne posvećuju dovoljno vremena učenju.

Igrifikacija može, ali i ne mora, biti vrsta e-učenja jer se katkad ne provodi s pomoću računalne tehnologije (npr. igre na papiru i na ploči tijekom nastave). „E-učenje blisko je i povezano s e-leksikografijom jer svaki rječnik, leksikon i enciklopedija ima i obrazovnu dimenziju te je namijenjen učenju i poučavanju. Stoga e-leksikografska djela imaju u sebi i elemente e-učenja.” (Hudeček i Mihaljević, 2019a: 86). Pojam igrifikacije često se izjednačuje s pojmom učenja utemeljenoga na igri (engl. *Game-based learning*) koji zapravo podrazumijeva primjenu tehnologije i igara u svrhu stjecanja znanja i vještina, a u tome slučaju najčešće je riječ o obrazovnim videoigramama (Plantak Vukovac, Škara i Hajdin, 2018: 183). Za razliku od igrifikacije, koja za provođenje ne mora nužno uključivati videoigru ili čak tehnologiju, učenje utemeljeno na igri primjenjuje videoigre kao medij za učenje. Te su videoigre napravljene da budu obrazovnoga karaktera, npr. igre *My Coach* za Nintendo DS konzolu koje se upotrebljavaju za učenje stranih jezika rješavanjem različitih zagonetka (YIP, 2007). Igre mogu biti dobar medij za poticanje motivacije učenika ili korisnika kako bi se povećalo zanimanje za određenu temu.

Učenje na temelju igara te igrifikacijski elementi koji su ubačeni u obrazovne sustave spadaju u područje e-učenja jer uključuju informatičku tehnologiju kao glavni alat za rad. Kod e-učenja uglavnom se spominju sustavi za učenje na daljinu⁶ i sustavi za upravljanje učenjem (engl. *Learning management system*)⁷. Mnogi od tih sustava koji se upotrebljavaju za obrazovne svrhe, poput Moodla, imaju ugrađene mogućnosti izrade križaljka i kvizova te sadržavaju igrifikacijske elemente poput bodovanja korisnika i davanje značaka za završene tečajeve.

Igrifikaciju treba razgraničiti i od teorije igara (engl. *game theory*), čiji je utemeljitelj John von Neumann te je usmjerena na situacije u igri u kojima strategije igrača utječu na strategije drugih igrača u igri (Hughes, 2011).

2.4. E-leksikografija

Leksikografija (prema grč. *λεξικός*: koji se odnosi na riječi, odn. *λεξικόν [βιβλίον]*: rječnik + -grafija) sustavno je popisivanje, opis i tumačenje rječničkoga blaga (riječi, izraza, imena) jednoga ili više jezika (Hrvatska enciklopedija, 2014). Tradicionalno je leksikografija smatrana jezikoslovnom disciplinom, ali se razvojem e-leksikografije leksikografija sve više ubraja i u

⁶ Učenje na daljinu oblik je učenja koji ne zahtijeva od nastavnika i učenika da se nađu u određenome fizičkom prostoru kako bi održali nastavu jer se poučavanje odvija s pomoću tehnologije koja može uključiti radio, telefon, e-poštu te internet i druge informatičko-komunikacijske tehnologije (Merriam-Webster, 2020).

⁷ Sustav za upravljanje učenjem (engl. *LMS – Learning management system*) sustav je koji omogućuje administraciju, dokumentaciju, praćenje, obavještanje te izradu i dijeljenje obrazovnih sadržaja, programa i lekcija za vježbanje i učenje (Ellis, 2009: 1).

informatičke znanosti. U vrijeme razvoja interneta problem nije nedostatak pristupa traženim podacima, nego činjenica da se traženi podaci ne mogu pronaći ili se pronalaze u količinama koje dovode do toga da korisnici odustaju od pretrage prije nego što pronađu traženi podatak. Stoga danas leksikografiju možemo definirati kao interdisciplinarnu znanost koja se bavi proučavanjem, oblikovanjem i razvojem alata kojima je svrha zadovoljavanje informacijskih potreba korisnika (Fuertes-Olivera i Bergenholtz, 2011: 307).

Razvoj tehnologije doveo je do toga da se informacije objavljuju i razmjenjuju digitalno. Mladi posebno lako prihvaćaju nove tehnologije, pa su njima glavni izvori informacija često digitalni (Kraus i dr., 2017: 168). Elektronička leksikografija ili e-leksikografija počela se razvijati sredinom prošloga stoljeća. Tada se najčešće nazivala *računalnom leksikografijom* (engl. *computer/computational lexicography*). Rječnici su se nazivali *strojno čitljivim rječnicima*, a ne kao danas *elektroničkim rječnicima* ili *e-rječnicima*. U počecima elektroničke leksikografije leksikografi su i dalje svoje obrade pisali na papiru, a nakon toga su računalni stručnjaci obradili podatke i prebacili ih u računalni oblik. *Random House Dictionary of the English Language*, koji je objavljen 1966. godine, smatra se prvim rječnikom koji se služio računalnom tehnologijom za sortiranje, kodiranje, preraspodjelu i dohvaćanje podatka (Granger i Paquot, 2012: 1). Prvi je rječnik u kojemu se ogleda ključan iskorak od strojno čitljivoga rječnika prema leksičkoj bazi podataka *Longman Dictionary of Contemporary English* (1978.). Na početku osamdesetih godina prošloga stoljeća revolucionaran je bio projekt *COBUILD* Johna Sinclaira. U sklopu toga projekta izrađen je i analiziran elektronički korpus suvremenih tekstova na kojemu se temelji rječnik objavljen 1987. (*Collins COBUILD English Language Dictionary*) (Štrkalj Despot i Möhrs, 2015: 330–331). „Neka od prvih dostupnih elektroničkih leksikografskih izdanja na optičkim medijima CD-ROM-u ili DVD-ROM-u objavljena su s tiskanom knjigom. Do pojave pete inačice HTML-a 2008. internetska tehnologija nije bila dovoljno razvijena za prikaz multimedijских sadržaja, npr. naprednih animacija te različitih interaktivnih programa poput igara (Gasston, 2013: 21). Zbog toga su krajem 90-ih godina 20. st. i početkom 21. stoljeća elektronički rječnici i enciklopedije, kako bi mogli imati napredne multimedijски sadržaje, bili izrađeni kao programi, najčešće za operacijske sustave Windows ili kao prijenosne *flash*-datoteke, koje se pokreću s optičkoga medija.” (Mihaljević, 2019: 190–191).

„HTML5 svojim razvojem omogućio je da mrežni preglednici poput Chroma i Firefoxa mogu bez poteškoća i potrebe za instalacijom dodatka pokrenuti različite interaktivne sadržaje, što je dovelo do toga da se elektronička leksikografska izdanja sve više prebacuju na mrežu.” (Ibid.: 190–191). Razvoj različitih sustava za izradu i održavanje mrežnih stranica (engl. *CMS* –

Content management system) te programa za sastavljanje rječnika poput TLexa (TshwaneLex)⁸ također je pridonio tomu da se leksikografska izdanja sve više izrađuju za mrežu i izdaju na mreži (Štrkalj Despot i Möhrs, 2015: 336). Ti programi omogućuju da više korisnika istodobno obrađuje natuknice unutar grafičkoga sučelja te ih pohrani u određenu bazu podataka. Ti programi u svojim sučeljima omogućuju uređivanje grafičkoga dizajna stranice. „Velika je prednost interneta kao medija za prikaz rječnika ili enciklopedije ta da korisnik ne ovisi o prijenosnome mediju poput CD-a ili USB-a za pregled sadržaja, nego je dovoljno da ima računalni uređaj s pristupom internetu. Internet leksikografu također omogućuje da jednostavno ažurira podatke na mrežnim stranicama leksikografskoga djela, što prije nije bilo moguće kod fizičkih medija koji su već bili izdani te prostor za digitalnu pohranu na mreži nije ograničen kao fizički medij.” (Mihaljević, 2019: 191).

Treba razlikovati leksikografska djela koja su izvorno nastala kao tiskana izdanja te su naknadno digitalizirana od onih koja su izvorno stvorena za mrežu. Tiskani leksikografski oblici koji su prebačeni u digitalni oblik ne moraju uvijek biti istovjetni sadržaju tiskane inačice jer se mogu nadopunjavati, ažurirati te se u njima mogu ispravljati pogreške. Primjer je takva leksikografskoga djela *Školski rječnik hrvatskoga jezika*, koji je tiskan 2012., a 2019. objavljen na mreži⁹ te je sadržaj usklađen s *Hrvatskim pravopisom* Instituta za hrvatski jezik i jezikoslovlje objavljenim 2013. godine. „Leksikografska djela koji se ne nadopunjuju nakon svoje objave na mreži smatraju se statičnima, a leksikografska djela koja se redovito nadopunjuju novim natuknicama, definicijama, primjerima te ostalim sadržajima smatraju se dinamičnima.” (Štrkalj Despot i Möhrs, 2015: 333).

„Leksikografska djela koji su rađena za mrežu nemaju ograničenja kao tiskana jer omogućuju iscrpniju obradu. Leksikografska djela na mreži omogućuju brže pronalaženje natuknica, prilagođenu veličinu slova, popratne multimedijske zapise, npr. slike, audiozapise, videozapise i igre. Za slijepe i slabovidne osobe može se ugraditi program za sintezu govora¹⁰ ili sintetizator govora, koji može pročitati tekst te asistent za govor koji može pronalaziti riječi na temelju glasovnih naredaba. Zbog nagloga razvoja i brojnih prednosti elektroničke leksikografije došlo je do njezina potpuna izjednačavanja s pojmom leksikografije te do predviđanja o skorome potpunom nestanku papirnatih rječničkih izdanja (Granger 2012: 2).” (Mihaljević, 2019: 192).

⁸ URL: <https://tshwanedje.com/tshwanelex/> (28. 11. 2019.)

⁹ URL: <http://rjecnik.hr/> (28. 11. 2019.)

¹⁰ Sinteza govora tehnologija je koja omogućuje govornu komunikaciju čovjeka i računala. Jedna od primjena sinteze govora programi su koji omogućuju pretvaranje računalnoga teksta u govor (engl. *text-to-speech*), koji se zovu sintetizatori govora (Pobar i dr., 2008: 31).

2.4.1. Podjela e-leksikografskih djela

„S obzirom na to je li u prvome redu usmjerena na riječi ili na pojmove razlikuje se enciklopedijska i jezična leksikografija. Proizvod je jezične leksikografije rječnik dok je proizvod enciklopedijske leksikografije enciklopedija ili leksikon” (Hudeček i dr., 2001: 90).

„S obzirom na širinu obrađenoga područja rječnike i enciklopedije možemo podijeliti na opće, koji obrađuju sva područja i posebne koji obrađuju određeno područje” (Mihaljević i dr., 2015: 9).

Najčešće se mrežna leksikografska djela razvrstavaju po sličnim ili istim kriterijima kao i tiskana od kojih se najčešće spominju podjele na opće ili specijalne te jednojezične, dvojezične ili višejezične enciklopedije i rječnici. Postoje i podjele koje se isključivo odnose na mrežna izdanja. Jedna od osnovnih podjela mrežnih rječnika odnosi se na to je li leksikografsko djelo nastalo kao rad zajednice poput *Wikipedije* ili je nastalo unutar određene obrazovne ustanove ili instituta. Također je moguće da se više leksikografskih djela spoji u jedan leksikografski portal kao na njemačkome portalu *ellexico*¹¹ na kojemu je moguće usporedno pretraživati više rječnika i jezičnih baza koji su nastali unutar Instituta za njemački jezik. Bago i Majetić (2017: 194–201) analizirale su razvojne kriterije za različite tipove tiskanih i mrežnih rječnika te su izradile model evaluacije mrežnih rječnika (na primjeru rječnika znakovnoga jezika) na temelju unaprijed ponuđenih kriterija proučavanja: analizira se komu je rječnik namijenjen, je li opći ili specijalni, je li normativni ili deskriptivni, je li jednojezični, dvojezični ili višejezični, kakve opcije nudi grafičko sučelje, na koje se načine može pretraživati rječnik, na koji su način prikazani rezultati, koji su dodatni sadržaji i može li korisnik unositi ili predložiti svoje riječi ili definicije.

Suvremeni mrežni rječnici s obzirom na odnos prema korpusu dijele se na rječnike vođene korpusom (engl. *corpus driven*) i rječnike utemeljene na korpusu (engl. *corpus based*). Katkad se spominju i korpusom oprimjereni rječnici (engl. *corpus illustrated dictionary*). Rječnici koji su vođeni korpusom sve natuknice, značenja, primjere uporabe i kolokacije bez izmjena uzimaju iz korpusa te se ne smije dodati primjer koji nije iz korpusa ili značenje koje nije korpusno ovjereno, a rječnici koji su utemeljeni na korpusu uzimaju određene primjere iz korpusa, ali ih po potrebi izmjenjuju i nadopunjuju (Štrkalj Despot i Möhrs, 2015: 342).

¹¹ URL: <https://www.owid.de/docs/ellex/start.jsp> (29. 11. 2019.)

2.4.2. Istraživanja utjecaja e-leksikografije na usvajanje jezičnih sadržaja

Provedena su različita empirijska istraživanja o tome pomaže li korištenje mrežnim rječnicima osobama koje uče strani jezik. Stockwell (2007) je u svojim radovima objavljenim od 2001. do 2005. u časopisima *CALICO Journal*, *CALL*, *Language Learning and Technology* i *ReCALL* utvrdio da se mrežni rječnici uglavnom proučavaju u kontekstu učenja riječi i pisanja. Hill i Laufer (2000: 73) otkrivaju da mrežni rječnici imaju pozitivan učinak pri učenju riječi jer sadržavaju dodatne informacije koje katkad ne mogu stati u tiskani rječnik, poput različitih konteksta riječi i prijevoda riječi, te sadržavaju poveznice na druge riječi poput sinonima, antonima, hiperonima, hiponima itd. Također mogu sadržavati medije poput slika te audiozapisa.

Jecić, Jermen i Kraus (2017: 177–179) na temelju provedenih istraživanja te proučavanja enciklopedija za djecu i odrasle *Britannica Kids*, *Q-files* i *KidzSearch Encyclopedia* pronalaze glavne elemente koji se trebaju uzeti u obzir pri razvoju dobre obrazovne leksikografske stranice: sadržaj, program za pretraživanje sadržaja, naslovna ili početna stranica, mrežne poveznice, načini na koje se pregledava sadržaj stranice, multimedijски elementi, mogućnosti izravnoga dijeljenja sadržaja s pomoću društvenih mreža i mogućnost za mrežnu suradnju više suradnika na izradi sadržaja stranice. Jantassova i suradnici (2009) proveli su istraživanje o tome kako računalne enciklopedije i rječnici kao didaktički alat pomažu učenju i poučavanju engleskoga kao drugoga jezika. Istraživanje je provedeno na nastavnicima i učenicima srednjih škola u gradu Karaganda u Kazahstanu. Prije istraživanja s učenicima i nastavnicima engleskoga jezika srednje škole dan je upitnik o stavu i uporabi e-leksikografskih djela u okviru nastave. 57 % nastavnika spomenulo je da se koriste e-rječnicima na mreži pri pripremi nastave, provjeri određenih činjenica te izradi izvannastavnih materijala umjesto tiskanim knjigama, ostali se koriste knjigama jer prednost daju tradicionalnijim načinima rada te određeni nastavnici navode da učenici ili oni sami nemaju pristup e-rječnicima i e-enciklopedijama zbog nedostatka informatičke tehnologije (Ibid.: 58). Uzorak je sadržavao 40 učenika iz dviju škola. Učenici su bili podijeljeni u kontrolnu i eksperimentalnu skupinu. U idućih mjesec dana učenici eksperimentalne skupine obučeni su da se služe e-rječnikom i sustavima za prevođenje te su im se za zadaću davali zadatci koji zahtijevaju da analiziraju i prevode tekstove s *Wikipedije* koji se odnose na zemlje Ujedinjenoga Kraljevstva (Ibid.: 59). Učenici kontrolne skupine koristili su se tiskanim rječnicima tijekom nastave. Na kraju svakoga tjedna obje su skupine rješavale test kako bi se pratio njihov napredak. Unutar četiriju tjedana više učenika iz eksperimentalne skupine ostvarilo je bolje rezultate od učenika iz kontrolne skupine (vidi tablice 4 i 5).

Tablica 4. *Tjedni rezultati eksperimentalne skupine (Jantassova i suradnici, 2009: 59)*

tjedan	broj ispitanika	broj ispitanika koji su ostvarili izvrsne ili vrlo dobre ocjene	postotak studenata koji su ostvarili izvrsne ili vrlo dobre ocjene
1	20	11	55 %
2	20	15	75 %
3	20	14	70 %
4	20	17	85 %

Tablica 5. *Tjedni rezultati kontrolne skupine (Ibid.: 60)*

tjedan	broj ispitanika	broj ispitanika koji su ostvarili izvrsne ili vrlo dobre ocjene	postotak studenata koji su ostvarili izvrsne ili vrlo dobre ocjene
1	20	7	35 %
2	20	9	45 %
3	20	11	55 %
4	20	9	45 %

Autori rada navode da je jedan od razloga za bolji napredak eksperimentalne skupine taj da elektronička leksikografska djela i računalna tehnologija dopuštaju brži pristup i povezivanje informacija te su zato učenici mogli brže obavljati zadane zadatke (Ibid.: 60). Jantassova i suradnici (2009: 58) uz rezultate svojega istraživanja navode da integracija elektroničkih leksikografskih publikacija u nastavne procese rješava mnoge didaktičke probleme jer leksikografske publikacije poput *Wikipedije* mogu razviti vještine čitanja s obzirom na to da sadržavaju određene prilagođene i zanimljive tekstne sadržaje koje mogu razumjeti korisnici s različitim jezičnim znanjima. Također, e-leksikografske publikacije mogu utjecati na razvoj vještine slušanja jezika s razumijevanjem zbog točno snimljenoga audioizgovora koji često sadržavaju, poboljšati vještine pisanja tako što korisnici na mrežnoj stranici *wikija*¹² odgovaraju na tuđa pitanja ili pišu vlastite članke, obogatiti vokabular korisnika te im pomoći da se upoznaju s kulturom jezika koja uključuje govorni bonton, značajke govornoga ponašanja različitih ljudi i tradiciju zemlje. Ostala istraživanja o e-leksikografiji u obrazovanju opisali su Meishar-Ta (2015), Deng i Trainin (2015), Mihaljević (2018) i Kocijan i suradnici (2019).

Dosad nisu provedena iscrpnija istraživanja o tome kako se može igrificirati rječnička ili leksikografska građa. Posebno ne postoji nijedan rad koji bi se bavio mogućnostima igrifikacije rječnika hrvatskoga jezika te bi ovaj rad pružio inovativan konceptualni okvir igrifikacije

¹² *Wiki* je tip mrežne stranice koji omogućuje posjetiteljima mrežne stranice da predlože, stvore, komentiraju, dopune ili isprave sadržaj stranice (Merriam-Webster, 2017).

rječničke građe na primjeru *Mrežnika*, koji se trenutačno izrađuje u sklopu projekta *Hrvatski mrežni rječnik – Mrežnik*.

3. PRIMJENA IGRIFIKACIJE I ISTRAŽIVANJA O IGRIFIKACIJI

Budući da se većina situacija može pretvoriti u igru, igrifikacija se može primijeniti u različitim područjima ljudskoga života, poput prodaje (Boer, 2013), ekonomije (Hamari i dr., 2015), menadžmenta (Sitzmann, 2011), obrazovanja (Kiryakova i dr., 2014), medicine (McCoy i dr. 2015: 22) i sporta (Shipherd i Burt, 2018). Najčešće je primjena igrifikacije povezana s uporabom tehnologije. Međutim, katkad uporaba tehnologije nije nužna. Bettis (2013) navodi da igrifikacija ne mora imati elemente svojstvene računalnim igrama kao što su priča, igranje uloga, bodovanje i značke jer je u literaturi utvrđeno da su i mnogi drugi elementi prilagođeni okruženju koje nije igra te se njima može uspješno koristiti u poslovne i obrazovne svrhe. Na primjer, u obrazovanju nije nužna uporaba tehnologije kako bi se igrificirali nastavni sadržaji jer nastavnici mogu napraviti igre za učenike ili studente na satu, podijeliti ih u skupine, dati im zadatke za natjecanje, bodovati ih na ploči te poredati učenike po uspjehu u tablicu na ploči, dodijeliti im fizičke značke ili druge oblike nagrada za uspješan rad na satu. Takav način primjene igrifikacije dosta je zahtjevan jer traži opsežnu pripremu te se teško može primijeniti u ostalim područjima jer zahtijeva osobu koja će bodovati svakoga igrača za radnje koje izvodi te igračima dodijeliti nagrade za uspjeh (Zainuddin i dr., 2019). Kod računalnih sustava više se igrača automatski i usporedno može bodovati, rangirati i nagrađivati. Budući da ima mnogo primjera igrifikacije u mnogim područjima, ovaj rad usmjerit će se na nekoliko poznatih programa, aplikacija te mrežnih stranica ili sustava koji primjenjuju igrifikaciju. U ovome će se radu iscrpnije prikazati igrifikacija u tjelovježbi i sportu te igrifikacija u obrazovanju iako primjera igrifikacije ima i u ostalim područjima.

3.1. Primjena igrifikacije u tjelovježbi i sportu

Jedan je od čestih primjera primjene igrifikacije aplikacija za *fitness* koja prati korisnikov redoviti trening te mu postavlja vježbe kao dnevne ciljeve. Za izvršavanje tih ciljeva korisnik dobiva bodove te se prikazuje njegov napredak s pomoću značaka, tablica te prikaza razine do koje je došao u aplikaciji. Napredak na virtualnoj razini koja se mjeri količinom obavljenoga treninga prenosi se na korisnika u fizičkome svijetu jer se bavi tjelovježbom. Primjeri su takvih aplikacija Fitbit, Fitrockr i CARROT Fit (vidi sliku 3) (Osypenko, 2019).

Slika 3. *Primjer primjene igrifikacije s bodovanjem, značkama te praćenje razvoja različitih vještina u aplikaciji CARROT Fit (Osypenko, 2019)*

Tvrtka Nike, koja se bavi sportskom opremom, objavila je 2006. poznatu sportsku aplikaciju Nike+. Nike+ je mrežna aplikacija koja može biti instalirana na mobitelima, satovima, iPodu i drugim manjim računalnim uređajima. Svrha je aplikacije motivirati korisnike da se više kreću. Aplikacija, neovisno o tipu uređaja te trenutnoj programskoj inačici, bilježi rezultate trčanja ili šetanja korisnika te ga s pomoću različitih zadataka motivira da se redovitije kreće. Aplikacija za svaki zadatak bilježi broj koraka, brzinu kretanja, otkucaje srca i potrošnju kalorija te sprema rezultate na korisnikov profil kako bi on mogao pratiti svoj napredak. Korisnik za uspješno ostvarene zadatke, kao i u prethodno spomenutim aplikacijama, dobiva značke kao povratnu informaciju i potvrdu o uspjehu. U novijoj inačici aplikacije Nike+ Run Club¹³ istaknutija je društvena sastavnica te se korisnici mogu međusobno natjecati ili zadavati zadatke ostalim korisnicima. Također mogu dijeliti svoje rute kretanja (kretanje na karti prati se s pomoću GPS-a) i slike. Korisnici mogu postavljati ciljeve, npr. da sruše svoje ili prijateljeve

¹³ URL: <https://apps.apple.com/app/nike-run-club/id387771637> (27. 11. 2019.)

rekorde u kretanju. Nakon uspjeha Nikeove aplikacije konkurentski proizvođači Adidas¹⁴ i Puma¹⁵ izdali su svoju igrificiranu aplikaciju za kretanje (Dubey, 2018). Još su dvije popularne aplikacije Zombies, Run!¹⁶ i Pokémon GO¹⁷. Zombies, Run!, kao i Nike+, aplikacija je koja zadaje korisniku zadatke za koje nakon izvršavanja dobiva određenu virtualnu nagradu. Ta je aplikacija drukčija od sličnih aplikacija po tome što ima priču u kojoj je došlo do apokalipse zbog zombija¹⁸, a igrač je jedan od preživjelih ljudi koji moraju bježati od zombija te skupljati sredstva za preživljavanje na određenim mjestima označenim na karti do kojih trče. Igrač sluša priču s pomoću slušalica koje spoji na zvučnik mobilnoga uređaja. O učinkovitosti te aplikacije napravljeno je istraživanje na Novome Zelandu. U istraživanju je sudjelovao 51 ispitanik tinejdžerske dobi. Istraživalo se pomažu li aplikacije za trčanje u postizanju boljih rezultata u *fitnessu* te podižu li motivaciju za daljnji rad (Direito i dr., 2015: 1). U istraživanju nije došlo do statistički značajne razlike među ispitanicima koji su se koristili aplikacijom Zombies, Run! od ispitanika koji se njom nisu koristili, ali ispitanici koji su se koristili tom aplikacijom i dalje su se nastavili njome koristiti nakon istraživanja (Ibid.: 8). Više o istraživanju nalazi se u potpoglavlju *Pregled dosadašnjih istraživanja*.

Igra za mobilne uređaje Pokémon GO unatoč tomu što se nije u prvome redu reklamirala kao aplikacija za tjelovježbu zahtijeva od igrača da se mnogo kreće te istražuje područja na karti kako bi ulovio Pokémone. Aplikacija je izdana 2016. godine i postigla je velik uspjeh. Do kraja te godine skinulo ju je oko 500 milijuna korisnika te je igra zaradila 500 milijuna dolara (Perez, 2016). Unatoč velikomu broju korisnika i zaradi, mišljenja korisnika i kritičara o igri uglavnom su bila umjereno pozitivna ili mješovita (Metacritic, 2016). Igra je dobila dosta negativnih komentara zbog tehničkih pogrešaka (*bugova*) i drugih tehničkih problema. Ipak, mnogi su kritičari pohvalili aplikaciju jer ih je potaknula da više izlaze te da se druže s drugim ljudima koji igraju istu igru. Na stranici IGN-a Schwartz (2016) je spomenula da je to najbolja prikrivena aplikacija za vježbanje jer je poboljšala svoje dnevne navike hodanja. Istraživanje Microsoft Research (Althoff i dr., 2016) spominje da većina igrača te aplikacije dnevno napravi 25 % koraka više nego inače (više o istraživanju u potpoglavlju *Istraživanja o sustavima i aplikacijama za učenje i vježbanje*). Razlog je velikoga uspjeha aplikacije Pokémon GO u

¹⁴ URL: <https://www.adidas.co.in/micoach> (27. 11. 2019.)

¹⁵ URL: https://play.google.com/store/apps/details?id=com.pumapumatrac&hl=en_US (27. 11. 2019.)

¹⁶ URL: <https://zombiesrungame.com/> (27. 11. 2019.)

¹⁷ URL: <https://www.pokemongo.com/en-us/> (27. 11. 2019.)

¹⁸ Zombi je u *vudu*-kulturi reanimirano tijelo mrtve osobe koje može davati neke naznake života kroz uspomene kretanje. Zombiji ne mogu govoriti niti imaju vlastitu volju. U filmovima, stripovima i igrama dodatno su prikazani kao ljudožderi koji ugrizom mogu smrtno zaraziti ljude te ih pretvoriti u zombije (Dictionary.com, 2009).

motivaciji korisnika koji ne vježbaju da se više kreću možda i činjenica da Pokémoni imaju mnogo obožavatelja. Riječ je o serijalu koji sadržava mnogo videoigara, odnosi se na animiranu seriju koja se izrađuje i prikazuje od 1997. do danas, igru s kartama te film (Wikipedia, 2019). Zbog toga su mnogi korisnici instalirali aplikaciju te je počeli igrati. Slično toj igri napravljena je i igra Harry Potter: Wizards Unite, u kojoj igrači istražuju svijet te se bore protiv čudovišta iz knjiga o Harryju Potteru. Igra je u prvih 24 sata od objave preuzeta 400 000 puta (Perez, 2019). Igre Harry Potter: Wizards Unite i Pokémon GO pokazuju da poznata marka može biti važna za privlačenje korisnika.

3.2. Primjena igrifikacije u obrazovnim sustavima

Igrifikacija se često primjenjuje u obrazovnim sustavima u kojima se sve više uvrštavaju elementi iz igara igranja uloga (RPG igara¹⁹) poput stupaca i brojka koje prikazuju određene vještine korisnika te je uvršten brojčani sustav napredovanja igrača s pomoću avatara. Za svakoga igrača piše njegova razina i status (npr. početnik, ekspert). Također je kao i u mrežnim RPG igrama moguće skupno igranje u obliku natjecanja ili međusobnoga rješavanja zadataka. Stranica Codecademy²⁰ za učenje računalnih jezika i stranica Duolingo²¹ za učenje stranih jezika za svaki jezik koji se uči imaju razine slične onima u videoigramima, u kojima je svaka iduća razina teža. Obje stranice također imaju mobilne aplikacije na kojima se mogu prolaziti isti tečajevi te se napredak korisnika može usporedno bilježiti na aplikacijama i mrežnim stranicama jer se lekcije povezuju s korisničkim profilom. Što se korisnik više služi sadržajima stranice te novostečenim znanjem, ostvaruje bolje rezultate i napreduje kroz svoj virtualni profil u kojemu se bilježe bodovi za svaku igru te dodjeljuju virtualne značke za određena postignuća. Osim stranice Codecademy postoje i druge stranice za učenje programiranja CodeWars²², CodinGame²³ i Ruby-warrior²⁴, koje se koriste sličnim načelima za igrifikaciju nastavnih lekcija.

Stranice poput CodinGame i Ruby-warrior također imaju grafičko sučelje u kojemu je na dijelu zaslona grafičkim animacijama prikazana radnja igre koja se postupno odvija u koracima u trenutcima kad korisnik napiše dio koda te ga preda. Svaka lekcija ima svoju priču u kojoj su

¹⁹ Igre igranja uloga (engl. *RPG, Role Playing Games*) žanr su igre u kojemu igrač uglavnom oblikuje svoj lik ili njegovu avanturu u igri. Taj žanr igara karakteriziraju sustavi napredovanja, razgranate priče i različiti pristupi izazovima (Techopedia, 2011d).

²⁰ URL: <https://www.codecademy.com/learn> (17. 9. 2019.)

²¹ URL: <https://www.duolingo.com/learn> (23. 9. 2019.)

²² URL: <https://www.codewars.com/> (23. 9. 2019.)

²³ URL: <https://www.codingame.com/> (23. 9. 2019.)

²⁴ URL: <https://www.bloc.io/ruby-warrior#/> (23. 9. 2019.)

na pametan način ubačeni obrazovni sadržaji iz lekcije tako da su smisleno povezani s pričom. Na primjer, u lekcije za učenje programskih petlja ubačena je priča da se svemirski brod treba spustiti na planet, ali mu osam planina smeta te ima goriva za samo osam okretaja oko površine za slijetanje. Korisnik treba petljom zadati brodu da u svakome osmom pokretu pogodi određenu planinu. Na prvoj razini s obzirom na redoslijed brojeva od manjega do većega gađaju se planine te u idućim razinama treba drukčijim redoslijedom pogoditi planine unutar petlje²⁵. Na stranici Ruby-warrior korisnike se poučava logici programiranja u jeziku Ruby tako da s pomoću zadanih funkcija (npr. funkcije za kretanje lika, napad protivnika itd.) korisnik sigurno dovede lik do cilja te pritom ubije sva čudovišta i izbjegne zamke (vidi sliku 4). Takvi su sustavi za učenje s grafičkim prikazom igre dobri, pogotovo za mlađe korisnike, jer im vizualno prikazuju funkcionalnost programskih kodova (Costa Paiva, 2018: 57).

Slika 4. Sučelje za učenje logike programiranja na stranici Ruby-warrior

Od stranica za učenje računalnih jezika treba još spomenuti stranicu na hrvatskome jeziku *Informatičke igre i multimedijски i prikaz znanja*^{26,27}, koju je izradio autor ovoga rada. Stranica je napravljena 2016. s pomoću sustava WordPress. „Stranica je nastala kako bi se napravile mrežne stranice na kojima učenici mogu igrati različite igre iz kojih mogu na zabavan način naučiti činjenice vezane uz informacijsku i komunikacijsku tehnologiju. Igre su različite poput kvizova s različitim tipovima pitanja, križića i kružića, tetrisa te križaljke. Sve te igre, koje se igraju na poznat način, imaju ugrađena pitanja na koja igrač mora odgovoriti kako bi mogao

²⁵ URL: <https://www.codingame.com/ide/puzzle/the-descent> (24. 11. 2019.)

²⁶ URL: <https://informatickeigre.com/> (4. 1. 2020.)

²⁷ Autor je za tu stranicu dobio nagradu Ministarstva znanosti i obrazovanja za 100 najboljih digitalnih obrazovnih sadržaja. URL: <http://ihjj.hr/clanak/doktorand-josip-mihaljevic-dobio-nagradu-za-inovativni-digitalni-obrazovni-sadrzaj/731/> (5. 1. 2020.)

nastaviti s igrom.” (Mihaljević, 2018: 966). Primjerice tetris²⁸ se igra na uobičajeni način, tj. tako da se popunjavaju polja redaka s blokovima, ali čim igrač popuni redak, pojavi mu se pitanje s ponuđenim odgovorima na koje mora odgovoriti kako bi mogao nastaviti s igrom. Ako igrač odgovori točno, igra se nastavlja i igrač dobiva bodove, ali ako igrač odgovori pogrešno, gubi bodove te igra postaje teža jer blokovi počinju padati brže. Igra križić-kružić može se igrati samostalno protiv računala ili protiv drugoga igrača. Da bi igrač mogao staviti svoju oznaku u polje tablice, mora točno odgovoriti na pitanje. Igrač u slučaju pogrešnoga odgovora propušta svoj red (vidi sliku 5). „Sve igre sa stranice mogu se također igrati i na mobilnim uređajima, pa se učenici mogu koristiti njima i izvan nastave tijekom svakodnevnih aktivnosti poput vožnje autobusom ili tramvajem ili čekanja u redu²⁹. Autor se određenim igrama sa stranice koristio na početku sata u svrhu podizanja učeničkoga interesa za nastavni sadržaji, a neke igre koje ispituju znanje, poput kvizova, autor je uvodio na kraju sata za ponavljanje gradiva.” (Ibid.: 966). Pilot-istraživanje koje se odnosi na igre koje se nalaze na toj stranici prikazano je u potpoglavlju *Pregled dosadašnjih istraživanja o igrifikaciji*.

Slika 5. Igra križić-kružić, u kojoj je zadatak da igrač odabere točan odgovor na pitanje, što će mu omogućiti da na polje stavi svoju oznaku

²⁸ URL: <https://informatickeigre.com/1r/binarni-tetris-internet/> (4. 1. 2020.)

²⁹ Više o tehnologiji povezanoj s izradom igara i stranice *Informatičke igre i drugi multimedijски i prikaz znanja u radu Korištenje programima otvorenoga koda u nastavi informatike* (Mihaljević, 2018).

U hrvatskome se obrazovnom sustavu upotrebljava sustav Loomen³⁰, koji je zapravo prilagođeni i preimenovani sustav Moodle. Loomen omogućuje svima korisnicima s AAI@Edu.hr³¹ računom da stvore vlastite tečajeve ili sudjeluju u tuđim tečajevima. Taj se sustav najviše upotrebljava u školama. Nastavnici s pomoću sustava mogu stvoriti vlastite tečajeve te učenicima omogućiti pristup. U sustavu Loomen unutar programa *Škola za život*³² postoje također različiti tečajevi za nastavnike poput *Hrvatski jezik OŠ I*³³ u kojemu nastavnici mogu proći kroz nastavne materijale te za svaku lekciju mogu ispuniti određene zadatke kako bi dobili značku (vidi sliku 6). Ta značka nastavnicima služi kao potvrda da su stekli određene kompetencije. Ministarstvo znanosti i obrazovanja dodjeljuje potvrde o profesionalnome razvoju u sustavu te ima popis ostvarenih tema i ishoda učenja te brojeve sati izobrazbe za svakoga sudionika. Na potvrdi će biti navedene samo teme za koje su odrađene sve obvezne aktivnosti i dobivene značke (Ministarstvo znanosti i obrazovanja, 2019).

<p>Mrežni izvori Instituta za hrvatski jezik i jezikoslovlje - Hrvatski jezik, osnovna škola I</p>	<p>Značka Mrežni izvori Instituta za hrvatski jezik i jezikoslovlje - HJ-OŠ-I stečena je u virtualnoj učionici predmeta Hrvatski jezik - osnovna škola I i predstavlja dokaz o ostvarenim ishodima u temi Mrežni izvori Instituta za hrvatski jezik i jezikoslovlje. Ishodi su teme: Učitelj/nastavnik primjenjuje različite mrežne izvore Instituta za hrvatski jezik i jezikoslovlje u osmišljavanju aktivnosti za učenike. Razlikuje izvore s obzirom na vrstu informacije koju traži. Trajanje edukacije: 4 sata.</p>	<p>Korisnici dobivaju ovu značku kada završe BILO KOJI od navedenih zahtjeva.</p> <ul style="list-style-type: none"> • Ova aktivnost treba biti dovršena: <ul style="list-style-type: none"> ◦ "Forum - Mrežni izvori Instituta za hrvatski jezik i jezikoslovlje u učenju i poučavanju predmeta Hrvatski jezik" • Ova značka mora biti dodijeljena od strane korisnika koji ima ovu ulogu: <ul style="list-style-type: none"> ◦ Voditeljica kolegija
---	--	---	--

Slika 6. Primjer značke za tečaj Hrvatski jezik OŠ I za koji pišu aktivnosti koje se moraju izvršiti te obrazovni ishodi koje nastavnici stječu uspješnim završavanjem tih aktivnosti

³⁰ URL: <https://loomen.carnet.hr/> (27. 11. 2019.)

³¹ „AAI@EduHr sustav autentifikacijska je i autorizacijska infrastruktura sustava znanosti i visokoga obrazovanja u Republici Hrvatskoj. Svaka ustanova iz sustava Ministarstva znanosti, obrazovanja i sporta koja je uključena u sustav AAI@EduHr ima vlastitu bazu u kojoj su pohranjeni elektronički identiteti zaposlenika iz te ustanove.” (AAI@EduHr, 2016).

³² „Škola za život naziv je eksperimentalnoga programa čiji je nositelj Ministarstvo znanosti i obrazovanja. U *Školi za život* sudjeluje 48 osnovnih i 26 srednjih škola iz svih županija u Republici Hrvatskoj. Eksperimentalni program provodi se u 1. i 5. razredu osnovnih škola te u 7. razredu za predmete biologija, kemija i fizika. U srednjim se školama provodi u 1. razredu gimnazije u svim predmetima te u 1. razredu četverogodišnjih strukovnih škola u općeobrazovnim predmetima. Cilj je eksperimentalnoga programa provjera primjenjivosti novih kurikula i oblika metoda rada te novih nastavnih sredstava s obzirom na sljedeće ciljeve: povećanje kompetencija učenika u rješavanju problema, povećanje zadovoljstva učenika u školi te motivacija njihovih učitelja i nastavnika.” (Ministarstvo znanosti i obrazovanja, 2019).

³³ URL: <https://loomen.carnet.hr/course/view.php?id=10557> (27. 11. 2019.)

3.2.1. Primjena igrifikacije u učenju jezika

Igrifikacija se često upotrebljava u sustavima za učenje jezika. Kod učenja jezika kao polazište uzima se ova definicija igre: aktivnost koja omogućuje vježbanje jezika na opušten i zabavan način (Brewster i dr., 2002: 172). Od mrežnih sustava za učenje jezika Duolingo se smatra najuspješnijim sustavom sa zabilježenih 300 milijuna korisnika, 19 jezika te 62 mrežna tečaja (Smith, 2019). Dio uspjeha Duolinga temelji se na primjeni igrifikacije u svakome dijelu sučelja (vidi sliku 7). Korisnik odabere jezik koji želi učiti te mu se na početku prikazuju svi tečajevi i težinske razine odabranoga jezika. Na svakoj se razini grafički prikazuje korisnikov napredak. Korisnici na sustavu mogu raditi samostalno te učiniti svojim tempom, ali dobivaju dodatne bodove ako redovitije rade i ako ostvaruju dnevne zadatke koji zahtijevaju da prođu kroz određene lekcije. Time se dodatno potiče motivacija za učenje. Postoji također virtualna novčana valuta u sustavu koja se zove lingot, koju korisnici dobivaju za završavanje lekcija te je mogu upotrijebiti za kupovinu dodatnih tečajeva te pomagala za rješavanje zadataka. Duolingo također funkcionira kao društvena mreža jer korisnici mogu međusobno pratiti profile, natjecati se, komunicirati privatno ili na forumu te razmjenjivati lingote (Loayza, 2018).

Slika 7. Prikaz elemenata igrifikacije u sučelju sustava Duolingo (Loayza, 2018)

Zadaci u sustavu uglavnom su kvizovi u kojima se miješaju pitanja različitoga tipa. Najviše je pitanja s ponuđenim odgovorima, ako se vježba pravilno pisanje, onda se postavljaju pitanja na

koja se upisuju odgovori, kod pitanja povezanih sa slaganjem rečenica primjenjuje se mehanika dovlačenja (engl. *drag-n-drop*) odgovora na mjesto. Igrač čuje riječi ili rečenice za koje treba odabrati pravilan prijevod ili, u drugome tipu pitanja, napisati ih ili rasporediti redom kojim ih čuje. Također postoje zadatci u kojima se preslušavaju razgovori na odabranome jeziku koji se odnose na svakodnevne situacije, pa se nakon svakoga dijela razgovora korisnika pita o čemu je riječ te mora spojiti prevode s odabranoga jezika na engleski³⁴. Postoje i vježbe pri čijemu rješavanju korisnik može uključiti ili isključiti vremensko ograničenje, kod uključivanja vremenskoga ograničenja korisnik na početku vježbe ima 30 sekunda za rješavanje svih zadataka. Vrijeme rješavanja malo se poveća svaki put kad točno odgovori na pitanje, te mora riješiti vježbu prije nego što istekne vrijeme koje ovisi o brzini rješavanja³⁵.

Duolingo također ima statistiku riječi koje je korisnik najviše vježbao u sustavu. Te riječi biraju se na temelju pitanja na koja je igrač točno odgovorio. Munday (2016: 92) je u svojem istraživanju, koje je proveo na 62 studenata (46 studenata A1 razina znanja, 16 studenata B2 razina znanja), ispitao zadovoljstvo studenata s Duolingom. Na A1 razini 78,3 % studenata zadovoljno je sustavom, a na B2 razini samo je 50 % studenata zadovoljno sustavom, 6,3 % ih je neutralno, a ostali nisu zadovoljni (više o istraživanju u potpoglavlju *Pregled dosadašnjih istraživanja o igrifikaciji*). Postoje i drugi besplatni sustavi za učenje stranih jezika s igrifikacijskim elementima poput Memrise³⁶, Busuu³⁷, Lingualia³⁸ i Clozemaster³⁹. „Clozemaster čak ima tečajeve za učenje rječnika hrvatskoga jezika. U tečajevima se prikazuju jednostavne rečenice na hrvatskome koje sadržavaju prazno mjesto. Te praznine igrač popunjava odabirom jedne od četiriju ponuđenih riječi (vidi sliku 8). U drugoj inačici za iste zadatke igrač samostalno upisuje riječi na prazno mjesto. Za svaku je rečenicu dan prijevod na engleskome kako bi igrač razumio značenje. Rješavanje se zadataka boduje te postoji ljestvica poretka. Nažalost, u ovome se sustavu mogu učiti samo riječi. Nedostaju zadatci za učenje pravopisa i gramatike, ispravljanje tipičnih jezičnih pogrešaka, sastavljanja teksta te više tipova igara i interaktivnih sadržaja.” (Lazić i Mihaljević, 2020: 124).

³⁴ URL: <https://stories.duolingo.com/> (25. 11. 2019.)

³⁵ URL: <https://www.duolingo.com/practice> (3. 12. 2019.)

³⁶ URL: <https://www.memrise.com/home/> (29. 11. 2019.)

³⁷ URL: <https://www.busuu.com> (29. 11. 2019.)

³⁸ URL: <http://www.lingualia.com> (29. 11. 2019.)

³⁹ URL: <https://www.clozemaster.com/dashboard> (29. 11. 2019.)

Slika 8. Prikaz zadatka u sustavu Clozemaster⁴⁰

I na portalima *Hrvatski u školi*⁴¹ i *Jezične igre i multimedijски prikaz jezika*⁴² nalaze se stranice koje sadržavaju igre i igrifikacijske elemente. „Igre na portalu *Hrvatski u školi* uglavnom su namijenjene učenicima nižih razreda osnovne škole, što se može vidjeti na temelju dizajna stranice koji uključuju ilustracije primjerene djeci, ali ima i igara namijenjenih učenicima viših razreda osnovne škole i srednjoškolcima (leksikografija, anglizmi). S pomoću tih igara ispituje se pravopis (pisanje *č/ć*, *ije/je* te *dž/đ*, veliko i malo početno slovo, pravopisni znakovi itd.), znanje leksikografije (sinonimi, antonimi itd.), hrvatske zamjene za anglizme. Posebnu skupinu čine igre za učenje glagoljice⁴³.” (Ibid.: 123). Igre za učenje glagoljice uključuju pamtilicu u kojoj se sparuju latinična i glagoljična slova, kviz za uglatu i oblu glagoljicu te stranicu na kojoj se uči pisati uglatu glagoljicu s pomoću strelica. Kod pamtilice moguće je prilagoditi težinu igre tako da se kod slova uključe boje kako bi igrači na temelju iste boje znali koja latinična i glagoljična slova treba spariti te se može odabrati broj parova za spajanje (4, 8 i 12). Kviz se igra tako da se igraču prikaže glagoljično slovo te mu se ponude četiri latinična slova od kojih mora odabrati točno. Kviz sadržava vremensko ograničenje od deset sekunda za svako pitanje te se igraču za svaki odgovor, točan ili netočan, daje povratna informacija prije idućega pitanja. Ta povratna informacija u slučaju netočnoga odgovora ili isteka vremena pokazuje igraču točan odgovor tako da mu pokaže latinično slovo do glagoljičnoga slova, a u slučaju točnoga odgovora igraču se prikazuje koliko je bodova ostvario. Svaki točan odgovor nosi deset bodova, ali se dodatno boduje i brzina kojom je dan odgovor. Dodatno bodovanje ide od jedan do deset

⁴⁰ URL: <https://bit.ly/30ws8jj> (29. 11. 2019.)

⁴¹ URL: <http://hrvatski.hr/> (6. 1. 2020.)

⁴² URL: <https://jezicneigre.com/> (6. 1. 2020.)

⁴³ URL: <http://hrvatski.hr/volim-glagoljicu/> (18. 1. 2020.)

te se provodi tako da se odabere vremensko ograničenje od deset sekunda te se oduzme od vremena potrebnoga da korisnik odgovori na pitanje. Na primjer, ako igrač na pitanje odgovori u pet sekunda, dobiva pet dodatnih bodova (10 – 5), a ako odgovori u sedam sekunda, dobiva tri boda (10 – 7)⁴⁴.

Osim igara za učenje glagoljice na stranici *Hrvatski u školi* igre za učenje glagoljice nalaze se i na stranicama Staroslavenskoga instituta⁴⁵. I te je igre izradio isti autor. Neke od obrazovnih igara dosta su jedinstvene poput tetrisa, u kojemu se pojavljuju glagoljična slova s transliteracijom unutar blokova, zmija koja jede glagoljična slova, igra pucanja u kojoj se gađaju glagoljična slova, zagonetka u kojoj se mijenjaju polja s latiničnim slovima u polja s glagoljičnim slovima i igre nadahnute igrom *flappy birds*⁴⁶, u kojima se glagoljičnim slovima izbjegavaju prepreke. Postoji i pamtilica, ali za razliku od pamtilice na stranici Instituta za hrvatski jezik i jezikoslovlje u toj igri nema mogućnosti sparivanja slova bez boja za iskusišnje igrače te se u tablicu rezultata pohranjuju samo rezultati jednoga igrača lokalno, a ne svih igrača koji igraju s različitih mjesta⁴⁷.

Ostale igre za hrvatski jezik raznolike su te uključuju kvizove znanja⁴⁸, križaljku⁴⁹, daktilografsku igru⁵⁰, u kojoj treba što brže upisati padajuće riječi (vidi sliku 9), pamtilicu⁵¹ te igru *kalodont*^{52, 53}. „Igre kao igrifikacijske elemente sadrže bodovanje te neke igre imaju mogućnost odabira razine ili prilagodbe težine poput daktilografske igre, u kojoj se na temelju odabira razina može prilagoditi brzina i količina riječi koje padaju⁵⁴.” (Lazić i Mihaljević, 2020: 123).

⁴⁴ Više o igrama za učenje glagoljice na stranicama Instituta za hrvatski jezik i jezikoslovlje vidi u Mihaljević (2019).

⁴⁵ URL: https://www.stin.hr/hr/category/obrazovne_igre/29 (22. 1. 2020.)

⁴⁶ *Flappy birds* igra je za mobilne aplikacije iz 2014. u kojoj igrači kontrolirajući pticu izbjegavaju prepreke. Ptica se kontrolira pritiskom zaslona na dodir te igra postaje sve teža što više prepreka ptica prijeđe (Williams, 2014).

⁴⁷ Više o igrama za učenje glagoljice na stranicama Staroslavenskoga instituta vidi u Mihaljević (2016) i Mihaljević (2017).

⁴⁸ URL: <http://hrvatski.hr/igra/9/> (18. 1. 2020.)

⁴⁹ URL: <http://hrvatski.hr/igra/5/> (18. 1. 2020.)

⁵⁰ URL: <http://hrvatski.hr/igra/4/> (18. 1. 2020.)

⁵¹ URL: <http://hrvatski.hr/igra/3/> (18. 1. 2020.)

⁵² „*Kalodont* je igra u kojoj sudjeluje više igrača. Ona počinje tako da jedan igrač napiše prvu riječ, a sljedeći igrač sljedeću riječ započinje s posljednja dva slova prethodne riječi. Cilj je igre da jedan igrača napiše takvu riječ da ostali igrači ne mogu smisliti novu riječ koja počinje posljednjim dvama slovima te riječi. Također, ako igrač napiše riječ koja završava s *ka*, ispada iz igre. Igra je korisna za vježbanje leksika i temelji se na abecedariju *Školskoga rječnika hrvatskoga jezika* (2012.).” (Lazić i Mihaljević, 2020: 123).

⁵³ URL: <http://hrvatski.hr/igra/8/> (18. 1. 2020.)

⁵⁴ Više o tim igrama vidi u Mihaljević (2016) i Mihaljević (2017).

Slika 9. Daktilografska igra u kojoj igrači trebaju utipkati padajuće riječi koje sadržavaju č, ć, dž, đ, ije i je prije nego udare brod

„Stranica *Jezične igre i multimedijски prikaz jezika* sadržava različite tipove igara za učenje hrvatskoga, njemačkoga i latinskoga jezika. Igre na stranici sadržavaju oznake (engl. *tags*) s obzirom na tip i sadržaj. Najviše igara ima za učenje glagoljice (kviz, pamtilica, zagonetka, *Pac-Man*⁵⁵ i igra *Space Invaders*⁵⁶ u kojoj se gađaju glagoljična slova). Na stranici se nalaze i kvizovi koji korisnicima pomažu u pripremi za maturu iz hrvatskoga jezika, križić-kružić igra s oblicima riječi koja funkcionira na sličan način kao križić-kružić igra na stranici *Informatičke igre i multimedijски i prikaz znanja*, igra za učenje frazema na temelju dovlačenja slika u

⁵⁵ *Pac-Man* arkadna je igra nastala 1980. u kojoj igrači s likom *Pac-Man* moraju u labirintu pojesti sve žute kuglice te pritom izbjegavati duhove (Partridge, 2015). Na stranici *Jezične igre i multimedijски prikaz jezika* *Pac-Man* za učenje glagoljice funkcionira na isti način, ali igrači u određenim kuglicama imaju glagoljična slova za koja im piše transliteracija na latinici. URL: <https://jezicneigre.com/glagoljojed-2/> (7. 1. 2020.)

⁵⁶ *Space Invaders* arkadna je igra nastala 1978. u kojoj igrač sa svemirskim brodom gađa izvanzemaljce koji se spuštaju na zemlji te povremeno građaju igračev svemirski brod (Dusty, 2016: 11). U inačici igre za učenje glagoljice koja se zove *Glagoljostrelka* umjesto svemirskoga broda kontrolira se luk sa strijelom te gađaju glagoljična slova koja se, kad su pogodena, pretvore u latinična slova. URL: <https://jezicneigre.com/glagoljostrelka/> (7. 1. 2020.)

rečenice, pamtilica za riječi, kviz za slova brajice te znakovni jezik⁵⁷.” (Lazić i Mihaljević, 2020: 123).

Stranica također sadržava igre koje se nalaze na portalu *Hrvatski u školi*. Neke igre poput kviza koji služi kao priprema za maturu i pamtilice za učenje glagoljice sadržavaju ljestvice poretka za sve igrače koji su završili igru te odlučili predati rezultat pod korisničkim imenom. Za korisničko ime nije potrebna registracija na stranici, nego igrač napiše korisničko ime na kraju igre pri predaji rezultata. Noviji kvizovi, poput kviza koji korisnika priprema za maturu iz hrvatskoga jezika⁵⁸, sadržavaju vremensko ograničenje za pitanja te se korisnik dodatno boduje ako brže odgovori na pitanje. Primjeri igrifikacije koji su povezani uz leksikografska djela nalaze se u potpoglavljima *Analiza e-rječnika* i *Analiza e-enciklopedijama*. Također u potpoglavlju *Igrifikacija i crowdsourcing* spominju se jezične igre Zombilingo⁵⁹ i Wordrobe⁶⁰.

3.3. Značajke igrificiranih aplikacija i sustava

Spomenute aplikacije i sustavi sadržavaju većinu temeljnih elemenata igrifikacije poput bodovanja, zadataka, značka itd. Svaka spomenuta aplikacija ili sustav ima svoje tehničke specifikacije. U tablici 6 ističu se pozitivne značajke aplikacije ili sustava.

Tablica 6. Značajke aplikacija i sustava

aplikacije i sustavi	značajke
Nike+	<ul style="list-style-type: none"> • mogućnost primjene aplikacije na različitim uređajima (pametni telefoni, satovi, tableti i računala) • mogućnost korisnika da zadaju zadatke te postavljaju izazove za druge korisnike
Zombies, Run!	<ul style="list-style-type: none"> • zanimljiva priča koja se otključava kroz više razina i može dodatno motivirati igrača da se redovito koristi aplikacijom kako bi otključao više razine te nastavio s pričom
Pokémon GO	<ul style="list-style-type: none"> • poznata robna marka koji ima mnogo starih i novih obožavatelja; time je moguće privući mnogo korisnika kojima je poznata kvaliteta te marke • prikrivena motivacija za izvršavanje određenih zadataka ostvarena glavnom radnjom igre (zadaje se igraču primamljiv zadatak, hvatanje Pokémona, u kojemu igrač mora činiti aktivnosti koje vjerojatno inače ne radi, hodati i istraživati okolinu, jer ih ne smatra zabavnima, zanimljivima ili ih smatra napornima)

⁵⁷ Više o time igrama pisali su Mihaljević i Mihaljević (2019).

⁵⁸ URL: <https://jezicneigre.com/zadatci-za-drzavnu-maturu/> (7. 1. 2020.)

⁵⁹ URL: <https://zombilingo.org/> (24. 1. 2020.)

⁶⁰ URL: <http://www.wordrobe.org/> (24. 1. 2020.)

aplikacije i sustavi	značajke
CodinGame i Ruby-warrior	<ul style="list-style-type: none"> • grafičko sučelje u kojemu je kroz animacije prikazana radnja igre do programskoga koda koji se uči • mnogi zadatci imaju priču koja se rješava pisanjem programskoga koda
<i>Informatičke igre i multimedijски prikaz znanja i Jezične igre i multimedijски prikaz jezika</i>	<ul style="list-style-type: none"> • zasebne stranice s igrama na kojima su igre podijeljene na temelju kategorija te svaka igra na temelju tipa i sadržaja ima i svoju oznaku • mnogo jedinstvenih igara od kojih su mnoge rađene na temelju popularnih arkadnih igara (<i>Pac-Man, Tetris, Space Invaders</i>)
<i>Hrvatski u školi</i>	<ul style="list-style-type: none"> • vesele i šarene ilustracije za djecu koje su uvrštene u dizajn stranice i igre • mnogo različitih igara za učenike različite dobi
igre za učenje glagoljice na stranicama Staroslavenskoga instituta	<ul style="list-style-type: none"> • mnogo jedinstvenih igara od kojih su mnoge rađene na temelju popularnih zabavnih igara (<i>tetris, flappy birds, zmija</i> itd.)
Duolingo	<ul style="list-style-type: none"> • sustav je preuzeo mnoge elemente iz RPG igara poput stabla igračih vještina (engl. <i>skill tree</i>), virtualnih novčanih valuta (<i>lingot</i>) te razvijenih društvenih sastavnica • kvizovi u lekcijama kombiniraju različite tipove pitanja (višestruki odabir, nadopunjavanje, dovlačenje odgovora) te različite multimedijske elemente (slike, zvučni zapisi i animacije)
tečajevi unutar programa <i>Škola za život</i>	<ul style="list-style-type: none"> • značke koje se dobivaju u sustavu potvrđuju stjecanje kompetencije koje Ministarstvo znanosti i obrazovanja priznaje kao usavršavanje za nastavnike⁶¹

Treba posebno spomenuti igrifikacijske elemente koji se odnose na zadatke (engl. *quests*) jer oni zahtijevaju od korisnika da radi na sebi (učenjem ili fizičkim vježbanjem) kako bi nastavio s pričom u aplikaciji ili sustavu. Čim je korisnicima dan dodatni kontekst za izvršavanje određenih zadataka kao u igrama *Zombies*, *Run!*, *Pokémon GO*, *CodinGame* i *Ruby-warrior*. Iako se taj kontekst nalazi u izmišljenoj priči ili situaciji koja uključuje te zadatke, korisnik će možda biti motiviraniji da izvrši te radnje. Također, kod aplikacije *Pokémon GO* treba uzeti u obzir da će prepoznatljive marke privući više korisnika. Prije su se primjenjivale poznate marke pri izradi obrazovnih programa i igara poput obrazovnih igara *Super Mario* (*Mario's Early*

⁶¹ URL: <https://skolazivot.hr/razredna-nastava-virtualna-ucionica-2018-19/> (26. 11. 2019.)

Years!, *Mario Is Missing!* i *Mario's Early Years!*)⁶² i igara na stranici Sesame Street⁶³ za djecu u vrtiću i nižim razredima osnovne škole. Sustavi kao što su Duolingo imaju razvijen prikaz napretka korisnika koji je hijerarhijski prikazan stablom (engl. *skill tree*). Kvizovi u sustavu također kombiniraju različite tipove pitanja i multimedijских elemenata, što ih čini dinamičnima. Duolingo uz Nike+ također ima vrlo razvijene društvene sastavnice te se korisnici mogu međusobno natjecati ili rješavati zadatke. Kod Nike+ moguće je još zadavati izazove drugim korisnicima. CodinGame i Ruby-warrior sadržavaju grafičko sučelje koje kombinira zadatke pisanja koda s animacijama koje prikazuju radnju igre. Slično bi se moglo napraviti i za jezične igre. Tečajevi koji su izrađeni unutar programa Ministarstva znanosti i obrazovanja *Škola za život*, unatoč tomu što su napravljeni kao standardne stranice unutar sustava Moodle, ipak sadržavaju igrifikacijski element značke. Značke koje nastavnici dobivaju završetkom tečaja potvrđuju njihove kompetencije. Stranice *Informatičke igre i multimedijски prikaz znanja*, *Jezične igre i multimedijски prikaz jezika*, igre za učenje glagoljice na stranicama Staroslavenskoga instituta i *Hrvatski u školi* igrifikaciju temelje na različitim tipovima igra koje su namijenjene korisnicima koji se razlikuju po dobi i predznanju. Stranice nemaju kao prethodno spomenuti sustavi za učenje Duolingo i CodinGame mogućnost izrade avatara unutar kojega će se spremati napredak i značke koje korisnik ostvaruje prolazeći kroz sadržaje, ali za razliku od tih stranica ne zahtijevaju od korisnika registraciju kako bi se igrale igre te sadržavaju bodovanje, a neke igre imaju ljestvice poretka te mogućnost prilagođavanja razine i težine.

3.4. Igrifikacija i *crowdsourcing*

Igrifikacija se često upotrebljava u *crowdsourcingu*⁶⁴. *Crowdsourcing* se uspješno primjenjuje u mnogim projektima povezanim s obradom prirodnoga jezika (engl. *NLP – Natural Language Processing*). Najčešće se primjenjuje kod rada na razvoju jezičnih resursa, pogotovo onih koji su povezani s jezicima na kojima nisu temeljitije istraženi (Krstev i Savay, 2018: 2). Osim razvoja resursa za područje obrade prirodnoga jezika, *crowdsourcing* se može primijeniti i za analizu te vrednovanje izrađenih resursa i programskih alata za rad s resursima (Ibid.: 2). Jedna je od tehnika *crowdsourcinga* GWAP (*Game with a Purpose*) koja korisnike potiče na doprinos u *crowdsourcingu* nudeći im zabavu umjesto novca. GWAP su igre koje primjenjuju *crowdsourcing* kako bi iz zabavnih procesa prikupljale podatke (Ibid.: 1). GWAP potiče

⁶² URL: https://en.wikipedia.org/wiki/List_of_Mario_educational_games#Mario's_Early_Years!_games (3. 12. 2019.)

⁶³ URL: <https://www.sesamestreet.org/games> (3. 12. 2019.)

⁶⁴ „*Crowdsourcing* je postupak dobivanja potrebnih usluga, ideja ili podataka od neodređene skupine ljudi.” (Bolje je hrvatski!, 2019).

korisnike da pokušaju ostvariti bolje rezultate u izvršavanju određenih aktivnosti koje se boduju (Venhuizen i dr., 2013: 1). Primjeri su korištenja GWAP-om igre Wordrobe i Zombilingo. Venhuizen i suradnici (2013) stvorili su igrači sustav na mreži Wordrobe, u kojoj igrači označuju tekst odgovarajući na pitanja iz kviza. Igraču se postavi pitanje u kojemu je označena određena riječ u tekstu te za označenu riječ treba odrediti točno značenje (npr. točnu definiciju, je li riječ o imenici ili o glagolu itd.). Više bodova dobivaju igrači koji češće i duže igraju igru te ostvaruju bolje rezultate u igri. Rezultati igrača pohranjuju se te se najčešći odgovori ili odgovori iskusnih igrača vrednuju kao točni. Kako bi se izbjegle pogreške u završnoj obradi teksta, glavni obrađivač provjerava rješenja. Unatoč tomu što ovaj model ne daje najtočnije rješenje, ipak u procesu krajnje obrade ubrzava posao obrađivača kad mu je u tekstu sve označeno, pa mu je jedini posao pregledati i ispraviti pogreške.

Zombilingo je igra u kojoj igrači označavaju vrste riječi u rečenicama izvađenim iz korpusa. Igra sadržava mnoge igrifikacijske elemente poput bodovanja, razina, igranja s više igrača, zadavanja zadataka igraču, nagrađivanja igrača različitim virtualnim nagradama (Fort i dr., 2014: 2–3). Da bi igrač odigrao tu igru, treba stvoriti korisnički profil na kojemu se bilježi njegov napredak. Igra je trenutačno dostupna samo na francuskome te se autor koristio Googleovim prevodiocem kako bi jasnije pregledao sadržaj igre. U igri se pojavljuje nasumično odabrana rečenica iz korpusa te se od igrača traži da odabere riječ koja pripada određenoj vrsti riječi (npr. glagol) (vidi sliku 10). Kad igrač odabere riječ, dobiva povratnu informaciju o točnosti odgovora. Ako se igrač ne slaže s objašnjenjem, može poslati primjedbu ili savjet urednicima igre.

Slika 10. Prikaz zadatka u igri Zombilingo

Zombilingo je u veljači 2017. uz sudjelovanje 986 igrača uspješno proizveo 213 082 anotacije riječi unutar različitih francuskih korpusa (Fort i dr., 2017: 1). Godine 2017. poslan je upitnik registriranim korisnicima koji se odnosi na korištenje igrom. Upitnik je ispunilo 109 igrača (tada je u igri bilo registrirano 986 igrača) od čega je 89 igrača koji su novi ili ne igraju često i 20 igrača koji često igraju, odnosno koji su napravili više od 500 anotacija za riječi ili igrali pet puta tjedno. Od 109 igrača 65 % su muškarci. Oko 80 % igrača ima između 21 i 60 godina. Među igračima koji češće igraju, 45 % ih je između 21 i 40 godina, a među igračima koji rjeđe igraju 17 % ih je između 21 i 40 godina. Većina igrača ima završen fakultet (75 % igrača koji često igraju i 57 % igrača koji rijetko igraju) (Ibid.: 2). Anotacija je bila uspješna jer su igrali obrazovani igrači. Također, 25 % igrača koji često igraju inače se bavi obradom prirodnoga jezika, a 15 % po obrazovanju su lingvisti. Od novih ili manje uspješnih igrača 74 % ih se bavi drugim područjima. Uz pitanja koja se odnose na motivaciju za igranje igrači su trebali napisati zašto vole igrati igru. Igrači koji često igraju spomenuli su da vole lingvistiku i da razumiju svrhu igre te žele doprinijeti označavanju korpusa. Kod igrača koji rjeđe igraju najčešći su odgovori bili zbog znatiželje jer ih je zanimalo kako radi igra ili su također htjeli doprinijeti označavanju korpusa (Ibid.: 2). Na temelju obrade rezultata postignutih tom igrom te ispitivanjem igrača, autori igre uspjeli su potvrditi da igrifikacija zadataka koji zahtijevaju *crowdsourcing* može pomoći u obavljanju velike količine posla. To su neki od primjera primjene igrifikacije i *crowdsourcinga* u području obrade prirodnoga jezika. Više o tome pisali su Dumitrache i suradnici (2013), Cirqueira i suradnici (2017) te Roa-Valverde (2014).

Autor je u veljači 2020. napravio demo inačicu igre za učenje frazema i kolokacija koja se temelji na *crowdsourcingu*. Igra je napravljena u sklopu radionice *enetCollect Crowdfest 2020*, u kojoj se okupljaju stručnjaci iz različitih područja i struka (npr. programeri, lingvisti, stručnjaci za *crowdsourcing* itd.) koji u odvojenim skupina surađuju dva dana kako bi razvili aplikaciju, prototip, igru ili konceptualni okvir povezan s učenjem jezika koji se služi *crowdsourcingom* (Lionel, 2019). Prije održavanja radionice suradnici su nacrtali dijagrame s konceptom⁶⁵ kako treba funkcionirati interakcija između više korisnika s igrom za učenje višerječnih izraza (engl. *multiword expressions*) koja se temelji na *crowdsourcingu* i interakcija te igre s bazom podataka. Ti višerječni izrazi uključuju frazeme i česte kolokacije. Igra treba biti osmišljena tako da sustav korisnicima ponudi početni izraz ili riječ s kojima korisnici trebaju izvršiti određenu aktivnost za koju dobivaju virtualne nagrade. Kad igrač izvršava radnje na riječima i izrazima, predlaže i svoja rješenja za određene probleme (npr. što je točno

⁶⁵ URL: <https://bit.ly/2NUPppL> (24. 1. 2020.)

značenje određenoga izraza) te osvaja virtualne nagrade. Također, može se igraču ponuditi da ocijeni tuđa rješenja te šalje vlastite zadatke koje dobivaju drugi korisnici. U igri se u bazi bilježe i boduju sva rješenja igrača koja se mogu upotrijebiti za različite svrhe (istraživanja i statističke analize, dopunu leksikografske baze).

Kolokacijska igra⁶⁶ napravljena je tako da se navede imenica, a igrač mora dati što više odgovora na kolokacijska pitanja (vidi tablicu 7).

Tablica 7. *Primjeri kolokacijskih pitanja*

kolokacijsko pitanje	primjeri
Kakav je x?	Kakav je pas? Kakva je banana?
Što se s x može?	Što se sa psom može? Što se s bananom može?

Kolokacijska pitanja oblikovana su u skladu s kolokacijskim pitanjima za imenice u *Mrežniku*. Budući da pridjevi koji odgovaraju na pitanje *Kakav je x?* ne odgovaraju uvijek obliku natuknice u *Mrežniku*, napravljen je izvoz u XML formatu imenica koje sadržavaju kolokacijska pitanja. Ta XML datoteka može se parsirati (parsati)⁶⁷ s pomoću jezika Python koristeći se programskom skriptom Beautiful Soup 4⁶⁸. Tim parsiranjem mogu se precizno izdvojiti odgovori za kolokacijska pitanja te spremi u bazu. Igra se igra tako da igrač treba napisati što više odgovora prije nego što mu istekne vrijeme. Odgovori igrača spremaju se u tablicu te se bilježi koliko su puta određeni odgovori odabrani. Odgovori koje su više puta napisali različiti igrači nose više bodova (npr. ako na pitanje *Kakav je pas?* pet igrača odgovori *zaigran*, a dva igrača odgovori *bijesan*, onda novi igrači koji odgovore *zaigrani* umjesto *bijesan* dobivaju više bodova). Time se vrijednosti riječi boduje na temelju popularnosti te se bodovanje riječi s obzirom na reakcije drugih igrača povremeno mijenja.

Igra s frazemima⁶⁹ funkcionira slično, tako da se ponudi dio frazema te se očekuje od igrača da ga završi. Npr. *Pijan kao...* Točan je odgovor npr. *majka* ili *deva*, ali također se može napisati *magarac*, *otac* itd. Frazemi su također preuzeti iz *Mrežnika* filtriranjem natuknica koje sadržavaju polje frazemi u svojoj strukturi (vidi sliku 11).

⁶⁶ URL: <https://bornal2.gitlab.io/igre-mreznik/crowdsourcing/kolokacije> (7. 2. 2020.)

⁶⁷ „Parsiranje (engl. *parsing*) je raščlanjivanje rečenice u računalnoj obradi jezika.” (Hudeček dr., 2018).

⁶⁸ URL: <https://www.crummy.com/software/BeautifulSoup/bs4/doc/> (7. 2. 2020.)

⁶⁹ URL: <https://bornal2.gitlab.io/igre-mreznik/crowdsourcing/> (28. 1. 2020.)

1/3.

Pijan kao .

10

majka 31, stup 10, deva 24, majmun 1, brat 1, ministar 1

potvrdi odgovor

Slika 11. Igra za upisivanje frazema u kojoj se boduju frazemi na temelju tuđih odgovora

Tako se može vidjeti koliko ljudi znaju frazeme te što su im prve asocijacije kad im se prikaže dio frazema. To je posebno zanimljivo kod poredbenih frazema sa sastavnicom *kao* ili *poput* kod kojih često postoji više točnih odgovora. Nakon što istekne vrijeme, igraču se prikazu svi njegovi odgovori s bodovima koje je postigao te točan ili točni frazemi. Riječi se boduju na temelju popisa koji se nalazi u *Mrežniku*. Za kolokacije se upotrijebio popis pridjeva, a za frazeme popis glagola i imenica. Za igru u kojoj se traži frazem, a igrač treba upisivati glagole, problem su u ovoj fazi glagolski oblici jer u *Mrežniku* nisu navedeni svi glagolski oblici, npr. za frazem *Kocka je bačena*. korisnik bi na prazno mjesto (*Kocka je ____.*) umjesto *bačena* trebao napisati *baciti* da bi mu se priznao odgovor. Oblik *bačena* ne nalazi se u *Mrežniku*, a budući da ima mnogo glagolskih frazema s glagolima u različitim oblicima, jako je teško izraditi igru koja prepoznaje sve glagolske oblike glagola iz *Mrežnika*. Igra provjerava unosi li igrač riječ koja se nalazi u popisu (npr. za frazem *Pijan kao...* kao odgovor se očekuje imenica, pa se odgovori korisnika provjeravaju s pomoću popisa imenica kako bi se spriječilo unošenje riječi koje ne pripadaju hrvatskomu jeziku, nepristojnih riječi, šaljivih odgovora i odgovora koji nemaju smisla (npr. da igrač utipka niz znakova koje dobiva brzim i nasumičnim tipkanjem *dsidjsalldsauidhas, sajkdhsldljsa, a eto*). Riječi koje se ne nalaze na popisu ne priznaju se u igri, ali se spremaju u tablicu, pa ih autor igre ima na uvid u slučaju da je riječ o riječima hrvatskoga jezika koje nisu unesene u rječnik. Te riječi mogu se poslije dodati u igru i u rječnik. Rješenja igrača spremaju se i učitavaju iz Googleovih tablica, pa se podatci koji se nalaze tablicama mogu lako izmijeniti, obraditi i izvesti.

Unutar radionice razvila se nova igra *MWExpress* koristeći se gotovim kodovima za aplikaciju Plagio⁷⁰. Plagio je program koji se upotrebljava u aplikaciji za slanje poruka Telegram⁷¹. Plagio se igra tako da korisnici u aplikaciji otvore *bot*⁷² na adresi @PlagioBot. Nakon toga mogu odabrati jezik igre (hrvatski ili talijanski) i pokrenuti skupnu igru odabirom ključne riječi koju svi igrači upisuju kako bi pristupili igri. Pravila igre takva su da jedan igrač odabere citat iz knjige ili poznatu uzrečicu ili frazem te napiše njihov dio. Ostali igrači moraju dovršiti prethodno napisanu rečenicu drugoga igrača. Nakon što svi igrači dovrše rečenice, prikazuju im se rješenja ostalih igrača nasumičnim redoslijedom. Igrači moraju odabrati što smatraju točnim odgovorom, tj. onaj odgovor koji je napisao prvi igrač koji je napisao dio rečenice. Igrači dobiju bodove ako točno pogode rečenicu koju je prvi igrač zadao te također dobivaju bodove ako drugi igrači odaberu njihovu rečenicu jer je smatraju pravilnom (Sangati i Monti, 2020). Igra *MWExpress* funkcionira slično, jedino se upotrebljava za učenje višerječnih izraza. U igri sudionici stvaraju i ocjenjuju tuđe višerječne izraze te pritom dobivaju bodove i značke. Korisnici aplikacije Telegram s pomoću poveznice @MWExpress pokreću igru i biraju žele li ocijeniti tuđe primjere višerječnih izraza ili dodati svoje. Ako dodaju svoje primjere, aplikacija iz baze učita jedan višerječni izraz (npr. *look up to*) za koji moraju dati primjer uporabe (npr. *He looks up to his older brother.*) te objasniti kakvo je značenje višerječnoga izraza u rečenici (značenje nije zbroj značenja *look + up + to*). Za svaki uneseni primjer igraču se dodjeljuje bod. Baze višerječnih izraza dopunjuju se tako da korisnici šalju prijedloge koje administratori mogu uključiti u igru. Baze koje pohranjuju višerječne izraze te korisnikove primjere, recenzije, bodove i medalje napravljene su na mrežnome servisu DigitalOcean⁷³, stranici koja omogućuje izradu virtualnih poslužitelja (poslužitelji – na stranici se zovu Dropleti) po najmanjoj cijeni od pet dolara mjesečno. Bazu je lako staviti na virtualni poslužitelj, na kojemu će stalno biti dostupna za korisnike te je administratori mogu lako mijenjati. Ako igrač želi ocijeniti primjere koje je unio koji drugi igrač, prikazuju mu se primjeri iz baze koje još nije ocijenio. Igrač ih ocjenjuje s obzirom na to smatra li ih primjerima dobre uporabe navedenoga višerječnog izraza. Primjerice, ako igrač dobije dvije dobre ocjene od drugih igrača za rečenicu koju je predao, dobiva dva boda. Ako dobije loše ocjene, gubi bodove. U igri se nalaze i ljestvice poretka kako bi se dodatno motivirali igrači (vidi sliku 12). Takva igra potiče kreativnost i kritičko

⁷⁰ URL: <https://gitlab.com/kercos/plagio> (13. 1. 2020.)

⁷¹ URL: <https://telegram.org/> (13. 1. 2020.)

⁷² *Bot* je automatiziran ili poluautomatiziran program koji izvršava određene radnje za korisnike i druge programe. (Collins English Dictionary, 2011).

⁷³ URL: <https://www.digitalocean.com/> (30. 1. 2020.)

promišljanje o uporabi višerječnih izraza te stvarateljima igre daje uvid u to koji se višerječni izrazi najčešće upotrebljavaju te kako igrači opisuju njihovo značenje.

Slika 12. Prikaz različitih scenarija igre MWExpress

Na *enetCollect Crowdfest 2020* predstavljena je i demoinačica RPG igre *The Game of Lost Words*⁷⁴ za učenje staroirskog jezika. U igri igrači igraju s mladim avanturistom koji mora spasiti selo od zloga čarobnjaka i njegova zmaja. Na početku igre igrač rješava nekoliko zagonetka tako što u dijalogu s drugim likovima spominje riječi iz staroirskoga koje se rimuju s određenom riječi ili su povezane s njom (sinonim, antonim, hiponim itd.). Odgovori korisnika spremaju se u odvojene TXT datoteke, pa ih administratori igre mogu pregledati. Igra je rađena s pomoću programa RPG maker⁷⁵ te time grafički izgleda kao klasična japanska RPG igra izrađena u 90-ima za igrače konzole kao što su SNES i SEGA Genesis. Zato igra izgleda vrlo atraktivno i lakše privlači igrače.

3.5. Pregled dosadašnjih istraživanja o igrifikaciji

Caponetto i suradnici (2014: 50) analizirali su znanstvene radove o igrifikaciji u obrazovanju objavljene u razdoblju 2000. – početak 2014. Analiza je pokazala da se nakon 2011. naglo

⁷⁴ URL: <https://bisame.paris-sorbonne.fr/lost-words/index.html> (6. 2. 2020.)

⁷⁵ URL: <https://www.rpgmakerweb.com/> (6. 2. 2020.)

povećao broj objavljenih radova: 206 radova objavljeno je 2011., dok je 1620 radova objavljeno 2013. To potvrđuje da je popularnost igrifikacije posljednjih godina porasla. Ortiz i suradnici (2016) koncentrirali su se na uporabu igrifikacije u visokome obrazovanju u području STEM-a. Analizom trideset znanstvenih radova utvrdili su da se igrifikacija najčešće primjenjuje u području računalnih znanosti, najčešće kao kombinacija različitih elemenata (bodovanje, značke i ljestvice poretka), te da pozitivno utječe na studente.

3.5.1. Istraživanja o obrazovnim igrama

„Vrijednost igre u procesu odgoja i obrazovanja opisana je u brojnim radovima s područja psihologije, pedagogije, didaktike i drugih znanosti te se spominje, među ostalim, pozitivan učinak obrazovnih igara na motivaciju učenika, brzinu učenja i trajnost znanja.” (Mihaljević i Mihaljević, 2019: 117–119). „Nadalje, razvoj tehnologije i digitalizacija društva unijeli su promjene i u područje obrazovanja i doveli su do sve većih mogućnosti, ali i sve češćega zahtjeva za uključivanjem tehnologije u obrazovni proces. Kao element digitalizacije računalne obrazovne igre mogu se uključiti u učenje i poučavanje u cilju motiviranja učenika i lakšega uvježbavanja i usvajanja nastavnoga gradiva.” (Lazić i Mihaljević, 2020: 122).

Vučković, Ujdur, Stojanov i Dovedan (2005: 57–58) u svojem radu opisuju sadržaje *Interaktivnoga dječjeg slikovnog rječnika* prilagođenoga predškolskoj dobi sa slikovnim prikazima i zvučnim zapisima koji se nalaze u natuknicama rječnika. Rječnik ima igre te elemente igrifikacije poput bodovanja, bilježenja rezultata, mogućnost uključivanja vremenskoga ograničenja za obavljanje određenih interaktivnih aktivnosti kako bi bile izazovne. Autori rada ističu da je važno igraču dati povratnu informaciju, a ne samo potvrdu je li točno ili netočno odgovorio kako bi bolje naučio sadržaj i dobio poticaj za daljnji rad. Na temelju rezultata igraču se savjetuje koje bi daljnje aktivnost trebao poduzeti (npr. *vježbaj još malo, idi na sljedeću vježbu...*). Svaki se točan odgovor i napredak u igri nagrađuje bodovima, lijepom riječju ili dodatnim zabavnim aktivnostima (npr. bojenje crteža).

Jensen (2003) navodi kako se svijet u posljednje vrijeme promijenio te kako osnovni izvor informacija za učenike više nisu učitelji i roditelji, nego internet i elektronički mediji. Također navodi i da istraživanja mozga pokazuju opravdanost igranja mnogih tipova igara kod učenika jer igre aktiviraju više igračevih osjetila te većinu njegove pozornosti zaokuplja kontrast među pokretima, zvukovima i emocijama. Elektroničke obrazovne igre tako idu u korak s vremenom omogućujući učeniku da uvježba nastavne sadržaje na suvremenome mediju koji mu je blizak. Singer i Singer (2007) smatraju da unatoč tomu što mnogi znanstvenici upozoravaju na moguću štetnost videoigara, treba uzeti u obzir da se takva upozorenja uglavnom odnose na pretjerano

nasilje u određenim igrama ili udaljavanje od stvarnosti zbog virtualne stvarnosti u njima. Aladrović Slovaček, Ivanković i Srzentić (2013: 16) ističu da je igra učenicima najzabavniji oblik učenja, a znanje stečeno u igri trajnije od znanja stečenoga na koji drugi način.

U školstvu se igrama želi povećati zanimanje učenika, njihova motivacija te osnažiti komunikacija i dijeljenje znanja (Medica Ružić i Dumančić, 2015). Frost, Reifel i Wortham (2012) pisali su o razvoju računalnih igara namijenjenih djeci te o utjecaju igara na odgoj i obrazovanje.

Studija koju je provela Traci Sitzmann (2011), profesorica menadžmenta na sveučilištu Colorado Denver Business School, pokazala je da su djelatnici koji su pohađali radionice na kojima su usvajali sadržaje s pomoću videoigara doznali više činjenica, postigli višu razinu vještina te je njihovo znanje bilo dugotrajnije od znanja djelatnika poučavanih u manje interaktivnome okružju. Otkrila je također da razina kvalitete nastave koja se postiže uvođenjem igara nije rezultat samo igre nego i studentskoga angažmana pri učenju.

Botički i dr. (2018) proveli su empirijsko istraživanje o igrifikaciji matematičkoga gradiva s pomoću računalne igre. U istraživanju su u tri skupine učenika (skupina u kojoj se primjenjuju suradničke igre, skupina u kojoj se primjenjuju prilagodljive igre te skupina u kojoj se primjenjuju natjecateljske igre) nižih razreda osnovne škole za vrijeme nastave matematike povremeno uveli rješavanje zadataka s pomoću igara na tabletu. Njihov uzorak sastojao se od 54 učenika, od čega su pola djevojčice, a pola dječaci. Istraživanje je provedeno bilježenjem ponašanja i ostvarenih rezultata učenika na satima matematike te pojedinačnim intervjuima provedenim s učenicima. Igra rezultate učenika sprema u bazu podataka kako bi se mogao pratiti njihov uspjeh u razredu. Rezultati istraživanja pokazuju da su učenici najmotiviraniji za rad na satu te postižu bolje rezultate u rješavanju zadatka kad se služe obrazovnim igrama prilagodljivoga tipa koje imaju priču koja je dobro uklopljena u nastavnu jedinicu. Igre također izmjenjuju mehanike s obzirom na rezultate koje igrač postiže u igri. Suradničke i natjecateljske igre, unatoč tomu što su manje uspješne od prilagodljivih, i dalje povećavaju zanimanje učenika za nastavno gradivo više nego klasične metode učenja.

Jagušt (2018: 96) smatra da bi buduća istraživanja igrifikacije trebalo usmjeriti na utjecaje različitih igrivih mehanika koje se mogu kombinirati za učenje različitoga gradiva.

Godine 2017. u Školi za medicinske sestre Vrapče provedeno je pokusno istraživanje o zadovoljstvu učenika s igrama za učenje nastavnog sadržaja informatike sa stranice *Informatičke igre i multimedijски prikaz znanja*. Istraživanje je detaljnije prikazano u radu *Creation and Use of Game-Based Learning Material* (Mihaljević, 2017a). Nakon nastave ispitano je 69 dobrovoljaca od kojih je 77 % reklo da im se sviđa primjena igara tijekom nastave,

63 % ih je reklo da misli da im igre pomažu pri učenju. Ipak 51 % učenika spomenulo je da se nisu koristili igrama kad su trebali neposredno ponavljati gradivo prije provjere znanja. Pitalo se učenike koja im je najdraži tip igre koji se koristi na nastavi (vidi grafikon 1). Najdraži tip igre⁷⁶ učenicima je bila igra križić-kružić s pitanjima (54 %, prikaz igre u slici 5). To ne iznenađuje jer je riječ o popularnoj igri koja se često primjenjivala na nastavi. Igralo se tako da su se učenici podijelili u dvije skupine koje su se međusobno natjecale. Učenici su mogli staviti oznaku na polje samo ako točno odgovore na pitanje. Skupina koja ispuni sva polja pobjeđuje (Ibid.: 326).

Grafikon 1. *Odabir najdražih igara sa stranice Informatičke igre i multimedijски prikaz znanja* (Ibid.: 327)

Delfin i dr. (2017: 1) analizirali su učinak učenja utemeljenoga na igri na temelju rezultata testova učenika 2. razreda srednje škole na satu prirode. Uzorak istraživanja obuhvaćao je 204 učenika iz šest razreda. Od tih šest razreda u trima razredima nastava se provodila s pomoću igara (104 učenika), a u ostalim trima razredima klasičnim metodama (100 učenika). Razredi u kojima se nastava provodila s pomoću igara sačinjavali su eksperimentalnu skupinu, a razredi koji su radili klasičnim metodama kontrolnu skupinu. Igre uključuju igre pamćenja (npr. pamtilica) i kvizove. Razlike u znanju među skupinama provjerene su s pomoću desetominutnih testova brze provjere koji su se provodili na satu nakon poučavanja igrama ili klasičnim

⁷⁶ Tip igre određuje sličan način igranja i karakteristike (Ernest, 2013: 1).

metodama. Tim testovima provjeravalo se kratkoročno znanje učenika. Dulji testovi s ponuđenim odgovorima sličnim kvizovima i test koji osim pitanja s ponuđenim odgovorima uključuje pitanja povezana s analizom i sastavljanjem definicija i pojmova te izbacivanjem uljeza pisani su nakon određenoga razdoblja. Sadržaji obrađeni na satu u objema skupinama ispitani su posttestom koji uključuje gradivo povezano sa strukturom i kopiranjem DNK-a, sintezom proteina, mutacijom, evolucijom i ekologijom. Istraživanjem se htjelo provjeriti postoji li značajna razlika u rezultatima kod svih oblika testiranja između obiju skupina (Ibid.: 3–4). Ta razlika provjerila se s pomoću dvosmjernoga Mann-Whitneyjeva U-testa u kojemu su se usporedili rezultati obiju skupina za sva tri tipa testa. Mann-Whitneyjev U-test pokazuje da kod desetominutnih testova dolazi do male značajnosti u razlici rezultata među skupinama ($p = 0,045$), a kod druga dva tipa testa ne dolazi do značajne razlike (za test sličan kvizu $p = 0,899$, a za drugi test $p = 0,514$). S obzirom na aritmetičku sredinu za prosjek bodova te aritmetičku sredinu rangova učenika eksperimentalna skupina bila je bolja u desetominutnim testovima i testovima koji sadržavaju pitanja u kojima se analiziraju pojmovi i sastavlja definicija. Kod testa sličnoga kvizu bolje rezultate ostvarili su studenti kontrolne skupine (Ibid.: 7). U zaključku rada na temelju rezultata autori navode da igre mogu pomoći određenim učenicima da poboljšaju kratkoročno pamćenje, ali rezultati istraživanja o utjecaju igara na dugoročno pamćenje trenutačno su neodređeni (Ibid.: 7).

3.5.2. Istraživanja o sustavima i aplikacijama za učenje i vježbanje

Klasnić, Lasić-Lazić i Seljan (2014) spominju da se u posljednje vrijeme sve više provode istraživanja o uporabi i poboljšanju sustava i programa za e-učenje radi donošenja novih standarda okvira i smjernica. Oni provode istraživanje o kvaliteti i uporabi materijala na sustavu za poučavanje Omega, koji je izrađen na sustavu otvorenoga koda Moodle, anketiranjem 148 studenata na Filozofskome fakultetu Sveučilišta u Zagrebu. Većina studenata smatra da sustav poput Omega omogućava lakšu distribuciju obrazovnoga materijala, koji može uključivati i igre (85,7 %), te podupiru ideju veće integracije sustava za e-učenje u tradicionalnu nastavu. Studenti su zadovoljniji kvalitetom nego količinom korištenja sustavom jer više od 40 % smatra da se Omega ne upotrebljava dovoljno u nastavi, a ostali smatraju suprotno ili to ne mogu procijeniti.

Lauc i dr. (2006: 117) proveli su istraživanje na 43 hrvatska učenika trećega razreda osnovne škole koji uče engleski kao strani jezik. U istraživanju su provjerili koliko obrazovni računalni programi mogu pomoći učenicima pri usvajanju vokabulara tijekom nastave. Jedna skupina učenika obradila je određenu nastavnu jedinicu s pomoću multimedijeskoga programa koji je

izrađen sa svrhom usvajanja vokabulara, a druga skupina učenika obradila je istu nastavnu jedinicu, ali klasičnim metodama rada s pomoću knjige i papira. Zadatci i aktivnosti tijekom sata bili su provedeni na isti način u dvjema skupinama. S objema je skupinama na početku napravljen predtest kako bi se provjerilo njihovo postojeće znanje. U predtestu su 24 riječi bile napisane u stupcu za koje se tražilo da se napiše prijevod na hrvatski jezik. Rezultati predtesta pokazali su da su obje skupine ujednačene u znanju engleskoga jezika (45 % točnih rješenja za skupinu koja će se koristiti multimedijским sadržajima te 42 % točnih rješenja za skupinu koja će nastaviti učiti klasičnim metodama) (Ibid.: 119). Na kraju nastavne jedinice proveden je i završni test u kojemu se provjeravalo učeničko razumijevanje novonaučenih imenica. Time se mogao provjeriti napredak obje skupina. Obrazovni program kojim se koristila jedna skupina učenika bio je napravljen kao *flash*-datoteka te je za zadatke sadržavao priču s različitim animacijama. Priča je bila prikazana kao strip koji prati Harryja i njegovu obitelj koja prolazi kroz svakodnevne situacije. U priči su određene riječi označene te se te iste riječi kasnije ponavljaju s pomoću različitih pitanja koja se rješavaju popunjavanjem praznih polja, dovlačenjem slika i riječi, pamtilicama i kvizovima. Igrači za rješenje svakoga zadatka dobivaju izravnu povratnu informaciju u obliku kratke tekstne poruke (Ibid.: 118). Završni ispit koji se upotrebljava na kraju nastavne jedinice pokazao je da je skupina učenika koja se koristila multimedijским programom ostvarila mnogo bolje rezultate od skupine koja se nije koristila multimedijским programom na nastavi jer su točno riješili 82 % zadataka povezanih s usvajanjem imenica dok je druga skupina riješila točno 50 % zadataka. Također se vidi velik napredak u odnosu na predtest jer je većina učenika riješila više od pola ispita točno, što kod predtesta nije bio slučaj. Kod zadataka pisanja riječi u prvoj skupini napravljen je samo pet pravopisnih pogrešaka dok ih je u drugoj skupini napravljen 18. Skupini koja se koristila multimedijским sadržajem dan je kratak upitnik u kojemu se ispitalo njihovo zadovoljstvo te želja da nastave učiti engleski jezik na taj način. Samo dvoje učenika izrazilo je negativan stav, a ostali su bili zadovoljni nastavnim satom koji je bio proveden u obliku igre te su izrazili želju da nastave učiti s pomoću multimedijških programa (Ibid.: 120).

Objavljeni su i ovi radovi hrvatskih autora koji se odnose na istraživanja o uporabi tehnologije za poučavanje stranih jezika: Kišiček i dr. (2013) *Interactive Application for Learning the Latin Language*, Libernjak i dr. (2016) *Croatian students' attitudes towards technology usage in teaching Asian languages — A field research*, Libernjak i dr. (2016b) *Improving Students' Language Performance Through Consistent Use of E-Learning: An Empirical Study in Japanese, Korean*.

Munday (2016: 83) je sa studentima koji uče španjolski ispitala kako se mogu iskoristiti igrificirani sustavi za učenje jezika. Odabrala je sustav Duolingo te ga uvrstila u svoju nastavu za A1 (46 studenata) i B2 (16 studenata) razinu španjolskoga kao drugoga jezika. Studenti su se koristili sustavom preko interneta i mobilnih uređaja. Glavni je cilj istraživanja bio da se provjeri koliko je Duolingo studentima jednostavan za korištenje, zabavan te pomaže li im u učenju španjolskoga jezika. Također se ispitalo koliko je zadovoljstvo korištenja Duolingom u odnosu na rješavanje zadataka na papiru, smatraju li da će im znanje stečeno na sustavu Duolingo biti korisno nakon što završe tečaj te koji su njihovi savjeti za poboljšanja sustava s obzirom na sveučilišni kurikulum (Ibid.: 90). Studenti A1 razine zadovoljni su Duolingom. 91 % studenata smatra da je sustav jednostavan za uporabu, 82 % studenta smatra da im je sustav pomogao u učenju, 80,4 % studenata smatra sustav zabavnim te je na kraju 78,3 % studenata zadovoljno sustavom (Ibid.: 92). Studenti B2 razine bili su manje zadovoljni Duolingom. 87,6 % studenata smatra da je sustav jednostavan za korištenje, 81,3 % studenata smatra da im je sustav pomogao u učenju, 43,8 % studenata smatra sustav zabavnim te je na kraju 50 % studenata zadovoljno sustavom, a 6,3 % neutralno, dok su ostali nezadovoljni. 84,8 % studenata A1 razine više voli rješavati zadatke na sustavu Duolingo nego na papiru, a u B2 razini studenti su podijeljeni, 50 % ih je zadovoljno, a 50 % nije (Ibid.: 93). 56 % studenata A1 razine reklo je da su završili više lekcija nego što je bilo potrebno da završe kolegij, 39,1 % ih je reklo da će se nastaviti služiti Duolingom na naprednijim razinama za daljnje usavršavanje, a 43,5 % ih je reklo da će se možda nastaviti koristiti Duolingom. Samo 20 % studenata B2 razine završilo je više od obveznih lekcija, 6,7 % ih je reklo da će se nastaviti služiti sustavom, a 46,7 % da će se možda nastaviti služiti sustavom (Ibid.: 94–95). Studenti A1 razine na posljednje pitanje upitnika povezano s poboljšanjem sustava s obzirom na kurikulum koji se uči na sveučilištima, uglavnom nisu dali dodatne savjete za poboljšanje te kritike sustavu. Nekoliko studenata spomenulo je da sadržaj iz sustava Duolingo nije u potpunosti odgovarao sadržaju koji se inače uči tijekom nastave za ispit te su bili navedeni prijedlozi da se Duolingo lekcije rade na satu oko 5 minuta. Također su bile primijećene neke pogreške u prijevodima. Studenti B2 razine napisali su među prijedlozima da bi sustav trebao biti manje strog u nagrađivanju te dati igračima više bodova kako bi bio zabavniji za uporabu (Ibid.: 96). Autorica istraživanja u zaključku spominje da sustavi za učenje jezika kao što su Duolingo mogu biti dobar dodatak redovitoj nastavi u učionicama. Kao prednosti navodi da studenti mogu samostalno učiti preko sustava koji ih boduje, ispravlja te motivira s pomoću igrifikacijskih elemenata. Ipak napominje da rezultate studenata iz sustava ne bi trebalo bodovati s više od 15 % pri donošenju završne

ocjene. Također na temelju statistike skupina A1 i B2 smatra da igrificirane sustave za učenje jezika bolje prihvaćaju početnici nego iskusniji govornici stranoga jezika (Ibid.: 97).

U Novome Zelandu godine 2015. provedeno je istraživanje o tome pomažu li aplikacije za trčanje tinejdžerima u postizanju boljih rezultata. Ispitivanje se provelo na 51 tinejdžeru koji su nasumično bili podijeljeni u tri skupine od kojih je svaka imali isti osmotjedni program trčanja. Nakon osam tjedana provedeno je završno testiranje na svim ispitanicima kako bi se mogle vidjeti razlike u rezultatima njihova treninga. Prva skupina (17) koristila se igrificiranom aplikacijom *Zombies, Run!* (više o aplikaciji u potpoglavlju *Primjena igrifikacije u tjelovježbi i sportu*) tijekom trčanja, druga se skupina koristila aplikacijom *Get Running*, koja je bilježila tračanje igrača, ali nije sadržavala nikakvu priču (16), a treća se skupina (18) nije koristila nijednom aplikacijom (Direito i dr., 2015: 1). Na kraju eksperimenta rezultati nisu pokazali statistički značajnu razliku među skupinama, ali su skupine koje su se koristile mobilnim aplikacijama pri treningu ipak ostvarile malo bolje rezultate. Dio sudionika iz skupine koja se koristila aplikacijom *Zombies, Run!* u intervjuima nakon završnoga testiranja spomenuo je da se dalje koriste tom aplikacijom za trčanje ili tijekom trčanja. Kao razlog naveli su da im se sviđa da mogu pratiti napredak svojega trčanja te da im je priča u aplikaciji zabavna te ih potiče na trčanje (Ibid.: 8).

U Americi je Microsoft Research (Althof i dr., 2016) proveo slično istraživanje s aplikacijom *Pokémon GO*. Tijekom mjesec dana s pomoću mreže anonimno su pratili broj koraka korisnika koji su prvi put instalirali aplikaciju *Pokémon GO* (1420 korisnika, više o aplikaciji u potpoglavlju *Primjena igrifikacije u tjelovježbi i sportu*) i te podatke usporedili podacima s korisnicima koji nemaju instaliranu tu aplikaciju (30 373). Svi sudionici istraživanja koristili su se brojačem koraka *Microsoft Band*, koji je slao podatke istraživačima. Ispitanici nisu imali nikakve fizički testove i zadatke u ispitivanju, nego su normalno živjeli. Rezultati su pokazali da ispitanici koji se koriste aplikacijom *Pokémon GO* u prosjeku dnevno naprave 1479 (25 %) koraka više nego prije korištenja aplikacijom. Ispitanici iz kontrolne skupine koji se nisu koristili aplikacijom u prosjeku su napravili 50 koraka manje nego prije početka istraživanja (Ibid.: 5). To se odnosi na korisnike koji nisu prije bili fizički jako aktivni. Autori istraživanja zato navode da je aplikacija bila uspješna u motiviranju ljudi koji nisu bili fizički aktivni da se počnu kretati (Ibid.: 7).

3.5.3. Istraživanja o negativnim utjecajima igrifikacije

Unatoč tomu što rezultati većine istraživanja prikazuju pozitivne učinke igrifikacije, ideja igrifikacije doživjela je nekoliko kritika. Dvije studije (Fitz-Walter, Tjondronegoro i Wyeth,

2011; Montola i dr., 2009) spomenule su da ima mnogo problema u igrifikaciji povezanih s bodovanjem i nagrađivanjem korisnika jer ako korisnik automatski počinje ponavljati akcije koje sustav ili igra boduju, a igra ne promijeni svoju dinamiku ili težinu zadataka ili bilo koju drugu mehaniku koja bi potaknula kognitivno razmišljanje igrača, gubi se svrha da korisnik uspješno postiže rezultate do kojih je došao svojim trudom i učenjem. Time igra ili igrificirani sadržaji mogu biti zabavni, ali ne postižu obrazovnu svrhu jer se igrač ne razvija u stvarnosti iako virtualno dobiva više bodova.

Armando i suradnici (2018: 11) proučili su negativne studije povezane s elementima igrifikacije i otkrili da od svih igrifikacijskih elemenata tablice s rezultatima igrača mogu dovesti do najvećega negativnog utjecaja. Neki igrači ne vole dobivati bodove za svoje znanje i vještine te se ne vole uspoređivati s uspješnijim igračima. Također spominju problem bodovanja koji dovodi do ljestvice poretka jer se često neispravno boduje težina zadataka te nagrade koje se nude za određene rezultate nisu zadovoljavajuće.

Hoe-Lian Goh i Razikin (2015: 612–614) proveli su istraživanje na 100 korisnika o utjecaju igrificirane sportske aplikacije Fitocracy⁷⁷ kao motivacije za vježbanje. Unatoč tomu što su rezultati istraživanja dokazali da je aplikacija kod većine ispitanika pomogla da vježbaju više, manji je dio ispitanika bio demotiviran. Jedan ispitanik spomnuo je da je razlog taj da neće svi postići jednako dobre rezultate u određenoj vježbi te neki korisnici mogu biti demotivirani ako redovito vide svoje niske rezultate u odnosu na ostale korisnike- To može dovesti do toga da korisnik ne želi sudjelovati u aktivnostima (Ibid.). Stålnacke Larsson (2013: 15–16) nakon intervjua sa šest korisnika koji se koriste različitim igrifikacijskim aplikacijama (npr. Fitocracy, Nike+), spominje da problem igrifikacije u sportu i tjelovježbi ili bilo kojoj drugoj društvenoj aktivnosti može biti nedostatak natjecateljskoga duha jer mnogi korisnici nemaju motivaciju za vježbanje, a dodatano ih demotivira kad ih aplikacija redovito podsjeća na to da nisu fizički aktivni te da njihovi rezultati nisu dobri kao u drugih korisnika.

Dominguez i suradnici (2013: 386) u svojem su istraživanju sa studentima došli do rezultata da igrifikacija na temelju koje studenti dobivaju značke dovodi do pozitivne motivacije studenata, ali da studenti koji se koriste igrificiranim obrazovnim sadržajima na nastavi postižu podjednake rezultate kao studenti koji imaju klasičan oblik nastave. Igrifikacija unatoč tomu što može potaknuti veću aktivnost učenika ili studenata tijekom nastave i dalje ne jamči da će to učiniti nakon nastave.

⁷⁷ URL: <https://www.fitocracy.com/> (14. 3. 2021.)

Markopoulos i suradnici (2015: 130–131) u pregledu publikacija povezanih s igrifikacijom utvrdili su da loše dizajnirane obrazovne igre i sadržaji mogu smanjiti intrinzičnu motivaciju studenata ili učenika. Također smatraju da igrifikaciju ne mogu dobro prihvatiti svi nastavnici jer je teško redovito pripremiti i održavati igrificirani oblik nastave kroz računalni ili klasičan oblik igre te je teško određene obrazovne sadržaje uspješno igrificirati. Zato je vrlo važno uskladiti elemente igrifikacije s obrazovnim sadržajem i krajnjim ciljem koji se želi postići. Igrificirani sadržaji uvijek moraju biti namijenjeni određenim korisnicima te tehnički dobro pripremljeni kako bi bili zanimljivi te omogućili trajnije povratno korištenje koje bi dovelo do određenih rezultata.

4. PROJEKT *HRVATSKI MREŽNI RJEČNIK – MREŽNIK*

Budući da se praktični dio istraživanja provodi u sklopu projekta *Hrvatski mrežni rječnik – Mrežnik*, u ovome poglavlju ukratko će se opisati projekt i osvrnuti u prvome redu na tehnološke aspekte.

Mrežnik je četverogodišnji projekt Instituta za hrvatski jezik i jezikoslovlje koji financira Hrvatska zaklada za znanosti. Projekt je započeo 1. ožujka 2017. te će završiti 31. srpnja 2021. Voditeljica je projekta Lana Hudeček. O projektu *Mrežnik* napisan je niz članaka⁷⁸, u kojima se o *Mrežniku* govori s različitih aspekata.

„Cilj je *Mrežnika* stvoriti slobodno dostupan, jednojezični, hipertekstni, jednostavno pretraživ mrežni rječnik hrvatskoga standardnog jezika od 10 000 natuknica koji će omogućiti interakciju s korisnicima.” (Hudeček i Mihaljević, 2017b: 2–3). *Mrežnik* će imati unutarnje poveznice između natuknica za sinonime, antonime, meronime, hiponime, tvorenice itd. Rječnički članci također će biti povezan s vanjskim izvorima Instituta za hrvatski jezik i jezikoslovlje: *Jezični savjetnik*⁷⁹, *Bolje.hr*⁸⁰, *Struna – Hrvatsko strukovno nazivlje*⁸¹, baza glagolskih valencija *e-Glava*⁸², *Repozitorij hrvatskih metafora*⁸³, *Hrvatski u školi* i *Hrvatski terminološki portal*⁸⁴ (Hudeček i Mihaljević, 2019b: 77). Za svaku natuknicu i podnatuknicu napraviti će se kolokacije i primjeri uporabe riječi koji će biti utemeljeni na korpusu Instituta za hrvatski jezik i jezikoslovlje *Hrvatskoj mrežnoj riznici*⁸⁵ i *Hrvatskome mrežnom korpusu hrWaC-u*⁸⁶, koji su izradili dr. sc. Nikola Ljubešić i Filip Klubička⁸⁷. *Mrežnik* se obrađuje u programu TLex. Prvo se u TLexu izradila DTD struktura⁸⁸ za *Mrežnik* te se nakon toga počelo unositi natuknice te popunjavati polja u toj strukturi (vidi sliku 13).

⁷⁸ URL: <http://ihjj.hr/mreznik/page/radovi/5/> (19. 1. 2020.)

⁷⁹ URL: <http://jezicni-savjetnik.hr/> (28. 5. 2019.)

⁸⁰ URL: <http://bolje.hr/> (28. 5. 2019.)

⁸¹ URL: <http://struna.ihjj.hr/> (28. 5. 2019.)

⁸² URL: <http://valencije.ihjj.hr/> (28. 5. 2019.)

⁸³ URL: <http://ihjj.hr/metafore/> (28. 5. 2019.)

⁸⁴ URL: <http://nazivlje.hr/> (28. 5. 2019.)

⁸⁵ URL: <http://riznica.ihjj.hr/index.hr.html> (24. 8. 2019.)

⁸⁶ URL: <http://nlp.ffzg.hr/resources/corpora/hrwac/> (24. 8. 2019.)

⁸⁷ O izradi korpusa vidi više u radu *{bs,hr,sr}WaC – Web Corpora of Bosnian, Croatian and Serbian* (Ljubešić i Klubička, 2014).

⁸⁸ DTD (Document Type Definition) je opis kojim se koristi za određivanje XML sheme. Kod *TLexa* njime se koristi za određivanje elementa rječnika te atributa koje ti elementi mogu sadržavati. Svaki računalni rječnik koji se izrađuje u TLexu treba imati vlastitu DTD strukturu koja se određuje na početku izrade rječnika s mogućim izmjenama u procesu izrade. Nakon određivanja logičke strukture rječnika obrađivači slijede strukturu pri obradi natuknica te je jedino administratori mogu izmijeniti. U TLexu DTD struktura izrađuje se s pomoću grafičkoga sučelja, pa nije potrebno veliko tehničko znanje za rad s njom (Joffe i Schryver, 2018: 55).

Slika 13. Prikaz strukture rječničkoga članka u osnovnome modulu u Mrežniku (prema Hudeček i Mihaljević, 2018: 5)

Obrada natuknica u TLexu prikazana je na primjeru obrade natuknice *broj*, koja ima bogatu strukturu i poveznice na vanjske sadržaje (*Struna, Hrvatska školska gramatika*) (vidi sliku 14).

z
n
a
č
e
n
j
e

natuknica **gramatički blok**

broj **broj** im. m. (G broja, A broj, I broju, I brojem; mu. N brojevi, G brojčevā, DLI brojčevima, A brojčeve)

¹ **mat.** Broj je riječ ili znak koji pokazuje od koliko se jedinka sastoji konačni skup ili koje je što po redu. → **definicija**

- U odnosu na procjenu prethodne godine najveći pad broja stanovnika zabilježen je u Ličko-senjskoj županiji.
- Znanstveno je definirano da znatno veći udio od ukupnog broja mišićnih vlakana u odnosu na klasično vježbanje snažno kontrahira i to serijama refleksnih kontrakcija, koje dodatno poboljšavaju cirkulaciju i potiču rast pulsa u treningu. → **primjeri**

Kakav je broj? dovoljan, mali, ogroman, velik, ukupan
Kakav je broj? ili Čega je broj? broj članova, broj djece, broj ljudi, broj korisnika, broj slučajeva, broj stanovnika, broj sudionika → **kolokacije**

• Iako se u praksi često riječi *broj* i *brojka* upotrebljavaju kao sinonimi, u hrvatskome standardnom jeziku treba razlikovati njihovo značenje. U značenju 'riječ ili znak koji pokazuje od koliko se jedinka sastoji konačni skup' treba upotrebljavati riječ *broj*, a u značenju 'znak za zapis broja' riječi *brojka* ili *znamenka*. → **poveznica unutar rječnika**

SINONIM: brojka :2 → **normativna napomena**

Struna: <http://struna.ihj.hr/naziv/broj/30053/#naziv> → **vanjska poveznica**

cijeli broj mat.
Cijeli broj prirodni je broj, nula ili broj suprotan prirodnomu broju.
Struna: <http://struna.ihj.hr/search-do/?q=cijeli+broj#container>

glavni broj mat.
Glavni broj riječ je ili znak koji pokazuje od koliko se jedinka sastoji konačni skup.
Struna: <http://struna.ihj.hr/search-do/?q=glavni+broj&naziv=1&polje=0#container>

negativni broj
ANTONIM: broj pozitivni broj
Negativni broj broj je koji je manji od nule.
Struna: <http://struna.ihj.hr/search-do/?q=negativni+broj#container>

neparni broj mat.
Neparni broj cijeli je broj koji nije djeljiv s dva.
ANTONIM: broj parni broj
Struna: <http://struna.ihj.hr/search-do/?q=neparni+broj#container>

parni broj mat.
Parni broj cijeli je broj koji je djeljiv s dva.
ANTONIM: broj neparni broj
Struna: <http://struna.ihj.hr/search-do/?q=parni+broj&naziv=1&polje=0#container>

pozitivni broj mat.
Pozitivni broj broj je koji je veći od nule.
ANTONIM: broj negativni broj

prirodni broj mat.
Prirodni broj broj je koji pokazuje od koliko se jedinka sastoji koji skup.
Struna: <http://struna.ihj.hr/search-do/?q=prirodni+broj&naziv=1&polje=0#container>

redni broj mat.
Struna: <http://struna.ihj.hr/search-do/?q=redni+broj&naziv=1&polje=0#container>

² **gram.** Broj je nepromjenjiva ili promjenjiva riječ kojom se označuje koliko čega ima ili koje je što po redu.
- Osim glavnih i rednih brojeva, brojeve su riječi i: broj(ev)ne imenice (dvojica, obojica, polovina, desetina, stotinka, dvoje, oboje...), broj(ev)ni prilozi (desetak, dvadesetak, stotinjak), broj(ev)ni pridjevi (dvoji, troji, četverī/četvori).
- U hrvatskome jeziku postoje ove vrste riječi: imenice, glagoli, pridjevi, zamjenice, brojevi te prilozi, prijedlozi, veznici, usklici i čestice.
Kakav je broj? glavni, redni
Hrvatska školska gramatika: <http://gramatika.hr/pravilo/brojevi/32/#pravilo>

³ **gram.** Broj je gramatička kategorija riječi kojom se označuje je li riječ o jednome primjerku čega ili o više njih.
- Problemiziranje semantičkoga te djelomice morfološkog aspekta gramatičke kategorije broja na odabranim dijelovima sintaktičkih struktura hrvatskoga jezika, provedeno je u ovoj znanstvenoj studiji opisima odnosa matematičkoga prema gramatičkome broju.
- Jasno mi je da se logički i gramatički broj ne moraju poklapati.
Kakav je broj? gramatički

⁴ **Broj je oznaka veličine odjeće i obuće.**
- S obzirom na veliku ponudu čak i na kraju još možete naći svoj broj cipela ili odjeće.
- Zbog povećane tekućine u tijelu mnoge trudnice osjete oticanje u nogama i moraju nositi veći broj cipela.

telefonski broj
Telefonski broj broj je koji treba utipkati u telefon da bi se uspostavila veza.
- U prvih 5 sekundi nakon podizanja slušalice trebali biste utipkati bilo koji željeni telefonski broj.
Što se s telefonskim brojem može? doznati ga, nazvati ga, okrenuti ga, razmijeniti ga, utipkati ga, zadržati ga, zapamtiti ga, zapisati ga, Koordinacija: adresa i telefonski broj, ime i telefonski broj
• U hrvatskome standardnom jeziku, kad god je to moguće, u pravilu kad se time ne mijenja značenje, skupinu imenica + imenica u genitivu treba zamijeniti skupinom pridjev + imenica. To pravilo osobito treba primjenjivati u tvorbi višerječnih naziva koje struke ili u području službene djelatnosti. Prema tome pravilu umjesto izraza *broj telefona* bolje je upotrebljavati izraz *telefonski broj*. To pravilo ne treba primjenjivati i kad izrazi *imenica* + *imenica* u genitivu i pridjev + *imenica* imaju različito značenje, npr. Praznik rada ('praznik kojim se slavi rad') i radni praznik ('praznik na koji se radi').

kućni broj
Kućni broj brojčana je oznaka koja jednoznačno određuje kuću ili zgradu u ulici.
- Zakonska je obveza vlasnika osigurati propisani kućni broj, a prekšaj se sankcionira slijedom propisa o komunalnom redu

poštanski broj
Poštanski broj oznaka je mjesne pošte koja se stavlja na adresu i služi za bržu dostavu pošte.
- Svaki rad treba imati na poledini (sve pisano čitljivim, velikim slovima): ime i prezime djeteta (prvo ime, pa prezime) godine i spol puno ime i adresa škole ili ustanove adrese po načelu: ime škole, ulica, broj, poštanski broj, grad, država broj telefona škole ili ustanove.
tvorenice brojan, brojiti, brojka tvorenice brojlica, brojan, brojevni, brojiti, brojka mrtve tvorenice: brojač
Struna: <http://struna.ihj.hr/search-do/?q=broj#container>

p
o
d
n
a
t
u
k
n
i
c
e

Slika 14. Prikaz obrade natuknice broj u osnovnome modulu u Mrežniku

Budući da je osnovna tema ovoga rada igrifikacija, prikazat ću i kako je natuknica *igrifikacija* obrađena u *Mrežniku* (vidi sliku 15).

Slika 15. Prikaz obrade natuknice igrifikacija u osnovnome modulu

Određene natuknice sadržavat će i slike te audiozapise izgovora te igre koje su osmišljene i razvijene u okviru ovoga rada. Audiozapisi će se snimiti u studiju. Razmišljalo se i o korištenju sustavom za sintezu govora koji automatski pretvara tekst u govor, ali nažalost kvaliteta besplatnoga sintetizatora za mrežne preglednike⁸⁹ nije dovoljno dobra za hrvatski jezik. Igre će se u strukturi *Mrežnika* nalaziti u polju za vanjske poveznice,⁹⁰ kao što je prikazano na sljedećemu dijagramu. U osnovnoj strukturi *Mrežnika* (prema Hudeček i Mihaljević, 2018) dodano je mjesto donošenja poveznica na igre. Na primjer poveznica na igre za učenje brajice može se staviti u rječnički članak natuknice *brajica* i sinonimnu podnatuknicu *Brailleovo pismo*. Kako bi korisnik lakše mogao naći sve igre koje će biti uvrštene u *Mrežnik*, napraviti će se podstranica za igre, na kojoj će igre biti kategorizirane po tipu i sadržaju. Više o tome u poglavlju *Konceptualni okvir igrifikacije mrežnoga rječnika*.

„Uz osnovne definicije i primjer uporabe, rječnik će uključivati i školske definicije i primjere uporabe za učenike (3000) te definicije i primjere uporabe za strance koji uče hrvatski kao drugi, strani ili nasljedni jezik (1000).” (Hudeček i Mihaljević, 2017b: 9). Sve riječi iz modula s manjim brojem natuknica nalaze se i u osnovnome modulu. „Za ta su tri modula uspostavljena tri modela strukture natuknice, pa će se ti moduli osim po broju uključenih riječi razlikovati i po načinu obrade tih riječi (opsegu i vrsti gramatičkih podataka, ustroju i opsegu definicije značenja, značenjskoj razvedenosti, primjerima, povezivanje s drugim natuknicama i izvanrječničkim izvorima, uspostaviti će se značenjski odnosi s drugim natuknicama i riječima

⁸⁹ URL: https://developer.mozilla.org/en-US/docs/Web/API/Web_Speech_API (29. 1. 2020.)

⁹⁰ Vanjske poveznice najčešće se izravno povezuju na natuknicu, a ne na značenje (*sense*). U rijetkim slučajevima u kojima se vanjski izvor može povezati samo s jednim određenim značenjem, vanjski se izvori povezuju sa značenjem (kao npr. u natuknici *broj*).

koje neće biti zastupljene u *Mrežniku* (tzv. mrtvi sinonimi, antonimi, tvorenice itd.), po svezama i frazemima koji se u pojedinome modulu donose te njihovoj obradi, po vrsti i opsegu normativnih i pragmatičkih napomena). Abecedarij za *Mrežnik* sastavljen je od čestotnog popisa riječi iz korpusa *Hrvatske jezične riznice* i *hrWaca*. Abecedarij modula za učenike sastavljen je na temelju školskih priručnika i udžbenika, a abecedarij modula za neizvorne govornike na temelju rječnika koji se nalazi na kraju udžbenika hrvatskoga jezika namijenjenoga neizvornim govornicima.” (Hudeček i Mihaljević, 2017b: 2–3). Nakon završetka leksikografske obrade podatci će biti izvezeni iz programa TLexa u repozitorij europske znanstvene infrastrukture CLARIN⁹¹. *Mrežnik* je osmišljen tako da se i nakon završetka projekta e-rječnik može nadopunjavati novim natuknicama, interaktivnim sadržajima te drugim podacima povezanim s jezičnom obradom.

4.1. Dodatni sadržaji izrađeni za *Mrežnik*

Osim samoga *Mrežnika* (e-rječnika) te znanstvenih istraživanja u sklopu projekta *Hrvatski mrežni rječnik* izrađuju se i neki dodatni sadržaji. Sadržaji koji se mogu igrificirati te sadržaji u čijoj je izradi doktorand sudjelovao prikazat će se u ovome potpoglavlju.

4.1.1. Odostražni rječnik

„Odostražni rječnik rječnik je u kojemu su natuknice poredane abecednim redom, ali su abecedirane od svojega kraja. Takav je rječnik koristan proučavateljima hrvatske tvorbe, pjesnicima, rješavateljima križaljki itd.” (Lewis i Mihaljević, 2018: 21). Odostražne rječnike imaju mnogi jezici, npr. engleski, francuski, njemački, ruski, slovenski, srpski, talijanski i ukrajinski jezik. (Grčević, 2017: 2). Ipak većina tih odostražnih rječnika nije dostupna na mreži u obliku mrežne stranice unutar koje se može izravno pretraživati sadržaj rječnika. Odostražni rječnici u elektroničkome obliku uglavnom su objavljeni kao računalne datoteke (najčešće skenirane knjige u formatu PDF) koje se otvaraju u nekom od instaliranih programa. „Takav je slučaj i s hrvatskim jezikom. Hrvatski je jezik dosad bio zastupljen u rječniku Josipa Matešića *Rückläufiges Wörterbuch des Serbokroatischen* (1965. – 1967.), koji je mrežno dostupan na stranicama Sveučilišta u Innsbrucku⁹² kao .mdb (Microsoft Database) datoteka koja se otvara u Microsoft Access programu. U okviru projekta *Mrežnik* predviđena je i izrada odostražnoga rječnika u četvrtoj (2020.) godini projekta jer se završna inačica odostražnoga rječnika može

⁹¹ URL: <http://www.clarin.si> (29. 5. 2019.)

⁹² URL: <https://www.uibk.ac.at/slavistik/institut/matesic.html> (10. 1. 2020.)

izraditi tek nakon dobivanja završne inačice abecedarija.” (Lewis i Mihaljević, 2018: 24). Demoinačica odostražnoga rječnika izrađena je te je objavljena na GitLab repozitoriju^{93, 94} (vidi sliku 16).

Odostražni rječnik

pronađi

Pronađen broj riječi: 1705.

Bogorod <u>ica</u>	ljestv <u>ica</u>	ravnatelj <u>ica</u>
Pedesetn <u>ica</u>	ljevaon <u>ica</u>	ravn <u>ica</u>
administrator <u>ica</u>	ljev <u>ica</u>	ravnodne <u>ica</u>
admiral <u>ica</u>	ljubavn <u>ica</u>	razarač <u>ica</u>
adolescent <u>ica</u>	ljub <u>ica</u>	razbijač <u>ica</u>
advokat <u>ica</u>	ljubim <u>ica</u>	razbojn <u>ica</u>
agent <u>ica</u>	ljubitelj <u>ica</u>	razgledn <u>ica</u>
agin <u>ica</u>	ljut <u>ica</u>	razigravač <u>ica</u>
agitator <u>ica</u>	logoraš <u>ica</u>	razmetljiv <u>ica</u>

Slika 16. Prikaz demoinačice općega odostražnog rječnika za hrvatski jezik

„S obzirom na riječi koje obuhvaćaju, odostražni rječnici mogu biti opći i posebni. Opći odostražni rječnici obuhvaćaju opći leksički fond pojedinoga jezika, poput općih jednojezičnih rječnika, ali građu donose abecedirano od kraja riječi. Posebni odostražni rječnici donose građu jednoga područja ili nekoliko njih, a od rječnika te vrste u hrvatskome jeziku može se izdvojiti odostražni rječnik koji su izradili Božidar Finka i Antun Šojat u radu *Govor otoka Žirja*⁹⁵ iz 1968.” (Ibid., 22: 2018). Na temelju prethodno spomenutoga odostražnog rječnika, koji je izrađen unutar projekta *Mrežnik*, napravljen je poseban odostražni rječnik naziva za

⁹³ URL: <https://borna12.gitlab.io/odostraznji/> (28. 11. 2019.)

⁹⁴ „GitLab je sustav za upravljanje inačicama programa (engl. *version control system*) koji omogućava redovito ažuriranje datoteke u odabranim direktorijima te vraćanje prethodnih datoteka koje su spremljene u određenoj vremenskoj točki. Datoteke su spremljene na GitLabovim mrežnim repozitorijima te im mogu pristupiti i ažurirati ih ovlašteni korisnici. GitLab također omogućava objavljivanje mrežnih sadržaja s pomoću privatnih mrežnih poveznice te je tako moguće testirati interaktivne sadržaje poput igara i slati ih na uvid prije službenoga objavljivanja (GitLab, 2018).” (Lazić i Mihaljević, 2020: 124).

⁹⁵ URL: <https://hrcak.srce.hr/68849> (10. 1. 2020.)

vršitelje/vršiteljice radnje za projekt *Muško i žensko u hrvatskome jeziku*⁹⁶. I taj se rječnik temelji na specijaliziranome popisu mocijskih parnjaka⁹⁷, koji se temelji na radnome abecedariju izrađenome za projekt *Muško i žensko u hrvatskome jeziku*.

„Rječnici su izrađeni s pomoću HTML5 i jQuery tehnologije. Početni kod za izradu rječnika preuzet je sa stranice CodePen⁹⁸. Na toj su stranici dostupni različiti besplatni razvojni kodovi za mrežne stranice, pa nije potrebno napredno znanje programiranja kako bi se iz bilo kojega popisa riječi izradili rječnici jer je logika pretraživanja i prikaza riječi ugrađena u razvojnim kodovima. U razvojnome kodu zamijenjen je popis riječi te dizajn i funkcionalnosti sučelja. Razvojni kod na toj stranici u početku nije bio razvijen za odostražno pretraživanje, ali je poslije to izmijenjeno.” (Lewis i Mihaljević, 2018: 23).

„Pretraživanje odostražnoga rječnika provodi se s pomoću regularnih izraza⁹⁹ ili skraćeno regexa koji učitavaju riječi iz JSON¹⁰⁰ datoteke. Rječnici su responzivni, tj. mogu se pregledavati na svim računalnim uređajima te na različitim mrežnim preglednicima.” (Ibid.). Moguće je i s pomoću drugih programskih rješenja isprogramirati logiku funkcioniranja odostražnoga rječnik poput programskoga jezika Pythona¹⁰¹ i programa NooJ-a¹⁰².

4.1.2. Stranice projekta *Mrežnik*

U okviru projekta *Hrvatski mrežni rječnik – Mrežnik* izrađene su mrežne stranice objavljene pod domenom Instituta za hrvatski jezik i jezikoslovlje¹⁰³. Te su stranice već javno dostupne te

⁹⁶ „U sklopu projekta *Muško i žensko u hrvatskome jeziku* proučavaju se različiti aspekti muško-ženskih odnosa u hrvatskome jeziku (tvorbeni, leksikografski, sociolingvistički, pragmatički itd.). Aktualnost je toga problema očita i iz velikoga broja savjeta koji se odnose na tvorbu ženskih parnjaka od muških, ali i muških od ženskih, na način oslovljavanja muških i ženskih osoba, pisanje zakonskih tekstova u kojima se spominju muške i ženske osobe i slično. Problem je u najvećem mjeri povezan s mocijskom tvorbom, ali je katkad i širi od nje jer se muško-ženski odnosi ne mogu uvijek izraziti tvorbenim odnosom (*medicinska sestra – medicinski tehničar*). Pri analizi tvorbenih mogućnosti iznimno je korisno imati odostražni rječnik kako bi se moglo lako pretražiti sve riječi koje imaju određeni završetak (npr. *-ica*, *-ač*, *-inja*, *-lac*).” (Lewis i Mihaljević, 2012: 22). Više o projektu: <http://ihjj.hr/projekt/musko-i-zensko-u-hrvatskome-jeziku/72/> (10. 1. 2020.).

Unutar projekta napravljena je pamtilica *Muško-ženski parovi* u kojoj se sparuju nazivi zanimanja koji su prikazani slikovno. Ista se igra uz male preinake može upotrijebiti i za igrifikaciju *Mrežnika*. URL igre: <https://jezicneigre.com/hr/musko-zenski-parovi/> (10. 1. 2020.)

⁹⁷ „Mocijski parnjaci imenice su suprotnog spola koje su u mocijskom odnosu čineći mocijski par (npr. *car – carica*, *otac – majka*).” (Barić, 1987).

⁹⁸ URL: <https://codepen.io/> (10. 1. 2020.)

⁹⁹ „Regularni izraz (engl. *regular expression*) zadani je niz znakova čija se kombinacija može upotrijebiti u programu ili programskom jeziku za pronalaženje i označavanje određenih dijelova teksta”. (Techopedia, 2011).

¹⁰⁰ „JSON (JavaScript Object Notation) je tekstno otvoreni standard dizajniran za čitljivu razmjenu podataka koji se temelji na sintaksi JavaScripta. Koristi se u mrežnome razvoju jer omogućuje interoperabilnu, brzu i neometanu razmjenu informacija između različitih sustava i programa.” (Techopedia, 2011b)

¹⁰¹ URL: <https://www.python.org/> (16. 3. 2021.)

¹⁰² URL: <http://www.nooj-association.org/> (16. 3. 2021.)

¹⁰³ URL: <http://ihjj.hr/mreznik/> (17. 1. 2020.)

se na njima, osim opisa projekta, mogu pratiti aktivnosti povezane s projektom, kao što su godišnja usavršavanja i diseminacije suradnika na projektu¹⁰⁴, napisani radovi povezani s projektom i mrežni pojmovnik e-leksikografije, koji se redovito dopunjuje (vidi više u idućemu potpoglavlju *Pojmovnik Mrežnika*).

Na stranicama projekta također se nalaze vanjske poveznice na druge mrežne rječnike (npr. *Íslex*, *Slovarji Instituta za slovenski jezik Frana Ramovša ZRC SAZU*, *Wječnik*, *elexiko*) i leksičke baze otvorenoga pristupa (npr. *CroWN*, *Hrvatski terminološki portal*, *Microsoft Terminology Collection*)¹⁰⁵, upute za obrađivače¹⁰⁶ u kojima se nalazi i struktura obrade natuknica (slika 13) te informacije o održanome znanstvenom skupu *E-rječnici i e-leksikografija*¹⁰⁷, koji je organiziran unutar projekta. Stranica projekta napravljena je s pomoću vlastitoga institutskog sustava za upravljanje mrežnim sadržajem (engl. *CMS – Content management system*), u kojemu je moguće ažurirati sadržaje s pomoću jednostavnoga grafičkog sučelja.

4.1.2.1. Pojmovnik *Mrežnika*

Budući da se pri izradi *Mrežnika* upotrebljava suvremena tehnologija i način rada primjeren e-leksikografiji, svatko tko se bavi e-leksikografijom mora ovladati mnogim novim nazivima. Zbog toga je na stranicama projekta *Mrežnik* izrađen *Pojmovnik*¹⁰⁸. *Pojmovnik* može pomoći svakomu tko se bavi e-leksikografijom ili tek ulazi u to područje te se povremeno susreće s nepoznatim nazivima ili ga zanima koje su tehnologije dostupne za izradu različitih računalnih leksikografskih sadržaja. Pojmovnik je izrađen u suradnji s projektom *Hrvatsko jezikoslovno nazivlje – Jena*¹⁰⁹ Instituta za hrvatski jezik i jezikoslovlje (Hudeček i Mihaljević, 2019c: 27). Razlika između obrade natuknice *regularni izraz* u *Jeni* i Pojmovniku *Mrežnik* prikazana je u tablici 8.

¹⁰⁴ URL: <http://ihjj.hr/mreznik/page/usavrsavanje-i-diseminacija-2019/26/> (21. 1. 2020.)

¹⁰⁵ URL: <http://ihjj.hr/mreznik/page/vazne-poveznice/7/> (21. 1. 2020.)

¹⁰⁶ URL: <http://ihjj.hr/mreznik/uploads/upute.pdf> (21. 1. 2020.)

¹⁰⁷ URL: <http://ihjj.hr/mreznik/page/e-rjecnici-i-e-leksikografija/8/> (21. 1. 2020.)

¹⁰⁸ URL: <http://ihjj.hr/mreznik/page/pojmovnik/6/> (10. 1. 2019.)

¹⁰⁹ „Cilj je projekta *Hrvatsko jezikoslovno nazivlje – Jena* unijeti u bazu 1500 naziva sa sinonimima, definicijama i istovrijednicama na četirima svjetskim jezicima: engleskome, njemačkome, francuskome i ruskome. Takva baza bit će temelj za daljnje usustavljanje jezikoslovnoga nazivlja jer će se i nakon završetka predviđenoga trajanja projekta upotpunjavati dodavanjem novih naziva. Da bi se postigao taj cilj, izradit će se priručni kontrolni korpus računalno dostupnih i pretraživih izvora koji će biti temelj i za daljnja proučavanja jezikoslovnoga nazivlja. Također će se izraditi e-monografija o jezikoslovnome nazivlju te će se uključiti terminološki naziva izrađenoga na ovome projektu u međunarodni projekt Terminološke komisije Međunarodnoga slavističkog komiteta.” (JENA, 2020).

Tablica 8. *Natuknica regularni izraz u Jenu i Pojmovniku Mrežnika*

Jena	Pojmovnik Mrežnika
<p>regularni izraz unesen: 04.08.2019, 18:38 faza obradbe: naziv zaključan status naziva: preporučeni naziv definicija: zadani niz znakova čija se kombinacija može upotrijebiti za pronalaženje određenih dijelova teksta vrelo definicije: Pojmovnik, <i>Mrežnik</i>. http://ihjj.hr/mreznik/page/pojmovnik/6/. područje: jezikoslovlje potpodručje: e-leksikografija i korpusno jezikoslovlje jezična odrednica: višerječni naziv istovrijednica – engleski: regular expression; regex njemački: regulärer Ausdruck francuski: expression régulière ruski: регулярное выражение slika:</p> <p>poveznica: https://sketchengine.co.uk/documentation/corpus-querying/ napomena: Regularni izraz uspostavlja se za pretraživanje korpusa s pomoću alata SketchEngine i NoSketchEngine za traženje ciljanih gramatičkih ili leksičkih uzoraka.</p>	<p>regularni izraz <i>(engl. regular expression)</i> definicija: zadani niz znakova čija se kombinacija može upotrijebiti za pronalaženje određenih dijelova teksta, izraz koji se uspostavlja za pretraživanje korpusa s pomoću alata SketchEngine i NoSketchEngine za traženje ciljanih gramatičkih ili leksičkih uzoraka (popis regularnih izraza dostupan je na https://sketchengine.co.uk/documentation/corpus-querying/). Regularni izrazi iz SketchEngineova kalendara za 2018.: slika:</p>

Definicija, istoznačnica i istovrijednica na engleskome jeziku preuzete su u *Jenu* iz *Mrežnikova Pojmovnika*. U *Jeni* su dodane i istovrijednice na njemačkome, francuskome, ruskome i švedskome te je dodana normativna napomena u kojoj se objašnjava zašto se daje normativna prednost nazivu *odostražni rječnik* pred nazivom *odostražnik*.

4.1.3. Etnici i ktetici

U sklopu projekta *Mrežnik* sustavno se obrađuju i toponimi, etnici¹¹⁰ i ktetici¹¹¹ koji se zasad nalaze na portalu *Hrvatski u školi*, a pojedine se natuknice u *Mrežniku* vanjskim poveznicama povezuju s člankom s portala (npr. uz obradu pridjeva *hrvatski* dodaje se poveznica na odgovarajuću obradu na portalu *Hrvatski u školi*)¹¹². Primjer članak za *Hrvatska, Hrvat, Hrvatica, hrvatski* s portala prikazan je u slici 17:

Hrvatska, Hrvat, Hrvatica, hrvatski
Hīvātskā, G Hīvātskē, D Hīvātskōj, A Hīvātskū, L u Hīvātskōj, I Hīvātskōm
Hīvāt, GA Hrvāta, DL Hrvātu, V Hīvāte, I Hrvátom; mn. NV Hrvāti, G Hrvātā, DLI Hrvátima, A Hrváte
Hrvātica, G Hrvaticē, DL Hrvātici, A Hrvaticu, V Hrvátice, I Hrvaticōm; mn. NAV Hrvátice, G Hrvaticā, DLI Hrvaticama
hīvātskī

Slika 17. Članak *Hrvatska, Hrvat, Hrvatica, hrvatski* s portala Etnici i ktetici

Neka pitanja iz pravopisnoga kviza¹¹³ na portalu *Hrvatski u školi* odnose se na etnike i ktetike. Konceptualnim okvirom igarifikacije predviđena je izrada više igara za učenje etnika i ktetika poput kvizova, pamtilice u kojoj se sparuju nazivi naseljenih mjesta sa stanovnicima, igra upisivanja etnika i ktetika na temelju slike zemlje, slike zastave, imena naseljenoga mjesta i slično.

4.1.4. Frazemi

Pri obradi *Mrežnika* važno mjesto zauzima i obrada frazema. Frazemi se upisuju u posebno polje u rječničkom članku (npr. u natuknici *peta* u polje frazemi unesen je frazem *Ahilova peta*). U sklopu projekta *Mrežnik* izrađuje se i popis frazema s objašnjenjima, koji se također trenutačno nalazi na portalu *Hrvatski u školi*¹¹⁴ (vidi sliku 18). Tu se nalaze i mnogi frazemi koji su objašnjeni na jednostavan i učenicima blizak način (Hudeček i Mihaljević, 2019a: 100).

¹¹⁰ Etnici (grč. *ethnikós* = koji pripada narodu) imena su stanovnika naseljenih mjesta.

¹¹¹ Ktetici (grč. *ktētikós* = posvojni) posvojni su pridjevi izvedeni od imena naseljenih mjesta.

¹¹² URL: <http://hrvatski.hr/etnici-i-ktetici/> (11. 1. 2020.)

¹¹³ URL: <http://hrvatski.hr/igra/9/> (11. 1. 2020.)

¹¹⁴ URL: <http://hrvatski.hr/frazemi/> (11. 1. 2020.)

Ahilova peta

Izraz je utemeljen na grčkome mitu o neustrašivome borcu Ahileju, kojega je njegova majka Tetida, u želji da ga učini neranjivim, nakon rođenja umočila u rijeku Stiks. Pritom ga je držala za petu, koja je ostala suha. Tako je peta postala jedino ranjivo mjesto na njegovu tijelu. Kad kažemo da je što čija Ahilova peta, želimo reći da je to njegovo ranjivo mjesto ili slaba strana.

Arijadnina nit

Augijine štale

baciti bisere pred svinje

crna ovca

Iznimna je rijetkost da se rodi crna ovca koja se po boji ističe u svojem stadi. Stočari je smatraju manje vrijednom jer njezina vuna nije pogodna za bojenje. Kad za koga kažemo da je crna ovca, znači da ga smatramo osobom koja se svojim ponašanjem, stavovima ili izgledom razlikuje od svoje sredine.

Slika 18. *Primjer frazema s objašnjenjima na portalu Hrvatski u školi*

Izrađene su igre za učenje frazema¹¹⁵ u koje se dovlači slike unutar rečenica kako bi se dobilo odgovarajuće značenje (vidi sliku 19). Igre su zasad objavljene na stranici *Jezične igre i multimedijски prikaz znanja*, ali se predviđa povezivanje frazemske natuknice na te igre te objava igara na podstranici *Mrežnika*. Predviđeni su i drugi tipovi igara za učenje frazema, kao npr. igra nadopunjavanja (npr. ... je bačena., izrađena je demo inačica igre koja se temelji na *crowdsourcingu* u potpoglavlju *Igrifikacija i crowdsourcing*), kvizovi i križaljke.

Slika 19. *Igra za učenje frazema u kojoj se dovlače slike kako bi se dobili odgovarajući frazemi*

¹¹⁵ URL: <https://jezicneigre.com/frazemi/> (15. 1. 2020.)

4.2. Tehnologija rada na *Mrežniku*

4.2.1. Sketch Engine

Podatci za rječnik iz spomenutih korpusa pronalaze se s pomoću programa za rad s korpusima Sketch Engine, koji je proizveo Lexical Computing. Sketch Engine omogućuje prikaz konteksta odabrane riječi s pomoću skica riječi. Skice riječi za hrvatski jezik dobivene su na temelju gramatike skica koju je za potrebu projekta napisao Nikola Ljubešić te na čijemu su dopunjavanju radili članovi projekta *Mrežnik*. Najčešće su kolokacije razvrstane prema njihovim sintaktičkim kategorijama. Na taj se način olakšava pronalaženje dobrih primjera i kolokacija. U okviru projekta *ELEXIS*¹¹⁶ omogućen je do 2022. besplatan pristup Sketch Engineu svima koji imaju korisnički račun unutar sustava AAI@EduHr. Javno dostupne korpus hrvatskoga jezika *hrWac* i *Hrvatsku mrežnu riznicu*, koji se nalaze u programu Sketch Engine, moguće je pretraživati i programom NoSketchEngine na stranicama CLARINA¹¹⁷ (Blagus Bartolec i Ivanković, 2017: 25). NoSketchEngine besplatna je inačica programa Sketch Engine koja omogućuje pretraživanje korpusa i popis najfrekventnijih riječi, ali ne sadržava funkcionalnosti poput izrade skica riječi, n-grama te mogućnosti izrade korpusa, pa je za izradu *Mrežnika* bilo potrebno koristiti se komercijalnom inačicom programa.

4.2.1.1. Proces izrade korpusa

„Korpus je zbirka tekstova prirodnoga jezika sastavljena po određenome kriteriju, skup jezičnih odsječaka (tekstova) koji su odabrani i skupljeni prema jasnim kriterijima radi dobivanja određenoga jezičnog uzorka.” (Hudeček i dr., 2018). U suvremenome jezikoslovlju pod tim se nazivom podrazumijeva računalni skup tekstova namijenjen pretraživanju (Birtić i dr., 2012: 260). Suvremena leksikografija potiče što veću uporabu korpusa pri izradi rječnika kako bi se dobili primjeri uporabe riječi, prikazali odnosi među riječima na čestim primjerima iz jezika te otkrile nove riječi, nova značenja i nove kolokacije koji dosad nisu zabilježeni u rječnicima. Korpus se može dijeliti prema jezicima, tipu i vrsti sadržaja. Prema broju jezika razlikuju se jednojezični, dvojezični i višejezični korpusi, a dvojezični i višejezični korpusi mogu biti usporedni (paralelni) korpusi i usporedivi korpusi (Sketch Engine, 2016). Usporedni korpusi sastoje se od dvaju jednojezičnih korpusa, od kojih je jedan korpus prijevod drugoga

¹¹⁶ *ELEXIS* je projekt koji okuplja više europskih ustanova, izdavača i sveučilišta. Cilj je projekta unapređenje računalnih rječnika i rječničkih resursa. U sklopu projekta i u suradnji s mnogim ustanovama razvijaju se i objavljuju leksikografski računalni alati. Više o projektu: <https://elex.is/objectives/> (24. 1. 2020.).

¹¹⁷ URL: <https://www.clarin.si/noske/> (28. 5. 2019.)

korpusa. Tekstovi su obaju korpusa povezani, pa korisnik za rezultate pretraživanja korpusa u jednome jeziku može vidjeti te iste tekstove i na drugome jeziku. Tako korisnik može vidjeti kako su određene riječi, kolokacije i izrazi prevedeni u drugim jezicima. Višejezični korpus omogućuje pretraživanje korpusa na više od dva jezika, tj. pri pretraživanju višejezičnoga korpusa mogu se dobiti rezultati prijevoda na više od dva jezika (Ibid.). Po tipu korpus može biti općejezični, posebni, usporedivi, multimedijski, dijakronijski te korpus za učenje jezika. Usporedivi korpusi sastoje se od dvaju ili više različitih jezičnih korpusa koji su tematski povezani, ali nemaju isti sadržaj, nisu prijevodi korpusa, nego obuhvaćaju ista područja te sadržavaju zajedničke metapodatke. Korpus za učenje jezika korpus je koji se sastoji od tekstova neizvornih govornika koji uče određeni strani jezik. Taj tip korpusa upotrebljava se kako bi se analizirale česte pogreške koje neizvorni govornici rade pri učenju stranoga jezika. Dijakronijski je korpus korpus koji se sastoji od tekstova iz različitih razdoblja i njime se koristi za proučavanje razvoja i mijena u jeziku. Posebni korpusi sadržavaju tekstove koji su ograničeni na određeno sadržajno ili znanstveno područje ili disciplinu. Takvi se korpusi primjenjuju za proučavanje jezika struke i užih područja znanosti. Primjer je takvoga korpusa jezikoslovni korpus opisan u ovome radu. Multimedijski korpusi sadržavaju tekstove koji imaju kao dodatak zvučni zapis ili videozapis, npr. *British National Corpus* u Sketch Engineu sadržava snimke koje se mogu pokrenuti unutar Sketch Enginea (Ibid.). Na temelju provedene analize može se predložiti podjela korpusa prikazana u tablici 9 prema različitim gore navedenim kriterijima.

Tablica 9. *Kriteriji podjele korpusa*

kriteriji	podjela		
jezik tekstova	engleski	njemački	hrvatski itd.
broj jezika	jednojezični	dvojezični	višejezični
odnos među jezicima (odnosi se samo na dvojezične i višejezične korpuse)	usporedivi (<i>comparable</i>)		usporedni
tip korpusa	općejezični	posebni (posebni se dalje dijeli s obzirom na različite struke, stilove itd.)	
vremenski odnos	sinkronijski		dijakronijski
autori tekstova	izvorni govornici	učenici nižih razreda osnovne škole	neizvorni govornici

Za hrvatski jezik postoje ovi općejezični korpusi koji se mogu pretraživati s pomoću Sketch Enginea: *Hrvatski jezični korpus (hrWaC)*¹¹⁸ i *Hrvatska jezična riznica*¹¹⁹. Na tim se korpusima i na korpusu *Jene* (za jezikoslovno nazivlje) temelji obrada u *Mrežniku*. Skice riječi za hrvatski jezik izrađene su u okviru projekta *Mrežnik*. Osim navedenih korpusa postoji i *Hrvatski nacionalni korpus*, koji se počeo sastavljati u Zavodu za lingvistiku Filozofskoga fakulteta Sveučilišta u Zagrebu 1998. prema zamisli Marka Tadića. Korpus je sastavljen od odabranih tekstova na hrvatskome jeziku iz različitih područja, struka, žanrova i stilova. Uključuje književna i znanstvena djela, udžbenike, novine, mrežne članke i brbljaonice (engl. *chat*) (Tadić, 2000: 200). Od 2005. „*Hrvatski nacionalni korpus* sadržava više od 105 milijuna pojava i sastoji se od niza potkorpusa koji se mogu pretraživati pojedinačno i zajedno.” (Hudeček i dr., 2018). Za pretraživanje korpusa upotrebljava se program Bonito¹²⁰. Posljednja inačica korpusa koja ima 216,8 milijuna pojava ne nalazi se u programu Sketch Engine, ali se može pretraživati s pomoću programa NoSketchEngine na domeni Filozofskoga fakulteta Sveučilišta u Zagrebu¹²¹. Budući da je autor sudjelovao u procesu izrade korpusa *Jene*, a nije sudjelovao u radu na *Hrvatskome jezičnome korpusu (hrWaC-u)* i *Hrvatskoj jezičnoj riznici*, iscrpnije će se objasniti proces izrade korpusa na primjeru korpusa *Jene*, koji je pomoćni korpus za rad na *Mrežniku*.

U okviru projekta *Hrvatsko jezikoslovno nazivlje – Jena*, projekta koji je blisko povezan s projektom *Mrežnik*, izgrađuje se i specijalizirani jezikoslovni korpus. Taj je korpus jednojezični (hrvatski jezik), posebni (obuhvaća tekstove iz jezikoslovnih članaka i monografija), sinkronijski, sastavili su ga izvorni govornici hrvatskoga jezika te je samo tekstni jer ne obuhvaća multimedijske elemente. Za hrvatski jezik do pojave ovoga korpusa nije postojao specijalizirani korpus jezikoslovnoga nazivlja. Većina se korpusnih istraživanja hrvatskoga jezika provodi na dvama hrvatskim korpusima – *Hrvatskoj jezičnoj riznici* i *Hrvatskome jezičnom korpusu (hrWaC-u)*. „Ti korpusi, međutim, obuhvaćaju malo tekstova koji pripadaju znanstvenomu stilu, pa stoga nisu prikladni za terminološka istraživanja. Za hrvatski jezik ne

¹¹⁸ „*Hrvatski jezični korpus (hrWaC)* je lematiziran i na morfosintaktičkoj razini označen mrežni korpus hrvatskoga jezika koji se sastoji od tekstova prikupljenih sa stranica koje su objavljene pod .hr domenom. Trenutačna inačica korpusa sadržava 1,9 pojava.” (Natural Language Processing group, 2013).

¹¹⁹ „*Hrvatska jezična riznica* korpus je Instituta za hrvatski jezik i jezikoslovlje koji se sastoji od temeljnih djela hrvatske književnosti (romani, pripovijetke, drame, poezija, i dr.), publicističkih djela, znanstvenih djela različitih struka i sveučilišnih udžbenika, osnovnoškolskih i srednjoškolskih udžbenika, prijevodne literature vrsnih hrvatskih prevoditelja, mrežno dostupnoga dnevnog, tjednog i mjesečnog tiska te knjiga iz predstandardnoga razdoblja hrvatskoga jezika koje su prilagođene današnjemu hrvatskom jezičnom standardu.” (Institut za hrvatski jezik i jezikoslovlje, 2010).

¹²⁰ URL: <https://nlp.fi.muni.cz/projects/bonito/> (28. 1. 2019.)

¹²¹ URL: http://filip.ffzg.hr/cgi-bin/run.cgi/corp_info?corpname=HNK_v30 (28. 1. 2020.)

postoji specijalizirani korpus znanstvenoga stila ili korpus pojedine struke. Demoinačica specijaliziranoga korpusa jezikoslovnoga nazivlja izrađena je u okviru projekta *Hrvatsko jezikoslovno nazivlje – Jena*, na kojemu je autor surađivao kao izvanprojektni suradnik. Taj je korpus poslužio i za oprimjeravanje nekih jezikoslovnih naziva u *Mrežniku*. Zasad je demoinačica dostupna svim članovima projekta *Jena*, a na zahtjev i svim ostalim članovima akademske zajednice koji imaju pristup programu Sketch Engine te AAI@EduHr korisnički račun. Korpus je u siječnju 2020. imao 1882 različitih izvora (knjiga i članaka), 1032 498 pojava i 8 020 908 riječi. (Mihaljević, Mihaljević i Marković, 2020: 8).

Pri izradi računalnoga korpusa može doći do brojnih tehničkih problema. Prvo je važno odabrati tekstove koji se mogu uvrstiti u korpus. „Dovoljno reprezentativan korpus je onaj koji veličinom i kvalitetom obuhvaća mnogo mogućnosti za obradu riječi i rečenica koje su potrebne korisniku. Reprezentativnost se korpusa određuje s obzirom na veličinu i sadržaj korpusa te s obzirom na to kako se tekstovi iz korpusa dohvaćaju za izradu jezičnih uzoraka.” (McEnery i dr., 2006: 13). Kako bi jezikoslovni korpus bio reprezentativan, uključeno je više različitih izvora različitih autora. Ti izvori uglavnom sačinjavaju dostupne izvore na *Portal hrvatskih znanstvenih i stručnih časopisa – Hrčku*, kojima se može koristiti bez ograničenja (npr. *Fluminensia: časopis za filološka istraživanja*, *Suvremena lingvistika*, *Folia onomastica Croatica*, *Filologija* itd.). Ostale izvore zasad sačinjavaju monografije u izdanju Instituta za hrvatski jezik i jezikoslovlje (npr. *Hrvatska školska gramatika* (Hudeček i Mihaljević, 2017a), *Instrumental u hrvatskom jeziku* (Brač, 2018) itd.) na koje Institut ima autorska prava (Marković, Mihaljević i Mihaljević, 2020: 19).

„Članci s *Hrčka* preuzeti su jedan po jedan, pri čemu je svaki članak preimenovan tako da je naziv datoteke istovjetan nazivu članka. Datoteke u svojem nazivu osim naslova članka sadržavaju i ime časopisa te godište i broj časopisa. To je napravljeno kako bi korisnik mogao vidjeti izvor teksta u korpusu. Da bi se više članaka moglo usporedno brže preimenovati, upotrijebio se besplatni alat Advanced Renamer¹²². Za knjige su uz naslov dodana i imena autora te godina kad je knjiga izdana.” (Ibid.: 20).

„Izrada korpusa bila je otežana činjenicom da neki stariji brojevi časopisa sadržavaju članke koji su objavljeni kao skenirane slike bez prepoznatoga teksta, pa je bilo potrebno napraviti optičko prepoznavanje znakova (engl. *OCR*) s pomoću programa ABBYY FineReader¹²³, koji može precizno prepoznati utipkane znakove za hrvatski jezik ako se tekst u slici jasno vidi te je

¹²² URL: <https://www.advancedrenamer.com/> (2. 1. 2020.)

¹²³ URL: <https://bit.ly/36pNaRK> (2. 1. 2020.)

riječ o prepoznatljivome fontu (npr. Times New Roman, Arial, Calibri itd.). Budući da Sketch Engine ne može ispravno prikazati slike, tablice, bilješke, brojeve stranica, tekstove zaglavlja itd., bilo je potrebno maknuti ih iz teksta kako bi korpus imao manje pogrešaka u prikazu glavnoga teksta (npr. kod rečenice koja se nastavlja na idućoj stranici broj stranice umetne se usred rečenice jer Sketch Engine čita tekst kao jedan odlomak). Problem sa zaglavljem i brojem stranice riješio se tako da su se u dokumentu u PDF-u odredile margine za rezanje zaglavlja i podnožja u programu Sejda¹²⁴. Program je omogućio da se usporedno učita više članaka iz određenoga časopisa, od kojih svaki časopis ima određeno područje za zaglavlje i brojeve stranice te se u grafičkome sučelju moglo precizno odrediti kako će se izrezati članci. Bilješke se nisu rezale jer su drukčije ovisno o količini teksta. Nakon toga svaki se dokument iz PDF-a prebacio u *Word* (.docx) s pomoću ABBYY FineReadera, koji u procesu prebacivanja ima opciju da prepozna bilješke, tablice i slike unutar tekstne strukture.” (Ibid.)

„Kod dokumenata u Wordu slike, tablice i bilješke očišćene su s pomoću makronaredbe¹²⁵ koja se jednim pokretanjem izvršila na više dokumenata. Dokumenti u Wordu dodatno su se još očistili te prebacili u TXT dokumente s pomoću skripte za Python¹²⁶, koja je kod dokumenta nad kojim je izvršeno optičko prepoznavanje znakova ispravila nekoliko nepoznatih znakova u tekstu (npr. ❖u ü), maknula nepotrebne razmake, nepotrebne spojnice na kraju retka te obrisala popis literature na kraju teksta (početak popisa literature prepoznaje se na temelju ključnih riječi na početku odlomka: *Literatura:*, *Izvori:*, *Vrela:*, *Bibliografija:* itd.). Dodatno je u programu Notepad++ pregledan svaki TXT dokument kako se ne bi u korpus unijeli tekstovi koji nisu na hrvatskome te izbrisali određeni sažetci na stranim jezicima koji su se često nalazili na početku ili kraju teksta ili koji imaju još nekoliko uočljivih pogrešaka u tekstu.” (Ibid.).

Ovo su faze izrade jezikoslovnoga korpusa u kojoj je autor sudjelovao:

1. pronalaženje odgovarajućih izvora (znanstveni i stručni časopisi s *Hrčka: Rasprave*, *Hrvatski jezik*, *Fluminensia*, *Filologija* itd.)
2. preimenovanje izvora
3. pročišćavanje teksta
 - a. s pomoću programa ABBYY Finereader prebačene su datoteke iz PDF-a u Word (neke je PDF-ove bilo potrebno i OCR-irati)
 - b. s pomoću makronaredbe izbrisane su tablice, slike, grafikoni te nepotrebne bilješke, podnožja i zaglavlja

¹²⁴ URL: <https://www.sejda.com/> (2. 1. 2020.)

¹²⁵ URL: <https://bit.ly/39uqp1U> (2. 1. 2020.)

¹²⁶ URL: <https://bornal2.gitlab.io/igre-mreznik/kod%20za%20jenu/prevarac/word%20to%20txt.py> (2. 1. 2020.)

- #### 4.2.2. TLex (TshwaneLex)

T File Edit View Lemma Dictionary Format Tools Window Help

New entry (Ins) Delete entry Quick-search (Esc): glagoljica Entry List: glizdavo glizdavost glacio glaciati gladi glad gladan glaplo glapol glalski glagoljica glagoljni glas glasati se glasnica glasovir glasovirski glav glavni glavolja glabja glazbalo glazbeni gle gledalšte gledatelj gledateljev gledateljka gledateljčin gledateljски gledati glede glježnja glisinski glig Recent: glagoljica glograkija kofor hamburger

Lemma: glagoljica LemmaSign=glagoljica, Naglaseno=glagoljica, vrsta_rjeci=im. ž. Notes=Mivra, Modified=2018 Gramaticki_blok: Oblici: naglaseni=G glagoljici, DL glagoljici, A glagoljicu, I glagoljičom Sense: Senseslumber=1, stručna_odrednica=ling Definicija: definicija=glagoljica je najstarije slavensko pismo nastalo polovicom 9. st., koje je poslije 12. stoljetja primjer: Primjer-U Jurandvoru se održavaju radionice u kojima se može naučiti pisati uglatu glagoljicu. Primjer: Primjer-Mogu se pohvaliti da uz ćirilicu i latinicu pišem i čitam glagoljicu. Primjer: Primjer-Ploča je pisana latinicom i glagoljom te na dva jezika: latinskim i starohrvatskim. Kolokacija: Kolokacija: odrednica-Kakva je glagoljica?, kolokacija=ispisana, tiskana, uklesana; kurzivna, obla, ugla Kolokacija: odrednica-Što se s glagoljom može?, kolokacija=pisati njome, uklesati je Kolokacija: odrednica-Koordinacija, kolokacija=glagoljica i bosančica, glagoljica i ćirilica, glagoljica i latinka Tvorbena_rz: References: tvorenia glagoljn(i) vanjska_poveznica: izvor-Hrvatski u školi, poveznica=http://hrvatski.hr/hriga/7/ vanjska_poveznica: izvor-Hrvatski pravopis, poveznica=http://pravopis.hr/uploads/slova-2.pdf

Lemma_Dve: natuknica=glagoljušćilica, vrsta_rjeci=imenica Sense: Senseslumber=1 Definicija: definicija=Glajolica je najstarije slavensko pismo koje je nastalo u 9. stoljeću.

Attributes (F1) Attributes (F2) Search (F3) Format (F4) Filter (F5) Corpus (F6)

Lemma:	Incomplete
Djeca	-
Stranci	-
LemmaSign	glagoljica
Naglaseno	glagoljica
Vrsta_rjeci	im. ž.
Milica	
Frequency	0
Slike	Browse ...
Zvuk	Browse ...

Gramaticki_blok: Oblici: naglaseni G glagoljici, DL glagoljici, A glagoljicu, I glagoljičom nenaglaseni vanjska_poveznica djeca Sense: atiska_odrednica

Hrvatski TAB(C)ĆD(Ė)F(Ė)G(H)I(J)K(L)U(M) N(N)O(P)R(S)Š(T)V(U)Z(Z)

D

glagoljica **glagoljica** im. ž. (G glagoljici, DL glagoljici, A glagoljicu, I glagoljičom)
ling. Glagoljica je najstarije slavensko pismo nastalo polovicom 9. st., koje je poslije 12. stoljeća u stalnoj uporabi samo u Hrvatskoj.
 - U Jurandvoru se održavaju radionice u kojima se može naučiti pisati uglatu glagoljicu.
 - Mogu se pohvaliti da uz ćirilicu i latinicu pišem i čitam glagoljicu.
 - Ploča je pisana latinicom i glagoljom te na dva jezika: latinskim i starohrvatskim.
 Kakva je glagoljica? a) ispisana, tiskana, uklesana; kurzivna, obla, uglat
 Što se s glagoljom može? pisati njome, uklesati je
 Koordinacija: glagoljica i bosančica, glagoljica i ćirilica, glagoljica i latinka
 tvorenia **glagoljn(i)**
 Hrvatski u školi: http://hrvatski.hr/hriga/7/
 Hrvatski pravopis: http://pravopis.hr/uploads/slova-2.pdf

Article has cross-references to >>

glagoljici **glagoljčni** prid. (G glagoljčni(a); ž. glagoljčna, s. glagoljčno)
Glagoljčni je koji se odnosi na glagoljicu.
 - Najstariji glagoljčni abecedarij je nepotpuni Preslavski abecedarij (IX. st.), a na hrv. tlu Ročki glagoljčni abecedarij.
 - Dobro poznavanje općega jezikoslovlja i glagoljničina hrvatskoga srednjovjekovnog korpusa rezultiralo je znanstvenim radovima zavidne razine.
 Što je glagoljčni? abecedarij, azbukica, brevijar, bukvar, epigraf, inkunabula, misal, natpis, ostržak, slovo, suvenir, zbornik
 Koordinacija: ćirilica i glagoljčni, latinični i glagoljčni
 Tvorba: glagolj-ni.

glagoljčni **glagoljčni** prid. (G glagoljčni(a); ž. glagoljčna, s. glagoljčno)

Slika 20. Dijelovi grafičkoga sučelja u programu TLex

Tablica 10. *Objašnjenje dijelova sučelja u programu TLex*

A	Popis natuknica u rječniku. U ovome dijelu sučelja korisnici mogu odabrati natuknicu koju žele obrađivati ili obrisati. U gornjem dijelu nalazi se tražilica koja omogućuje brzi odabir natuknice te tipka koja omogućuje stvaranje novih natuknica.
B	Prikaz strukture za odabranu natuknicu. Za odabranu natuknicu iz popisa prikazuje se njezina hijerarhijska struktura. U ovome dijelu sučelja mogu se dodavati, brisati te raspoređivati elementi napravljene strukture za natuknice.
C	Dio sučelja koji služi za popunjavanje polja elemenata strukture (pisanje definicija, tvorbe, naglasaka; dodavanje slika, poveznica i audiozapisa). Također se u ovome dijelu sučelja nalaze filtri i opcije naprednoga pretraživanja koji korisniku omogućuju da pronađe i označi samo one natuknice nad kojima može izvršiti daljnju obradu ili ih zasebno izvesti u jednome od formata (RTF, HTML, XML itd.).
D	Grafički prikaz za obradu označene natuknice. Prikaz obrade izgleda jednako kad se natuknica rječnika izveze u HTML ili RTF format. Oblikovanje je prikaza moguće prilagoditi u sučelju.
E	Glavni izbornik sučelja. S pomoću ovoga izbornika spaja se na bazu u kojoj je pohranjen rječnik. Također se unutar ovoga izbornika može obrisati, spremiti ili izraditi kopija rječnika, dati i ograničiti ovlasti korisnika koji će raditi kao obrađivač na rječniku, stvoriti struktura natuknice, prilagoditi grafički prikaz elemenata strukture (dio sučelja E) te izvesti rječnik u jednome od ponuđenih formata (RTF, HTML, XML itd.)

Za svako polje strukture rječnika moguće je odrediti grafički izgled prikaza. Na obradi rječnika istodobno može raditi više obrađivača, ali je natuknica tijekom obrade na određenome korisničkom računu zaključana sve dok je korisnik ne spremi. Rječnici na mreži spremljeni su na PostgreSQL bazi podataka, koja se koristi ODBC (Open Database Connectivity) protokolom¹²⁷. Natuknice u TLexu mogu se filtrirati te je moguće pretraživati određena polja u natuknicama.

4.2.2.1. Izvoz podataka iz TLexa

Kod izvoza rječničke obrade, koji uključuje izvoz u različitim formatima poput CSV-a, XML-a, RTF-a, i HTML-a, moguće je odrediti koje se natuknice s kojim poljima žele izvesti. Nakon što obrađivač završi obradu natuknica u *Mrežniku*, označi novoobrađene natuknice te jedino njih proslijedi na uvid s izvozom u .rtf formatu koji se otvara u programima za rad s tekstem poput MS Word, OpenOffice Writera i WordPeda. Pri izradi demoinačice *Mrežnika*¹²⁸ svaka

¹²⁷ Open Database Connectivity (ODBC) protokol je koji se upotrebljava za pristup i razmjenu podataka između različitih baza i aplikacija. Protokol može neovisno izvršavati obradu i pohranu podataka između različitih vrsta računalnih sustava, sustava baza i aplikacija pisanih u različitim programskim jezicima (Techopedia, 2011c).

¹²⁸ URL: <https://bornal2.gitlab.io/mreznik/> (28. 5. 2019.)

se natuknica izvezla kao zasebna mrežna stranica (HTML datoteka). TLex također izrađuje naslovnu stranicu za abecedirani pregled svih natuknica koje imaju poveznice na svoje stranice. U TLexu je moguće cijeli rječnik izvesti kao jednu mrežnu stranicu s abecedno poredanim rječničkim člancima u kojima se prikazuju sva polja ili napraviti stranice za svako slovo abecede tako da se na zasebnoj stranici nalaze rječnički članci svih natuknica koje počinju određenim slovom. U slučaju izrade *Rječnika suvremenih hrvatskih osobnih imena*¹²⁹, rječnika koji je također izrađen u TLexu, ali koji ima manje natuknica od *Mrežnika* i koji sadržava manje polja, cijeli je rječnik izvezen kao jedna HTML stranica koja je dodatno obrađena JavaScriptom i CSS-om za poboljšani prikaz sadržaja.

Pri izvozu *Mrežnika* odlučeno je da će se svaka natuknica izvesti kao zasebna stranica radi preglednosti te mogućnosti korištenja zasebnim poveznicama među riječima. Nažalost, TLex pri izvozu sadržaja na mrežu ne omogućuje međusobno povezivanje mrežnih stranica za natuknice te ne stvara tražilicu za pronalazak natuknica. Ipak, s drugim računalnim programima moguće je automatski obraditi datoteke izvezene iz TLexa. Pri izvozu natuknica u formatu HTML u TLexu je moguće odrediti CSS klase za elemente u strukturi natuknice. Te klase osim što služe za grafičko oblikovanje određenih dijelova mrežnih stranica, mogu poslužiti za dohvaćanje i obradu podataka koji se nalaze unutar klasa. Tako su se u mrežnoj inačici *Rječnika suvremenih hrvatskih osobnih imena* mogli izraditi filtri za pretraživanje te popisi natuknica na temelju zajedničkih elemenata strukture koje natuknice sadržavaju jer se ti elementi pri izvozu na mrežu prebacuju u CSS klase koje se mogu izdvojiti. Programom rummage¹³⁰ provedena je iteracija kroz više HTML dokumenata te se automatski mogu napraviti željene izmjene na stranicama. Te izmjene uključuju stvaranje poveznica među natuknicama unutar polja za sinonime, antonime, tvorenice te suprotni spol (muško/žensko) jer je naziv dokumenta mrežnih stranica isti kao natuknica. Budući da većina poslužitelja različitih mrežnih stranica ne može učitati HTML dokumente koji u nazivu imaju nepoznate znakove (č, ć, š, ž, đ) jer se koriste ASCII kodom¹³¹, sa skriptom programskoga jezika Python automatski su zamijenjeni ti znakovi

¹²⁹ „*Rječnik suvremenih hrvatskih osobnih imena* izrađen je u Institutu za hrvatski jezik i jezikoslovlje u sklopu projekta *Baza suvremenih hrvatskih osobnih imena*, a namijenjen je najširemu krugu korisnika. Premda postoje brojne studije i knjige iz područja antroponomastike, broj onomastičkih leksikografskih djela gotovo je zanemariv te je ovo prvi hrvatski opći rječnik osobnih imena izrađen prema suvremenim zahtjevima onomastičke struke.” (Čilaš Šimpraga i dr., 2018). Obrade imena za rječnik napravljene su u programu TLex. Za knjigu je napravljen izvoz u formatu .rtf koji se može uređivati u programima za rada s tekstem. Iste su obrade izvezene za mrežnu stranicu koju je autor izradio 2019. Mrežna stranica rječnika nije još službeno objavljena. URL: https://bornal2.gitlab.io/plain-html/imena_rjecnik/ (15. 1. 2020.)

¹³⁰ URL: <https://facelessuser.github.io/Rummage/> (13. 6. 2019.)

¹³¹ ASCII (American Standard Code for Information Interchange) je način kodiranja koji predstavlja tekst u računalima, komunikacijskoj opremi i drugim napravama. ASCII za kodiranje znakova koristi se samo sa 7 bitova te najviše može prikazati 128 znakova koji se nalaze u engleskoj abecedi (Panian, 2005a: 38).

($\check{c}$ i $\acute{c} \rightarrow c$, $\check{s} \rightarrow s$, $\check{z} \rightarrow z$, $\check{d} \rightarrow dj$). Radi preglednosti na naslovnoj stranici rječnika popis natuknica prikazan je vodoravno sa svakom natuknicom u svojem okviru. Na naslovnici je također dodana tražilica kako bi korisnik mogao lakše naći tražene natuknice. Dodat će se još napredne opcije pretraživanja s kojima će korisnik moći filtrirati prikaz natuknica po tipu riječi, po području, po stilskoj vrijednosti, po tvorenica itd. Dodat će se i izbornik koji će korisnika voditi na dodatne sadržaje koji uključuju obrazovne igre nastale unutar projekta, stranicu projekta, radove povezane s *Mrežnikom* te poveznice na odostražni rječnik, etimologiju frazema te etnike i ktetike.

Demoinačica *Mrežnika* pohranjena je i objavljena na privatnom GitLab repozitoriju te je stranici bilo moguće pristupiti upisivanjem njezine URL adrese u mrežnome pregledniku koju su imali samo suradnici na projektu *Mrežnik* (vidi sliku 21). Time su se na mreži mogle testirati funkcionalnosti rječnika iako on nije bio javno objavljen. Za sva tri modula napravljene su računalne igre koje su implementirane unutar rječnika. Određene stranice natuknica imaju ugrađene igre. Također na temelju koncepta infozabave (*infotainment*) pokušalo se informacije prikazati na što zabavniji i atraktivniji način s dodanim audiozapisom izgovora riječi, videozapisima i slikama (Techopedia, 2011). Kad rječnik bude gotov, planira ga se objaviti pod dvije domene rjecnik.hr i rječnik.hr, na kojima se trenutačno nalazi mrežna inačica *Školskoga rječnika*.

Slika 21. Mrežni prikaz natuknice *breskva* u modulu za učenike nižih razreda osnovne škole u demoinačici *Mrežnika*¹³²

¹³² Dizajn će u posljednjoj inačici izgledati drukčije.

4.3. Ostale dostupne tehnologije za izradu mrežnih rječnika

Sastavljanje rječnika smatra se vremenski zahtjevnim poslom. Prelaskom na računalni rad proces se sastavljanja rječnika ubrzao jer leksikograf unutar programa može jednom odrediti strukturu obrade za natuknicu koja se prenosi za svaku obradu, što ubrzava proces unošenja natuknica. Računalna tehnologija također omogućuje lakšu pohranu i očuvanje redoslijeda obrađenih natuknica te usporedan rad više obrađivača koji je omogućen na mreži. Izrada e-rječnika također omogućuje da se rade poveznice za natuknice koje se nalaze unutar rječnika ili za vanjske izvore koji se nalaze na internetu (Abel, 2012: 2–3; Hudeček i Mihaljević, 2019b: 74). „Programi čija je svrha sastavljanje rječnika nazivaju se sustavi za pisanje rječnika (engl. *dictionary writing system*).” (Abel, 2012: 1). Lexonomy¹³³ je jedan od tih sustava tvrtke Lexical Computinga, koji služi za pisanje i izdavanje rječnika. Program je otvorenoga koda te se koristi načinom rada u oblaku¹³⁴ (engl. *cloud computing*). Prednost je Lexonomyja njegovo jednostavno i pregledno sučelje za rad te mogućnost da više obrađivača usporedno radi na natuknicama u rječniku. Budući da je riječ o mrežnoj aplikaciji, nije potrebna instalacija, nego se korisnik samo treba prijaviti svojim korisničkim računom kojim se koristi i za Sketch Engine. Rječnike je moguće pregledavati na domeni mrežnoga sustava (lexonomy.eu). Nažalost, mogućnosti objavljivanja rječnika slabije su nego u drugim programima poput TLexa. Ako korisnik želi rječnik sa stranice objaviti na vlastitoj domeni, može preuzeti XML dokument koji sadržava strukturu rječnika, pa iz XML dokumenta učitati podatke na mrežnu stranicu. Preuzeta XML datoteka s Lexonomyja može se prebaciti u JSON datoteku s pomoću mrežnoga programa Code Beutify¹³⁵, koji služi za konverziju jednoga formata u drugi. JSON je čitljiviji od XML-a te se iz njega može lakše izravno učitati podatke na mrežnu stranicu jer se podatci ne moraju parsirati na serveru kao što je to slučaj kod XML-a, nego se obrade i učitaju na mrežnome pregledniku s pomoću skriptnoga programskog jezika JavaScript.

Od besplatnih programa za izradu rječnika vrijedi spomenuti i program Lexique Pro¹³⁶, koji unatoč tomu što je posljednji put ažuriran 2012. godine i dalje nudi osnovne opcije za obradu natuknica te dodavanje slika i izgovora za riječi, s time da korisnik za svako polje obrade mora

¹³³ URL: <https://www.lexonomy.eu/> (15. 1. 2020.)

¹³⁴ „Računalstvo u oblaku ili oblačno računalstvo (engl. *cloud computing*) neki stručnjaci s područja informacijskih tehnologija određuju kao mogućnost iznajmljivanja jednoga poslužioca ili više njih te pokretanja različitih aplikacija na njima. Obični će korisnici *cloud computing* definirati kao novi i jeftiniji način uporabe programskih rješenja koja će se unajmljivati prema potrebi, a informatički će ga stručnjaci definirati kao novi poslovni model ili novi tehnološki sustav za smještaj, pokretanje i uporabu informatičke programske podrške.” (Bolje je hrvatski!, 2015).

¹³⁵ URL: <https://codebeautify.org/xmltojson> (25. 5. 2019.)

¹³⁶ URL: <http://www.lexiquepro.com/index.htm> (25. 5. 2019.)

znati njegovu kraticu te je nemoguće odrediti vlastitu strukturu za natuknice, nego se treba koristiti postojećom strukturom unutar sustava. Ipak, program omogućuje izvoz natuknica u formatu mrežne stranice (HTML), na kojoj se izradi tražilica i kazalo za pretraživanje natuknica.

Treba spomenuti i besplatni program Tummo Dictionary Maker¹³⁷, koji ima jednostavno sučelje za izradu natuknica te opciju izvoza rječnika u XML i HTML formatu. U tome programu moguće je odrediti vlastitu strukturu, ali izvoz rječnika u formatu HTML prikazuje obradu svih natuknica na jednoj stranici te ne postoji tražilica za traženje natuknica. Ne postoji ni mogućnost poveznica među natuknicama (npr. sinonim, antonim, hiponim, hiperonim itd.) te dodavanja više korisnika koji bi surađivali pri izradi rječnika. Prednosti i nedostaci svih spomenutih programa za izradu rječnika prikazani su u tablici 11.

Tablica 11. *Prednosti i nedostaci programa za izradu rječnika*

program	prednosti	nedostaci
TLex	<ul style="list-style-type: none"> ● mogućnost usporednoga rada više korisnika ● pohrana rječnika na mrežnoj bazi ● izrada vlastite strukture rječnika ● sučelje jednostavno za rad ● izvoz rječnika i dijelova rječnika u različitim formatima (RTF, HTML, XML) 	<ul style="list-style-type: none"> ● nije besplatan ● izvoz je rječnika za mrežu (HTML) statičan (stvaraju se statične stranice)
Lexonomy	<ul style="list-style-type: none"> ● mogućnost usporednoga rada više korisnika ● izrada vlastite strukture rječnika ● jednostavno sučelje za rad ● besplatan za korisnike koji imaju AAI@EduHr račun 	<ul style="list-style-type: none"> ● rječnik se može izvesti samo u formatu XML ● nemogućnost izrade poveznica među natuknicama
Lexique Pro	<ul style="list-style-type: none"> ● besplatan ● izvoz rječnika u formatu HTML koji nudi tražilicu za natuknice rječnika 	<ul style="list-style-type: none"> ● nemogućnost izrade vlastite strukture (biraju se postojeće strukture za različite jezike) ● složen način rada u sučelju (potrebno je znati kratice za svako polje obrade) ● nema mogućnosti usporednoga rada više korisnika ● nemogućnost izrade poveznica

¹³⁷ URL: <https://github.com/tummosoft/dicmaker> (25. 5. 2019.)

program	prednosti	nedostatci
		među natuknicama
Tummo Dictionary Maker	<ul style="list-style-type: none"> ● besplatan ● izvoz rječnika u formatu HTML i XML ● sučelje jednostavno za rad 	<ul style="list-style-type: none"> ● nemogućnost usporednoga rada više korisnika ● nemogućnost izrade poveznica među natuknicama ● izvoz rječnika za mrežu (HTML) statičan je (stvaraju se statične stranice)

Moguće je izraditi leksikografska mrežna djela s pomoću dodataka (engl. *plug-in*) za popularne sustave za upravljanje mrežnim stranicama¹³⁸ kao što su WordPress i Joomla, ali besplatni dodatci poput Encyclopedia/Glossary/Wiki¹³⁹ za WordPress i Dictionary¹⁴⁰ za Joomla ne omogućuju prilagodbe povezane s odredbom strukture natuknica, definiranjem vlastitih polja za unos podataka te grafičkim izgledom prikaza podatka.

¹³⁸ Sustav za upravljanje mrežnim sadržajem (engl. *CMS*) sučelje je kojim se može koristiti za izradu, objavu i ažuriranje sadržaja mrežnih stranica. Ono je što često karakterizira ovaj sustav pokretanje na mrežnome pregledniku, pohrana podataka u bazi, usporedna mogućnost rada više korisnika na mrežnim resursima stranice te mogućnost nadopuna sustava različitim programskim dodacima (Cvitković, 2017: 15).

¹³⁹ URL: <https://hr.wordpress.org/plugins/encyclopedia-lexicon-glossary-wiki-dictionary/> (25. 5. 2019.)

¹⁴⁰ URL: <https://extensions.joomla.org/extensions/extension/directory-a-documentation/glossary/dictionary/> (24. 8. 2019.)

5. ZASTUPLJENOST IGRIFIKACIJSKIH ELEMENATA U LEKSIKOGRAFSKIM IZDANJIMA I INFORMACIJSKIM USTANOVAMA

U ovome poglavlju osnovni je cilj istražiti koji se tipovi igara i igrifikacijskih elemenata nalaze na mrežnim stranicama rječnika i enciklopedija. Dodatno su proučeni sadržaji stranica infomacijskih ustanova služeći se istom metodologijom. Na stranicama leksikografskih izdanja nalaze se različiti tipovi igara poput kvizova, križaljka, zagonetka, igara pronalaska riječi itd. Moguće je izraditi i drukčije tipove obrazovnih igara za učenje riječi koje uključuju mehanike iz drugih popularnih komercijalnih igara u koje su uvršteni sadržaji iz rječnika i enciklopedija. Postoje i mrežni leksikografskih alati koji pomažu pri igranju igara u fizičkome svijetu, poput tražilice za riječi koje se smiju upotrijebiti u igri Scrabble¹⁴¹, koja se igra na fizičkoj ploči. S pomoću te tražilice igrači mogu provjeriti kojim se riječima smiju koristiti, koje riječi postoje te koja su značenja tih riječi.

Na mrežnim stranicama također se mogu nalaziti zadatci i igre u dokumentu (npr. u PDF-u) koji se može ispisati na papir i podijeliti igračima. Neki od tih zadataka zahtijevaju istodobnu uporabu rječnika i enciklopedije kako bi se igra uspješno riješila. Primjerice, na stranici rječnika *Macmillan Dictionary* postoje zagonetke¹⁴² koje su spremne za preuzimanje u PDF dokumentu. Zadatci su napravljeni tako da se korisniku na prvoj stranici dokumenta ponudi tablica sa slovima unutar koje igrači moraju pronaći određeni broj riječi koje se odnose na određenu temu (npr. blagdane, američku povijest, sportove, boje itd.). Na drugoj stranici dokumenta nalaze se definicije koje korisnici moraju povezati s riječima koje su pronašli. Definicije sadržavaju poveznice koje vode do natuknica u rječniku u slučaju da igrač ne može naći riječ te mu treba pomoć. Prve leksikografske računalne igre izrađivale su se na prijenosnoj memoriji poput disketa i CD-a. Mnoge od tih igara teško je danas pokrenuti jer su izrađene za stara računala te se pokreću s pomoću starijih programa. Jedan je od prvih igrificiranih hrvatskih rječnika *Prvi školski rječnik*¹⁴³ Instituta za hrvatski jezik i jezikoslovlje i Školske knjige iz 2008., koji je imao multimedijски CD s igrama. Igre s CD-a moguće je pokrenuti samo s pomoću Adobe Flash playera ili SWF playera. Igre su namijenjene djeci nižih razreda osnovne škole te zato

¹⁴¹ Scrabble je igra riječi u kojoj dva ili više igrača stavljaju pločice sa slovima na polja igraće ploče (raspored polja 15 × 15). Igrači dobivaju bodove za riječi koje sastavljaju s pločicama koje se čitaju kao u križaljka slijeva nadesno te odozgo prema dolje. Dulje riječi te rjeđa slova u riječi nose više bodova (Hasbro, 2014).

¹⁴² URL: <https://www.macmillandictionary.com/language-games/puzzles> (29. 1. 2020.)

¹⁴³ URL: <http://knjige.ihjj.hr/knjiga/prvi-skolski-rjecnik-hrvatskoga-jezika/201/> (29. 11. 2019.)

sadržavaju vesele crteže i animacije. Igre se također jednostavno igraju i služe za učenje slova i riječi hrvatskoga jezika. U jednoj igri padaju slova koja igrač treba utipkati prije nego što padnu na dno zaslona, u drugoj igri igračima se zadaju riječi za koje trebaju pronaći objekt ili biće koje se nalazi na zaslonu, a u trećoj se igri igračima napiše riječ, koja je također prikazana slikom, u kojoj nedostaju slova koja igrači trebaju unijeti (vidi sliku 22). Riječi za drugu i treću igru preuzete su iz *Rječnika*.

Slika 22. Igra u kojoj igrači trebaju unijeti slova kako bi dovršili riječ koja je prikazana slikom

Igre uključuju bodovanje, neke igre sadržavaju i razine te vremensko ograničenje, ali im nedostaje tablica rezultata koja bilježi prethodne rezultate igrača te rezultate ostalih igrača. Stoga djeca koja igraju igru mogu teže pratiti svoj napredak jer on nije nigdje zabilježen i ne mogu se natjecati sa svojim prijateljima. To je uvjetovano godinom nastanka tih igara jer tada tehnologija za izradu igara nije bila toliko jednostavna i nije bilo mnogo radova povezanih s igrifikacijom koji bi istaknuli važnost primjene određenih igrifikacijskih elemenata. Slično multimedijiskome sadržaju *Prvog školskoga rječnika*, postoji multimedijiski sadržaj na CD-u *Putovanje kroz znanje* iz 2009. namijenjen djeci predškolske i ranije školske dobi kao poticaj brzemu i potpunijemu razvoju njihovih perceptivnih sposobnosti i pomoć u učenju. Na CD-u

se također nalazi rječnik te igre koje su predstavljene različitim životinjskim likovima (Vučković, Družijanić Hajdarević i Ujdur, 2009).

5.1. Metodologija

Istraživanjem su obuhvaćene enciklopedije i rječnici. Za pronalaženje relevantnih e-leksikografskih izdanja upotrijebljene su dostupne akademske tražilice poput RefSeek¹⁴⁴ i iSEEK¹⁴⁵ te popis poznatih izvora koji je prikupljen na stranicama *Wikipedije*¹⁴⁶. Istraživanjem su obuhvaćeni rječnički izvori koji se nalaze na *Europskome rječničkom portalu*¹⁴⁷ (engl. *European Dictionary Portal*), koji prema utvrđenim kriterijima okuplja mrežne rječnike zajamčene kvalitete različitih europskih jezika. Na *Europskome rječničkom portalu* nalaze se i neki posebni rječnici, npr. za učenje brajice, znakovnoga jezika, etimologije, povijesti jezika, dijalekata različitih jezika itd. Razdoblje pronalaženja izvora te pregleda njihovih sadržaja trajalo je od prosinca 2018. do prosinca 2019. godine. Stranice na stranim jezicima, osim engleskoga, prevedene su s pomoću dodataka Google Translate na mrežnome pregledniku Chromeu. Na kraju su pregledane mrežne stranice 181 mrežnoga rječnika i 71 enciklopedije. Za svaku stranicu utvrđeno je koja leksikografska izdanja sadržavaju igre. Nakon toga su ta izdanja iscrpnije analizirana te je utvrđeno koje tipove igara sadržavaju te koji su igrifikacijski elementi poput bodovanja, ljestvice poretka, razina i težine u njima zastupljeni. Ovim istraživanjem nisu obuhvaćeni sustavi za poučavanje jezika poput Duolingo i Memrise unatoč tomu što se služe definicijama i pojmovima iz rječnika i enciklopedija. O tim se sustavima govori u potpoglavlju *Primjena igrifikacije u učenju jezika*. U ovome potpoglavlju analiziraju se mrežno objavljeni sadržaji koji su besplatni i javno dostupni. Zbog toga u analizu nisu uključeni rječnici, poput *Velikoga rječnika hrvatskoga standardnog jezika*¹⁴⁸, čijim se digitalnim inačicama može samo pristupiti s pomoću instalirane aplikacije koja zahtijeva od korisnika da unese lozinku koju dobiva nakon što kupi knjigu. Inače, analiza digitalne inačice *Velikoga rječnika hrvatskoga standardnog jezika* pokazuje da on ne sadržava nikakve igre ni igrifikacijske elemente. Iako je početna ideja bila analizirati igrifikacijske elementi koji se nalaze i na fizičkim medijima (CD, DVD, USB) koje korisnik dobiva ako kupi knjigu, od te se ideje odustalo jer je vremenski zahtjevno naći sva leksikografska izdanja koja sadržavaju multimedijски dodatak. U knjižnicama se često mogu dobiti samo tiskana djela bez

¹⁴⁴ URL: <https://www.refseek.com/> (29. 9. 2019.)

¹⁴⁵ URL: <http://education.iseek.com/iseek/home.page> (29. 9. 2019.)

¹⁴⁶ URL: https://en.wikipedia.org/wiki/List_of_online_encyclopedias (29. 9. 2019.)

¹⁴⁷ URL: <http://www.dictionaryportal.eu/hr/ctlg/?objLang=hr> (29. 11. 2019.)

¹⁴⁸ URL: <https://www.rjecnici.hr/> (19. 2. 2020.)

multimedijskoga dodatka jer je on izgubljen, oštećen ili zbog zastarjelosti tehnike više ne radi. Na primjeru *Prvoga školskog rječnika* može se uočiti da igre koje su snimljene na fizičkim medijima (u ovome slučaju CD-u) ne rade više na suvremenim sustavima jer su rađene za stare operacijske sustave te ih je moguće pokrenuti samo s pomoću instalacije programa koji pokreću starije programe ili s pomoću virtualnoga stroja¹⁴⁹ na sustavu koji se upotrebljavao u trenutku nastanka multimedijskoga sadržaja. Zbog sličnih problema odustalo se od cjelovitoga proučavanja mobilnih aplikacija za enciklopedije i rječnike jer ih ima mnogo te se neke aplikacije poput Dictionary Pro¹⁵⁰ i The Free Dictionary¹⁵¹ plaćaju. Neke aplikacije također ne rade na određenim operacijskim sustavima, npr. aplikacije rječnika ili enciklopedija rađene isključivo za sustav iOS ili Windows Phone ne rade na drugim operacijskim sustavima. Ipak treba istaknuti da *Hrvatski pravopis*¹⁵² Instituta za hrvatski jezik i jezikoslovlje, koji uključuje i pravopisni rječnik, ima kviz koji se nalazi samo na mobilnoj aplikaciji, a ne na mrežnoj stranici. Naravno, treba još uzeti u obzir i to da se mrežne stranice redovito ažuriraju te se na njih dodaju novi sadržaji.

5.2. Razredba leksikografskih djela

Pri analizi igrificiranih sadržaja u e-rječnicima i e-enciklopedijama uzima se u obzir vrsta rječnika ili enciklopedije. S obzirom na to jesu li usmjerene u prvome redu na riječi ili na pojmove, leksikografska se djela dijele na rječnike i leksikone/enciklopedije, koji se dalje dijele s obzirom na različite razredbene kriterije (vidi tablicu 12).

¹⁴⁹ Virtualni stroj (engl. *virtual machine*) program je ili sustav koji oponaša određene programske i strojne sastavnice drugoga računala. Često se njime koristi za testiranje određenih programa jer funkcionira kao zasebno programski stvoreno računalo koje sve pokreće u vlastitoj virtualnoj okolini te zbog toga ne može napraviti štetu fizičkome računalu koje pokreće sve aktivnosti s pomoću virtualnoga stroja. Također se njime koristi za pokretanje starih programa tako što oponaša stara računala i sustave koji su pokretali taj program (Techopedia, 2011).

¹⁵⁰ URL: https://play.google.com/store/apps/details?id=thefreedictionary.dictionary&hl=en_US (31. 1. 2020.)

¹⁵¹ URL: <https://apps.apple.com/us/app/dictionary-and-thesaurus-pro/id492085918> (31. 1. 2020.)

¹⁵² URL: <https://play.google.com/store/apps/details?id=hr.ihji.pravopis&hl=hr> (31. 1. 2020.)

Tablica 12. *Razredba leksikografskih djela*

leksikografsko djelo usmjereno na						
riječi			pojmove			
rječnik			dijeli se s obzirom na opseg			
			mali – leksikon		veći – enciklopedija	
dijeli se s obzirom na područje			dijeli se s obzirom na područje			
opći	pojedinoa područja		opći	pojedinoa područja	opći	pojedinoa područja

5.3. Analiza e-rječnika

Rječnici su knjige ili drugi objavljeni izvori koji sadržavaju ustrojeno popis leksičkih jedinica s njihovim definicijama ili prijevodom na drugi jezik (Birtić i dr., 2012: 674). Postoje različiti kriteriji podjele rječnika (vidi tablicu 13). Neki od tih kriterija podjele već su spomenuti u potpoglavlju *Podjela e-leksikografskih djela*. Unatoč tomu, u ovome potpoglavlju prikazan je i prošireni kriterij podjele koji se odnosi isključivo na rječnike (npr. s obzirom na odnos prema korpusu). S obzirom na obuhvaćeni leksik rječnici se dijele na opće i posebne (posebni rječnici obuhvaćaju terminološke, slikovne, znakovne, zvučne itd.), s obzirom na broj jezika na jednojezične, dvojezične i višejezične (dvojezični rječnici mogu se podijeliti na jednociljne ili dvociljne¹⁵³, dvojezični rječnici mogu se dijeliti i s obzirom na ciljnika korisnika na jednosmjerne i dvosmjerne¹⁵⁴), s obzirom na narav rječničkoga članka na objasnidbene i prijevodne, s obzirom na odnos prema normi na normativne¹⁵⁵ i deskriptivne¹⁵⁶, s obzirom na razdoblje koje obuhvaćaju na povijesne i suvremene, s obzirom na odnos prema korpusu na

¹⁵³ „Dvojezični rječnici dijele se i na jednociljne (engl. *monoscopal*) i dvociljne rječnike (engl. *biscopal*). Podjela se temelji na tome je li jedan jezik početni, a drugi ciljnik ili su oba jezika i početni i ciljnik.” (Bago i Majetić, 2017: 196). Jednociljni dvojezični rječnici donose natuknice na jednomo jeziku i prijevod na drugi jezik A → B. Dvociljni rječnici donose prijevode na oba jezika A ⇄ B.

¹⁵⁴ „Jednosmjerni rječnici (engl. *monodirectional dictionary*) namijenjeni su izvornim govornicima jezika A koji uče jezik B, a dvosmjerni (engl. *bidirectional dictionary*) i govornicima jezika A koji uče jezik B i govornicima jezika B koji uče jezik A.” (Bago i Majetić, 2017: 197).

¹⁵⁵ „Normativni rječnici rječnici su koji opisuju riječi koje se smatraju pravilnima u standardnome jeziku, a ostale se riječi upućuju na pravilne riječi ili se označuju odgovarajućim odrednicama.” (JENA, 2020).

¹⁵⁶ „Deskriptivni rječnici rječnici su koji opisuju riječi bez obzira na njihov normativni status u standardnome jeziku.” (JENA, 2020).

napametne, korpusno vođene (engl. *corpus driven*)¹⁵⁷, korpusno utemeljenje (engl. *corpus based*)¹⁵⁸ i korpusom oprimjerene (engl. *corpus illustrated*)¹⁵⁹, s obzirom na raspored građe na abecedne, odostražne¹⁶⁰, sustavne i čestotne¹⁶¹, s obzirom na ciljne korisnike rječnici mogu biti namijenjeni odraslim izvornim govornicima, djeci i neizvornim govornicima koji uče neki jezik, s obzirom na medij rječnici se dijele na papirnate, rječnike na CD-u, DVD-u ili bilo na kojemu drugom prijenosnom mediju, mrežne rječnike te rječničke baze podataka (Bago i Majetić, 2017: 195–201; Hudeček i dr., 2001: 92–93). Svi ti kriteriji međusobno se mogu kombinirati za rječnike (npr. opći, jednojezični, suvremeni, deskriptivni, napametni, abecedni, objasnidbeni, mrežni rječnik namijenjen neizvornim govornicima). Postoje i rječnici utemeljeni na *crowdsourcingu* poput *Wiktionaryja*¹⁶², koji omogućuju posjetiteljima stranice da unose natuknice te ih zajednički obrađuju. *Wiktionary* je višejezični rječnik (sadržava 171 jezik) koji omogućuje iscrpnu obradu natuknica (definicije, upute za izgovor, primjere uporabe, povezane izraze, slike za ilustraciju itd.) i povezivanje s obradom iste natuknice na drugome jeziku.

Tablica 13. *Različiti kriteriji podjele rječnika*

kriteriji	podjela		
po opsegu i tipu leksika	opći		posebni
po broju jezika	jednojezični	dvojezični	višejezični
s obzirom na ciljne korisnike	namijenjen odraslim izvornim govornicima	namijenjen djeci	namijenjen neizvornim govornicima
s obzirom na narav rječničkoga članka	objasnidbeni		prijevodni

¹⁵⁷ „Korpusom vođen rječnik (engl. *corpus driven dictionary*) rječnik je u kojemu se obrađivač služi isključivo korpusom, pa se u rječniku nalazi samo ono što se nalazi u korpusu.” (Hudeček i dr., 2018).

¹⁵⁸ „Korpusno utemeljen rječnik (engl. *corpus based dictionary*) rječnik je u kojemu se obrađivač služi korpusom, ali može slobodno procijeniti što treba unijeti u rječnik te rječnik može po potrebi dopunjavati i riječima iz drugih izvora te kolokacijama i značenjima koji nisu potvrđeni u korpusu.” (Hudeček i dr., 2018).

¹⁵⁹ „Korpusom oprimjeren rječnik (engl. *corpus illustrated*) rječnik je u kojemu se obrađivač isključivo služi korpusom za navođenje primjera.” (JENA, 2020).

¹⁶⁰ „Odostražni rječnik (engl. *reverse dictionary*) rječnik je u kojemu su riječi abecedirane od kraja.” (Hudeček i dr., 2018).

¹⁶¹ „Čestotni rječnik (engl. *frequency dictionary*) rječnik je u kojemu su riječi poredane po čestoti pojavljivanja u nekome jeziku.” (JENA, 2020).

¹⁶² URL: <https://www.wiktionary.org/> (13. 2. 2020.)

kriteriji	podjela			
s obzirom na normu	normativni		deskriptivni	
s obzirom na razdoblje	povijesni		suvremeni	
s obzirom na odnos prema korpusu	napametni	korpusno vođeni	korpusno utemeljeni	korpusom oprimjereni
s obzirom na raspored građe	abecedni	odostražni	sustavni	čestotni
s obzirom na medij	papirnati	na prijenosnome mediju	mrežni rječnik	rječničke baze podataka

Sustavnim su rječnicima bliski pojmovnici ili tezaursi. To su popisi riječi ustrojani prema hijerarhijskim vezama i asocijativnim odnosima unutar kojega tematskog područja. Postoje opći rječnici, specijalni rječnici, tezaursi¹⁶³, tehnički ili posebni rječnici te terminološke baze (Hudeček i dr., 2001: 93). U ovo istraživanje uključeni su poznati mrežni rječnici engleskoga jezika poput *Merriam-Webster*, *Oxford Dictionaries* i *Dictionary.com*, višejezični rječnici poput *Linguee*, *LEO* i *Multitran* te rječnici nekih drugih jezika. Također su analizirani svi dostupni hrvatski mrežni rječnici poput *Hrvatskoga jezičnog portala* i *Školskoga rječnika hrvatskoga jezika*. U analizi su obuhvaćene i rječničke baze poput *Hrvatskoga terminološkog portala* i *Strune* te pravopisnoga rječnika koji se nalazi na stranicama *Hrvatskoga pravopisa*. Pri analizi leksikografskih djela katkad je problem u tome što nisu jasni kriteriji razgraničenja, pa se često događa da riječi iz naslova djela ne odgovaraju sadržaju djela. Naime, priručnici često u naslovu imaju riječ *glosar*, *tezaurs*, *pojmovnik*, *rječnik* i *leksikon*. Stoga su u analizu uključena djela koja su izrijekom određena kao rječnik od kojih većina ima riječ *rječnik* u svojem nazivu. U analizu nisu uključeni rječnici koji su na mreži objavljeni samo kao PDF dokumenti poput *Džepnoga rječnika za građevinare*¹⁶⁴ i *Englesko-hrvatskoga pomorskog rječnika*¹⁶⁵. Također nisu uključeni mrežni pojmovnici, npr.: *Pojmovnik Hrvatskoga*

¹⁶³ „Tezaurs je zbirka riječi prirodnoga jezika (općega i/ili stručnoga) s prikazom njihovih pojmovnih odnosa.” (Hudeček i dr., 2018).

¹⁶⁴ URL: https://bib.irb.hr/datoteka/705571.DEPNI_RJENIK_ZA_GRAEVINARE_2014.pdf (28. 3. 2019.).

¹⁶⁵ URL: https://www.pfri.uniri.hr/bopri/IMEC_Proceedings/Rjecnik_Eng_Hrv_2018.pdf (28. 3. 2019.).

restauratorskog zavoda¹⁶⁶, Meteo-info¹⁶⁷, Pojmovnik – Optometrija.net¹⁶⁸, Pojmovnik poštanske terminologije i usluga¹⁶⁹ i Pojmovnik – Stručni studiji – Agencija za znanost i visoko obrazovanje¹⁷⁰ jer nijedan od njih ne sadržava igrificirane sadržaje. Neki od mrežnih rječnika koji se spominju na internetu poput Wordia¹⁷¹ u trenutku objave imali su obrazovne igre, ali se trenutačno više ne nalaze na mreži, pa se njima na može pristupiti te zbog toga nisu uvršteni u analizu.

5.3.1. Igre na stranicama e-rječnika

Početni uzorak analize sastojao se od 181 rječnika i rječničke baze za koje je provjereno sadržavaju li igrifikacijske elemente (tablica s popisom svih analiziranih rječnika nalazi se u prilogu *Rječnici za čije je mrežne sadržaje provjereno imaju li igrifikacijske elemente*). Od 181 rječnika samo 26 rječnika (14,36 %) sadržava neki igrifikacijski element (mrežnu ili izvanmrežnu (*offline*) igru). Od tih 26 rječnika dva su na hrvatskome jeziku (*Englesko-hrvatski kemijski rječnik & glosar*¹⁷² i *Arhivistički rječnik*¹⁷³).

Analiza je dalje provedena samo na tim rječnicima (vidi tablicu 14). Treba napomenuti da su neki rječnici uvršteni u ovu analizu posebni rječnici poput terminoloških i dijalektoloških koji kao ciljnu skupinu imaju istraživače, znanstvenike i studente kojima rječnik služi za pristup informacijama, a ne za učenje jezika ili zabavu (za podjelu rječnika po tipovima vidi tablicu 15).

Tablica 14. *Rječnici prema vrsti i jeziku*

rječnik s igrama	vrsta rječnika	jezici obuhvaćeni rječnikom
Collins Online Dictionary	višejezični, opći	engleski, francuski, hindi, njemački, portugalski, španjolski, talijanski
Dictionary.com	jednojezični, opći	engleski
Merriam-Webster	jednojezični, opći	engleski
Oxford Dictionaries Online	jednojezični, opći	engleski

¹⁶⁶ URL: <http://www.h-r-z.hr/index.php/pojmovnik> (28. 3. 2019.)

¹⁶⁷ URL: <http://blog.meteo-info.hr/pojmovnik/> (28. 3. 2019.)

¹⁶⁸ URL: <https://www.optometrija.net/pojmovnik/pojmovnik/> (28. 3. 2019.)

¹⁶⁹ URL: <https://www.posta.hr/pojmovnik-272/272> (28. 3. 2019.)

¹⁷⁰ URL: <https://www.azvo.hr/hr/pojmovnik> (28. 3. 2019.)

¹⁷¹ URL: <https://www.crunchbase.com/organization/wordia#section-overview> (28. 3. 2019.)

¹⁷² URL: <https://glossary.periodni.com/> (2. 2. 2020.)

¹⁷³ URL: <https://infoz.ffzg.hr/Stancic/Arhivisticki-rjecnik/> (2. 2. 2020.)

rječnik s igrama	vrsta rječnika	jezici obuhvaćeni rječnikom
Longman Dictionary of Contemporary English	višejezični, opći	engleski, japanski, korejski, španjolski
Vocabulary.com	jednojezični, opći	engleski
Macmillan English Dictionary	jednojezični, opći	engleski
Van Dale	višejezični, opći	engleski, francuski, nizozemski, portugalski, španjolski, talijanski
Your dictionary	jednojezični, opći	engleski
Englesko-hrvatski kemijski rječnik & glosar	višejezični, terminološki	engleski i hrvatski
The Free Dictionary	jednojezični, opći	engleski
Arhivistički rječnik	višejezični, terminološki	engleski i hrvatski
Merriam Webster Visual Dictionary	jednojezični, slikovni	engleski
BSL Signbank	jednojezični, znakovni	engleski
Dictionary of the dialects of Jutland	jednojezični, dijalektni rječnik	danski
Sprotn Online dictionaries	portal za pretraživanje više rječnika (uključuje jednojezični, znakovni rječnik i višejezični, opći rječnik)	danski, ferski, engleski, kineski, ruski, španjolski, talijanski
NGT Signbank	višejezični, znakovni	engleski, kineski, nizozemski
Online English Turkish and Multilingual Dictionary	portal za pretraživanje više rječnika (uključuje višejezične, opće rječnike)	engleski, turski
Diccionario Clave	jednojezični, opći	španjolski
Diccionario visual	višejezični, slikovni	engleski, francuski, španjolski
Romanian Language Dictionaries	portal za pretraživanje više rječnika (uključuje višejezične, opće rječnike)	engleski i rumunjski
Infopédia Dicionários Porto Editora	prijevodni rječnik	engleski, francuski, grčki, kineski, nizozemski, njemački, španjolski, talijanski, tetumski
Duden Online-Wörterbuch	jednojezični, opći	njemački
Dictionnaire visuel	višejezični, slikovni	engleski, španjolski
Bildwörterbuch	jednojezični, slikovni	njemački
LEO	prijevodni rječnik	engleski, kineski, njemački,

rječnik s igrama	vrsta rječnika	jezici obuhvaćeni rječnikom
		portugalski, poljski, ruski, španjolski, talijanski

Tablica 15. *Broj rječnika s igrama po tipovima podjele*

broj objasnidbenih rječnika s igrama					broj prijevodnih rječnika s igrama	
24						
opći		posebni			2	
14		slikovni	dijalektni	terminološki		znakovni
		4	1	2		3
višejezični	jednojezični	višejezični		jednojezični		
5	9	5		5		

Od 26 rječnika dva su rječnika prijevodna (*LEO* i *Infopédia Dicionários Porto Editora*¹⁷⁴), a ostali su rječnici objasnidbeni. Od objasnidbenih rječnika 14 ih je jednojezično i 10 višejezično. 14 općih rječnika i 10 posebnih rječnika sadržavaju igre. Većina posebnih rječnika slikovni su i znakovni rječnici. Jedan dijalektni rječnik *Dictionary of the dialects of Jutland* (dan. *Jysk Ordbog*)¹⁷⁵ sadržava kviz. Taj kviz sadržava dva pitanja za koja se ne daju bodovi, ali se daju objašnjenja odgovora. Većina općih rječnika poput rječnika *Merriam-Webster*¹⁷⁶ i *Macmillan English Dictionary*¹⁷⁷ ipak sadržavaju obrazovne igre te mnoge sadržaje namijenjene djeci i neizvornim govornicima te ljubiteljima jezičnih zanimljivosti. Višejezični rječnici *Longman Dictionary* i *Collins Online Dictionary* unatoč tomu što podržavaju mnogo jezika, imaju igre samo na engleskome. Od ostalih višejezičnih rječnika *Sprotn Online dictionaries* ima igre na švedskome, *Van Dale* i *NGT Signbank* na nizozemskome, *Romanian Language Dictionaries* na rumunjskome, *Online English Turkish and Multilingual Dictionary* na turskome, *Arhivistički rječnik* na hrvatskome te *Dictionnaire visuel* i *Diccionario visual* na španjolskome. *Infopédia*

¹⁷⁴ URL: <https://www.infopedia.pt/dicionarios/lingua-portuguesa> (11. 2. 2020.)

¹⁷⁵ URL: <http://www.jyskordbog.dk/jyskordbog/ordbog.html> (11. 2. 2020.)

¹⁷⁶ URL: <https://www.merriam-webster.com/word-games> (2. 2. 2020.)

¹⁷⁷ URL: <https://www.macmillandictionary.com/language-games/> (2. 2. 2020.)

Dicionários Porto Editora ima kvizove prevedene na sve jezike rječnika, a drugi prijevodni rječnik *LEO* ima kvizove za prevođenje s engleskoga na njemački i s njemačkoga na engleski. Iako *Englesko-hrvatski kemijski rječnik & glosar* sadržava natuknice i definicije samo na dvama jezicima, pamtilica za povezivanje kemijskih elemenata s njihovim nazivima može se igrati na šest jezika: hrvatskome, njemačkome, talijanskome, španjolskome, engleskome i francuskome. Ostali jednojezični rječnici imaju igre na jeziku na kojemu je rječnik napisan. *Merriam-Webster* svaki tjedan objavljuje nove kvizove. Njihovi kvizovi uglavnom služe za učenje značenja riječi te se korisniku nakon odgovora napišu zanimljivosti ili definicije povezane s riječju ili vezom riječi s drugim riječima (npr. sinonimi, antonimi, hiponimi, hiperonim itd.) (vidi sliku 23).

7 OF 12	:08 SECONDS	1820 POINTS
---------	-------------	-------------

Difficulty: 😊 😐 😞 🤖

Name that thing:

Chinese checkers

reversi

go ✓

pente

Go is one of the most complicated games in existence. Only in 2016 did an artificial intelligence program finally beat the best human player almost 20 years after the same feat was accomplished with chess.

NEXT QUESTION ▼

Slika 23. Primjer pitanja iz kviza na stranici rječnika Merriam-Webster

Četiri rječnika *LEO*¹⁷⁸, *Van Dale*¹⁷⁹, *NGT Signbank*¹⁸⁰ i *Diccionario Clave*¹⁸¹ sadržavaju obrazovne igre poput kvizova, ali im je pristup ograničen samo na registrirane korisnike koji su platili pristup. Ipak oni nude i probnu inačicu na određeno vrijeme. Za te su rječnike tipovi obrazovnih igara te igrifikacijski elementi analizirani na temelju dostupnih probnih inačica, opisa, slika i videozapisa. Analizom su utvrđeni ovi tipovi igara: kvizovi, vješala, igre povezivanja, pamtilice, križaljke, igre popunjavanja, igre upisivanja izgovorenih riječi, slagalice, izvanmrežni (*offline*) materijali za igre, daktilografske igre, osmosmjerke te jedinstvene igre koje sadržavaju vlastiti način i pravila igre, pa ih se ne može svrstati među ostale poznate tipove igara (vidi tablicu 16).

¹⁷⁸ URL: <https://dict.leo.org/trainer/index.php?lp=ende&lang=en&pos=7> (2. 2. 2020.)

¹⁷⁹ URL: <https://www.vandale.nl/taaltrainingen> (2. 2. 2020.)

¹⁸⁰ URL: <https://signbank.science.ru.nl/> (2. 2. 2020.)

¹⁸¹ URL: <http://clave.smdiccionarios.com/app.php> (2. 2. 2020.)

Tablica 16. *Igrivi materijali na stranicama rječnika*

	kviz	vješala	igre povezivanja	pamtilica	križaljka	igre popunjavanja praznina	igre upisivanja izgovore njih riječi	slagalice i zagone tke	izvanmrežni materijal i za igru	daktilografske igre	osmo smjerka	jedinstvena igra
Bildwörterbuch	ne	ne	da	ne	ne	ne	da	ne	ne	ne	da	ne
Merriam-Webster	da	ne	da	ne	da	da	da	da	ne	ne	ne	da
Oxford Dictionaries	da	ne	ne	ne	ne	ne	ne	ne	ne	ne	ne	ne
Macmillan English Dictionary	da	ne	ne	ne	ne	ne	ne	ne	da	ne	ne	ne
Vocabulary.com	da	ne	ne	ne	ne	da	da	ne	ne	ne	ne	ne
Collins Online Dictionary	ne	ne	ne	ne	ne	ne	ne	ne	da	ne	ne	ne
Dictionary.com	da	ne	ne	ne	da	ne	ne	ne	da	ne	ne	ne
Longman Dictionary of Contemporary English	da	ne	da	ne	ne	da	ne	ne	ne	ne	ne	ne
LEO	da	ne	ne	ne	ne	da	ne	ne	ne	ne	ne	ne
Your dictionary	ne	ne	ne	ne	ne	ne	ne	ne	da	ne	ne	ne
Englesko-hrvatski kemijski rječnik & glosar	ne	ne	ne	da	ne	ne	ne	ne	ne	ne	ne	ne
The Free Dictionary	da	da	da	ne	ne	ne	da	ne	ne	ne	ne	ne
Merriam-Webster Visual Dictionary	ne	ne	da	ne	ne	ne	da	ne	ne	ne	ne	ne
Van Dale	da	ne	ne	ne	ne	ne	ne	ne	ne	ne	ne	ne

	kviz	vješala	igre po- veziva- nja	pamti- lica	križaljka	igre popu- njavanja praznina	igre upisiva- nja izgovore nih riječi	slagalice i zagone- tke	izvan- mrežni materijal i za igru	daktilo- grafske igre	osmo- smjerka	jedin- stvena igra
Arhivistički rječnik	ne	ne	ne	ne	ne	ne	ne	ne	ne	da	ne	ne
BSL Signbank	da	ne	ne	ne	ne	ne	ne	ne	ne	ne	ne	ne
Dictionary of the dialects of Jutland	da	ne	ne	ne	ne	ne	ne	ne	ne	ne	ne	ne
Sprotn Online dictionaries	da	ne	ne	ne	ne	ne	ne	ne	ne	ne	ne	ne
NGT Signbank	da	ne	ne	ne	ne	ne	ne	da	ne	ne	ne	ne
Online English Turkish and Multilingual Dictionary	da	da	ne	da	da	ne	ne	ne	ne	ne	da	ne
Diccionario Clave	ne	ne	da	ne	ne	ne	ne	ne	ne	ne	ne	ne
Diccionario visual	ne	ne	da	ne	ne	ne	ne	ne	ne	ne	ne	ne
Romanian Language Dictionaries	da	da	ne	ne	ne	ne	ne	da	ne	ne	ne	ne
Infopédia Dicionários Porto Editora	da	ne	ne	ne	ne	ne	ne	ne	ne	ne	ne	ne
Duden Online-Wörterbuch	da	ne	ne	ne	ne	ne	ne	ne	ne	ne	ne	ne
Dictionnaire visuel	ne	ne	da	ne	ne	ne	ne	ne	ne	ne	ne	ne

Tablica 17. *Broj e-rječnika koji sadržavaju igre*

kviz	igra povezivanja	igra pisanja riječi na temelju audiozapisa	igre popunjavanja	izvan- mrežni materijali za igru	slagalice i zagonetke	križaljka	pamtilica	osmosmjerka	vješala	daktilografska igra	jedinstvena igra
17	8	5	4	4	3	3	2	2	2	1	1

Iz rezultata (vidi tablicu 17) možemo vidjeti da je kviz najzastupljeniji tip obrazovne igre koji se nalazi na stranicama rječnika (65 %). Uglavnom svi kvizovi sadržavaju pitanja uz ponuđene odgovore te igrači dobivaju bodove za točno riješene zadatke. Kvizovi na stranicama *Dictionary.com*¹⁸² imaju bazu koja bilježi koliko je ljudi odabralo koji odgovor te za svako pitanje igračima nakon njihova odgovora pokazuje koliki je postotak za odabrane odgovore drugih igrača.

Zanimljivo je napomenuti da tri rječnika, *BSL Signbank*¹⁸³, *NGT Signbank*¹⁸⁴ i *Sprotin Online dictionaries*¹⁸⁵, imaju kvizove za učenje znakovnoga jezika na temelju slika. *BSL Signbank* u svojem kvizu stvara nasumično riječ koju prikazuje kao niz slika za koje korisnik može odabrati brzinu izmjene slova znakovnoga jezika koje igrač treba prepoznati te upisati riječi u polje (vidi sliku 24).

Slika 24. Kviz za učenje riječi na temelju niza slika koje prikazuju pokrete ruku znakovnoga jezika

Drugi su po zastupljenosti tip igre igre dovlačenja ili povezivanja pojmova (31 %), a nakon toga toga igre u kojima igrač mora točno napisati izgovorenu riječ (19 %). Igre dovlačenja uglavnom

¹⁸² URL: <https://www.dictionary.com/e/c/fun/quizzes/> (7. 2. 2020.)

¹⁸³ URL: <https://bslsignbank.ucl.ac.uk/spell/practice.html> (7. 2. 2020.)

¹⁸⁴ URL: <https://signbank.science.ru.nl/> (7. 2. 2020.)

¹⁸⁵ URL: <https://fo.signwiki.org/index.php/B%C3%B3lkur:B%C3%B8rn> (7. 2. 2020.)

su prisutne u slikovnim rječnicima *Diccionario visual*, *Merriam-Webster Visual Dictionary*, *Dictionnaire visuel* i *Bildwörterbuch*, koji svi imaju isti tip igre s dovlačenjem riječi na polja u slici. *Bildwörterbuch* ima čak odvojenu stranicu *Igra tjedna* (ger. *Das Spiel der Woche*)¹⁸⁶, na kojoj se tjedno bira jedna slika s predmetom ili bićem na kojoj su označeni dijelovi za koje korisnici trebaju dovući riječi.

Najviše različitih i jedinstvenih tipova igara ima stranica rječnika *Merriam-Webster*. Ona sadržava kvizove koji se objavljuju svaki tjedan te križaljke¹⁸⁷, zagonetke¹⁸⁸, osmosmjerke¹⁸⁹, pasijans (soliter) s riječima¹⁹⁰ te različite druge jedinstvene igre. Tjedni kvizovi omogućuju mrežno natjecanje te je moguće uključiti ili isključiti vremensko ograničenje tijekom igranja igre. *Dictionary.com* i *Merriam-Webster* nude dnevne križaljke¹⁹¹ u kojima se u prazna polja dopunjava definicija ili pišu nazivi za riječi na temelju definicija. Kod tih križaljka postoji tipka na zaslonu koja omogućuje njihov ispis. Među obrazovnim materijalima za izvanmrežnu (offline) igru *Collins Online Dictionary* i *Your dictionary* nude tražilicu i pomagala za igru Scrabble¹⁹², a *Macmillan English Dictionary* sadržava osmosmjerke¹⁹³ koje se mogu ispisati na papir. Igre za pisanje izgovorenih riječi na stranicama *Vocabulary.com*¹⁹⁴ i *The Free Dictionary*¹⁹⁵ namijenjene su učenju pravopisa te razumijevanju riječi. U igri *The Free Dictionary* moguće je odabrati težinu riječi koja se mora napisati nakon izgovora.

Treba napomenuti da je *Arhivistički rječnik* jedini mrežni rječnik za koji je pronađena poveznica na daktilografski tip igre¹⁹⁶ na mreži, u kojemu igrač treba što brže utipkati padajuće nazive na engleskome jeziku kako bi dobio njihove prijevode na hrvatskome. Na višim razinama duže riječi brže padaju. Cilj je te igre naučiti igrače hrvatskim istovrijednicama engleskih naziva.

Englesko-hrvatski kemijski rječnik & glosar jedan je od dvaju rječnika (drugi je *Online English Turkish and Multilingual Dictionary*¹⁹⁷) na kojemu se nalazi pamtilica¹⁹⁸ u kojoj se povezuju karte naziva s njihovim slikama. Može se povezivati kratice za kemijske elemente s njihovim

¹⁸⁶ URL: http://www.bildwoerterbuch.com/static/all/spiele_zuordnen (7. 2. 2020.)

¹⁸⁷ URL: <https://www.merriam-webster.com/word-games/universal-daily-crossword> (10. 2. 2020.)

¹⁸⁸ URL: <https://www.merriam-webster.com/word-games/bee-cubed> (10. 2. 2020.)

¹⁸⁹ URL: <https://www.merriam-webster.com/word-games/word-roundup> (10. 2. 2020.)

¹⁹⁰ URL: <https://www.merriam-webster.com/word-games/jumble-solitaire> (10. 2. 2020.)

¹⁹¹ URL: <https://www.dictionary.com/e/crossword/> (7. 2. 2020.)

¹⁹² URL: <https://wordfinder.yourdictionary.com/> (7. 2. 2020.)

¹⁹³ URL: <https://www.macmillandictionary.com/us/language-games/puzzles> (7. 2. 2020.)

¹⁹⁴ URL: <https://www.vocabulary.com/lists/ev72l5vt/grab-bag-for-word-nerds> (7. 2. 2020.)

¹⁹⁵ URL: <https://www.thefreedictionary.com/> (7. 2. 2020.)

¹⁹⁶ URL: <https://www.had-info.hr/tipkalica/> (7. 2. 2020.)

¹⁹⁷ URL: <https://www.seslisozluk.net/en/> (21. 2. 2020.)

¹⁹⁸ URL: https://www.periodni.com/hr/pronadi_parove.html (7. 2. 2020.)

nazivima, kemijske elemente s drugim elementima, laboratorijska oprema s kemijskim elementima itd. Moguće je odabrati broj stupaca i redaka te jezik naziva elemenata. Igra bilježi vrijeme i broj poteza igrača (vidi sliku 25).

Slika 25. Pamtilica za učenje naziva i kratica kemijskih elemenata koja se nalazi na stranici Englesko-hrvatski kemijski rječnik & glosar

5.3.2. Analiza igrifikacijskih elementa igara e-rječnika

Za igre koje se nalaze na stranicama rječnika dodatno su analizirani igrifikacijski elementi (vidi tablicu 18). Igrifikacijski elementi nabrojeni su i analizirani u potpoglavlju *Igrifikacijski elementi*. Zbog povezanosti i sličnih značajka određenih elemenata odlučeno je da se ti elementi svrstaju u skupine. Primjerice, značke se često ubrajaju u sustav nagrađivanja, priča je često usmjerena na izvršavanje zadataka (engl. *quests*), avatari se povezuju s društvenim elementima jer igrači komuniciraju s pomoću njih te se stablo igračevih vještina (engl. *skill tree*) i napredak

igrača (engl. *progress bar/progression*) prikazuje unutar avatara. Stoga se igrifikacijski elementi koji su prisutni u igrama proučavaju s obzirom na bodovanje, razine ili težine, vremensko ograničenje, značke ili drugi sustav nagrađivanja, priče sa zadatcima, ljestvice poretka te avatar igrača.

Tablica 18. *Igrifikacijski elementi u rječnicima*

	bodovanje	razine / težine	vremensko ograničenje	značke ili drugi sustav nagrađivanja	avatar	ljestvice poretka	priča sa zadatcima
Bildwörterbuch	ne	ne	ne	ne	ne	ne	ne
Merriam-Webster	da	da	da	ne	ne	da	ne
Oxford Dictionaries	da	da	ne	ne	ne	ne	ne
Macmillan English Dictionary	da	ne	da	ne	ne	ne	ne
Vocabulary.com	da	da	da	da	da	da	ne
Collins Online Dictionary	ne	ne	ne	ne	ne	ne	ne
Dictionary.com	da	ne	ne	ne	ne	ne	ne
Longman Dictionary of Contemporary English	da	da	ne	ne	ne	ne	ne
LEO	da	da	ne	da	da	ne	ne
Your dictionary	ne	ne	ne	ne	ne	ne	ne
Englesko-hrvatski kemijski rječnik & glosar	ne	da	ne	ne	ne	ne	ne
The Free Dictionary	da	da	da	da	da	da	ne
Merriam Webster Visual Dictionary	ne	ne	ne	ne	ne	ne	ne
Van Dale	da	ne	ne	ne	ne	ne	ne
Arhivistički rječnik	da	da	da	ne	ne	ne	ne
BSL Signbank	ne	ne	ne	ne	ne	ne	ne
Dictionary of the dialects of Jutland	ne	ne	ne	ne	ne	ne	ne
Sprotin Online dictionaries	da	ne	ne	ne	ne	ne	ne
NGT Signbank	da	ne	ne	ne	ne	ne	ne

	bodovanje	razine / težine	vremensko ograničenje	značke ili drugi sustav nagrađivanja	avatar	ljestvice poretka	priča sa zadatcima
Online English Turkish and Multilingual Dictionary	da	ne	da	ne	ne	da	ne
Diccionario Clave	da	ne	ne	ne	ne	ne	ne
Diccionario visual	ne	ne	ne	ne	ne	ne	ne
Romanian Language Dictionaries	da	da	da	da	da	ne	ne
Infopédia Dicionários Porto Editora	ne	da	da	ne	ne	ne	ne
Duden Online-Wörterbuch	da	ne	ne	ne	ne	ne	ne
Dictionnaire visuel	ne	ne	ne	ne	ne	ne	ne

Tablica 19. Broj rječnika koji sadržavaju određene igrifikacijske elemente

bodovanje	razine/težine	vremensko ograničenje	značke ili drugi sustav nagrađivanja	avatar	ljestvice poretka	priča sa zadatcima
16	10	8	4	4	4	0

Po rezultatima (vidi tablicu 19) možemo vidjeti da je bodovanje najprisutniji igrifikacijski element (16 rječnika sadržava bodovanje u igrama). Nakon toga slijedi mogućnost odabira razina u igri koje se temelje na sadržaju igre ili na težini igre. Rječnici poput *Vocabulary.com* i *The Free Dictionary* izgrađeni su kao obrazovni sustavi te registrirani korisnici imaju avatare koji mogu bilježiti sve aktivnosti unutar rječnika. S pomoću avatara igrači mogu sudjelovati u više različitih aktivnosti poput natjecanja u obrazovnoj igri. Njihovo sudjelovanje u igri virtualno se nagrađuje te se bilježi napredak korisnika kroz različite sadržaje. Da bi korisnici sudjelovali u natjecateljskim igrama, stvaraju korisnički račun kojim se koriste kao avatarom za stranice rječnika. Taj avatar bilježi rezultate igrača u igrama te se iz tih rezultata stvaraju ljestvice poretka. Ti rječnici također dodjeljuju korisnicima značke za igranje igara te ne mogu nagrađivati i ostale aktivnosti unutar rječnika poput pretraživanja sadržaja rječnika na temelju različitih kategorija. Značke su povezane s avatarom korisnika te korisnici pri pregledu stanja svojega avatara mogu vidjeti skupljene značke te pokušati dobiti nove tako da ispunjavaju

izazove koji su povezani s igranjem obrazovne igre ili pronalaženjem određene informacije u rječniku (vidi sliku 26).

Slika 26. Prikaz sustava nagrađivanja na stranicama Vocabulary.com, koji se zasniva na značkama koje se spremaju na avatar korisnika

Collins Online Dictionary jedini je rječnik koji ne sadržava elektroničke igre, nego igre koje se ispisuju na papir, pa se stoga u njemu ne proučavaju igrifikacijski elementi. *Englesko-hrvatski kemijski rječnik & glosar* ne sadržava bodovanje, nego samo obavještava igrača je li točno odgovorio na pitanje. Slikovni rječnici sadržavaju igre dovlačenja (*Dictionnaire visuel*, *Diccionario visual*, *Merriam Webster Visual Dictionary* i *Bildwörterbuch*) koje nemaju bodovanje ni koji drugi osnovni igrifikacijski elementi. Ipak, i dalje se mogu smatrati igrama jer imaju određena pravila te su zabavne. U većini igara sadržaji igara podijeljeni su u odvojene razine, npr. u rječniku *Longman Dictionary of Contemporary English* postoje igre za svako poglavlje rječnika povezano s vokabularom, gramatikom i izgovorom¹⁹⁹, s time da se uglavnom razine ne zaključavaju kao u klasičnim igrama, nego korisnik sam proizvoljno bira razinu (vidi sliku 27). Katkad se može postaviti težina zadataka kao u određenim igrama u rječnicima *Merriam-Webster*. U tim se rječnicima pri većoj težini ubaci novi igrifikacijski element – vremensko ograničenje za rješavanje zadatka.

¹⁹⁹ URL: <https://www.ldoceonline.com/exercise/> (29. 4. 2019.)

Slika 27. Prikaz podjele igre na razine po sadržaju unutar rječnika Longman Dictionary of Contemporary English

Rječnici *Romanian Language Dictionaries* sadržavaju kviz koji postavlja pitanja prema težini koju korisnik odabere²⁰⁰. Ljestvice poretka imaju samo četiri rječnika od kojih su *Vocabulary.com* i *The Free Dictionary* već spomenuti te za njih korisnik mora izraditi avatar, a druga dva rječnika, *Merriam-Webster* i *Online English Turkish and Multilingual Dictionary*, ne zahtijevaju od korisnika registraciju kako bi se mrežno natjecali. Korisnik može ostati anonimn s pomoću korisničkoga imena u tablici koja se prikazuje na samome kraju igre. Nijedna igra ne sadržava priču u kojoj bi igrači izvršavali određene zadatke (engl. *quest*), postoje rječnici koji zadaju zadatke poput *Vocabulary.com*, ali ti zadatci nisu povezani s pričom, nego prolaženjem igre, s pomoću kojega se uči rječnički sadržaj.

5.4. Analiza e-enciklopedija

Enciklopedija je djelo koje abecednim redoslijedom ili kakvim drugim slijedom daje pregled osnovnih znanja iz različitih područja (Birtić i dr., 2012: 124). Enciklopedije se po opsegu obuhvaćenoga sadržaja dijele se na opće i posebne enciklopedije, ali se mogu kao i rječnici dijeliti i s obzirom na ciljne korisnike (odrasle i učenike), medij (papirni, prijenosni, mrežna enciklopedija itd.) i veličinu (većega i manjega opsega) (Hudeček i dr., 2001: 93). Različiti kriteriji podjele enciklopedija prikazani su u tablici 20. Ti kriteriji mogu se međusobno kombinirati kad se odnose na određenu enciklopediju (npr. enciklopedija koja je većega opsega, jednojezična, opća, namijenjena djeci te objavljena na mreži).

²⁰⁰ URL: <https://dexonline.ro/moara> (29. 4. 2019.)

Tablica 20. *Različiti kriteriji podjele enciklopedija*

kriterij	podjela			
po veličini	većega opsega – enciklopedije	manjega opsega – leksikoni		
po broju jezika	jednojezične	dvojezične	višejezične	
po opsegu obuhvaćenoga sadržaja	opće	posebne (npr. tehnička enciklopedija)		
s obzirom na ciljne korisnike	odrasli	djeca (dječja enciklopedija)		
s obzirom na medij	papirnat	prijenosni medij	mrežna enciklopedija	baza enciklopedijskih podataka

Kao i kod rječnika u posljednje su vrijeme popularne enciklopedije koje se temelje na *crowdsourcingu* poput onih izrađenih na *wiki*-sustavima²⁰¹, u kojima sadržaj stvaraju i održavaju volonteri. Ipak, za razliku od rječnika koji se temelje na *crowdsourcingu*, neke enciklopedije koje se temelje na *crowdsourcingu* poput *Wikipedije* sadržavaju i igre. Te se enciklopedije također mogu podijeliti na temelju kriterija iz gornje tablice. U ovome su potpoglavlju analizirane opće i posebne enciklopedije koje se mogu pronaći s pomoću spomenutih akademskih tražilica RefSeek i iSEEK, npr. *Encyclopedia Britannica*²⁰², *Encyclopedia Mythica*²⁰³, *Medline Medical Encyclopedia*²⁰⁴, *Scholarpedia*²⁰⁵. Analiza obuhvaća i enciklopedije koje se spominju u popisu enciklopedija na stranicama *Wikipedije* poput *encyclopedia.com*²⁰⁶, *Encyclopædia Universalis*²⁰⁷ i *The Canadian Encyclopedia*²⁰⁸. Pojmovnici (npr. *Vrijeme i klima hrvatskog Jadrana – pojmovnik*²⁰⁹, *Pojmovnik – Medijska*

²⁰¹ *Wiki*-sustav (engl. *wiki software*) suradnički program koji omogućuje korisnicima stvaranje i uređivanje *wiki*-sadržaja s pomoću mrežnih preglednika (Gurteen, 2012: 91).

²⁰² URL: <https://www.britannica.com/> (13. 2. 2020.)

²⁰³ URL: <https://pantheon.org/> (13. 2. 2020.)

²⁰⁴ URL: <https://medlineplus.gov/encyclopedia.html> (13. 2. 2020.)

²⁰⁵ URL: http://www.scholarpedia.org/article/Main_Page (13. 2. 2020.)

²⁰⁶ URL: <https://www.encyclopedia.com/> (13. 2. 2020.)

²⁰⁷ URL: <https://www.universalis.fr/> (13. 2. 2020.)

²⁰⁸ URL: <https://www.thecanadianencyclopedia.ca/en/article/encyclopedia> (13. 2. 2020.)

²⁰⁹ URL: <http://jadrان.gfz.hr/pojmovnik.html> (29. 4. 2019.)

*pismenost*²¹⁰, *A-Z: Animals glossary*²¹¹) nisu uvršteni u analizu. Tako se određen uzorak za analizu sastoji od 71 enciklopedije.

5.4.1. Igre na stranicama e-enciklopedija

Početni se uzorak za analizu sastojao od 71 enciklopedije za koje je provjereno sadržavaju li igrifikacijske elemente (tablica s popisom analiziranih enciklopedija nalazi se u prilogu *Enciklopedije za čije je mrežne sadržaje provjereno imaju li igrifikacijske elemente*). Od 71 pregledane enciklopedije samo njih 10 sadržava igrifikacijske elemente (14,1 %) (popis svih enciklopedija nalazi se u prilogu 2). Nijedna od tih enciklopedija nije na hrvatskome jeziku (vidi tablicu 21).

Enciklopedije nisu usmjerene isključivo na jezik, pa bi mogle omogućiti izradu još više različitih igara za usvajanje sadržaja. Zanimljivo je da rezultat analize korpusa rječnika i enciklopedija daje isti postotak (14 %) leksikografskih djela koja sadržavaju igrifikacijske elemente. Međutim, na stranicama enciklopedija ima manje igara nego na stranicama rječnika. Neke enciklopedije nemaju svoju zasebnu stranicu, nego su integrirane u stranice drugih institucija poput *Talijanske enciklopedije znanosti, književnosti i umjetnosti*²¹², koja se nalazi na stranici instituta *Treccani*, ili su poput enciklopedije *Baidu* integrirane na obavještajne portale poput *Baike.com*²¹³, pa je katkad bilo teško procijeniti koji su sadržaji leksikografski. Također neke enciklopedije poput *Winkler Prins*²¹⁴ zahtijevaju registraciju prije mogućnosti korištenja njome te sadržavaju interaktivne sadržaje poput karata, animacija i videozapisa, ali ti sadržaji nisu igre i ne sadržavaju igrifikacijske elemente.

Tablica 21. *Enciklopedije po tipovima podjele i jezicima*

enciklopedija s igrama	vrsta enciklopedije	jezici obuhvaćeni enciklopedijom
Britannica	jednojezična, opća	engleski
Columbia Encyclopedia (prikazna kroz FactMonster)	jednojezična, opća	engleski
Encyclopedia Smithsonian	jednojezična, posebna (povijesnoumjetnička)	engleski

²¹⁰ URL: <https://www.medijskapismenost.hr/pojmovnik/> (29. 4. 2019.)

²¹¹ URL: <https://a-z-animals.com/reference/glossary/#jump-animal> (29. 4. 2019.)

²¹² URL: <http://www.treccani.it/enciclopedia/> (14. 2. 2020.)

²¹³ URL: <http://www.baike.com/> (14. 2. 2020.)

²¹⁴ URL: <http://www.winklerprins.com/> (14. 2. 2020.)

enciklopedija s igrama	vrsta enciklopedije	jezici obuhvaćeni enciklopedijom
Medline Medical Encyclopedia	jednojezična, posebna (medicinska)	engleski
Wikipedia	višejezična, opća (crowdsourc)	postoje sadržaji napisani na 264 jezika ²¹⁵
Baidu Baike	jednojezična, opća (crowdsourc)	kineski
Krugosvet	jednojezična, opća	ruski
Nationalencyklopedin	jednojezična, opća	švedski
World Book Encyclopedia	jednojezična, opća	engleski
Encyclopédie Larousse en ligne	jednojezična, opća	francuski

Tablica 22. Broj enciklopedija po opsegu obuhvaćenoga sadržaja i broju jezika

broj općih enciklopedija	broj posebnih enciklopedija	
8	2	
	povijesnoumjetnička	medicinska
	1	1
broj jednojezičnih enciklopedija	broj višejezičnih enciklopedija	
9	1	

Od tih deset enciklopedija osam su opće enciklopedije, a *Encyclopedia Smithsonian*²¹⁶ i *Medline Medical Encyclopedia* posebne su enciklopedije (vidi tablice 21 i 22). Od općih enciklopedija jedino se *Wikipedija* i *Baidu Baike*²¹⁷ koriste *crowdsourcingom* za izradu sadržaja. Poveznice na igre koje se nalaze na *Medline Medical Encyclopedia* vanjske su poveznice na igre povezane s medicinskim nazivljem koje se nalaze na drugim stranicama. Igre za učenike izrađene na temelju enciklopedije *Columbia Encyclopedia* ne nalaze se na stranici rječnika, nego na stranici portala *FactMonster*²¹⁸. *Wikipedia* je jedina višejezična enciklopedija

²¹⁵ URL: https://en.wikipedia.org/wiki/Wikipedia:Multilingual_statistics (21. 2. 2020.)

²¹⁶ URL: <https://www.si.edu/explore> (15. 2. 2020.)

²¹⁷ URL: <https://baike.baidu.com/> (15. 2. 2020.)

²¹⁸ URL: <https://www.factmonster.com/> (14. 2. 2020.)

koja sadržava igre, ali većina tih igara izrađeno je za stranice napisane na engleskome. Igra *Wikirace*²¹⁹ sadržava i mogućnost igranja na člancima napisanim na španjolskome, esperantu, francuskome, talijanskome, nizozemskome, poljskome, portugalskome i švedskome. Ostale su igre na jeziku na kojemu je enciklopedija napisana.

Analizom je utvrđeno koje tipove igara enciklopedije sadržavaju. Pri analizi igrifikacijskih elementa enciklopedija primijenjeni su isti kriteriji kao i za rječnike. Identificirani tipovi igara uglavnom su isti kao u rječnicima: kvizovi, vješala, igra povezivanja, križaljka, igra popunjavanja praznina, slagalice te izvanmrežni materijali za igru. (vidi tablicu 23) Jedino nema daktilografske igre, igre u kojoj korisnik upisuje riječ koju je čuo i osmosmjerke, pa se ti tipovi igara ne spominju u ovoj analizi. S druge strane, za razliku od rječnika, enciklopedije katkad imaju jedinstvene obrazovne igre koje se ne nalaze u rječnicima. Te jedinstvene igre imaju vlastiti način, pravila i radnju igre.

²¹⁹ URL: <http://2pages.net/wikirace.php> (5. 2. 2019.)

Tablica 23. Igrivi materijali na stranicama e-enciklopedija

	kviz	vješala	igra povezivanja	pamtilica	križaljka	igre popunjavanja praznine	slagalice i zagonetke	izvanmrežni materijali za igru	jedinstvene igre
Britannica	da	ne	ne	ne	ne	ne	ne	ne	ne
Columbia Encyclopedia	da	da	ne	ne	ne	ne	ne	ne	ne
Encyclopedia Smithsonian	da	ne	da	ne	ne	ne	da	ne	da
Medline Medical Encyclopedia	da	ne	da	da	da	da	da	da	da
Wikipedia	ne	ne	ne	ne	ne	ne	ne	ne	da
Baidu Baike	ne	ne	ne	ne	ne	ne	ne	ne	ne
Krugosvet	da	ne	ne	ne	ne	ne	ne	ne	ne
Nationalencyklopedin	da	ne	ne	ne	ne	ne	ne	ne	ne
Encyclopédie Larousse en ligne	da	ne	ne	ne	ne	ne	ne	ne	ne
World Book Encyclopedia	da	ne	da	ne	da	ne	da	ne	ne

Tablica 24. Tipovi igara koji se nalaze u e-enciklopedijama

kviz	jedinstvena igra	igra povezivanja	slagalice i zagonetke	križaljka	igra popunjavanja praznina	izvanmrežni materijali za igru	pamtilica	vješala
8	3	3	3	2	1	1	1	1

Kao i kod rječnika kvizovi su najprisutniji tip obrazovnih igara (vidi tablicu 24). Posebno se *Encyclopedia Britannica* ističe svojim kvizovima²²⁰ jer sadržava različite kvizove iz različitih kategorija, koji se temelje na sadržaju (vidi sliku 28), u kojima se registrirani korisnici mogu međusobno natjecati te s pomoću tipke na stranici izravno dijeliti obrazovne sadržaje na društvenim mrežama.

Slika 28. Izbor kvizova na temelju različitih sadržaja

Igre popunjavanja praznina, pamtilica, vješala i obrazovni materijali za izvanmrežne igre nalaze se samo u jednoj od spomenutih enciklopedija. Poveznice za obrazovnu igru pamtilice, igru popunjavanja i obrazovne materijale za izvanmrežne igre nalaze se na stranici *Medline Medical Encyclopedia*. Obrazovni materijali za izvanmrežne igre sadržavaju igre koje treba ispisati i u kojima se povlačenjem crta povezuje slike kukaca s nazivom kukaca²²¹. Na odvojenoj stranici napisani su odgovori s rješenjima. Drugi su izvanmrežni obrazovni materijali koji se mogu naći križaljka²²² i pamtilica²²³, koji se mogu ispisati i rješavati na papiru.

Igra za popunjavanje praznina nije izvanmrežna i služi za učenje brajice²²⁴. Igra vješala²²⁵ koja se temelji na sadržaju *Columbia Encyclopedia* nalazi se na stranicama *Fact Monster*. *Medline Medical*

²²⁰ URL: <https://www.britannica.com/quiz/browse> (15. 2. 2020.)

²²¹ URL: <https://www.aaaai.org/conditions-and-treatments/just-for-kids/stinging-insect-matching-game> (15. 2. 2020.)

²²² URL: <http://www.sleepforkids.org/html/clues.html> (15. 2. 2020.)

²²³ URL: <http://www.sleepforkids.org/html/cards.html> (15. 2. 2020.)

²²⁴ URL: <http://braillebug.org/Games.asp> (15. 2. 2020.)

²²⁵ URL: <https://www.factmonster.com/games/hangman> (15. 2. 2020.)

Encyclopedia također sadržava vanjsku poveznicu za igru *The Food detectives*²²⁶, koja se sastoji od više manjih igara poput pamtilice ili kvizova koji uče korisnike o higijeni i zdravoj prehrani (vidi sliku 29). Pamtilica iz igre *Food detectives* funkcionira tako da se spajanjem sličice dobiva informacija, šala ili savjet koji se odnosi na predmet sa slike. Kad se spoje, parovi se miču sa scene igre te se u pozadini otkriva slika koja sadržava određenu poruku.

Slika 29. Pamtilica iz igre *Food detectives*

Ono što je svojstveno enciklopedijama, a što rječnici nemaju, jedinstvene su obrazovne igre koje imaju vlastita pravila i način igranja zbog kojih se ne mogu svrstati u ostale spomenute tipove igara. Različite igre ima *Encyclopedia Smithsonian*, od kojih su neke poput *Morphy!*²²⁷ i *Pilot Pals*²²⁸ rađene isključivo za mobilne uređaje. Ta enciklopedija sadržava stratešku igru *Aquation: The Freshwater Access Game*²²⁹, u kojoj igrač mora među više različitih zemalja ravnomjerno izgraditi vodovodne cijevi kako bi svaka zemlja imala dovoljno vode u kućanstvu (vidi sliku 30). Igrač pritom mora paziti na novac kojim se koristi za izgradnju cijevi, destilacijskih tvornica i istraživanja

²²⁶ URL: <https://www.fooddetectives.com/> (15. 2. 2020.)

²²⁷ URL: <https://apps.apple.com/us/app/morphy/id1033580915?ls=1> (15. 2. 2020.)

²²⁸ URL: <https://apps.apple.com/us/app/pilot-pals/id920173926?ls=1> (15. 2. 2020.)

²²⁹ URL: <https://ssec.si.edu/aquation> (15. 2. 2020.)

koja se odnose na uporabu vode te mora paziti na količinu vode koja se daje određenoj zemlji. Tom se igrom igrač upoznaje s važnošću raspodjele vode u svijetu te s potrebom upravljanja materijalnim resursima kako bi se ostvarili ciljevi potrebni za zadovoljavajući ljudski život. Igra je rađena za mrežu koristeći se programom Unity²³⁰, koji se često upotrebljava u profesionalne svrhe za izradu komercijalnih ili *indie*-igara, i 3D modeliranjem te time igra grafički izgleda mnogo bolje od ostalih spomenutih igara.

Slika 30. Prikaz situacije u igri Aquation: The Freshwater Access Game u kojoj je ulaganje u istraživanje u Rusiji dovelo do otkrića nove metode za pročišćavanje kišnice

Na stranicama *Encyclopedia Smithsonian* nalaze se i *flash*-igre *BumperDucks*²³¹, *Disaster Detector*²³², *Shutterbugs: Wiggle and Stomp*²³³ i *Habitats*²³⁴. Sve su te igre vrlo napredne s lijepom grafikom i animacijama, pričom, glazbom i glasovnom glumom za likove u igri. Nažalost, budući da su rađene u *flash*-tehnologiji, teže se pokreću jer je potrebno dodatno instalirati dodatak za pokretanje u pregledniku. Podrška za *flash*-tehnologija za mrežne preglednike ukinut će se krajem 2020. (Warren, 2017), što može dovesti do problema da novije inačice mrežnih preglednika, poput nove inačice Firefox, automatski ne pokreću *flash* osim ako se ne naprave izmjene u naprednim

²³⁰ URL: <https://unity.com/> (15. 2. 2020.)

²³¹ URL: <https://ssec.si.edu/bumperducks> (15. 2. 2020.)

²³² URL: <https://ssec.si.edu/disaster-detector> (15. 2. 2020.)

²³³ URL: <https://ssec.si.edu/shutterbugs-wiggle-and-stomp> (15. 2. 2020.)

²³⁴ URL: <https://ssec.si.edu/habitats> (15. 2. 2020.)

postavkama mrežnoga preglednika. *Shutterbugs: Wiggle and Stomp* kviz je u kojemu igrač treba prepoznati određene kretnje karakteristične za različite životinje.

Habitats je igra povezivanja u kojoj igrač za određeni pejzaž treba odrediti koje životinje mogu živjeti u njemu. *BumperDucks* igra je u kojoj igrači određenom snagom pod određenim kutom mišem mora gurnuti patku na jezeru kako bi došla do hrane te se pritom patka mora odbijati od određenih predmeta i površina te izbjegavati prepreke u jezeru poput kornjača i žaba. Igra pripada skupini obrazovnih igara iz fizike te ilustrira igračima što se događa kad se dva objekta različite mase sudare pri određenoj brzini. Igra *Disaster Detector* uči igrače kako da analiziraju i interpretiraju podatke povezane s prirodnim katastrofama kako bi mogli spriječiti sve buduće opasnosti poput poplava, uragana, vulkana itd.

U ovoj je analizi *Wikipedia* uz *Baidu Baike* jedina enciklopedija nastala *crowdsourcingom* koja sadržava igrfikijske elemente. Zanimljivo je da su sve igre na *Wikipediji* povezane s korištenjem *Wikipedijom*. Igre mogu igrati samo registrirani korisnici. Igra *The Wikipedia Adventure*²³⁵ kroz nekoliko razina uči igrače kako da oblikuju svoje korisničke profile, uređuju sadržaje na *Wikipediji*, stavljaju citate za izvore koje objavljuju na mreži, provjere i procijene valjanosti izmjena sadržaja članaka koje su napravili drugi korisnici (vidi slika 31). U igri se prvo izrađuje avatar te se s virtualnim vodičem prolazi kroz sadržaj koji treba naučiti pa se na kraju korisniku postavljaju pitanja na koja on odabire odgovor. Za razine koje je prošao igrač osvaja značku te slično kao u RPG igrama postoji stablo igračevih vještina koje prikazuje igračev napredak u uređivanju članaka, razumijevanju prava korištenja te komunikaciji s drugim korisnicima.

²³⁵ URL: https://en.wikipedia.org/wiki/Wikipedia:The_Wikipedia_Adventure (16. 2. 2020.)

Slika 31. Prikaz razina te značka i razvoja vještina koje igrač stječe igrajući igru The Wikipedia Adventure

Igra *The Wiki game*²³⁶ zadaje korisnicima nasumično odabran početni članak te od njih traži da u određenome vremenu od toga članka kroz mrežne poveznice dođu do određenoga završnog članka. Onemogućena je uporaba tražilice na stranici *Wikipedia* kako igrač ne bi mogao izravno pronaći članak. U igru je uključeno vremensko ograničenje te ljestvica poretka za najbolje igrače svake posebne igre i najbolje igrače općenito koji igraju igru više puta. Na kraju igre igračima su prikazana i rješenja kako trebaju pronaći određene članke (npr. *History of video games* → *World War II* → *Infection* → *Pathogenic bacteria* → *Salmonella* → *Paratyphoid fever* → *Typhoid fever*). Igru je također moguće preuzeti kao mobilnu aplikaciju²³⁷.

S pomoću *Wikipedije* mogu se igrati i igre *Wikington Crescent*, *Wiki Ladders* i *Wikirace*, koje funkcioniraju slično kao *The Wiki game*. Cilj je da korisnik od jednoga članka dođe što brže do

²³⁶ URL: <https://www.thewikigame.com/> (30. 4. 2019.)

²³⁷ URL: <https://apps.apple.com/us/app/the-wiki-game-a-wikipedia-game-of-exploration/id459318432> (16. 2. 2020.)

drugoga pritiskom na što manje poveznica²³⁸. Te je igre u potpunosti zamijenila igra *The Wiki game* jer omogućuje računalno praćenje natjecanja s bodovanjem i spomenutim tablicama rezultata. Za pristup mrežnoj stranici enciklopedije *World Book Encyclopedia* potrebno je imati lozinku koja se dobiva kupnjom fizičke knjige, ali je iz videozapisa koji demonstrira stranicu²³⁹ vidljivo da se u dječjoj enciklopediji nalaze zagonetke, kvizovi i slagalice. Igre su također podijeljene po kategorijama: životinje, vrijeme, vozila itd.

5.4.2. Analiza igrifikacijskih elementa igara e-enciklopedija

Kao i kod rječnika dodatno se analiziralo igrifikacijske elemente koji se nalaze u enciklopedijskim igrama. Elementi su koji su se uzimali u obzir pri analizi isti kao i kod rječnika: bodovanje, razine ili težine, vremensko ograničenje, značke ili drugi sustav nagrađivanja, avatar, ljestvice poretka te avatar igrača (vidi tablicu 25 i 26).

Tablica 25. *Igrifikacijski elementi u enciklopedijama*

	bodovanje	razine/ težine	vremensko ograničenje	značke ili drugi sustav nagrađivanja	avatar	ljestvice poretka	priča sa zadacima
Britannica	da	ne	da	ne	ne	da	ne
Columbia Encyclopedia (prikazna kroz FactMonster)	da	da	da	ne	ne	ne	ne
Encyclopedia Smithsonian	da	da	da	ne	ne	ne	da
Medline Medical Encyclopedia	da	da	da	ne	ne	ne	da
Wikipedia	da	da	da	da	da	da	ne
Baidu Baike	da	ne	ne	da	da	da	ne
Krugosvet	da	ne	ne	ne	ne	ne	ne
Nationalencyklopedin	da	ne	ne	ne	ne	ne	ne
Encyclopédie Larousse en ligne	da	ne	ne	ne	ne	ne	ne
World Book Encyclopedia	da	da	ne	ne	ne	ne	ne

²³⁸ URL: https://en.wikipedia.org/wiki/Wikipedia:Wikipedia_games (30. 4. 2019.)

²³⁹ URL: <https://www.youtube.com/watch?v=LhA4TLmQjQU> (17. 2. 2020.)

Tablica 26. Prikaz elemenata igrifikacije prisutnih u enciklopedijama

bodovanje	razine/ težine	vremensko ograničenje	ljestvice poretka	avatar	značke ili drugi sustavi nagrađivanja	priča sa zadacima
10	5	5	3	2	2	2

Sve spomenute enciklopedije barem u jednoj od svojih igara imaju element bodovanja. Točno pola enciklopedija s igrama imaju igre podijeljene na razine s obzirom na sadržajne cjeline koje se uče. *Fact Monster* stranica za neke igre poput igre pogađanja rimskih brojeva²⁴⁰ ima i mogućnost izbora težine zadataka.

Kvizovi na stranicama *Britannice* te neki kvizovi na stranicama enciklopedije *Medline Medical Encyclopedia* imaju vremensko ograničenje za odgovaranje na pitanja. Jednostavni matematički zadatci²⁴¹ na stranici *Fact Monster* također imaju vremensko ograničenje za rješavanje zadataka. Igra *Disaster Detector* traži od igrača da paze na vrijeme jer se u određenim razmacima odvijaju različite vremenske nepogode. *The Wiki game* daje korisnicima određeno vrijeme da pronađu članak. *Wikipedia* i *Baidu Baike* jedine unutar svojega sustava imaju značke kojima nagrađuju korisnike za aktivnosti poput uređivanja članaka te rješavanja i odgovaranja na pitanja povezana s točnim značenjem i činjenicama. Usto sadržavaju ljestvice poretka za najbolje korisnike koji su pridonijeli uređivanju sadržaja. *Wikipedia* to ima integrirano unutar igre. U njoj postoje članci oblikovani radi uvježbavanja uređivača *Wikipedije*. Enciklopedia *Baidu Baike* ne sadržava igre, ali se koristi elementima igrifikacije unutar svojega sustava u kojemu se korisnika s pomoću avatara boduje te mu se daju značke za njegove aktivnosti povezane s odgovorima na pitanja koja se postavljaju na stranici iz određenih područja, znanje korisnika boduje se i rangira u tablici unutar područja na koja odgovaraju. Također postoje tjedni zadatci koje korisnici mogu izvršavati kako bi osvojili više bodova (vidi sliku 32).

²⁴⁰ URL: <https://www.factmonster.com/math/roman> (17. 2. 2020.)

²⁴¹ <https://www.factmonster.com/math/flashcards> (21. 2. 2020.)

Slika 32. Prikaz avatara u ljestvici poretka u enciklopediji Baidu Baike

Pojedine igre na stranici *Encyclopedia Smithsonian* poput *Disaster Detector*, *BumperDucks* te *Food detectives* na stranici *Medline Medical Encyclopedia* sadržavaju jednostavnu priču s likovima koja igračima daje kontekst zašto rješavaju određene zadatke. Primjerice u igri *BumperDucks* igrači igraju s gumenom patkom Dustyjem, koja je gladna, te je na svakoj razini trebaju dovesti do hrane. U igri *Food detectives* igrač preuzima ulogu detektiva koji kroz različite manje igre (koje se zovu slučajevima) rješava zadatke koji su povezani s higijenom, zdravom prehranom i borbom protiv bakterija, koje su u priči prikazane kao glavni negativci.

5.5. Zaključak analize o zastupljenosti igrifikacijskih elemenata u leksikografskim djelima

Rezultati analize pokazuju da više od 86 % mrežnih leksikografskih stranica nema nikakve igrifikacijske elemente. Samo 26 rječnika i 10 enciklopedija sadržava neki oblik igrificiranoga sadržaja.

Tablica 27. Zastupljenost tipova igara na stranicama rječnika i enciklopedija

tip igre	zastupljenost
kviz	25
igre povezivanja	11
slagalice i zagonetke	6
križaljka	5

tip igre	zastupljenost
igre popunjavanja	5
igre upisivanja izgovorenih riječi	5
izvanmrežni materijali za igru	5
jedinstvena igra	4
pamtilica	3
vješala	3
osmosmjerka	2
daktilografske igre	1

Najčešći je tip igre i u rječnicima i u enciklopedijama kviz s ponuđenim odgovorima (25 kvizova nalazi se u leksikografskim izdanjima) (vidi tablicu 27). Razlog je tomu vjerojatno to što je izrada kvizova konceptualno i tehnički jednostavna. Lako se igraju te najbolje mogu provjeriti znanje korisnika te pomoći korisniku u učenju kad mu daju povratnu informaciju za odgovor na svako pitanje. Kvizovi također mogu lako implementirati igrifikacijske elemente poput bodovanja, vremenskoga ograničenja i ljestvice poretka. Može se napraviti više manjih kvizova koji imaju različite razine ili sadržajne cjeline. Kvizovima se mogu ispitati različiti sadržaji od pravopisa, gramatike, sintakse i rječnika do činjenica iz različitih znanstvenih disciplina i područja. Kvizove je lakše dizajnirati i programirati nego ostale tipove igara jer se jedino očekuje da korisnik unese odgovor koji će algoritam procijeniti točnim ili pogrešnim na temelju unaprijed zadanih parametara. Također postoje različita gotova rješenja i predlošci za izradu kvizova na mrežnim servisima poput Quizleta²⁴², Kahoot!-a²⁴³, H5P-a²⁴⁴ itd. Ipak, na temelju ove analize važno je napomenuti da je bitno da kviz izravno daje povratnu informaciju s objašnjenjem rješenja nakon svakoga odgovora kako bi obrazovni materijali bili učinkovitiji. Igre povezivanja uglavnom su namijenjene djeci te se nalaze u slikovnim rječnicima i u dječjim enciklopedijama poput *Habitats*, u kojima se dovlače sličice na određena polja (npr. životinje na zemljopisno područje na kojemu žive). Prednošću se ostalih rjeđih tipova obrazovnih igara poput pamtilica (tri se pamtilice nalaze u leksikografskim izdanjima), daktilografskih igara (jedna se daktilografska igra nalazi u leksikografskim izdanjima), slagalica i zagonetka (šest

²⁴² URL: <https://quizlet.com/> (19. 2. 2020.)

²⁴³ URL: <https://kahoot.com/> (19. 2. 2020.)

²⁴⁴ URL: <https://h5p.org/> (19. 2. 2020.)

slagalica i zagonetka nalazi se u leksikografskim izdanjima) može smatrati što imaju složeniji način igranja koji se ne zasniva isključivo na zadavanju pitanja i odabiru ponuđenoga odgovora. Križaljke i zagonetke mogu razvijati kognitivne funkcije jer igrač mora razmišljati tijekom rješavanja problema. Provedena istraživanja također dokazuju da se s pomoću zagonetka i križaljka može povećati motivacija i zanimanje za određenu temu (Franklin i dr., 2003; Crossman i Crossman, 1983). U rječnicima nema jedinstvenih igara koje imaju vlastita pravila, ali se takve igre nalaze u dvjema enciklopedijama. Problem je s takvim igrama što ih je tehnički i konceptualno teže razviti jer se ne razvijaju iz postojećih predložka i ideja, pa autori igara moraju biti inovativni te samostalno programirati i dizajnirati igru. Također u igre osim kviza lakše se mogu uvrstiti ostali igrifikacijski elementi poput avatara, priča sa zadacima te sustava nagrađivanja.

Tablica 28. *Broj mrežnih rječnika i enciklopedija s obzirom na zastupljenost određenoga igrifikacijskog elementa*

bodovanje	razine / težine	vremensko ograničenje	ljestvice poretka	avatar	značke ili drugi sustavi nagrađivanja	priča sa zadacima
26	15	13	7	6	6	2

Najčešći su primijenjeni igrifikacijski elementi bodovanje (nalazi se u igrama 26 leksikografskih stranica) te podjela sadržaja na razine (nalazi se u igrama 15 leksikografskih stranica) (vidi tablicu 28). Bodovanje je vjerojatno najprimjereniji igrifikacijski element jer se može lako primijeniti na svaku igru te je izrazito povezano s ostalim igrifikacijskim elementima kao što su ljestvice poretka igrača i sustavi nagrađivanja. Također je lako podijeliti dijelove igre na različite razine na temelju težine ili sadržaja. Vremensko ograničenje često se upotrebljava kod pitanja u kvizovima. Sustav nagrađivanja, avatar, priča sa zadacima i ljestvice poretka nisu uvršteni u e-leksikografska izdanja, a u različitim istraživanjima i radovima često se ti igrifikacijski elementi spominju kao elementi uspješne igrifikacije sadržaja jer mogu pobuditi zanimanje i podići motivaciju korisnika (Dominguez i dr., 2013; Rangaswami, 2015; Qian i dr., 2016). Mogući je razlog slabije primjene tih igrifikacijskih elemenata u odnosu na bodovanje i podjele na razine to da ih je iz tehničkih razloga teže uvrstiti u igre jer je za avatar, ljestvice poretka i sustav nagrađivanja poželjno imati bazu podataka koja mora biti povezana s igrama. Baze podataka na internetu kojima igra može uvijek pristupiti uglavnom se plaćaju mrežnim poslužiteljima. Avatar i sustavi nagrađivanja uglavnom se nalaze na istim leksikografskim stranicama (npr. vocabulary.com, Baidu Baike) jer su usko povezani (značke se često spremaju na avatare korisnika). Priče nisu prisutne u analiziranim rječnicima te su prisutne samo u

enciklopedijama i to najčešće kod jedinstvenih tipova igara. Igre kao što su križaljke, igre povezivanja, kvizovi itd., koje imaju jednostavna pravila, najčešće ne zahtijevaju priču kako bi se igrale jer je cilj i način igranja igre jasan. Kod jedinstvenih igara poput igre *Disaster Detector*, koja sadržava priču u kojoj se prate zemljopisne promjene i štiti grad od prirodnih katastrofa, potrebno je igraču dati razlog zašto čini određene aktivnosti, pa se to uglavnom radi s pomoću izmišljene radnje koja ima izmišljene likove.

5.6. Igrifikacijski elementi na mrežnim stranicama informacijskih ustanova

Analizom su obuhvaćene i mrežne stranice informacijskih ustanova. Te ustanove uključuju arhive, muzeje i knjižnice. Analizirano je 179 mrežnih stranica muzeja, 254 mrežne stranice knjižnica te 21 mrežna stranica arhiva. Kao i kod stranica rječnika i enciklopedija, stranice koje nisu bile napisane na hrvatskome i engleskome prevedene su s pomoću dodatka Google Translate za Chrome. Analizirani su tipovi obrazovnih igara te igrifikacijski elementi prisutni u igrama.

5.6.1. Igrifikacija sadržaja muzeja

Muzeji su zahvaljujući virtualnim izložbama²⁴⁵ te bogatim kulturnim i povijesnim sadržajima koji se u njima nalaze idealne ustanove za igrifikaciju sadržaja. Za muzeje se mogu izraditi različiti tipovi obrazovnih igara, koji ne obuhvaćaju samo najčešće igre kao što su pamtilice, slagalice, kvizovi i igre povezivanja. Također, stranice muzeja često sadržavaju druge multimedijske tipove obrazovnih sadržaja poput virtualnih šetnja²⁴⁶, vremenskih lenta²⁴⁷, 3D modela, interaktivnih karata itd. U ovome se potpoglavlju istražuju sadržaji mrežnih stranica poznatih muzeja, galerija te drugih izložbenih prostora u Hrvatskoj i svijetu. Prema podacima *Museums of the World* postoji 55 000 muzeja u 202 zemlje (Ruth i dr., 2011). Zbog iznimno velikoga broja muzeja morao se odabrati manji uzorak za analizu mogućih igrifikacijskih elemenata. Stoga su analizirane mrežne stranice hrvatskih muzejskih ustanova i najposjećenijih muzeja izvan Hrvatske. U svibnju 2018. provedeno je istraživanje 160 hrvatskih muzejskih

²⁴⁵ Virtualni muzej ili izložba logički je uređena medijska zbirka digitalnih predmeta koja zbog međusobnoga spajanja medija s pomoću različitih točaka pristupa nadrađa tradicionalne načine komunikacije i interakcije s posjetiteljima (Schweibenz, 1998: 191).

²⁴⁶ Virtualna šetnja (engl. *virtual tour*) simulacija je određenoga fizičkog prostora koja se prikazuje s pomoću više povezanih slika. Unutar tih slika mogu biti označeni određeni dijelovi koji, kad se pritisnu, vode do drugoga virtualnog prostora ili prikazuju informacije o pritisnutome predmetu. Virtualne šetnje također mogu uključiti druge medije kao što su video, zvuk itd. (Techopedia, 2015).

²⁴⁷ Vremenska lenta (engl. *timeline*) grafički prikaz određenih povijesnih događaja koji su kronološki poredani (Collins English Dictionary, 2020).

ustanova, a u prosincu 2019 istraživanje 62 poznata strana muzeja (cijela analiza nalazi se u prilogu 3 i 4). Za hrvatske muzeje u trenutku istraživanja dodatno su pregledani i ostali tipovi interaktivnih sadržaja osim igara. Popis hrvatskih ustanova preuzet je sa stranica Ministarstva kulture Republike Hrvatske²⁴⁸, a popis najposjećenijih stranih muzeja sa stranice *Wikipedije*, a izrađen je na temelju izvještaja svakoga muzeja o posjetu u 2018. godini²⁴⁹.

Od 160 hrvatskih ustanova 43 ih u trenutku u kojemu je provedena analiza nije imalo službenu mrežnu stranicu jer su to uglavnom manje galerije, zavičajne zbirke ili gradski nacionalni muzeji. Time je u hrvatskome uzorku za proučavanje ostalo 117 mrežnih stranica, od čega ih 105 (89,7 %) ima vlastite interaktivne sadržaje (popis svih hrvatskih muzeja s njihovim interaktivnim sadržajima nalazi se u prilogu *Hrvatski muzeji s interaktivnim sadržajima*). Ti interaktivni sadržaji uključuju interaktivne galerije²⁵⁰ slika, ugrađene videozapise i audiozapise na stranici, virtualne šetnje kroz prostor ustanove, 3D modele za pregled predmeta, vremenske lente i obrazovne igre (vidi tablicu 29).

Tablica 29. Zastupljenost interaktivnih sadržaja na stranicama hrvatskih muzeja

tip interaktivnoga sadržaja	zastupljenost
virtualna galerija	95
ugrađeni video i zvučni zapis	31
virtualna šetnja prostorom	14
interaktivna karta	7
vremenska lenta	6
obrazovna igra	6
3D model	2

Od 117 stranica 105 ima interaktivne sadržaje, od čega većina (95) ima virtualne galerije, 31 muzej na stranicama osim teksta i slika ima videozapise ili audiozapise, 14 muzeja ima virtualnu šetnju, 7 ima interaktivne karte, 2 muzeja imaju 3D model, 6 muzeja ima vremenske lente te 6 ima obrazovne igre. Većina obrazovnih igara na stranicama muzeja nalazi se na poveznicama povezanim s obrazovnim ili pedagoškim dijelom sadržaja.

²⁴⁸ Očevidnik muzeja te muzeja, galerija i zbirka unutar ustanova i drugih pravnih osoba. URL: <http://www.min-kulture.hr/default.aspx?id=212> (6. 5. 2018.)

²⁴⁹ URL: https://en.wikipedia.org/wiki/List_of_most_visited_museums#cite_note-1 (23. 12. 2019.)

²⁵⁰ Interaktivne su galerije galerije koje omogućuju korisnicima da s pomoću mrežnoga preglednika mogu iscrpno pregledati i listati slike koje su grupirane na temelju određenoga kriterija (Nielsen, 2012).

Na stranicama muzeja igre su razvrstane na isti način kao i igre na stranicama rječnika i enciklopedija te su analizirani isti igrifikacijski elementi (vidi tablicu 30).

Tablica 30. Tipovi igara i igrifikacijskih elemenata na stranicama hrvatskih muzeja

muzej	tipovi igara	igrifikacijski elementi
Etnografski muzej	<ul style="list-style-type: none"> ● pamtilica ● kviz 	<ul style="list-style-type: none"> ● bodovanje ● razine ili težine
Gradski muzej Karlovac	<ul style="list-style-type: none"> ● slagalica ● igra u kojoj se spajaju točke u sliku (PDF) 	<ul style="list-style-type: none"> ● razine ili težine
Hrvatski muzej Turizma	<ul style="list-style-type: none"> ● kviz 	<ul style="list-style-type: none"> ● bodovanje
Hrvatski prirodoslovni muzej	<ul style="list-style-type: none"> ● kviz ● pamtilica ● slagalica 	<ul style="list-style-type: none"> ● bodovanje
Prirodoslovni muzej Rijeka	<ul style="list-style-type: none"> ● igra povezivanja 	<ul style="list-style-type: none"> ● bodovanje ● vremensko ograničenje
Muzej Mimara	<ul style="list-style-type: none"> ● kviz ● pamtilica ● igra povezivanja ● slagalica 	<ul style="list-style-type: none"> ● bodovanje ● razine ili težine

Grafikon 2. Broj hrvatskih muzeja s određenim tipom igre

Grafikon 3. Broj hrvatskih muzeja s obzirom na zastupljenost određenoga igrifikacijskog elementa

Pet muzeja ima na svojim stranicama kviz, četiri muzeja imaju slagalice, tri muzeja imaju pamtilice, jedan muzej ima igru povezivanja (vidi grafikon 2). Muzej grada Karlovca osim mrežne slagalice ima PDF dokumente koji sadržavaju igre povezivanja točkica u sliku²⁵¹ koje se trebaju ispisati na papiru kako bi se moglo igrati olovkom. Nažalost, Prirodoslovni muzej Rijeka²⁵² koristi se zastarjelom *flash*-tehnologijom za pokretanje igara. Dobre primjere obrazovnih igara možemo vidjeti na virtualnoj izložbi *Istraživanja braće Seljan Etnografskoga muzeja*²⁵³ i obrazovnome kutku Muzeja Mimara²⁵⁴, u kojima ima mnogo obrazovnih igara različitoga tipa koje su prilagođene i mobilnim uređajima te imaju dinamičan sadržaj koji se pojavljuje tijekom igre poput animacija, slika koje se mogu detaljno pregledati povećalom, informativnoga teksta i zvuka. Od elemenata igrifikacije većina igara koristi se bodovanjem (nalazi se u igrama pet muzeja) (vidi grafikon 3). Etnografski muzej, Gradski muzej Karlovac i Muzej Mimara u pamtilicama i slagalicama imaju mogućnost prilagodbe težine na temelju broja sličica za spajanje. Kvizovi sa stranica Prirodoslovnoga muzeja Rijeka imaju vremensko ograničenje, ali nijedna igra nema tablicu rezultata.

²⁵¹ URL: <http://www.gmk.hr/Aktivnosti/Pedago%a1ka%20djelatnost/Igre> (3. 6. 2020.)

²⁵² URL: <https://www.prirodoslovni.com/hr/homepage.html> (3. 6. 2020.)

²⁵³ URL: <http://bracaseljan.emz.hr/Memory.aspx#> (4. 12. 2019.)

²⁵⁴ URL: <http://www.mimara.hr/edukativniKutak/> (4. 12. 2019.)

Od 62 najposjećenija strana muzeja jedino muzeji Tate Modern²⁵⁵ i American Museum of Natural History²⁵⁶ sadržavaju igre kao interaktivne sadržaje (popis analiziranih mrežnih stranica najposjećenijih stranih muzeja nalazi se u prilogu *Najpopularniji strani muzeji za čije je mrežne sadržaje provjereno imaju li igrifikacijske elemente*). Dodatno se s pomoću Googleove tražilice koristeći se riječju *museum games* pokušalo pronaći još primjera muzeja koji sadržavaju obrazovne igre te su pronađeni primjeri igara na stranicama Science Museum UK²⁵⁷ i National Museums Scotland²⁵⁸ te igra *Great Fire of London*²⁵⁹, na kojoj je radio Museum of London. Muzeji koji sadrže igre i igrifikacijske elemente prikazani su u tablici 31.

Tablica 31. Tipovi igara i igrifikacijskih elemenata svjetskih muzeja

muzej	tipovi igara	igrifikacijski elementi
Tate Modern	<ul style="list-style-type: none"> kviz 	<ul style="list-style-type: none"> bodovanje
American Museum of Natural History	<ul style="list-style-type: none"> kvizovi jedinstvene igre (<i>board</i> igre, igre istraživanja) igre povezivanja zagonetke 	<ul style="list-style-type: none"> bodovanje priča sa zadacima
Science Museum UK	<ul style="list-style-type: none"> jedinstvene igre (<i>board</i> igre, igre istraživanja, avanture) zagonetke 	<ul style="list-style-type: none"> bodovanje razine ili težine priča sa zadacima avatar
National Museums Scotland	<ul style="list-style-type: none"> kviz igre povezivanja zagonetke 	<ul style="list-style-type: none"> bodovanje priča sa zadacima razine
Museum of London	<ul style="list-style-type: none"> jedinstvene igre (avantura) 	<ul style="list-style-type: none"> priča sa zadacima razine ili težine

²⁵⁵ URL: <https://www.tate.org.uk/kids/games-quizzes> (3. 6. 2020.)

²⁵⁶ URL: <https://www.amnh.org/explore/ology/games> (3. 6. 2020.)

²⁵⁷ URL: <https://www.sciencemuseum.org.uk/games-and-apps> (6. 3. 2020.)

²⁵⁸ URL: <https://www.nms.ac.uk/explore-our-collections/> (6. 3. 2020.)

²⁵⁹ URL: <http://www.fireoflondon.org.uk/game/> (6. 3. 2020.)

Grafikon 4. *Broj stranah muzeja s određenim tipom igre*

Grafikon 5. *Zastupljenost igrifikacijskih elementa na stranicama najposjećenijih stranah muzeja*

Za razliku od hrvatskih muzeja stranice najposjećenijih stranah muzeja imaju jedinstvene igre. American Museum of Natural History sadržava sve tipove igara koji se nalaze na grafikonu 4.

Od pet muzeja s igrama kvizovi nisu prisutni samo u Museum of London, koji na stranicama ima samo igru *Great Fire of London* koja, unatoč tome što ima priču sa zadatcima te različite razine, ne sadržava bodovanje. Stranice Science Museum UK imaju mnogo jedinstvenih mrežnih igara koje simuliraju protok energije, prikazuju funkcije organa ljudskoga tijela, ističu važnost recikliranja određenoga tipa otpada te općenito promoviraju znanost. Obrazovna igra *Total Darkness*²⁶⁰ sadržava i priču u kojoj glavni lik (koji služi kao avatar igrača) istražuje nestanak struje u gradu te razgovara s različitim likovima na različitim lokacijama i rješava određene zagonetke. S obzirom na način komunikacije s likovima (koji se izvršava biranjem ponuđenih dijaloga) te načine rješavanja zagonetka razvijaju se određene vještine lika u igri (npr. kreativnost, komunikacija, znatiželja).

Na mrežnim stranicama muzeja National Museums Scotland nalaze se igre koje mogu npr. pomoći pri učenju Morseova koda ili razumijevanju životinjske genetike te igre povezivanja u kojima se oblače stari Rimljani ili Egipćani. Na stranicama muzeja Museum of London nalazi se mrežna igra *Great Fire of London*, koja je izrađena u suradnji s drugim kulturnim ustanovama. U toj se igri s pomoću priče s igrivim mehanikama prikazuje požar u Londonu koji je izbio 1666. godine i uništio trećinu grada. Igra ima šest razina. Igrači igraju s pomoću izmišljenih povijesnih likova koji rješavaju različite zagonetke te tako prolaze kroz igru, dok s pomoću predmeta koji su se upotrebljavali u to vrijeme spoznaju kako se živjelo sredinom 17. stoljeća te koji su bili razlozi izbijanja toga požara (vidi sliku 33).

²⁶⁰ URL: <https://totaldarkness.sciencemuseum.org.uk/> (25. 12. 2019.)

Slika 33. *Primjer scenarija u igri Great Fire of London, u kojem igrač mora odabrati predmete za gašenje požara koji su bili dostupni 1666.*

5.6.2. Igrifikacijski elementi na stranicama arhiva

U ovome potpoglavlju analiziraju se obrazovni sadržaji arhiva. Analiza je provedena u svibnju 2018.²⁶¹ Analizirana je 21 mrežna stranica arhiva (popis arhiva nalazi se u prilogu *Pregled obrazovnih sadržaja na mrežnim stranicama 21 svjetskog arhiva*). „Istraživanjem su obuhvaćeni strani arhivi na području Europe te Nacionalni arhiv SAD-a, Japanski državni arhiv, Novozelandski državni arhiv, Brazilski državni arhiv te Knjižnica i arhiv Kanade. Europski arhivi izabrani su jer je riječ o susjednim zemljama, a arhivi izvan Europe, poput arhiva SAD-a, Japana, Novoga Zelanda i Brazila, izabrani su jer je riječ o velikim arhivima koji se nalaze na različitim kontinentima te koji su zanimljivi svojim ustrojem i odrazom kulture zemlje koju predstavljaju. U analizi je utvrđeno koji arhivi imaju stranice s obrazovnim materijalima i interaktivnim sadržajima te je za stranice s interaktivnim sadržajima provedena analiza.” (Marković i Mihaljević, 2018: 191).

Od 21 arhiva 18 arhiva sadržava interaktivne sadržaje. U Hrvatskoj nijedan arhiv nema obrazovne igre, ali na stranici Hrvatskoga arhivističkog društva²⁶² postoje različiti tipovi obrazovnih igara poput kviza koji se odnosi na arhivsku praksu i Hrvatski državni arhiv,

²⁶¹ Analiza je iscrpnije prikazana u radu *Elektronički arhivski obrazovni sadržaji* (Marković i Mihaljević, 2018).

²⁶² URL: <https://had-info.hr/arhivisticke-igre> (5. 12. 2019.)

prethodno spomenute daktilografske igre izrađene prema *Arhivističkome rječniku*, slagalice s arhivskim gradivom i pamtilice s arhivima. Na stranici također se mogu pronaći interaktivne karte koje prikazuju poznate arhive u svijetu²⁶³ i povijest arhivistike^{264, 265}. Izrađena je i galerija na kojoj se nalaze scene iz filmova koji govore o arhivima i arhivskome gradivu²⁶⁶ (Ibid.: 194). Od 18 arhiva koji imaju interaktivne sadržaje svi imaju interaktivne galerije. Tri arhiva (Nizozemski državni arhiv, Francuski državni arhiv i Nacionalni arhiv SAD-a) imaju virtualnu šetnju, a sedam arhiva sadržava rjeđe tipove obrazovnih materijala, prikazanih u tablici 32, poput obrazovnih sustava, videoigara i kvizova (Ibid.).

Tablica 32. *Rjeđi tipovi obrazovnih materijala (Ibid.: 191–192)*

arhiv	posebni obrazovni programi ili sustavi	obrazovne videoigre
Francuski državni arhiv	ne	ne
Nacionalni arhiv UK-a	da	da
Nacionalni arhiv Škotske	da	ne
Nacionalni arhiv Islanda	da	ne
Nizozemski državni arhiv	da	ne
Nacionalni arhiv SAD-a	da	da
Australski državni arhiv	da	ne

„Od sedam arhiva koji imaju interaktivne obrazovne sadržaje svi osim Francuskoga državnog arhiva imaju svoji tip obrazovnoga sustava ili programa. S pomoću tih obrazovnih programa, npr. DocsTeacha Nacionalnoga arhiva SAD-a, nastavnici mogu na temelju ponuđena arhivskoga gradiva izraditi vlastite obrazovne materijale poput galerija, igara povezivanja događaja i vremenskih lenta²⁶⁷.” (Ibid.: 195). Mogu oznakama u sustavu odrediti komu je namijenjen obrazovni sadržaj (učenicima osnovne škole, srednje škole, studentima, nastavnicima), na koje se povijesno razdoblje odnosi, koje se vještine razvijaju (povijesna

²⁶³ URL: <https://had-info.hr/arhivi-svijet/> (6. 3. 2020.)

²⁶⁴ URL: <https://had-info.hr/povijest/> (6. 3. 2020.)

²⁶⁵ Izrada sadržaja opisana je u radu *Izrada multimedijiskoga mrežnog sadržaja za promoviranje arhivske djelatnosti* (Mihaljević, 2017b)

²⁶⁶ URL: <https://had-info.hr/filmovi/> (6. 3. 2020.)

²⁶⁷ URL: <https://www.docsteach.org/> (6. 3. 2016.)

analiza i razmišljanje, povijesno razumijevanje itd.) te u kojemu stupnju Bloomove taksonomije taj obrazovni sadržaj pripada. S pomoću tih oznaka, koje se mogu u pretraživanju kombinirati, korisnici mogu lako pronaći tuđe nastavne materijale.

Samo nacionalni arhivi Ujedinjenoga Kraljevstva i SAD-a imaju elektroničke obrazovne igre od kojih se većina odnosi na povijest (vidi tablicu 33, grafikon 6 i grafikon 7). Nacionalni arhiv Australije u jednoj zbirci ima stare društvene igre koje su pohranjene kao slike²⁶⁸, ali te igre ne možemo uvrstiti u analizu jer nije riječ o elektronički interaktivnim igrama. Slike igara moraju se ispisati kako bi se igrale.

Tablica 33. *Tipovi obrazovnih igara*

arhiv	tipovi igara	igrifikacijski elemenati
Nacionalni arhiv UK-a	<ul style="list-style-type: none"> ● kviz ● zagonetke ● jedinstvene igre (strategije, avanture, igra označavanja životinja) 	<ul style="list-style-type: none"> ● bodovanje ● razine ili težine ● priča sa zadacima
Nacionalni arhiv SAD-a	<ul style="list-style-type: none"> ● kviz ● križaljke ● zagonetke 	<ul style="list-style-type: none"> ● bodovanje

²⁶⁸ URL: <http://www.guides.naa.gov.au/collection/snapshots/Games/tennis.aspx> (5. 12. 2019.)

Grafikon 6. Broj stranih arhiva s određenim tipom igre

Grafikon 7. Zastupljenost određenih igrifikacijskih elementa na stranicama arhiva

„Na stranicama Nacionalnoga arhiva Ujedinjenoga Kraljevstva i Nacionalnoga arhiva SAD-a najčešće su igre kvizovi. Kvizovi Nacionalnog arhiva Ujedinjenoga Kraljevstva²⁶⁹ imaju samo pitanja na zaokruživanje te nisu vizualno atraktivni jer ne sadržavaju slike uz pitanja te neki kvizovi nemaju animacije za prijelaz među pitanjima. Dio kvizova te drugih obrazovnih sadržaja napravljen je s pomoću programa Adobe Flash, čiji .swf format nije dobro podržan za pregled na suvremenim mrežnim preglednicima. Na stranicama Nacionalnoga arhiva SAD-a kvizovi²⁷⁰ nisu tehnički napredniji od kvizova Arhiva Ujedinjenoga Kraljevstva, nego se uglavnom sastoje od pitanja s mrežnom poveznicom koja vodi do druge stranice s odgovorom.” (Ibid.:195). Kvizovi iz obaju arhiva, unatoč tomu što imaju bodovanje te neki od njih daju povratnu informaciju i objašnjenje odgovora, nemaju vremensko ograničenje ni tablicu rezultata. „Nacionalni arhiv Ujedinjenoga Kraljevstva ima najviše različitih igara na stranici pod dijelom vezanim za obrazovanje te igre sadržavaju najviše igrifikacijskih elemenata²⁷¹. Igre na toj stranici dijele se po razdobljima i vrsti.” (Ibid.:195). Također ima mnogo jedinstvenih tipova i obrazovnih igara od kojih neke imaju priče. „Na primjer, za srednji vijek postoji igra *Catch the Robber*²⁷², u kojoj se igraču postavlja pitanje što bi u srednjemu vijeku trebao učiniti u slučaju da pljačkaš provali u njegovu kuću i ukrade vrijedne predmete. Igra *Domesday Game*²⁷³ bavi se povijesnim događajem u kojemu je kralj Engleske William 1. Osvajač u 11. stoljeću napravio popis stoke i zemlje stanovnika Engleske kako bi utvrdio njihovu imovinu. Na temelju toga povijesnoga događaja napravljena je igra u kojoj igrač treba brzo pritisnuti na životinje koje se pojavljuju na zaslonu kako bi ih zbrojio kao vlastitu stoku. Igrač treba paziti da ne pritisne na divlju životinju poput lisice jer će izgubiti bodove.” (Ibid.: 195–196).

„Neke od igara na stranicama drugih arhiva poput Nacionalnoga arhiva SAD-a nisu interaktivne nego je riječ o križaljka i zagonetkama²⁷⁴ koje se mogu ispisati i dati učenicima da ih rješavaju. Treba napomenuti da su neke igre zastarjele u prezentacijskom i tehničkom aspektu te time neće biti zanimljive mlađim korisnicima koji uglavnom pregledavaju mrežne sadržaje s pomoću mobilnih uređaja.” (Ibid.:197).

²⁶⁹ URL: <https://www.nationalarchives.gov.uk/education/focuson/domesday/activities/quiz.htm> (6. 3. 2020.)

²⁷⁰ URL: <https://www.archives.gov/education/lessons/inaugural-quiz> (6. 3. 2020.)

²⁷¹ URL: <http://www.nationalarchives.gov.uk/education/> (7. 3. 2020.)

²⁷² URL: <http://www.nationalarchives.gov.uk/education/candp/games/galleries/gallery2.htm> (7. 3. 2020.)

²⁷³ URL: <http://www.nationalarchives.gov.uk/domesday/domesday-game/> (7. 3. 2020.)

²⁷⁴ URL: <https://www.archives.gov/education> (7. 3. 2020.)

5.6.3. Igrifikacijski elementi na stranicama knjižnica

Istraživanje mrežnih stranica knjižnica provedeno je u prosincu 2019. godine. Popis većih knjižnica nalazi se na stranicama *Wikipedije*²⁷⁵. Neke od knjižnica s toga popisa, npr. Bugvia library u Pakistanu, Nottingham Subscription Library i John Rylands University Library, nemaju mrežne stranice, pa nisu uvrštene u analizu. Analiza je time obuhvatila 254 knjižnice od kojih 22 knjižnice sadržavaju igre ili barem poveznice na stranice s igrama (popis svih knjižnica nalazi se u prilogu *Knjižnice za čije je mrežne sadržaje provjereno imaju li igrifikacijske elemente*).

Većina stranica knjižnica (232 knjižnice) ne sadržava igre, ali neke knjižnice sadržavaju obavijesti o terminima kad se održavaju radionice i igraonice za djecu u prostorijama knjižnice. Većina tih radionica i igraonica u knjižnicama poput Phoenix Public Library²⁷⁶, Jacksonville Public Library²⁷⁷ i New York Public Library²⁷⁸ usmjerene su na to da djeca uče i vježbaju čitanje. Na stranicama knjižnica poput San Francisco Public Library²⁷⁹ nalaze se i tečajevi za učenje programiranja u programu Scratch²⁸⁰. Neke knjižnice poput Marathon County Public Library²⁸¹ i Moncton Public Library²⁸² nemaju igre na stranici, ali nude posjetiteljima prostorija knjižnice videoigre koje mogu igrati na različitim igraćim konzolama. Od digitalnih resursa na stranicama knjižnica, poput stranica knjižnica Calgary Public Library²⁸³, Carnegie Library of Pittsburgh²⁸⁴ i Montgomery County Public Libraries²⁸⁵, najčešće se mogu naći audioknjige²⁸⁶ i elektroničke knjige²⁸⁷. Igre koje se mogu naći na stranicama knjižnice, čak i na vanjskim poveznicama, namijenjene su djeci predškolske dobi te učenicima nižih razreda osnovne škole te se na stranicama često nalaze unutar podstranica za djecu. Većina knjižnica poput Chicago

²⁷⁵ URL: https://en.wikipedia.org/wiki/List_of_libraries (8. 12. 2019.)

²⁷⁶ URL: <https://www.phoenixpubliclibrary.org/kids> (20. 12. 2019.)

²⁷⁷ URL: <https://www.jaxpubliclibrary.org/kids-teens/young-children-birth-4-years> (20. 12. 2019.)

²⁷⁸ URL: <https://www.nypl.org/education> (20. 12. 2019.)

²⁷⁹ URL: <https://sfpl.org/research-learn/elearning> (19. 12. 2019.)

²⁸⁰ Scratch je besplatan program koji korisnicima omogućuje učenje programiranja s pomoću grafičkog sučelja u kojem dovlače i spajaju blokove kodova s pomoću kojih upravljaju grafičkim resursima na podlozi (Scratch, 2019.)

²⁸¹ URL: <https://www.mcpl.us/catalogs/video-games> (18. 12. 2019.)

²⁸² URL: <https://monctonpubliclibrary.ca/teens/> (18. 12. 2019.)

²⁸³ URL: <https://calgarylibrary.ca/read-learn-and-explore/digital-library/?query=> (8. 12. 2019.)

²⁸⁴ URL: <https://www.carnegielibrary.org/eresources/?format-id=20> (8. 12. 2019.)

²⁸⁵ URL: <https://www.montgomerycountymd.gov/library/> (18. 12. 2019.)

²⁸⁶ Audioknjige su digitalne zvučne snimke osobe koja čita knjigu (Dictionary.com, 2019.)

²⁸⁷ Elektronička knjiga ili e-knjiga knjiga je izdana u digitalnome obliku koja se čita s pomoću određenoga računalnog uređaja (računala, mobilnog uređaja, tableta) koji sadržava odgovarajući program za pokretanje i prikaz njezina sadržaja (Techopedia, 2016a).

Public Library²⁸⁸ i Contra Costa County Library²⁸⁹ nema vlastite igre, ali sadržava poveznice na obrazovne igre koje se nalaze na drugim mrežnim stranicama. Nažalost, neke od stranica koje se nalaze na tim poveznicama, poput poveznica na Pikes Peak Library District²⁹⁰, sadržavaju igre koje nisu obrazovnoga karaktera poput zabavnih igara na stranicama *Miniclip*²⁹¹ i *Cartoon Network*²⁹². Zbog toga se u nastavku analize u obzir uzimaju knjižnice koje imaju vlastite obrazovne igre ili poveznice na one stranice koje sadržavaju obrazovne igre (vidi grafikon 8). Vlastite obrazovne igre imaju samo dvije knjižnice: Orange County Library System i Carnegie Library of Pittsburgh (vidi tablicu 34). Od analiziranih 22 knjižnice koje imaju vanjske poveznice na tuđe obrazovne igre, 18 knjižnica ima vanjske poveznice na obrazovne igre (vidi tablicu 35), dok Cincinnati Public Library, Montgomery County Public Libraries, Park Ridge Public Library i Bibliotheca Alexandrina imaju poveznice na igre koje nisu obrazovnoga karaktera. Stoga analiza obuhvaća samo 20 mrežnih stranica knjižnica koje nude obrazovne igrificirane sadržaje.

Grafikon 8. Broj obrazovnih igara koje se nalaze na stranicama knjižnice i vanjskim poveznicama

²⁸⁸ URL: <https://www.chipublib.org/kids/> (20. 12. 2019.)

²⁸⁹ URL: <https://ccclib.org/kids-landing-page/> (20. 12. 2019.)

²⁹⁰ URL: <https://www.parkridgelibrary.org/fun-and-games/> (19. 12. 2019.)

²⁹¹ URL: <https://www.miniclip.com/games/en/> (19. 12. 2019.)

²⁹² URL: <https://www.cartoonnetworkhq.com/> (19. 12. 2019.)

Tablica 34. *Tipovi igara i igrifikacijski elementi knjižnica koje sadržavaju vlastite obrazovne igre*

knjižnica	tip igre	igrifikacijski elementi
Carnegie Library of Pittsburgh	<ul style="list-style-type: none"> • jedinstvena igra 	<ul style="list-style-type: none"> • priča sa zadatcima
Orange County Library System	<ul style="list-style-type: none"> • kviz 	<ul style="list-style-type: none"> • bodovanje

Tablica 35. *Tipovi obrazovnih igara i igrifikacijski elemenati koji se nalaze na vanjskim poveznicama kojima se koriste knjižnice*

vanjska poveznica	tipovi igre	igrifikacijski elementi	knjižnice koje koriste vanjsku poveznicu
ABCmouse	<ul style="list-style-type: none"> • igra povezivanja • igra popunjavanja (matematika) • kviz • slagalica i zagonetka 	<ul style="list-style-type: none"> • bodovanje • razine i težine • vremensko ograničenje • priča sa zadatcima • značke ili drugi sustavi nagrađivanja • avatar 	<ul style="list-style-type: none"> • Chicago Public Library • Clinton-Macomb Public Library • Los Angeles Central Library • New Orleans Public Library • Prince George's County Memorial Library System • St. Louis Public Library • San Diego County Library • San Francisco Public Library • San José Public Library • South San Francisco Public Library • Southfield Public Library • Kenton County Public Library • Pikes Peak Library District
Funbrain	<ul style="list-style-type: none"> • igra popunjavanja (matematika) • kviz 	<ul style="list-style-type: none"> • bodovanje 	<ul style="list-style-type: none"> • Winnipeg Public Library • Cerritos Millennium Library in Cerritos
NASA Space Place	<ul style="list-style-type: none"> • kviz • slagalica i zagonetka 	<ul style="list-style-type: none"> • bodovanje • razine ili težine 	<ul style="list-style-type: none"> • Contra Costa County Library

vanjska poveznica	tipovi igre	igrifikacijski elementi	knjižnice koje koriste vanjsku poveznicu
		<ul style="list-style-type: none"> • vremensko ograničenje 	
National Geographic Kids	<ul style="list-style-type: none"> • igra povezivanja • igra popunjavanja • kviz • slagalice i zagonetke 	<ul style="list-style-type: none"> • bodovanje • razine ili težine 	<ul style="list-style-type: none"> • Chicago Public Library • Contra Costa County Library

Grafikon 9. Vanjske poveznice na stranice s obrazovnim igrama koje se pojavljuju na stranicama knjižnica

Grafikon 10. Knjižnice s poveznicom na određeni tip igre

Grafikon 11. Zastupljenost određenih igrifikacijskih elementa

Trinaest knjižnica sadržava poveznicu na stranicu *ABCmouse.com*²⁹³ (vidi grafikon 9), koja služi kao obrazovni sustav i usklađena je s obrazovnim kurikulumom za djecu od druge do osme godine. Pristup se toj stranici plaća 9,95 dolara mjesečno, s time da je nakon registracije prvih

²⁹³ URL: <https://www.abcmouse.com/> (11. 3. 2020.)

mjesec dana besplatno, a nakon toga korisnik može ukinuti pretplatu. Na toj stranici nalaze se različiti kvizovi, igre dovlačenja (npr. poredaj planete Sunčeva sustava, dovuci riječi koje sadržavaju određeno slovo u odgovarajuće polje), jednostavni matematički zadatci (npr. $2 + 5 = ?$), slagalice, zagonetke s brojkama i riječima. Igre zanimljivima čini to što svaka od njih ima priču i likove koji su prikazani animacijama. Tako se npr. u igri *Word Card Challenge* nalaze rakun Roxie i leopard Carl koji, dok čekaju prijatelja, igraju društvenu igru u kojoj dovlače riječi kako bi završili rečenice.

Sustav podržava mnoge igrifikacijske elemente. Na početku se od korisnika traži da stvori vlastiti avatar za lik u sustavu te odredi razinu svojega znanja. Taj avatar napreduje što više prolazi kroz obrazovne sadržaje sustava te dobiva bodove i značke koji se spremaju na njegov profil (vidi sliku 34).

Slika 34. *Primjer statusa avatara za aktivnosti u sustavu ABCmouse.com*

Od ostalih knjižnica s vanjskim poveznicama Cerritos Millennium Library in Cerritos i Winnipeg Public Library imaju poveznice na stranicu *Funbrain*²⁹⁴, Chicago Public Library i Contra Costa County Library imaju poveznice na igre sa stranice *National Geographic*²⁹⁵, Contra Costa County Library također ima poveznicu na igre na stranici NASA-e²⁹⁶. Igre na

²⁹⁴ URL: <https://www.funbrain.com/> (14. 12. 2019.)

²⁹⁵ URL: <https://kids.nationalgeographic.com/games/> (14. 12. 2019.)

²⁹⁶ URL: <https://spaceplace.nasa.gov/menu/play/> (19. 12. 2019.)

stranicama *National Geographica* raznolike su te obuhvaćaju tematske kvizove, slagalice, zagonetke, igre popunjavanja, platformerske igre²⁹⁷. Posebno je zanimljiva igra povlačenja u kojoj djeca uče reciklirati otpad. Igre na stranicama NASA-e manje su raznolike. To su uglavnom zagonetke koje se odnose na određene fizičke mehanike poput kretanja objekata u svemiru. Neke od igara na stranicama *National Geographica* i NASA-e, unatoč dosta brznoj dinamici igre, spadaju u obrazovne igre jer se dotiču tema povezanih s očuvanjem okoliša i istraživanjem Zemlje i svemira.

Igre na stranici *Funbrain* nisu sve primarno obrazovnoga karaktera, ali postoje matematičke igre poput *Math Basketball*²⁹⁸, u kojoj igrač treba dovršiti jednadžbu kako bi njegov lik u igri zabio koš te igra *Coral Reef*²⁹⁹, u kojoj se nalaze kvizovi za morska bića. Orange County Library System, Carnegie Library of Pittsburgh jedine su knjižnice koje imaju vlastite igre pokrenute na svojim stranicama. Nažalost, igre na Orange County Library System teško je pokrenuti jer se koriste zastarjelom *flash*-tehnologijom, pa je jedino moguće pokrenuti kviz o povijesti američke vlade³⁰⁰. Treba istaknuti *flash*-igru *Storymaker*³⁰¹ sa stranice Carnegie Library of Pittsburgh, u kojoj igrači stvaraju vlastitu priču kao interaktivnu knjigu. Priča se stvara tako da se odabere glavni lik, glavna aktivnost koju glavni lik izvodi u radnji te drugi sporedni lik oko kojega se vrti odabrana radnja. Nakon toga igrač slaže svoje scene za priču u kojima može dovlačiti više likova te predmeta. U grafičkome sučelju za svaki lik mogu se odabrati interakcije koje će on izvoditi s drugim likovima ili predmetima. Te interakcije generiraju tekst priče koji se može izmijeniti. Te se interakcije prikazuju s pomoću animacija. Nakon što igrač završi priču, može pokrenuti animirani filmić s tekstom te ga podijeliti s drugim igračima (vidi sliku 35). Takav tip sadržaja dobar je za razvoj kreativnosti kod djece te ih potiče da počnu smišljati i pisati vlastite priče. Nažalost, takvu je igru teško napraviti jer zahtijeva dosta animacija za sve likove te treba pažljivo programirati i uskladiti sve moguće interakcije među likovima i predmetima u igri. Igra ne sadržava prethodno spomenute igrifikacijske elemente jer nije riječ o klasičnoj igri u kojoj igrač rješavajući zadatke mora doći do određenoga cilja.

²⁹⁷ Platformerska igra igra je u kojoj igrač većinu vremena sa svojim likom skače s jedne platforme na drugu (Macmillian Dictionary, 2010).

²⁹⁸ URL: <https://www.funbrain.com/games/math-basketball> (22. 12. 2019.)

²⁹⁹ URL: <https://www.funbrain.com/games/tinybop-schools-coral-reef> (22. 12. 2019.)

³⁰⁰ URL: http://kids.ocls.info/games/activities_display.asp?id=10 (21. 12. 2019.)

³⁰¹ URL: <https://www.carnegielibrary.org/storymaker/> (8. 12. 2019.)

Slika 35. Prikaz postavljanja scene u priči

5.6.4. Zaključak analize o zastupljenosti igrifikacijskih elemenata na mrežnim stranicama informacijskih ustanova

Iz analize igrifikacijskih elemenata informacijskih ustanova možemo vidjeti da 20 knjižnica, 11 muzeja i 2 arhiva sadržavaju obrazovne igre ili poveznice na igre, sveukupno 33 stranice, što je malo manje nego stranice enciklopedija i rječnika (36 stranica). Stranice enciklopedija i rječnika sadržavaju više tipova igara (12) za razliku od stranica arhiva, knjižnica i muzeja koji imaju samo sedam tipova igara (vidi tablicu 36). Tipovi igara koji nisu prisutni na stranicama arhiva, knjižnica i muzeja, a nalaze se na stranicama enciklopedija i rječnika su osmosmjerka, daktilografska igra, vješala, igra upisivanja izgovorene riječi te izvanmrežni materijali za igru. Razlog za to je da se tih pet tipova igara odnosi na rječnike te se igrifikacijom rječnika veliku važnost pridaje pisanju i izgovaranju riječi.

Tablica 36. *Broj određenih tipova igara na mrežnim stranicama arhiva, knjižnica i muzeja*

tip igre	broj
kviz	27 (29,3 %)
slagalice i zagonetka	23 (25 %)
igra povezivanja	18 (19,6 %)
igra popunjavanja	15 (16,3 %)
jedinstvena igra	5 (5,4 %)
pamtilica	3 (3,3 %)
križaljka	1 (1,1 %)

Bodovanje i razine ili težine su kao i kod rječnika i enciklopedija najprisutniji igrifikacijski elementi. Igre muzeja i na vanjskim poveznicama knjižnica češće imaju više igrifikacijskih elemenata nego igre koje se nalaze na stranicama enciklopedija i rječnika. Često sadržavaju i rjeđe igrifikacijske elemente koji nisu bili toliko prisutni u enciklopedijama i rječnicima poput avatara, priče sa zadacima, značke ili drugih sustava nagrađivanja (vidi tablicu 37).

Tablica 37. *Igrifikacijski elementi mrežnih stranica arhiva, knjižnica i muzeja*

igrifikacijski element	broj
bodovanje	28 (25,7 %)
razine ili težine	20 (18,3 %)
priča sa zadacima	19 (17,4 %)
vremensko ograničenje	15 (13,8 %)
avatar	14 (12,8 %)
značke ili drugi sustavi nagrađivanja	13 (11,9 %)

6.TIPOVI OBRAZOVNIH IGARA

U ovome se poglavlju analiziraju svi tipovi obrazovnih igara sa stranica enciklopedija, knjižnica te informacijskih ustanova. Kriteriji su analize pedagoški i tehnički aspekti. Početna je ideja bila proučiti i metodičke aspekte koji se odnose na mogućnosti primjene igara u nastavi. Ti bi se aspekti odnosili na interaktivnost između nastavnika, igre i učenika te jesu li igre rađene za individualan rad, radu u paru ili u skupini. Nakon pokušaja provedbe takve analize uočeno je da nastavnik svaki tip igre može po potrebi uvrstiti u vlastitu nastavu te dati učenicima da samostalno igraju igre ili zajedno s njima igre proći pojedinačno ili u skupini prikazom igara s pomoću projektora. Prikazom igara s pomoću projektora tijekom nastave učenici zajedno mogu rješavati zadatke iz igara tako da nastavniku govore rješenja zadataka, a nastavnik može podijeliti učenike u skupine i kontrolirati njihov rad. Učenici svaki tip igre mogu igrati samostalno, u paru ili u skupini. Čak i kad svaki igrač zasebno igra igru na računalu, ta se igra može igrati u skupini ili paru ako su igre mrežno povezane, pa tako igrači zajedno rješavaju zadatke ili igraju jedan protiv drugoga.

Analiza pedagoških i tehničkih aspekata kvalitativna je ili nefrekvencijska analiza³⁰², kvalitativna analiza proizlazi iz autorova znanja i iskustva (Posavec, 2011: 106). Teško je provesti kvantitativnu analizu³⁰³ jer ima mnogo različitih računalnih tipova igara te se mnogi nastavnici ne koriste njima na nastavnome satu. Do objektivnijih rezultata sigurno bi se došlo da se mogao provesti eksperiment koji bi uključio veliki broj nastavnika i učenika te anketiranje vezano za rad sa svim tipovima igara kod poučavanja određenih nastavnih jedinica te da se onda rezultate ankete prebaci u brojčane vrijednosti (Posavec, 2011: 6). Unatoč tome što je ovo kvalitativna analiza rađena s pomoću analitičke matrice, pregledan je svaki tip igre te sadržaj koji se poučava njima. Autor je također izradio vlastite inačice većine tipova igara na stranicama *Jezične igre*, *Informatičke igre* i *Hrvatski u školi* te kao nastavnik informatike i voditelj radionice *Digitalno učenje glagoljice* u Matici hrvatskoj³⁰⁴ i na predavanjima koja se svake

³⁰² Kvalitativna analiza usmjerena je na način na koji pojedinci i skupine promatranjem određenoga entiteta ili fenomena dolaze do novih spoznaja te oblikuju nova značenja izvan svojega iskustva. U statistici kvalitativna analiza sastoji se od postupaka koji se koriste jedino dihotomnim podacima (podacima koji mogu poprimiti vrijednost 0 i 1). Taj tip analize prikladan je za manja istraživanja u kojima se događaji ili entiteti mogu lakše izbrojiti ili razvrstati nego izmjeriti (Crossman, 2020).

³⁰³ Kvantitativna analiza provodi se u društvenim znanostima te se oslanja na statistiku i teoriju vjerojatnosti. Rezultati analize koji se dobija na uzorkom koriste se za objašnjavanje određene situacije ili fenomena (Lucas-Alfieri, 2015: 284–285).

³⁰⁴ URL: <http://www.matica.hr/zbivanja/dan-hrvatske-glagoljice-i-glagoljastva-2678/> (2. 4. 2020.)

godine odvijaju na Danima otvorenih vrata Instituta za hrvatski jezik i jezikoslovlje³⁰⁵ isprobao različite tipove igara na različitim skupinama učenika srednjih i osnovnih škola³⁰⁶.

6.1. Pedagoški aspekti igara

U ovome se potpoglavlju procjenjuje koliko je učenicima i nastavnicima jednostavan svaki tip igara s obzirom na mehaniku i dizajn igre. Važno je da obrazovne igre ne budu prezahtjevne s obzirom na način igranja te da pravila igre razumiju nastavnici i učenici. Također je važno da igre dobro integriraju obrazovne sadržaje sa zabavnim mehanikama i daju igraču povratne informacije izravno nakon rješavanja zadatka. Važno je i proučiti koliko je svaki tip igre fleksibilan za poučavanje određenih nastavnih sadržaja (npr. pravopisa, gramatike, vokabulara). Na temelju prethodno iznesenih razmatranja jedinice su analitičke matrice ovog aspekta:

Lakoća igranja:

- 0. jednostavno
- 1. teško procijeniti zahtjevnost
- 2. zahtjevno

Primjena igre na različite obrazovne sadržaje:

- 0. tip igre može se rijetko primjenjivati pri poučavanju različitih obrazovnih sadržaja
- 1. tip igre može se redovito primjenjivati pri poučavanju različitih obrazovnih sadržaja
- 2. tip igre može se stalno primjenjivati pri poučavanju različitih obrazovnih sadržaja.

Tipovi igara isti su kao i u prethodnim analizama. Analizom je obuhvaćeno 11 tipova igara: kviz, igra povezivanja, slagalica i zagonetka, križaljka, igra popunjavanja, igra upisivanja izgovorenih riječi, jedinstvena igra, pamtilica, osmosmjerka, daktilografska igra i vješala. U analizu nisu uvršteni izvanmrežni materijali za igru jer nije riječ o igrama te ti materijali mogu biti raznoliki po sadržaju i tehnici pa ih je stoga teško uvrstiti u analizu. Analiza je prikazana u tablici 38.

Tablica 38. Proučavanje pedagoških aspekata tipova obrazovnih igara

	lakoća igranja	primjena igre na različite obrazovne sadržaje
kviz	0	2
igra povezivanja	0	2
slagalice i zagonetke	1	1

³⁰⁵ URL: <http://ihjj.hr/stranica/dani-otvorenih-vrata/21/> (2. 4. 2020.)

³⁰⁶ O reakcijama nastavnika i učenika na prikazane igre na Danima otvorenih vrata vidi rad *Elektroničke obrazovne igre očima učenika i nastavnika* (Mihaljević, 2021: 17–21).

	lakoća igranja	primjena igre na različite obrazovne sadržaje
križaljka	1	2
igra popunjavanja	0	2
igra upisivanja izgovorenih riječi	0	0
jedinstvena igra	1	2
pamtilica	0	1
osmosmjerka	1	1
daktilografska igra	1	0
vješala	0	1

* lakoća igranja: 0 – jednostavna, 1 – teško procijeniti zahtjevnost, 2 – zahtjevna

**primjena igre na različite obrazovne sadržaje: 0 – tip igre može se rijetko primjenjivati pri poučavanju različitih obrazovnih sadržaja, 1 – tip igre može se redovito primjenjivati pri poučavanju različitih obrazovnih sadržaja, 2 – tip igre može se stalno primjenjivati pri poučavanju različitih obrazovnih sadržaja

Kvizovi, vješala, igre popunjavanja, igre povezivanja, igre upisivanja izgovorenih riječi i pamtilice vrlo su jednostavne i pravila su igre veoma jasna te ih većina učenika, studenata i nastavnika može igrati bez pomoći te dodatnih objašnjenja. Nema nijedan tip igre koja je procijenjena kao zahtjevna. Ostali tipovi igara poput slagalica, križaljki, osmosmjerki itd. nisu zahtjevni za korištenje jer imaju jasna pravila igre, ali određenim igračima ti tipovi igara mogu biti teži za rješavanje. Stoga ih je teže koristiti u nastavi. Pogotovo je u slučajevima jedinstvenih igara teško procijeniti zahtjevnost jer su to igre koje imaju svoja pravila. Unatoč tomu što te igre mogu biti jednostavne za igranje i dalje je potrebno posebno proučiti pravila igre za razliku od igara čija pravila učenici unaprijed znaju.

Kvizovi, igre popunjavanja, križaljke, igre povezivanja i jedinstvene igre mogu se primijeniti za učenje svih vrsta obrazovnih sadržaja, ali s pomoću njih uglavnom se ne mogu naučiti praktične vještine (npr. ne možemo s pomoću kviza naučiti osobu kako će voziti auto, ali je možemo naučiti sve teorijske činjenice povezane s vožnjom auta). Jedinstvene igre koje mogu imitirati bilo koju situaciju mogu donekle pomoći u učenju praktičnih vještina (npr. simulacije vožnje poput *City Car Driving*³⁰⁷ ili igra *Arma 3*³⁰⁸, koja simulira djelovanje različitih vojnih

³⁰⁷ URL: https://store.steampowered.com/app/493490/City_Car_Driving/ (30. 3. 2020.)

³⁰⁸ URL: https://store.steampowered.com/app/107410/Arma_3/ (30. 3. 2020.)

jedinica na terenu). Igre poput pamtilica, slagalica i zagonetka te osmosmjerka mogu se koristiti za većinu obrazovnih sadržaja, ali se s pomoću njih teško mogu ispitati sve vrste gradiva. Osmosmjerkom je nemoguće poučavati i uvježbavati matematiku, kemiju i fiziku jer se jednadžbe ne mogu uvrstiti u tablice. U odnosu na to slagalice i zagonetke uglavnom se mogu koristiti za učenje matematike, logike, fizike, ali nisu primjenjive za učenje teorije jer ne postavljaju pitanja. S pomoću pamtilica može se ispitati većina sadržaja jer se ne moraju nužno spajati iste slike, nego se može spajati riječ sa značenjem, jednadžba s rješenjem, slika s nazivom, ali se s pomoću pamtilice teško mogu ispitati sadržaji koji imaju duga pitanja ili odgovor jer cijeli tekst ne stane na jednu karticu. Igre koje koriste pitanja za nadopunjavanje korisne su za provjeru činjeničnoga znanja, npr. poznavanja nazivlja kemijskih elemenata, biljaka, planeta, životinja itd. Također se mogu koristiti za učenje pravopisa i rješavanje matematičkih zadataka. Takav tip pitanja nije primjeren za početnike, ali je dobar za naprednije učenja jezika radi boljšeg razumijevanja konteksta, riječi i gramatičkih koncepata. Teže se programiraju nego pitanja s ponuđenim odgovorima jer se provjerava korisnikov unos više znakova. Taj tip zadataka zahtijeva od korisnika da točno zna napisati odgovor u prazninu. Igre povezivanja jednoga ili više sadržaja uz korištenje vizualnih elemenata omogućuju grupiranje elemenata koji imaju zajedničke značajke, redanje elemenata ili postavljanje elemenata u pravilan položaj. Ti elementi mogu biti slike ili tekst. Takva vrsta pitanja dobra je za kategorizaciju, povezivanje ili podjelu pojmova. Mogu se povezati dvije slike (npr. zastave država s njihovim oblikom na zemljopisnoj karti), slike i tekst (npr. dovuci naziv do njegove slike) ili se dovlačiti slike i tekst u odgovarajuća polja (npr. dovuci *glagol* u polje u kojemu piše njihov pravilan oblik, npr. *vozt čete* – futur I., *budem vozio* – futur II., ili dovuci slike drveća u polje za crnogorično i bjelogorično drveće). Daktilografskim igrama uglavnom se mogu jedino ispitati daktilografske vještine i pravopis. Ipak, u igri *Utipkaj riječi s glasovnim promjenama*³⁰⁹ (koja se nalazi na stranici *Jezične igre*) od riječi koje padaju jedino treba utipkati one koje sadržavaju određenu glasovnu promjenu. To znači da se daktilografske igre mogu upotrijebiti za postavljanje kratkih pitanja te od padajućih odgovora treba na brzinu utipkati točan i tako se može uvježbavati gradivo. Ipak je nemoguće postavljati dulja pitanja koja zahtijevaju složeniji odgovor. Te igre također zahtijevaju daktilografske vještine te se teško mogu koristiti za rješavanje složenijih jednadžba jer one često zahtijevaju korištenje operatorima, što onda od korisnika traži da na brzinu upiše simbole koji se ne nalaze na tipkovnici. Također je teško napraviti da daktilografske igre funkcioniraju na mobilnim uređajima jer je brzina tipkanja na

³⁰⁹ URL: <https://jezicneigre.com/utipkaj-rijeci-s-glasovnim-promjenama/> (30. 3. 2020.)

njima mnogo sporija te tipkovnica na mobilnim uređajima zauzima oko pola zaslona, što je nezgodno za igre u kojima riječi padaju na dno zaslona. Igre upisivanja izgovorenih riječi lako se mogu razumjeti i napraviti, ali njihova primjena ima smisla samo za učenje stranoga jezika i pravopisa.

6.2. Tehnički aspekti igara

Tehnički aspekti jako su bitni jer određuju je li igru moguće lako izraditi s dostupnom tehnologijom. Za sve tipove igara moguće je pronaći dostupne programske kodove na stranicama kao što su CodePen i GitHub, koji se mogu preuzeti bez autorskih ograničenja te izmjenjivati po potrebi, ali nemaju svi koji žele izrađivati obrazovne igre dovoljno tehničkih vještina da mogu izmjenjivati složene funkcionalnosti ili dizajn određenih igara. Zato je važno proučiti koji se tipovi igara mogu napraviti s pomoću grafičkih sučelja dostupnih programa koji se mogu naći na internetu kao što je npr. H5P. S pomoću takvih programa moguće je lakše napraviti igre jer korisnik unutar sučelja unosi upute, pitanja, odgovore, slike te upravljanje logikom igre. Izrada igre na taj će način često imati ograničenja jer je većina napravljena s pomoću zatvorenoga tuđeg programskog koda koji se ne može izmijeniti te je teže promijeniti neke funkcionalnosti igre, lokalizirati igru na druge jezike te izmijeniti izgled određenih dijelova igre. Neki od besplatnih programa za izradu obrazovnih igara zahtijevaju od korisnika da se registrira, imaju ograničenja količine izrađenoga sadržaja te postavljaju digitalni vodeni žig³¹⁰ na izrađeni sadržaj. Određene tipove igara također je teško prilagoditi za igranje na mobilnim uređajima koji imaju manji zaslon te nemaju miš i tipkovnicu. Na temelju prethodne analize utvrđene su ove jedinice sadržaja za analitičku matricu:

Mogućnost potpune izrade igre s pomoću grafičkoga sučelja programa:

- 0. nije moguće
- 1. moguće je

Mogućnost izmjene programskoga koda i dizajna za sadržaje napravljene s pomoću grafičkoga sučelja:

- 0. nije moguće
- 1. moguće je.

Mogućnost igranja igre na mobilnim uređajima:

- 0. nije moguće

³¹⁰ Digitalni vodeni žig (engl. *Digital watermark*) prozirna je oznaka koja se stavlja na određeni digitalni dokument ili program kako bi se zaštitilo autorsko pravo (webopedia, 2001).

1. moguće je.

Pri proučavanju druge jedinice tehničkoga aspekta kao uzorak uzelo se u obzir samo one tipove igara koji se mogu napraviti s pomoću grafičkoga sučelja. Analiza je prikazana u tablici 39.

Tablica 39. *Proučavanje tehničkih aspekata obrazovnih igara*

	mogućnost izrade igre s pomoću grafičkoga sučelja programa	mogućnost izmjene programskoga koda za sadržaje napravljene s pomoću grafičkoga sučelja	mogućnost igranja igre na mobilnim uređajima
kviz	1	0	1
igra povezivanja	1	0	1
slagalice i zagonetke	0	-	1
križaljka	1	1	1
igra popunjavanja	1	0	1
igra upisivanja izgovorenih riječi	1	0	1
jedinstvena igra	0	-	1
pamtilica	1	0	1
osmosmjerka	1	0	1
daktilografska igra	1	0	0
vješala	1	0	1

*0 –nije moguće, 1 – moguće je

Analizirani su programi H5P, Quizzlet, sustav Moodle i EclipseCrossword. Postoje i drugi mrežni servisi, sustavi i programi za izradu igara poput Baamboozle³¹¹ i Kahoot!, ali budući da su funkcionalnosti i mogućnosti svih tih programskih rješenja dosta slične, nije bilo potrebno i njih uključiti u analizu. H5P omogućuje izradu igara poput kvizova, pamtilica, osmosmjerka, igara povezivanja, igara popunjavanja i igara upisivanja izgovorenih riječi. Moodle sustav omogućuje izradu kvizova, a instalacijom određenih dodataka moguće je napraviti i druge

³¹¹ URL: <https://www.baamboozle.com/> (31. 3. 2020.)

tipove igara poput vješala i križaljka³¹². Postoji i dodatak za povezivanje sustava s mrežnim servisom H5P³¹³. Quizzlet se uglavnom primjenjuje za izradu kvizova, ali je moguće napraviti i igru popunjavanja i igre povezivanja na temelju istih pitanja te daktilografsku igru. Daktilografska igra igra se tako da se napišu nazivi i njihove definicije te u igri u kojoj padaju asteroidi igrači odaberu žele li upisivati nazive za definicije ili obrnuto. Nazivi i definicije napisani su unutar asteroida koje igrači uništavaju tako da napišu naziv za definiciju ili definiciju za naziv.

Sadržaje izrađene s pomoću Quizzleta ne može se prilagođavati izgledom i jezikom. H5P za razliku od Quizzleta omogućuje lokalizaciju igara te mnogo opcija za kontroliranje bodovanja te mogućnost prikazivanja napomena koje se tiču pitanja i odgovora. H5P još nema opciju pohrane rezultata igrača i mogućnost izmjene izgleda igre. Igre napravljene na stranicama servisa Quizzlet i H5P mogu se ugraditi na druge mrežne stranice, ali će pisati napomena da su igre izrađene s pomoću tih servisa te se njima ne može koristiti u komercijalne svrhe. Ako je igra napravljena s pomoću H5P dodataka za sustave Moodle, Drupal i WordPress, a ne na službenoj stranici, onda se ne stavlja ta napomena. EclipseCrossword³¹⁴ program kojim se koristi za izradu križaljka omogućuje da se izrađena križaljka ispiše na papir ili spremi kao mrežna stranica. Ako se izabere opcija spremanja križaljke kao mrežne stranice, cijeli kod za izradu križaljke dostupan je korisniku jer se križaljka sprema lokalno na računalo korisnika. To je jedino programsko rješenje koje omogućuje dodatnu doradu izrađenoga sadržaja u grafičkome sučelju. Jedini je problem to što program ne podržava znakove standarda UTF-8, pa je dijakritičke znakove za određene riječi potrebno dodati unutar koda. Igre poput slagalica i zagonetka koje je moguće stvoriti za obrazovne svrhe ne mogu se stvoriti u spomenutim programskim rješenjima. Postoji stranica Scrabble Maker³¹⁵ za izradu igre Scrabble, ali nije riječ o računalnoj inačici igre, nego o igri koja se ispisuje na papir. Jedinstvene igre koje imaju vlastite načine igranja teško je napraviti s pomoću grafičkoga sučelja dostupnih programa na internetu. Postoje besplatni programi s grafičkim sučeljem za izradu različitih mobilnih aplikacija i mrežnih igara poput GDevelop i Godot Engine, ali za rad u tim programima potrebno je znati logičke osnove programiranja. Sve tipove igara osim daktilografskih moguće je igrati na mobilnim uređajima. Čak se i križaljke i osmosmjerke koje zauzimaju dosta prostora na zaslonu mogu prilagoditi tako da se igraju na malome dodirnom zaslonu. Daktilografsku

³¹² URL: https://moodle.org/plugins/mod_game (31. 3. 2020.)

³¹³ URL: https://moodle.org/plugins/mod_hvp (31. 3. 2020.)

³¹⁴ URL: <https://eclipsecrossword.com/> (31. 3. 2020.)

³¹⁵ URL: <https://www.edu-games.org/word-games/scrabble-word-maker.php> (31. 3. 2020.)

igru teže je prilagoditi za mobilne uređaje zbog male veličine zaslona, kod dodirnih zaslona tipkovnica zauzima oko pola ekrana, te potrebe za brzim tipkanjem.

6.3. Rezultati analize

Za svaku jedinicu aspekta analize izračunana je najčešća vrijednost i postotak njezine zastupljenosti te su uspoređene najčešće vrijednosti svih aspekata kako bi se došlo do zaključka o tipovima igara (vidi grafikone 12, 13, 14, 15 i 16 te tablicu 40). Ukupno ima 11 tipova igara. U slučaju druge jedinice tehničkoga aspekta *moгуćnost izmjene programskoga koda i dizajna za sadržaje napravljene s pomoću grafičkoga sučelja* analizirano je deset tipova igara koje se mogu napraviti s pomoću grafičkoga sučelja određenih programa.

Grafikon 12. Tipovi igara koji se lako upotrebljavaju

Grafikon 13. Tipovi igara po mogućnosti primjene pri poučavanju različitih obrazovnih sadržaja

Grafikon 14. Tipovi igara koji se mogu izraditi s pomoću grafičkih sučelja dostupnih programa

Grafikon 15. *Tipovi igara čiji se razvojni kodovi mogu prilagoditi nakon njihove izrade u grafičkome sučelju programa*

Grafikon 16. *Tipovi igara koji se mogu igrati na mobilnim uređajima manjih zaslona*

Tablica 40. *Najčešće vrijednosti za jedinice analize za pedagoški aspekt i tehnički aspekt za sve tipove igara*

pedagoški aspekti	najčešća vrijednost
lakoća igranja	jednostavno (54 %)
primjena igre za različite obrazovne sadržaje	tip igre može se stalno primjenjivati pri poučavanju različitih obrazovnih sadržaja (45 %)
tehnički aspekti	najčešća vrijednost
mogućnost potpune izrade igre s pomoću grafičkoga sučelja programa	moguće je (82 %)
mogućnost izmjene programskoga koda i dizajna za sadržaje napravljene s pomoću grafičkoga sučelja	nije moguće (89 %)
mogućnost igranja igre na mobilnim uređajima	moguće je (91 %)

Iz grafikona 12 možemo vidjeti da se nijedan tip igre ne može smatrati zahtjevnim te ih se većina jednostavno igra. Međutim, teško je za određene tipove igara procijeniti zahtjevnost jer igre poput križaljke, osmosmjerke, slagalice i zagonetke mogu biti različite težine ovisno o sadržaju i broju polja, te nisu primjerene za sve učenike ili studente. Malo manje od pola tipova igara može se stalno primjenjivati za poučavanje različitih obrazovnih sadržaja. To su igre unutar kojih se jednostavno može uvrstiti pitanja s odgovorima poput kvizova, križaljka, igara popunjavanja. Ostali tipovi igara mogu se rjeđe primjenjivati ili u slučaju daktilografske igre i igre upisivanja izgovorenih riječi rijetko se mogu primijeniti za poučavanje obrazovnih sadržaja zbog toga što su uglavnom ograničeni u količini sadržaja koja se može poučavati (npr. igre upisivanja izgovorenih riječi primjerene su u prvome redu učenju stranoga jezika, a daktilografske igre uglavnom su namijenjene učenju daktilografije ili pravopisa).

82 % igara moguće je napraviti s pomoću dostupnih besplatnih programa koji se mogu naći na internetu. Tim se programima za izradu igara mogu koristiti korisnici koji ne znaju programirati. EclipseCrossword omogućuje da se cijeli kod za izrađenu igru dalje mijenja, dopunjuje i dijeli. Osim daktilografske igre ostale tipove igara razvijatelji igara mogu lako prilagoditi za igranje na mobilnim uređajima. Na temelju rezultata analitičke matrice može se zaključiti:

1. kvizovi, igre povezivanja i igre popunjavanja najjednostavniji su tipovi igara jer se lako mogu razumjeti te se lako mogu primijeniti za poučavanje različitih obrazovnih sadržaja. Unatoč tomu, to ne bi trebalo isključiti primjenu drugih tipova igara.
2. programima i sustavima za izradu obrazovnih igara može se koristiti ako se igre žele napraviti na brzinu te se pritom veliku važnost ne posvećuje vlastitomu dizajnu, lokalizaciji sučelja igre te detaljnomu upravljanju svih mogućnosti unutar igre. Ako je nešto od toga važno, onda se igra mora samostalno programirati i dizajnirati jer uglavnom svi programi i sustavi koji nude gotova rješenja za izradu igara ne dopuštaju uređivanje razvojnoga koda.
3. gotovi svi tipovi igara mogu se prilagoditi igranju na mobilnim uređajima.

6.4. Razvoj obrazovnih igara

U ovome poglavlju objasniti će se proces i tehnologija izrade obrazovnih igara koje se nalaze na stranicama *Jezične igre*, *Informatičke igre* i *Hrvatski u školi* (prethodno spomenute u poglavlju *Igrifikacija u obrazovnim sustavima*). Te stranice zajedno sadržavaju sve tipove igara koji se spominju u prethodnim analizama. Tehnologija i načela igara koje se nalaze na tim stranicama primijenjeni su u izradi igara za istraživanje na Croaticumu (vidi poglavlje *Istraživanje na Croaticumu*) te pri izradi igara za *Mrežnik* (vidi poglavlje *Konceptualni okvir igrifikacije mrežnoga rječnika*).

Tijekom razvoja bilo kojega programskog rješenja, uključujući i igre, važno je odabrati virtualni prostor unutar kojega će se to rješenje razvijati. Poželjno je da taj virtualan prostor bude na mreži, tj. da se igra ne pohranjuje isključivo lokalno ili izvanmrežno. Razlog za to je taj da pohrana na mreži omogućuje lak pristup i sigurnu pohranu podataka jer su sadržaji pohranjeni na više mjesta (posebno ako je riječ o pohrani u oblaku) te je manja opasnost da se podatci izgube. Također je moguće pristupiti i razvijati sadržaj s pomoću više računala koja imaju ovlasti pristupa virtualnomu prostoru u kojemu se sadržaj razvija. Sadržaj pohranjen na mreži zaštićen je od nedopuštenoga pristupa ako je zaštićen dobrom lozinkom. Velika je prednost razvoja igara na mreži i to da više osoba može sa svojih računala istodobno pristupiti sadržajima pohranjenim na mreži, dok je brza izvanmrežna suradnja više korisnika na udaljenim lokacijama nemoguća. Za mrežnu pohranu dokumenata najčešće se primjenjuju sustavi za pohranu kao što su Dropbox i Google Drive, ali u slučaju razvoja programskih rješenja bolje je koristiti se nekim od mrežnih sustava za upravljanjem inačicama programa (engl. *version*

control system)³¹⁶ u kojima se određeni dijelovi programa mogu testirati te redovito ažurirati. Git³¹⁷ je najpopularniji od tih sustava te je također besplatan i otvorenoga koda. Besplatne digitalne repozitorije³¹⁸ za mrežnu pohranu i objavu programa razvijenih s pomoću Gita može se napraviti s pomoću servisa GitHub³¹⁹, GitLab³²⁰, BitBucket³²¹ itd. Igre razvijene za *Mrežnik* izrađene su na GitLab i GitHub repozitorijima jer ti repozitoriji omogućuju objavljivanje mrežnih stranica pod njihovom domenom. Tako su igre bile objavljene kao mrežne stranice na domenama repozitorija i moglo im se pristupiti s pomoću poveznica mrežnih stranica kad je trebalo testirati igre na drugim uređajima ili kad su ih trebali testirati drugi korisnici. Rad sa sustavom Git vršio se s pomoću programa GitKraken³²², koji je s pomoću grafičkoga sučelja omogućio jednostavnu povezanost lokalnih datoteka s računalnima. Unatoč tomu što je Git namijenjen tomu da više osoba radi na razvoju programskih rješenja, u izradi ovih igara sudjelovao je samo autor. Razvoj igara s pomoću sustava Git na mrežnome repozitoriju omogućio mu je da na više računala razvija igre te da redovitim spremanjem više inačica igara uvijek može sigurno raditi nadopune za igre te u slučaju pogreške koja čini cijelu igru nefunkcionalnom, može vratiti igru na neku od starijih inačica koja je radila ispravno te ne ponoviti istu pogrešku u daljnjemu programiranju. Također, pohrana na spomenutim mrežnim repozitorijima nudi mogućnost objave mrežnih igara te su se demoinačice igara mogle pokazati korisnicima radi dobivanja povratne informacije te slati na testiranje prije objave na službenoj domeni *Mrežnika*.

Prve razvijene igre pod domenom `bornal2.gitlab.io/igre-mreznik` koristile su se repozitorijem GitLab. Prednost je repozitorija GitLab u odnosu na repozitorije GitHub što besplatno mogu biti privatni. Time je razvojni kod za rad na igrama skriven svakomu osim autoru. Ipak s besplatnom inačicom programa GitKraken od rujna 2019. godine odlučeno je da se rad s privatnim repozitorijima plaća³²³. Moglo se i dalje raditi na privatnim repozitorijima GitLaba s pomoću drugih programa, ali zbog jednostavnosti nastavilo se razvijati igre s pomoću

³¹⁶ Sustav za upravljanje inačicama (engl. *version control system*) omogućuje redovito ažuriranje datoteke u direktorijima te pregled i po potrebi vraćanje prethodnih inačica koje su bile spremljene u određenome trenutku. Sustav također bilježi radove korisnika na određenim datotekama te omogućuje upravljanje i spajanje svih korisnikovih izmjena sadržaja. Korisnici za svaku predanu izmjenu mogu napisati dokumentaciju kako bi se lako mogle pratiti izmjene. Najpopularniji je sustav kojim se koristi *Git* (Margaret, 2016).

³¹⁷ URL: <https://git-scm.com/> (2. 4. 2020.)

³¹⁸ Digitalni repozitorij mjesto je na kojemu se što prikuplja i čuva digitalne podatke (Mihaljević i dr., 2015: 98).

³¹⁹ URL: <https://github.com/> (2. 4. 2020.)

³²⁰ URL: <https://about.gitlab.com/> (2. 4. 2020.)

³²¹ URL: <https://bitbucket.org/> (2. 4. 2020.)

³²² URL: <https://www.gitkraken.com/> (2. 4. 2020.)

³²³ URL: <https://www.gitkraken.com/pricing> (4. 3. 2020.)

GitKrakena. Zato se igre koje su razvijene za istraživanje na Croaticumu pod domenom borna12.github.io/croaticum koriste repozitorijima GitHub koji nisu privatni te je razvojni kod za igre dostupan svima koje zanima. Unatoč tomu što se moglo i dalje koristiti repozitorijima GitLaba koji su javni, repozitorije na GitHubu lakše je izraditi i na njima objaviti mrežne stranice. Također je zaključeno da kodovi za igre koje su razvijene za eksperiment na Croaticumu mogu biti objavljeni kao javno dobro te se njima svatko može koristiti za izradu vlastitih igara.

Dio igara sa stranica *Jezične igre i multimedijски prikaz jezika*, *Informatičke igre* i *Hrvatski u školi* izrađivao se s pomoću grafičkoga sučelja u programu H5P, a križaljke su se izrađivale s pomoću programa EclipseCrossword. Ostale igre ručno su programirane i dizajnirane.

Razlog je za uporabu H5P i EclipseCrossword to što je riječ o besplatnim programima koji ne postavljaju ograničenja na izrađene materijale te omogućuju mnogo opcija za upravljanje logikom igre te prijevoda dijelova sučelja igre. Sustav H5P omogućuje registriranim korisnicima da s pomoću grafičkoga sučelja izrade različite obrazovne materijale koji uključuju kvizove, pamtilice, virtualne šetnje, interaktivne videozapise, igre učenja riječi na temelju slika i audiozapisa, igre spajanja slika ili određenih sekvencija, izradu interaktivnih prezentacija, vremenskih lenta, virtualnih simulacija itd.

Sustav je nastao 2013. godine te temelji svoj rad na jeziku JavaScript.³²⁴ Od svojega nastanka sadržaji i funkcionalnost sustava počeli su se proširivati te time svake godine nastaju novi predlošci za izradu interaktivnih sadržaja. Razvojni kod svakoga predloška besplatno je dostupan na repozitoriju GitHub te svatko s odgovarajućim tehničkim vještinama može sudjelovati u njegovu poboljšavanju i testiranju³²⁵. Kod izrade sadržaja nije potrebno imati programersko znanje i znanje grafičkoga dizajna jer sustav H5P nudi vlastito grafičko sučelje za učitavanje i namještanje grafičkih resursa i logike igre. Unutar sučelja moguće je i prevesti tekst za sve dijelove sučelja interaktivnoga sadržaja. Igre koje se izrade s pomoću H5P-a imaju ugrađen sustav bodovanja koji se može dodatno prilagoditi. Sustav nema mogućnost dodavanja vlastitoga zvuka koji bi se čuo na određenim dijelovima igre. Na stranici sustava trenutačno ne postoji pristup bazi podataka u pozadini koja bi omogućila pohranu bodova igrača za svaku igru te prikazala tablicu rezultata za najbolje igrače. Moguće je, ako se instalira H5P kao dodatak za sustave Moodle, Wordpress ili Drupal³²⁶, bilježiti rezultate registriranih korisnika u sustavu (npr. studenata), ali ti registrirani korisnici ne vide svoj rezultat u odnosu na rezultate ostalih

³²⁴ URL: <https://h5p.org/about-the-project> (6. 4. 2020.)

³²⁵ URL: <https://h5p.org/getting-involved> (14. 6. 2019.)

³²⁶ URL: <https://h5p.org/installation> (14. 6. 2019.)

igrača. Ipak, u planu razvoja sustava navodi se da se razvijaju mogućnosti uzastopnoga igranja više igrača (engl. *multiplayer*).

Na početku izrada sadržaja za registrirane korisnike na stranici sustava nije bilo ograničenja. Svatko je mogao izraditi svoje interaktivne sadržaje te ih ugraditi na vlastite stranice s pomoću linije HTML koda. Izrađeni sadržaji pohranjeni su na profilu korisnika. Od veljače 2020. svaki novoizrađeni sadržaj koji se ugrađuje s pomoću ugradnje HTML koda sa službene stranice sadržava napomenu na vrhu da je sadržaj napravljen s pomoću sustava H5P. To se međutim ne odnosi na starije sadržaje, koji se mogu i dalje mijenjati, a da se ta napomena ne pojavi, pa kvizovi sa stranice *Hrvatski u školi* Instituta za hrvatski jezik i jezikoslovlje, poput pravopisnoga kviza³²⁷ i kviza znanja za srednje škole³²⁸ ne sadržavaju tu napomenu. Ako se sadržaje H5P izradi s pomoću dodatka za WordPress i Moodle ili se plati uporaba sustava, onda sadržaji nemaju tu napomenu. S pomoću tih sustava nisu rađene igre za *Mrežnik* ni testiranje na Croaticumu jer Moodle i WordPress zahtijevaju rad na poslužitelju koji ima bazu podatka, što nije dobro za lokalni razvoj. Nemogućnost izrade novih sadržaja na stranici H5P bez napomene navela je autora da ne izrađuje nove igre za *Mrežnik* s pomoću H5P jer se ipak htjelo izraditi sadržaje koji neće sadržavati digitalni žig ili napomenu o tome u kojemu je programu sadržaj izrađen. Također, u H5P-u nije moguće mijenjati izgled predložaka igara te mijenjati opcije koje se ne nalaze u sučelju. Zbog toga je za većinu igara odlučeno da će se razviti ručnim programiranjem i dizajnom. Posljednja igra izrađena s pomoću toga sustava koja ne sadržava navedenu napomenu, igra je dovlačenja dijelova automobila izrađena za eksperiment na Croaticumu³²⁹ (vidi sliku 36).

³²⁷ URL: <http://hrvatski.hr/igra/9/> (6. 4. 2020.)

³²⁸ URL: <http://hrvatski.hr/igra/2/> (6. 4. 2020.)

³²⁹ URL: <https://bornal2.github.io/croaticum/dijelovi-automobila.html> (6. 4. 2020.)

Slika 36. Igra u kojoj se dovlače dijelovi automobila napravljena s pomoću H5P-a

Križaljke su izrađene s pomoću programa EclipseCrossword. Riječ je o programu koji se može preuzeti s interneta te nakon instalacije omogućuje izvanmrežni (engl. *offline*) način rada. Sučelje programa omogućuje unošenje riječi koje idu u polja te pitanja koja se na njih odnose. Popis riječi s pitanjima za križaljku može se spremiti u zasebnu datoteku koja se poslije može učitati u istome programu. Križaljke se mogu izvesti kao mrežne stranice ili .rtf dokumenti. Pri izvozu igre kao mrežne stranice, igre sadržavaju bodovanje te daju povratne informacije za odgovore. Moguće je uključiti ili isključiti opciju da igrač može dobiti rješenja za pitanja pritiskom na tipku.

Razvojni kod izvezene križaljke otvoren je te se može uređivati dizajn i funkcionalnosti križaljke, što je i bilo potrebno autoru kako bi križaljka bila prilagođena za pregled na mobilnim uređajima. Također, križaljka se koristi ASCII znakovima, koji ne podržavaju dijakritike te je u kodu određene znakove potrebno zamijeniti (npr. *c* u *č* ili *ć*, *dz* u *dž*, *z* u *ž* itd.). Jedan od prvih primjera prilagodbe dizajna i funkcionalnosti križaljke možemo vidjeti u igri *Prvi školski pravopis – križaljka*³³⁰, koja se nalazi na stranici *Hrvatski u školi*. Ta križaljka sadržava dijakritičke znakove, a dizajn je izrađen na temelju ilustracija iz knjige *Prvi školski pravopis*³³¹ (vidi sliku 37).

³³⁰ URL: <http://hrvatski.hr/igra/5/> (18. 1. 2020.)

³³¹ URL: <http://knjige.ihjj.hr/knjiga/prvi-skolski-pravopis-hrvatskoga-jezika/222/> (7. 4. 2020.)

Slika 37. *Prikaz dizajna Prvi školski pravopis – križaljka*

Većina igara koje se izrađuju za *Mrežnik* te koje su korištene za testiranja studenata na Croaticumu nije izrađena s pomoću grafičkoga sučelja dostupnih besplatnih programa, nego s pomoću napisanoga programskog koda. Tako je autor imao potpunu kontrolu nad mogućnostima i dizajnom igara. Također se na taj način moglo izraditi jedinstvene igre za koje ne postoje predlošci (npr. tetris za pronalaženje riječi u kojemu se s blokovima u kojima su slova traži riječi iz rječnika³³²). S kontrolom koda u igri lakše se može za svako pitanje u igri dati povratna informacija koja iscrpno objašnjava zašto je nešto točan odgovor. Također se mogu lakše ugraditi i izmijeniti željeni igrifikacijski elementi. Kod većina igara ugrađeno je vremensko ograničenje ili brojač vremena kako bi igre bile dinamičnije igračima jer moraju brže rješavati zadatke. Dodatno se u kodu može prilagoditi način bodovanja igrača. Svaka sekunda za odgovor može se bodovati te se tako dobivaju i veće razlike među rezultatima. Primjerice u kvizu, da se ne boduje vrijeme, svi bi igrači koji točno odgovore na sva pitanja zajedno bili na prvome mjestu, pa vrijeme koje im je bilo potrebno da odgovore čini tu dodatnu razliku po kojoj ih se može poredati. Vremensko ograničenje također može smanjiti mogućnost prijevara u igri jer igrač ne stigne na vrijeme pogledati drugi izvor na internetu da dođe do odgovora. Pohranom igračevih bodova mogu se napraviti i ljestvice poretka te nagraditi najbolji igrači. Najbolja tri igrača nakon završetka igre dobivaju brončanu, srebrnu ili zlatnu medalju po uzoru na sportske igre. Neke igre poput pamtilice za učenje glagoljice *Glagoljica pamtilica*³³³ imaju opcije prilagodbe težine tako da se bira broj kartica za povezivanje te želi li

³³² URL: <https://bornal2.gitlab.io/igre-mreznik/lettris-master/> (7. 4. 2020.)

³³³ <http://hrvatski.hr/games/pamtilica-glagoljica/> (16. 6. 2019.)

igrač imati pomoć u prepoznavanju glagoljice tako što su ista latinična i glagoljična slova obojena. U igri *Upisivanje nastavaka za glagole* težina se može prilagoditi tako što se može igrati s manjim ili većim vremenskim ograničenjem za svako pitanje ili bez vremenskoga ograničenja³³⁴. Za različite težine izrađuju se posebne ljestvice poretka kako bi svi igrači bili ravnopravni (vidi sliku 38).

Slika 38. Prikaz tablice rezultata s medaljama koje se daju najboljim igračima

Većina igara programirana je s pomoću jezika jQuery. Kako bi se ubrzao razvoj igara te pronašli određeni algoritmi, pregledani su dostupni programski kodovi i rješenja koja se nalaze na stranicama CodePen i GitHub. Na stranicama CodePena nalaze se gotovi kodovi i dizajni mrežnih dizajnera i programera koji se mogu preuzeti besplatno i bez ograničenja povezanih s autorskim pravima. Na toj stranci našli su se kodovi za izradu kviza, daktilografske igre i pamtilice. Kodovi za te igre s obzirom na dizajn i funkcionalnosti izmijenjeni su u odnosu na originalni kod.

Primjerice, igra *Utipkaj riječ*³³⁵, koja se nalazi na stranici *Hrvatski u školi*, prilagođena je u odnosu na originalnu igru³³⁶ tako što je promijenjeno kodiranje za znakove u UTF-8 formatu koji podržava naše dijakritičke znakove (č, ć, š, ž, đ). Unesen je popis riječi iz *Hrvatskoga školskog rječnika* te se grafički dizajn igre prilagodio tako da je igra u svemiru (vidi sliku 39).

³³⁴ <https://bornal2.gitlab.io/igre-mreznik/kviz-mijesani/> (16. 6. 2019.)

³³⁵ URL: <http://hrvatski.hr/igra/4/> (18. 1. 2020.)

³³⁶ URL: <https://codepen.io/jakealbaugh/full/GopoLa> (7. 4. 2020.)

Slika 39. Prikaz izmjene izvornoga dizajna za igru Utipkaj riječi

Za kvizove koji su također rađeni s pomoću dostupnoga koda iz CodePena dodano je vremensko ograničenje za svako pitanje, koje ovisno o sadržaju i težini može biti 10, 20, 40, 60 ili 120 sekunda. Dodane su i povratne informacije koje se pojavljuju nakon korisnikova odgovora s pomoću dodatka SweetAlert ³³⁷. Te povratne informacije, osim što daju točan odgovor i prikazuju bodove, mogu sadržavati i objašnjenja rješenja i dodatne slike. Još je jedna dopuna u kvizu to da se korisnici mogu međusobno natjecati jer se njihovi rezultati bilježe u tablici poretka. Korisnici se ne trebaju registrirati kako bi predali rezultate, nego upišu proizvoljno korisničko ime koje se prikazuje u tablici. U izvornome su kodu za kviz³³⁸ bila samo pitanja višestrukoga izbora (engl. *multiple choice*), ali s nadogradnjom koda izrađene su i inačice igre u kojoj igrač mora upisati odgovor (igre popunjavanja) poput igre u kojoj se upisuje pravilan oblik glagola³³⁹ ili kvizovi koji miješaju pitanja višestrukoga izbora i nadopunjavanja za učenje glagolskih vremena (igrač napiše oblik glagola te ga se pita da odabere do koje glasovne promjene u tome obliku dolazi)³⁴⁰ (vidi sliku 40).

³³⁷ URL: <https://sweetalert2.github.io/> (16. 6. 2019.)

³³⁸ URL: <https://codepen.io/johnnycopes/pen/LbWYgP> (7. 4. 2020.)

³³⁹ URL: <https://bornal2.github.io/croatikum/nadopunjavanje-glagoli/index.html> (7. 4. 2020.)

³⁴⁰ URL: <https://bornal2.gitlab.io/igre-mreznik/kviz-mijesani/> (7. 4. 2020.)

Slika 40. Primjer kviza koji daje raznovrsna pitanja, komentare na odgovore te tablicu rezultata

Pamtilice su prilagođene prema izvornome kodu³⁴¹ tako da ne treba spajati samo dvije iste slike, nego se može spajati slika s nazivom ili dvije različite slike koje su tematski povezane (npr. slika medicinske sestre s medicinskim tehničarom kod pamtilice za muško-ženske parnjake³⁴²). U nekim pamtilicama korisnici mogu odabrati žele li povezivati 4, 8 ili 12 parova. U pamtilici se pri bodovanju uzima u obzir i koliko je igrač napravio pogrešaka pri povezivanju parova. Unatoč tomu što nema vremensko ograničenje, igraču se može izračunati vrijeme potrebno za rješavanje igre. Neke pamtilice, poput pamtilice za prometna vozila izrađene za istraživanje sa studentima na Croaticumu³⁴³, imaju dodatnu opciju da naprave stanku u igri i prikažu informacije za spojeni par. Te informacije prikazane su u skočnome prozorčiću koji je napravljen s pomoću spomenutoga dodatka SweetAlert 2 (vidi sliku 41).

³⁴¹ URL: <https://codepen.io/natewiley/pen/HBrbL> (7. 4. 2020.)

³⁴² URL: <https://jezicneigre.com/hr/musko-zenski-parovi/> (19. 1. 2020.)

³⁴³ URL: <https://borna12.github.io/croaticum/pamtilica-prjevozna-sredstva/> (7. 4. 2020.)

Slika 41. *Primjer pamtilice u kojoj se povezuju nazivi sa slikama te se ispiše definicija predmeta sa slike*

Svaka igra ima responzivan dizajn, koji omogućuje prilagođavanje veličine sadržaja i položaja sadržaja s obzirom na veličinu zaslona na kojemu korisnik pregledava sadržaj. Igre podržavaju i dodirne kontrole jer većina ljudi otvara mrežne stranice s mobilnih uređaja. Neke se igre poput daktilografskih teško prilagođuju igranju na mobilnim uređajima, pa je u njihovu opisu naznačeno da se trebaju igrati na računalu. Većina igara koristila se različitim JavaScript dodatcima. SweetAlert 2 bio je dodatak kojim se često koristilo u kvizovima i drugim igrama u kojima je trebalo igraču dati obavijest u određenim trenutcima igre jer omogućuje jednostavno dodavanje *pop-up* prozorčića s informacijama u bilo kojemu trenutku. Rezultati za igru kod tablica poretka pohranjivali su se na Googleovim tablicama te bi se one učitale na mrežnim stranicama s pomoću dodatka Tabletop.js³⁴⁴. Googleovim tablicama koristilo se kao zamjenom za bazu podataka jer ne zahtijevaju korištenje bazom i prilagodbu baze na mrežnome poslužitelju (engl. *server*). Podatci za tablicu rezultata nesmetano se učitavaju na mrežnu stranicu, pa korisnik ne primjećuje da se Googleove tablice nalaze u pozadini. Za rezultate je također zabilježen datum i vrijeme predaje.

Budući da većina igara ima responzivan dizajn te podržava dodirne kontrole, mogle bi se bez većih problema pretvoriti u mobilne aplikacije. Stoga se u ovome poglavlju istražuje mogućnost pretvaranja igara u mobilne aplikacije. Mrežne stranice mogu se prilagoditi za aplikaciju Android s pomoću objekta *WebView*³⁴⁵ unutar programa za izradu Android aplikacija Android Studio, s time da aplikacije katkad ne zadržavaju funkcionalnost određenih JavaScript dodataka. Primjerice za igre koje imaju ljestvice poretka umjesto da se učita stranica s rezultatima otvaraju

³⁴⁴ URL: <https://github.com/jsoma/tabletop> (7. 4. 2020.)

³⁴⁵ URL: <https://developer.android.com/reference/android/webkit/WebView> (18. 6. 2019.)

se Googleovi obrasci jer se njima koristi u pozadini za pohranu podataka u Googleovu tablicu koja se učitava na stranici. Mnogo je bolja metoda prebacivanja mrežnih stranica u mobilne aplikacije uporaba programa Apache Cordova³⁴⁶, koji omogućuje prebacivanje mrežnih stranica u Android, iOS i Windows aplikacije sa svim funkcionalnostima. Prebacivanje za iOS zahtijeva da korisnik ima ili emulira³⁴⁷ Apple računalo. Cordovom se moguće koristiti unutar terminala računala ili unutar Android Studia. S pomoću stranice PhoneGap Build³⁴⁸, koja se također koristi Cordovom, također je moguće prebaciti mrežne stranice u mobilnu aplikaciju za Android, iOS i Windows. Korisnik treba na stranici učitati .zip datoteku u kojoj se nalazi HTML, CSS i JavaScript te stranica stvori aplikacije za preuzimanje te mogućnost učitavanja korisnikova licencnoga ključa koji dopušta njihovo službeno objavljivanje na prodajnim mjestima kao što su Google Play i App Store. Licencni ključ za korištenje aplikacijom (engl. *app key store*) može se stvoriti s pomoću Jave u terminalu sustava ili u programu Android Studio te sadržava informacije o autoru programa (ime, prezime, zemlja, ustanova). PhoneGap Build omogućuje besplatnu izradu samo jedne aplikacije koja se učitava s privatnoga računala, ali je s pomoću repozitorija na servisu GitHub moguće neograničeno učitavati aplikacije pod uvjetom da je razvojni kod za njihovu izradu javno dostupan na repozitoriju.

Pri razvoju i objavi igara može se koristiti različitim programima za rad s medijima (slikama, videozapisima, audiozapisima itd.) i pisanje koda. Za pisanje koda može se koristiti mnogim besplatno dostupnim programima: Notepad++³⁴⁹, Brackets³⁵⁰, Visual Studio Code³⁵¹ i Atom³⁵². Svaki od tih programa ima vlastite dodatke te mogućnost rada bilo s kojom vrstom računalnoga jezika (programskih jezika³⁵³, skriptnih jezika³⁵⁴, jezika za postavljanje upita³⁵⁵ i jezika za

³⁴⁶ URL: <https://cordova.apache.org/> (18. 6. 2019.)

³⁴⁷ Emulacija je proces kojim program unutar određenoga računala simulira strojne i programske specifikacije drugoga računalnog uređaja. S pomoću emulacije računala omogućuje se izvođenje istih programa i obradu istih podataka koji se mogu izvoditi na tome računalu (Panian, 2005a: 193).

³⁴⁸ URL: <https://build.phonegap.com/apps> (18. 6. 2019.)

³⁴⁹ URL: <https://notepad-plus-plus.org/downloads/> (9. 4. 2020.)

³⁵⁰ URL: <http://brackets.io/> (9. 4. 2020.)

³⁵¹ URL: <https://code.visualstudio.com/> (9. 4. 2020.)

³⁵² URL: <https://atom.io/> (9. 4. 2020.)

³⁵³ Programski jezici računalni su jezici s pomoću kojih korisnik može zadavati naredbe računalu. Programi računala stvaraju se s pomoću programskih jezika kojima se kontrolira ponašanje te ulaz, obrada i izlaz određenih tipova podataka iz računala (Techopedia, 2016).

³⁵⁴ Skriptni jezici programski su jezici koji se izravno izvršavaju unutar svojega radnog okružja, tj. ne zahtijevaju kompilaciju za izvršavanje programa te se naredbe u kodu izvršavaju u stvarnome vremenu. Često se njima koristi za izradu mrežnih aplikacija (Beal, 2008).

³⁵⁵ Jezici za postavljanje upita ili upitni jezici (engl. *query language*) vrsta su računalnih jezika kojima se koristi za dohvaćanje podataka iz baze podataka ili informacijskoga sustava (Panian, 2005b: 128).

označavanje³⁵⁶). Programeri, dizajneri i razvijatelji aplikacija uglavnom se koriste jednim od spomenutih programa na temelju vlastitih preferencija. Svaki od tih programa za pisanje koda dobar je za izradu mrežnih igara jer označuje i strukturira dijelove koda (Keeton, 2019). Kod igara za *Mrežnik* koristio se program Visual Studio Code jer ne zauzima mnogo memorije pri radu sustava te se brzo izvršavaju radnje unutar programa. Većina igara sadržava slike (pogotovo pamtilice), a neke igre sadržavaju i zvuk. Pri odabiru slika za igre pazilo se na autorska prava te su s interneta upotrijebljene samo one slike koje su označene za slobodnu uporabu (kod slika pisalo je *Free for commercial use. No attribution required*). Slike su preuzete sa stranice Pixabay³⁵⁷, koja za slobodnu uporabu prikuplja slike visoke rezolucije. Programom GIMP³⁵⁸ koristilo se za rezanje, spajanje ili druge načine obrade slika. Također, s pomoću slojeva u GIMP-u napravljene su animacije za pisanje hrvatske abecede na stranici *Nauči hrvatsku abecedu!*³⁵⁹ namijenjene govornicima arapskoga jezika koji uče hrvatski jezik kao ini.

Logotip za tu stranicu bio je napravljen u vektorima³⁶⁰ (autor je izvornoga logotipa Waddah Almasri) te je bilo potrebno izmijeniti logotip i prebaciti ga u rastersku grafiku³⁶¹. To je napravljeno s pomoću programa Inkscape³⁶².

Zvučni zapisi za igre koji uglavnom uključuju zvuk kad korisnik točno ili pogrešno odgovori na pitanje preuzeti su sa stranice Freesound³⁶³, koja sadržava različite zvučne zapise kojima se može koristiti bez ograničenja. Ako ih je trebalo dodatno urediti, npr. izbaciti šum iz zvučnoga zapisa ili izrezati zvučne zapise ili promijeniti formate (npr. .wav u .mp3), koristilo se programom za obradu zvuka Audacity³⁶⁴. Kako bi se sve igre mogle lakše pronaći, poželjno je napraviti portal koji objedinjuje poveznice za više igara na jednome mjestu i omogućuje

³⁵⁶ Jezici za označavanje (engl. *markup language*) računalni su jezici koji služe za oblikovanje tekstnih datoteka i njihovo povezivanje s drugim datotekama i medijima. Najpopularniji su jezici za označavanje HTML i XML (Panian, 2005b: 13).

³⁵⁷ URL: <https://pixabay.com/> (9. 4. 2020.)

³⁵⁸ URL: <https://www.gimp.org/> (9. 4. 2020.)

³⁵⁹ URL: https://bornal2.gitlab.io/igre-mreznik/sadrzaji_za_strance/ (9. 4. 2020.)

³⁶⁰ Vektorska grafika podrazumijeva računalnu sliku koju čine grafički objekti kao što su crte te drugi geometrijski likovi koji su nastali s pomoću matematičkih formula. Prednost vektorske grafike u odnosu na rastersku, koja se koristi pikselima, prilagodba je veličine i kvalitetan ispis ili objavljivanje na mreži jer vektori zadržavaju jednaku kvalitetu bez obzira na veličinu. Jedini je nedostatak što ne mogu prikazati mnogo detalja kao rasterske slike. Vektorima se uglavnom koristi za crteže i logotipove (Panian, 2005b: 68).

³⁶¹ Rasterska grafika je koju sačinjavaju redci i stupci ispunjeni pikselima u određenim bojama. Gustoća točaka, tj. razlučivost, određuje oštrinu prikaza slike. Rasterskom grafikom uglavnom se koristi za fotografije te prikaz slike na računalu (Panian, 2005b: 60).

³⁶² URL: <https://inkscape.org/hr/> (9. 4. 2020.)

³⁶³ URL: <https://freesound.org/> (9. 4. 2020.)

³⁶⁴ URL: <https://www.audacityteam.org/> (9. 4. 2020.)

pronalaženje igara s pomoću tražilice ili oznaka (engl. *tags*) i kategorija. Kategorije omogućuju grupiranje određenih sadržaja (npr. pravopisne igre, igre za vokabular itd.), čak se kategorizacija može hijerarhijski izraditi s pomoću potkategorija (npr. potkategorija glagoli unutar kategorije glagoli) (Cvitković, 2017: 99). Oznake osim opisa sadržaja omogućuju da se izrade veze između sadržaja iz različitih kategorija i potkategorija koje imaju istu oznaku, npr. pod oznakom *kviz* mogu se dobiti svi kvizovi neovisno o tome spadaju li u kategoriju pravopisne igre ili igre za učenje vokabulara (Cvitković, 2017: 105). Portal igara za *Mrežnik* nije još izrađen jer se *Mrežnik* još razvija, ali stranice *Jezične igre i multimedijски prikaz znanja te Informatičke igre* imaju sve značajke koje će imati i portal *Mrežnika*, pa se na tome primjeru pokazuje kako bi trebao izgledati i funkcionirati portal s igrama. Ti portali sadržavaju sve igre na jednome mjestu, a one imaju vlastite kategorije i oznake. Obje stranice napravljene su s pomoću WordPressa, a za korištenje WordPressom potrebno je imati MySQL bazu podataka na mrežnome poslužitelju, što se najčešće plaća. Zbog nedostatka baze na poslužitelju, za igre koje su izrađene za eksperiment na Croaticumu napravljena je statična stranica³⁶⁵. Pisanje koda i izrada dizajna mrežne stranice dugotrajan je proces, posebno ako je riječ o stranici koja prilagođava prikaz sadržaja i za mobilne uređaje. Odlučeno je da će se koristiti program za izradu mrežnih stranica Publii,³⁶⁶ koji može s pomoću grafičkoga sučelja omogućiti izradu mrežne stranice na temelju gotovih predložaka za dizajn stranice. Ti predlošci mogu se dodatno izmijeniti jer je kod za izradu cijele mrežne stranice otvoren. Stranica koja se izrađuje može se izravno objaviti i ažurirati na poslužitelju te omogućuje povezivanje programa s digitalnim repozitorijima na servisima GitHub i GitLab. Tako se lako može ažurirati stranica. Publii omogućuje grupiranje sadržaja na temelju kategorija i oznaka.

6.5. Zaključak

Svi programi te programski kodovi kojima se koristilo za razvoj igara besplatni su te slobodni za korištenje bez ograničenja povezanih s autorskim pravom. Tako je tehnologija kojom se koristi za razvoj igara dostupna svima. Programska rješenja koja su se koristila za izradu igara za *Mrežnik* prikazana su u tablici 41.

³⁶⁵ Statične mrežne stranice mrežne su stranice koje svim korisnicima jednako prikazuju sadržaje. Za razliku od dinamičkih mrežnih stranica ne prilagođuju prikaz sadržaja korisnicima na temelju njihovih prethodno pregledanih sadržaja ili rezultata. Statične mrežne stranice često nemaju bazu podataka u pozadini jer ne pohranjuju podatke o korisnicima (Techopedia, 2009).

³⁶⁶ URL: <https://getpublii.com/> (10. 4. 2020.)

Tablica 41. *Programi, mrežne stranice i programski kodovi korišteni za razvoj igara*

mjesto za pohranu, ažuriranje i testiranje igara	GitLab, GitHub, BitBucket
stranice za pronalazak programskih kodova za igre	CodePen, GitHub
korišteni JavaScript dodatci	SweetAlert 2, Tabletop.js
stranica za pronalazak besplatnih slika	PixaBay
program za obradu slika	GIMP
program za rad s vektorima	Inkscape
stranica za pronalazak besplatnih zvučnih snimka	Freesound
program za obradu zvučnih zapisa	Audacity
program za izradu mrežnoga portala s igrama	Publii

Važno je dobro organizirati proces izrade igara ili bilo kojega drugog obrazovnog interaktivnog sadržaja. Koraci kojim se izrađuju igre za *Mrežnik* temelje se i prošireni su na temelju koraka koje objašnjava Wright (2020). Koraci su:

1. osmišljavanje ideje za igru (npr. kviz za učenje definicija glagola, pamtilicu za učenje muško-ženskih parnjaka)
 - a. uvijek imati ideju tko je ciljna populacija (uzeti u obzir dob, predznanje te interes igrača)
2. prikupljanje obrazovnih sadržaja te oblikovanje pitanja i odgovora
3. odlučivanje o igrifikacijskim elementima koji se mogu uvrstiti u igru (npr. bodovne ljestvice, ljestvice poretka, razine itd.)
4. pronalaženje programskih rješenja za razvoj igre
5. razvoj igara s dostupnom tehnologijom

6. testiranje igara na privatnoj stranici ili izvanmrežno na računalu (pojedinačno ili s manjom skupinom potencijalnih korisnika³⁶⁷)
7. ispravljanje tehničkih i sadržajnih pogrešaka (u slučaju da ih ima)
 - a. u ovome koraku često se dopunjavaju sadržaji i funkcionalnosti
8. objava i promoviranje igara
9. praćenje korisnike te ako je potrebno, ažuriranje sadržaja igara.

Za promoviranje igara (osmi korak) najbolje se koristiti društvenim mrežama kojima se koristi na prostorima na kojima se objavljuje igra. Društvene mreže besplatne su za korištenje te imaju mnogo korisnika koji međusobno dijele sadržaje. Na taj se način sadržaji mogu brzo raširiti među potencijalnim korisnicima. U Hrvatskoj su u kolovozu 2019. najkorištenije društvene mreže za pisanje novosti Facebook (oko 1 900 000 korisnika u Hrvatskoj) i Instagram (oko 1 100 000 korisnika u Hrvatskoj). Možemo uračunati i YouTube među najkorištenije društvene mreže, ali ta se mreža više koristi za objavu zabavnih videosadržaja umjesto reklama i novosti. Twitterom se mnogo koriste korisnici izvan Hrvatske, ali nije toliko popularan u Hrvatskoj (Gelenčir, 2019). Zato je većina prethodno izrađenih igara za portal *Jezične igre i multimedijски prikaz znanja* nakon izrade objavljena na Facebookovoj stranici portala³⁶⁸. Posljednjih šest igara koje su objavljene na stranici, od lipnja 2018. do listopada 2019. prosječno su dostigle oko 260 korisnika.

Mnogo više pregleda od Facebookove stranice portala *Jezične igre i multimedijски prikaz znanja* imaju igre objavljene na Facebookovim stranicama Instituta za hrvatski jezik i jezikoslovlje³⁶⁹. Tamo svaka objava koja se odnosi na igru prosječno doseže oko 14 tisuća korisnika, ima oko 6,5 posjeta te 497 oznaka svidanja (vidi sliku 42).

³⁶⁷ Demoinačice igara koje se razvijaju unutar projekta *Mrežnik* često su prije objave predstavljene na znanstvenim skupovima (vidi Lazić i Mihaljević, 2020, Mihaljević i Mihaljević, 2019 te Matijević i Mihaljević, 2019), učenicima na Danima otvorenih vrata Instituta za hrvatski jezik i jezikoslovlje 2018. i 2019. godine te neizvornim govornicima koji uče hrvatski na Croaticumu i koji su posjetili Institut za hrvatski jezik i jezikoslovlje (vidi Mihaljević, 2021: 17–21). Povratne informacije učenika, studenata i nastavnika uključuju promatranje njihovih reakcija tijekom igranja igre te razgovor s njima nakon sata. Njihovi stavovi, prijedlozi i mišljenje o igrama, uzeti su u obzir pri nadogradnji igara.

³⁶⁸ URL: <https://www.facebook.com/jezicne> (11. 4. 2020.)

³⁶⁹ URL: <https://www.facebook.com/ihjj.hr/> (11. 4. 2020.)

15.10.2019 08:54		15. listopada – Međunarodni dan bijelog štapa U povodu		7,3K		288 150	
20.9.2019 16:42		U povodu Međunarodnoga dana znakovnih jezika, 23.		3,7K		295 384	
27.5.2019 14:00		Dragi maturanti, provjerite svoje znanje hrvatskoga jezika uz		30,9K		4,6K 684	
21.2.2019 13:20		Povodom sutrašnjega Dana hrvatske glagoljice i		16,9K		1,2K 770	

Slika 42. Statistika pregleda objava Instituta koje se odnose na igre

Razlog je mnogo većega širenja igara na Facebookovoj stranici Instituta za hrvatski jezik i jezikoslovlje od stranice *Jezične igre i multimedijски prikaz jezika* što Facebookova stranica Instituta ima mnogo više pratitelja. U travnju 2020. stranica Instituta ima više od 6 tisuća pratitelja na Facebooku, a stranica *Jezične igre i multimedijски prikaz jezika* ima više od 500 pratitelja na Facebooku. Facebookova stranica Instituta mnogo je aktivnija jer se redovito pišu objave povezane s različitim aktivnostima. Zato će se igre koje se izrade za *Mrežnik* prvo promovirati na stranicama Instituta, ali će se također podijeliti na stranicama *Jezične igre i multimedijски prikaz jezika* kako bi stigle do većega broja korisnika. Koliko korisnika igra koju igru, može se pratiti s pomoću servisa Google Analytics³⁷⁰. Primjerice, s pomoću servisa Google Anyltics može se za stranicu *Jezične igre i multimedijски prikaz znanja* vidjeti da u dvije godine ima 178 940 pregleda, od čega je najviše posjetitelja (18 782) pregledalo pravopisni kviz³⁷¹ (vidi sliku 43). Na stranici je znatno porastao broj posjeta u ožujku (16 920 posjeta) i travnju (18 014 posjeta) 2020. u odnosu na siječanj (9477 posjeta) i veljaču (10 587 posjeta). Razlog za nagli porast posjeta vjerojatno je početak epidemije bolesti COVID-19 zbog koje su nastavnici održavali nastavu na daljinu i zbog toga su se više služili elektroničkim materijalima te im u tome obrazovne igre pomažu.

Također, može se pregledati iz koje zemlje većina korisnika pristupa stranici (npr. 68,16 % iz Hrvatske, 13,98 % iz Bosne i Hercegovine) te pristupaju li s pomoću mobilnoga uređaja (mobiteli 46,78 %, tableti 2,94 %) ili stolnoga računala (50,28 %). Moguće je uključiti opciju da se prate demografski podatci o korisnicima (dob i spol), ali ta opcija nije bila uključena na stranici *Jezične igre i multimedijски prikaz znanja* jer bi se u tome slučaju trebalo u skladu s GDPR-om obavijestiti korisnike da se prikupljaju njihovi podatci te tražiti da potvrde slažu li se s time (Christopher, 2018). Demografske podatke ne može se prikupiti za sve korisnike, nego

³⁷⁰ URL: <https://analytics.google.com/analytics/web/> (11. 4. 2020.)

³⁷¹ URL: <https://jezicneigre.com/pravopisni-kviz/> (11. 4. 2020.)

samo za one koji su u trenutku posjeta stranice prijavljeni u neki od drugih Googleovih servisa (YouTube, Gmail, Android Mobile Devices itd.) (Google Analytics, 2019).

Slika 43. Prikaz pregleda stranice Jezične igre i multimedijски prikaz jezika od 4. travnja 2018. do 10. travnja 2020.

Za svaku igru na *Mrežniku* ugradit će se računalni kod za praćenje korisnika, isto kao na stanicama *Jezične igre i multimedijски prikaz znanja*, kako bi se znalo koji su sadržaji najposjećeniji. Igrači mogu dati povratne informacije s pomoću društvenih mreža ili autorima poslati poruke povezane s izmjenom sadržaja ili poboljšanjima u igrama.

7. ISTRAŽIVANJE NA CROATICUMU

7.1. Hrvatski kao ini jezik

Kad se govori o ovladavanju hrvatskim jezikom često se spominju nazivi *strani jezik*, *nasljedni jezik*, *drugi jezik* i *ini jezik* (Cvikić, Jelaska, Kanajet Šimić, 2010: 118–119). „Drugi jezik (engl. *second language*) bilo je koji jezik kojim pojedinac ovladava nakon što je usvojio barem osnove materinskoga jezika, a označava se kraticom L2, odnosno hrvatskom inačicom J2.” (Jelaska, 2005: 28). „Drugi jezik često učimo u prirodnoj okolini, u kojoj smo okruženi izvornim govornicima i služimo se njime u svakodnevnim situacijama. Strani se jezik, za razliku od drugoga, uči izvan države u kojoj se govori. On dakle nije ni državni, ni službeni, ni obrazovni jezik zemlje u kojoj se uči. Katkad složenost društvenih situacija može utjecati na to da se teško može razgraničiti strani od drugoga jezika. Neki psiholingvisti odlučili su pojednostaviti situaciju, pa se jedino koriste nazivom *drugi jezik* koji obuhvaća sve jezike usvojene ili naučene nakon materinskoga. Drugi jezik smatra se nematerinskim jezikom koji se upotrebljava u toj zemlji u obrazovanju, poslovanju ili upravljanju, a strani jezik nematerinski je jezik koji se ne upotrebljava kao priopćajno sredstvo u toj zemlji. Drugi jezik onaj je jezik kojim se osoba redovito služi u svakodnevnim situacijama, a strani onaj koji se koristi povremeno i neredovito.” (Ibid.). Na primjer osoba koja uči engleski, švedski ili njemački u Hrvatskoj osoba je koja uči strani jezik, a osoba koja je došla u Hrvatsku bilo iz kojega razloga i uči hrvatski osoba je koja uči hrvatski kao drugi jezik jer je okružena njime te se treba njime redovito koristiti. Govornici nasljednoga jezika (engl. *heritage language*) za razliku od govornika stranoga jezika imaju izravnu obiteljsku vezu s jezikom. Jezik koji je tko usvojio u svojem domu ili jezičnoj zajednici kao materinski ili jedan od materinskih, ali mu je izloženost nadmoćnijemu jeziku okoline promijenila jezični razvoj, pa je nazadovao, okamenio svoje znanje ili nije usvojio sva jezična obilježja svojega jezika naziva se nasljedni jezik (Jelaska, 2016: 93). Uz naziv nasljedni jezik upotrebljavaju se bliskoznačni nazivi jezik podrijetla ili predački jezik. Predački jezik (engl. *ancestral language*) strani je jezik s kojim je učenik toga jezika povezan podrijetlom, ali ga nije učio u obitelji (Ibid.: 97). „Upravo je nasljedni jezik jedan od važnijih poticaja za učenje (naraštajna motivacija).” (Cvikić, Jelaska, Kanajet Šimić 2010: 113). U engleskome se naziv *second language* često upotrebljava za svaki jezik koji nije materinski, što u hrvatskome može biti višeznačno, pa Jelaska (2007: 89) predlaže naziv *ini jezik*. Prema tome, ini jezik obuhvaća svaki nematerinski jezik bez obzira na to na koji ga način govornik usvaja. Pri poučavanju jezika važno je spomenuti i međujezik (engl. *interlanguage*). „Međujezik se odnosi na dinamički jezični sustav koji se razvija kod učenika *inoga jezika*, a u

procesu učenja približava se ciljnomu jeziku zadržavajući pritom neka svojstva *prvoga jezika*³⁷² ili uopćavajući pravila *inoga jezika* pri govoru ili pisanju ili stvarajući vlastite inovacije.” (Obad i Šarić, 2015: 135). U ovome radu rabić će se naziv hrvatski kao ini jezik zato što su sudionici istraživanja osobe različitoga podrijetla koje uče hrvatski jezik u centru za hrvatski kao drugi i strani te je sudionicima istraživanja hrvatski jezik drugi, strani ili nasljedni.

Ovladavanje inim jezikom složeni je proces na koji djeluju različiti čimbenici. Postoje mnoga istraživanja koja različitim pristupima proučavaju ovladavanje inim jezikom te istražuju različite perspektive poput lingvističke, kognitivne, psiholingvističke, sociolingvističke, neurolingvističke (Medved Krajnović, 2010; Jelaska, 2005). Ovisno o pristupu istražuju se različiti čimbenici te ih je moguće kategorizirati na različite načine. Jedna je od mogućih podjela na unutarnje čimbenike povezane isključivo s učenikom te one vanjske, koji su povezani s učenikovom okolinom (Cvikić, 2012: 35). „Kod ovladavanja jezikom čimbenike je moguće podijeliti na jezične i nejezične. Jezični čimbenici podrazumijevaju utjecaj materinskoga i ostalih jezika koje netko govori na ovladavanje novim jezikom. U njih se ubrajaju i utjecaji različitih unutarjezičnih elemenata, obilježja jezika kojim se ovladava, na samo ovladavanje. Osim obilježja materinskoga i inoga jezika za učenje inoga jezika važan je i stupanj znanja materinskoga jezika, izloženosti inomu jeziku, način svladavanja inoga jezika (npr. učenje ili usvajanje) itd.” (Ibid.). Nejezični čimbenici obuhvaćaju društvene čimbenike, afektivne čimbenike i pojedinačna obilježja učenika (Ibid.). „Mnogo je istraživanja provedeno o utjecaju jezičnih čimbenika na učenje hrvatskoga jezika kao inoga (Cvikić, 2005; Cvikić i Bergovec, 2008; Jelaska, 2005; Novak Milić, 2002). Manje istraživanja i objavljenih radova napisano je o nejezičnim čimbenicima ovladavanja hrvatskim kao inim jezikom (Cvikić, Jelaska, Kanajet Šimić, 2010; Jelaska i Hržica, 2005) premda se i oni smatraju jednako važni za uspješno ovladavanje jezikom.” (Cvikić, 2012: 35–36). Među nejezičnim čimbenicima možemo proučiti metodu poučavanja s pomoću igara jer mnogi ljudi vole igrati igre te se igre počinju sve više primjenjivati u obrazovanju (Sanders, 2015). Elektroničke obrazovne igre dostupne svima mogu biti dobar način da se potakne učenje ili usvajanje hrvatskoga jezika s obzirom na sve prethodno spomenute moguće probleme poput straha od jezika, nemogućnosti pohađanja tečajeva za učenje jezika te razlika između materinskoga i hrvatskoga jezika. Besplatno dostupni interaktivni obrazovni mrežni materijali omogućuju studentima ili učenicima da

³⁷² Naziv *prvi jezik* može se odnositi na kronološki prvi jezik koji je pojedinac usvojio. U tome je značenju naziv *prvi jezik* donekle sinoniman nazivima *materinski jezik* i *rodni jezik*. Osim toga, naziv *prvi jezik* može se odnositi na hijerarhijski primarni jezik sporazumijevanja i jezik kojim tko najlakše vlada. U tome je značenju ovaj naziv sinoniman nazivu *glavni jezik* (Matijević, Gulešić Machata i Udier, 2020: 33).

privatno uče bez straha da će pogriješiti pred ostalima te po želji određene lekcije mogu ponavljati više puta. Kod natjecateljskih igara unatoč tomu što igrači mogu objaviti svoje rezultate pred ostalim igračima i dalje mogu biti anonimni s pomoću vlastitoga korisničkog imena na temelju kojega ih drugi igrači ne mogu identificirati. Korisnik u igrama ima osjećaj uključenosti, povratnu informaciju dobiva brzo, ima osjećaj napredovanja i uspjeha jer dobiva izazove koje može ispuniti (Zhou, 2016: 3). U dobro dizajniranoj obrazovnoj igri s mnogo opcija igrač može izazove ispunjavati postupnim napredovanjem, a na motivaciju pozitivno utječe i to što korisnik, ako mu to igra dopušta, u potpunosti može prilagoditi učenje sebi: učiti sam ili s još kime, ciljano napredovati u razinama ili se vraćati na prethodne lekcije, izdvajati vrijeme za učenje ili samo ispunjavati vrijeme u stankama od drugoga posla i sl.

7.2. Plan istraživanja

Prije izrade konačne inačice igara korisno je testirati igre na različitim skupinama korisnika. To je posebno korisno kad je riječ o igrama za rječnik poput *Mrežnika*, koji ima tri modula (za odrasle izvorne govornike hrvatskoga jezika, učenike nižih razreda osnovne škole i neizvorne govornike hrvatskoga jezika). Osim samotestiranja i testiranja na kolegama i suradnicima neke su igre predstavljene na Danima otvorenih vrata Instituta te na različitim radionicama i tribinama s različitim skupinama učenika. Tijekom njihova posjeta Institutu neke od prvih inačica igara koje se nalaze u *Mrežnikovu* modulu za neizvorne govornike hrvatskoga jezika predstavljene su studentima koji su prošli A1, A2, B1 ili B2 tečaj na Croaticumu.³⁷³ Igre namijenjene izvornim govornicima arapskoga jezika koji uče hrvatski jezik predstavljene su skupini izvornih govornika arapskoga jezika koji uče hrvatski jezik. Studenti su ispunili upitnik u kojemu su izrazili zadovoljstvo igrama i iznijeli neke svoje prijedloge (više vidi u Matijević i Mihaljević, 2020). Stavovi, prijedlozi i mišljenja o igrama ciljnih korisnika uzimaju se u obzir pri izradi konačne inačice igara.

Kako bi se uspješno testirali sadržaji koji ulaze u konceptualni okvir igrifikacije za mrežni rječnik (u ovome slučaju *Mrežnik*) te dosad izrađeni tipovi igara u dogovoru s Croaticumom – Centrom za hrvatski kao drugi i strani jezik³⁷⁴ provedeno je istraživanje o učinkovitosti igra u

³⁷³ URL: <http://ihjj.hr/mreznik/page/usavrsavanje-i-diseminacija-2020/30/> (15. 4. 2020.)

³⁷⁴ „Croaticum – Centar za hrvatski kao drugi i strani jezik ustanova je u kojoj se poučava te znanstveno i stručno proučava i opisuje hrvatski kao ini jezik. Dio je Odsjeka za kroatistiku Filozofskoga fakulteta Sveučilišta u Zagrebu. Croaticumovi obrazovni programi prilagođeni su brojem sati i sadržajem potrebama različitih polaznika, a nastava se održava po razinama prema *Zajedničkome europskom referentnom okviru za jezike* (A2.2, B1.1, B1.2, B2.1, B2.2, C1). Polaznici Croaticuma studenti su inozemnih sveučilišta koji dolaze na Sveučilište u Zagrebu u sklopu različitih programa studentskih mobilnosti, zatim potomci hrvatskih iseljenika, kao i osobe koje uče hrvatski jezik jer rade u Hrvatskoj ili su se doselile u Hrvatsku te osobe koje uče hrvatski iz brojnih drugih razloga. Polaznici su odrasle osobe sa svih kontinenata, iz većine svjetskih zemalja, različite dobi i različitih prvih jezika.

nastavi, s posebnim obzirom na usvajanje vokabulara³⁷⁵. Cilj toga istraživanja bio je da se ispita hipoteza:

- H1: *Osobe koje uče hrvatski kao ini jezik, a koje se služe igrificiranim sadržajima, postižu statistički značajno bolje rezultate na testu usvajanja vokabulara od osoba koje se ne služe igrificiranim sadržajima.*

Kako bi se dokazala ta hipoteza provedeno je testiranje s dvjema različitim skupinama studenata (eksperimentalnom i kontrolnom) na Croaticumu, koje su na istome stupnju znanja hrvatskoga jezika (A2) te rade po istome udžbeniku *Razgovarajte s nama!* (Čilaš Mikulić i dr., 2018: 78–93). Eksperimentalna skupina studenata pri obradi lekcije služi se igrama, a kontrolna skupina studenata radi isključivo klasičnim metodama. Kako bi se mogao izmjeriti napredak njihova znanja, provodi se ispitivanje na dvama nastavnim satima koji su u razmaku od dvaju tjedana. Na početku prvoga sata studenti su pisali pretest iz vokabulara koji je rađen na temelju lekcije *Transport i komunikacija* iz spomenutoga udžbenika i vježbenice *Razgovarajte s nama!*. Taj test potreban je kako bi se provjerilo početno znanje studenata te mogao izmjeriti njihov napredak. Test je izrađen u suradnji s nastavnicama koje predaju studentima kontrolne i eksperimentalne skupine po istome planu i programu. Provedba istraživanja i odabir nastavnika koji predaju u dvije odgovjene skupine dogovoreni su s voditeljicom Croaticuma dr. sc. Milvijom Gulešić Machata. Odabrane su nastavnice Jelena Cvitanušić i Ranka Đurđević jer je procijenjeno da predaju skupinama koje su podjednake po predznanju (razina A2) i broju polaznika. Prošle godine na Croaticumu nisu bile dvije skupine na istoj razini kojima predaje ista nastavnica. Te su nastavnice pri pripremi i provedbi istraživanja komunicirale međusobno i s autorom oko usklađivanja sadržaja te održavanja sata kako bi nastava (osim uporabe igara) bila provedena što ujednačenije (vidi tablicu 42). Studenti obiju skupina s nastavnicama su obrađivali i ponavljali nastavnu jedinicu koja se nalazila u pretestu. Eksperimentalna je skupina to radila s pomoću igara, a kontrolna klasičnim metodama rada. Na kraju istoga sata

Posljednjih godina broj polaznika ustalio se na otprilike 250 polaznika po semestru te stotinjak polaznika na kraćim programima.” (Croaticum, 2020).

³⁷⁵ Tabaľ i Ordulj (2015: 103–121) također su provele istraživanje na Croaticumu koje se odnosilo na usvajanje vokabulara hrvatskoga kao inoga jezika. One su se bavile strategijama usvajanja vokabulara. Te strategije uključuju strategije formalnoga učenja i vježbanja vokabulara, strategije samopoticajnoga nezavisnog učenja i strategije spontanoga učenja. Cilj njihova istraživanja bio je da utvrde koje će se strategije pokazati najrelevantnijima u kontekstu hrvatskoga kao inoga jezika te razlikuje li se uporaba strategija s obzirom na različit stupanj ovladanosti jezika. Rezultati istraživanja pokazuju da se ispitanici često koriste svim trima strategijama učenja vokabulara. Po prosjeku najviše se koriste strategijama formalnoga učenja i spontanoga učenja, dok su strategije samopoticajnoga učenja nešto slabije zastupljene. Ipak polaznici nižega stupnja (B1) češće se koriste strategijama samopoticajnoga učenja ($t = 2,083$; $p < 0,05$) od polaznika višega stupnja (B2 i B2+).

U istraživanju koje je proveo autor ovoga rada istraživao se utjecaj igrifikacije samo u okviru formalnoga učenja i vježbanja vokabulara.

studenti su rješavali posttest koji je isti kao i pretest, jedino s izmiješanim redoslijedom pitanja i odgovora, kako bi se provjerilo koliko su studenti napredovali nakon obrade i ponavljanja nastavnih sadržaja. Dodatno se provjerava trajnost stečenoga znanja. Dva tjedna nakon prvoga sata proveden je odgođeni posttest koji se ponovno sastojao od istih pitanja. Tako se mogao izmjeriti utjecaj igara na učenje vokabulara te na kratkoročno i dugoročno pamćenje. Nakon prikupljanja i analize rezultata svih testova uočeno je da su u sva tri testa studenti kontrolne skupine ostvarili bolje rezultate od studenata eksperimentalne skupine (vidi više u potpoglavlju *Rezultati studenata*). Zbog toga se, unatoč korištenju neparametrijskim Mann–Whitneyjevim U-testom koji se temelji na rangovima studenata, može u početku zaključiti da treba odbaciti prethodnu glavnu hipotezu (H1) da studenti eksperimentalne skupine koji se služe igrificiranim sadržajima postižu statistički značajno bolje rezultate na testu usvajanja vokabulara (rezultati testova pojedinih studenata prikazani su u prilogu 11). Unatoč tomu, hipoteza se i dalje provjerila te se, budući da se mjerilo početno znanje studenata pretestom te znanje nakon obrade nastavnih sadržaja posttestom te odgođenim posttestom, mogao mjeriti napredak studenata u testovima koji je prisutan kod obiju skupina te je stoga odlučeno da se preoblikuje glavna hipoteza istraživanja ovako:

- H1_b: *Osobe koje uče hrvatski kao ini jezik, a koje se služe igrificiranim sadržajima, postižu statistički značajno bolji napredak na testu usvajanja vokabulara od osoba koje se ne služe igrificiranim sadržajima.*

Uz tu hipotezu postavljene su i druge hipoteze koje provjeravaju postoji li značajan odnos između studentovih samoprocjena znanja hrvatskoga jezika i ostvarenih rezultata na ispitu te ostvaruju li studenti koji vole igrati elektroničke igre bolje rezultate od studenata koji ne vole igrati elektroničke igre (vidi više u potpoglavlju *Postavljene hipoteze*). Studenti obiju skupina prvi su sat ispunili upitnik s demografskim podacima te odgovorili na pitanje vole li igrati igre ili se koristiti sustavima za poučavanje. Studenti eksperimentalne skupine dodatno su još odgovarali na pitanja koja se odnose na njihovo zadovoljstvo igrama koje su igrali na satu.

Tablica 42. *Plan istraživanja*

sat	eksperimentalna skupina	kontrolna skupina
1.	<ul style="list-style-type: none"> • predtest koji se odnosi na novu nastavnu jedinicu (20 minuta) • obrada nastavne jedinice s pomoću igara (oko 100 minuta) • posttest (isti kao predtest) (20 minuta) • anketa koja prikuplja podatke o sudioniku (materinski jezik, poznavanje drugih jezika, jezik obrazovanja, dob) i zadovoljstvu igrama (10 minuta) 	<ul style="list-style-type: none"> • predtest koji se odnosi na novu nastavnu jedinicu (20 minuta) • obrada nastavne jedinice klasičnim metodama (uobičajena nastava) (oko 100 minuta) • posttest (isti kao predtest) (20 minuta) • anketa koja prikuplja podatke o sudioniku (materinski jezik, poznavanje drugih jezika, jezik obrazovanja, dob) (5 minuta)
2.	<ul style="list-style-type: none"> • odgođeni posttest (isti kao predtest i posttest) 	

Ispitivanje studenta obiju skupina bilo je anonimno te autor istraživanja nije znao identitet sudionika istraživanja. Prikupljeni su sociodemografski podatci za studente jer vanjski čimbenici kao što su zemlja podrijetla, jezik obrazovanja, poznavanje drugih jezika, godina rođenja mogu utjecati na usvajanje hrvatskoga jezika kao inoga (više o tome u potpoglavlju *Sociodemografske usporedbe rezultata*). S pomoću korisničkih imena rezultati studenata mogli su se pratiti u svim trima testovima i upitniku, a da se pritom sačuva anonimnost studenta. Korisnička imena studenti su samostalno birali. Plan istraživanja odobrilo je Etičko povjerenstvo Odsjeka za informacijske i komunikacijske znanosti Filozofskoga fakulteta u Zagrebu na sjednici 16. svibnja 2019. Studenti su bili obaviješteni o istraživanju informativnim pismom koje su im nastavnice poslale e-poštom te su dodatno o tome bili obaviješteni i na satu. Studenti koji su pristali sudjelovati u istraživanju poslali su potpisane dokumente nastavnicima, koja ih je prosljedila autoru. U dogovoru s nastavnicama s Croaticuma istraživanje je provedeno u travnju 2020. Zbog epidemije bolesti COVID-19 i sprečavanja javnih okupljanja³⁷⁶, nastava u objema skupinama održala se mrežno s pomoću programa Zoom³⁷⁷. Prelazak na Zoom mogao je do neke mjere utjecati na rezultate planiranoga istraživanja

³⁷⁶ URL:

<https://vlada.gov.hr/UserDocsImages/Vijesti/2020/03%20o%C5%BEujak/18%20o%C5%BEujka/Odluka%20-%20mjere%20ograni%C4%8Davanja%20dru%C5%A1tvenih%20okupljanja%2C%20rada%20trgovina.pdf> (17. 4. 2020.)

³⁷⁷ URL: <https://zoom.us/> (17. 4. 2020.)

(nestabilna veza, promjena motivacije, novo okruženje). Ipak su rezultati valjani jer su i eksperimentalna i kontrolna skupina imali nastavu na Zoomu (dakle, iste uvjete), studenti su prije provedbe prvoga sata istraživanja već odslušali nekoliko predavanja s pomoću Zooma te su bili upoznati s tim oblikom nastave, a ni tijekom istraživanja nije uočen nikakav tehnički problem. Prvi sat s eksperimentalnom skupinom održan je 6. travnja 2020., a s kontrolnom skupinom 8. travnja 2020. Idući tjedan studenti su imali uobičajenu nastavu bez testova. Sat na kojemu se održao odgođeni posttest bio je dva tjedna nakon prvoga sata, 20. travnja za eksperimentalnu skupinu i 22. travnja za kontrolnu skupinu. Predtest, posttest, i odgođeni posttest te anketa napravljeni su s pomoću Googleova obrasca te su studentima dane poveznice za pristup na satu. Rezultate studenata u svim trima testovima i upitniku moglo se pratiti s pomoću korisničkoga imena koje su studenti odabrali. Tako se lako mogla sačuvati anonimnost studenata i na jednostavan način povezati njihove rezultate. Autor je kao promatrač sudjelovao na obama početnim satovima, a na na drugome je satu bio prisutan jedino tijekom pisanja odgođenoga posttesta. Igre su bile dostupne samo eksperimentalnoj skupini tijekom prvoga sata. Nakon prvoga sata pristup igrama nije bio dopušten tijekom iduća dva tjedna. Na kraju istraživanja igre su dostupne svima koji znaju njihovu mrežnu adresu³⁷⁸.

7.3. Izrada igara za istraživanje na Croaticumu

Igre koje su rađene za Croaticum napravljene su s pomoću besplatnih tehnologija koje su opisane u poglavlju *Tehnologija i proces izrade obrazovnih igara*. Prije izrade igara i testa održan je 19. veljače 2020. sastanak s nastavnicama na kojemu je odabrana lekcija koja će se obrađivati (*Transport i komunikacija*) te je točno dogovoreno koje će se gradivo iz odabrane lekcije obrađivati na satu, tj. koji se sadržaj obrađuje taj sat po nastavnome planu i programu. Nastojalo se da igre i testovi budu što uklopljeniji u nastavnu jedinicu, ali i integrirani sa sadržajem *Mrežnikova* modula. Prema planu nastave na satu na kojemu je provedeno istraživanje obrađivala su se prometna vozila, dijelovi automobila te glagoli: *zahvaljivati*, *radovati se*, *čuditi se*, *prigovarati*, *diviti se*, *veseliti se*, *govoriti*, *reći*, *smijati se*, *pisati*, *kazati*, *vjerovati*, *slati*, *približavati se*, *dati*, *pomagati*, *smetati* i *nadati se*. Za nazive svih vozila, neke dijelove automobila (npr. retrovizor, kotač) i glagole preuzete su definicije iz *Mrežnikova* modula za neizvorne govornike na kojima je radila Dinka Pasini, viša lektorica na Croaticumu. Primjeri uporabe riječi, tj. kolokacije, također su preuzeti iz obrada koje se nalaze u modulu za neizvorne govornike. Ako su određene definicije ili kolokacije nedostajale u *Mrežniku*, bile su

³⁷⁸ URL: <https://bornal2.github.io/croaticum/> (17. 4. 2020.)

dodane u trenutku izrade igara iz udžbenika ili pretraživanjem korpusa s pomoću Sketch Engina. Sve igre poslane su nastavnicama odabranih skupina kako bi one mogle dati povratnu informaciju prije održavanja prvoga sata. Stranica koja objedinjuje sve igre na jednoj adresi izrađena je s pomoću programa Publii. Ta stranica zajedno s igrama podignuta je na GitHub repozitorij na adresi: <https://borna12.github.io/croaticum/> (vidi sliku 44).

Slika 44. Prikaz stranice koja objedinjuje igre kojima se koristi u ovome istraživanju

Tipovi igara za sve nastavne sadržaje iz obrađene lekcije prikazani su u tablici 43.

Tablica 43. Tipovi igara za poučavanje određenih nastavnih sadržaja

nastavni sadržaj	tip igre
prometna vozila	<ul style="list-style-type: none"> • križaljka • kviz • pamtilica
dijelovi automobila	<ul style="list-style-type: none"> • igra dovlačenja • kviz
glagoli	<ul style="list-style-type: none"> • igra dovlačenja • igra popunjavanja • kviz

nastavni sadržaj	tip igre
razumijevanje teksta	<ul style="list-style-type: none"> kviz
značajke javnoga prijevoza i automobila	<ul style="list-style-type: none"> igra dovlačenja

Stranica trenutačno sadržava 12 igara koje su povezane sa sadržajem lekcije *Transport i komunikacije*. Unatoč tomu što se znalo da neće biti vremena da se sve igre prođu na satu, odlučeno je do 6. travnja 2020. napraviti što više igara kako bi se obuhvatilo što više sadržaja. Nastavnica je odabrala igre kojima se želi koristiti na satu. Neiskorištenim igrama može se koristiti u budućnosti te se one mogu povezati s *Mrežnikovim* modulom za neizvorne govornike. U igre se željelo uvrstiti što više igrifikacijskih elemenata.

Sve igre sadržavaju igrifikacijski element bodovanja. Osim *Kviza razumijevanja teksta*³⁷⁹, kvizovi imaju ljestvice poretka u kojima se najbolje igrače nagrađuje medaljama. Vremensko ograničenje za kvizove može se uključiti ili isključiti ovisno o odabiru težinske razine. Razine se mogu prilagoditi i u pamtilici tako da se odabere broj karata za spajanje. *Kviz razumijevanja teksta* ima na temelju razina podijeljene sadržaje za učenje (*zajedničko korištenje automobilom, prvi tramvaj i automobil te prometne gužve*). *Kviz razumijevanja teksta* također sadržava elemente priče, što je jedan od igrifikacijskih elemenata. Igrači moraju odgovoriti na pitanja povezana s pričom, pa su uključeni u radnju teksta.

*Križaljka o prometnim vozilima*³⁸⁰ i *Dijelovi automobila* (igra dovlačenja)³⁸¹ jedine su igre koje su izrađene s pomoću grafičkoga sučelja u programima H5P i EclipseCrossword te sadržavaju samo igrifikacijski element bodovanja.

Igrama nadopunjavanja poput *Igra nadopunjavanja (dativ pridjeva i imenica)*³⁸² i *Upiši pravilan oblik glagola*³⁸³ koristi se kako bi se uvježbali različiti oblici riječi (dativ pridjeva i imenica te oblici u različitim licima u igri za glagole).

Sve igre osim *Križaljke o prometnim vozilima* i *Značajke javnoga prijevoza i automobila* (igra dovlačenja) sadržavaju slike do zadataka kako bi studenti mogli bolje razumjeti značenja riječi. U svakoj spomenutoj igri moguće je koristiti se različitim igrifikacijskim elementima. U tablici 44. za izrađene igre prikazuju se igrifikacijski elementi.

³⁷⁹ URL: <https://bornal2.github.io/croaticum/kviz-razumijevanje/index.html> (17. 4. 2020.)

³⁸⁰ URL: <https://bornal2.github.io/croaticum/krizaljka/index.html> (18. 4. 2020.)

³⁸¹ URL: <https://bornal2.github.io/croaticum/dijelovi-automobila.html> (6. 4. 2020.)

³⁸² URL: <https://bornal2.github.io/croaticum/nadopunjavanje/index.html> (18. 4. 2020.)

³⁸³ URL: <https://bornal2.github.io/croaticum/nadopunjavanje-glagoli/index.html> (7. 4. 2020.)

Tablica 44. Igrifikacijski elementi za svaku igru (igre koje imaju zvjezdicu na kraju naziva nastavnica je odabrala za korištenje na satu)

igra	igrifikacijski elementi
Pamtilica za prometna vozila*	<ul style="list-style-type: none"> • bodovanje • razine • ljestvica poretka • sustav nagrađivanja (medalje)
Kviz – značenje glagola*	<ul style="list-style-type: none"> • bodovanje • razine • ljestvica poretka • sustav nagrađivanja (medalje) • vremensko ograničenje
Glagoli igra dovlačenja*	<ul style="list-style-type: none"> • bodovanje • razine • ljestvica poretka • sustav nagrađivanja (medalje)
Dijelovi automobila (igra dovlačenja)*	<ul style="list-style-type: none"> • bodovanje
Kviz dijelovi automobila*	<ul style="list-style-type: none"> • bodovanje • ljestvica poretka • sustav nagrađivanja (medalje) • vremensko ograničenje
Križaljka o prometnim vozilima	<ul style="list-style-type: none"> • bodovanje
Kviz razumijevanje teksta	<ul style="list-style-type: none"> • bodovanje • razine • priča
Značajke javnoga prijevoza i automobila (igra dovlačenja)	<ul style="list-style-type: none"> • bodovanje • ljestvica poretka • sustav nagrađivanja (medalje) • vremensko ograničenje
Kviz (dativ ličnih zamjenica)	<ul style="list-style-type: none"> • bodovanje • ljestvica poretka • sustav nagrađivanja (medalje) • vremensko ograničenje
Igra nadopunjavanja (dativ pridjeva i imenica)	<ul style="list-style-type: none"> • bodovanje • razine • ljestvica poretka • sustav nagrađivanja (medalje) • vremensko ograničenje
Igra dovlačenja riječi u rečenicu	<ul style="list-style-type: none"> • bodovanje
Upiši pravilan oblik glagola	<ul style="list-style-type: none"> • bodovanje • razine • ljestvica poretka • sustav nagrađivanja (medalje) • vremensko ograničenje

7.4. Predtest, posttest i odgođeni posttest

Sva tri mrežna testa za mjerenje znanja istovjetna su za obje skupine kako bi se najbolje moglo provjeriti i usporediti promjene u znanju. Iako sva tri testa imaju ista pitanja, u svakome testu pitanja i ponuđeni odgovori idu nasumičnim redoslijedom kako bi se testovi što je moguće više razlikovali. Kao i igre i testovi su izrađeni na temelju sadržaja lekcije *Transport i komunikacija*. Testovi su prije primjene na satu bili poslani nastavnicama kako bi se dodatno mogli prilagoditi studentima. Predtest je proveden kako bi se vidjelo početno znanje studenta i piše se na početku prvoga sata. Pretpostavka je da studenti neće znati sve riješiti jer je riječ o sadržajima koje još nisu obradili na nastavi. Također, predtest se radio kako bi se mogao pratiti napredak obiju skupina studenta, što može biti važno u slučaju da jedna skupina u početku ima znatno bolje rezultate. Prvim posttestom koji se održava na kraju prvoga sata nakon obrade nastavne jedinice koristi se kako bi se analizirao pomak znanja nakon obrade nastavnoga sadržaja. Rezultati toga testa ovise o kratkoročnome pamćenju³⁸⁴ studenata jer rješavaju test koji ispituje veći dio sadržaja koje su naučili taj dan. Kako bi se provjerilo koliko je znanje studenata povezano sa sadržajem toga sata ostalo u dugoročnome pamćenju³⁸⁵, dva tjedna kasnije proveden je odgođeni posttest.

Ispitivanje studenata provedeno je na mreži unutar virtualne učionice. Testovi se sastoje od pitanja s ponuđenim odgovorima i napravljeni su s pomoću Googleova obrasca, koji je omogućio automatsku pohranu odgovora u tablice, automatsko bodovanje točnih odgovora te izradu grafikona za odgovore svih studenata. Studentima je za rješavanje svakoga testa dano 20 minuta. Sadržaj testa može se podijeliti na tri dijela. U prvome dijelu ispituju se nazivi vozila (pitanja 1 – 17), u drugome dijelu dijelovi automobila (pitanja 18 – 28), u trećemu dijelu pravilni oblici imenica (pitanja 29 – 34) te u četvrtome dijelu značenje i razumijevanje glagola (pitanja 35 – 47). Svako pitanje nosi jedan bod te nema negativnih bodova. Student ne može predati prazan odgovor na pitanje te mora odabrati jedan od ponuđenih odgovora. Prva dva dijela testa sadržavaju slike te se ispod slika nalaze definicije iz *Mrežnika*. Kod pitanja koja se odnose na dijelove automobila u predtestu moguće je da vozači imaju malu prednost pred nevozačima jer bolje poznaju dijelove automobila. Ipak, riječ je o najčešćim nazivima za koje se može

³⁸⁴ Nakon što osoba primi informaciju preko svojih senzora, ona dolazi u kratkoročno pamćenje. U kratkoročnome pamćenju osoba može zadržati informaciju koliko je god dugo smatra potrebnom. Ako se osoba ne služi informacijom iz kratkoročnoga pamćenja te je ne interpretira da bude smisljena, onda je privremeno zaboravlja (Zarevski, 1995: 14).

³⁸⁵ Ako korisnik počne primjenjivati informaciju te je može pohraniti u obliku koji može kasnije pronaći za daljnju uporabu, onda se ta informacija pohranjuje u dugoročno pamćenje. Dugoročno pamćenje mora biti dobro organizirano jer ga ne možemo brzo pregledati kao kratkoročno pamćenje kod traženja potrebnih informacija (Zarevski, 1995: 14, 17).

pretpostaviti da ih na materinskome jeziku poznaju i nevozači. Dijelovi automobila uvršteni su u istraživanje jer se nalaze u udžbeniku te se obrađuju po nastavnome planu i programu. Slike u testu preuzete su s interneta te su pronađene s pomoću Googleove tražilice s uključenim filtrom da slike nisu zaštićene autorskim pravom (sadržavaju oznaku *Označeno za ponovnu upotrebu s izmjenama*). Cijeli test nalazi se u prilogu 7. *Test za studente s Croaticuma*.

7.5. Provedba nastave

Prvi sat s eksperimentalnom skupinom proveden je 6. travnja 2020. Nastava se provodila na mreži s pomoću programa Zoom. Autor je sudjelovao na nastavi kao promatrač, nastavu je vodila nastavnica koja inače predaje toj skupini. Sa studentima se komuniciralo s pomoću mikrofona i kamere. Poveznice na igre, testove i upitnik nastavnica je poslala studentima s pomoću grupnoga *chata*³⁸⁶ u programu Zoom. Na početku sata nastavnica je studentima poslala poveznicu na predtest te im je dala 20 minuta da ga riješe. Studente je zamolila da ne pretražuju internet te da ne gledaju u udžbenik kako bi pronašli rješenja. Nakon što je i posljednji student predao test, nastavnica je s pomoću PowerPoint prezentacije upoznala studente s vozilima i dijelovima automobila. Nakon toga studenti su samostalno igrali ove igre: *Pamtilica za prometna vozila*³⁸⁷ (vidi sliku 41), *Dijelovi automobila (igra dovlačenja)*³⁸⁸ (vidi sliku 36) te *Kviz dijelovi automobila*³⁸⁹ (vidi sliku 45). Kviz je svih deset studenata odigralo do kraja, ali je samo četvero studenata odlučilo predati svoj rezultat za ljestvicu poretka. Ti su studenti u prosjeku ostvarili 90 % točnih odgovora. Igra dovlačenja nema ljestvicu poretka. Kod igre pamtilice za vozila nijedan student nije odabrao razinu s 12 parova za spajanje, nego su odabrali lakše razine s 8 ili 4 para. Nakon što su odigrali igre imali su stanku od 10 minuta.

³⁸⁶ *Chat* ili brbljaonica virtualni je prostor na mreži u kojemu korisnici mogu razgovarati s pomoću vlastitih računalnih uređaja. Komunicira se korištenjem tekstem (Panian, 2005a: 86).

³⁸⁷ URL: <https://borna12.github.io/croaticum/pamtilica-prjevozna-sredstva/> (7. 4. 2020.)

³⁸⁸ URL: <https://borna12.github.io/croaticum/dijelovi-automobila.html> (6. 4. 2020.)

³⁸⁹ URL: <https://borna12.github.io/croaticum/kviz-dijelovi-auta/index.html> (23. 4. 2020.)

Slika 45. Kviz za dijelove automobila

Nakon stanke nastavnica je sa studentima razgovarala o značenjima glagola. Nakon toga studenti su odigrali igre *Kviz – značenje glagola*³⁹⁰ te *Glagoli igra dovlačenja*³⁹¹. U kvizu za glagole postoje dvije razine (vidi sliku 46). Na prvoj razini napiše se značenje glagola te student mora od četiriju ponuđenih glagola odabrati onaj koji smatra pravilnim. Na drugoj razini napiše se glagol te za njega student mora pogoditi značenje, dakle zadatak je obrnut od onoga na prvoj razini. Svaki je glagol u objema razinama prikazan slikom. Petero studenta predalo je svoje rezultate za prvu razinu kviza te su po prosjeku ostvarili oko 83 % točnih odgovora. Troje studenata predalo je svoje rezultate za drugu razinu kviza, u kojoj su ostvarili 75 % točnih odgovora. Studenti koji su predali rezultate isti su studenti koji su predali rezultate igre *Kviz dijelovi automobila*. Troje studenata koji su predali rezultate igre na posttestu ostvarili su 94 % ili više točnih odgovora.

³⁹⁰ URL: <https://bornal2.github.io/croatium/kviz-glagoli/index.html> (23. 4. 2020.)

³⁹¹ URL: <https://bornal2.github.io/croatium/glagoli-dovlacenje/index.html> (23. 4. 2020.)

Slika 46. Pitanje u igri Kviz – značenje glagola

Druga igra u kojoj se uvježbavaju glagoli *Glagoli igra dovlačenja* ima također dvije razine (vidi sliku 47). Prva se razina odnosi na glagole u jednini, a druga na glagole u množini. U igri se prikazuju dva glagola koji se trebaju dovući u odgovarajuću rečenicu kako bi ta rečenica imala smisla. Kad se glagol dovuče u odgovarajuće polje, pojavi se njegova definicija. Studenti su riješili obje razine.

Zahvaljujem obitelji na podršci.

Zahvaljivati znači izražavati zahvalnost.

Ne smetam prijatelju dok uči.

Slika 47. Pitanje u igri Glagoli igra dovlačenja

Posljednjih pola sata nastave eksperimentalna skupina ispunila je posttest te upitnik koji se odnosi na zadovoljstvo igrama (opisano u poglavlju *Zadovoljstvo igrama u eksperimentalnoj skupini*). Iduće nastavne sate do odgođenoga posttesta autor nije sudjelovao na nastavi, ali mu je nastavnica rekla da su obrađivali nove nastavne sadržaje s malo ponavljanja. U ponavljanju se nisu koristili nikakvim igrama kako to ne bi utjecalo na rezultate odgođenoga posttesta.

Odgođeni posttest proveden je 20. travnja 2020. Autor je bio prisutan samo na početku sata kad se provodilo testiranje te je nakon toga napustio nastavu.

Prvi sat s kontrolnom skupinom proveden je 8. travnja 2020., dva dana nakon sata s eksperimentalnom skupinom. Nastava se također provodila s pomoću programa Zoom. Autor je sudjelovao kao promatrač na nastavi kontrolne skupine. Obrađen je potpuno isti sadržaj kao u eksperimentalnoj skupini. Na početku sata i studenti kontrolne skupine imali su 20 minuta da riješe predtest. Nastavnica se također koristila prezentacijom u PowerPointu, koja je drukčija od prezentacije u eksperimentalnoj skupini, ali obuhvaća identične sadržaje, u kojoj je objasnila nazive dijelova automobila i vozila te je ispitivala studente i razgovarala s njima o značajkama vozila. Također su razgovarali o značenjima odabranih glagola. Posljednjih pola sata nastave,

kao i u eksperimentalnoj skupini, studenti su rješavali posttest i upitnik povezan s njihovim sociodemografskim podacima. Nažalost, zbog tehničkih problema dvoje studenata nije uspjelo na mreži predati rezultate posttesta i nije bilo vremena da ga ponovno ispune pa to dvoje studenata nije uvršteno u daljnju analizu. Kao i u eksperimentalnoj skupini do odgođenoga posttesta autor nije sudjelovao u nastavi, ali nastavnica spominje da su radili obradu novih nastavnih sadržaja i malo ponavljali staro gradivo. Nakon dvaju tjedana, 22. travnja 2020., na početku sata studenti su riješili odgođeni posttest.

7.6. Uzorak studenata

Uzorak obuhvaća 21 studenta koji je u akademskoj godini 2019./2020. pohađao nastavu u Croaticumu te ima A2 razinu znanja hrvatskoga jezika. Dvanaest studenata pripada kontrolnoj skupini, a devet studenata eksperimentalnoj skupini. U kontrolnoj skupini na početku je sudjelovalo 15 studenata, ali dvoje studenata na prvome satu nije predalo posttest, a jedna studentica na drugome satu nije predala odgođeni posttest. U eksperimentalnoj skupini na početku je trebalo biti dvanaest studenata, ali dvoje nije bilo na prvome satu. Jedan student eksperimentalne skupine za 8 je bodova lošije napisao prvi posttest od predtesta te je odgođeni posttest napisao za 7 bodova lošije od predtesta (predtest 32 boda, posttest 24 boda i odgođeni posttest 25 bodova). Taj je student u posttestu i odgođenome posttestu napravio različite pogreške u posljednjih 10 pitanja od kojih je na većinu pitanja točno odgovorio u predtestu, pa je moguće da je nasumično birao odgovore jer se žurio da što prije završi. Budući da njegovi rezultati bitno odudaraju od rezultata ostalih studenata te zato što narušava prosjek eksperimentalne skupine kategoriziran je kao stršeća ili ekstremna vrijednost (engl. *outliers*)³⁹² te njegovi rezultati nisu uvršteni u analizu.

Na kraju prvoga sata studenti su dobili upitnik napravljen s pomoću Googleova obrasca koji prikuplja sociodemografske podatke o studentima poput spola, dobi, zemlje podrijetla, materinskoga jezika i poznavanja drugih jezika. Dodatno je ispitano služe li se studenti mrežnim rječnicima pri učenju hrvatskoga jezika, vole li elektroničke igre te jesu li se prije koristili nekim obrazovnim igrama ili sustavima za učenje jezika. Studente eksperimentalne skupine dodatno se pitalo o njihovu zadovoljstvu igrama s prvoga sata (vidi poglavlje *Zadovoljstvo igrama korištenim na satu kod eksperimentalne skupine*). Pitanja i objašnjenja upitnika napisana su na hrvatskome i engleskome (cijeli upitnik nalazi se u prilogu *Upitnik za prikupljanje podataka o*

³⁹² Ekstremna ili stršeća vrijednost (engl. *outliers*) podatak je čija vrijednosti previše odstupa od vrijednosti ostalih podataka koji se proučavaju u istraživanju. Zbog toga se ekstremne vrijednosti često ne uvrštava u statističke analize kako ne bi iskrivili stvarne rezultate (Frost, 2019a).

studentima s Croaticuma). Većina uzorka u objema skupinama sačinjavaju studentice (6 u eksperimentalnoj i 9 u kontrolnoj skupini). Kontrolna i eksperimentalna skupina imaju jednak broj studenata (3) (vidi tablicu 45).

Tablica 45. *Broj studenata u skupinama*

	studenti	studentice	ukupno
kontrolna skupina	3	9	12 (57 %)
eksperimentalna skupina	3	6	9 (43 %)
ukupno	6 (29 %)	15 (71 %)	21

U kontrolnoj skupini svi studenti imaju između 20 i 43 godina, a u eksperimentalnoj skupini između 20 i 39 godina. Studenti kontrolne skupine u prosjeku su malo stariji nego studenti eksperimentalne skupine jer ima više studenata koji pripadaju generaciji X³⁹³, a manje koji pripadaju generaciji Z³⁹⁴. Jedan student kontrolne skupine pripada generaciji Z, osmero ih pripada milenijalcima³⁹⁵, a troje ih pripada generaciji X.

U eksperimentalnoj skupini troje studenata pripada generaciji Z, petero ih pripada milenijalcima i jedan pripada generaciji X. Time unutar obiju skupina najviše ima milenijalaca (13), a studenata koji pripadaju generaciji Z i generaciji X u cijelome je uzorku jednako (4) (vidi tablicu 46 te grafikone 17 i 18).

³⁹³ Generacija X naziv je za generaciju rođenih od 1965. do 1980. Prethode im *baby boomeri*, a nasljeđuju ih milenijalci. Generacija X rođena je i odrasla u razdoblju kada je *hip-hop* i *grunge* postao popularan tip glazbe te je većina njih odrasla uz MTV program koji je puštao glazbene spotove, što im je dalo i dodatan naziv *MTV generacija* (Dimock, 2019).

³⁹⁴ Generacija Z naziv je za generaciju rođenih u rasponu od 1997. do 2012. Prethode im milenijalci, a nasljeđuje ih generacija alfa. Generacija Z rođena je i odrasla u razdoblju interneta te većina njihova znanja dolazi s interneta (Dimock, 2019).

³⁹⁵ Milenijalci su generacija rođenih od 1981. do 1996. Prethodi im generacija X, a nasljeđuje ih generacija Z. Milenijalci su generacija koja je odrasla u vrijeme nagloga razvoja informacijsko-komunikacijske tehnologije te se većina njih bez problema zna koristiti tehnologijom, internetom i društvenim mrežama (Dimock, 2019).

Tablica 46. Broj studenata po generacijama u skupinama

	generacija Z	mladenjanci	generacija X
kontrolna skupina	1	8	3
eksperimentalna skupina	3	5	1
ukupno	4 (19 %)	13 (62 %)	4 (19 %)

Grafikon 17. Studenti kontrolne skupine po dobi

Grafikon 18. Studenti eksperimentalne skupine po dobi

U kontrolnoj skupini sedmero je studenata iz Južne Amerike (dvoje je studenata iz Argentine, dvoje iz Brazila, dvoje iz Venezuele, a jedan je student iz Čilea), dvoje je studenata iz Kanade, jedan je student iz Mongolije i dvoje je studenata iz Europe, za razliku od eksperimentalne skupine koja nema studenata iz Europe. Od tih dvoje studenata jedan je iz Ukrajine, a drugi iz Španjolske. U eksperimentalnoj skupini troje je studenata iz Južne Koreje, četvero ih je iz Južne Amerike (po jedan student iz Čilea, Perua, Venezuele, Bolivije), jedan je student iz Australije te jedan iz Mauritanije. Dakle, u obje je skupine najviše studenata (11) iz Južne Amerike (u prilogu *Studenti po zemlji podrijetla* može se u tablici vidjeti broj studenata s obzirom na zemlju podrijetla u svakoj skupini).

U kontrolnoj skupini većini studenata iz Južne Amerike materinski je jezik španjolski (6). Studentima iz Brazila materinski je jezik portugalski (2). Student iz Kanade naveo je engleski (1) kao materinski jezik. Student iz Ukrajine kao materinski jezik naveo je ruski (1). Svi studenti obrazovali su se na svojim materinskim jezicima. Student iz Kanade naveo je i francuski uz engleski kao jezik obrazovanja, a student iz Ukrajine i ukrajinski uz ruski.

Svi studenti eksperimentalne skupine obrazovali su se na svojim materinskim jezicima. Budući da je četvero od devet studenata eksperimentalne skupine iz Južne Amerike, najčešći je materinski jezik tih studenata također španjolski (4). Kod ostalih studenata unutar skupine materinski je jezik korejski (3), arapski (1) i engleski (1) (vidi tablicu 47). Nijedan od materinskih jezika studenata eksperimentalne skupine ne pripada slavenskima jezicima. Studenti iz Koreje naveli su da su se obrazovali i na engleskome jeziku, a student iz Mauritanije naveo je i francuski jezik.

Tablica 47. *Materinski jezik studenata*

	španjolski	korejski	arapski	engleski	portugalski	ruski	mongolski
kontrolna skupina	6	0	0	2	2	1	1
eksperimentalna skupina	4	3	1	1	0	0	0
ukupno	10 (48 %)	3 (14 %)	1 (5 %)	3 (14 %)	2 (9 %)	1 (5 %)	1 (5 %)

U kontrolnoj skupini svi studenti (12) odgovorili su da znaju engleski, dvoje studenata odgovorilo je da znaju njemački te ih je još dvoje odgovorilo da zna francuski i japanski. Student iz Španjolske odgovorio je da zna i portugalski. Nijedan od studenata kontrolne skupine nije napisao da zna hrvatski unatoč tomu što imaju osnovno znanje (A1 su razinu svladali).

U eksperimentalnoj skupini sedam studenata, ne računajući studenta iz Australije, navelo je da zna i engleski jezik. Jedan je student naveo da zna malo njemački, jedan da zna japanski i jedan da zna kineski. Dvoje studenata napisalo je da znaju i hrvatski (vidi tablicu 48).

Tablica 48. *Poznavanju drugih jezika*

	francuski	engleski	njemački	japanski	kineski	hrvatski	portugalski
kontrolna skupina	2	12	2	2	0	0	1
eksperimentalna skupina	1	7	1	1	1	2	0
ukupno	3 (14 %)	19 (90 %)	3 (14 %)	3 (14 %)	1 (5 %)	2 (9 %)	1 (5 %)

Većina studenata kontrolne skupine, njih sedmero, ocijenilo je svoje znanje hrvatskoga jezika ocjenom *dovoljan*. Troje ih se ocijenilo ocjenom *dobar* te se jedan student ocijenio ocjenom *vrlo dobar* i jedan ocjenom *odličan*.

Nijedan student eksperimentalne skupine nije ocijenio svoje znanje hrvatskoga jezika ocjenom *odličan*. Četvero studenata ocijenilo je svoje znanje ocjenom *dobar*, a četvero ocjenom *dovoljan*. Jedan student ocijenio je svoje znanje ocjenom *nedovoljan*, a jedan ocjenom *vrlo dobar*. Dakle, najviše studenta obiju skupina (11) ocijenilo je svoje trenutačno znanje hrvatskoga jezika ocjenom *dovoljan* (vidi tablicu 49).

Tablica 49. *Samoprocjena znanja hrvatskoga jezika*

	nedovoljan	dovoljan	dobar	vrlo dobar	odličan
kontrolna skupina	0	7	3	1	1
eksperimentalna skupina	1	4	3	1	0
ukupno	1 (5 %)	11 (52 %)	6 (28 %)	2 (10 %)	1 (5 %)

Dodatna su pitanja na kraju upitnika za studente obiju skupina bila koriste li se mrežnim rječnicima za učenje hrvatskoga jezika, vole li igrati elektroničke igre te jesu li ikada igrali obrazovne elektroničke igre ili se koristili sustavima za učenje jezika (npr. Duolingo, Rosetta Stone itd.). Ako na posljednje pitanje odgovore s *da*, tražilo ih se da upišu nazive igara ili sustava za učenje jezika.

U kontrolnoj skupini deset od dvanaest studenata (sedam studentica i troje studenata) navelo je da se koriste mrežnim rječnicima pri učenju hrvatskoga jezika, od kojih su sedam milenijalci, dvoje iz generacije X i jedan iz generacije Z.

Sedmero od devet studenata eksperimentalne skupine navelo je da se služi mrežnim rječnicima (četiri studenta i tri studentice) za učenje hrvatskoga rječnika, od kojih ih šestero po dobi pripada milenijalcima i jedan pripada generaciji Z (vidi tablicu 50).

Tablica 50. *Korištenje mrežnim rječnicima za učenje hrvatskoga jezika*

	Koristite li se mrežnim rječnicima za učenje hrvatskoga jezika?	
ponuđeni odgovori	da	ne
kontrolna skupina	10	2
eksperimentalna skupina	7	2
ukupno	17 (81 %)	4 (19 %)

U kontrolnoj skupini na pitanje vole li igrati elektroničke igre pola njih (šestero) odgovorila je *s ni da ni ne*. Petero ih je odgovorilo da vole igrati elektroničke igre, a jedan je odgovorio da ne voli igrati elektroničke igre.

U eksperimentalnoj skupini šestero studenata navelo je da voli elektroničke igre, jedna osoba spomenula je da ne voli elektroničke igre, a troje ih je odgovorilo je *s ni da ni ne* (vidi tablicu 51).

Dob i spol u objema skupinama nisu bili presudan čimbenik za to vole li igrati elektroničke igre.

Tablica 51. *Mišljenje studenata o elektroničkim igrama*

	Vole li elektroničke igre?		
ponuđeni odgovori	da	ne	ni da ni ne
kontrolna skupina	5	1	6
eksperimentalna skupina	6	0	3
ukupno	11 (52 %)	1 (5 %)	9 (43 %)

Šestero studenata (četiri studentice i dva studenta) kontrolne skupine, četiri milenijaca i dva

studenta generacije X, odgovorilo je s *da* na pitanje jesu li prije igrali obrazovne elektroničke igre za učenje jezika ili se koristili sustavima za učenje jezika, a ostali su odgovorili s *ne*. U eksperimentalnoj skupini na isto pitanje šestero studenta (tri studentice i jedan student), od kojih su svi milenijalci, odgovorilo je s *da*, a ostali su odgovorili s *ne* (vidi tablicu 52).

Tablica 52. Broj studenata koji su se koristili obrazovnim igrima i sustavima za učenje jezika

	Jeste li ikada igrali obrazovne elektroničke igre ili se koristili sustavima za učenje jezika (npr. Duolingo, Rosetta Stone itd.)?	
ponuđeni odgovori	da	ne
kontrolna skupina	6	6
eksperimentalna skupina	6	3
ukupno	12 (57 %)	9 (43 %)

Posljednje pitanje odnosi se na obrazovne sustave ili igre i nije obvezatno te se pojavljuje samo studentima koji su na prethodno pitanja odgovorili s *da*. Na to je pitanje odgovorilo 10 od 21 studenta (šest studenata kontrolne skupine i četiri studenta eksperimentalne skupine).

Od šestero studenata kontrolne skupine koji su odgovorili da su se prije koristili sustavima za učenje jezika ili obrazovnim igrima, troje ih je navelo Duolingo, jedan Memrise, jedan je spomenuo ruski sustav Puzzle English³⁹⁶ za učenje engleskoga jezika, jedan je naveo Facebookove igre za učenje jezika³⁹⁷, a jedan je student naveo da je igrao kvizove za učenje jezika, ali nije spomenuo koje.

Od četvero studenata eksperimentalne skupine koji su prije igrali obrazovne igre za učenje jezika te su se koristili sustavima za učenje jezika, svaki student odvojeno je napisao iduće sustave: Mondly³⁹⁸, Kahoot!, Socrative³⁹⁹ i Duolingo (vidi tablicu 53).

³⁹⁶ URL: <https://puzzle-english.com> (21. 4. 2020.)

³⁹⁷ URL: <https://www.facebook.com/games/instantgames/?category=420> (21. 4. 2020.)

³⁹⁸ URL: <https://www.mondly.com/> (20. 4. 2020.)

³⁹⁹ URL: <https://socrative.com/> (20. 4. 2020.)

Tablica 53. *Spomenute obrazovne igre te sustavi za učenje jezika*

	Jeste li ikada igrali obrazovne elektroničke igre ili se koristili sustavima za učenje jezika (npr. Duolingo, Rosetta Stone itd.)?							
sustav ili igra	Duolingo	Kahoot!	Mondly	Socrative	Memrise	Puzzle English	igre na Facebooku za učenje jezika	kvizovi za učenje jezika
kontrolna skupina	3	0	0	0	1	1	1	1
eksperimentalna skupina	1	1	1	1	0	0	0	0
ukupno	4 (19 %)	1 (5 %)	1 (5 %)	1 (5 %)	1 (5 %)	1 (5 %)	1 (5 %)	1 (5 %)

7.7. Zadovoljstvo igrama eksperimentalne skupine

Na satu su studenti eksperimentalne skupine odigrali ove igre: Pamtilica za prometna vozila, Kviz – značenja glagola, Glagoli igra dovlačenje, Kviz dijelovi automobila i Dijelovi automobila (igra dovlačenja). Prije stanke na prvome satu studenti su komentirali pamtilicu, igru dovlačenja dijelova automobila i kviz za dijelove automobila te su rekli da su im zabavne. Spomenuli su da im se sviđa pamtilica jer ih vraća u djetinjstvo. Pri kraju prvoga sata studenti su komentirali igre koje se odnose na glagole. Komentari na te igre također su bili pozitivni te su rekli da im se više sviđa kviz od igre dovlačenja. Dvoje studenata ostavilo je dva pozitivna komentara za cijeli nastavni sat: *Zašto ne možemo imati češće nastavu ovakvoga tipa?, Bilo je zabavno i naučio sam mnogo danas*. Nakon sata studenti su ispunili upitnik, a autor je komentirao sat s nastavnicom. Nastavnica je komentirala da bi bilo bolje da se upotrebljava više različitih pohvalnih pridjeva kad student točno odgovori na pitanja, a ne da se samo napiše točno te broj bodova. Studenti su odgovorili na pitanja mrežnoga upitnika napisanoga na engleskome i hrvatskome jeziku koji se odnosi na zadovoljstvo igrama sa sata (cijeli upitnik nalazi se u prilogu *Upitnik za studente eksperimentalne skupine s Croaticuma povezan sa zadovoljstvom igrama*). Studente se pitalo koliko igre sa sata smatraju jednostavnima za igranje, dobrim za učenje hrvatskoga jezika i zabavnim za igranje. Također, pitalo ih se i je li im draži ovaj oblik nastave u kojemu se uči s pomoću igara ili više vole raditi klasične vježbe, koja im je najdraža igra kojom se koristilo na satu te žele li igrati ove igre nakon nastavnoga sata. Osmero od devet studenata odgovorilo je da im se više sviđa ovakav oblik nastave u kojemu se igre kombiniraju s klasičnim oblikom nastave od rada samo klasičnim metodama. Jedan student

odgovorio je da mu je klasična nastava draža od nastave s igrama te je napisao komentar da igru dovlačenja glagola smatra prejednostavnom (vidi tablicu 54).

Tablica 54. *Odgovori studenata na pitanje o zadovoljstvu igrama*

	Je li vam draže na satu igrati ovakve igre nego raditi klasične vježbe?		
ponuđeni odgovori	da	ne	svejedno mi je
broj odgovora	8	1	0

Na temelju Likertove ljestvice⁴⁰⁰ pet studenata u potpunosti se slaže da su igre jednostavne za igranje, tj. lake za korištenje i da je potrebna niska razina znanja kako bi se naučile igrate. Troje ih se donekle slaže da su jednostavne, a jedan se student donekle ne slaže (vidi tablicu 55). Međutim, i taj je student u ostalim pitanjima odgovorio da mu se igre donekle sviđaju te da ih donekle smatra korisnima, pa je moguće da mu samo ovo pitanje nije bio jasno.

Tablica 55. *Odgovori studenata na pitanje o složenosti igara*

	Igre su jednostavne za igranje.				
ponuđeni odgovori	u potpunosti se slažem	donekle se slažem	niti se slažem, niti se ne slažem	donekle se ne slažem	u potpunosti se ne slažem
broj odgovora	5	3	0	1	0

Četvero studenata u potpunosti se slaže da su predložene igre dobre za učenje hrvatskoga jezika, troje ih se donekle slaže, a dvoje se niti slaže niti ne slaže (vidi tablicu 56).

⁴⁰⁰ Likertova ljestvica (engl. *Likert scale*) najčešće je primjenjivana ljestvica za mjerenje stavova. Za razvoj i primjenu ljestvice zaslužan je Renis Likert. Sastoji se od tvrdnja koje prate najčešće pet mogućih odgovora kojima se izražava stupanja slaganja i neslaganja (potpuno slaganje, slaganje, neodlučnost/neutralnost, neslaganje, potpuno neslaganje) (Hrvatska enciklopedija, 2013).

Tablica 56. *Odgovori studenata na pitanje o tome jesu li igre dobre za učenje hrvatskoga jezika*

	Igre su dobre za učenje hrvatskoga jezika.				
ponuđeni odgovori	u potpunosti se slažem	donekle se slažem	niti se slažem, niti se ne slažem	donekle se ne slažem	u potpunosti se ne slažem
broj odgovora	4	3	2	0	0

Petero studenata u potpunosti se slaže s time da su igre zabavne za igranje, troje ih se donekle slaže, a jedan se student niti slaže, niti ne slaže (isti student koji je i za prošlo pitanje bio neutralan) (vidi tablicu 57).

Tablica 57. *Odgovor studenata na pitanje o tome smatraju li igre zabavnima*

	Igre su zabavne za igranje.				
ponuđeni odgovori	u potpunosti se slažem	donekle se slažem	niti se slažem, niti se ne slažem	donekle se ne slažem	u potpunosti se ne slažem
broj odgovora	5	3	1	0	0

Najdražom igrom studenti smatraju *Pamtilicu za prometna vozila* i *Kviz – značenje glagola*. Za pamtilicu su studenti komentirali da im se sviđa jer ih vraća u djetinjstvo, a kviz s glagolima smatraju korisnim. Samo jedan student označio je da mu je najdraža igra *Dijelovi automobila (igra dovlačenja)* (vidi tablicu 58).

Tablica 58. *Najdraža igra studenata*

	Moja je najdraža igra sa sata...				
ponuđeni odgovori	Kviz – značenje glagola	Pamtilica za prometna vozila	Glagoli igra dovlačenja	Dijelovi automobila (igra dovlačenja)	Kviz dijelovi automobila
broj odgovora	4	4	0	1	0

Pet je studenata reklo da želi igrati igre nakon nastavnoga sata. Dvoje ih je reklo da to ne želi, a dvoje je odgovorilo s *možda* (vidi tablicu 59).

Tablica 59. *Odgovor studenata na pitanje žele li igrati igre nakon nastavnoga sata*

	Želite li igrati ove igre nakon nastavnoga sata?		
ponuđeni odgovori	da	ne	možda
broj odgovora	5	2	2

Dvoje studenta odgovorilo je na posljednje neobvezno pitanje koje se odnosi na primjedbe i savjete povezane s igrama. Jedan od njih bio je student koji je odgovorio da više voli klasične nastavne metode. Riječ je o studentu iz Australije koji ima 24 godina. Napisao je da smatra igru s dovlačenjem glagola prejednostavnom. Unatoč tomu, odgovorio je da smatra igre zabavnima, ali neutralan je oko toga koliko pomažu u učenju hrvatskoga jezika. Taj je student svoje znanje hrvatskoga jezika ocijenio ocjenom vrlo dobar te je među boljim studentima što se tiče rješavanja zadataka na testu iako nije najbolje riješio test u svojoj skupini (predtest 37 bodova, posttest 44 boda i odgođeni posttest 42 boda, svaki test ima 47 bodova). Ipak, nakon korištenja igrama poboljšao se njegov rezultat u posttestu i odgođenome posttestu. Kod pitanja koja se odnose na glagole imao je samo jednu pogrešku u predtestu, što dokazuje da dobro zna glagole, pa mu je vjerojatno stoga igra s glagolima bila prejednostavna. Drugi student koji je dao prijedlog odgovorio je na prethodna pitanja iz upitnika da se u potpunosti slaže da su igre zabavne, jednostavne i dobre za učenje hrvatskoga jezika, ali je napisao da bi možda bilo bolje da se upotrebljava više opisnih pridjeva (engl. *descriptive words*) za neke primjere.

7.8. Rezultati testova

7.8.1. Rezultati predtesta

Kontrolna skupina pisala je predtest 8. travnja 2020., a eksperimentalna skupina 6. travnja 2020. (pojedinačni rezultati svih testova nalaze se u prilogu *Rezultati studenata Croaticuma iz predtesta, posttesta i odgođenoga posttesta*). Studenti kontrolne skupine ostvarili su prosječno 38,08 bodova, a eksperimentalne 33,67 bodova (vidi tablicu 60). Time možemo vidjeti da su studenti kontrolne skupine na početku postigli bolje rezultate od studenata eksperimentalne skupine. U kontrolnoj skupini jedan je student ostvario 45 od 47 bodova, dok je u eksperimentalnoj skupini najbolji student ostvario 40 bodova. Nijedan student iz kontrolne skupine nije imao manje od 30 bodova, a u eksperimentalnoj skupini bilo je dvoje studenata koji su imali manje od 30 bodova (27 i 29).

Tablica 60. Opisna statistika za rezultate predtesta u obje skupine

	N	aritmetička sredina (prosjek)	medijan	mod	minimum	maksimum	raspon bodova
kontrolna skupina	12	38,08	38	39	30	45	15
eksperimentalna skupina	9	33,67	32	nema	27	40	13

Rezultati studenata eksperimentalne i kontrolne skupine razvrstani su u pet razreda na temelju raspona ostvarenih bodova na predtestu (vidi grafikon 19). Duljina raspona bodova za tih pet razreda određena je tako da se uzeo najveći rezultat koji je jedan student ostvario na testu (45) te je od njega oduzet najmanji rezultat (27) koji je student ostvario na testu. Dobiveni broj (18) nakon toga podijeljen je s brojem pet. Rezultat te jednadžbe (3,6) zaokružio se na cijeli broj te time razrede možemo razlikovati za četiri boda.

$$\text{duljina raspona za razrede} = \frac{45 - 27}{5} = 3,6 = 4$$

Studenti su na temelju ostvarenih bodova i duljine raspona time svrstani u idućih pet razreda: 27 – 30, 31 – 34, 35 – 38, 39 – 42, 43 – 46.

Grafikon 19. Raspon bodova studenata na predtestu

U nižim razredima između 27 – 30 (1), 31 – 34 (1) ima manje studenata kontrolne skupine od studenata eksperimentalne skupine, a u ostalim ih razredima ima više. Najviše studenta nalazi se u razredima 35 – 38 (4) i 39 – 42 (4). Čak dvoje studenta ima između 43 i 46 bodova. Možemo vidjeti da je najviše studenata (3) u eksperimentalnoj skupini ostvarilo između 27 i 30 bodova. Po dvoje studenata nalazi se u idućim razredima: 31 – 34, 35 – 38 i 39 – 42. Nijedan student nije ostvario između 43 i 46 bodova. Studenti eksperimentalne skupine tijekom prvoga sata komentirali su da su im pitanja iz testa srednje težine (rekli su *tako-tako*), a studenti kontrolne skupine nisu komentirali pitanja.

Kod eksperimentalne i kontrolne skupine gotovo svi studenti znali su prepoznati nazive vozila (94 % točnih odgovora kod kontrolne skupine i 88 % točnih odgovora kod eksperimentalne skupine). Većina pogrešaka u objema skupinama odnosila se na rijeđe korištena vozila, npr. žičaru, romobil, koturaljke i čamac. Kod pitanja koja se odnose na dijelove automobila bilo je više pogrešaka unutar obiju skupina (79 % točnih odgovora kod kontrolne skupine i 62 % kod eksperimentalne skupine). Većina studenata obiju skupina znala je prepoznati češće dijelove automobila, npr. vrata automobila, sjedalo, motor i retrovizor. U eksperimentalnoj skupini oko 50 % studenata (pet ili šest od devet studenata) znalo je što je pojas za vezanje, mjenjač brzina i volan. Manje je studenata (od dva do četiri) znalo prepoznati prtljažnik, kotač i ručnu kočnicu. Kod kontrolne skupine najviše je bilo pogrešaka u odgovoru na pitanje u kojemu se tražio kotač i ručna kočnica (pet od dvanaest studenata pogrešno je odgovorilo). Pitanja u kojima se tražio pravilan oblik imenica bila su teža studentima u objema skupinama (31 % točnih odgovora u kontrolnoj skupini i 43 % u eksperimentalnoj skupini), što nije čudno jer je riječ o morfološkoj razini koja može biti složena za neizvorne govornike hrvatskoga jezika. Riječ je o dijelu ispita koji su studenti eksperimentalne skupine riješili bolje od studenata kontrolne skupine. Najviše pogrešaka u objema skupinama bilo je na pitanjima 31 i 32 (vidi u prilogu *Test za studente s Croaticuma*). Pitanja povezana sa značenjem glagola obje su skupine mnogo bolje riješile nego pitanja koja se odnose na oblike imenica. Ta pitanja dijele se na pitanja u kojima iz definicije treba prepoznati glagol i obrnuto. Studenti obiju skupina postigli su nešto bolji rezultat u pitanjima u kojima su glagolu trebali pridružiti značenje nego u pitanjima u kojima se za značenje odabiru glagoli. U tablici 61 prikazani je postotak točnih odgovara i prosjek bodova u dijelovima pretesta za obje skupine.

Tablica 61. *Postotak točnih odgovara i prosjek bodova u dijelovima predtesta*

	vozila	dijelovi automobila	oblici imenica	značenje glagola	ukupno
broj pitanja i bodova	17	11	6	13	47
postotak točnih odgovora u kontrolnoj skupini	94 %	79 %	31 %	90 %	74 %
prosjeck bodova u kontrolnoj skupini	15,92	8,67	1,83	11,67	38,08
postotak točnih odgovora u eksperimentalnoj skupini	88 %	62 %	43 %	74 %	67 %
prosjeck bodova u eksperimentalnoj skupini	14,89	6,67	2,56	9,56	33,67

7.8.2. Rezultati posttesta

Studenti obje skupina pisali su posttest na kraju istoga sata na kojemu su pisali i predtest. Rezultati su očekivano bili bolji na posttestu za obje skupine te se razlika u rezultatima između kontrolne i eksperimentalne skupine smanjila (razlika je prosjeka između skupina za posttest 1,97, a u predtestu je 4,41). Prosjeck bodova kontrolne skupine 44,08, a eksperimentalne 42,11 (vidi tablicu 62). Eksperimentalna skupina, unatoč tomu što ima malo lošije rezultate od kontrolne skupine, ostvarila je veći napredak jer se njihov prosjeck bodova od predtesta povećao za 8,44, a kod kontrolne je prosjeck povećan za 6. Najveći napredak u eksperimentalnoj skupini vidi se kod studenata 5, 6, 7 i 8 jer je svaki od tih studenata ostvario 11 – 15 bodova više nego na predtestu. U kontrolnoj skupini najveći napredak ostvario student koji je napredovao za 14 bodova. U objema skupinama neki su studenti uspjeli sve točno riješiti.

Tablica 62. Opisna statistika za rezultate posttesta u objema skupinama

	N	aritmetička sredina (prosjek)	medijan	mod	minimum	maksimum	raspon bodova
kontrolna skupina	12	44,08	45	46	40	47	7
eksperimentalna skupina	9	42,11	42	44	37	47	10

Pri razvrstavanju rezultata u razrede na temelju raspona bodova koristilo se istim razredima kao i za predtest kako bi se lakše mogao vidjeti odnos između tih dvaju rezultata. Dodan je jedan novi razred 47 za studente koji su ostvarili sve bodove, ali su ukinuta prva dva razreda jer nijedan student nije ostvario manje od 37 bodova. Time se koristilo idućim četirima razredima za grupiranje studenata po ostvarenim bodovima: 35 – 38, 39 – 42, 43 – 46, 47 (vidi grafikon 20).

Grafikon 20. Raspon bodova studenata na posttestu

Svaki student kontrolne skupine ostvario je više od 90 % bodova jer je raspon bodova za tu skupinu između 40 i 47 bodova. Većina studenata (8) ima između 43 i 46 bodova, troje ih ima između 39 i 42 boda. Raspon je rezultata eksperimentalne skupine između 37 i 47 bodova, troje studenata ima između 39 i 42 boda te 43 i 46 bodova. Dva studenata imaju između 25 i 38

bodova. Treba napomenuti da je jedan student u eksperimentalnoj skupini riješio posttest lošije od predtesta (student 4 ostvario je 38 bodova, što je za jedan bod manje od predtesta), dok je ostalih osam studenata bolje napisalo posttest. U objema je skupinama po jedan student sve točno riješio (47).

U kontrolnoj skupini u pitanjima koja se odnose na nazive vozila bila je samo jedna pogreška kod jednoga studenta na pitanje koje se odnosi na bicikl. Eksperimentalna skupina pitanja povezana s vozilima bolje je napisala za 5 % u odnosu na predtest. Kod pitanja povezanih s dijelovima automobila u kontrolnoj skupini došlo je do napretka za 13 %, a u eksperimentalnoj za 17 %. Taj dio testa eksperimentalna je skupina bolje napisala od kontrolne iako je u predtestu kontrolna skupina bila bolja. Dio koji su obje skupine najslabije napisale odnosi se na oblike imenica, ali je tu došlo do najvećega poboljšanja u objema skupinama. Kontrolna skupina postigla je poboljšanje za 48 %, a eksperimentalna za 31 %. U predtestu taj dio testa bolje je napisala eksperimentalna skupina, a kontrolna je skupina bolje napisala taj dio testa u posttestu. Kod dijela testa koji se odnosi na značenje glagola kontrolna skupina napredovala je za samo 5 %, a u eksperimentalnoj je skupini došlo do napretka za 12 %. Sveukupan je postotak točnih odgovora kontrolne skupine 91 %, što je više od eksperimentalne skupine za 4 %. U tablici 63 prikazani je postotak točnih odgovora i prosjek bodova u dijelovima posttesta za obje skupine.

Tablica 63. Postotak točnih odgovora i prosjek bodova u dijelovima posttesta

	vozila	dijelovi automobila	oblici imenica	značenje glagola	ukupno
broj pitanja i bodova	17	11	6	13	47
postotak točnih odgovora u kontrolnoj skupini	99 %	92 %	79 %	95 %	91 %
prosijek bodova u kontrolnoj skupini	16,92	10,08	4,75	12,33	44,08
postotak točnih odgovora u eksperimentalnoj skupini	93 %	96 %	74 %	86 %	87 %
prosijek bodova u eksperimentalnoj skupini	15,89	10,56	4,44	11,22	42,11

7.8.3. Rezultati odgođenoga posttesta

Dva tjedna nakon posttesta studenti su pisali odgođeni posttest. Kontrolna ga je skupina pisala 22. travnja 2020., a eksperimentalna 20. travnja 2020. Rezultati odgođenoga posttesta u objema su skupinama bolji od rezultata predtesta. Početno očekivanje bilo je da će rezultati biti bolji u prvome posttestu nego u odgođenome posttestu, ali da će i dalje rezultati biti bolji od predtesta. Za prvi posttest očekivalo se da će biti malo bolji rezultati jer su ga studenti pisali odmah nakon što su naučili gradivo, pa im je znanje bilo svježije. Nakon dva tjedna tijekom kojih su obje skupine uglavnom radile nove nastavne sadržaje moglo se očekivati da će dio prethodno naučenoga nastavnog sadržaja zaboraviti. Unatoč tomu, u kontrolnoj skupini rezultati odgođenoga posttesta malo su bolji od rezultata prvoga posttesta (prosjeak bolji za 0,33, a od predtesta za 6,34), a u eksperimentalnoj skupini malo su lošiji od rezultata prvoga posttesta (prosjeak slabiji za 1,33), ali su zato i dalje bolji nego kod predtesta (prosjeak bolji za 7,11). Prosjeak je bodova kontrolne skupine 44,42, a eksperimentalne skupine 40,78. Najčešća je vrijednost bodova u objema skupinama 46 bodova (dvoje studenta eksperimentalne skupine i četiri studenta kontrolne skupine 7,41). Jedan je student u kontrolnoj skupini (student 10) sve zadatke točno riješio (47 bodova), a najlošiji rezultat ostvario je student eksperimentalne skupine (student 2) koji je ostvario 35 bodova (vidi tablicu 64).

Tablica 64. *Opisna statistika za rezultate odgođenoga posttesta u objema skupinama*

	N	aritmetička sredina (prosjeak)	medijan	mod	minimum	maksimum	raspon bodova
kontrolna skupina	12	44,42	45	46	40	47	7
eksperimentalna skupina	9	40,78	40	46	35	46	11

Kao i u predtestu i posttestu studenti su razvrstani po razredima na temelju raspona bodova. Razvrstani su u iduća četiri razreda: 35 – 38, 39 – 42, 43 – 46, 47 (vidi grafikon 21).

Grafikon 21. *Raspon bodova studenata u odgođenome posttestu*

U kontrolnoj skupini najviše studenata (8) ostvarilo je između 43 i 46 bodova. U eksperimentalnoj skupini u istome rasponu bodova nalazi se troje studenata, ali više studenata eksperimentalne skupine (4) ostvarilo je između 39 i 42 boda. U kontrolnoj skupini ponovno je jedino jedan student (student 10) ostvario 47 bodova, ali nije riječ o istome studentu koji je imao sve bodove u prvome posttestu (student 9). U eksperimentalnoj skupini nitko nije ostvario sve bodove, a u kontrolnoj skupini nitko nije ostvario manje od 40 bodova (zato ih nema u rasponu od 35 do 38 bodova). Student kontrolne skupine koji je najlošije riješio odgođeni posttest imao je 85 % točnih odgovora (40 bodova). Student eksperimentalne skupine (student 4) koji je lošije napisao prvi posttest od predtesta za jedan bod, u odgođenome posttestu imao je jednak broj bodova kao i u predtestu (39). Točni i pogrešni odgovori uglavnom su isti, što znači da mu je razina znanja ostala približno ista u svim trima testovima.

Kod pitanja koja se odnose na vozila nema velikih promjena u rezultatima, jedino je eksperimentalna skupina u odnosu na prvi posttest lošija za 1 bod, a kontrolna skupina ima jednak broj bodova. Najveći pomak u rezultatima u kontrolnoj skupini može se vidjeti u pitanjima povezanim s dijelovima automobila (odgovori bolji za 6 %). Odgovori na pitanja koja se odnose na značenje glagola i oblike imenica u objema skupinama malo su lošiji nego u prvome posttestu. U tablici 65 prikazani je postotak točnih odgovara i prosjek bodova u dijelovima odgođenoga posttesta za obje skupine.

Tablica 65. *Postotak točnih odgovara i prosjek bodova u dijelovima odgođenoga posttesta*

	vozila	dijelovi automobila	oblici imenica	značenje glagola	ukupno
broj pitanja i bodova	17	11	6	13	47
postotak točnih odgovora u kontrolnoj skupini	99 %	98 %	76 %	93 %	92 %
prosjeak točnih odgovora u kontrolnoj skupini	16,8	10,8	4,66	12,16	44,42
postotak točnih odgovora u eksperimentalnoj skupini	92 %	89 %	72 %	85 %	85 %
prosjeak točnih odgovora u eksperimentalnoj skupini	15,67	9,78	4,33	11,00	40,78

7.8.4. Sociodemografske usporedbe rezultata

7.8.4.1. Usporedba rezultata na temelju spola

Kad bismo analizirali rezultate na temelju spola, kod svih studenata neovisno o skupini možemo iz tablice 66 vidjeti da studentice ostvaruju bolji prosjek bodova u posttestu i odgođenome posttestu, ali ne i na predtestu. U nijednome testu studenti nisu ostvarili sve bodove (47).

Tablica 66. *Opisna statistika rezultata studenata i studentica eksperimentalne i kontrolne skupine u predtestu*

	predtest		posttest		odgođeni posttest	
	M	Ž	M	Ž	M	Ž
broj studenata	7	14	7	14	7	14
aritmetička sredina (prosjeak)	36,29	36,14	41,71	44	41,86	43,36
medijan	37	37	42	44	42	44,5

	predtest		posttest		odgođeni posttest	
	M	Ž	M	Ž	M	Ž
mod	39	37	37	46	42	46
minimum	30	27	37	40	35	37
maksimum	42	45	46	47	46	47
raspon bodova	12	18	9	7	11	10

Ako gledamo rezultate kontrolne skupine, možemo vidjeti da su studentice bile bolje u svim trima testovima (vidi tablicu 67).

Tablica 67. Opisna statistika za rezultate studenata i studentica kontrolne skupine u predtestu, posttestu i odgođenome posttestu

	predtest		posttest		odgođeni posttest	
	M	Ž	M	Ž	M	Ž
broj studenata	4	8	4	8	4	8
aritmetička sredina (prosjeak)	37	38,63	43,25	44,5	44,25	44,5
medijan	37,5	38	43,5	46	44,5	45,5
mod	31	37	40	46	42	46
minimum	31	30	40	40	42	40
maksimum	42	45	46	47	46	47
raspon bodova	11	15	6	7	4	7

Ako gledamo rezultate samo eksperimentalne skupine, možemo vidjeti da su studenti bili bolji od studentica u predtestu, ali su u posttestu i odgođenome posttestu studentice bile bolje (vidi tablicu 68).

Tablica 68. Opisna statistika za rezultate studenata i studentica eksperimentalne skupine u predtestu, posttestu i odgođenome posttestu

	predtest		posttest		odgođeni posttest	
	M	Ž	M	Ž	M	Ž
broj studenata	3	6	3	6	3	6
aritmetička sredina (prosjeak)	35,33	32,83	39,67	43,33	38,67	41,83
medijan	37	31,5	38	43	39	41,5
mod	30	27	37	42	35	46
minimum	30	27	37	41	35	37
maksimum	39	40	44	47	42	46
raspon bodova	9	13	7	6	7	9

7.8.4.2. Usporedba rezultata na temelju dobi

Imamo tri generacije studenata u skupinama: generacija Z, milenijalci i generacija X. Usporedbom bodova na temelju generacija možemo vidjeti da studenti generacije X imaju najbolji ostvareni prosjek u svim trima testovima. Sva tri testa na temelju prosjeka najlošije su napisali studenti generacije Z, ali razlika u prosjeku bodova na posttestu i odgođenome posttestu nije velika između njih i milenijalaca (vidi tablicu 69).

Tablica 69. Opisna statistika za rezultate studenata obiju skupina na temelju generacija u predtestu, posttestu i odgođenome posttestu

	predtest			posttest			odgođeni posttest		
	gen. Z	milen.	gen. X	gen. Z	milen.	gen. X	gen. Z	milen.	gen. X
broj studenata	4	13	4	4	13	4	4	13	4
aritmetička sredina (prosjeak)	33	36,23	39,25	42	43,15	44,75	42	42,23	45,75
medijan	31	37	37,5	42	44	45	43,5	42	46
mod	30	39	37	37	46	42	35	42	46

	predtest			posttest			odgođeni posttest		
	gen. Z	milen.	gen. X	gen. Z	milen.	gen. X	gen. Z	milen.	gen. X
minimum	30	27	37	37	38	42	35	37	45
maksimum	40	44	45	47	46	47	46	47	46
raspon bodova	10	17	8	10	8	5	11	10	1

U kontrolnoj skupini najbolje rezultate ostvarili su najstariji studenti koji pripadaju generaciji X. Najmlađi student kontrolne skupine pripada generaciji Z te je taj student ostvario najlošije rezultate na predtestu i posttestu, ali je odgođeni posttest napisao jednako dobro kao milenijalci (vidi tablicu 70).

Tablica 70. Opisna statistika za studente kontrolne skupina na temelju generacije u predtestu, posttestu i odgođenome posttestu

	predtest			posttest			odgođeni posttest		
	gen. Z	milen.	gen. X	gen. Z	milen.	gen. X	gen. Z	milen.	gen. X
broj studenata	1	8	3	1	8	3	1	8	3
aritmetička sredina (prosjeak)	30	38,5	39,67	40	44	45,67	44	44	45,67
medijan	30	39	37	40	45,5	46	44	44,5	46
mod	30	36	37	40	46	44	44	42	46
minimum	30	31	37	40	40	44	44	40	45
maksimum	30	44	45	40	46	47	44	47	46
raspon bodova	0	13	8	0	6	3	0	7	1

U eksperimentalnoj skupini samo je jedan student iz generacije X, ali je taj student u predtestu i odgođenome posttestu ostvario bolje rezultate od studenata iz generacije Z i milenijalaca. Prvi posttest najbolje su napisali studenti generacije Z. Generacija Z eksperimentalne skupine bolje je napisala predtest i posttest od studenta generacije Z koji pripada kontrolnoj skupini, ali je onda taj student bolje napisao odgođeni posttest od studenata iste generacije koji se nalaze u

eksperimentalnoj skupini. Milenijalci su u eksperimentalnoj skupini najlošije napisali sva tri testa (vidi tablicu 71).

Tablica 71. *Opisna statistika za studente eksperimentalne skupine na temelju generacije u predtestu, posttestu i odgođenome posttestu*

	predtest			posttest			odgođeni posttest		
	gen. Z	milen.	gen. X	gen. Z	milen.	gen. X	gen. Z	milen.	gen. X
broj studenata	3	5	1	3	5	1	3	5	1
aritmetička sredina (prosjeak)	34	32,6	38	42,67	41,8	42	41,33	39,4	46
medijan	32	31	38	44	42	42	43	39	46
mod	30	27	38	37	44	42	35	39	46
minimum	30	27	38	37	38	42	35	37	46
maksimum	40	39	38	47	44	42	46	42	46
raspon bodova	10	12	0	10	6	0	11	5	0

7.8.5. Metodologija

Korištenjem statističkim testovima⁴⁰¹ na rezultatima predtesta, posttesta i odgođenoga posttesta možemo vidjeti je li došlo do statistički značajnih razlika⁴⁰² kod studenata eksperimentalne i kontrolne skupine. Kako bismo znali kojim bi se tipom statističkoga testa trebalo koristiti da bismo dobili valjane rezultata, važno je uzeti u obzir raspodjelu rezultata dobivenih u istraživanju te veličinu uzorka (Foley, 2018). Provjerava se jesu li bodovi normalno raspodijeljeni⁴⁰³ u objema skupinama kod predtesta, posttesta i odgođenoga posttesta s pomoću

⁴⁰¹ Statistički test određuje mehanizme za izradu kvantitativnih odluka o procesima. Cilj je testa odrediti postoji li dovoljno dokaza da se opovrgne ili dokaže postavljena pretpostavka ili hipoteza o određenome procesu ili pojavi. U slučaju da se rezultatima ne opovrgne hipoteza, dokazujemo da je hipoteza istinita te možemo dalje vjerovati u nju. Do opovrgavanja hipoteze u nekim slučajevima dolazi zbog nedovoljno prikupljenih podataka. Statistički testovi dijele se na parametrijske i neparametrijske (Kaur i Kumar, 2015: 336).

⁴⁰² Ako se rezultat dobiven obradom podataka smatra statistički značajnim, to znači da vjerojatno nije dobiven slučajno, nego je prouzrokovan povezanošću između dviju ili više varijabla (Kenton, 2020a).

⁴⁰³ Normalna ili Gaussova raspodjela funkcija je vjerojatnosti koja opisuje kako su vrijednosti varijable raspodijeljene. Riječ je o simetričnoj raspodjeli u kojoj se većina vrijednosti grupira oko središnjega vrha, a za ostale vrijednosti koje se nalaze dalje od središnjega vrha pretpostavlja se da su jednake u obama smjerovima (Frost, 2018).

Shapiro-Wilkova testa⁴⁰⁴ s razinom značajnosti (α) 0,05⁴⁰⁵. Za svaki test provjeravamo nultom hipotezom⁴⁰⁶ da su rezultati normalno raspodijeljeni, što doznajemo ako je p-vrijednost⁴⁰⁷ veća od 0,05, a u suprotnome ako je p-vrijednost manja ili jednaka 0,05, onda prihvaćamo alternativnu hipotezu da nam rezultati nisu normalno raspodijeljeni. p-vrijednosti zajedno s W-vrijednostima⁴⁰⁸ iz Shapiro-Wilkova testa dobivene su s pomoću programskoga jezika R⁴⁰⁹ u programu R studio⁴¹⁰. U tablici 72. napisan je kod za dobivanje željenih rezultata jednoga testa skupine.

Tablica 72. Kod za dobivanje rezultata Shapiro-Wilkova testa kod predtesta kontrolne skupine

```
x<-c(30,31,36,36,37,37,39,39,41,42,44,45)
shapiro.test(x)
```

Taj kod ponovimo za svaki test koji su pisale obje skupina te jedino u varijablu x unesemo rezultate odgovarajućega testa. Za svaki test napravio se i poligon frekvencija⁴¹¹ kako bi se raspodjela rezultata mogla grafički prikazati (vidi grafikone 22, 23 i 24).

⁴⁰⁴ Shapiro-Wilkov test jedan je od najčešće upotrebljivanih i najpouzdanijih testova za potvrđivanje hipoteze o normalnoj razdiobi (Struna, 2011).

⁴⁰⁵ Razina značajnosti α razina je vjerojatnosti ispod koje se odbacuje nulta hipoteza. Razina značajnosti α odabire se prije provedbe testiranja te α može poprimiti vrijednosti ,01; ,05 i ,1, koje označuju da postoji do 1 %, 5 % i 10 % vjerojatnosti da se dogodi pogreška tipa I (odbacivanje nulte hipoteze koja je zapravo istinita) (Noymer, 2008: 17).

⁴⁰⁶ Nulta hipoteza hipoteza je koja pretpostavlja da ne postoji razlika između određenih značajka koje se mjere u odabranoj populaciji. Suprotna je njoj alternativna hipoteza koja pretpostavlja da postoji razlika. Nulte hipoteze smatraju se istinitima dok se ne opovrgnu. U slučaju da se statističkim testom opovrgne nulta hipoteza, prihvaća se alternativna hipoteza (Hayes, 2020).

⁴⁰⁷ U statistici p-vrijednost (vrijednost vjerojatnosti) vjerojatnost je događaja da će testna statistika poprimiti vrijednosti za koje je vjerodostojnost nulte hipoteze u odnosu na alternativnu hipotezu manja od opažene vrijednosti te statistike ili joj je jednaka, uz uvjet da je nulta hipoteza istinita (Beers, 2020). Ako je p-vrijednost manja ili jednaka unaprijed određenoj razini značajnosti α , onda se nulta hipoteza može odbaciti te se može reći da su rezultati statistički značajni za odabranu razinu značajnosti (Mendenhall i dr., 2009: 352).

⁴⁰⁸ Vrijednost W dobiva se s pomoću Shapiro-Wilkova testa. Ako vrijednost ispadne blizu 1, smatra se da su rezultati blizu normalne raspodjele, a što su vrijednosti manje od 1, rezultat je udaljeniji od normalne raspodjele (Glen, 2014).

⁴⁰⁹ R je programski jezik i okružje za statističke izračune i vizualizaciju. R-om se može slobodno koristiti i distribuirati ga te je programsko rješenje otvorenoga koda (Radović, 2015: 3).

⁴¹⁰ URL: <https://rstudio.com/> (13. 6. 2020)

⁴¹¹ Poligon frekvencija grafički je prikaz razdiobe frekvencija numeričke statističke varijable u pravokutnome koordinatnom sustavu tako da je svaka točka kojoj je apscisa jedna vrijednost varijable, a ordinata frekvencija te vrijednosti u danome uzorku, povezana ravnom linijom s njoj susjednom takvom točkom (Struna, 2011).

Tablica 73. Rezultati Shapiro-Wilkova testa za obje skupine za pretest, posttest i odgođeni posttest

	pretest		posttest		odgođeni posttest	
skupine	W	p	W	p	W	p
kontrolna	0,955	0,7183	0,82272	0,01718	0,89132	0,1226
eksperimentalna	0,90606	0,301058	0,94124	0,5951	0,94898	0,6789

Grafikon 22. Poligon frekvencija za rezultate pretesta

Grafikon 23. Poligon frekvencija za rezultate posttesta

Grafikon 24. Poligon frekvencija za rezultate odgođenoga posttesta

Iz rezultata (vidi tablicu 73) možemo vidjeti da se raspodjela rezultata za sva tri testa smatra normalnom kod obiju skupina, osim kod posttesta kontrolne skupine ($p = 0,017$) (odstupanje od normalne raspodjele može se grafički vidjeti za kontrolnu skupinu kod grafikona 23). Također kad bismo spojili rezultate obiju skupina i postupali s njima kao da je riječ o jednoj skupini, onda bi došlo do normalne raspodjele u predtestu i posttestu, ali ne i u odgođenome posttestu ($W = 0,89932$, $p = 0,03395$).

Zbog neravnomjerne raspodjele rezultata kod jednoga testa te male veličine uzorka ($n = 21$) odlučeno je da će se koristiti neparametrijskim tipom testa za daljnju analizu⁴¹². Da je raspodjela rezultata kod svih testova bila normalna te da je uzorak studenata bio veći ($n \geq 30$), za dokazivanje hipoteza koristili bi se parametrijski tipovi testova⁴¹³ poput ANOVA testa⁴¹⁴ i t-

⁴¹² Neparametrijski testovi zasnivaju se na osnovi razlike ili ranga te za razliku od parametrijskih testova ne ovise o tipu raspodjele podataka. Uzorak na osnovi kojega se provodi ovaj tip testa može se temeljiti na različitim oblicima osnovnih skupova ili dijelova ispitivane populacije o kojoj se vrlo malo zna. Ovi oblici testova često se provode kod novih istraživanja koja sadržavaju male uzorke te do tada nepoznate, neproverene ili nepotvrđene rezultate (Kaur i Kumar, 2015: 337–338).

⁴¹³ Parametrijski testovi zasnivaju se na teoriji vjerojatnosti i pretpostavci da su podatci normalno raspodijeljeni. Njima se ocjenjuju pojedini parametri (srednje vrijednosti, standardne devijacije ili varijance). Smatraju se robusnijima te se s pomoću njih može doći do jačega zaključka nego kod neparametarskih testova (Kaur i Kumar, 2015: 337).

⁴¹⁴ Testovi analize varijance (engl. ANOVA) omogućuju da se analiziraju razlike više skupina na temelju prosjeka njihova rezultata. Često se njima koristi kad imamo tri ili više skupina. Postoje jednosmjerni i višesmjerni testovi analize varijance ponovljenih mjerenja. Jednosmjerni test analize varijance ponovljenih mjerenja test je dokazivanja hipoteza koji se koristi jednom nezavisnom varijablom te može imati dvije ili više skupina nad kojima se vrši testiranje i uspoređuju promjene rezultata u određenim vremenskim razmacima. Test višesmjernje analize varijance ponovljenih mjerenja sličan je testu jednosmjerne analize, ali se u analizi proučava utjecaj dviju ili više nezavisnih varijabla umjesto jedne (npr. da za ovo istraživanje uvrstimo spol kao dodatnu varijablu uz igrificirane

testa⁴¹⁵. Primjena neparametrijski testova ne zahtijeva da podatci imaju normalnu raspodjelu (Frost, 2017) te se temelje na rangiranju rezultata. Budući da imamo dvije nezavisne skupine za koje kod određenih hipoteza trebamo gledati je li jedna skupina bolja od druge (eksperimentalna skupina > kontrolna skupina) odlučeno je da će se primijeniti Mann-Whitneyjev U-test⁴¹⁶, koji se može provoditi jednosmjerno (engl. *one-tailed*)⁴¹⁷ i dvosmjerno (engl. *two-tailed test*)⁴¹⁸ za daljnju statističku obradu (razmatrana je primjena Kruskal-Wallisova testa⁴¹⁹, ali je taj test u prvome redu namijenjen analizi rezultata više od dviju skupina te nema mogućnost jednosmjernoga testiranja). Također se Mann-Whitneyjev U-test primjenjuje u sličnim istraživanjima poput istraživanja Lauc, Bago i Kišiček (2011: 124). U tome se istraživanju provjeravalo imaju li studenti informacijskih znanosti i studenti koji ne studiraju informacijske znanosti, a zajednički slušaju kolegij koji se provodi na sustavu Moodle, na pretestu i posttestu statistički značajnu razliku raspodjele rezultata. U istraživanju Delfin i dr. (2017) proučavala se razlika u rezultatima posttesta nakon sata prirode u kontrolnoj skupini koja je učila klasičnim metodama i eksperimentalnoj skupini koja je učila koristeći se različitim igrama (više o ovome istraživanju u poglavlju *Pregled dosadašnjih istraživanja*). Osim Mann-Whitneyjeva U-testa u jednoj hipotezi ovoga istraživanja promatrala se veza između dviju varijabla u istraživanju (samoprocjene znanja hrvatskoga jezika te rezultata u svakome testu) te se značajnost te veze računala s pomoću testa Spearmanove korelacije⁴²⁰. Isti tip testa upotrijebljen je u spomenutom radu Lauc, Bago i Kišiček (2011: 124–125) za provjeru

sadržaje te istražujemo ostvaruju li žene bolje rezultate od muškaraca, radila bi se višesmjerna analiza) (MacKenzie, 2018).

⁴¹⁵ T-test najčešće je upotrebljavan parametrijski test. Njime se koristi za testiranje razlike između aritmetičkih sredina dvaju velikih ili dvaju malih uzoraka. Temelji se na studentovoj t-raspodjeli. Izračunana vrijednost t-testa označava se slovom *t* (Kenton, 2020b).

⁴¹⁶ Mann-Whitneyjev U-test neparametrijski je test kojim se koristi pri testiranju razlike očekivanja na temelju dvaju nezavisnih uzoraka koji nemaju normalno raspodijeljene rezultate. Testiranje se temelji na rangiranju podataka. Njime se koristi kod neparametrijskih metoda kao zamjenom za t-test (Glen, 2015a).

⁴¹⁷ Jednosmjerni test (engl. *one-tailed test*) primjenjuje se kad je smjer učinka tretmana određen u alternativnoj hipotezi (H1). Jednosmjerni se testovi dijele na testove na donjoj granici (H1: $S1 < S2$) i testove na gornjoj granici (H1: $S1 > S2$). (Privitera, 2017: 16).

⁴¹⁸ Dvosmjerni test (engl. *two-tailed test*) primjenjuje se kad se želi provjeriti postoji li razlika pri učinku tretmana neovisno o smjeru učinka (H1: $S1 \neq S2$) (Privitera, 2017: 12).

⁴¹⁹ Kruskal-Wallisov test ili jednosmjerna ANOVA temeljena na rangovima neparametrijska je metoda za testiranje jesu li nezavisne skupine koje se testiraju različite na temelju raspodjele rezultata. Smatra se proširenjem Mann-Whitneyjeva U-testa jer može usporediti više od dviju skupina te se primjenjuje kad postoje tri nezavisna uzorka ili više njih (Salkind, 2019: 673).

⁴²⁰ „Spearmanova korelacija ili korelacija ranga (oznaka r_s ili ρ) statistički je neparametrijski postupak za izračunavanje povezanosti dviju varijabla na temelju njihova ranga. Izračunava se kad jedan skup podataka slijedi ordinalnu ljestvicu ili kad raspodjela podataka značajno odstupa od normalne raspodjele te postoje podatci koji značajno odstupaju od većine izmjerenih. Linearna povezanost podataka nije uvjet za Spearmanovu korelaciju, a može se računati i na manjim uzorcima ($n < 35$).” (Udovičić i dr., 2007: 10). Vrijednosti r_s nalaze se između -1 i 1, a u slučaju da dobivena vrijednost ispadne 0, možemo zaključiti da nema povezanosti među varijablama (Ibid.: 11).

značajnosti veze između rezultata predtesta i posttest kod studenata, veza između pristupljenih resursa za kolegij i rezultata posttesta, veza između pristupa zadacima za kolegij i rezultata posttesta te veza između pristupa zadacima za kolegij i pristupa resursima kolegija. Za dokazivanje jedne hipoteze u kojoj se promatra promjena znanja kod eksperimentalne skupine nakon korištenja igrama, koristio se Wilcoxonov test sume rangova jer je predviđen za analizu jedne skupine nad kojom se rade višestruka mjerenja.

Naknadno je provjerena statistička snaga testova ($P = 1 - \beta$) za svaku hipotezu s pomoću programa G*Power kako ne bi došlo do pogrešnih pretpostavka koje mogu biti prouzročene malim uzorkom u istraživanju te malom veličinom učinka (d)⁴²¹ postignutoga u istraživanju.

7.8.5.1. Provedba Mann-Whitneyjeva U-testa

Za provedbu Mann-Whitneyjeva U-testa, kako bismo dokazali postoji li statistički značajna razlika između kontrolne i eksperimentalne skupine u rezultatima, treba izračunati vrijednosti U^{422} na temelju rangova studenata. Iz te vrijednosti dalje možemo izračunati vrijednosti z^{423} i p , kojima se češće koristi kod statističkih testova za dokazivanje hipoteza. Prvo se za obje skupine trebalo rangirati rezultate. Treba napomenuti da rangiranje kod Mann-Whitneyjeva U-testa ide obrnutim redoslijedom te se najbolji rezultat rangira najvećim brojem (21 u ovome slučaju jer je toliko studenata u objema skupinama), a najlošiji najmanjim brojem (npr. u predtestu student 7 eksperimentalne skupine rangiran je kao broj 1 jer je najslabije napisao predtest, a student 9 kontrolne skupine rangiran je brojem 21 jer je najbolje napisao predtest). U slučaju da studenti dijele rang na temelju istoga broja bodova, njihov se rang zapisuje decimalnim brojem (npr. kod posttesta dvoje studenata ima sve bodove te umjesto da se kod obaju rangova napiše 21, napiše se 20,5).

⁴²¹ Veličina učinka (engl. *effect size*) kvantitativna je mjera učinka istraživanja koja se računa na temelju razlika između skupina (Coe, 2002: 1). Cohen (1988: 12) je za usporedbe dviju aritmetičkih sredina standardizirao osnovne veličine učinka kao male (od 0,2), srednje (od 0,5) i velike (od 0,8). Sawilowsky (2009: 598) te je standarde kasnije proširio s mogućom veličinom učinka jako malom (od 0,01), jako velikom (od 1,2) i ogromnom (od 2).

⁴²² U-vrijednost ili U-statistika rezultata koji se dobiju Mann-Whitneyjevim U-testom. Određuje broj puta kad je rezultat jedne skupine manji od rezultata druge skupine. Što je niža vrijednost U, to su veće razlike među skupinama (Glen, 2015a).

⁴²³ Z-vrijednost određuje vrijednost pojedinoga rezultata u odnosu na prosjek grupnoga rezultata, i to tako da se njegova vrijednost izrazi u dijelovima standardne devijacije (McLeod, 2019). Z-vrijednost kod Mann-Whitneyjeva U-testa računa se idućom formulom: $z = (U - \mu_U) / \sigma_U$.

Tablica 74. Statistika za rangove studenata po testovima

	N	predtest		posttest		odgođeni posttest	
		zbroj rangova (R)	prosjeak rangova	zbroj rangova (R)	prosjeak rangova	zbroj rangova (R)	prosjeak rangova
kontrolna	12	156	13	151,5	12,63	162,5	13,54
eksperimentalna	9	75	8,3	79,5	8,83	68,5	7,61
ukupno	21						

Iz tablice 74 možemo vidjeti da su studenti kontrolne skupine po prosjeku rangova bolji u svim trima testovima. Dolazi li do značajne razlike u rezultatima između skupina na temelju ranga u svakome testu, možemo vidjeti kad na temelju zbroja rangova za obje skupine izračunamo njihove U-vrijednosti (U_k i U_e). Vrijednost U za svaku skupinu dobiva se idućom formulom:

$$U_k = n_k * n_e + 0,5 * (n_k * (n_k + 1)) - R_k$$

$$U_e = n_k * n_e + 0,5 * (n_e * (n_e + 1)) - R_e$$

* R je oznaka za zbroj rangova u skupini, a n za broj studenata.

Od dobivenih vrijednosti U za obje skupine treba uzeti manju vrijednost U kao glavnu te provjeriti je li za razinu značajnosti (α) 0,05 manja od kritične U-vrijednosti⁴²⁴ koja se može pronaći u tablici kritičnih vrijednosti za Mann-Whitneyjev U-test⁴²⁵. Ta kritička vrijednost drukčija je za dvosmjerne i jednosmjerne testove. Ako gledamo postoji li značajna razlika u rezultatima između skupina (eksperimentalna skupina $\neq$ kontrolna skupina), koristimo se kritičnom vrijednošću za dvosmjerni test, a ako gledamo je li jedna skupina bolja od druge (npr. eksperimentalna skupina $<$ kontrolna skupina), koristimo se kritičnom vrijednošću za jednosmjerni test. U tablici 75 prikazane su U-vrijednosti za sve testove.

⁴²⁴ Kritična U-vrijednost je koja se nalazi u tablici kritičnih vrijednosti za Mann-Whitneyjev U-test te je određena na temelju veličine uzorka obje skupina i razine značajnosti. Ako je dobivena U-vrijednost Mann-Whitneyjevim U-testom manja ili jednaka kritičnoj U-vrijednosti, onda za postavljeno istraživanje odbacujemo nultu hipotezu i prihvaćamo alternativnu hipotezu (LaMorte, 2017).

⁴²⁵ URL: http://sphweb.bumc.bu.edu/otlt/mph-modules/bs/bs704_nonparametric/Mann-Whitney-Table-CriticalValues.pdf (14. 6. 2020.)

Tablica 75. *U-vrijednosti po skupinama*

	predtest	posttest	odgođeni posttest
U_k	30	34,5	23,5
U_e	78	73,5	84,5
$U = \min(U_k, U_e)$	30	34,5	23,5
Kritična vrijednost U za dvosmjerni test	26		
Kritična vrijednost U za jednosmjerni test	30		

Uzimamo manju vrijednost U kod svakoga testa (vrijednost kontrolne skupine u ovome slučaju) te ako je vrijednost U manja ili jednaka kritičnoj vrijednosti za dvosmjerne testove (26), onda možemo smatrati da u našem uzorku postoji značajna razlika u rezultatima između skupina, a u suprotnome nema značajne razlike. Osim s pomoću U -vrijednosti statistički značajne razlike u rezultatima testovima mogu se dokazati s pomoću z -vrijednosti i p -vrijednost. Z -vrijednost može se dobiti s pomoću z -testa, u kojemu uzmemo vrijednost U te oduzmemo od nje njezin prosjek (μ_U) te podijelimo s njezinom standardnom devijacijom (σ_U) (Hole, 2009: 4):

$$z = (U - \mu_U) / \sigma_U$$

Ako z -vrijednost kod dvosmjernoga testa s razinom značajnosti (α) 0,05 bude manja od -1,96 ili veća od 1,96, a kod jednosmjernoga testa s istom razinom značajnosti -1,64 i 1,64, onda možemo odbaciti nultu hipotezu i prihvatiti alternativnu hipotezu. p -vrijednost je teško izračunati ručno te se često za nju upotrebljavaju odgovarajuće tablice⁴²⁶ za jednosmjerne i dvosmjerne testove, u kojima se pronalaze p -vrijednosti na temelju z -vrijednosti i razine značajnosti. p -vrijednost služi kao indikator mogu li se rezultati dobiveni ovim testom preslikati na širu populaciju, tj. da ponovimo istraživanje s drugim uzorkom, bismo li dobili slične rezultate. Ako je p -vrijednost manja ili jednaka 0,05, onda se smatra vrlo vjerojatnim da se rezultati istraživanja mogu preslikati na širu populaciju, a ako je p -vrijednost veća od 0,05, onda se smatra da se trenutačni rezultati ne mogu preslikati na širu populaciju. Visoka p -vrijednost govori da rezultati dobiveni na temelju uzorka upućuju na istinitost nulte hipoteze, a niska p -

⁴²⁶ URL: <http://www.z-table.com/> (19. 6. 2020.)

vrijednost da ne upućuju na istinitost nulte hipoteze te da više upućuju na točnost alternativne hipoteze (Frost, 2019b).

Unatoč tomu što se spomenute statističke vrijednosti mogu raditi ručno i s pomoću tablica, odlučilo ih se računalno provesti s pomoću jezika R u programu R studio koristeći se *wilcox.test* funkcijom⁴²⁷ jer se brže i preciznije mogu izračunati rezultati. Ta se funkcija također može upotrijebiti za računanje Wilcoxonova testa sume rangova, ali ako je u funkciju unesena mogućnost *paired=FALSE* koja pokazuje da je riječ o dvjema neovisnim skupinama koje se uspoređuju, funkcija time prepoznaje da se treba koristiti Mann-Whitneyjevim U-testom.

7.8.5.2. Provedba Wilcoxonova testa sume rangova

Wilcoxonov test sume rangova (engl. *Wilcoxon Signed Rank Test*) neparametrijski je statistički test za dokazivanje hipoteza koji se može upotrebljavati za usporedbu dvaju zavisnih uzoraka ili jednoga uzorka na kojemu se radi više mjerenja (proučava se razlika između rezultata dobivenih prije i poslije tretmana) (McDonald, 2014: 186). Pri analizi jednoga uzorka na kojemu radimo više mjerenja, prvo se izračuna razlika između prvih rezultata te rezultata koji se dobiju nakon provedbe određenoga tretmana. Ta razlika onda se rangira od najmanje do najveće koristeći se apsolutnim vrijednostima (zanemaruje se što je negativna, a što pozitivna razlika). U slučaju da osobe dijele rang, njihov se rang piše kao aritmetička sredina (osobe koje imaju isti rezultat, a trebaju se nalaziti na drugome i trećemu mjestu obje imaju rang 2,5). Za rangove se dodaje + i – predznak s obzirom na to je li razlika rezultata bila u pozitivnome ili negativnome smjeru. Nakon što se odrede pozitivni i negativni rangovi, može se izračunati W-vrijednost. W-vrijednost dobiva se tako da se uzme manji broj između zbroja negativnih rangova (W-) i zbroja pozitivnih rangova (W+):

$$W = \min (W-, W+)$$

U slučaju da je nulta hipoteza istinita, očekuje se da će biti jednaki ili lošiji rezultati za zbroj pozitivnih rangova (W+) u odnosu na zbroj negativnih rangova (W-), a u slučaju da je alternativna hipoteza istinita, očekuje se da će zbroj pozitivnih rangova biti mnogo veći. Da bi se dokazala ili opovrgnula hipoteza s pomoću ovoga testa, W-vrijednost treba usporediti s kritičnom W-vrijednošću. Kritična vrijednost W kod testiranja može se pronaći u tablici⁴²⁸ u kojoj je određena na temelju razine značajnosti (α), veličine uzorka te na temelju toga je li riječ

⁴²⁷ URL: <https://www.rdocumentation.org/packages/stats/versions/3.6.2/topics/wilcox.test> (19. 6. 2020.)

⁴²⁸ URL: https://sphweb.bumc.bu.edu/otlt/MPH-Modules/BS/BS704_Nonparametric/Critical%20Values%20for%20Wilcoxon%20Ranked%20Sign%20Test.pdf (28. 9. 2020.)

o jednosmjernome ili dvosmjernome testiranju hipoteze. Ako je statistička vrijednost dobivena testom W manja od određene kritične vrijednosti W , onda možemo odbaciti nultu hipotezu i prihvatiti alternativnu hipotezu, a u suprotnome odbacujemo alternativnu hipotezu i prihvaćamo nultu hipotezu (LaMorte, 2017). Z-vrijednost, kao i kod Mann-Whitneyjeva U-testa, dobiva se na temelju statističke vrijednosti testa, što je u ovome slučaju W . Ipak, malo je izmijenjena formula s obzirom na izračun prosjeka i standardne devijacije (Glen, 2020):

$$z = (W - \mu W) / \sigma W$$

$$\mu W = n(n + 1)/4$$

$$\sigma W = \sqrt{((n(n + 1)(2n + 1))/24)}$$

Isto kao i kod Mann-Whitneyjeva U-testa z-vrijednost kod dvosmjernoga testa s razinom značajnosti (α) 0,05 mora biti manja od -1,96 ili veća od 1,96, a kod jednosmjernoga testa s istom razinom značajnosti manja od -1,64 ili veća od 1,64 kako bismo mogli reći da distribucija rezultata nema standardnu normalnu razdiobu, što upućuje na to da je alternativna hipoteza istinita. p-vrijednosti se jednako dobivaju s pomoću z-vrijednosti te se također interpretiraju kao i kod Mann-Whitneyjeva U-testa. Izračun statističkih vrijednosti Wilcoxonova testa sume rangova također je proveden s pomoću jezika R koristeći se funkcijom *wilcox.test*, samo što u ovome slučaju nije unesen argument da je riječ o dvama neovisnim ili nepovezanim uzorcima. Rezultati testova studenata kod svakoga analiziranog testa uneseni su od rezultata prvoga studenta do posljednjega koristeći se početnim redoslijedom, rezultati pojedinačnih testova nisu sortirani po veličini kao kod Mann-Whitneyjeva U-testa. Razlog je za to taj da programski jezik R kod analize zavisnih uzorka na temelju redoslijeda upisanih podataka razumije veze između njih, npr. četvrti upisani rezultat kod predtesta povezuje se s četvrtim upisanim rezultatom za posttest itd.

7.8.5.3. Provedba Spearmanova koeficijenta korelacije

Za provedbu Spearmanova koeficijenta korelacije (oznaka r_s ili ρ), kako bismo dokazali postoji li značajna veza između dviju varijabla (npr. X i Y), potrebno je prvo rangirati vrijednosti za svaku varijablu kako bismo kasnije mogli izračunati razlike između rangova pojedinih varijabla (oznaka d_i). Rangiranje kod Spearmanove korelacije funkcionira tako da se najveći broj u uzorku rangira s brojem 1, sljedeći s brojem 2 i tako sve do posljednjega broja u uzorku (najveći je mogući rang broj veličine uzorka n). Ako se neka vrijednost ponavlja, onda se svakoj od njih pridružuje aritmetička sredina pripadajućih rangova (McDonald, 2014: 209). U tablici se po redcima za vrijednost varijabla napravi rang (npr. za varijable X i Y imamo rangove r_x i r_y) te se te rangove za obje varijable onda oduzme kako bi se dobile razlike vrijednosti rangova

(oznaka d) te se ta vrijednost razlike kvadrira (d^2). Te kvadrirane razlike onda zbrojimo (Σd^2) te tu vrijednost možemo iskoristiti zajedno s informacijom o broju uzoraka (n) te ih uvrstiti u formulu za Spearmanovu korelaciju (Glen, 2015b):

$$r_s = 1 - (6 * \Sigma d^2 / (n^3 - n))$$

Ako je vrijednost r_s između 0 i 1, onda je odnos korelacija pozitivan, što znači da, ako se vrijednost varijable Y povećava, povećava se i vrijednost varijable X . Ako vrijednost X opada povećanjem vrijednosti Y , onda je korelacija negativna te je r_s između -1 i 0 (Mozejko, 2012: 104). U slučaju da dobivena vrijednost ispadne 0, možemo zaključiti da nema povezanosti među varijablama (Udovičić i dr., 2007: 10–11).

7.8.5.4. Izračun statističke snage testa

Statistička snaga testa ($P = 1 - \beta$)⁴²⁹ provjerena je za svaki statistički test kojim se želi dokazati hipoteze radi provjere mogućnost pojave pogreška tipa II (oznaka β), u kojoj se prihvaća nulta hipoteza koja je pogrešna (Prajapati, Dunne i Armstrong, 2010: 10). Za većinu slučajeva želi se postići minimalno snaga statističkoga testa od 0,80 (80 %), što znači da je vjerojatnost pogreške tipa II 20 %. Kad test ima snagu manju od 80 %, mogućnost donošenja valjanoga zaključka ugrožena je zbog dovoljno velikoga rizika da se dogodi pogreška tipa II (McHugh, 2008: 263). Snaga testa ovisi o idućim čimbenicima: veličina uzorka (n), veličina učinka (d) i razina značajnosti (α) (Ibid.: 263). Snaga za Mann-Whitneyjeve U-testove i Wilcoxonov test sume rangova izračunana je računalno s pomoću programa G*Power jer taj program podržava izračun snage za jednosmjerne i dvosmjerne testove za jednu ili dvije skupine. Kod računalnoga izračuna snage testa trebalo je upisati veličinu uzorka za obje skupine, razinu značajnosti 0,05 te veličinu učinka (d). Veličina učinka istraživanja (d) računa se tako što se uzme aritmetička sredina (μ) za rezultate eksperimentalne skupine i oduzme se od aritmetičke sredine za rezultate kontrolne skupine te se taj rezultat podijeli s objedinjenim standardnim devijacijama obje skupina (SD_{pooled}). Objedinjena standardna devijacija izračunana je na temelju Cohenove (1988: 20) formule:

$$d = (\mu_e - \mu_k) / SD_{pooled}$$

$$SD_{pooled} = \sqrt{(SD_e^2 + SD_k^2) / 2}$$

Na temelju tih podataka program G*Power mogao je izračunati snagu provedenih Mann-Whitneyjevih U-testova i Wilcoxonova testa sume rangova. Snaga testa za Spearmanovu

⁴²⁹ Statistička snaga testa (engl. *power of a statistical test*) mjera je vjerojatnosti da će istraživač u uzorku naći statističku značajnost ako učinak postoji u cijeloj populaciji (McHugh, 2008: 263).

korelaciju kod hipoteze H_f izračunala se s pomoću programskoga jezika R koristeći se funkcijom *pwr.r.test* (vidi tablicu 76). U funkciju je potrebno kod argumenata *r* i *n* umjesto *NULL* vrijednosti unijeti broj uzorka (*n*) te dobiveni koeficijent korelacije (*r*). Za argument *power* u funkciji se ostavlja vrijednost *NULL* jer se snaga želi izračunati (*NULL* se unosi za jedan od argumenata *r*, *N* i *power*, koje se želi odrediti na temelju vrijednosti drugih argumenta). Tablica 76. Naredba u R za dobivanje snage korelacijskoga testa

<pre>pwr.r.test(n = NULL, r = NULL, sig.level = 0.05, power = NULL, alternative = "two.sided")</pre>
--

7.8.5.5. Postavljene hipoteze

Na temelju rezultata predtesta, posttesta i odgođenoga posttesta u objema skupinama provjeravale su se iduće hipoteze:

- H_{a0} : Osobe koje uče hrvatski kao ini jezik, a koje će se služiti igrificiranim sadržajima, ne postižu statistički značajne razlike na rezultatima predtesta iz usvajanja vokabulara od osoba koje se neće služiti igrificiranim sadržajima.
- H_{a1} : Osobe koje uče hrvatski kao ini jezik, a koje će se služiti igrificiranim sadržajima, postižu statistički značajne razlike na rezultatima predtesta iz usvajanja vokabulara od osoba koje se neće služiti igrificiranim sadržajima.
- H_{b0} : Osobe koje uče hrvatski kao ini jezik, a koje se služe igrificiranim sadržajima, postižu statistički značajno lošije ili jednake rezultate na testu usvajanja vokabulara od osoba koje se ne služe igrificiranim sadržajima.
- H_{b1} : Osobe koje uče hrvatski kao ini jezik, a koje se služe igrificiranim sadržajima, postižu statistički značajno bolje rezultate na testu usvajanja vokabulara od osoba koje se ne služe igrificiranim sadržajima.
- H_{c0} : Osobe koje uče hrvatski kao ini jezik, a koje se služe igrificiranim sadržajima, postižu statistički značajno lošiji ili jednak napredak na testu usvajanja vokabulara od osoba koje se ne služe igrificiranim sadržajima.
- H_{c1} : Osobe koje uče hrvatski kao ini jezik, a koje se služe igrificiranim sadržajima, postižu statistički značajno bolji napredak na testu usvajanja vokabulara od osoba koje se ne služe igrificiranim sadržajima.
- H_{d0} : Osobe koje uče hrvatski kao ini jezik, nakon nastave u kojoj se služe igrificiranim sadržajima, postižu statistički značajno lošije ili jednake rezultate na testu usvajanja vokabulara.

- H_{d1} : Osobe koje uče hrvatski kao ini jezik, nakon nastave u kojoj se služe igrificiranim sadržajima, postižu statistički značajno bolje rezultate na testu usvajanja vokabulara.
- H_{e0} : Osobe koje uče hrvatski kao ini jezik te vole igrati elektroničke igre ne postižu statistički značajne razlike na rezultatima testova usvajanja vokabulara u odnosu na osobe koje ne vole igrati elektroničke igre ili su neutralne prema njima.
- H_{e1} : Osobe koje uče hrvatski kao ini jezik te vole igrati elektroničke igre postižu statistički značajne razlike na rezultatima testova usvajanja vokabulara u odnosu na osobe koje ne vole igrati elektroničke igre ili su neutralne prema njima.
- H_{f0} : Ne postoji značajan odnos između samoprocjene znanja hrvatskoga jezika i rezultata testova usvajanja vokabulara kod osoba koje uče hrvatski kao ini jezik.
- H_{f1} : Postoji značajan odnos između samoprocjene znanja hrvatskoga jezika i rezultata testova usvajanja vokabulara kod osobe koje uče hrvatski kao ini jezik.

U provedenome eksperimentu osobe koje se služe igrificiranim sadržajima studenti su eksperimentalne skupine, a osobe koje se ne služe igrificiranim sadržajima studenti su kontrolne skupine. Glavne su hipoteze koje se žele provjeriti u ovome istraživanju H_b i H_c (eksperimentalna > kontrolna) te H_d (rezultati posttesta > rezultati predtesta u eksperimentalnoj skupini) jer te hipoteze prikazuju koliki je bio utjecaj igara na studente eksperimentalne skupine. H_a provjerena je kako bi se vidjelo ima li značajnih razlika u predznanju između studenata kontrolne i eksperimentalne skupine.

Dodatno je provjereno unutar H_e ostvaruju li osobe koji vole igrati elektroničke igre razlike u rezultatima s obzirom na osobe koji ne vole igrati elektroničke igre ili su neutralne prema njima te za koje se pretpostavlja da ne igraju elektroničke igre. Posljednja hipoteza H_f provjerava se Spearmanovom korelacijom te se prikazuje veza samoprocjene znanja studenata s ostvarenim rezultatima na testovima. Za svaku hipotezu provjerila se i statistička snaga testa. Unatoč tomu što snaga testa nije visoka, i dalje se mogu interpretirati dobiveni rezultati jer se isti eksperiment može ponoviti u budućim sličnim istraživanjima i s većim uzorkom. Također, korisno je čak i na manjim uzorcima izračunati snagu testa jer onda ona dosta ovisi o veličini učinka (d).

7.8.6. Provjera hipoteza

7.8.6.1. Odgovor na hipotezu H_a

Prva hipoteza (H_a : kontrolna $\neq$ eksperimentalna) promatra razliku između predtesta u dvjema skupinama te se zato koristi dvosmjernim Mann-Whitneyjevim U-testom. Uzeti su rezultati predtesta svake skupine te su s pomoću jezika R napisane iduće naredbe u tablici 77.

Tablica 77. *Naredba u R-u za dobivanje rezultata Mann-Whitneyjeva U-testa za dokazivanje hipoteze H_a*

```
kontrolna <-c(30,31,36,36,37,37,39,39,41,42,44,45)
eksperimentalna <-c(27,29,30,31,32,37,38,39,40)
wilcox.test(kontrolna, eksperimentalna, alternative = "two.sided", paired = FALSE, exact = FALSE, correct = TRUE, conf.int = TRUE)
```

Rezultati testa prikazuju vrijednosti: $p = 0,09372$, $U = 30$ i $z = 1,676069$. Vrijednost U (30) dobivena Mann-Whitneyjevim U-testom veća je od kritične vrijednosti za dvosmjerene testove (26) te time u našem uzorku ne postoji značajna razlika u rezultatima između skupina utemeljenih na rangu za razinu značajnosti 0,05. Kod dokazivanja hipoteza na temelju p -vrijednosti na razini značajnosti 0,05 mnogi istraživači koriste se kliznim vrijednostima za zaključke u kojima se smatra da, ako je vrijednost $p < 0,01$, rezultat ima vrlo značajnu statističku razliku, ako je p između 0,01 i 0,05, onda se rezultat može smatrati statistički značajnim, ako je p između 0,05 i 0,1, onda je rezultat blizu toga da bude statistički značajan i ako je $p > 0,1$, onda rezultat nije statistički značajan (Mendenhall i dr.: 2009: 352). Budući da je p veći od 0,05 i z -vrijednost (1,676069) se nalazi između -1,96 i 1,96, što znači da distribucija rezultata između skupina ima standardnu normalnu razdiobu, time možemo odbaciti alternativnu hipotezu, ali budući da je p manji od 0,1, ipak je rezultat test blizu toga da bude statistički značajan. Da odbacimo nultu hipotezu kad se koristimo razinom značajnosti 5 % (0,05), mogućnost da se pojavi pogreška tipa I. (odbacivanje točne nulte hipoteze) bila bi dovoljno visoka: 9,37 %. Time nultu hipotezu ne možemo odbaciti. Unatoč tim rezultatima kad se izračunala statistička snaga Mann-Whitneyjeva U-testa provedenoga korištenjem programom G*Power, snaga testa ($P = 1 - \beta$) za razinu značajnosti 0.05 iznosi 0,50, što znači da postoji 50 % mogućnost da se pojavi pogreška tipa II. (prihvaćanje nulte hipoteze koja može biti neistinita). Razlog je za slabu snagu testa taj da uzorak nije dovoljno velik za dokazivanje te hipoteze. Također veličina učinka koja se dobiva temeljem rezultata studenata, unatoč tomu što je velika, nema dovoljno visoku vrijednost da pojača snagu testa na temelju manjega uzorka ($d = 0,9326$). Program G*Power procjenjuje da je potrebno najmanje 27 studenata u svakoj skupini s veličinom učinka 0,8 kako bi se snaga testa povećala na 80 %. Time trenutačni test s manjim uzorkom možemo smatrati statistički neznačajnim. Poželjni rezultat za H_a bio bi da osobe koje uče hrvatski kao ini jezik, a koje se služe igrificiranim sadržajima, ne postižu statistički značajne razlike na rezultatima predtesta iz usvajanja vokabulara u odnosu na osobe koje se ne služe igrificiranim sadržajima. Razlog je tomu što želimo da na početku istraživanje obje skupine imaju što ujednačenije

predznanje. Nažalost zbog slabe snage statističkoga testa to ne možemo sa sigurnošću zaključiti unatoč rezultatima Mann-Whitneyjeva U-testa koji potvrđuju nultu hipotezu.

7.8.6.2. Odgovor na hipotezu H_b

Kod dokazivanja hipoteze H_b nije bilo potrebno analizirati predtest jer se u tome trenutku studenti eksperimentalne skupine nisu služili igrificiranim sadržajima. Hipoteza H_b provjeravala se s pomoću jednosmjernoga Mann-Whitneyjeva U-testa koji je usmjeren na utvrđivanje postiže li eksperimentalna skupina bolje rezultate od kontrolne skupine (eksperimentalna > kontrolna). Test se s pomoću jezika R proveo dvaput na rezultatima obiju skupina kod posttesta koji se odnosi na kratkoročno znanje te rezultatima odgođenoga posttesta koji se odnosi na dugoročno znanje (vidi tablicu 78).

Tablica 78. *Naredba u R-u za dobivanje rezultata Mann-Whitneyjevim U-testom za dokazivanje hipoteze H_b*

```
## rezultati posttesta
kontrolna_posttest<-c(40,40,41,42,44,45,46,46,46,46,46,47)
eksperimentalna_posttest<-c(37,38,41,42,42,44,44,44,47)
wilcox.test(eksperimentalna_posttest, kontrolna_posttest, alternative = "greater", paired = FALSE, exact = FALSE, correct = TRUE, conf.int = TRUE)

## rezultati odgođeni posttest
kontrolna_odg_posttest<-c(40,42,42,44,44,45,45,46,46,46,46,47)
eksperimentalna_odg_posttest<-c(35,37,39,39,40,42,43,46,46)
wilcox.test(eksperimentalna_odg_posttest, kontrolna_odg_posttest, alternative = "greater", paired = FALSE, exact = FALSE, correct = TRUE)
```

Rezultati obaju testova prikazani su u tablici 79.

Tablica 79. *Statističke vrijednosti dobivene Mann-Whitneyjevim U-testom iz rezultata posttesta i odgođenoga posttesta*

	posttest	odgođeni posttest
U	34,5	23,5
z	-1,438727	-2,234491
p	0,9249	0,9873

Mann-Whitneyjev U-test za rezultate posttesta prikazuje vrijednost $U = 34,5$, $z = -1,438727$ te $p = 0,9249$. Kod posttesta vrijednost U (34,5) dobivena Mann-Whitneyjevim U-test veća je od kritične vrijednosti za jednosmjerne testove (30) te time u našem uzorku ne postoji značajna

razlika u rezultatima između skupina utemeljenih na rangovima za razinu značajnosti 0,05. Z-vrijednost nalazi se između -1,64 i 1,64, što znači da se distribucija rezultata između skupina ne razlikuje značajno, rezultati imaju standardnu normalnu razdiobu. p-vrijednost je 0,9249, što je snažan indikator da se ovaj test ne može nikako preslikati na populaciju, već samo vrijedi za ovu skupinu, tj. da ponovimo istraživanje s drugim uzorkom, nije sigurno da bismo dobili iste rezultate. Da odbacimo nultu hipotezu kad se koristimo razinom značajnosti 5 %, mogućnost da se pojavi pogreška tipa I bila bi jako visoka: 92,49 %. Time je vjerojatnije da je nulta hipoteza kod analize rezultata za posttest točna. Kad bismo ponovili isti statistički test, ali promijenili smjer učinka, tj. napravili analizu u kojoj pretpostavljamo da kontrolna skupina postiže bolje rezultate od eksperimentalne (kontrolna > eksperimentalna), onda bi U vrijednost ostala ista (34,5), z-vrijednost bi bila -1,366790 (distribucija rezultata između skupina ponovno se ne razlikuje značajno). Unatoč tomu, rezultat dokazivanja hipoteze bio bi malo bliži statističkoj značajnosti vrijednosti s $p = 0,0858455$. Kontrolna skupina imala je malo bolji prosjek bodova od eksperimentalne skupine, ali njihov se rezultat ne može preslikati na cijelu populaciju. Snaga je statističkoga testa za rezultate analize posttesta 0,4254424, što znači da postoji 67 % mogućnosti da se pojavi pogreška tipa II. Time snaga statističkoga testa nije dovoljno visoka za rezultate posttesta da bi se došlo do valjanoga zaključka.

Kod statističke analize rezultata odgođenoga posttesta s Mann-Whitneyjevim U-testom dobivene su vrijednosti $U = 23,5$, $z = -2,234491$ i $p = 0,9873$. U-vrijednost je 23,5, što je niže od kritične vrijednosti za jednosmjerne testove (30) te nam to potvrđuje da u ukupnome uzorku postoji značajno bolji rezultat utemeljen na rangovima između jedne od dviju skupina te z-vrijednost koja se nalazi izvan -1,64 i 1,64, također nam govori da se distribucija rezultata između skupina značajno razlikuje. P-vrijednost 0,9873 indikator je da test nije statistički značajan. Ne možemo potvrditi alternativnu hipotezu te time ne možemo kod odgođenoga posttesta reći da će studenti eksperimentalne skupine ostvariti bolje rezultate od kontrolne skupine kod šire populacije. Kad bismo okrenuli smjer testiranja tako da proučavamo postiže li kontrolna skupina statistički značajno bolje rezultate od eksperimentalne skupine u odgođenome posttestu (kontrolna > eksperimentalna), dobili bismo identičnu vrijednost U (23,5) te z-vrijednost -2,162410 (distribucija rezultata između skupina značajno se razlikuje). P-vrijednost bi bila 0,0152933, što upućuje na to da je test statistički značajan za smjer testiranja u kojemu je alternativna hipoteza da kontrolna skupina ostvaruje statistički značajno bolje rezultate od eksperimentalne skupine kod odgođenoga posttesta. Snaga je statističkoga testa za rezultate analize odgođenoga posttesta 0,81, što znači da postoji 19 % mogućnosti da se pojavi pogreška tipa II te time provedbu statističkoga testa možemo smatrati dovoljno snažnom za

preciznu interpretaciju rezultata. Razlog je za povećanu snagu statističkoga testa kod analize rezultata odgođenoga posttesta vrlo visoki učinak istraživanja $d = 1,1839996$. Ako uzmemo u obzir rezultate dokazivanja H_b za odgođeni posttest, u kojemu je postignuta veća snaga za provedeni statistički test, onda za H_b kod smjera testiranja u kojemu gledamo je li eksperimentalna skupina bolja od kontrolne skupine možemo prihvatiti nultu hipotezu da osobe koje uče hrvatski kao ini jezik, a koje se služe igrificiranim sadržajima, postižu statistički značajno lošije ili jednake rezultate na odgođenome posttestu iz usvajanja vokabulara od osoba koje se ne služe igrificiranim sadržajima. Ipak, taj odgovor za hipotezu odnosi se na dugoročno znanje te bi se još trebao ispitati na većemu uzorku jer ipak postoji mogućnost da se s većom eksperimentalnom skupinom dobije novi rezultat. Snaga ovoga testa ipak nije 100 %, pa postoji mala mogućnost (19 %) da nulta hipoteza nije istinita. S jačom statističkom snagom, do koje bi se vjerojatno došlo da je uzorak veći, vjerojatno bismo imali jasniju sliku za ovu hipotezu.

7.8.6.3. Odgovor na hipotezu H_c

Svrha je ovoga istraživanja proučiti učinkovitost obrazovnih igara u poučavanju hrvatskoga kao inoga jezika, a to se unatoč lošijim rezultatima eksperimentalne skupine na ispitima može provjeriti i usporediti s kontrolnom skupinom ako se usporedi napredak u bodovima između obiju skupina. Kod studenta eksperimentalne skupine većina studenata (8 od 9) postigli su bolji rezultati u posttestu i odgođenome posttestu nego u predtestu.

Kod provjere te hipoteze gledalo se drugu tablicu koja se odnosi na napredak u bodovima kod svakoga testa koja se dobila na temelju tablice rezultata studenata. Napredak u bodovima računa se tako što se uzmu bodovi iz posttesta ili odgođenoga posttesta te se od njih oduzmu bodovi predtesta (tablica s brojem bodova napretka nalazi se u prilogu *Napredak u bodovima studenata u odnosu na predtest*). Proučavao se napredak u posttestu i odgođenome posttestu u odnosu na predtest. Napredak odgođenoga posttesta u odnosu na prvi posttest nije analiziran jer je pomak u rezultatima bio malen za obje skupine (vidi tablicu 82).

Tablica 80. *Opisna statistika napretka studenata u posttestu u odnosu na predtest*

	N	aritmetička sredina (prosjeak)	medijan	mod	minimum	maksimum	raspon podatka
kontrolna skupina	12	6,42	6	7	2	14	12
eksperimentalna skupina	9	8,44	7	7	-1	15	16

Tablica 81. Opisna statistika napretka studenata u odgođenome posttestu u odnosu na pretest

	N	aritmetička sredina (prosjeak)	medijan	mod	minimum	maksimum	raspon podatka
kontrolna skupina	12	6,33	5,5	1	1	14	13
eksperimentalna skupina	9	7,11	8	5	0	12	12

Tablica 82. Opisna statistika napretka studenata u odgođenome posttestu u odnosu na posttest

	N	aritmetička sredina (prosjeak)	medijan	mod	minimum	maksimum	raspon podatka
kontrolna skupina	12	0,33	0	0	-4	5	9
eksperimentalna skupina	9	-1,33	-2	-2	-7	4	11

U tablicama 80 i 81. možemo vidjeti da su od pretesta po prosjeku bodova studenti eksperimentalne skupine više napredovali u posttestu i odgođenome posttestu u odnosu na studente kontrolne skupine. S druge strane, studenti kontrolne skupine u odgođenome posttestu napredovali su u odnosu na posttest za razliku od studenata eksperimentalne skupine koji su imali blagi pad. Međutim, već je spomenuto da je pomak bodova izražen prosjekom između posttesta i odgođenoga posttesta malen za obje skupine, pa se može reći da je znanje kod pisanja posttesta i odgođenoga posttesta ostalo slično.

U eksperimentalnoj skupini između pretesta i prvoga posttesta možemo vidjeti najveći porast bodova (15) kod studenta 6, koji je na pitanje voli li elektroničke igre odgovorio s *ni da ni ne*, ali je nakon igranja igara u upitniku odgovorio da mu se sviđa nastava s igrama. Međutim, isti je student imao najveći pad u odgođenome posttestu (za sedam bodova). Najbolje rezultate u svim trima testovima u eksperimentalnoj skupini ostvarili su student 1, student 9 i student 3. Student 7 na pitanje voli li elektroničke igre odgovorio je s *ni da ni ne*, ali je nakon igranja igara odgovorio da mu se sviđa taj oblik nastave. Taj je student ostvario drugi napredak u posttestu (+ 14 bodova), to je jednako najvećemu napretku koji je ostvario jedan student u kontrolnoj

skupini (student 2), što je dobro jer je prvi test napisao najlošije od svih studenata u objema skupinama (27 bodova), a nakon igara u idućim dvama testovima ostvario je više od 80 % bodova (41 bod u posttestu i 39 bodova u odgođenome posttestu). Za studenta 4 eksperimentalne skupine već je spomenuto da je jedini student koji nije napredovao te je čak lošije napisao posttest od pretesta (za jedan bod), a odgođeni posttest napisao je jednako kao pretest.

U kontrolnoj skupini unatoč tomu što su rezultati malo bolji kod odgođenoga posttesta, zanimljivo je da kod većine studenta nije došlo do napretka u odnosu na prvi posttest jer je četvero studenta lošije napisalo odgođeni posttest (s time da ih je troje napisalo lošije samo za 1 bod), a četvero ih ima jednak rezultat kao u posttestu. Kod četvero studenta koji su bolje napisali odgođeni posttest dvoje (student 6 i student 12) je ostvarilo 4 i 5 bodova više te je time ukupan prosjek svih rezultat studenta za odgođeni posttest ispao malo bolji.

Za provjere hipoteze H_c (H_c : eksperimentalna > kontrolna) korištenjem jednosmjernim Mann-Whitneyjevim U-testom napisan je idući kod u jeziku R prikazan u tablici 83.

Tablica 83. *Naredba u R-u za dobivanje rezultata Mann-Whitneyjeva U-testa za dokazivanje hipoteze H_c*

```
## napredak kod posttest u odnosu na pretest
kontrolna_posttest_napredak<-c(2,2,3,4,4,5,5,7,7,9,10,14)
eksperimentalna_posttest_napredak<-c(-1,4,7,7,7,11,12,14,15)
wilcox.test(eksperimentalna_posttest_napredak, kontrolna_posttest_napredak, alternative =
"greater", paired = FALSE, exact = FALSE, correct = TRUE, conf.int = TRUE)

## napredak kod odgođenog posttest u odnosu na pretest
kontrolna_odg_posttest_napredak<-c(1,1,3,3,4,4,7,8,9,9,13,14)
eksperimentalna_odg_posttest_napredak<-c(0,5,5,6,8,8,9,11,12)
wilcox.test(eksperimentalna_odg_posttest_napredak, kontrolna_odg_posttest_napredak,
alternative = "greater", paired = FALSE, exact = FALSE, correct = TRUE)
```

Rezultati obaju testova prikazani su u tablici 84.

Tablica 84. *Statističke vrijednosti dobivene Mann-Whitneyjevim U-testom za napredak bodova kod posttesta i odgođenoga posttesta u odnosu na pretest*

	posttest	odgođeni posttest
U	34,5	46
z	1,362266	0,535091
p	0,08656	0,2963

Mann-Whitneyjev U-test za posttest daje vrijednosti $U = 34,5$, $z = 1,362266$ i $p = 0,08656$. U-vrijednost 34,5 veća je od kritične vrijednosti za jednosmjerne testove, koja iznosi 30, te time ne postoji značajna razlika između rezultata utemeljenih na rang u objema skupinama. Z-vrijednost 1,362266 pokazuje da nema značajnoga odstupanja u distribuciji rezultata te da je riječ o normalnoj razdiobi rezultata. Na temelju p-vrijednosti 0,08656 može se pretpostaviti da rezultat test nije statistički značajan, ali je blizu toga. Da odbacimo nultu hipotezu kad se koristimo razinom značajnosti 5 %, mogućnost da se pojavi pogreška tipa I bila bi: 8,66 %. Također, snaga provedenoga statističkog testa nije visoka i iznosi 0,3216442, što znači da za interpretaciju rezultata testa postoji oko 68 % mogućnosti da se pojavi pogreška tipa II. Time snaga statističkoga testa nije dovoljno visoka za rezultate posttestova da bi se došlo do valjanoga zaključka.

Kod analize rezultata odgođenoga posttesta s Mann-Whitneyjevim U-testom dobivamo vrijednosti $U = 46$, $z = 0,535091$, $p = 0,2963$. Dobivena U-vrijednost (46) veća je od kritične U-vrijednosti (30) te nema razlika u rezultatima između skupina utemeljenih na rang za razinu značajnosti 0,05. Z-vrijednost 1,362266 govori nam da nema među rezultatima značajnoga odstupanja od prosjeka. Na temelju dobivene p-vrijednosti 0,2963 možemo zaključiti da test nije statistički značajan, tj. ne možemo na temelju rezultata testa dokazati pretpostavku da eksperimentalna skupina postiže statistički bolji napredak na posttestu od kontrolne skupine koja bi se mogla poopćiti i za širu populaciju. Da odbacimo nultu hipotezu kad se koristimo razinom značajnosti 5 %, mogućnost da se pojavi pogreška tipa I bila bi: 29,63 %. Unatoč tomu, treba uzeti u obzir da eksperimentalna skupina ima studenta 4, koji je jedini koji nije napredovao u objema skupinama. Da se njega isključilo iz eksperimentalne skupine, onda bi za rezultate posttesta p-vrijednost bila 0,0431, vrijednost U 25,5 i z-vrijednost 1,714832. Time kod posttesta dolazi do razlika u rezultatima između skupina utemeljenih na rang za razinu značajnosti 0,05, postoji značajno odstupanje među rezultatima od prosjeka te je test statistički značajan, tj. primjenjiv na širu populaciju. Unatoč tome, snaga testa (0,2687490) nije velika, pa ne možemo doći do valjanoga zaključka jer je uzorak premalen. Veličina učinka nije problem za snagu testa jer je $d = 0,84$. Da istoga studenta (student 4 eksperimentalne skupine) izbacimo kod rezultata odgođenoga posttesta, vrijednost U bila bi 34, z-vrijednost 1,046278 te bi p-vrijednost bila 0,147716. Time kod odgođenoga posttesta ne dolazi do razlika u rezultatima između skupina utemeljenih na rang za razinu značajnosti 0,05, značajnoga odstupanja među rezultatima od prosjeka te je test statistički neznačajan, tj. nije primjenjiv na cijelu populaciju. Kod provjere snage statističkoga testa za analizu rezultata napretka kod odgođenoga posttesta, nepovezano s time izbacimo li studenta 4, dobivena je mala snaga testa 0,18, što znači da postoji 82 % šanse

da se pojavi pogreška tipa II u istraživanju.

Time, što se tiče analize napretka kod posttesta i odgođenih posttestova, za H_c ne možemo zbog slabe snage testova doći do valjanoga zaključka te sa sigurnošću zaključiti da osobe koje uče hrvatski kao ini jezik, a koje se služe igrificiranim sadržajima, postižu statistički značajno bolji napredak na testu usvajanja vokabulara od osoba koje se ne služe igrificiranim sadržajima. Unatoč tomu, rezultati napretka na temelju aritmetičke sredine prikazuju veći napredak eksperimentalne skupine od kontrolne skupine kod posttesta i odgođenoga posttesta (vidi tablice 87 i 88).

7.8.6.4. Odgovor na hipotezu H_d

Ova hipoteza odnosi se samo na studente eksperimentalne skupine te se time uzorak sastoji samo od 9 studenata. Hipoteza H_d provjerila se s pomoću jednosmjernoga Wilcoxonova testa sume rangova namijenjenoga jednoj skupini jer se Mann-Whitneyjevim U-testom koristi za uspoređivanje dviju nezavisnih skupina (naredbe u jeziku R za dobivanje rezultata prikazane su u tablici 85). Testiranje je provedeno tako što se kod eksperimentalne skupine prvo provjerilo jesu li rezultati posttesta značajno bolji od rezultata predtesta te jesu li rezultati odgođenoga posttesta značajno bolji od rezultata predtesta. Time možemo vidjeti je li kod eksperimentalne skupine došlo do statistički značajno boljega rješavanja istoga testa (posttesta) nakon igranja igara te toga istog testa (odgođenoga posttesta) dva tjedna nakon što su prestali igrati te igre.

Tablica 85. *Naredba u R-u za dobivanje rezultata Wilcoxonova test sume rangova za dokazivanje hipoteze H_d*

```
eksperimentalna_predtest <-c(40,30,37,39,32,29,27,31,38)

## usporedba rezultata predtesta i posttesta
eksperimentalna_posttest<-c(47,37,44,38,44,44,41,42,42)
wilcox.test(eksperimentalna_posttest, eksperimentalna_predtest, paired = TRUE, exact =
FALSE, correct = TRUE)

## usporedba rezultata predtesta i odgođenog posttesta
eksperimentalna_odg_posttest<-c(46,35,42,39,43,37,39,40,46)
wilcox.test(eksperimentalna_odg_posttest, eksperimentalna_predtest, alternative =
"greater", paired = FALSE, exact = FALSE, correct = TRUE)
```

Rezultati obaju testova prikazani su u tablici 86.

Tablica 86. Statističke vrijednosti dobivene Wilcoxonovim testom sume rangova za usporedbe rezultata pretesta i posttesta te pretesta i odgođenoga posttesta

	posttest	odgođeni posttest
W_+	44	36
W_-	1	0
$W_{\min(W_+, W_-)}$	1	0
$W_{\text{kritičan}}$	8	
z	-2,496641	-2,456518
p	0,00626879	0,00701453

Kritična je vrijednost W za jednosmjerno testiranje u kojemu imamo uzorak veličine 9 studenata 8. Ta kritična vrijednost veća je od dobivene W -vrijednosti kod posttesta (1) i odgođenoga posttesta (0) te se time dokazuje alternativna hipoteza. Kod posttesta možemo vidjeti da su svi osim jednoga studenta svrstani u zbroj pozitivnih rangova (W_+). Zbroj negativnih rangova (W_-) nizak je jer se u njemu nalazi jedan student koji je lošije napisao posttest i to za jedan bod. Kod odgođenoga posttesta u kojemu je manji napredak u odnosu na posttest malo je manji zbroj pozitivnih rangova, ali je zato vrijednost negativnih rangova veća za 1 bod, tj. kod istoga studenta koji je lošije napisao posttest od pretesta došlo je do istoga rezultata kod odgođenoga posttesta i pretesta, što nije dovelo do napretka, ali nije ni dovelo do nazadovanja.

Dobivene z -vrijednosti kod posttesta -2,496641 i odgođenoga posttesta -2,456518 manje su od granice za standardnu normalnu razdiobu (-1,64) te se pretpostavlja da je razdioba rezultata iz posttesta i pretesta te odgođenoga posttesta i pretesta značajno različita jer su rezultati u posttestovima i odgođenim posttestovima značajno bolji od pretesta. Riječ je čak o vrlo značajnoj statističkoj razlici između rezultata pretesta i posttesta te pretesta i odgođenoga posttesta ($p < 0,01$), što znači da rezultate testa možemo preslikati na širu populaciju. Da odbacimo nultu hipotezu kad se koristimo razinom značajnosti 5 %, mogućnost da se pojavi pogreška tipa I, kod posttesta bila bi 0,63 % te odgođenoga posttesta 0,7 %.

Snaga je provedenoga statističkog testa za posttest 0,9999962 (99,9 %) te odgođeni posttest 0,9997902 (99,9 %), što je prouzročeno kod obaju testova veoma velikom veličinom učinka (za

posttest $d = 2,3321223$, za odgođeni posttest $d = 1,9638924$). Time je mogućnost da se pojavi pogreška tipa II kod oba testa 0,01 %.

Unatoč tomu što studenti eksperimentalne skupine nisu značajno bolji u rezultatima i napretku od studenata kontrolne skupine (analizirano u prošlim dvjema hipotezama), ipak su značajno napredovali nakon nastavnoga sata u kojemu su učili s pomoću igara te su postigli značajno bolje rezultate na posttestu i odgođenome posttestu u odnosu na predtest. Uzimajući u obzir i visoku snagu za provedene statističke testove, kod analize rezultata posttesta i odgođenoga posttesta s velikom sigurnošću možemo odbaciti nultu hipotezu te prihvatiti alternativnu hipotezu za H_a , koja kaže da osobe koje uče hrvatski kao ini jezik, nakon nastave u kojoj se koriste igrificiranim sadržajem, postižu statistički značajno bolji rezultat na testu usvajanja vokabulara.

7.8.6.5. Odgovor na hipotezu H_e

Dodatno se ispitalo postižu li studenti koji vole igrati igre značajne razlike u rezultatima u odnosu na studente koji računalne igre ne vole igrati ili su neutralni s obzirom na njih. Pretpostavlja se da studeni koji vole igre često ih i igraju, a ostali ih ne igraju često ili ih uopće ne igraju. Sve studente neovisno o kontrolnoj i eksperimentalnoj skupini podijelilo se u dvije skupine: one koji vole igrati igre ($n_1 = 11$) i one koji ne vole igrati igre ili su neutralni prema njima ($n_2 = 10$). Za dokazivanje ove hipoteze koristimo se dvosmjernim Mann-Whitneyjevim U-testom ($n_1 \neq n_2$).

Tablica 87. *Opisna statistika kod predtesta za studente koji vole igrati igre i studente koji ih ne vole ili su neutralni*

	n	aritmetička sredina (prosjeak)	medijan	mod	minimum	maksimum	raspon podatka
studenti koji vole igrati igre	11	36,91	39	39	30	42	12
studenti koji su neutralni ili ih ne vole igrati	10	35,40	36,50	37	27	45	18

Tablica 88. Opisna statistika kod posttesta za studente koji vole igrati igre i studente koji ih ne vole ili su neutralni

	n	aritmetička sredina (prosjeak)	medijan	mod	minimum	maksimum	raspon bodova
studenti koji vole igrati igre	11	43	44	46	37	47	10
studenti koji su neutralni ili ih ne vole igrati	10	43,5	44	44	40	47	7

Tablica 89. Opisna statistika kod odgođenoga posttesta za studente koji vole igrati igre i studente koji ih ne vole ili su neutralni

	n	aritmetička sredina (prosjeak)	medijan	mod	minimum	maksimum	raspon bodova
studenti koji vole igrati igre	11	41,91	42	46	35	46	11
studenti koji su neutralni ili ih ne vole igrati	10	43,90	45	46	37	47	10

Iz rezultata povezanih s opisnom statistikom (vidi tablice 87, 88 i 89) možemo vidjeti da su studenti koji su odgovorili da vole elektroničke igre po prosjeku bodova malo bolje napisali pretest, ali malo slabije napisali posttest i odgođeni posttest. Za provjeru ima li statistički značajne razlike kod testova napisan je kod u jeziku R prikazan u tablici 90.

Tablica 90. Naredba u R-u za dobivanje rezultata Mann-Whitneyjeva U-testa za dokazivanje hipoteze H_e

```
#pretest
n1<-c(30,31,32,36,37,39,39,39,40,41,42)
n2<-c(27,29,30,31,36,37,37,38,44,45)
wilcox.test(n1, n2, alternative = "two.sided", paired = FALSE, exact = FALSE, correct = TRUE, conf.int = TRUE)

#posttest
n1<-c(37,38,41,42,42,44,44,46,46,46,47)
n2<-c(40,40,41,42,44,44,45,46,46,47)
wilcox.test(n1, n2, alternative = "two.sided", paired = FALSE, exact = FALSE, correct = TRUE, conf.int = TRUE)
```

```
#odgođeni posttest
n1<-c(35,39,40,40,42,42,42,43,46,46,46)
n2<-c(37,39,44,44,45,45,46,46,46,47)
wilcox.test(n1, n2, alternative = "two.sided", paired = FALSE, exact = FALSE, correct =
TRUE, conf.int = TRUE)
```

Rezultati za testove prikazani su u tablici 91.

Tablica 91. Statističke vrijednosti dobivene Mann-Whitneyjevim U-testom za dokazivanje hipoteze H_e

	predtest	posttest	odgođeni posttest
U	41,5	53	36
z	0,918719	-0,178198	-1,392730
p	0,179121	0,570716	0,918149

Na temelju statističkih vrijednosti koje su dobivene Mann-Whitneyjevim U-testom za predtest, posttest i odgođeni posttest možemo zaključiti da nema statistički značajne razlike u rezultatima između studenata koji vole igrati elektroničke igre i onih koji ne vole igrati elektroničke igre. U-vrijednosti za nijedan od triju ispita nisu dovoljno blizu kritičnoj vrijednosti za dvosmjerni testove (26) da bi se moglo reći da postoje značajne razlike u rezultatima između skupina utemeljenih na rangovima za razinu značajnosti 0,05. Z-vrijednosti za sva tri ispita govore nam da nema velikoga odstupanja među rezultatima jer su svi unutar standardne normalne razdiobe, inače bi z-vrijednost bila iznad -1,96 ili veća od 1,96. Visoka p-vrijednost govori da rezultati testa nisu primjenjivi na širu populaciju te je velika mogućnost da se pojavi pogreška tipa I (kod predtesta 17,91 %, kod posttesta 57,07 % i kod odgođenoga posttesta 91,81 %). Statistička snaga kod provedbe svih triju testova te veličina učinka (d) prikazane su u tablici 92.

Tablica 92. Snaga i veličina učinka za provedene Mann-Whitneyjeve U-testove kod dokazivanja hipoteze H_e

	predtest	posttest	odgođeni posttest
$P = (1 - \beta)$	0,0936874	0,0644844	0,2439648
d	0,2880582	0,1670279	0,5967982

Snage svih triju statističkih testova jako su slabe te postoji velika mogućnost da se pojavi pogreška tipa II (kod predtesta 90,6 %, kod posttesta 93,6 % te odgođenoga posttesta 75,7 %).

Razlog je za to što je slaba statistička snaga testa, osim toga što je malen uzorak, to što je mala veličina učinka u testiranju (d) kod predtesta i posttesta te srednja veličina učinka kod odgođenoga posttesta ($d > 0,5$), do koje dolazi jer se obje skupine ne razlikuju mnogo po rezultatima.

Time se kod H_e zbog slabih snaga za statističke testova ne može doći do valjanoga zaključka povezanoga s time da osobe koje uče hrvatski kao ini jezik te vole igrati elektroničke igre postižu statistički značajne razlike u rezultatima testova usvajanja vokabulara od osoba koje ne vole igrati elektroničke igre ili su neutralne. Da se trenutačnim rezultatima koristimo kao indikatorima, rekli bismo da najvjerojatnije osobe koje vole igrati računalne igre postižu podjednake rezultate kao i osobe koje ne vole igrati računalne igre, što možemo vidjeti iz opisne statistike (vidi tablice 88, 89 i 91).

7.8.6.6. Odgovor na hipotezu H_f

Kad gledamo opisnu statistiku za rezultate studenata na temelju njihove samoprocjene znanja hrvatskoga jezika (vidi tablicu 93), možemo vidjeti da je po prosjeku bodova najbolje rezultate ostvarilo dvoje studenata koji su procijenili svoje znanje hrvatskoga jezika ocjenom vrlo dobar. Studenti koji su svoje znanje ocijenili s dovoljan ili dobar ostvaruju gotovo jednake rezultate na svim trima testovima. Kad usporedimo rezultat jednoga studenta koji pripada eksperimentalnoj skupini koji je ocijenio svoje znanje s nedovoljan s prosjecima ostalih studenata koji su svoje znanje ocijenili višom ocjenom, možemo vidjeti da je taj student malo lošiji od njih, ali je zanimljivo da je kod prvoga posttesta za jedan bod bolje napisao test od studenta koji se jedini ocijenio ocjenom odličan te je odgođeni posttest jednako napisao kao i taj student. Student koji se ocijenio ocjenom odličan pripada kontrolnoj skupini te je bolje napisao predtest samo od studenta koji se ocijenio ocjenom nedovoljan, a studenti koji su se ocijenili ocjenama dovoljan, dobar i vrlo dobar napisali su svaki test bolje od njega.

Tablica 93. *Opisna statistika rezultata studenata u svim trima testovima svrstanih na temelju njihove samoprocjene znanja hrvatskoga jezika*

ocjena	N	predtest			posttest			odgođeni posttest		
		prosjeak	mod	medijan	prosjeak	mod	medijan	prosjeak	mod	medijan
1	1	31	-	31	42	-	42	40	-	40
2	11	36,27	39	39	43,6	46	44	42,82	42	44
3	6	36,67	-	37	42,7	-	43	43,5	46	45,5
4	2	37	37	37	45	-	45	44	-	44
5	1	36	-	36	41	-	41	40	-	40

Zanima nas ima li veze između samoprocjene vlastitoga znanja i ostvarenih rezultata. Za posljednju hipotezu uzimaju se ocjene od nedovoljan do odličan kojima su studenti ocijenili svoje znanje hrvatskoga jezika u upitniku na kraju prvoga sata te su se te ocjene s pomoću Spearmanove korelacije u jeziku R usporedile s rezultatima u predtestu, posttestu i odgođenome posttestu. Nisu se promatrale razlike između skupina.

Napisan je idući kod u jeziku R za dobivanje p-vrijednosti i r_s vrijednosti te dijagrama rasipanja (engl. *scatter plot*) u tablici 94.

Tablica 94. *Naredba u R-u za dobivanje rezultata Spearmanove korelacije za dokazivanje hipoteze H_f*

```
library("ggpubr")

#predtest
samoprocjena <- c(2,2,3,4,2,2,2,2,3,2,5,3,2,3,4,2,3,2,2,1,3)
rezultat_testa <- c(41,31,39,37,37,30,39,42,45,44,36,36,40,30,37,39,32,29,27,31,38)
veza <- data.frame(samoprocjena, rezultat_testa)
ggscatter (veza, x = "samoprocjena", y = "rezultat_testa", add = "reg.line", conf.int =
TRUE, cor.coef = TRUE, cor.method = "spearman", xlab = "samoprocjena", ylab =
"bodovi")

#posttest
samoprocjena <- c(2,2,3,4,2,2,2,2,3,2,5,3,2,3,4,2,3,2,2,1,3)
rezultat_testa<-c(46,45,46,46,44,40,42,46,47,46,41,40,47,37,44,38,44,44,41,42,42)
veza <- data.frame(samoprocjena, rezultat_testa)
ggscatter (veza, x = "samoprocjena", y = "rezultat_testa", add = "reg.line", conf.int =
```

```
TRUE, cor.coef = TRUE, cor.method = "spearman", xlab = "samoprocjena", ylab = "bodovi")
```

```
#odgođeni posttest
```

```
rezultat_testa<-c(42,44,46,46,45,44,42,46,46,47,40,45,46,35,42,39,43,37,39,40,46)
```

```
veza <- data.frame(samoprocjena, rezultat_testa)
```

```
ggscatter (veza, x = "samoprocjena", y = "rezultat_testa", add = "reg.line", conf.int = TRUE, cor.coef = TRUE, cor.method = "spearman", xlab = "samoprocjena", ylab = "bodovi")
```

Dobiveni su idući rezultati u tablici 95 te grafikonima 25, 26 i 27.

Tablica 95. *Rezultati Spearmanove korelacije između samoprocjene znanja studenata i rezultat predtesta, posttesta i odgođenoga posttesta.*

predtest		posttest		odgođeni posttest	
r_s	p	r_s	p	r_s	p
0,021	0,93	-0,023	0,92	0,13	0,56

Grafikon 25. *Dijagrama rasipanja koji prikazuje vezu između bodova u predtestu sa samoprocjenom znanja studenata Croaticuma*

Grafikon 26. *Dijagrama rasipanja koji prikazuje vezu između bodova u posttestu sa samoprocjenom znanja studenata Croaticuma*

Grafikon 27. Dijagram rasipanja koji prikazuje vezu između bodova u odgođenome posttestu sa samoprocjenom znanja studenata *Croaticuma*

p-vrijednosti iz tablice 95 (kod predtesta $p = 0,93$, kod posttesta $p = 0,92$ te kod odgođenoga posttesta $p = 0,56$) snažno upućuju na to da nema značajne povezanosti između samoprocjene trenutačnoga znanja i rezultata svih triju testova. Time možemo reći da dobiveni rezultati testova nisu primjenjivi na širu populaciju. Ako gledamo vrijednost r_s prema interpretaciji koeficijenta korelacije (Petrak, 2010: 4), možemo detaljnije zaključiti da kod predtesta između samoprocjene i bodova postoji slaba povezanost koja ide u pozitivnome smjeru (r_s je između $+0,20$ do $+0,40$), kod posttesta je također slaba povezanost koja ide u negativnome smjeru (r_s je između $-0,20$ do $-0,40$) i kod odgođenoga posttesta nemamo nikakvu ili neznatnu povezanost (r_s je između $0,00$ i $+0,20$). Ipak, sve su te veze slabe i nijedna od njih nije značajna. Također statistička snaga provedene Spearmanove korelacije, koja je izračunana s pomoću veličine uzorka i vrijednosti koeficijenta korelacije (r_s) za svaki test korištenjem jezikom R (kod u tablici 96), jako je slaba za sva tri testa. Snaga je testa za rezultate predtesta $0,05023795$ (5 %), snaga je testa za analizu rezultata posttesta $0,05042727$ (5 %) i snaga je za analize rezultata odgođenoga posttesta $0,08674603$ (8 %). Kod svakoga od tih testova postoji više od 90 % mogućnosti (kod predtesta i posttesta 95 %, a kod odgođenoga posttesta 92 %) da se pojavi pogreška tipa II. Da bismo dobili veću statističku snagu korelacijskoga testa za uzorak koji se sastoji od 21 studenta, trebamo najmanje imati vrijednosti koeficijenta korelacije (r_s) $\pm 0,58$. Time ne možemo doći do valjanoga zaključka za H_f i ne možemo dokazati da postoji značajan odnos između samoprocjene znanja hrvatskoga jezika i rezultata testova usvajanja vokabulara kod osoba koje uče hrvatski kao ini jezik.

Tablica 96. *Naredba u R-u za dobivanje snage korelacijskih testova*

```
# statistička snaga testa korelacije za rezultate predtesta
pwr.r.test(n = 21, r = 0.021, sig.level = 0.05, power = NULL, alternative = "two.sided")

# statistička snaga testa korelacije za rezultate posttesta
pwr.r.test(n = 21, r = -0.023, sig.level = 0.05, power = NULL, alternative = "two.sided")

# statistička snaga testa korelacije za rezultate odgođenog posttesta
pwr.r.test(n = 21, r = 0.13, sig.level = 0.05, power = NULL, alternative = "two.sided")
```

7.9. Zaključak istraživanja

Provedenim istraživanjem nisu potvrđene alternativne hipoteze H_b i H_c koje su povezane s ostvarenjem statistički značajno boljih rezultata i napretka u bodovima kod studenata eksperimentalne skupine, koji su se pri učenju na satu koristili igrificiranim sadržajima, u odnosu na studente kontrolne skupine, koji se takvim sadržajima nisu koristili. Kod H_b za rezultate analize odgođenoga posttesta, koji se odnose na dugoročno znanje, pretpostavlja se da studenti eksperimentalne skupine postižu statistički značajano lošije ili podjednake rezultate od studenta kontrolne skupine. Za rezultate prvoga posttesta, koji se odnose na kratkoročno znanje, kod H_b te posttesta i odgođenoga posttesta kod H_c ne može se donijeti zaključak zbog slabe snage statističkoga testa. Ipak, ako gledamo podatke dobivene iz opisne statistike (tablica 66), možemo kao slabi indikator uzeti u obzir da su studenti kontrolne skupine na temelju aritmetičke sredine imali bolji rezultat na predtestu (za 4,41 boda). Na istome satu nakon igara, kod posttesta te dva tjedna kasnije kod odgođenoga posttesta, studenti eksperimentalne skupine na temelju aritmetičke sredine također su ostvarili veći napredak od kontrolne skupine u odnosu na predtest (razlika je aritmetičkih sredina za napredak između skupina kod posttesta 2,02, a razlika aritmetičkih sredina za napredak kod odgođenoga posttesta 0,78, vidi više u tablicama 87 i 88). Unatoč tomu što nema statistički značajnih razlika među skupinama, ipak se iz dobivenih podataka vidi da je došlo do napretka u bodovima kod eksperimentalne skupine koji je veći od napretka u bodovima kod kontrolne skupine. Međutim, ako se uzme u obzir da je opisna statistika slabiji indikator od provedenih statičkih testova, a mnogi od provedenih testova zbog veličine uzorka imaju slabu statističku snagu, dobivene indikacije upućuju na to da bi, da bi se dobio pouzdan odgovor na hipoteze, trebalo provesti eksperiment na većemu broju ispitanika. Također, bilo bi dobro koristiti se igrifikacijskim sadržajima tijekom više sati nastave jer se time može preciznije izmjeriti utjecaj igrifikacijskih sadržaja pri učenju hrvatskoga kao inoga jezika. To, međutim, iz objektivnih razloga nije bilo moguće u trenutku

pisanja ovoga rada. U dogovoru s voditeljicom Croaticuma odabrane su dvije skupine podjednake veličine i iste razine (ovdje A2), koje su procijenjene najprikladnijima za istraživanje. Iako je istraživanje dogovarano uživo, zbog epidemije bolesti COVID-19 istraživanje je preseljeno na mrežu, što je vjerojatno dovelo do toga da bude nešto manje studenata. Osim toga, mogli su se ocijeniti samo rezultati onih studenata koji su sudjelovali na satu na kojemu se pisao predtest i posttest te na satu na kojemu se pisao odgođeni posttest. Za hipoteze H_e i H_f također se nije mogao dobiti valjan zaključak zbog slabe statističke snage testa. Da je uzorak bio veći, to bi pojačalo snagu statističkoga testa te bi se dobilo statistički značajnije rezultate jer, kad je snaga testa manja, manja je i vjerojatnost da će se dokazati alternativna hipoteza te odbaciti nulta hipotezu, čak i kad postoji stvarna razlika između eksperimentalne i kontrolne skupine (McHugh, 2008: 264).

H_d , koji ima jaku statističku snagu testa, potvrđuje alternativnu hipotezu da nakon poučavanja nastavnoga sadržaja s pomoću igara studenti eksperimentalne skupine postižu statistički znatno bolje rezultate u posttestu i odgođenome posttestu u odnosu na predtest. Pokazalo se da se s pomoću igara može uspješno poučavati nastavni sadržaj koji se odnosi na učenje hrvatskoga vokabulara jer bi u suprotnome rezultati posttestova bili jednaki ili lošiji.

Većina studenata eksperimentalne skupine (8 od 9) u upitniku je odgovorila da im se sviđa nastava s pomoću obrazovnih igara. Iz obiju skupina 11 od 21 studenta napisalo je da voli elektroničke igre, a 10 ih nije sigurno (*ni da ni ne*) te samo jedna osoba ne voli računalne igre. Igre mogu pomoći studentima u učenju hrvatskoga kao inoga jezika i igre mogu biti dobro motivacijsko sredstvo za studente koji vole igre te ne vole učiti ili ponavljati klasičnim metodama. Kod eksperimentalne skupine iz rezultata možemo vidjeti da su najmlađi studenti (generacija Z) ostvarili najbolje rezultate u prvome posttestu unutar svoje skupine (tablica 76) te time možemo pretpostaviti da igre kod mlađih generacija bolje funkcioniraju kao obrazovni medij nego kod starijih generacija koje su se navikle učiti klasičnim metodama.

Treba napomenuti i to da su izrađene igre za istraživanje demoinačice te je riječ o igrama koje su napravljene besplatnom tehnologijom i koje ne sadržavaju naprednu grafiku, mehanike igara te priču. Baš zbog vremenskih i tehničkih ograničenja neki igrifikacijski elementi poput priče sa zadacima nisu napravljeni za sve igre. Primjerice, igre nadopunjavanja, pa čak i kvizovi, mogu integrirati priču s pomoću dvaju izmišljenih likova tako da igrači upisuju, ili u slučaju kviza, biraju pravilne oblike riječi unutar rečenica koje se koriste u razgovoru između dvaju likova. S pomoću priče mogao bi se više istaknuti kontekst za sadržaje koji se uče. Također, na satu nije bilo dovoljno vremena da studenti dulje igraju igre. Na taj bi način studenti mogli detaljnije proučiti sadržaje u igri te proći više puta određene razine. Igre su nov medij u odnosu

na filmove i knjige te se proces igrifikacije obrazovnih sadržaja tek nedavno počeo češće primjenjivati u praksi. Stoga će se obrazovne igre još razvijati te će doći do igara koje će pomoći različitim kategorijama korisnika u svladavanju sadržaja.

Nakon provedenoga istraživanja zaključeno je da će se igre koje se razvijaju za *Mrežnik* doraditi tako da se uzmu u obzir prijedlozi studenata eksperimentalne skupine. Stoga će se dopuniti objašnjenja u rješenjima, dodati više poticajnih riječi u ta objašnjenja kako bi se bolje motivirali igrači te će se uvesti više sadržajnih i težinskih razina jer je npr. kod igre dovlačenja glagola napomena studenata bila da je igra prejednostavna.

8. KONCEPTUALNI OKVIR IGRIFIKACIJE MREŽNOGA RJEČNIKA

Posljednja je hipoteza u radu:

- H₂: *Moguće je izraditi konceptualni okvir igrifikacije mrežnoga rječnika na temelju identifikacije igrifikacijskih elemenata obrazovnih sadržaja.*

Na temelju svih prikupljenih podataka o tome koji se igrifikacijski elementi primjenjuju u obrazovnim sustavima i aplikacijama (poglavlje *Primjena igrifikacije i istraživanja o igrifikaciji*), koje se igre te igrifikacijski elementi primjenjuju u leksikografskim izdanjima, koje se igre i igrifikacijski elementi primjenjuju na mrežnim stranicama arhiva, knjižnica i muzeja (poglavlje *Zastupljenost igrifikacijskih elemenata u leksikografskim izdanjima i informacijskim ustanovama*), analize pedagoških i tehnoloških aspekata za sve identificirane tipove igara na tim stranicama (poglavlje *Tipovi obrazovnih igara*), reakcija na prethodno izrađene igre i rezultata provedenih istraživanja izrađen je konceptualni okvir igrifikacije mrežnoga rječnika koji će biti primjenjiv i na druga leksikografska izdanja. Taj konceptualni okvir objasniti će se na primjeru igrifikacije *Hrvatskoga mrežnoga rječnika – Mrežnika*.

U slučaju *Mrežnika* ta hipoteza govori da je moguće osmisliti igre na temelju postojećih tipova obrazovnih igara i igrifikacijskih elemenata, različite po tipu i sadržaju koje su usklađene s različitim modulima *Mrežnika*. Da radimo na igrifikaciji drugoga tipa rječnika, npr. *Rječnika suvremenih hrvatskih osobnih imena*, onda bi trebalo osmisliti igre i primijeniti igrifikacijske elemente koji bi pomogli korisniku da nauči podatke koji se nalaze u tome rječniku (u ovome primjeru imena ljudi). Slično bi bilo i kod igrifikacije enciklopedija. Tada bi se izradile igre i primijenili igrifikacijski elementi koji bi pomogli korisniku da nauči različite informacije povezane sa sadržajem koji se nalazi u enciklopediji ili da pouči korisnika kako pretraživati i uređivati sadržaj enciklopedije (slično kao igra *The Wikipedia Adventure* spomenuta u poglavlju *Analiza e-enciklopedija*). Konceptualni okvir izrađuje se na temelju *Mrežnika*, ali unatoč tomu, koraci toga okvira osmišljeni su tako da se mogu primijeniti i na druga leksikografska djela.

Pri igrifikaciji *Mrežnika* s pomoću različitih tipova igara treba uzeti u obzir da je riječ o mrežnome rječniku koji će imati odvojene sadržaje za odrasle izvorne govornike, učenike nižih razreda osnovne škole i neizvorne govornike te će se stoga izraditi različiti tipovi igara za poučavanje različitih rječničkih sadržaja (npr. pravopisa, gramatike, riječi, značenja riječi) i omogućiti uporaba različitih multimedija. Iako je početna ideja bila da se igrificira samo modul za učenike nižih razreda osnovne škole, pri razvoju konceptualnoga okvira igrifikacije koji bi

trebao biti primjenjiv i za ostala leksikografska izdanja, zaključeno je da se određeni tipovi igara s igrifikacijskim elementima naprave za sva tri modula. Poticaj za to bile su igre na stranici *Merriam-Webster*, koje su različite s obzirom na sadržaj koji se s pomoću njih uči te neke od tih igara mogu biti korisne i odraslim korisnicima rječnika. Drugi poticaj bila su iskustva stečena tijekom istraživanja igrifikacije u različitim područjima u kojima je ciljni korisnik bio odrasla osoba (u poglavlju *Istraživanja o obrazovnim igrama*). Također je provedeno istraživanje s osobama koje uče hrvatski kao ini jezik na Croaticumu te je provjereno njihovo zadovoljstvo s igrama (u poglavlju *Istraživanje na Croaticumu*).

8.1. Koraci konceptualnoga okvira

Prvi je korak pri izradi konceptualnoga okvira određivanje ključnih koraka istraživanja (Attia, 2018). U procesu izrade konceptualnoga okvira igrifikacije mrežnoga rječnika identificirani su ovi koraci:

1. određivanje obrazovnih sadržaja i ciljeva igara
2. osmišljavanje igara i određivanje koji će se igrifikacijske elementi uključiti
3. izrada igara
4. testiranje i dorada igara
5. objava igara
6. promocija igara
7. praćenje zadovoljstva korisnika.

Koraci uglavnom slijede linearno tako da se nakon završetka jednoga koraka odmah ide na idući korak. Međutim, u slučaju posljednjega koraka (praćenje zadovoljstva korisnika) moguće je vraćanje unazad na četvrti korak (testiranje i dorada igara) zbog potrebe za doradom određenih igara na temelju mišljenja korisnika. Nakon toga ponovno linearno slijede idući koraci te ponovno postoji mogućnost da se sa sedmoga koraka vrati na četvrti korak, u kojemu se dorađuju te ponovno testiraju dijelovi igre. Pri vraćanju na prethodne korake može se preskočiti šesti korak (promocija igara) ako je riječ o sitnoj doradi igre (npr. sitan *bug* ili pravopisna pogreška) ili se aktivnost promocije može provesti u smanjenome opsegu jer je igra već prije objavljena. Zaključeno je da četvrti korak, unatoč tomu što bi se mogao podijeliti u dva zasebna koraka (testiranje igara i dorada igra), bude jedinstven korak jer proizvođači igara najčešće tijekom testiranja dijela igre uočavaju pogreške koje odmah ispravljaju te testiraju idući dio igre. Peti i šesti korak katkad se provode simultano, promocija se često provodi i prije objave, ali razlog zašto su odvojeni je taj što su procesi unutar svakoga koraka dovoljno drukčiji da ih je lakše opisati zasebno. Također glavni procesi promocije kod obrazovnih mrežnih igara za

Mrežnik planiraju se provoditi nakon objave igara. Svaki korak konceptualnoga okvira igrifikacije mrežnoga rječnika objasniti će se u idućim poglavljima na primjeru *Mrežnika*. Pregled cjelovitoga redoslijeda izvođenja koraka nalazi se u prilogu 14 *Konceptualni okvir igrifikacije mrežnoga rječnika*.

8.1.1. Određivanje obrazovnih sadržaja i ciljeva igara

Prvo što treba odrediti prije pristupanja samoj igrifikaciji leksikografskoga djela ciljevi su izrađenih igara. Pri tome treba, uzimajući u obzir vrstu leksikografskoga djela i ciljnoga korisnika, odrediti koje sadržaje leksikografskoga djela želimo naučiti ciljnoga korisnika te do koje razine znanja. Dakle, usporedno s odabirom sadržaja koji se želi naučiti potrebno je i odrediti korisnike koje želimo naučiti te sadržaje uzimajući u obzir njihovu dob i mogući stupanj predznanja (vidi sliku 48). Igra po sadržaju, težini i interesu mora biti prilagođena ciljnomu korisniku koji može biti dijete, odrasla osoba, osoba koja uči neki jezik kao ini itd. Kod primjera igara koje se razvijaju za *Mrežnik* važno je uzeti u obzir da će se njima korisnici služiti za učenje riječi, njihovih oblika, značenja, frazema, kolokacija te drugih informacija koje se nalaze u rječniku. S obzirom na to da je ovaj rad usmjeren na izradu obrazovnih igara za usvajanje sadržaja mrežnoga rječnika, izrađuju se igre koje svojom mehanikom i dizajnom najbolje ispituju znanje korisnika te mu daju najizravnije informacije o onome što želi naučiti. Ipak, igre moraju biti zanimljive kako bi mogle zadržati igračev interes.

Slika 48. Prikaz prvoga koraka konceptualnoga okvira igrifikacije mrežnoga rječnika

Na primjeru *Mrežnika* kod odabira rječničkoga sadržaja za koji se želi napraviti igre sadržaj je podijeljen na temelju jezičnih razina: pravopisna, fonološka, morfološka, sintaktička, tvorbeni, leksička, tekstna, kulturološka itd. (vidi sliku 49). Svaka jezična razina obuhvaća određene

sadržaje koji se mogu uvježbati unutar rječnika (vidi drugi stupac tablice 98 u idućemu poglavlju). Te razine nalazit će se na podstranici *Mrežnika* s igrama.

Slika 49. *Primjer odabira i podjele sadržaja koji se žele igrificirati za Mrežnik*

Ciljni korisnici određeni su modulima *Mrežnika* kao odrasli, učenici nižih razreda osnovne škole i neizvorni govornici hrvatskoga jezika. Za sve kategorije ciljnih korisnika određuju se sadržaji za koje se predviđa da će ih naučiti ili uvježbati igrama. U tablici 97 prikazuju se tri *Mrežnikova* modula s primjerima sadržaja koje igre mogu obuhvatiti.

Tablica 97. *Igrificirani sadržaji Mrežnika u pojedinim modulima*

	osnovni modul	modul za učenike nižih razreda osnovne škole	modul za neizvorne govornike
broj natuknica	10 000 natuknica	3000 natuknica	1000 natuknica
sadržaji koji se mogu uvježbavati u pojedinome modulu	<ul style="list-style-type: none"> • anglizmi • brajica • frazemi • glagoljica • glagolski oblici • glasovne promjene • pravopis (najčešće pogreške, <i>č/ć</i>, <i>dž/ď</i>, <i>ije/je</i>) • znakovni jezik 	<ul style="list-style-type: none"> • boje • brojevi • cvijeće • <i>č/ć</i> • drveće • države • <i>dž/ď</i> • hrana • <i>ije/je</i> • odjeća • planeti • slova • tijelo • točka i zarez (interpunkcija) • veliko i malo slovo • vozila • zanimanja • životinje 	<ul style="list-style-type: none"> • abeceda • osnovni glagolski oblici • oblici imenica • razumijevanje teksta • latinica • pisanje riječi • učenje riječi (može se doraditi zadatke iz modula za učenike nižih razreda osnovne škole: cvijeće, drveće, vozila, zanimanja itd.)

Nekim od sadržaja modula za učenike nižih razreda osnovne škole, posebno u slučaju učenja riječi, mogu se koristiti i neizvorni govornici kad počinju učiti jezik. Ipak, za neizvorne govornike koji tek počinju učiti hrvatski jezik, posebno ako je riječ o govornicima koji ne znaju latinicu, najvažnijim se smatralo da nauče hrvatsku abecedu, glasove i osnovni leksik. Kod učenika nižih razreda osnovne škole igre su usmjerene na prepoznavanje i razlikovanje cvijeća, drveća, dijelova tijela, zanimanja, životinja, država, hrane itd. Također, na pravopisno točno pisanje velikoga i maloga početnoga slova, uporabu pravopisnih znakova, pravilno pisanje *ije/je*, *č/ć* i *dž/đ*. Osnovni modul sadržavat će igre namijenjene učenju hrvatskih zamjena za angлизme, učenju frazema, prepoznavanju glagolskih oblika, učenju posebnih abeceda (glagoljice, brajice i znakovnoga jezika), prepoznavanju glasovnih promjena te još neke igre za učenje pravopisa (*č/ć*, *ije/je*, *đ/dž* – igre se temelje na cjelovitome abecedariju osnovnoga modula).

Na isti način kao što se za *Mrežnik* napravio odabir i podjela sadržaja koji će se igrificirati za svaku skupinu ciljnih korisnika, može se postupiti i igrifikaciji drugih leksikografskih izdanja, uzimajući u obzir njihov sadržaj i ciljne korisnike.

8.1.2. Osmišljavanje igara i određivanje koji će se igrifikacijski elementi uključiti

U drugome koraku konceptualnoga okvira igrifikacije mrežnoga rječnika nastoji se osmisliti igre koje bi svojim zadacima na prikladan način pomogle u utvrđivanju određenoga sadržaja koji je odabran u prošleme koraku te koji bi zanimao ciljne korisnike. Zato treba biti pažljiv pri osmišljavanju zadatka za igre. Svaki tip igara može sadržavati različite igrifikacijske elemente koji mogu pomoći u motiviranju igrača (bodovanje, ljestvice poretka u kojima se pokušava postići što bolji rezultata itd.) te dodatnoj podjeli ili prilagodbi sadržaja igara (s pomoću razina, vremenskoga ograničenja itd.) (vidi sliku 50). Pri odabiru tipa obrazovne igre i igrifikacijskih elemenata važno je znati koji sve tipovi igara i koji sve igrifikacijski elementi postoje. U poglavljima *Zastupljenost igrifikacijskih elemenata u leksikografskim izdanjima* i *Igrifikacijski elementi na mrežnim stranicama informacijskih ustanova* identificirani su tipovi igara i igrifikacijski elementi koji se najčešće upotrebljavaju u obrazovne svrhe. U poglavlju *Tipovi obrazovnih igra* analizirani su pedagoški i tehnički aspekti za tipove igara. Rezultati iz tih poglavlja pomogli su pri osmišljavanju obrazovnih igara za *Mrežnik* te vjerojatno mogu pomoći pri osmišljavanju obrazovnih igara za igrifikaciju drugih leksikografskih izdanja. U budućnosti se podatci tih istraživanja mogu nadopuniti zbog razvoja tehnologije i sve veće uporabe igrifikacije, koja može dovesti do pojave novih tipova igara i igrifikacijskih elemenata. Za *Mrežnik* je na temelju prethodnoga koraka konceptualnoga okvira igrifikacije mrežnoga

rječnika te poznavanja uporabe tipova igara i igrifikacijskih elemenata, odlučeno da će se koristiti idućim tipovima igara: kvizovi, pamtilice, igre dovlačenja, križaljke, zagonetke, igre upisivanja itd. U tablici 98 prikazuju se trenutačno izrađene igre s obzirom na sadržaj koji se njima uvježbava. Detaljniji opis igara za svaku jezičnu razinu nalazi se u idućim potpoglavljima.

Tablica 98. *Primjeri izrađenih tipova igara za Mrežnik na temelju jezičnih razina*

jezična razina	sadržaj koji se uvježbava	tip igre
pravopisna	<ul style="list-style-type: none"> • č/ć • dž/đ • ije/je • kratice i pokrate • pravopisni znakovi • razmaci među riječima • veliko i malo početno slovo 	<ul style="list-style-type: none"> • daktilografska igra • igra dovlačenja • igre popunjavanja praznina • križaljka • kviz
fonološka	<ul style="list-style-type: none"> • glasovne promjene • naglasci • izgovor glasova (č/ć, dž/đ, skupina ije/je) 	<ul style="list-style-type: none"> • daktilografska igra • igra dovlačenja • igre popunjavanja praznina • igre upisivanja izgovorenih riječi • kviz
morfološka	<ul style="list-style-type: none"> • glagolski oblici • oblici zamjenica • oblici imenica 	<ul style="list-style-type: none"> • igra dovlačenja • igre popunjavanja praznina • kviz • pamtilica
sintaktička	<ul style="list-style-type: none"> • poredak riječi u rečenici • najčešće pogreške u rečenici 	<ul style="list-style-type: none"> • igra dovlačenja • kviz
tvorbena	<ul style="list-style-type: none"> • etnici i ktetici • uvećanice • umanjenice • mocijski parnjaci 	<ul style="list-style-type: none"> • igra dovlačenja • igre popunjavanja praznina • kviz • pamtilica
leksička	<ul style="list-style-type: none"> • hrvatske riječi za strane riječi i tuđice • semantička polja • semantički odnosi • frazemi • pronalaženje riječi 	<ul style="list-style-type: none"> • igra dovlačenja • igre popunjavanja praznina • križaljka • kviz • pamtilica

jezična razina	sadržaj koji se uvježbava	tip igre
	<ul style="list-style-type: none"> • značenje riječi 	<ul style="list-style-type: none"> • jedinstvene igre
tekstna	<ul style="list-style-type: none"> • sastavljanje teksta • razumijevanje teksta 	<ul style="list-style-type: none"> • igra dovlačenja • igre popunjavanja praznina • kviz
kulturološka	<ul style="list-style-type: none"> • glagoljica • brajica • znakovni jezik 	<ul style="list-style-type: none"> • kviz • pamtilica • slagalica • jedinstvene igre

Važno je i u svaki tip igre uvrstiti odgovarajuće igrifikacijske elemente. Tablica 99 prikazuje igrifikacijske elemente koji se primjenjuju u igrama određenim za *Mrežnik*. Pri izradi sličnih igara za druga leksikografska izdanja moguće je primijeniti iste igrifikacijske elemente.

Tablica 99. *Igrifikacijski elementi koji se planiraju primijeniti za svaki tip igre u Mrežniku*

igre	igrifikacijski element
kvizovi za učenje glagoljice, brajice, znakovne abecede, prepoznavanje čestih jezičnih pogrešaka i značenja riječi	<ul style="list-style-type: none"> • bodovanje • ljestvice poretka • vremensko ograničenje • značke
pamtilice za spajanje glagoljice s latinicom, pamtilice za spajanje muškoga i ženskoga mocijskog parnjaka, pamtilice za spajanje oblika glagola s pravilnim vremenom	<ul style="list-style-type: none"> • bodovanje • ljestvice poretka • odabir težinske razine • značke
upisivanje nastavaka za glagole	<ul style="list-style-type: none"> • bodovanje • ljestvice poretka • odabir težinske razine • vremensko ograničenje • značke
daktilografska igra	<ul style="list-style-type: none"> • bodovanje • odabir težinske razine • priča
igra dovlačenja glagolskih oblika	<ul style="list-style-type: none"> • bodovanje • vremensko ograničenje • ljestvice poretka
igra upisivanja izgovorenih riječi	<ul style="list-style-type: none"> • bodovanje

igre	igrifikacijski element
igra razvrstavanja planeta, drveća, životinja	<ul style="list-style-type: none"> • bodovanje • priča
tetris za slaganje riječi	<ul style="list-style-type: none"> • bodovanje
igra spajanja slova u riječi	<ul style="list-style-type: none"> • bodovanje • ljestvica poretka • razine

Na temelju gornjega primjera možemo vidjeti da sve igre mogu imati bodovanje. Za većinu kvizova, pamtilica te igara nadopunjavanja mogu se implementirati ljestvice poretka za najbolje igrače. Prva tri igrača na ljestvici nagrađena su značkama (zlatnom, srebrnom i brončanom). Vremensko ograničenje može se uključiti u kvizovima, igrama dovlačenja ili upisivanja riječi. Težinske razine mogu se odabrati kod pamtilica na temelju broja karata koje treba povezati, a kod igre upisivanja nastavaka za glagole igraču se povećava vremensko ograničenje na većim razinama i pojavljuju teža pitanja. Igrifikacijskim elementom *priča sa zadatcima* lakše se koristiti pri igrifikaciji enciklopedija nego rječnika jer enciklopedije često, za razliku od rječnika, opisuju određene povijesne događaje koji se lako pretoče u priču. Unatoč tomu, u *Mrežniku* će se igrifikacijski element priče implementirati u neke igre modula za učenike nižih razreda osnovne škole. Riječ je o jednostavnome sadržaju koji će dati kontekst tomu što igrač radi (npr. u igri razvrstavanja drveća igrač će biti šumar koji mora prepoznavati drveće). Na tome primjeru pokazuje se da se može osmisliti jednostavna priča za svaku igru u rječniku, ali osmišljavanje priče može biti vremenski zahtjevno te za većinu igara namijenjenih odraslima nije potrebno.

Slika 50. Prikaz cijeloga drugog koraka konceptualnoga okvira igrifikacije mrežnoga rječnika

U idućim potpoglavljima prikazani su primjeri igara koje su osmišljene za svaku jezičnu razinu *Mrežnika*. Povremeno se spominju i druge igre koje je autor izradio, a nisu izravno povezane s *Mrežnikom* (npr. igre izrađene za Staroslavenski institut) ili igre sa stranice *Informatičke igre*. Neke od osmišljenih igara već su izrađene te se u svojoj demoinačici nalaze na repozitorijima GitLab ili GitHub, a neke su igre već objavljene na portalima *Hrvatski u školi* i *Jezične igre i multimedijски prikaz znanja*. Na temelju navedenih primjera iz *Mrežnika* objašnjava se kako se koristiti različitim tipovima igra i igrifikacijskim elementima za usvajanje različitih vrsta sadržaja. Ti primjeri odgovaraju jezičnim razinama te se slične igre mogu nalaziti i u drugim mrežnim rječnicima. Mnoge se igre mogu prilagoditi i za druga leksikografska izdanja.

8.1.2.1. Igre za učenje pravopisa

Igre za učenje pravopisa osmišljene su tako da se od igrača očekuje da od više ponuđenih odabere pravilno napisanu riječ ili da utipka pravilnu riječ. Pravopisni kviz⁴³⁰ koji se nalazi na portalu *Hrvatski u školi* izrađen je s pomoću programa H5P te se koristi miješanim tipom pitanja (vidi sliku 51). U planu je prilagođavanje toga kviza i uključivanje u modul za učenike nižih razreda osnovne škole u *Mrežniku*. Igre su sadržajno prilagođene učenicima nižih razreda osnovne škole i sadržavaju šarene ilustracije autorice Ivane Guljašević preuzete iz *Prvoga*

⁴³⁰ URL: <http://hrvatski.hr/igra/9/> (6. 4. 2020.)

školskog pravopisa hrvatskoga jezika⁴³¹. Kviz uključuje zadatke u kojima se razmacima rastavljaju riječi, pišu umanjnice (npr. *cvijet* – *cvjetić*), umeće dio koji nedostaje u riječ (npr. *dž/đ, ije/je, č/ć*), stupnjuju pridjevi (*lijep, ljepši i najljepši*), pišu brojevi slovima, prepisuje tekst pazeći na razmake itd. Postoje i pitanja u kojima se na prazna polja dovlači jedan od ponuđenih odgovora (npr. *dovuci će ili ćete u jedno od polja: Maja _____ pisati zadaću. i Vi _____ posjetiti baku.*).

Napiši neskrraćeno.

U 3. r. išao je u šk. god. 2015./2016.

U 3. razred išao je u školskoj godini 2015./2016.

Kako se glasaju životinje?

Pas laje, mačka mijauče, lav riče

patka pačje, puran

čurliče

provjeri

Napiši umanjnice od idućih riječi, npr. svijet – svjetić.

cvijet cvjetić

rijeka r

snijeg

provjeri rješenja

Popuni prazna mjesta u rečenicama!

Stanovnik Hrvatske je	Hrvat	Stanovnica Hrvatske je	Hrvatica
Stanovnik Japana je	Japanac	Stanovnica Japana je	Japanka
Stanovnik Kine je		Stanovnica Kine je	

provjeri rješenja

Napiši iduće brojeve slovima.

4	četiri
14	četnaest
400	I

provjeri rješenja

Kad završi škola...

Maja	pisati zadaću.
Vi	posjetiti baku.
čete	

provjeri

Prepiši rečenice pazeći na razmake među riječima.

Onneučiništa.	On ne uči ništa.
Nečeseigratisamnom.	
Višenismonečitači.	

provjeri rješenja

Slika 51. Pitanja u pravopisnome kvizu za učenike nižih razreda osnovne škole

Osmislit će se još sličnih kvizova za ispitivanje pravopisa te u njih uvrstiti vremensko ograničenje kako bi igrači bili koncentriraniji na zadatke, morali brže razmišljati i kako bi odgovorili prije nego što vrijeme istekne. Također će se uvrstiti ljestvice poretka kako bi se igrači mogli međusobno natjecati. Druga je igra za učenje pravopisa daktilografska igra *Utipkaj riječi*⁴³². Ta je igra izrađena iz koda dostupnoga na stranici CodePen⁴³³ (na slici 39 može se vidjeti razlika između izvornoga i izmijenjenoga koda). Igra sadržava riječi koje su učenicima

⁴³¹ URL: <http://knjige.ihjj.hr/knjiga/prvi-skolski-pravopis-hrvatskoga-jezika/222/> (7. 4. 2020.)

⁴³² URL: <http://hrvatski.hr/igra/4/> (17. 6. 2019.)

⁴³³ URL: <https://codepen.io/jakealbaugh/full/GopoLa> (7. 4. 2020.)

teške, npr. riječi koje sadržavaju *č/ć*, *ije/je* i *đ/dž*. U igri igrači s pomoću svemirskoga broda gađaju riječi koje padaju tako da ih utipkavaju. Riječi padaju na svemirski brod te pri dodiru s brodom igra završava. Igrač može sam odabrati početnu razinu težine. Na većim težinama pojavljuju se dulje riječi koje brže padaju te igra nakon prolaska jedne razine automatski prebacuje igrača na iduću razinu. Igra će se nadopuniti riječima koje se nalaze u konačnoj inačici abecedarija *Mrežnika*. Može se osmisлити i priča koja se pojavljuje na početku igre (npr. igrači u svemirskome brodu štite Zemlju od izvanzemaljaca koji loše govore hrvatski) kako bi se djeca dodatno motivirala na igranje igre.

Izrađena je križaljka na temelju *Prvoga školskog rječnika*⁴³⁴ s pomoću programa EclipseCrossword koja služi za uvježbavanje riječi s kojima je povezan koji pravopisni problem (vidi sliku 52). Kod dobiven iz toga programa lako se može prilagoditi sadržaju *Mrežnika* kako bi se dobio završni dizajn te funkcionalnosti koje bismo željeli imati u završnoj inačici igre. Mogu se izraditi i križaljke s pomoću kojih će se uvježbavati pisanje riječi (npr. riječi koje sadržavaju *č/ć*, *dž/đ*, *ije/je*, veliko i malo početno slovo, brojevi, državljani i državljanke, umanjnice), ali i učiti značenje riječi s pomoću definicija iz *Mrežnika* (napiši riječ za zadanu definiciju iz *Mrežnika*).

Slika 52. Primjer križaljke s pitanjem u desnome kutu i poljima za odgovor u lijevome kutu

Izrađene su demoinačice novih igara za učenje pravopisa koje se odnose na pisanje riječi koje sadržavaju *č/ć*, *dž/đ* i *ije/je* (vidi sliku 53). U konačnoj inačici upotrijebit će se abecedarij *Mrežnika* za svaki od triju modula. S pomoću programa za izradu rječnika TLex moguće je filtriranjem izdvojiti natuknice koje sadržavaju određena slova te ih izvesti kao popis riječi. Igra i dizajn izrađuju se ručnim pisanjem koda, a ručno treba i pročistiti abecedarij riječi s *ije/je* (npr. iz računalno dobivenoga popisa riječi s *je* treba izbaciti riječi u kojima nije riječ o odrazu jata, npr. *jesen*, *ljubav*). Uz neke će se riječi dodati i slike koje će odgovarati slikama pridruženim obradi natuknica u dječjem modulu *Mrežnika*.

⁴³⁴ URL: <http://hrvatski.hr/igra/5/> (18. 1. 2020.)

ije/je

lije k

Slika 53. Igra nadopunjavanja u kojoj se mora točno napisati riječ koja sadržava ije ili je

Igra se može doraditi i tako da se odabrana riječ nalazi u rečenici (primjer iz *Mrežnika*). S pomoću takvih popisa riječi može se napraviti i pravopisni kviz u kojemu igrač samo odabire ponuđenu riječ umjesto da je upisuje. Predviđeno je da spomenuta igra za pisanje riječi koje sadržavaju *č/ć*, *dž/đ* i *ije/je* omogućiti korisniku da odabere želi li upisivati riječi ili samo pritisnuti na njih.

8.1.2.2. Igre za usvajanje fonološke razine

Igre za uvježbavanje fonološke razine osmišljene su tako da uključuju igre za učenje glasovnih promjena i naglasaka. Pravopisne igre za učenje *č/ć*, *dž/đ* i *ije/je* također bi se mogle uključiti na fonološku razinu. Te igre mogu biti raznolike, poput kvizova, igara dovlačenja, igara popunjavanja praznina te daktilografskih igara. U kvizu koji sadržava pitanja za državnu maturu iz knjige *Hrvatski na maturi*⁴³⁵ možemo vidjeti primjere pitanja koja se odnose na fonologiju (vidi sliku 54). U tome se kvizu uz svaki odgovor daje i objašnjenje.

⁴³⁵ URL: <http://matura.ihjj.hr/> (4. 8. 2020.)

Do kojih glasovnih promjena dolazi u primjeru zadatak – zadatci?

zamjena / s o (vokalizacija), ispadanje suglasnika,
sibilarizacija

nepostojani a, sibilarizacija

zamjena / s o (vokalizacija), nepostojani a, palatalizacija

ispadanje suglasnika, jednačenje po zvučnosti, sibilarizacija

vrijeme preostalo za odgovor: 112

Slika 54. Primjer pitanja iz fonologije u kvizu za maturu

Daktilografska igra za učenje glasovnih promjena⁴³⁶ izrađena je na temelju pravopisne igre *Utipkaj riječi*. U igri igrač treba što brže utipkati samo one riječi u kojima se nalaze određene glasovne promjene. Na svakoj je razini nasumično zadana druga glasovna promjena. Za svaku točno utipkanu riječi igrač dobiva, a za pogrešno utipkanu riječ igrač gubi bod. Igrač također gubi bod ako ne utipka riječ u kojoj se nalazi zadana glasovna promjena. Na kraju igre igrač dobiva ukupan rezultat, broj točno utipkanih riječi, ispis svih pogrešno utipkanih riječi i popis riječi koje nije utipkao, a u kojima se nalazi zadana glasovna promjena. Igra je trenutačno objavljena na stranici *Jezične igre i multimedijски prikaz znanja*. Igra se može prilagoditi za rječnike, npr. *Mrežnik*, tako da se dodaju riječi iz njegova konačnoga abecedarija.

Igra za učenje naglasaka osmišljena⁴³⁷ je tako da se napiše riječ bez naglasaka te označi slovo nad kojim se bilježi naglasak (samoglasnik u naglašenome slogu). Nakon toga igrač mora odabrati naglasak o kojemu je riječ, npr. je li u riječi *sestra* na prvome *e* kratkosilazni (\\), kratkouzlazni (\\), dugosilazni (^) ili dugouzlazni naglasak (/). Zaključeno je da je ovakva igra

⁴³⁶ URL: <https://jezicneigre.com/hr/utipkaj-rijeci-glasovne/> (21. 5. 2020.)

⁴³⁷ Demoinačica igre: https://bornal2.github.io/mreznik_igre/odrasli/naglasci/ (17. 3. 2021)

funkcionalnija od igre nadopunjavanja jer ne znaju svi korisnici kako s pomoću računalne tipkovnice dobiti naglasak na slovu te je mnogo jednostavnije i brže ako se ponude rješenja od kojih treba odabrati pravilno. Izrađuje se i igra dovlačenja, u kojoj se naglasak dovlači na odgovarajuće slovo. Na primjeru *Mrežnika* u svakoj su natuknici rječnika (osim nenaglasnica) označeni naglasci, pa nije teško iz programa TLex izvesti popis naglašenih riječi koji se onda može upotrijebiti za igre. U planu je da *Mrežnik* ima zvučni zapis izgovora natuknica namijenjenih neizvornim govornicima, pa se u modulu za neizvorne govornike razvija igra u kojoj igrač sluša izgovor samostalne riječi ili riječi u rečenici koju neizvorni govornik mora točno napisati. Na stranici *Naučite hrvatski*⁴³⁸ za govornike arapskoga jezika koji uče hrvatski izrađene su igre u kojima igrač prvo posluša izgovor riječi te odabere ili upiše tu riječ. Postoje i polja za izgovor koja pretvaraju tekst u govor, ali ta polja trenutačno rade samo na preglednicima Google Chrome i tehnologija još nije najpreciznija, pa se mora razmotriti njezina primjenu.

8.1.2.3. Igre za usvajanje morfološke razine

Za razliku od nekih igara osmišljenih za uvježbavanje pravopisne razine koje su već javno dostupne na portalu *Hrvatski u školi*, trenutačno razvijene demoinačice igara za učenje morfološke razine pohranjene su na repozitoriju GitLab. Igre se primjenjuju za uvježbavanje morfoloških znanja koja učenicima mogu biti teška. Igre iz ove kategorije mogu uključivati igru pisanja glagolskih oblika i određivanja glasovnih promjena (mješoviti kviz), kviz s čestim jezičnim pogreškama, igru razvrstavanja glagolskih oblika (igra dovlačenja), pamtilicu s pomoćnim glagolima te igru određivanja padeža imenica, pridjeva i zamjenica (Lazić i Mihaljević, 2020: 125). Sve igre izrađene su ručnim pisanjem koda.

„Igru razvrstavanja glagolskih oblika⁴³⁹ vježba se njihovo prepoznavanje, dakle pasivno znanje. Igra trenutačno obuhvaća samo glagolska vremena (prezent, perfekt, aorist, imperfekt, pluskvamperfekt, futur I. i futur II.) te je osmišljena tako da zadane glagolske oblike treba razvrstati u kućice s odgovarajućim vremenima. U svakome zadatku prikazuju se po tri polja s odabranim glagolskim vremenima te devet izmiješanih blokova koji sadržavaju glagole u tim oblicima. Blokove je potrebno razvrstati u zadana polja, što se izvršava dovlačenjem s pomoću miša ili dodirnoga zaslona. Igranje je vremenski ograničeno te igrači za rješavanje svakoga zadatka imaju jednu minutu. Kad se svi blokovi dovuku na neko polje, u blokovima koji

⁴³⁸ URL: https://bornal2.gitlab.io/igre-mreznik/sadrzaji_za_strance/ (9. 4. 2020.)

⁴³⁹ URL: <https://bornal2.gitlab.io/igre-mreznik/glagoli/> (20. 5. 2020.)

sadržavaju točno razvrstane oblike prikažu se osvojeni bodovi, a ako je blok razvrstan u pogrešno polje, u njegovu gornjem desnom kutu prikaže se točno glagolsko vrijeme (vidi sliku 55). Vrijeme i točna rješenja boduju se. Nakon završetka igre rezultati se, ako korisnik to želi, bilježe se u tablicu koja prikazuje poredak svih igrača u igri.” (Ibid.: 125–126).

Slika 55. Igra razvrstavanja glagolskih oblika

Igra pisanja glagolskih oblika⁴⁴⁰ služi igračima kako bi provjerili svoje poznavanje glagolskih vremena. Igra se sastoji od dvanaest nasumično odabranih pitanja na koja moraju odgovoriti.

⁴⁴⁰ URL: <https://borna12.gitlab.io/igre-mreznik/kviz-mijesani/> (7. 4. 2020.)

Igraču se prikaže osnovni glagol koji treba napisati u zadanome licu i vremenu. Igraču je napisana osnova te treba na nju dodati pravilan nastavak (vidi sliku 56).

5/12.
ispeći
aorist 2. lice jd.
ti ispeće

Slika 56. *Primjer pitanja iz igre pisanja glagolskih oblika*

Igraču se daje povratna informacija za svaki odgovor koja je praćena emotikonom. Emotikon je sretno lice ako je igrač točno odgovorio, tužno lice ako je igrač pogrešno odgovorio ili nesretan sat ako je isteklo vrijeme. Povratna informacija osim prikaza točnoga rješenja, koje se pojavljuje ako je korisnik pogrešno odgovorio, sadržava i objašnjenje točnoga odgovora. Određena pitanja imaju i potpitanja s trima ponuđenim odgovorima, koja se pojavljuju nakon što korisnik točno odgovori na pitanje. U potpitanju se traži glasovna promjena do koje je došlo u navedenome glagolu (time ta igra dijelom spada i u igre kojima se ispituje fonološka razina). Boduju se pitanja i potpitanja, a bod se oduzima za pogrešan odgovor. Manje se bodova oduzima za pogrešan odgovor nego što se dobiva za točan odgovor kako se ne bi smanjila motivacija igrača. Na kraju se računa ukupan rezultat igrača. Točno riješena potpitanja nose dodatne bodove, ali pogrešno riješena potpitanja ne nose negativne bodove. Može se odabrati težinska razina igre tako da se uključi vremensko ograničenje za svako pitanje koje može biti po izboru igrača 20 ili 40 sekunda. Vrijeme se boduje samo kod igara s vremenskim ograničenjem. Ako igrač brže točno riješi zadatak, dobiva više bodova. Igrač može predati rezultate igre koristeći se proizvoljnim korisničkim imenom i emotikonom te vidjeti položaj svojega rezultata u odnosu na ostale igrače. Za prva tri mjesta igrači dobivaju medalje. Odvojeno se gledaju ljestvice poretka za igre bez vremenskoga ograničenja od ljestvica igara s vremenskim ograničenjem.

Kviz s čestim jezičnim pogreškama⁴⁴¹ prikazuje pitanje kao rečenicu koja ima prazninu na određenome mjestu za koju igrač treba odabrati pravilan glagolski oblik. Odgovori su ponuđeni

⁴⁴¹ URL: <https://bornal2.gitlab.io/igre-mreznik/kviz-cesta-pogreske/> (17. 1. 2020.)

korisniku te treba odabrati pravilan odgovor. Za svako pitanje postoji vremensko ograničenje od 10 sekunda. Pitanja su nasumično odabrana te im je redoslijed nasumičan (vidi sliku 57).

Slika 57. Primjer pitanja u kvizu s čestim jezičnim pogreškama

Za svaki odgovor pojavljuje se napomena s objašnjenjem rješenja (vidi sliku 58). To je posebno važno ako uzmemo u obzir da je napomena studenata s Croaticuma bila da bi trebalo dati više opisa za točne odgovore u igrama. Igra također pohranjuje rezultate u tablicu rezultata.

Slika 58. Napomena koja se pojavljuje na kraju pitanja u kvizu Česte jezične pogreške

„Pamtilica za pomoćne glagole⁴⁴² igra se tako da igrač odabere razinu za glagol *biti* ili *htjeti* za koje mora spojiti oblik glagola s glagolskim vremenom (npr. za glagol *biti* kartica futur 1. povezuje se s karticom *bit ću*). Nakon što igrač odabere glagol može dodatno odabrati razinu koja određuje težinu igre. Prva razina ima četiri para za spajanje, druga razina ima osam parova, a treća razina ima dvanaest parova (vidi sliku 59). Razine za *biti* i *htjeti* imaju drukčije slike

⁴⁴² URL: <https://bornal2.gitlab.io/igre-mreznik/pamtilica-pomocni-glagoli/> (17. 1. 2020.)

poledine koje se sastoje od oblaka riječi koje sačinjavaju različiti oblici spomenutih glagola. Igra nema vremensko ograničenje, ali se boduje vrijeme te broj poteza koji su potrebni igraču da završi igru. Rezultati se po želji spremaju u tablicu. Kao i kod prethodnih igara rezultati svih igrača podijeljeni su po tipu igre s obzirom na odabranu težinu, a u ovome slučaju i s obzirom na odabrani glagol.” (Lazić i Mihaljević, 2020: 128).

Slika 59. Razina pamtilice za glagol biti

Više o spomenutim gramatičkim igrama v. u radu *Morfološke igre na primjeru igara za učenje glagolskih oblika* (Lazić i Mihaljević, 2020).

Izradit će se i morfološke igre za neizvorne govornike. Razvijena je igra dovlačenja u kojoj igrač treba dovući svršeni ili nesvršeni glagol u odgovarajuće prazno polje kako bi rečenica bila pravilna⁴⁴³.

Izrađuju se i igre za učenje padeža, npr. dorađene inačice igara koje su razvijene za studente na Croaticumu poput igara dopunjavanja (dativ pridjeva i imenica)⁴⁴⁴ u kojima se u rečenice upisuje dativ imenica i pridjeva. Predviđena je izrada više takvih igara za učenje ostalih padeža imenica, pridjeva i zamjenica (vidi sliku 60). Također se može napraviti kviz s ponuđenim oblicima riječi u različitim padežima ili igra dovlačenja padeža u kojoj treba prepoznati padeže za riječi u rečenicama (npr. u rečenici *Slušam lijepu pjesmu na radiju.*, odredi padeže u kojima su riječi *pjesma* i *radio*). Takva bi igra bila iznimno korisna za učenike i studente koji

⁴⁴³ URL: <https://borna12.gitlab.io/igre-mreznik/igoli-dovlacenje/> (20. 5. 2020.)

⁴⁴⁴ URL: <https://borna12.github.io/croaticum/nadopunjavanje/index.html> (18. 4. 2020.)

uče/uvježbavaju padeže. Za neizvorne govornike može se izraditi igra u kojoj za imenice treba upisati ili odabrati pravilan oblik (npr. *Dao sam knjiga/knjigu/knjizi prijateljici.*).

ljetni praznik (množina)

Veselimo se .

Slika 60. Pitanje u igri u kojoj treba upisati dativ zadanih riječi i izraza u rečenici

8.1.2.4. Igre za učenje tvorbene razine

Igre za učenje tvorbene razine izrađene su za etnike i ktetike, uvećanice, umanjenice i mocijske parnjake. Poveznice za etnike i ktetike na portalu *Hrvatski u školi*⁴⁴⁵ uvrštene su u obradu određenih natuknica *Mrežnika*. Neka pitanja u pravopisnome kvizu na portalu *Hrvatski u školi* odnose se na etnike i ktetike. Iz *Mrežnika* se mogu izvesti sve natuknice koje sadržavaju ktetike te se za njih može napraviti igra upisivanja slična pitanjima iz spomenutoga pravopisnog kviza, ali za razliku od pitanja iz toga kviza prikazat će se slike za etnike i ktetike. Za mocijske parnjake izrađena je igra pamtilica koja se trenutno nalazi na stranici *Jezične igre*⁴⁴⁶ i *Muško i žensko u hrvatskome jeziku*. U njoj se spajaju muške i ženske profesijske imenice te riječi koje označuju životinje i ljude (vidi sliku 61).

⁴⁴⁵ URL: <http://hrvatski.hr/etnici-i-ktetici/> (11. 1. 2020.)

⁴⁴⁶ URL: <https://jezicneigre.com/hr/musko-zenski-parovi/> (19. 1. 2020.)

vozačica	odgojitelj	odgojiteljica

istraživačica	blagajnica
vozač		zubar

inženjerka	istraživač	zubarica

Slika 61. Pamtilica s profesijskim imenicama

Osim pamtilica za mocijske parnjake izradit će se i ostali tipovi igara poput kvizova, igara nadopunjavanja, križaljka, igara dovlačenja itd.

Česte uvećanice i umanjenice mogu biti samostalne natuknice u *Mrežniku*. Katkad se bilježe samo među mrtvim tvorenica te se te riječi također mogu izvesti iz *Mrežnika*, a njihov sadržaj (mali x, veliki x) igrificirati. Tu bi također najbolje bilo napraviti igru nadopunjavanja jer se kod pitanja za umanjenice i uvećanice često ispituje pravopis (npr. *č/ć* kod pitanja tipa *list – listić, prozor – prozorčina*, odraz jata *zvijezda – zvjezdica*), katkad se u istoj riječi može ispitati i *č/ć* i odraz jata, npr. *svijet – svjetić, cvijet – cvjetić*. Već je izrađen kviz s ponuđenim odgovorima⁴⁴⁷ za ispitivanje uvećanica i umanjenica. Taj bi se kviz mogao prilagoditi tako da ima više pitanja usklađenih s obradom koja se nalazi u rječniku, slika te više igrifikacijskih elemenata (vremensko ograničenje, razine, ljestvice poretka, sustav nagrađivanja).

8.1.2.5. Igre za uvježbavanje leksičke razine

Igre osmišljene unutar leksičke razine za *Mrežnik* trenutačno su na repozitoriju *GitLab* te su uglavnom namijenjene modulu za učenike nižih razreda osnovne škole, ali se razvijaju i igre za opći modul i modul za neizvorne govornike. Pri izradi igara za učenike nižih razreda osnovne škole uz *Mrežnik* koristilo se i *Prvim školskim rječnikom*⁴⁴⁸. Možemo ih podijeliti u dvije potkategorije: igre za učenje značenja riječi i igre za pronalaženje riječi. Igre za učenje značenja

⁴⁴⁷ URL: <https://learningapps.org/view3291524> (24. 5. 2020.)

⁴⁴⁸ URL: <http://knjige.ihjj.hr/knjiga/prvi-skolski-rjecnik-hrvatskoga-jezika/201/> (29. 11. 2019.)

riječi uključuju kvizove i igre dovlačenja. Kvizovi poput kviza za učenje naziva cvijeća⁴⁴⁹ prikazuju sliku cvijeta, a igrač mora prepoznati cvijet sa slike te odabrati točan od četiriju ponuđenih odgovora (vidi sliku 62).

Slika 62. Prikaz pitanja u kvizu za učenje naziva cvijeća

Igraču se u povratnoj informaciji prikaže i točna definicija riječi, u slučaju kviza s cvijećem definicija za cvijet koji se nalazi na slici. Definicije su preuzete iz *Mrežnika*.

Isti tip kviza izradit će se i za životinje, drveće, zanimanja, hranu, odjeću, vozila, glazbala, boje itd., tj. mogu se obraditi različita semantička polja. Također, se slične igre mogu osmisлити i izraditi za sadržaje koji se nalaze u enciklopedijama te u tim igrama povratna obavijest može biti iscrpnija. Osim djece neizvorni se govornici također mogu koristiti takvim kvizovima kako bi naučili i utvrdili značenja riječi, npr. u istraživanju na Croaticum koristilo se kvizom za učenje dijelova automobila⁴⁵⁰.

Igre dovlačenja funkcioniraju tako da igrač mora rasporediti slike u odgovarajuća polja. Trenutačnu su osmišljena dva tipa igara dovlačenja. U prvome tipu igre dovlačenja treba

⁴⁴⁹ URL: <https://bornal2.gitlab.io/igre-mreznik/kviz-cvijece/> (21. 5. 2020.)

⁴⁵⁰ URL: <https://bornal2.github.io/croaticum/kviz-dijelovi-auta/index.html> (23. 4. 2020.)

određenim redoslijedom razvrstavati riječi, npr. poredati planete Sunčeva sustava⁴⁵¹ (vidi sliku 63).

Slika 63. Igra dovlačenja u kojoj treba poredati planete Sunčeva sustava

U toj igri za svaki točno poredan planet igrač dobiva bodove te definiciju planeta preuzetu iz rječnika (u ovome slučaju *Mrežnika*). Kod za razvoj igre nalazi se na stranici CodePen⁴⁵². Slična se igra za djecu može napraviti tako da se redaju dani u tjednu ili mjeseci u godini.

Izrađena je i igra u kojoj se u dva stupca razvrstava drveće na crnogorično i bjelogorično⁴⁵³ ili plodovi na voće i povrće⁴⁵⁴ (vidi sliku 64). Kao i kod igre s planetima dobiva se definicija riječi iz rječnika za svaki točan odgovor. Takav je tip igre također primjeren igrifikaciji enciklopedija.

⁴⁵¹ URL: <https://bornal2.gitlab.io/igre-mreznik/planeti> (21. 5. 2020.)

⁴⁵² URL: <https://codepen.io/jcoulterdesign/pen/eJGoOx> (21. 5. 2020.)

⁴⁵³ URL: <https://bornal2.gitlab.io/igre-mreznik/drvece/> (21. 5. 2020.)

⁴⁵⁴ URL: https://bornal2.gitlab.io/igre-mreznik/voce_povrce/ (21. 5. 2020.)

Slika 64. Igra dovlačenja u kojoj se razvrstava drveće na bjelogoricu i crnogoricu

Kao i u kvizu može se koristiti postojećim tipom igre za razvrstavanje životinja na domaće i divlje, raspoređivanje država na kontinente, redanje brojeva po veličini itd. Jedna potkategorija igara za učenje riječi igre su u kojima igrač treba pronaći traženu riječ.

Na ovoj se razini razvijaju i igre u kojima se traže hrvatske zamjene za strane riječi i tuđice. Na portalu *Hrvatski u školi* već je napravljena pamtilica⁴⁵⁵ za spajanje angлизama s hrvatskim riječima na temelju popisa koji se nalazi na portalu *Bolje.hr!* (vidi sliku 65). Uz natuknicu *anglizam* u osnovnome modulu nalazi se i poveznica na tu igru. Mogu se izraditi slične igre koje bi se povezivale s natuknicama turcizam, germanizam, romanizam itd. Može se napraviti i igra u kojoj se povezuje hrvatske riječi (natuknice u *Mrežniku*) s istoznačnim angлизmima, turcizmima, germanizmima te drugim stranim riječima ili igra u kojoj niz posuđenica treba razvrstati na angлизme, germanizme, turcizme itd. Takva bi igra bila korisna srednjoškolcima za uvježbavanje nastavnoga gradiva.

⁴⁵⁵ URL: <http://hrvatski.hr/igra/3/> (16. 3. 2020.)

Slika 65. Pamtilica u kojoj se spajaju hrvatske riječi s anglicizmima

Za leksičku razinu također se mogu napraviti igre nadopunjavanja ili dovlačenja u kojima igrač mora dovući ili nadopuniti riječi u rečenici. Sličan primjer takve igre napravljen je za istraživanje na Croaticumu. Riječ je o igri u kojoj se dovlače riječi u rečenice⁴⁵⁶ (vidi sliku 66).

Slika 66. Igra dovlačenja u kojoj se nadopunjavaju rečenice ponuđenim riječima

Trenutačno se razvijaju i dvije jedinstvene igre za pronalaženje riječi. Jedna je igra tetris u kojoj se umjesto redaka spajaju riječi koje se nalaze u rječniku⁴⁵⁷. Za svaku spojenu riječ pojavljuje se sa strane definicija iz *Mrežnika* (vidi sliku 67). Kod koji je preuzet za tu igru sa stranice

⁴⁵⁶ URL: <https://bornal2.github.io/croaticum/dovlacenje/index.html> (23. 5. 2020.)

⁴⁵⁷ URL: <https://bornal2.gitlab.io/igre-mreznik/lettris-master/> (25. 9. 2019.)

GitHub izrađen je za engleski rječnik⁴⁵⁸. U testiranju koda uspelo se u probnoj inačici igre prilagoditi algoritam za hrvatski jezik, u kojemu je uvijek problem s dijakritičkim znakovima. Kad se iz programa za izradu rječnika TLex izveze cijeli abecedarij *Mrežnika* te se unesu sve definicije, u programu će se napraviti izvoz riječi i njihovih definicija koje će se ubaciti u igru.

Slika 67. Igra tetris u kojoj se spajaju slova u riječima te se za određene riječi dobivaju definicije

Druga je jedinstvena igra igra za pronalaženje riječi pod radnim nazivom *Slovotris*, koja se igra tako da padaju blokovi sa slovima koje igrač treba spojiti u riječi⁴⁵⁹ (vidi sliku 68). Igra će također biti dovršena kad se napravi izvoz svih riječi iz *Mrežnika*.

⁴⁵⁸ URL: <https://github.com/bamsarker/lettris> (25. 9. 2019.)

⁴⁵⁹ URL: <https://bornal2.gitlab.io/igre-mreznik/slovotris/> (25. 9. 2019.)

Slika 68. Igra u kojoj se spajaju blokovi slova u riječi s pomoću miša

8.1.2.6. Igre na sintaktičkoj razini

Igre na sintaktičkoj razini mogu biti usmjerene na povezivanje riječi u rečenice, određivanje vrsta sintagma i vrsta rečenica. Povezivanja riječi u rečenice može se uvježbavati s pomoću igre dovlačenja u kojoj se mora složiti pomiješane riječi u smislene rečenice te se također može napraviti kviz koji sadržava slična pitanja kao kviz za maturu (određivanje rečeničnih dijelova, uočavanje pogrešaka u rečenici, odabir pravilno napisanih rečenica) (vidi sliku 69).

Slika 69. Prikaz pitanja s objašnjenjem odgovora iz kviza za maturu hrvatskoga jezika

8.1.2.7. Igre na tekstnoj razini

Igre na tekstnoj razini uglavnom su rađene za neizvorne govornike hrvatskoga jezika. Budući da su usmjerene na razgovor, mogu se osmisliti likovi i radnja te se od igrača očekuje da razumije događaje i situacije. Sličan je tip igre izrađen za istraživanje na Croaticumu, u kojemu se provjeravalo znanje činjenica koje se nalaze u tekstu. Igrač je pročitao tekst koji govori o određenome sadržaju (npr. prvi tramvaj i automobil) (vidi sliku 70).

Zagrepčani su 1891. godine dobili prvi tramvaj. Vukli su ga konji. Prvi električni tramvaji počeli su voziti 1905. godine. Četiri godine prije, 1901., prvi automobil pojavio se na zagrebačkim ulicama. A u svijetu?

Prvi tramvaj postavljen je na tračnice 1832. godine u New Yorku. Također su ga vukli konji. Prvi električni tramvaj na svijetu izgrađen je u tvornici „Werner von Siemens” i pokrenut je 1881. godine u Berlinu, a vozio je maksimalnom brzinom od 20 kilometara na sat. Prvi automobil, marke Mercedes, konstruirao je Gottlieb Daimler 1885. U Francuskoj se prvi automobil pojavio 1890., a u Americi 1892. godine. Proizveo ga je Henry Ford.

pokreni

Slika 70. Prikaz teksta upotrijebljenoga u kvizu razumijevanja teksta

Nakon što pročita tekst, igrač može pokrenuti kviz u kojemu se ispituje sadržaj teksta. Ako ne zna odgovor, može se vratiti na tekst ponovnim pritiskom na poveznicu u igri (i) (vidi sliku 71).

Konjski tramvaj u Zagrebu postojao je na kraju 19. stoljeća.

56

netočno točno

tekst i

Slika 71. Prikaz pitanja koje se odnosi na tekst o prvim tramvajima i automobilima

Mrežnik ima mnogo primjera uporabe riječi u rečenici i u kolokacijama. Na temelju njih može se sastaviti radnja igre. Na stranici *Jezične igre* nalazi se igra dovlačenja *Dan u životu*. Na igri je u stripu prikazan svakodnevni život poslovnoga čovjeka. Igra je izrađena s pomoću H5P-a. U njoj igrač treba dovući rečenicu u kojoj je opisana određena dnevna aktivnost do crteža na kojemu je prikazana ta aktivnost. Igra je namijenjena neizvornim govornicima koji uče hrvatski kao ini jezik te im omogućuje ponavljanje izraza koji se upotrebljavaju za opisivanje tipičnih dnevnih aktivnosti⁴⁶⁰ (vidi sliku 72).

Slika 72. Prikaz igre *Dan u životu* u kojoj se uče izrazi za dnevne aktivnosti

8.1.2.8. Igre za promicanje kulture i jednakosti

Posljednja skupina igara koje su razrađene za *Mrežnik* usmjerena je na promicanje kulture (npr. stara pisma, književna razdoblja, mitologija) te sadržaje za promicanje jednakosti i tolerancije (brajica, jednoručna i dvoručna abeceda). Trenutačno postoje izrađene igre za učenje glagoljice

⁴⁶⁰ Više o igri *Dan u životu* u radu *Mrežne igre u poučavanju i učenju hrvatskoga jezika* (Mihaljević i Mihaljević, 2019: 126–127).

te drugih posebnih abeceda, poput abecede za brajicu te znakovni jezik. Igre za učenje glagoljice nalaze se i na stranicama Staroslavenskoga instituta⁴⁶¹. Jedna od tih igara uključuje pamtilicu u kojoj se sparuju latinična i glagoljična slova⁴⁶².

Ta je igra poslužila kao poticaj da se napravi bolja inačica pamtilice s glagoljicom i kviz za učenje slova oble i uglate glagoljice te stranica za učenje pisanja glagoljičnih slova. Novi interaktivni sadržaji za učenje glagoljice izdani su na Dan hrvatske glagoljice i glagoljaštva⁴⁶³ na portalu *Hrvatski u školi*, na podstranici *Volim glagoljicu*. Te će se igre također uvrstiti u *Mrežnik* (natuknica *glagoljica*). U novoj inačici pamtilice⁴⁶⁴ igrači mogu odabrati žele li imati pomoć pri spajanju slova tako da su ista slova dviju abeceda jednako obojena. Igrači mogu igrati pamtilicu i bez takve pomoći. Usto mogu podesiti težinu tako da odaberu koliko parova žele spajati (4, 8 i 12). Za svaku igru pamtilice boduje se broj pokušaja spajanja te vrijeme potrebno da se igra dovrši. Igrač za svaki spojeni par dobiva petnaest bodova, a za pogrešno spojeni par gubi pet bodova. Bodovi koji se dobivaju spajanjem parova povećavaju se na kraju igre ako igrač brže završi igru. Rezultat svake igre može se predati u tablicu rezultata. Igrač zato mora koncentriranije brže igrati igru kako bi ostvario bolje rezultate. Budući da se vrijeme dodatno boduje, rezultati su raznolikiji te ih je lakše poredati u tablicu (vidi sliku 73).

Slika 73. Glagoljična pamtilica na portalu Hrvatski u školi

⁴⁶¹ Više o izradi tih igara u člancima *Elektroničke mrežne igre za učenje glagoljice* i *Nove mrežne igre za učenje glagoljice* (Mihaljević, 2016a i Mihaljević, 2017c)

⁴⁶² URL: https://www.stin.hr/hr/article/120/memori_s_glagoljicom (21. 5. 2020.)

⁴⁶³ URL: <http://ihjj.hr/clanak/danas-je-dan-hrvatske-glagoljice-i-glagoljaštva/7308/> (23. 9. 2019.)

⁴⁶⁴ URL: <http://hrvatski.hr/games/pamtilica-glagoljica/> (16. 6. 2019.)

Kod kviza za učenje glagoljice⁴⁶⁵ igrač za pogađanje može odabrati uglata ili obla glagoljična slova. Igraču se prikazuje slika glagoljičnoga slova za koje mora odabrati jedan od četiriju ponuđenih odgovora. Točan odgovor nikad se ne nalazi na istome mjestu, a netočni su odgovori odabrani nasumično. Pitanja su uvijek izmiješana te je svaka nova igra kviza različita. Kako bi se povećala dinamika igre te uvele veće razlike u rezultatima, uvedeno je vremensko ograničenje od 10 sekunda za svako pitanje (vidi sliku 74).

Slika 74. Pitanje u kvizu za učenje oble glagoljice

U svrhu promicanje hrvatske baštine izradit će se i igre koje se odnose na glagoljične spomenike poput Bašćanske ploče. Za Bašćansku ploču na portalu *Jezik.hr*⁴⁶⁶ Instituta za hrvatski jezik i jezikoslovlje napravljena je slagalica koja daje osnovne obavijesti o Bašćanskoj ploči. Igrač u igri može odabrati broj dijelova za slaganje (vidi slike 75 i 76). Pri igrifikaciji enciklopedija slične bi se igre mogle izraditi i za ostale spomenike.

⁴⁶⁵ URL: <http://hrvatski.hr/games/kviz-glagoljica/> (15. 4. 2020.)

⁴⁶⁶ URL: <http://jezik.hr/bascanska-slagalica.html> (22. 5. 2020.)

Slika 75. Slagalica s Baščanskom pločom

Slika 76. Tekst o Baščanskoj ploči koji se pojavljuje nakon što se složi slagalica

Na stranici *Jezične igre* te na stranicama Staroslavenskoga instituta⁴⁶⁷ mogu se primijetiti mnoge jedinstvene igre za učenje glagoljice poput tetrisa, zmije, pac-mana, igre pucnjave (engl. *shooter*) te igre nadahnute igrom *flappy bird*, koje pokazuju da se abeceda može učiti na različite načine (vidi sliku 77).

Slika 77. Jedinstvene igre za učenje glagoljice⁴⁶⁸

Slično kvizu za učenje glagoljice napravljen je i kviz za učenje znakovne abecede i brajice. Kviz za učenje znakovne abecede objavljen je 23. rujna 2019. u povodu Međunarodnoga dana znakovnih jezika⁴⁶⁹. U kvizu igrač može odabrati želi li igrati igru s jednoručnom ili dvoručnom znakovnom abecedom.

Kviz za učenje brajice⁴⁷⁰ nije namijenjen slijepim osobama jer se uči igrajući ga vizualno, nego ljudima koji rade s njima te ljudima koje zanimaju slova brajice. Kviz nudi šest praznih polja koja sačinjavaju brajične znakove. Igrač mora za zadani znak abecede, aritmetički ili pravopisni

⁴⁶⁷ URL: https://www.stin.hr/hr/category/obrazovne_igre/29 (22. 5. 2020.)

⁴⁶⁸ Više o izradi tih igara možete pročitati u člancima *Elektroničke mrežne igre za učenje glagoljice* i *Nove mrežne igre za učenje glagoljice* (Mihaljević, 2016a i Mihaljević, 2017c).

⁴⁶⁹ URL: <http://ihjj.hr/clanak/nauci-slova-znakovnoga-jezika/7386/> (21. 5. 2020.)

⁴⁷⁰ URL: <http://ihjj.hr/brajica/> (18. 5. 2020.)

znak odabrati sva polja koja sačinjavaju taj znak u brajici (vidi sliku 78). Igra je objavljena na Međunarodni dan bijelog štapa 15. listopada 2019. Poveznice na navedene igre nalaze se u *Mrežniku* uz natuknice *glagoljica*, *znakovni jezik*, *abeceda*, *brajica*. Na isti način izradit će se i igra za učenje hrvatske ćirilice.

Slika 78. Pitanje u kvizu za učenje slova brajice

Osim igara za učenje abeceda može se učiti i druge sadržaje iz kulture povezane s hrvatskim jezikom i sadržajem rječnika. Primjerice na stranici *Jezične igre* postoji igra *Autori po razdobljima*⁴⁷¹ napravljena u H5P-u, u kojoj treba autora smjestiti u odgovarajuće razdoblje. Zastupljeni su najvažniji autori iz književnih razdoblja od antike do realizma. Igra može poslužiti kao ponavljanje za maturu (vidi sliku 79). Takva igra mogla bi se povezati s natuknicom rječnika *književnost*, a natuknice povezane s književnim razdobljima s natuknicama *antika*, *renesansa*, *barok*, *realizam* itd. Po istome bi se modelu mogla napraviti igra u kojoj bi se povezivali autori rječnika i gramatika s njihovim djelima.

Na stranici *Jezične igre* postoje različiti kvizovi izrađeni s pomoću H5P-a koji se odnose na grčke antičke junake, mitološka bića te grčke i rimske bogove⁴⁷². Primjerice poveznica na *Kviz o Ahileju*⁴⁷³ može se staviti u podnatuknicu *Ahilova peta*, a igra *Prepoznavaj mitološko biće*⁴⁷⁴

⁴⁷¹ URL: <https://jezicneigre.com/autori-po-razdobljima/> (24. 5. 2020.)

⁴⁷² URL: <https://jezicneigre.com/mitologija/> (24. 5. 2020.)

⁴⁷³ URL: <https://jezicneigre.com/kviz-o-ahileju/> (24. 5. 2020.)

⁴⁷⁴ URL: <https://jezicneigre.com/prepoznaj-mitolosko-bice/> (24. 5. 2020.)

može se staviti kao poveznica u natuknice *biće* i *mitologija*. Takve su igre posebno prikladne za enciklopedije.

Slika 79. Prikaz igre Autori po razdobljima u kojoj se dovlače imena autora u odgovarajuća razdoblja

Za neizvorne govornike također se može izraditi igra o Hrvatskoj s pomoću koje oni mogu naučiti neke činjenice o Hrvatskoj (gradovi, županije, hrana itd.).

8.1.3. Izrada igara

Proces izrade igara iscrpno je objašnjen u potpoglavlju *Razvoj obrazovnih igara*. Nakon što se osmisle igre sa zadatcima te odaberu igrifikacijski elementi za svaku igru, važno je odabrati između mnogih dostupnih tehnologija koje omogućuju izradu željenih igara. Često u tome procesu dolazi do testiranja tehnoloških rješenja za izradu određene igre, tj. provjere je li s pomoću određenoga programa ili koda moguće programirati ili dizajnirati određeni dio igre. Ako nije moguće dobiti željene funkcionalnosti u igri s pomoću odabranoga rješenja, potrebno je pronaći novo tehnološko rješenje. Kad je odabranom tehnologijom moguće izraditi igru, nakon njezine se izrade može krenuti na idući korak u kojemu se testira igra ili dijelovi igre (vidi sliku 80).

Slika 80. Prikaz cijeloga trećeg koraka konceptualnoga okvira igrifikacije mrežnoga rječnika

U zaključku poglavlja *Tipovi obrazovnih igara* prikazuju se tehnologije primijenjene za izradu igara za *Mrežnik*. Ta tehnička rješenja mogu se primijeniti i pri izradi igara za druga leksikografska izdanja. Kod *Mrežnika* većina igara izrađena je pisanjem koda, ali su kodovi za igre bili preuzeti sa stranica kao što su CodePen i GitHub te su izmijenjeni. Na isti način izmjenom postojećih kodova mogu se napraviti igre za druga leksikografska izdanja. H5P omogućuje besplatnu izradu kvizova, igara nadopunjavanja, igara upisivanja izgovorenih riječi te pamtilica unutar grafičkoga sučelja te to može biti dobro rješenje za one koji nemaju vještine programiranja i dizajniranja igara.

8.1.4. Testiranje i dorada igara

Nakon što se igra izradi, potrebno ju je testirati. Proizvođač igre prvo samostalno igra igru te uočava pogreške koje mora ispraviti. Osim toga, važno je testirati igre na određenoj skupini kojoj je igra namijenjena. Čak i za manje i jednostavne igre poželjno je da ih testiraju drugi prije nego što se objave jer se često mogu uočiti sitne pogreške koje autor nije vidio pri vlastitome testiranju. Na četvrti korak (proces dorade igre) može se vratiti kad se dođe do

sedmoga koraka u kojemu se prate reakcije igrača te ti igrači mogu dati povratne informacije u kojima zahtijevaju da se doradi igra. Bolje je objaviti prvu inačicu igre sa što manje pogrešaka (vidi sliku 81).

Zbog toga su demoinačice igara za *Mrežnik* prije završne dorade i objave bile predstavljene suradnicima na *Mrežniku*, a nakon toga učenicima i nastavnicima osnovnih i srednjih škola na Danima otvorenih vrata Instituta za hrvatski jezik i jezikoslovlje. Učenicima nižih razreda osnovne škole uglavnom su predstavljene igre namijenjene učeničkomu modulu (npr. pravopisni kviz i daktilografska igra za učenje pravopisa), a za više razrede osnovne škole te srednjoškolce igre iz osnovnoga modula (pamtilica za anglizme, kviz koji ispituje semantičke odnose i frazeme). Također su neizvornim govornicima koji uče hrvatski na *Croaticumu* prikazane igre koje se razvijaju unutar modula za neizvorne govornike hrvatskoga jezika (Hudeček, Mihaljević i Pasini, 2018: 10). Uzele su se u obzir reakcije pojedinaca i skupina koje su igrale igru te se s igračima razgovaralo o njihovim dojmovima te o tome koje bi izmjene i dorade htjeli vidjeti u završnoj inačici igre.

Slika 81. Prikaz cijeloga četvrtog koraka testiranje igara

Da bi se proučio utjecaj igara kao obrazovnoga medija, provedeno je istraživanje opisano u poglavlju *Istraživanje na Croaticumu*. Rezultati istraživanja te mišljenje ispitanika može dati autoru igara povratne informacije o tome jesu li igre učinkovite. U rezultatima takvoga tipa

istraživanja mogu se otkriti nedostaci određenih obrazovnih igara (npr. ako student nakon što riješi igru za učenje glagola i dalje ne ostvaruje bolje rezultate nego prije igranja igre, onda nešto treba u igri ispraviti). Također je moguće na organiziranim radionicama testirati igre na ciljnoj skupini kojoj je igra namijenjena.

8.1.5. Objava igre

Korak povezan s objavom igre nije jednostavan jer se igra ne može odmah prebaciti na mrežu, nego je prije toga potrebno dodati određene metaoznake koje opisuju igru (npr. naslov, opis, autor, ključne riječi) te Open Graph⁴⁷⁵ metaoznake za društvene mreže koje za kopiranu poveznicu na društvenim mrežama stvaraju opis i sliku. Svaki put kad netko dijeli poveznicu na društvenoj mreži poput Facebooka, Twittera, Pinteresta, LinkedIn itd., automatski se stvara opis za sadržaj te slika sadržaja koja na pritisak otvara stranicu na koju poveznica vodi. Time se na društvenim mrežama može lakše reklamirati sadržaje mrežnih stranica koji mogu uključiti i igre.

Metaoznakama za igru važno je odrediti o kojemu je tipu igre riječ (kviz, igra upisivanja, pamtilica itd.), koju jezičnu razinu obrađuje (pravopisnu, morfološku, sintaktičku, leksičku itd.), tj. koji se sadržaji igrom uče te komu je igra namijenjena. Te metaoznake važne su kako bi se sadržaj lakše našao i kategorizirao na internetu. Mrežne tražilice poput Googleove koriste se vlastitim mrežnim paucima (engl. *web spider* ili *web crawler*) koji redovito pregledavaju i indeksiraju mrežne stranice. Ti programi dohvaćaju opise mrežnih stranica te ih na temelju toga opisa kategoriziraju i svrstavaju u bazu za mrežne tražilice. Time se korisniku može prikazati željeni sadržaj na temelju upita koji sadržavaju riječi koje se nalaze u opisu, ključnih riječi ili naslova indeksirane mrežne stranice (Linxuan i dr., 2020: 2). Mrežni pauci također mogu povezivati sadržaje različitih mrežnih stranica te ih time mogu lakše hijerarhijski poredati unutar jednoga mrežnog mjesta ili domene te sadržajno povezati s drugim srodnim mrežnim stranicama. Hijerarhijski poredak mrežnih stranica na mrežnome mjestu (engl. *website*) ovisi o tome kako su ugniježdene mrežne stranice (engl. *web page*) unutar njih. Primjerice, na stranici *Informatičke igre* postoje kategorije za objavljene igre (*brojevni sustavi*, *Booleova algebra*, *dijelovi računala*, *programiranje* itd.) te svaka igra ima svoju oznaku s obzirom na tip (*pamtilica*, *kviz* itd.). Na temelju tih kategorija i oznaka lakše se mogu napraviti veze među sadržajima stranice. Kategorije hijerarhijski određuju veze, a oznake omogućuju veze između

⁴⁷⁵ Open graph tehnologija je koju je prvi put predstavio Facebook 2010. Ta tehnologija upotrebljava se za integraciju opisa sadržaja, mrežne stranice i društvene mreže (Aspinwall, 2020).

sadržaja unutar tih kategorija neovisno o njihovoj hijerarhiji (npr. oznaka *kviz* može povezati kviz iz programiranja s kvizom iz povijesti računala unatoč tomu što pripadaju dvjema odvojenim kategorijama) (Yingling, 2017: 22). Mrežni pauci bilježe te odnose i mogu ih prikazati tijekom pretraživanja sadržaja (vidi sliku 82).

Slika 82. Prikaz kategorija i oznaka koje se pojavljuju na Googleovoj tražilici za stranicu Informatičke igre

Osim metaoznaka na stranici potrebno je povezati igre te ostale mrežne sadržaje s mrežnim servisima poput Google Search Console koji provjeravaju status indeksiranja stranice te prilagoditi vidljivost stranice. Google Search Console upotrebljava se kako bi se provjerilo ima li tehničkih poteškoća povezanih s mrežnom stranicom, poput toga da mrežni pauci ne mogu pročitati opis stranice, da se mrežna stranica sporo učitava ili ne prikazuje pravilno na mobilnim uređajima te da je sadržaj stranice hakiran ili napadnut zlonamjernim programom (engl. *malware*). Također se može s pomoću servisa Google Search Console vidjeti osnovna statistika koja se odnosi na broj posjeta stranice u određenome razdoblju pritiskom na njezinu poveznicu (Jones, 2019). Ipak, kako bi se bolje pratio posjet i korištenje sadržajem stranice, poželjno je koristiti se servisom Google Analytics. Google Analytics može dati detaljnije podatke o pregledu stranice tako da prikazuje najposjećenije sadržaje, sadržaje na koje se

korisnici najčešće vraćaju, kako korisnici navigiraju sadržajem stranice i koliko vremena provode na kojoj stranici.

Također, bilježe se mrežni preglednici kojima se korisnici koriste, koriste li se mobilnim uređajima ili računalima za pristup sadržaju te iz koje zemlje korisnici pristupaju sadržaju. Može se pratiti i dob korisnika (na temelju njihova Googleova računa) (Shivar, 2020). Kod praćenja korisnika detaljnije se može pratiti čestoća kretanja pokazivača miša te pritisaka na poveznice s pomoću servisa za stvaranje toplinskih mapa (engl. *heatmap*) poput hotjar⁴⁷⁶ ili besplatnoga programa smartlook⁴⁷⁷. Ti servisi povežu se na stranicu te stvaraju grafički prikaz u obliku temperature tako da su crveniji sadržaji oni koji imaju više pritisaka na stranici ili više kretnji pokazivača miša, ovisno o tome što se promatra unutar servisa, kao što je prikazano na slici 83 (Yap, 2017).

Slika 83. Prikaz izgleda analize toplinskih mapa za različite stranice (Yap, 2017)

Nakon što se doda opis za igre te poveže igre sa servisima za praćenje ponašanja korisnika i mogućih tehničkih poteškoća, igre su spremne za povezivanje s mrežnim rječnikom (vidi sliku 84).

⁴⁷⁶ URL: <https://www.hotjar.com> (27. 5. 2020.)

⁴⁷⁷ URL: <https://www.smartlook.com/> (27. 5. 2020.)

Slika 84. Prvi koraci koji se trebaju napraviti prije izdavanja igre

Pri integraciji igre na mrežne stranice rječnika treba razmisliti o položaju na kojemu će se sve igre nalaziti.

Za *Mrežnik* će se izraditi podstranica namijenjena igrama slično kao na stranicama rječnika *Merriam-Webster*⁴⁷⁸. Na toj podstranici sve izrađene igre podijelit će se na kategorije na temelju modula za koji su izrađene (osnovni, učenici nižih razreda osnovne škole i neizvorni govornici hrvatskoga jezika, v. tablicu 104 u prvome koraku okvira), nakon toga će se kategorije podijeliti u potkategorije s obzirom na jezične razine. Te potkategorije, koje su u osnovnome modulu određene s obzirom na jezične razine, prilagođene su za ostala dva modula. Primjerice potkategorije sintaktička razina, morfološka razina i tvorbeni razina koje se nalaze u osnovnome modulu u ostalim dvama modulima spojene su u jednu potkategoriju gramatika, pravopisna razina u drugim dvama modulima zove se pravopis, a leksička razina leksik (u modulu za neizvorne govornike) i riječi (u modulu za učenike nižih razreda osnovne škole). Svaka će igra imati i oznaku tipa (npr. *pamtilica*, *križaljka*) te sadržaje koji se njome uče (*abeceda*, *definicije*, *riječi*) kako bi se mogle povezati igre istoga sadržaja i istoga tipa (vidi sliku 85). Time će korisnici moći lako pregledavati i pronaći različite igre koje su objavljene na stranici rječnika. Kod drugih leksikografskih izdanja također se može na mrežnim stranicama napraviti podstranica te rasporediti poveznice za igre na temelju njihova sadržaja koji je određen u drugome koraku konceptualnoga okvira.

⁴⁷⁸ URL: <https://www.merriam-webster.com/word-games> (2. 2. 2020.)

Slika 85. Pregled kategorija i potkategorija za igre unutar svakoga modula na stranici Mrežnika

U obradi *Mrežnika* u određenim će natuknicama biti poveznice na igre (vidi sliku 13 na početku poglavlja *Projekt Hrvatski mrežni rječnik – Mrežnik*, u kojoj je prikaz cijele strukture *Mrežnika*). Ostali rječnici i enciklopedije u pojedinim leksikografskim člancima također mogu uvrstiti igre (vidi sliku 86).

Slika 86. *Mogući načini integracije igre u rječnik*

Time se izravno povezuje sadržaj rječnika i s igrama te korisnici rječnika mogu za određene natuknice pronaći igre koje im mogu pomoći u učenju sadržaja koji je povezan s nekom natuknicom. Igre koje se uvrštavaju u natuknice ne moraju nužno obraditi samo sadržaj te natuknice nego i sadržaj srodnih natuknica u kojima će se također nalaziti poveznica na tu igru. Primjerice, u modulu za učenike nižih razreda osnovne škole *Mrežnika* poveznica na igre za razvrstavanje voća i povrća nalazit će se uz natuknice *voće*, *povrće*, ali i *jabuka*, *kruška*, *kupus* itd. Neke natuknice imat će više poveznica (npr. uz natuknicu *glagoljica* bit će poveznica na pamtilicu, kviz i na slagalicu Bašćanske ploče).

Tablica s primjerima natuknica *Mrežnika* za svaki modul u kojima je trenutačno određeno da će se nalaziti poveznice na igru nalazi se u prilogu *Natuknice Mrežnika koje će sadržavati poveznice na igre*.

Slika 87. *Prikaz cijeloga petog koraka povezanoga s objavom igara*

8.1.6. Promocija igre

Nakon što se igra objavi, važno je da bude vidljiva ciljnim korisnicima te da korisnici nakon što odigraju igru budu zadovoljni i da je preporuče drugima. Promocija igre može se i izvršavati i prije četvrtoga (izrada i testiranje igre) i petoga koraka (objava igre), što se često i radi za komercijalne igre u zabavnoj industriji, u kojoj se često prije razvoja igre napravi videonajava (engl. *teaser*) te se redovito prije objave igre prikazuju videoisječci i slike iz igre (Majek, 2011: 1–2). U slučaju obrazovnih igara rađenih za rječnik većina se igara predstavi odmah nakon objave ili ih se najavi nekoliko dana prije objave. Promocija obrazovnih igara može se raditi s pomoću klasičnih medija kao što su novine i televizija. Ipak, zbog manjega korištenja tim medijima, posebno u mlađoj generaciji te cijene i troška koji dolazi s objavom sadržaja u novinama i na televiziji, preporučuje se promovirati igre na internetu na obavještajnim stranicama ili portalima te društvenim mrežama (vidi sliku 88).

Zbog toga je važno reklamirati se s pomoću društvenih mreža jer će se reakcija na igre proširiti među ostalim korisnicima na društvenim mrežama. Također, ako se objavljuje više različitih tipova igara na društveni mrežama, može se pratiti koje su igre popularnije na temelju pritisaka, pregleda i komentara. Reakcije na Facebookovim stranicama za neke objavljene igre na stranicama Instituta za hrvatski jezik i jezikoslovlje prikazane su u zaključku poglavlja *Tipovi obrazovnih igara* te u tablici 100.

Tablica 100. *Trenutačna statistika (svibanj 2020.) reakcija korisnika na objave povezane s igrama Instituta za hrvatski jezik i jezikoslovlje*

igre	broj korisnika koji su vidjeli objavu	broj pritisaka na objavu	broj oznaka <i>sviđa mi se</i> (engl. <i>like</i>)	broj dijeljenja	broj komentara
kviz abeceda znakovni jezik	3739	295	317	51	17
kviz abeceda brajica	7320	288	128	19	3
kviz iz mature za hrvatski jezik	30 963	4584	509	124	50
igre za učenje glagoljice	16 855	1180	640	106	24

Osim društvenih mreža poželjno je da se igre predstave na određenim obavještajnim stranicama ili portalima koje prate ciljni korisnici. Primjerice jedna igra za učenje glagoljice *Leteća glagoljica*⁴⁷⁹ spomenuta je na portalu *Slavorum*⁴⁸⁰, koji se bavi kulturom, poviješću i zanimljivostima koje se odnose na Slavene. O elektroničkoj igri za učenje glagoljice napisan je članak na tome portalu. Ta stranica ima 1 034 392 pratitelja na Facebooku, što je pomoglo da više ljudi primijeti igru. Neki obavještajni portali preuzimaju objave s društvenih mreža, što možemo vidjeti na stranici *Srednja.hr*⁴⁸¹ i *Teen385*⁴⁸², na kojima je kao glavni sadržaj objave stavljena Facebookova objava Instituta za hrvatski jezik i jezikoslovlje povezana s *Kvizom za državnu maturu iz hrvatskoga jezika*⁴⁸³. Taj kviz spomenut je i na *Portal za škole* jer je riječ o kvizu za srednjoškolce te je glavni cilj bio da vijest dođe to takvih portala. Na tim obavještajnim portalima često postoji veza s društvenim mrežama jer korisnici mogu dijeliti obavijesti portala na društvenim mrežama te ih komentirati preko profila društvenih mreža. Mogu se organizirati i predavanja i radionice za nastavnike i učenike te bilo koju drugu skupinu ciljnih korisnika (npr. u Mjesecu hrvatskoga jezika 2021. organiziran je Sat hrvatskoga jezika u Institutu za hrvatski jezik i jezikoslovlje u sklopu kojega je održano mnogo predavanja na Zoomu na kojima su predstavljene i jezične igre). Igre s portala *Hrvatski u školi* predstavljene su i na sajmu knjiga *Interliber*⁴⁸⁴.

Prema Jozić i dr. (2020: 22) posjeti stranici *Hrvatski u školi* u 2020. tijekom pandemije bolesti COVID-19 porasli su više od pet puta (8400 korisnika u ožujku u odnosu na 1500 korisnika u siječnju). Nagli porast posjeta može se povezati s potrebom za e-nastavom te s promocijom interaktivnih obrazovnih materijala u medijima, npr. tijekom televizijske emisije za učenike 4. razreda u *Školi na Trećem* 20. ožujka 2020. portal *Hrvatski u školi* spomenula je i učiteljica koja se njime služi u nastavi.

⁴⁷⁹ URL: <https://zci.stin.hr/games/leteca-glagoljica/> (28. 5. 2020.)

⁴⁸⁰ URL: <https://www.slavorum.org/croats-developed-a-new-game-meet-flappy-glagoljica/> (28. 5. 2020.)

⁴⁸¹ URL: <https://www.srednja.hr/matura/odlicna-vijest-maturante-webu-objavljen-interaktivni-kviz-vjezbanje-hrvatskog-jezika/> (28. 5. 2020.)

⁴⁸² URL: <http://www.teen385.com/funzone/zanimljivosti/stecka-ti-znanje-hrvatskog-jezika-ovo-je-odlicna-stvar-za-utvrditi-gradivo-za-drzavnu-maturu> (28. 5. 2020.)

⁴⁸³ URL: <http://matura.ihjj.hr/kviz/> (16. 3. 2020.)

⁴⁸⁴ URL: <http://ihjj.hr/clanak/predstavljanje-institutskih-izdanja-na-interliberu/528/> (25. 9. 2020.)

Slika 88. Prikaz cijeloga šestog koraka povezanoga s objavom igre

Igre za *Mrežnik* planiraju se promovirati s pomoću Facebookove stranice Instituta za hrvatski jezik i jezikoslovlje, koja u svibnju 2020. ima 6357 pratitelja. Planira se napraviti videodemonstracija igara na stranici *Mrežnika*, koja se može objaviti na *YouTubeu*. Na sličan način ostala leksikografska izdanja mogu planirati promociju svojih igrificiranih sadržaja. Promocija preko ostalih medija ne može se sustavno planirati. Neke su igre izrađene za *Mrežnik* već prikazane na televiziji, poput igara za učenje glagoljice u emisiji *Školski sat*⁴⁸⁵ te igara koje se nalaze na portalu *Hrvatski u školi* u emisiji *Škola na Trećem*⁴⁸⁶.

8.1.7. Praćenje zadovoljstva korisnika

Nakon objave i promocije igre jedino preostaje da se provjere reakcije na izdane igre. Reakcije se najjednostavnije može prikupiti s pomoću društvenih mreža jer korisnici mogu s pomoću oznaka odrediti emocije koje se odnose na sadržaj (npr. na Facebooku *svidi mi se*, *volim ovo*, *ljut sam* itd.).

Mogu se pratiti komentari korisnika, s njima se može komunicirati u komentarima, pratiti dijeljenje sadržaja i broj pritisaka na objavu, a korisnici se katkad jave autoru sa svojim prijedlozima i s pomoću e-poruke. Koje igre korisnici najviše igraju te koliko se zadržavaju na stranici, može se analizirati s pomoću spomenutoga servisa Google Analytics. Kako bi se dobile informacije koje se odnose na poboljšanje igre, poželjno je ostvariti izravnu komunikaciju s igračima kako bi mogli iznijeti svoje stavove o igri te mogućim poboljšanjima. Jedan je od načina da se to napravi da se na kraju svake igre igraču da upitnik u kojemu ga se može zamoliti da ocijeni određene sadržaje igre ili cijelu igru te da napiše svoje dojmove, primjedbe te savjete za poboljšanje igre. Moguće je ostvariti i izravnu komunikaciju s nastavnicima koji se koriste

⁴⁸⁵ URL: <https://skolski.hrt.hr/emisije/1070/jezicne-igrice> (2. 7. 2020.)

⁴⁸⁶ URL: <https://www.youtube.com/watch?v=5T4bgsBLZZQ&t=55m17s> (2. 7. 2020.)

igrom kao obrazovnim sadržajima te posjećuju Institut za hrvatski jezik i jezikoslovlje (npr. na Danima otvorenih vrata u Institutu za hrvatski jezik i jezikoslovlje). Ako se igra zbog zahtjeva korisnika mora doraditi (ispravak pogrešaka, dopuna sadržaja, dopuna funkcionalnosti), postupak se vraća na dio četvrtoga koraka (izrada igre). Nakon što se igra doradi, ponovno se objavljuje (korak pet) te se kreće s procesom promocije (korak šest), ali promocija uglavnom nije toliko važna kao prvi put kad se objavi igra. Ako je riječ o malim doradama igre (npr. ispravak zatipaka i sitnih pogrešaka), korak promocije najčešće se preskače, ali ako je dodan novi sadržaj ili funkcionalnosti u igri, onda je poželjno da se to objavi u kratkoj obavijesti na društvenim mrežama. Nakon toga vraća se na sedmi korak (vidi sliku 89). Taj se korak može stalno izvršavati te je igru uvijek moguće dopunjavati te prepravljati na temelju prijedloga korisnika. Moguće je, naravno, ako su komentari pozitivni i nema prijedloga za doradu, sedmi korak u potpunosti zanemariti te igra ostaje nepromijenjena.

Slika 89. Prikaz cijeloga sedmog koraka povezanoga s praćenjem zadovoljstva korisnika igrama

8.2. Cjeloviti pregled konceptualnoga okvira

Nakon prolaza svakoga koraka konceptualnoga okvira s primjerima uporabe dokazana je hipoteza iznesena na početku poglavlja:

- H₂: *Moguće je izraditi konceptualni okvir igrifikacije mrežnoga rječnika na temelju identifikacije igrifikacijskih elemenata obrazovnih sadržaja.*

Moguće je osmisлити igre različite po tipu i sadržaju koje odgovaraju različitim rječničkim sadržajima, što možemo vidjeti na primjeru igrifikacije triju modula *Mrežnika*. Ono što je važno kod procesa igrifikacije mrežnoga rječnika (a moglo bi se primijeniti i na igrifikaciju ostalih leksikografskih djela) jest postaviti ciljeve igara koji uključuju da se odredi koje se sadržaje rječnika želi s pomoću igara približiti ciljnoj skupini korisnika.

Nakon što se to odredi, treba odlučiti o tipu igre koji najviše odgovara za učenje sadržaja te koji odgovara ciljnim korisnicima. Za svaki tip igre treba pažljivo odrediti zadatke te primijeniti odgovarajuće igrifikacijske elemente. Za to je potrebno poznavanje tipova obrazovnih igara i mogućih igrifikacijskih elemenata koji se mogu uvrstiti u određeni tip igre. Zbog toga je autor proveo istraživanja o igrama i igrifikacijskim elementima na mrežnim stranicama rječnika i enciklopedija te arhiva, knjižnica i muzeja. Podatci prikupljeni tim istraživanjima mogu uštedjeti vrijeme onima koji rade na igrifikaciji drugih leksikografskih izdanja.

Nakon što se igre osmisle, potrebno je pronaći odgovarajuća tehnološka rješenja za njihovu izradu. U tome koraku često dolazi do testiranja različitih tehnoloških rješenja (npr. kodova ili programa) dok se ne izradi željena igra ili dio igre.

Nakon izrade autor treba sam testirati igru te je nakon toga testirati sa što većim brojem drugih korisnika kako bi se na temelju povratnih informacija napravile potrebne dorade prije objave igre. Važno je da korisnici koji testiraju igru po mogućnosti spadaju u ciljnu skupinu korisnika. Pri objavi važno je napraviti optimizaciju za mrežne tražilice, tj. dodati opis u igru te dodati druge odgovarajuće metaoznake na temelju kojih će korisnici moći pronaći igre kad pretražuju internet. Igre se mogu objaviti na mrežnim stranicama rječnika, najbolje na podstranici koja objedinjuje sve igre. Na toj podstranici dobro je napraviti podjelu igara po kategorijama i oznakama. Kategorije za podjelu igara mogu biti određene već u prvome koraku, u kojemu je napravljen izbor i podjela sadržaja leksikografskoga izdanja koje će se igrificirati za određene ciljne korisnike. Poveznice na igre također se mogu uvrstiti unutar strukture natuknica.

Igru je nakon objave, čak i u nekim slučajevima i malo prije objave, potrebno promovirati kako bi ciljni korisnici za nju doznali. Promocija se u današnje vrijeme može provoditi besplatno i jednostavno s pomoću društvenih mreža, ali i dalje je poželjno igre promovirati i na obavještajnim stranicama, radionicama i predavanjima te u medijima kao što su novine i televizijske emisije.

Nakon što se igre objave, potrebno je pratiti zadovoljstvo korisnika te prikupljati povratne informacije. Te povratne informacije mogu pomoći pri doradi postojećih igara (koje mogu vratiti korisnika na 5. korak) te izradi novih igara. Komunikacija s ciljnom publikom pomaže

čak i nakon objave igre jer stvara dobar odnos između tvorca igre i igrača o kojima ovisi hoće li igra biti uspješna i prihvaćena.

Projekt *Hrvatski mrežni rječnik – Mrežnik* unutar kojega se izrađivao konceptualni okvir igrifikacije mrežnoga rječnika završava 31. srpnja 2021. te će nakon toga igre za *Mrežnik* biti javno dostupne na mrežnim stranicama *Mrežnika* (na predviđenoj domeni rjecnik.hr/igre). Te igre mogu poslužiti kao primjer kako igrificirati druga leksikografska izdanja koristeći se ovim konceptualnim okvirom. Grafički prikaz cijeloga konceptualnoga okvira igrifikacije *Mrežnika* nalazi se u 14. prilogu *Konceptualni okvir igrifikacije mrežnoga rječnika*.

9. ZAKLJUČAK

U ovome radu istražuju se igre i igrifikacijski elementi koji se nalaze na stranicama rječnika i enciklopedija te se prikazuje proces izrade konceptualnoga okvira igrifikacije e-rječnika s obzirom na njegov sadržaj, vrstu i ciljne korisnike. Pri istraživanju igrifikacijskih elemenata postavilo se istraživačko pitanje:

- IP₁: *Koji su igrifikacijski elementi zastupljeni u hrvatskim i stranim leksikografskim e-izdanjima?*

Za odgovor na to pitanje u poglavlju *Zastupljenost igrifikacijskih elemenata u leksikografskim izdanjima* analizirani su 181 rječnik i rječničke baze, od kojih 26 sadržava igre i igrifikacijske elemente, i 76 enciklopedija, od kojih 10 sadržava igre i igrifikacijske elemente. Ti rezultati pokazuju da više od 86 % mrežnih leksikografskih stranica nema nikakve igre i igrifikacijske elemente. Na tim su stranicama identificirani ovi tipovi igara: kviz, igra povezivanja, slagalice i zagonetke, križaljke, igre popunjavanja, igre upisivanja izgovorenih riječi, izvanmrežni materijali za igru, jedinstvena igra, pamtilica, osmosmjerka, daktilografska igra te vješala. Najzastupljeniji je tip igre kviz s ponuđenim odgovorima (25) te igre povezivanja (10). Najmanje su zastupljene igre vješala (1) i daktilografske igre (1).

U tim su igrama identificirani ovi igrifikacijski elementi: bodovanje, razine/težine, vremensko ograničenje, ljestvice poretka, avatar, značke ili drugi sustavi nagrađivanja i priča sa zadacima. Najprisutniji su igrifikacijski elementi bodovanje (26) te podjela sadržaja na razine (15). Najrjeđi je igrifikacijski element priča sa zadacima, koja se jedino nalazi kod određenih igara u dvjema enciklopedijama (*Encyclopedia Smithsonian* i *Medline Medical Encyclopedia*).

Nakon provedenoga istraživanja zaključeno je da će se, kako bi se dobili iscrpniji rezultati, to istraživačko pitanje proširiti i ovim pitanjem:

- IP₂: *Koji su igrifikacijski elementi zastupljeni na stranicama knjižnica, arhiva i muzeja?*

Za odgovor na to pitanje u poglavlju *Igrifikacijski elementi na mrežnim stranicama informacijskih ustanova* analizirano je 179 mrežnih stranica muzeja, 254 mrežne stranice knjižnica te 21 mrežna stranica arhiva. 20 knjižnica, 11 muzeja i 2 arhiva sadržavaju obrazovne igre ili poveznice na igre i igrifikacijske elemente. Igre su koje su zastupljene na tim stranicama: kviz, slagalice i zagonetka, igre povezivanja, igre popunjavanja, jedinstvene igre, pamtilice i križaljke. Kvizovi su ponovno bili najzastupljeniji tip igre (27) te nakon toga slagalice i zagonetke (23). Prisutnije su jedinstvenije igre (5) nego kod leksikografskih izdanja. Najmanje ima križaljka (1).

Igrifikacijski su elementi koji su identificirani unutar tih igara i na stranicama arhiva, knjižnica i muzeja bodovanje, razine/težine, priča sa zadacima, vremensko ograničenje, avatar, značke ili drugi sustavi nagrađivanja. Najprisutniji su igrifikacijski elementi bodovanje (28) i razine (20). Za razliku od igara izrađenih za mrežne rječnike i enciklopedije na mrežnim stranicama knjižnica, muzeja i arhiva mnogo su prisutniji igrifikacijski elementi priča sa zadacima (19), avatar (14) i značke ili drugi sustavi nagrađivanja (13).

Za svaki identificirani tip igre unutar istraživačkih pitanja provedena je pedagoška kvalitativna analiza koja procjenjuje jednostavnost uporabe svakoga tipa igre te mogućnost primjene igre za poučavanje različitih obrazovnih sadržaja. Kvizovi, igre povezivanja te igre popunjavanja tipovi su igara koji su jednostavni za uporabu (nemaju složeni način i pravila igre) te se mogu stalno primjenjivati pri poučavanju različitih obrazovnih sadržaja jer se pitanja lako mogu ubaciti u te tipove igara. Također ti tipovi igara korisniku mogu nakon odgovora izravno dati povratnu informaciju (npr. točno, netočno, broj bodova) i objašnjenje (zašto je nešto točan odgovor). Nijedan tip igre nije procijenjen kao zahtjevan za igranje, ali se daktilografske igre rijetko mogu primijeniti za poučavanje različitih obrazovnih sadržaja jer se temelje na brzome tipkanju slova, što nije pogodno za postavljanje pitanja ili bilo koji drugi tip zadatka koji zahtijeva dulje razmišljanje da bi se došlo do odgovora. Također, za svaki identificirani tip igre provedena je kvalitativna analiza tehničkih aspekata na temelju autorova iskustva, pri čemu je proučeno koje je tipove igara moguće izraditi s pomoću grafičkih sučelja dostupnih besplatnih programa, je li moguće igre izrađene s pomoću tih programa dalje mijenjati te koji se tipovi igara mogu igrati na mobilnim uređajima. Osim slagalica i zagonetka te jedinstvenih tipova igara ostali tipovi igara poput kvizova, igara nadopunjavanja i pamtilica mogu se napraviti s pomoću grafičkih sučelja programa (npr. H5P-om). Unatoč tomu, igre izrađene s pomoću grafičkoga sučelja, osim u slučaju križaljke izrađene programom EclipseCrossword, ne mogu se nakon izrade dodatno izmijeniti. Sve tipove igara osim daktilografskih moguće je prilagoditi igranju na mobilnim uređajima.

Na temelju analize identificiranih igara i elemenata iz istraživačkoga pitanja mogle su se izraditi prve demoinačice igara za *Mrežnik*. Tehnologija i mrežni izvori kojima se koristilo za izradu igara spominju se u poglavlju *Tehnologija i proces izrade obrazovnih igara*. Te demoinačice zajedno s nekim igrima koje je autor prethodno izradio za stranice *Jezične igre i multimedijски prikaz znanja* i *Hrvatski u školi* predstavljene su učenicima na Danima otvorenih vrata Instituta za hrvatski jezik i jezikoslovlje te studentima s Croaticuma koji su posjetili Institut.

Kako bi se poboljšala izrada konceptualnoga okvir igrifikacije mrežnoga rječnika, testirala se učinkovitost izrađenih igara. Zato je provedeno istraživanje sa studentima koji uče hrvatski

jezik na Croaticumu te su se na temelju rezultata istraživanja modificirale neke izrađene igre. Istraživanjem se provjeravalo iduće hipoteze:

- *H_{a0}: Osobe koje uče hrvatski kao ini jezik, a koje će se služiti igrificiranim sadržajima, ne postižu statistički značajne razlike na rezultatima pretesta iz usvajanja vokabulara od osoba koje se neće služiti igrificiranim sadržajima.*
- *H_{a1}: Osobe koje uče hrvatski kao ini jezik, a koje će se služiti igrificiranim sadržajima, postižu statistički značajne razlike na rezultatima pretesta iz usvajanja vokabulara od osoba koje se neće služiti igrificiranim sadržajima.*
- *H_{b0}: Osobe koje uče hrvatski kao ini jezik, a koje se služe igrificiranim sadržajima, postižu statistički značajno lošije ili jednake rezultate na testu usvajanja vokabulara od osoba koje se ne služe igrificiranim sadržajima.*
- *H_{b1}: Osobe koje uče hrvatski kao ini jezik, a koje se služe igrificiranim sadržajima, postižu statistički značajno bolje rezultate na testu usvajanja vokabulara od osoba koje se ne služe igrificiranim sadržajima.*
- *H_{c0}: Osobe koje uče hrvatski kao ini jezik, a koje se služe igrificiranim sadržajima, postižu statistički značajno lošiji ili jednak napredak na testu usvajanja vokabulara od osoba koje se ne služe igrificiranim sadržajima.*
- *H_{c1}: Osobe koje uče hrvatski kao ini jezik, a koje se služe igrificiranim sadržajima, postižu statistički značajno bolji napredak na testu usvajanja vokabulara od osoba koje se ne služe igrificiranim sadržajima.*
- *H_{d0}: Osobe koje uče hrvatski kao ini jezik, nakon nastave u kojoj se služe igrificiranim sadržajima, postižu statistički značajno lošije ili jednake rezultate na testu usvajanja vokabulara.*
- *H_{d1}: Osobe koje uče hrvatski kao ini jezik, nakon nastave u kojoj se služe igrificiranim sadržajima, postižu statistički značajno bolje rezultate na testu usvajanja vokabulara.*
- *H_{e0}: Osobe koje uče hrvatski kao ini jezik te vole igrati elektroničke igre ne postižu statistički značajne razlike na rezultatima testova usvajanja vokabulara u odnosu na osobe koje ne vole igrati elektroničke igre ili su neutralne prema njima.*
- *H_{e1}: Osobe koje uče hrvatski kao ini jezik te vole igrati elektroničke igre postižu statistički značajne razlike na rezultatima testova usvajanja vokabulara u odnosu na osobe koje ne vole igrati elektroničke igre ili su neutralne prema njima.*
- *H_{f0}: Ne postoji značajan odnos između samoprocjene znanja hrvatskoga jezika i rezultata testova usvajanja vokabulara kod osoba koje uče hrvatski kao ini jezik.*

- H_{f1} : *Postoji značajan odnos između samoprocjene znanja hrvatskoga jezika i rezultata testova usvajanja vokabulara kod osoba koje uče hrvatski kao ini jezik.*

Istraživanje su sačinjavale dvije nezavisne skupine studenata koji uče hrvatski jezik na Croaticumu i čije je znanje na A2 razini. Kontrolna skupina sastojala se od 12 studenata, a eksperimentalna od 9 studenata. Iako je istraživanje prvotno planirano za nastavu uživo, zbog pandemije izazvane koronavirusom istraživanje je provedeno mrežno. Studenti obje skupine tijekom mrežne nastave pisali su na početku sata predtest rađen na temelju obrazovnih sadržaja nastavne jedinice *Transport i komunikacija*, koju su trebali taj sat obrađivati. Nakon predtesta eksperimentalna skupina učila je dio sadržaja s pomoću izrađenih igara, a kontrolna skupina učila je klasičnim metodama i oblicima rada. Na kraju toga sata pisali su posttest koji je istovjetan predtestu kako bi se vidio napredak studenata nakon što obrade obrazovne sadržaje. Nakon dvaju tjedana na početku sata studenti su pisali odgođeni posttest, ponovno istovjetan prvomu posttestu, da se vidi koliko je trajno stečeno znanje. Za provjeru hipoteza na temelju rezultata studenata koristilo se Mann-Whitneyjevin U-testom, osim kod H_d , gdje se koristilo Wilcoxonovim testom sume rangova i H_f , gdje se koristilo Spearmanovom korelacijom. Statistički testovi proveli su se računalno s pomoću programskoga jezika R. Za svaki statistički test dodatno je provjerena snaga statističkoga testa na temelju veličine uzorka i veličine učinka istraživanja kako se ne bi došlo do pogrešnoga zaključka (npr. prihvatila nulta hipoteza koja može biti netočna).

Rezultati dobiveni za svaki test kod svake hipoteze, osim hipoteze H_d , odbacuju alternativnu hipotezu i prihvaćaju nultu hipotezu. Unatoč tomu, kod H_a , posttesta za H_b , H_c , H_e te H_f računski je dokazana slaba snaga statističkoga testa te je zato i nultu hipotezu teško prihvatiti. Zaključeno je da bi se istraživanja mogla nastaviti te bi se testiranje tih hipoteza trebalo ponoviti na većemu uzorku koji bi dao statistički značajnije rezultate. Ipak, za H_d dokazana je alternativna hipoteza, a snaga je provedenoga statističkog testa velika (veća od 90 % za rezultate posttesta i odgođenoga posttesta) zbog velikog učinka istraživanja. Dokazano je da studenti eksperimentalne skupine nakon učenja s pomoću igrificiranih sadržaja u posttestu i odgođenome posttestu postižu značajno bolji rezultat u odnosu na predtest iako ne postižu značajno bolje rezultate od studenata kontrolne skupine. Za studente kontrolne skupine pri analizi rezultata odgođenoga posttesta za H_b dokazala se nulta hipoteza te provedeni statistički test ima visoku snagu (višu od 80 %), što upućuje na zaključak da s obzirom na postizanje dugoročnoga znanja studenti eksperimentalne skupine koji se služe igrama postižu lošije ili podjednake rezultate.

Kako su studenti procijenili svoje znanje prije pisanja testa, nije imalo značajnu vezu s ostvarenim rezultatima u svim trima testovima. Unatoč tomu što rezultati nisu statistički značajno bolji, kod studenata eksperimentalne skupine, ako gledamo aritmetičku sredinu za napredak bodova u posttestu i odgođenome posttestu u odnosu na pretest, ipak možemo vidjeti da je došlo do napretka (izraženoga u bodovima) koji je nešto veći od napretka kontrolne skupine. Na temelju rezultata testa te odgovora studenata na upitnik o zadovoljstvu igrama koji su dobili na kraju prvoga sata, možemo zaključiti da igre imaju potencijal da pomognu studentima u učenju hrvatskoga kao inoga jezika. Nakon istraživanja zaključeno je da će se igre koje se razvijaju za *Mrežnik* dodatno doraditi tako da se uzmu u obzir prijedlozi studenata eksperimentalne skupine i njihova nastavnika koji uključuju dopunu objašnjenja u rješenjima, dodavanje više poticajnih riječi u ta objašnjenja radi motiviranja igrača te uvrštavanje više sadržajnih i težinskih razina.

Kako bi se cjelovitije istražio utjecaj igrificiranih sadržaja u obrazovanju, bilo bi korisno ubuduće provesti niz istraživanja. Provedeno istraživanje može se ponoviti na većoj skupini studenata. Igre bi također trebalo testirati na drugim skupinama ciljnih korisnika, npr. pravopisne igre modula za učenike nižih razreda osnovne škole mogle bi se testirati na učenicima osnovne škole uz dopuštenje škole, roditelja i etičkoga povjerenstva. Takvo bi istraživanje moglo odgovoriti na pitanje pomažu li jezične igre učenicima u usvajanju pravopisa.

Nakon istraživanja sa studentima zadatak je bio dokazati iduću hipotezu o izradi konceptualnoga okvira igrifikacije mrežnoga rječnika.

- *H₂: Moguće je izraditi konceptualni okvir igrifikacije mrežnoga rječnika na temelju identifikacije igrifikacijskih elemenata obrazovnih sadržaja.*

Za dokazivanje te hipoteze uzeti su u obzir rezultati istraživačkih pitanja, analiza tipova igara, proces izrade igara te rezultati istraživanja povezanih s prvom hipotezom. Time je određeno sedam koraka koji čine konceptualni okvir:

1. određivanje obrazovnih sadržaja i ciljeva igara
2. osmišljavanje igara i određivanje koji će se igrifikacijski elementi uključiti
3. izrada igara
4. testiranje i dorada igara
5. objava igara
6. promocija igara
7. praćenje zadovoljstva korisnika.

Koraci toga konceptualnog okvira uglavnom slijede linearno tako da se nakon završetka jednoga koraka odmah ide na idući korak, ali u slučaju posljednjega koraka (pratiti zadovoljstvo korisnika igrom) moguće je vraćanje unazad na četvrti korak (testiranje i dorada igara) zbog potrebe dorade igre koja se pokazala temeljem mišljenja korisnika. Nakon toga, ponovno linearno slijede idući koraci te ponovno postoji mogućnost da se sa sedmoga koraka vrati na četvrti korak u kojemu se dorađuju dijelovi igre te ponovno testiraju. U poglavlju *Konceptualni okvir igrifikacije mrežnoga rječnika* analiziran je i objašnjen svaki osmišljeni korak konceptualnoga okvira na primjeru igrifikacije *Mrežnika*. Prikazane su različite igre izrađene za *Mrežnik* koje sadržavaju prethodno identificirane igrifikacijske elemente te je time dokazana hipoteza da se na temelju postojećih identificiranih igrifikacijskih elemenata može izraditi konceptualni okvir igrifikacije mrežnoga rječnika. Za uspješnu igrifikaciju mrežnih rječnika važan je prvi korak u kojemu se treba jasno odrediti cilj igara, za što je potrebno odabrati odgovarajući sadržaj rječnika (ono što se želi igrificirati) te ciljne korisnike kojima će igra biti namijenjena. Na temelju toga može se odrediti cilj igre (što se igrom želi korisnika poučiti). U drugome koraku treba odlučiti o tipu igre koji bi bio primjeren za ciljne korisnike i usvajanje odabranoga rječničkog sadržaja te osmisliti zadatke za igru i odlučiti o uporabi mogućih igrifikacijskih elemenata. Nakon toga, u idućemu koraku može se krenuti s tehničkim procesom izrade igre. Nakon izrade igre važno je testirati igru na ciljnim skupinama korisnika kojima je igra namijenjena kako bi se temeljem njihovih primjedaba napravile potrebne dorade te ispravile pogreške. Nakon što se igra izradi, počinje proces povezan s objavom igre u kojemu treba metaoznakama dati opis sadržaja igre kako bi se igra mogla lakše naći na internetu te objaviti igru pod odgovarajućom kategorijom na mrežnoj stranici rječnika. Posljednja dva koraka odnose se na promociju igre, koju je najlakše raditi na društvenim mrežama, te praćenje zadovoljstva korisnika igrama. Zadovoljstvo korisnika također se može pratiti na društvenim mrežama te je moguće s pomoću određenih programa (npr. Google Analytics) dobiti i pratiti statistiku koja se odnosi na broj posjeta pojedinoj igri te vrijeme provedeno na igri. S posljednjega koraka na temelju povratne informacije korisnika može se vratiti na četvrti korak u kojemu se ispravljaju pogreške ili testiraju novi sadržaji. U slučaju *Mrežnika* prva su četiri koraka već napravljena, a posljednja su tri samo djelomično provedena i bit će ih moguće u cijelosti provesti nakon završetka projekta nakon što se igre neko vrijeme nalaze na stranici *Mrežnika*.

Projekt *Hrvatski mrežni rječnik – Mrežnik*, u sklopu kojega su izrađene prikazane igre s igrifikacijskim elementima u ovome radu te čija je rječnička građa poslužila kao primjer uporabe konceptualnoga okvira igrifikacije mrežnoga rječnika, trebao bi završiti 31. srpnja

2021. te se očekuje da će tada igre unutar svih triju modula *Mrežnika* (osnovni, modul za učenike nižih razreda osnovne škole i modul za neizvorne govornike) biti dostupne (na poveznici rjecnik.hr/igre). Igre će se implementirati na stranicama *Mrežnika* na podstranici posvećenoj igrama, na kojoj će se igre pretraživati na temelju kategorija, potkategorija i sadržaja. Svaka će igra biti kategorizirana i s obzirom na korisnika kojemu je namijenjena (učenici nižih razreda osnovne škole, odrasli i neizvorni govornici) te će imati potkategorije s obzirom na jezične razine. Također će se igre označiti po tipu sadržaja koji se njima uči (npr. glagolski oblici, značenje riječi, frazemi). Igre će se implementirati i u pojedine natuknice rječnika, što nema nijedan od pregledanih mrežnih rječnika, pa je to jedna od inovacija predloženoga konceptualnog okvira. U planu je da se izrade i neke rječničke igre koje se temelje na *crowdsourcingu* slično kao igre za kolokacije i učenje frazema koje su predstavljene u potpoglavlju *Izrada igara koje se koriste crowdsourcingom*. Te igre koje primjenjuju *crowdsourcing* također će moći poslužiti kao primjer kako s pomoću rječničkih igara prikupiti određene informacije od korisnika (npr. u igri za kolokacije utvrditi koje kolokacije govornicima najčešće padaju na pamet te ih usporediti s rezultatima dobivenim iz Sketch Enginea).

Koraci i procesi određeni unutar ovoga konceptualnog okvira dodatno se mogu primijeniti na igrifikaciju sadržaja drugih e-leksikografskih izdanja te se metodologija igrifikacije jezičnih sadržaja u digitalnome okružju može primijeniti na druge obrazovne sadržaje. To se može vidjeti po postojećim igrama za muzeje, knjižnice i arhive, koje se spominju u potpoglavlju *Igrifikacijski elementi na mrežnim stranicama informacijskih ustanova*.

Mrežnik se nakon objave i završetka službenoga projekta planira proširiti novim sadržajima koji će uključiti i nove igre ili dorade starih igara. Te dorade mogu dovesti do toga da se izrađeni konceptualni okvir još doradi. Unatoč tomu što autor smatra da je izrađeni konceptualni okvir primjenjiv na ostala leksikografska djela, posebno ostale rječnike, okvir bi ipak trebalo isprobati pri igrifikaciji, npr. opće enciklopedije. U prvome će se koraku sadržaji enciklopedije drukčije dijeliti od rječnika, u kojemu se sadržaj može podijeliti na jezične razine. Enciklopedije također obuhvaćaju šira područja koja nisu povezana s jezikom, nazivima i definicijama. Time je moguće izraditi više tipova igara i primjenjivati više igrifikacijskih elemenata. Zbog toga bi se s malim izmjenama postojećega okvira mogao izraditi cjeloviti konceptualni okvir igrifikacije enciklopedija. Također se može razmisliti o mogućnosti izrade konceptualnoga okvira za igrifikaciju sadržaja arhiva, knjižnica i muzeja.

U ovome radu otvorena su mnoga pitanja koja zahtijevaju daljnju analizu:

1. primjena konceptualnoga okvira igrifikacije na enciklopedije (kasnije na sadržaje arhiva, knjižnica i muzeja)
2. daljnje istraživanje utjecaja igrifikacije na usvajanje obrazovnih sadržaja s većim brojem ispitanika ili s drugim ciljnim skupinama
3. primjena *crowdsourcinga* u igrifikaciji
4. povremeno ponovno utvrđivanje tipova igara i igrifikacijskih elemenata jer se igre stalno razvijaju te je moguće da se u bliskoj budućnosti pojave novi tipovi igara i igrifikacijski elementi.

U zaključku ovoga rada treba istaknuti da se igrama u obrazovanju može koristiti da bi se privuklo, uključilo i motiviralo studente ili učenike za obavljanje zadataka. Usto, vrlo je važno prilagoditi obrazovne igre s obzirom na sadržaj, mehanike igre te ciljnu publiku. Obrazovna igra ne smije biti takva da sadržava obrazovne sadržaje koje igrači mogu lako ignorirati te se koncentrirati samo na igrivost. Zato igre u svoje mehanike moraju na pravi način uključiti obrazovne sadržaje kako bi korisnici naučili nešto tijekom igranja, ali igre također moraju biti dovoljno zabavne kako korisnik ne bi odustao od njihova igranja. Treba također biti oprezan pri uključivanju igara u obrazovne svrhe jer pretjerana uporaba igara može trivijalizirati i smanjiti učinak primjene igre (Griffin i Butler, 2005: 34). Uspješna je ona obrazovna igra u kojoj igrač, što je više igra, stječe više znanja i usvaja činjenice koje se nalaze u samoj igri. Zato je igrifikacija obrazovnih sadržaja za različite skupine korisnika bila veliki izazov pri izgradnji konceptualnoga okvira i igrifikaciji *Mrežnika*.

10. POJMOVNIK

Pojmovnik se sastoji od odabranih naziva koji se nalaze u ovome radu te se često spominju u znanstvenim i stručnim radovima te mrežnim člancima povezanim s igrifikacijom, e-učenjem, informacijskim znanostima i e-leksikografijom. Definicije su preuzete iz literature kojom se autor služio u pisanju ovoga rada, a mnoge je definicije autor sam oblikovao. Neki nazivi preuzeti su iz *Pojmovnika*,⁴⁸⁷ koji se nalazi na stranicama projekta *Mrežnik* te je u planu da se i taj pojmovnik i baza *Jene* nadopune nekim nazivima iz ovoga rada.

- **AAI@EduHr** – autentikacijska i autorizacijska infrastruktura sustava znanosti i visokoga obrazovanja u Republici Hrvatskoj (AAI@EduHr, 2016)
- **alternativna hipoteza** (engl. *alternative hypothesis*) – hipoteza je koja pretpostavlja da postoji razlika između određenih značajka koja se mjere u odabranoj populaciji. Njoj je suprotna nulta hipoteza (Hayes, 2020)
- **ASCII (American Standard Code for Information Interchange)** – način kodiranja koji prikazuje tekst u računalima, komunikacijskoj opremi i drugim napravama. ASCII se za kodiranje znakova koristi sa samo 7 bitova te može prikazati najviše 128 znakova koji se nalaze u engleskoj abecedi (Panian, 2005a: 38).
- **audioknjiga** (engl. *audio book*) – digitalna zvučna snimka osobe koja čita knjigu (Dictionary.com, 2019)
- **avatar igrača** (engl. *player avatar*) – virtualna reprezentacija igrača s pomoću koje se bilježe bodovi i napredak u igri (Figuerola, 2015: 39)
- **bodovi** (engl. *scores*) – brojčana vrijednost koja se dodjeljuje igraču za izvršavanje određenih aktivnosti (Figuerola, 2015: 39)
- **bot** – automatizirani ili poluautomatizirani program koji izvršava određene radnje za korisnike i druge programe (Collins English Dictionary, 2011)
- **brbljaonica** (engl. *chat*) – virtualni prostor na mreži u kojemu korisnici mogu razgovarati s pomoću vlastitih računalnih uređaja koristeći se tekстом (Panian, 2005a: 86)
- **CALL (Computer-assisted language learning)** – proces učenja jezika potpomognut uporabom računalne tehnologije (Kiš i dr., 1993: 92)
- **čestotni rječnik** (engl. *frequency dictionary*) – rječnik u kojemu su riječi poredane po čestoći pojavljivanja u nekome jeziku (JENA, 2020)

⁴⁸⁷ URL: <http://ihjj.hr/mreznik/page/pojmovnik/6/> (10. 1. 2019.)

- **Croaticum** – Centar za hrvatski kao drugi i strani jezik ustanova je u kojoj se poučava te znanstveno i stručno proučava i opisuje hrvatski kao ini jezik. Dio je Odsjeka za kroatistiku Filozofskoga fakulteta Sveučilišta u Zagrebu. Croaticumovi obrazovni programi prilagođeni su brojem sati i sadržajem potrebama različitih polaznika, a nastava se održava po razinama prema *Zajedničkome europskom referentnom okviru za jezike* (A2.2, B1.1, B1.2, B2.1, B2.2, C1) (Croaticum, 2020).
- **crowdsourcing** – postupak dobivanja potrebnih usluga, ideja ili podataka od neodređene skupine ljudi (Bolje je hrvatski!, 2019)
- **deskriptivni rječnik (engl. *descriptive dictionary*)** – rječnik koji opisuje riječi bez obzira na njihov normativni status u standardnome jeziku (JENA, 2020)
- **digitalni repozitorij (engl. *digital repository*)** – mjesto na kojemu se prikupljaju i čuvaju digitalni podatci (Mihaljević i dr., 2015: 98)
- **digitalni vodeni žig (engl. *digital watermark*)** – prozirna oznaka koja se stavlja na određeni digitalni dokument ili program kako bi se zaštitilo autorsko pravo (webopedia, 2001)
- **dijagram rasipanja (engl. *scatter plot*)** – dijagram koji u obliku raspršenih točaka prikazuje vezu između dviju varijabla. Pri određivanju varijabla za izradu ovoga dijagrama moramo voditi računa o tome koja je varijabla nezavisna (x), a koja zavisna (y). U koordinatni sustav ucrtavaju se parovi točaka koji prikazuju veze između vrijednosti varijabla (x i y), a ucrtane točke još se nazivaju *oblak točaka* (Krpan, 2013).
- **dizajn igre (engl. *game design*)** – zadani ciljevi u igri te pravila, mogućnosti i izazovi unutar igre (Ashaari i dr., 2016: 871)
- **drugi jezik (engl. *second language*)** – bilo je koji jezik kojim pojedinac ovladava nakon što je usvojio barem osnove materinskoga jezika, a označava se kraticom L2, odnosno hrvatskom inačicom J2 (Jelaska, 2005: 28)
- **društveni elementi (engl. *social elements*)** – mogući odnosi koje igrači mogu imati u igri (igranje u paru ili skupini, razmjena virtualnih dobara) (Figuerola, 2015: 39)
- **DTD (Document Type Definition)** – opis za određivanje XML sheme (Joffe i Schryver, 2018: 55)
- **dvosmjerni rječnik (engl. *bidirectional dictionary*)** – rječnik namijenjen govornicima jezika A koji uče jezik B i govornicima jezika B koji uče jezik A (Bago i Majetić, 2017: 197)

- **dvosmjerni test (engl. *two-tailed test*)** – test koji se primjenjuje kad se želi provjeriti postoji li razlika u rezultatima obaju uzoraka nakon provođenja tretmana unutar eksperimenta neovisno o smjeru učinka ($H_1: S_1 \neq S_2$) (Privitera, 2017: 12)
- **e-knjiga (engl. *e-book*)** – knjiga izdana u digitalnome obliku koja se čita s pomoću određenoga računalnog uređaja (računala, mobilnoga uređaja, tableta) koji sadržava odgovarajući program za pokretanje i prikaz njezina sadržaja (Techopedia, 2019a)
- **ekstremna ili stršuća vrijednost (engl. *outliers*)** – podatak čija vrijednosti previše odstupa od vrijednosti ostalih podataka koji se proučavaju u istraživanju. Zbog toga se ekstremne vrijednosti često ne uvrštavaju u statističke analize kako ne bi iskrivile stvarne rezultate (Frost, 2019a)
- **ELEXIS** – projekt koji okuplja više europskih ustanova, izdavača i sveučilišta. Cilj je projekta unapređenje računalnih rječnika i rječničkih resursa. U sklopu projekta i u suradnji s mnogim ustanovama razvijaju se i objavljuju leksikografski računalni alati (ELEXIS, 2018)
- **emulacija (engl. *emulation*)** – proces kojim program unutar određenoga računala simulira strojne i programske specifikacije drugoga računalnog uređaja (Panian, 2005a: 193)
- **e-učenje (engl. *e-learning*)** – učenje podržano uporabom informacijsko-komunikacijske tehnologije (SRCE, 2016)
- **generacija X (engl. *generation X*)** – generacija rođenih od 1965. do 1980. Prethode im *baby boomeri*, a nasljeđuju ih milenijalci. Generacija X rođena je i odrasla u razdoblju u kojemu je *hip-hop* i *grunge* postao popularan tip glazbe te je većina njih odrasla uz MTV program, koji je puštao glazbene spotove, što im je dalo i dodatni naziv *MTV generacija* (Dimock, 2019).
- **generacija Z (engl. *generation Z*)** – generacija rođenih od 1997. do 2012. Prethode im milenijalci, a nasljeđuje ih generacija alfa. Generacija Z rođena je i odrasla u razdoblju interneta te većina njihova znanja dolazi s interneta (Dimock, 2019).
- **GWAP (Game with a Purpose)** – igra koja se temelji na *crowdsourcingu* kako bi se iz zabavnih procesa s pomoću igre prikupljali podatci (Krstev i Savay, 2018: 1)
- **Hrvatska jezična riznica** – korpus Instituta za hrvatski jezik i jezikoslovlje koji se sastoji od temeljnih djela hrvatske književnosti (romani, pripovijetke, drame, poezija i dr.), publicističkih djela, znanstvenih djela različitih struka i sveučilišnih udžbenika, osnovnoškolskih i srednjoškolskih udžbenika, prijevodne literature vrsnih hrvatskih prevoditelja, mrežno dostupnoga dnevnog, tjednog i mjesečnog tiska te knjiga iz

predstandardnoga razdoblja hrvatskoga jezika koje su prilagođene današnjemu hrvatskom jezičnom standardu (Institut za hrvatski jezik i jezikoslovlje, 2010)

- **Hrvatski jezični korpus (hrWaC)** – lematiziran i na morfosintaktičkoj razini označen mrežni korpus hrvatskoga jezika koji se sastoji od tekstova prikupljenih sa stranica koje su objavljene pod .hr domenom. Trenutačna inačica korpusa sadrži 1,9 pojava (Natural Language Processing group, 2013).
- **igra (engl. *game*)** – fizička ili mentalna aktivnost koja se smatra zabavnom i u kojoj sudjeluje jedna ili više osoba (Merriam-Webster, 2007)
- **igre igranja uloga (engl. *RPG, Role Playing Games*)** – igre u kojima igrač uglavnom oblikuje svoj lik ili njegovu avanturu u igri. Značajke su toga žanra sustavi napredovanja, razgranate priče i različiti pristupi izazovima (Techopedia, 2011).
- **igrifikacija (engl. *gamification*)** – proces u kojemu se različiti elementi igara ubacuju u svakodnevne procese kako bi se učinili zabavnijima i lakšima za izvođenje (Merriam-Webster, 2019; Cambridge English Dictionary, 2019)
- **igrifikacijski element (engl. *gamification element*)** – element preuzeti iz igre koji se dodaje u situacije koje inače nisu igrive (Ashaari i dr., 2016: 870)
- **igrivost (engl. *gameplay*)** – svojstva igre i način na koji se igra igra (Techopedia, 2016b)
- **indie-igre (engl. *indie games*)** – nezavisne igre koje najčešće stvara jedna osoba ili manji tim razvijatelja igara bez financijske potpore velikoga izdavača (Gnade, 2010)
- **infozabava (engl. *infotainment*)** – prikaz informacija na što zabavniji i atraktivniji način (Techopedia, 2011a)
- **interaktivna galerija (engl. *lightbox*)** – galerija koja omogućuje korisnicima da s pomoću mrežnoga preglednika iscrpno pregledaju i listaju slike okupljene na temelju određenoga kriterija (Nielsen, 2012)
- **izvorno mrežni rječnik (engl. *born-digital dictionary, web-born dictionary*)** – rječnik izvorno osmišljen kao mrežni sustav, što uključuje lakše međusobno povezivanje rječničkoga sadržaja i rječničkoga sadržaja s drugim mrežnim sadržajima, unošenje u rječnik sadržaja poput audiozapisa i videozapisa te mogućnost komunikacije s korisnicima koji mogu biti i aktivni sudionici u stvaranju rječničkoga sadržaja (Hudeček i dr., 2018)
- **jedinstvene igre (engl. *unique games*)** – igre koje sadržavaju vlastiti način i pravila igre, pa ih se ne može svrstati među ostale poznate tipove igara
- **jednosmjerni rječnici (engl. *monodirectional dictionary*)** – rječnici koji su namijenjeni izvornim govornicima jezika A koji uče jezik B (Bago i Majetić, 2017: 197)

- **jednosmjerni test (engl. *one-tailed test*)** – test unutar eksperimenta koji se primjenjuje kad je smjer učinka kod uzorka nakon provođenja tretmana određen u alternativnoj hipotezi (H_1). Jednosmjerni testovi dijele se na testove na donjoj granici ($H_1: S_1 < S_2$) i testove na gornjoj granici ($H_1: S_1 > S_2$) (Privitera, 2017: 16)
- **jezik za označavanje (engl. *markup language*)** – računalni jezik koji služi za oblikovanje tekstnih datoteka i njihovo povezivanje s drugim datotekama i medijima (Panian, 2005b: 13)
- **JSON (JavaScript Object Notation)** – tekstno otvoreni standard dizajniran za čitljivu razmjenu podataka koji se temelji na JavaScript sintaksi. Primjenjuje se u mrežnome razvoju jer omogućuje interoperabilnu, brzu i neometanu razmjenu informacija između različitih sustava i programa (Techopedia, 2011b).
- **kalodont (engl. *wordpaste*)** – igra u kojoj sudjeluje više igrača koja počinje tako da jedan igrač napiše prvu riječ, a sljedeći igrač sljedeću riječ započinje s posljednjim dvama slovima prethodne riječi. Cilj je igre da jedan igrač napiše takvu riječ da ostali igrači ne mogu smisliti novu riječ koja počinje posljednjim dvama slovima te riječi. Također, ako igrač napiše riječ koja završava s *ka*, ispada iz igre.
- **kodiranje (engl. *coding*)** – proces kojim se implicitna tekstna svojstva čine eksplicitnima, a podatak (tj. tekst) jasno se i nedvojbeno razlikuje od oznaka (engl. *tag*) (Panian, 2005a: 94)
- **konceptualni okvir (engl. *conceptual framework*)** – struktura je s pomoću koje istraživač želi objasniti određeni fenomen koji proučava (Camp, 2001)
- **korpus (engl. *corpus*)** – cjelovita zbirka podataka, dokumenata ili građe za određenu znanstvenu disciplinu ili struku; u suvremenome jezikoslovlju podrazumijeva računalni skup tekstova namijenjen pretraživanju (Birtić i dr., 2012: 260)
- **korpusno utemeljen rječnik (engl. *corpus based dictionary*)** – rječnik u kojemu se obrađivač služi korpusom, ali može slobodno procijeniti što treba unijeti u rječnik te rječnik može po potrebi dopunjavati i riječima iz drugih izvora te kolokacijama i značenjima koji nisu potvrđeni u korpusu (Hudeček i dr., 2018)
- **korpusom oprimjeren rječnik (engl. *corpus illustrated*)** – rječnik u kojemu se obrađivač isključivo služi korpusom za navođenje primjera (JENA, 2020)
- **korpusom vođen rječnik (engl. *corpus driven dictionary*)** – rječnik u kojemu se obrađivač služi isključivo korpusom, pa se u rječniku nalazi samo ono što se nalazi u korpusu (Hudeček i dr., 2018)

- **Kruskal-Wallisov test** (engl. *Kruskal-Wallis test*) – neparametrijska metoda za testiranje je li raspodjela rezultata nezavisnih testnih skupina različita. Smatra se proširenjem Mann-Whitneyjeva U-testa jer može usporediti više od dviju skupina te se primjenjuje kad postoje tri nezavisna uzorka ili više njih (Salkind, 20190: 673).
- **kvalitativna analiza** (engl. *qualitative analysis*) – analiza koja je usmjerena na način na koji pojedinci i skupine promatranjem određenoga entiteta ili pojave dolaze do novih spoznaja te oblikuju nova značenja izvan svojega iskustva. U statistici kvalitativna analiza sastoji se od postupaka koji se koriste jedino dihotomnim podacima (podacima koji mogu poprimiti vrijednost 0 i 1). Taj tip analize prikladan je za manja istraživanja u kojima se pojam ili entiteti mogu lakše izbrojiti ili razvrstati nego izmjeriti (Crossman, 2020).
- **kvantitativna analiza** (engl. *quantitative analysis*) – analiza je koja se provodi u društvenim znanostima te se oslanja na statistiku i teoriju vjerojatnosti. Rezultati analize koji se dobiju na uzorku upotrebljavaju se za objašnjavanje određene pojave (Lucas-Alfieri, 2015: 284–285).
- **Likertova ljestvica** (engl. *Likert scale*) – najčešće primjenjivana ljestvica za mjerenje stavova. Za razvoj i primjenu ljestvice zaslužan je Renis Likert. Sastoji se od tvrdnja koje prate najčešće pet mogućih odgovora kojima se izražava stupanja slaganja i neslaganja (potpuno slaganje, slaganje, neodlučnost/neutralnost, neslaganje, potpuno neslaganje) (Hrvatska enciklopedija, 2013).
- **ljestvica poretka** (engl. *leaderboards*) – prikaz poretka svih igrača u igri ili na određenoj razini na temelju njihova rezultata (Figueroa, 2015: 39)
- **Mann-Whitneyjev U-test** (engl. *Mann-Whitney U test*) – neparametrijski test koji se primjenjuje pri testiranju razlike očekivanja na temelju dvaju nezavisnih uzoraka koji nemaju normalno raspodijeljene rezultate. Testiranje se temelji na rangiranju podataka. Primjenjuje se kod neparametrijskih metoda kao zamjena za t-test (Glen, 2015a).
- **međujezik** (engl. *interlanguage*) – dinamički jezični sustav koji se razvija kod učenika inoga jezika, a u procesu učenja približava se ciljnomu jeziku zadržavajući pritom neka svojstva prvoga jezika ili uopćavajući pravila *inoga jezika* pri govoru ili pisanju ili stvarajući vlastite inovacije (Obad i Šarić, 2015: 135)
- **mehanika igre** (engl. *game mechanics*) – način interakcije koju korisnik može imati s objektima unutar igre (Ashaari i dr., 2016: 869)
- **milenijalci** (engl. *millennials*) – generacija rođenih od 1981. do 1996. Prethodi im generacija X, a nasljeđuje ih generacija Z. Milenijalci su generacija koja je odrasla u

vrijeme nagloga razvoja informacijsko-komunikacijske tehnologije te se većina njih bez problema zna koristiti tehnologijom, internetom i društvenim mrežama (Dimock, 2019).

- **napredak igrača (engl. *progress bars/progression*)** – prikaz napretka igrača kroz igru ili klasičnim učenjem (Figueroa, 2015: 39)
- **nasljedni jezik (engl. *heritage language*)** – jezik koji je tko usvojio u svojem domu ili jezičnoj zajednici kao materinski ili jedan od materinskih, ali mu je izloženost nadmoćnijemu jeziku okoline promijenila jezični razvoj, pa je nazadovao, okamenio svoje znanje ili nije usvojio sva jezična obilježja svojega jezika (Jelaska, 2016: 93)
- **natjecateljska igra (engl. *competitive game*)** – igra u kojoj se igrači natječu tko će ostvariti više bodova ili prije ostvariti određeni cilj (Jagušt, 2018: 45)
- **neparametrijski test (engl. *nonparametric test*)** – test koji se zasniva na razlici ranga te za razliku od parametrijskih testova ne ovisi o tipu raspodjele podataka. Uzorak na osnovi kojega se provodi ovaj tip testa može se temeljiti na različitim oblicima osnovnih skupova ili dijelova ispitivane populacije o kojoj se vrlo malo zna (Kaur i Kumar, 2015: 337–338).
- **normalna raspodjela (engl. *normal or Gaussian distribution*)** – funkcija vjerojatnosti koja opisuje kako su vrijednosti varijable raspodijeljene. Riječ je o simetričnoj raspodjeli u kojoj se većina vrijednosti okuplja oko središnjega vrha, a za ostale vrijednosti koje se nalaze dalje od središnjega vrha pretpostavlja se da su jednake u obama smjerovima (Frost, 2018).
- **nulta hipoteza (engl. *null hypothesis*)** – hipoteza koja pretpostavlja da ne postoji razlika između određenih značajka koje se mjere u odabranoj populaciji. Suprotna je njoj alternativna hipoteza (Hayes, 2020).
- **odostražni rječnik (engl. *reverse dictionary*)** – rječnik u kojemu su natuknice poredane abecednim redom od svojega kraja (Hudeček i dr., 2018)
- **Open Database Connectivity (ODBC)** – interoperabilan protokol koji se upotrebljava za pristup i razmjenu podataka između različitih baza i aplikacija (Techopedia, 2011c)
- **optičko prepoznavanje znakova (engl. *OCR – Optical character recognition*)** – program koji može prepoznati slova iz slike na temelju podataka o izgledu znakova te njihovih međusobnih veza u tvorenju riječi (Techopedia, 2017)
- **ozbiljne igre (engl. *serious game*)** – igre kojima nije glavna svrha zabaviti igrače te kojim se koristi u područjima kao što su vojska, obrazovanje, znanost, zdravstvo, upravljanje resursima i ljudskim potencijalima, graditeljstvo, inženjerstvo i politika (Damien i dr., 2015: 1; Allbeck, 2010)

- **parametrijski test** (engl. *parametric tests*) – test koji se zasniva na teoriji vjerojatnosti i pretpostavci da su podaci normalno raspodijeljeni. Njime se ocjenjuju pojedini parametri (srednje vrijednosti, standardne devijacije ili varijance). Smatra se postojanijim i zahtijeva manje podataka da bi se došlo do jačega zaključka od neparametarskoga testa (Kaur i Kumar, 2015: 337).
- **parsiranje** (engl. *parsing*) – raščlanjivanje rečenice u računalnoj obradi jezika (Hudeček i dr., 2018)
- **platformska igra** (engl. *platformer*) – igra u kojoj lik kojim upravlja igrač većinu vremena skače s jedne platforme na drugu (Klappenbach, 2019)
- **pogreška tipa I.** (engl. *type I error*) – pogreška do koje može doći kod dokazivanja hipoteza statističkim testom u kojoj se odbacuje nulta hipoteza koja je zapravo istinita (Noymer, 2008: 17)
- **pogreška tipa II.** (engl. *type II error*) – pogreška do koje može doći kod dokazivanja hipoteza statističkim testom u kojoj se prihvaća nulta hipotezu koja je pogrešna (Prajapati, Dunne i Armstrong, 2010: 10)
- **poligon frekvencija** (engl. *frequency polygon*) – grafički prikaz razdiobe frekvencija numeričke statističke varijable u pravokutnome koordinatnom sustavu tako da je svaka točka kojoj je apscisa jedna vrijednost varijable, a ordinata frekvencija te vrijednosti u danome uzorku, povezana ravnom linijom s njoj susjednom takvom točkom (Struna, 2011)
- **predački jezik** (engl. *ancestral language*) – strani jezik s kojim je učenik toga jezika povezan podrijetlom, ali ga nije učio u obitelji (Jelaska, 2016: 93)
- **priča** (engl. *storyline*) – radnja igre koja se otkriva postupno tijekom igre (Figueroa, 2015: 39)
- **prilagodljiva igra** (engl. *adaptive game*) – igra koja prilagođuje svoj sadržaj ili težinu na temelju rezultata koje igrač ostvaruje u igri (Jagušt, 2018: 12)
- **programski jezik** (engl. *programming language*) – računalni jezik s pomoću kojega korisnik može zadavati naredbe računalu. Programi računala stvaraju se s pomoću programskih jezika kojima se nadzire ponašanje te ulaz, obrada i izlaz određenih tipova podataka iz računala (Techopedia, 2016).
- **prvi jezik** (engl. *first language*) – 1. prvi jezik koji je osoba usvojila (sinoniman naziv *materinski jezik* i *rodni jezik*), 2. hijerarhijski primarni jezik sporazumijevanja i jezik kojim tko najlakše vlada (sinoniman naziv *glavni jezik*) (Matijević, Gulešić Machata i Udier, 2020: 33)

- **p-vrijednost (engl. *p-value*)** – vrijednost vjerojatnosti. Vjerojatnost je događaja da će testna statistika poprimiti vrijednosti za koje je vjerodostojnost nulte hipoteze u odnosu na alternativnu hipotezu manja od opažene vrijednosti te statistike ili joj je jednaka, uz uvjet da je nulta hipoteza istinita. Ako je p-vrijednost manja ili jednaka unaprijed određenoj razini značajnosti α , onda se nulta hipoteza može odbaciti te se može reći da su rezultati statistički značajni za odabranu razinu značajnosti (Beers, 2020; Mendenhall i dr., 2009: 352).
- **R** – programski jezik i okruženje za statističke izračune i vizualizaciju. R se može slobodno upotrebljavati i distribuirati te je programsko rješenje otvorenoga koda (Radović, 2015: 3)
- **računalstvo u oblaku, oblačno računalstvo (engl. *cloud computing*)** – mogućnost iznajmljivanja jednoga poslužioca ili više njih te pokretanja različitih aplikacija na njima. **Napomena:** Obični će korisnici računalstvo u oblaku definirati kao nov i jeftiniji način uporabe programskih rješenja koja će se unajmljivati prema potrebi, a informatički će ga stručnjaci definirati kao nov poslovni model ili novu tehnološku platformu za smještaj, pokretanje i uporabu informatičke programske podrške (Bolje je hrvatski!, 2015).
- **rasterska grafika (engl. *raster graphics*)** – grafika koju sačinjavaju redci i stupci ispunjeni pikselima u određenim bojama (Panian, 2005b: 60)
- **razina značajnosti α (engl. *significance level α*)** – razina vjerojatnosti ispod koje se odbacuje nulta hipoteza. Razina značajnosti α odabire se prije provedbe testiranja te α može poprimiti vrijednosti ,01; ,05 i ,1 koje označuju da postoji do 1 %, 5 % i 10 % vjerojatnosti da se dogodi pogreška tipa I. (odbacivanje nulte hipoteze koja je zapravo istinita) (Noymer, 2008: 17).
- **razine (engl. *levels*)** – sadržajni ili težinski dijelovi igre (Figueroa, 2015: 39)
- **regularni izraz (engl. *regular expression*)** – zadani niz znakova čija se kombinacija može upotrijebiti u programu ili programskome jeziku za pronalaženje i označavanje određenih dijelova teksta (Techopedia, 2011)
- **responzivan dizajn (engl. *responsive design*)** – dizajn koji omogućuje prilagođavanje veličine i položaja sadržaja s obzirom na veličinu zaslona na kojemu korisnik pregledava sadržaj (Gasston, 2013: 41)
- **rječnik (engl. *dictionary*)** – knjiga ili drugi objavljeni izvor koji sadržava ustrojeni popis leksičkih jedinica s njihovim definicijama ili prijevodom na drugi jezik (Birtić i dr., 2012: 674)

- **Shapiro-Wilkov test (engl. *Shapiro-Wilk test*)** – jedan od najčešće upotrebljivanih i najpouzdanijih testova za potvrđivanje hipoteze o normalnoj razdiobi (Struna, 2011)
- **sintetizatori govora (engl. *speech synthesizer*)** – program koji omogućuje pretvaranje računalnoga teksta u govor (engl. *text-to-speech*) (Pobar i dr., 2008: 31)
- **sinteza govora (engl. *speech synthesis*)** – tehnologija koja omogućuje govornu komunikaciju čovjeka i računala (Pobar i dr., 2008: 31)
- **skriptni jezik (engl. *scripting language*)** – programski jezik koji se izravno izvršava unutar svojega radnog okružja, tj. ne zahtijeva kompilaciju za izvršavanje programa te se naredbe u kodu izvršavaju u stvarnome vremenu (Beal, 2008)
- **Spearmanova korelacija (engl. *Spearman's rank correlation*)** – korelacija ranga (oznaka r_s ili ρ) statistički neparametrijski postupak za izračunavanje povezanosti dviju varijabla na temelju njihova ranga. Izračunava se kad jedan skup podataka slijedi ordinalnu ljestvicu ili kad raspodjela podataka značajno odstupa od normalne raspodjele te postoje podatci koji značajno odstupaju od većine izmjerenih. Linearna povezanost podataka nije uvjet za Spearmanovu korelaciju, a može se računati i na manjim uzorcima ($n < 35$). Vrijednosti r_s nalaze se između -1 i 1, ako dobivena vrijednost ispadne 0, možemo zaključiti da nema povezanosti među varijablama (Udovičić i dr., 2007: 10–11).
- **stablo igračevih vještina (engl. *skill tree*)** – vizualna reprezentacija različitih vještina po kategorijama koje igrač ima ili će ih tek imati ako napreduje u igri (Figuerola, 2015: 39)
- **statistička snaga testa (engl. *power of a statistical test*)** – mjera vjerojatnosti da će istraživač u uzorku naći statističku značajnost, ako učinak postoji u cijeloj populaciji. Snaga testa ovisi o idućim čimbenicima: veličini uzorka (n), veličini učinka i razini značajnosti (α) (McHugh, 2008: 263).
- **statistički test (engl. *statistical test*)** – test koji određuje mehanizme za izradu kvantitativnih odluka o procesima. Cilj je testa odrediti postoji li dovoljno dokaza da se opovrgne ili dokaže postavljena pretpostavka ili hipoteza o određenome procesu ili pojavi. Ako se rezultatima ne opovrgne hipoteza, dokazuje se da je hipoteza istinita te možemo dalje u nju vjerovati. Do opovrgavanja hipoteze u nekim slučajevima dolazi zbog nedovoljno prikupljenih podataka. Statistički testovi dijele se na parametrijske i neparametrijske (Kaur i Kumar, 2015: 336).
- **suradnička igra (engl. *collaborative game*)** – igra u kojoj više igrača mora međusobno surađivati kako bi došli do određenoga cilja (Jagušt, 2018: 77)

- **sustav nagrađivanja (engl. *rewards/rewards system*)** – unaprijed zadani sustav po kojemu korisnik dobiva nagrade kad ostvari određeni broj bodova, prođe određene razine ili postigne određeni uspjeh u igri; primjenjuje se kako bi dodatno motivirao igrača (Figueroa, 2015: 39)
- **sustav za pisanje rječnika (engl. *dictionary writing system*)** – program čija je svrha sastavljanje rječnika (Abel, 2012: 1)
- **sustav za upravljanje inačicama programa (engl. *version control system*)** – sustav koji omogućuje redovito ažuriranje datoteke u direktorijima te pregled i po potrebi vraćanje prethodnih inačica koje su bile spremljene u određenome trenutku. Sustav također bilježi radove korisnika na određenim datotekama te omogućuje upravljanje i spajanje svih korisnikovih izmjena sadržaja. Korisnici za svaku predanu izmjenu mogu napisati dokumentaciju kako bi se lako mogle pratiti izmjene. Najpopularniji je sustav kojim se koristi *Git* (Margaret, 2016).
- **sustav za upravljanje mrežnim sadržajem (engl. *CMS – Content management system*)** – sučelje kojim se može koristiti za izradu, objavu i ažuriranje sadržaja mrežnih stranica. Ono je što često karakterizira ovaj sustav pokretanje na mrežnome pregledniku, pohrana podataka u bazi, usporedna mogućnost rada više korisnika na mrežnim resursima stranice te mogućnost nadopuna sustava različitim programskim dodatcima (Cvitković, 2017: 15).
- **sustav za upravljanje učenjem (engl. *LMS – Learning management system*)** – sustav koji omogućuje administraciju, dokumentaciju, praćenje, obavješćavanje te izradu i dijeljenje obrazovnih sadržaja, programa i lekcija za vježbanje i učenje (Ellis, 2009: 1)
- **tehnologija *Open Graph* (engl. *Open Graph technology*)** – tehnologija je koju je prvi put predstavio Facebook 2010. koja se primjenjuje za integraciju opisa sadržaja, mrežne stranice i društvene mreže (Aspinwall, 2020)
- **teorija igara (engl. *game theory*)** – teorija čiji je utemeljitelj John von Neumann i koja je usmjerena na situacije u igri u kojima strategije igrača utječu na strategije drugih igrača u igri (Hughes, 2011)
- **test analize varijance (engl. *ANOVA – Analysis of variance*)** – test koji omogućuje da se analiziraju razlike više skupina na temelju prosjeka njihova rezultata. Često se primjenjuje za tri skupine ili više njih. Postoje jednosmjerni i višesmjerni testovi analize varijance ponovljenih mjerenja. Jednosmjerni test analize varijance ponovljenih mjerenja test je dokazivanja hipoteza koji se koristi jednom nezavisnom varijablom te može imati dvije ili više skupina nad kojima se vrši testiranje i uspoređuju promjene

rezultata u određenim vremenskim razmacima. Test višesmjernje analize varijance ponovljenih mjerenja sličan je testu jednosmjernje analize, ali se u analizi proučava utjecaj dviju ili više nezavisnih varijabla umjesto jedne (MacKenzie, 2018).

- **tezaurus** (engl. *thesaurus*) – zbirka riječi prirodnoga jezika (općega i/ili stručnoga) s prikazom njihovih pojmovnih odnosa (Hudeček i dr., 2018)
- **tip igre** (engl. *game type*) – igre koje imaju sličan načini igranja i slične značajke
- **t-test** – najčešći parametrijski test koji se primjenjuje za testiranje razlike između aritmetičkih sredina dvaju velikih ili dvaju malih uzoraka. Temelji se na studentovoj t-raspodjeli. Izračunana vrijednost t-testa označuje se slovom *t* (Kenton, Will. 2020b).
- **učenje na daljinu** (engl. *distance education*) – oblik učenja koji ne zahtijeva od nastavnika i učenika da se nađu unutar određenoga fizičkog prostora kako bi održali nastavu jer se poučavanje odvija s pomoću tehnologije koja može uključivati radio, telefon, e-poštu te internet i druge informatičko-komunikacijske tehnologije (Merriam-Webster, 2020)
- **učenje utemeljeno na igri** (engl. *game-based learning*) – učenje koje podrazumijeva primjenu tehnologije i igara u svrhu stjecanja znanja i vještina, a najčešće je riječ o obrazovnim videoigrama (YIP, 2007)
- **upitni jezici** (engl. *query language*) – vrsta računalnih jezika kojima se koristi za dohvaćanje podataka iz baze podataka ili informacijskoga sustava (Panian, 2005b: 128)
- **U-vrijednost** (engl. *U statistic*) – rezultat koje se dobije Mann-Whitneyjevim U-testom. Određuje koliko je puta rezultat jedne skupine manji od rezultata druge skupine. Što je niža vrijednost U, to su veće razlike među skupinama (Glen, 2015a).
- **vektorska grafika** (engl. *vector graphics*) – računalna slika koju čine grafički objekti kao što su crte te drugi geometrijski likovi koji su nastali s pomoću matematičkih formula (Panian, 2005b: 68)
- **videoigra** (engl. *videogame*) – računalni program namijenjen zabavi (Kiš i dr., 1993: 454)
- **virtualna šetnja** (engl. *virtual tour*) – simulacija određenoga fizičkog prostora koja se prikazuje s pomoću više povezanih slika. Unutar tih slika mogu biti označeni određeni dijelovi koji, kad se pritisnu, vode do drugoga virtualnog prostora ili prikazuju informacije o pritisnutome predmetu. Virtualne šetnje također mogu uključiti druge medije kao što su video, zvuk itd. (Techopedia, 2015).
- **virtualni muzej ili izložba** (engl. *virtual museum*) – logički uređena medijska zbirka digitalnih predmeta koja zbog međusobnoga spajanja medija s pomoću različitih točaka

pristupa nadrađa tradicionalne načine komunikacije i interakcije s posjetiteljima (Schweibenz, 1998: 191)

- **virtualni stroj** (engl. *virtual machine*) – program ili sustav koji oponaša određene programske i strojne sastavnice drugoga računala. Često se upotrebljava za testiranje određenih programa jer funkcionira kao zasebno programski stvoreno računalo koje sve pokreće u vlastitoj virtualnoj okolini te zbog toga ne može napraviti štetu fizičkomu računalu koje pokreće sve aktivnosti s pomoću virtualnoga stroja (Techopedia, 2011).
- **vremenska lenta** (engl. *timeline*) – grafički prikaz kronološki poredanih povijesnih događaja (Collins English Dictionary, 2020)
- **vremensko ograničenje** (engl. *timelimit*) – vrijeme u kojemu igrač mora izvršiti određeni zadatak (Figueroa, 2015: 39)
- **vrijednost W** (engl. *W value*) – vrijednost koja se dobiva s pomoću Shapiro-Wilkova testa. Ako vrijednost ispadne blizu 1, smatra se da su rezultati blizu normalne raspodjele, a što su vrijednosti manje od 1, rezultat je udaljen od normalne raspodjele (Glen, 2014).
- **wiki** – tip mrežne stranice koji omogućuje posjetiteljima mrežne stranice da predlože, naprave, komentiraju, dopune ili isprave sadržaj stranice (Merriam-Webster, 2017)
- **wiki-sustav** (engl. *wiki software*) – suradnički program koji omogućuje korisnicima da stvaraju i uređuju *wikije* s pomoću mrežnih preglednika (Gurteen, 2012: 91)
- **Wilcoxonov test sume rangova** (engl. *Wilcoxon Signed Rank Test*) – neparametrijski statistički test za dokazivanje hipoteza koji se može upotrebljavati za usporedbu dvaju zavisnih uzoraka ili jednoga uzorka na kojemu se radi više mjerenja (proučava razlika između rezultata dobivenih prije i poslije tretmana) (McDonald, 2014: 186)
- **zadatci** (engl. *quests*) – radnje koje igrač mora ostvariti kako bi dobio bodove i napredovao u igri (Figueroa, 2015: 39)
- **značka** (engl. *badge*) – virtualna reprezentacija postignuća (Figueroa, 2015: 39)
- **z-vrijednost** (engl. *z-score*) – vrijednost pojedinoga rezultata u odnosu na prosjek skupnoga rezultata, i to tako da se njegova vrijednost izrazi u dijelovima standardne devijacije (McLeod, 2019)

11. LITERATURA

11.1. Publikacije

1. Abel, Andrea. 2012. Dictionary Writing Systems and Beyond. *Electronic Lexicography*. Ur. Granger, Sylviane; Paquot, Magali. Oxford University Press. Oxford. 1–46.
2. Aladrović Slovaček, Katarina; Ivanković, Melita; Srzentić, Dunja. 2013. Jezične igre u nastavnoj praksi. *Play and playing in early childhood*. OMEP Hrvatska. Zagreb. 14–23.
3. Ally, Mohamed; Samaka, Mohammed. 2013. Open Education Resources and Mobile Technology to Narrow the Learning Divide. *The International Review of Research in Open and Distributed Learning* 14/2. 14–27.
4. Althoff, Tim; White, Ryen W.; Horvitz, Eric. 2016. Influence of Pokémon GO on Physical Activity: Study and Implications. *Journal of Medical Internet Research* 18/12. 315–325.
5. Armando, Toda; Valle, Pedro Henrique; Isotani, Seiji. 2018. The Dark Side of Gamification: An Overview of Negative Effects of Gamification in Education. *Higher Education for All. From Challenges to Novel Technology-Enhanced Solutions*. Ur. Ioana Cristea, Alexandra; Ibert Bittencourt, Ig; Lima, Fernanda. Springer. Cham.
6. Ashaari, Noraidah Sahari; Layth Khaleel, Firas; Tengku Wook, Tengku Siti Meriam; Amirah, Ismail. 2016. Gamification Elements for Learning Applications. *International Journal on Advanced Science, Engineering and Information Technology* 6/6. 868–874.
7. Bago, Petra; Majetić, Klara. 2017. Proposing an Instrument for Evaluation of Online Dictionaries of Sign Languages. *INFuture2017: Integrating ICT in Society*. Ur. Atanassova, Iana; Zaghoulani, Wajdi; Kragić, Bruno; Aas, Kuldar; Stančić, Hrvoje; Seljan, Sanja. Department of Information and Communication Sciences, Faculty of Humanities and Social Sciences. Zagreb. 189–203.
8. Bago, Petra; Majetić, Klara. 2018. Model online rječnika hrvatskog znakovnog jezika. *Studia lexicographica: časopis za leksikografiju i enciklopedistiku* 11/21. 43–59.
9. Barić, Eugenija. 1987. Mocijski parnjaci i njihova upotreba. *Rasprave: Časopis Instituta za hrvatski jezik i jezikoslovlje* 13/1. 9–18.
10. Bergovec, Marina; Cvikić, Lidija. 2008. CEFRL between L2 Language Learning and Acquisition: an Example of Croatian. *The Common European Framework of Reference for Languages (CEFRL): Benefits and Limitations*. IATEFL. Canterbury, Kent. 21–26.
11. Bežen, Ante; Reberski, Siniša. 2014. *Početno pisanje na hrvatskome jeziku*. Institut za hrvatski jezik i jezikoslovlje. Zagreb.
12. Birkić, Tamara; Ćorić Samardžija, Ana; Golem, Kristina; Kučina Softić, Sandra;

- Martinović, Zvonko; Radobolja, Tona; Zemljak Pećina, Ana. 2019. *Sustav za e-učenje Merlin: priručnik za studente*. Sveučilišni računski centar. Zagreb.
13. Birtić, Matea; Blagus Bartolec, Goranka; Hudeček, Lana; Jojić, Ljiljana; Kovačević, Barbara; Lewis, Kristian; Matas Ivanković, Ivana; Mihaljević, Milica; Miloš, Irena; Ramadanović, Ermina; Vidović. Domagoj. 2012. *Školski rječnik hrvatskoga jezika*. Institut za hrvatski jezik i jezikoslovlje, Školska knjiga. Zagreb.
 14. Blagus Bartolec, Goranka; Matas Ivanković, Ivana. 2017. Kad nam korpus ispunjava želje. *Hrvatski jezik: znanstveno-popularni časopis za kulturu hrvatskoga jezika* 4/3. 25–28.
 15. Boer, Piet van den. 2013. *Introduction to Gamification*. SG4Adults. Hoboken.
 16. Botički, Ivica; Jaguš, Tomislav; So, Hyo-Jeong. 2018. Examining Competitive, Collaborative and Adaptive Gamification in Young Learners' Math Learning. *Computers and education* 125. 444–457.
 17. Brewster, Jean; Ellis, Gail; Girard, Denis. 2002. *The Primary English Teacher's Guide, New Edition*. Penguin. London.
 18. Cambridge, Vibert C. 2009. Evolution of Mass Communication: Mass Communication and Sustainable Futures. *Journalism and Mass Communication* 1/1. 137–157.
 19. Camp, William G. 2001. Formulating and Evaluating Theoretical Frameworks for Career and Technical Education Research. *Journal of Vocational Educational Research* 26/1. 27–39.
 20. Caponetto, Ilaria; Earp, Jeffrey; Ott, Michela. 2014. Gamification and education: A literature review. *European Conference on Games Based Learning*. Academic Conferences International Limited. Brighton.
 21. Čilaš Mikulić, Marica; Gulešić Machata, Milvia; Lucija Udier, Sanda. 2018. *Razgovarajte s nama!*. Croaticum: Centar za hrvatski kao drugi i strani jezik. Zagreb.
 22. Čilaš Šimpraga, Ankica; Ivšić Majić, Dubravka; Vidović, Domagoj. 2018. *Rječnik suvremenih hrvatskih osobnih imena*. Institut za hrvatski jezik i jezikoslovlje. Zagreb.
 23. Cirqueira, Douglas; Vinícius, Lucas; Pinheiro, Marcia; Santana, Ádamo; Lobato, Fábio. 2017. Opinion Label: A Gamified Crowdsourcing System for Sentiment Analysis Annotation. u *XVI Workshop de Ferramentas e Aplicações (WFA 2017)*. Sociedade Brasileira de Computação. Gramado.
 24. Coe, Robert. 2002. It's the Effect Size, Stupid – What effect size is and why it is important. u *Annual Conference of the British Educational Research Association*. University of Exeter. Exeter.
 25. Cohen, Jacob. 1988. *Statistical power analysis for the behavioral sciences*. Lawrence

- Earlbaum Associates. Hillsdale. New York.
26. Costa Paiva, José Carlos. 2018. *Assessment of Programming Challenges using Gamification*. Faculdade de Ciências da Universidade do Porto. Porto.
 27. Crossman, Edward K.; Crossman, Sharyn M. 1983. The Crossword Puzzle as a Teaching Tool. *Teaching of Psychology* 10/2. 98–99.
 28. Čubrić, Marina. 2021. Nastava na daljinu. *Hrvatski jezik: znanstveno-popularni časopis za kulturu hrvatskoga jezika* 8/1. 12–14.
 29. Cvikić, Lidija, Jelaska, Zrinka; Kanajet Šimić, Lada. 2010. Nasljedni govornici i njihova motivacija za učenjem hrvatskoga jezika. *Croatian Studies Review* 6/6. 113–127.
 30. Cvikić, Lidija. 2005. Hrvatski kao drugi i strani jezik: trenutačno stanje i potrebe. *Hrvatski kao drugi i strani jezik*. Hrvatska sveučilišna naklada. Zagreb. 311–329.
 31. Cvikić, Lidija. 2012. Nejezični čimbenici ovladavanja inim jezikom. *Inojezični učenik u okruženju hrvatskoga jezika*. Ur. Mićanović, Miroslav. Agencija za odgoj i obrazovanje. Zagreb. 35–42.
 32. Cvitković, Maja. 2017. *Osnove rada u WordPressu*. Sveučilišni računski centar. Zagreb.
 33. Deesri, Angkana. 2002. Games in the ESL and EFL Class. *The Internet TESL Journal* 8/9. 4–5.
 34. Delfin, Ma. Ana Marianne; Gaba-Overio, Anne Theresa. 2017. The Effect of Game-Based Learning on Science 10 Test Scores. *ACE/AURS2017: The Asian Conference on Education 2017*. The International Academic Forum. Tokyo.
 35. Deng, Qizhen; Trainin, Guy. 2015. Learning Vocabulary with Apps: From Theory to Practice. *The Nebraska Educator: A Student-Led Journal* 29. 49–69.
 36. Deterding, Sebastian. 2018. Gamification in Management : Between Choice Architecture and Humanistic Design. *Journal of Management Inquiry* 28/2. 131–136.
 37. Deterding, Sebastian; Dixon, Dan; Khaled, Rilla; Nacke, Lennart. 2011. From game design elements to gamefulness: defining gamification. *Proceedings of the 15th International Academic MindTrek Conference: Envisioning Future Media Environments*. ACM. Tampere. 9–15.
 38. Direito, Artur; Jiang, Yannan; Whittaker, Robyn; Maddison, Ralph. 2015. Apps for IMproving FITness and Increasing Physical Activity Among Young People: The AIMFIT Pragmatic Randomized Controlled Trial. *J Med Internet Res* 20 17/8. 1–13.
 39. Djaouti, Damien; Alvarez, Julian; Jessel, Jean-Pierre; Rampnoux, Olivier. 2011. Origins of Serious Games. *Serious Games and Edutainment Applications*. Springer. London.
 40. Domínguez, Adrián; Joseba, Saenz-de-Navarrete; de-Marcos, Luis; Fernández-Sanz, Luis;

- Pagés, Carmen; Martínez-Herráiz, José-Javier. 2013. Gamifying learning experiences: Practical implications and outcomes. *Computers & Education* 63. 386–392.
41. Dumitrache, Anca; Aroyo, Lora; Welty, Christopher; Levas, Anthony; Sips, Robert-Jan. 2013. ‚Dr. Detective‘: Combining gamification techniques and crowdsourcing to create a gold standard in medical text. *CrowdSem, ISWC2013*. Ur. Alani, Harith; Kagal, Lalana; Fokoue, Achille; Groth, Paul; Biemann, Chris; Xavier Parreira, Josiane; Aroyo, Lora; Noy, Natasha; Welty, Chris; Janowicz, Krzysztof. University of Queensland. Sydney.
 42. Đurđević, Ranka; Podboj, Martina. 2016. Izbjeglice kao posebna kategorija učenika inog jezika. *Strani jezici* 45/3–4. 245–261.
 43. Eric, Jensen. 2003. *Super-nastava: nastavne strategije za kvalitetnu školu i uspješno učenje*. Educa. Zagreb.
 44. Ernest, Adams. 2013. *Fundamentals of Game Design*. 3. izd. New Riders. San Francisco.
 45. Figueroa-Flores, Jorge F. 2015. Using Gamification to Enhance Second Language Learning. *Digital Education Review* 27/21. 32–54.
 46. Finka, Božidar; Šojat, Antun. 1968. Govor otoka Žirija. *Rasprave: Časopis Instituta za hrvatski jezik i jezikoslovlje* 1/1. 121–220.
 47. Fitz-Walter, Zachary; Tjondronegoro, Dian W.; Wyeth, Peta. 2011. Orientation passport: Using gamification to engage university students. *Proceedings of the 23rd Australian computer-human interaction conference*. ACM. Fremantle. 122–125.
 48. Fort, Karen; Guillaume, Bruno; Chastant, Hadrien. 2014. Creating Zombilingo, a Game With A Purpose for dependency syntax annotation. *Gamification for Information Retrieval*. Ur. Hopfgartner, Frank; Kazai, Gabriella; Kruschwitz, Udo; Meder, Michael. Association for Computing Machinery. New York. 2–6.
 49. Fort, Karén; Guillaume, Bruno; Lefebvre, Nicolas. 2017. Who wants to play Zombie? A survey of the players on ZOMBILINGO. *Games4NLP 2017 – Using Games and Gamification for Natural Language Processing*. Valencia.
 50. Franklin, Sue; Peat, Mary; Lewis, Alison. 2003. Non-Traditional Interventions to Stimulate Discussion: The Use of Games and Puzzles. *Journal of Biological Education* 37/2. 76–82.
 51. Frost, Joe L.; Wortham, Sue C.; Reifel, Stuart C. 2012. *Play and Child Development*. Pearson. Boston.
 52. Fuertes-Olivera, Pedro A.; Bergenholtz, Henning. 2011. *e-Lexicography*. continuum. Londonezikiel chooke.

53. Gasston, Peter. 2013. *Moderni Web: responzivni Web dizajn uz HTML5, CSS3 i JavaScript*. Dobar plan. Zagreb.
54. Granger, Sylviane; Paquot, Magali. 2012. *Electronic lexicography: From challenge to opportunity*. Oxford University Press. Oxford.
55. Grant, Cynthia; Osanloo, Azadeh. 2014. Understanding, Selecting, and Integrating a Theoretical Framework in Dissertation Research: Creating the Blueprint for 'House'. *Administrative Issues Journal: Connecting Education, Practice and Research* 4/2. 12–22.
56. Grčević, Mario. 2017. *Hrvatski odostražni rječnik*. Hrvatski studiji. Zagreb.
57. Griffin, Linda L.; Butler, Joy. 2005. *Teaching Games for Understanding: Theory, Research, and Practice*. Human Kinetics. Champaign.
58. Gurteen, David. 2012. *Leading Issues in Social Knowledge Management*. Sv. 1. Academic Publishing International. Rotherham.
59. Hamari, Juho; Huotari, Kai; Tolvanen, Juha. 2015. Gamification and economics. *Walz—The Gameful World*. MIT Press. Cambridge. 139–161.
60. Hansen, Dusty. 2016. *Game On! Video Game History From Pong and Pac-Man to Mario, Minecraft and More*. MacMillan Publishing Group, LLC. New York City.
61. Hoe-Lian Goh, Dion; Razikin, Khasfariyati. 2015. Is Gamification Effective in Motivating Exercise?. *International Conference on Human-Computer Interaction*. Ur. Kurosu, Michio. Springer, Cham. Los Angeles.
62. Hole, Graham. 2009. *Research Skills: Nonparametric tests with large sample sizes*. University of Sussex. Sussex.
63. Huang, Yueh-Min; Chao, Han-Chieh; Deng Deng, Der-Jiunn; J. Park., James. 2013. *Advanced Technologies, Embedded and Multimedia for Human-centric Computing*. Springer. New York.
64. Hudeček, Lana; Mihaljević, Milica. 2017a. *Hrvatska školska gramatika*. Institut za hrvatski jezik i jezikoslovlje. Zagreb.
65. Hudeček, Lana; Mihaljević, Milica. 2017b. Hrvatski mrežni rječnik – *Mrežnik*. Hrvatski jezik 4/4. 1–8.
66. Hudeček, Lana; Mihaljević, Milica. 2018. *Hrvatski mrežni rječnik (Mrežnik) – Upute za obrađivače (radna inačica)*. Institut za hrvatski jezik i jezikoslovlje. Zagreb.
67. Hudeček, Lana; Mihaljević, Milica. 2019a. Uloga e-učenja i e-rječnika u usvajanju hrvatskoga jezika. *Dijete i jezik danas – Razvoj pismenosti u materinskom i inom jeziku*. Ur. Majdenić, Valentina; Trtanj, Ivana; Živković Zebec, Vedrana. Fakultet za odgojne i

- obrazovne znanosti. Osijek. 85–111.
68. Hudeček, Lana; Mihaljević, Milica. 2019b. Croatian Web Dictionary – *Mrežnik* – Linking with Other Language Resources. *Proceedings of eLex 2019*. Ur. Kosem, Iztok; Zingano Kuhn, Tanara; Correia, Margarita; Pedro Ferreira, José; Jansen, Maarten; Pereira, Isabel; Kallas, Jelena; Jakubiček, Miloš; Krek, Simon; Tiberius, Carole. Lexical Computing CZ, s.r.o. Sintra. 72–98.
 69. Hudeček, Lana; Mihaljević, Milica. 2019c. Croatian Web Dictionary – *Mrežnik* vs. Croatian Linguistic Terminology – Jena. *INFuture 2019: Knowledge in the Digital Age*. Ur. Bago, Petra; Hebrang Grgić, Ivana; Ivanjko, Tomislav; Juričić, Vedran; Miklošević, Željka; Stublić, Helena. Department of Information and Communication Sciences, Faculty of Humanities and Social Sciences. Zagreb. 22–31.
 70. Hudeček, Lana; Mihaljević, Milica; Pasini, Dinka. 2018. Radionica na Croaticumu – provjera strukture modula za strance Hrvatskoga mrežnog rječnika – *Mrežnika*. *Hrvatski jezik* 5/2. 9–12.
 71. Hudeček, Lana; Mihaljević, Milica; Pilić, Josip. 2001. *Hrvatski jezik 4. Profil*. Zagreb.
 72. Jaguš, Tomislav. 2018. *Višeploatformski sustav za unaprjeđenje učenja u ranom osnovnoškolskom obrazovanju zasnovan na digitalnim interaktivnim sadržajima, načelima obrazovnih igara i prilagodljivosti sustava učeniku*. Doktorski rad. Fakultet elektrotehnike i računarstva. Zagreb. 131 str.
 73. Jantassova, Damira; Zhilkishenova, Safura; Klukina, Elena. 2009. Computer Dictionaries and Encyclopedias in Teaching English as a Second Language. *Journal of NELTA* 14/1–2. 55–62.
 74. Jelaska, Zrinka. 2005. *Hrvatski kao drugi i strani jezik*. Hrvatska sveučilišna naklada. Zagreb.
 75. Jelaska, Zrinka. 2007. Ovladavanje jezikom: izvornojezična i inojezična istraživanja. *Lahor: časopis za hrvatski kao materinski, drugi i strani jezik* 2/3. 86–99.
 76. Jelaska, Zrinka. 2016. Ini hrvatski jezik i identitet – od stranoga do nasljednoga govornika. *Zbornik radova 44. seminara Zagrebačke slavističke škole*. Ur. Pišković, Tatjana; Vuković, Tvrtko. Filozofski fakultet Sveučilišta u Zagrebu. Zagreb. 87–106.
 77. Joffe, David; de Schryver, Gilles-Maurice. 2018. *The TLex Suite (2012 – 2018)*. TshwaneDJe. Gordons Bay.
 78. Jozić, Željko; Hudeček, Lana; Mihaljević, Milica. 2020. Mrežni izvori u vrijeme korone. *Hrvatski jezik: znanstveno-popularni časopis za kulturu hrvatskoga jezika* 7/2. 20–24.
 79. Kaur, Amandeep; Kumar, Robin. 2015. Comparative Analysis of Parametric and Non-

- Parametric Tests. *Journal of Computer and Mathematical Sciences* 6/6. 336–342.
80. Kaur, S. P. 2013. Variables in research. *IJRRMS* 3/4. 36–38.
 81. Kiryakova, Gabriela; Angelova, Nadezhda; Yordanova, Lina. 2014. Gamification in Education. *9th International Balkan Education and Science Conference*. Ur. Bülbül, Tuncer; Çakici, Yılmaz. Trakya University. Edirne. 679–683.
 82. Kiš, Miroslav; Buljan, Joško; Vuković, Sanja; Onić, Azren. 1993. *englesko – hrvatski informatički rječnik s računalnim nazivljem*. Školska knjiga. Zagreb.
 83. Klasnić, Ksenija; Lasić-Lazić, Jadranka; Seljan, Sanja. 2014. Mjerenje kvalitete integriranog sustava za e-učenje na Filozofskom fakultetu u Zagrebu iz perspektive studenata. *Informacijska tehnologija u obrazovanju*. Ur. Lasić-Lazić, Jadranka. Zavod za informacijske studije. Zagreb.
 84. Kocijan, Kristina; Janjić, Marijana; Poljak, Dario;. 2019. eDictionary: the Good, the Bad and the Ugly. *Proceedings of eLex 2019*. Ur. Kosem, Iztok; Zingano Kuhn, Tanara; Correia, Margarita; Pedro Ferreira, José; Jansen, Maarten; Pereira, Isabel; Kallas, Jelena; Jakubiček, Miloš; Krek, Simon; Tiberius, Carole. Lexical Computing CZ, s.r.o. Sintra. 270–290.
 85. Kolić-Vehovec, Svjetlana. 2018. Razvoj fonološke svjesnosti i učenje čitanja: trogodišnje praćenje. *Hrvatska revija za rehabilitacijska istraživanja* 39/1. 17–32.
 86. Kraus, Cvijeta; Jermen, Nataša; Jecić, Zdenko. 2017. An insight into online encyclopaedias for children and young adults. *INFuture2017: Integrating ICT in Society*. Ur. Atanassova, Iana; Zaghoulani, Wajdi; Kragić, Bruno; Aas, Kuldar; Stančić, Hrvoje; Seljan, Sanja. Department of Information and Communication Sciences, Faculty of Humanities and Social Sciences. Zagreb. 167–180.
 87. Krstev, Cvetana; Agata Savary. 2017. Games on multiword expressions for community building. *Infotheca – Journal for Digital Humanities* 17/2. 7–25.
 88. Laganà, Marco. 2017. *Team-CARE, together we win*. Youcanprint. Bologna.
 89. Lauc, Tomislava; Bago, Petra; Kišiček, Sanja. 2011. Using quantitative methods for a student study activity analysis in a virtual learning environment concerning different students' backgrounds. *34th International Convention MIPRO: Computers in Education*. Ur. Čičin-Šain, Marina; Uroda, Ivan; Turčić-Prstačić, Ivana; Slugačević, Ivanka. MIPRO – Hrvatska udruga za informacijsku i komunikacijsku tehnologiju, elektroniku i mikroelektroniku. Rijeka. 259–262.
 90. Lauc, Tomislava; Sanja, Matić; Mikelić Preradović, Nives. 2006. Educational multimedia software for English language vocabulary. *Proceedings of the 1 International*

- Conference on Multidisciplinary Information Sciences and Technologies*. Ur. Guerrero-Bote, Vicente P. InSciT2006. Mérida. 117–121.
91. Laufer, Batia; Hill, Monica. 2000. What lexical information do L2 learners select in a CALL dictionary and how does it affect word retention? *Language Learning i Technology* 3/2. 58–76.
 92. Lazić, Daria; Mihaljević, Josip. 2020. Morfološke igre na primjeru igara za učenje glagolskih oblika. *Jezik, književnost i obrazovanje – suvremeni koncepti* 4. Međimurski filološki i pedagoški dani. Ur. Kolar-Billege, Martina; Višnjić-Jevtić, Adrijana; Filipan-Žignić, Blaženka; Lapat, Goran; Mikulan, Krunoslav. Učiteljski fakultet Sveučilišta u Zagrebu. Čakovec. 122–135.
 93. Lewis, Kristian; Mihaljević, Josip. 2018. Odostražni rječnik – što je, kako ga izraditi i čemu služi. *Hrvatski jezik: znanstveno-popularni časopis za kulturu hrvatskoga jezika* 5/2. 21–24.
 94. Librenjak, Sara; Kocijan, Kristina; Janjić, Marijana. 2016. Croatian students' attitudes towards technology usage in teaching Asian languages — A field research. *39th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*. MIPRO Croatian Society. Rijeka. 117–121.
 95. Librenjak, Sara; Kocijan, Kristina; Janjić, Marijana. 2016. Improving Students' Language Performance Through Consistent Use of E-Learning: An Empirical Study in Japanese, Korean, Hindi and Sanskrit. *Acta Linguistica Asiatica* 6/2. 79–94.
 96. Liehr, Patricia; Jane Smith, Mary. 1999. Middle Range Theory: Spinning Research and Practice to Create Knowledge for the New Millennium. *Advances in Nursing Science* 21/4. 81–91.
 97. Ljubešić, Nikola; Klubička, Filip. 2014. {bs,hr,sr}WaC – Web Corpora of Bosnian, Croatian and Serbian. *Proceedings of the 9th Web as Corpus Workshop*. Ur. Bildhauer, Felix; Schäfer, Roland. Association for Computational Linguistics. Gothenburg. 29–35.
 98. Lovrenčić, Sandra; Plantak Vukovac, Dijana; Slibar, Barbara; Nahod, Bruno; Androcec, Darko; Šestak, Martina; Stapić, Zlatko. 2018. Igrifikacija: prema sistematizaciji termina na hrvatskom jeziku. *Računalne igre 2018*. Ur. Konecki, Mario; Schatten, Markus; Konecki, Mladen. Fakultet organizacije i informatike. Varaždin. 1–12.
 99. Lucas-Alfieri, Debra. 2015. *Marketing the 21st Century Library*. Chandos Publishing. Oxford.
 100. Lugmayr, Artur; Sutinen, Erkki; Suhonen, Jarkko; Islas Sedano, Carolina; Hlavacs, Helmut; Suero Montero, Calkin. 2017. Serious storytelling – a first definition and

- review. *Multimedia Tools and Applications* 76/14. 15707–15733.
101. Luse, Andy; Mennecke, Brian; Townsend, Anthony. 2012. Selecting a Research Topic: A Framework for Doctoral Students. *International Journal of Doctoral Studies* 7. 143–152.
 102. Majek, Dee. 2011. *The Cinematisation of Computer and Console Games*. Stockholm universitet. Stockholm.
 103. Malović, Stjepan; Vilović, Gordana; Maletić, Franjo; Kurtić, Najil. 2014. *Masovno komuniciranje*. Golden marketing-tehnička knjiga, Sveučilište Sjever. Zagreb.
 104. Markopoulos, Angelos P.; Fragkou, Anastasios; Kasidiaris, Petros D.; Davim, J. Paulo. 2015. Gamification in engineering education and professional training. *International Journal of Mechanical Engineering Education* 43/2. 118–131.
 105. Marković, Mario; Mihaljević, Josip. 2018. Elektronički arhivski obrazovni sadržaji. 50. *savjetovanje hrvatskih arhivista: privatno arhivsko gradivo i koncept sveobuhvatnog arhiva*. Hrvatsko arhivističko društvo. Osijek. 181–201.
 106. Marković, Mario; Mihaljević, Josip; Mihaljević, Milica. 2020. Kako pronaći jezikoslovni naziv. *Hrvatski jezik* 7/1. 18–22.
 107. Matea, Leko; Kišiček, Sanja; Knežević, Josip; Marić, Petar Krešimir; Martinović, Ivana; Vusić, Elvis. 2013. Interactive Application for Learning the Latin Language. *INFuture 2013*. Ur. Gilliland, Anne; McKemmish, Sue; Stančić, Hrvoje; Seljan, Sanja; Lasić-Lazić, Jadranka. Department of Information Science, Faculty of Humanities and Social Sciences. Zagreb. 215–225.
 108. Matijević, Maja. 2018. O sretnome vikendu i novim pogledima – nastavnička iskustva s tečaja hrvatskoga jezika za azilante i tražitelje azila. *Hrvatski jezik: znanstveno-popularni časopis za kulturu hrvatskoga jezika* 5/4. 5–8.
 109. Matijević, Maja; Gulešić Machata, Milvia; Udier, Sanda Lucija. 2020. Nazivlje u području ovladavanja hrvatskim kao inim jezikom. *Hrvatsko jezikoslovno nazivlje*. Ur. Mihaljević, Milica; Hudeček, Lana; Jozić, Željko. Institut za hrvatski jezik i jezikoslovlje. Zagreb. 327–344.
 110. Matijević, Maja; Mihaljević, Josip. 2019. Arabic Speakers as Croatian Language Learners Electronic Educational Games as a Support for Learning. *INFuture 2019: Knowledge in the Digital Age*. Ur. Bago, Petra; Hebrang Grgić, Ivana; Ivanjko, Tomislav; Juričić, Vedran; Miklošević, Željka; Stublić, Helena. Department of Information and Communication Sciences, Faculty of Humanities and Social Sciences. Zagreb. 135–145.
 111. Matijević, Maja; Mihaljević, Josip. 2020. Mrežne igre prilagođene arapskim govornicima

- kao potpora učenju hrvatskoga. *HINIZ – Hrvatski inojezični*. Ur. Jelaska, Zrinka; Gligorić, Igor Marko. Hrvatsko filološko društvo – Institut für Slawistik. Zagreb – Klagenfurt. 153–174.
112. McCoy, Lise; H. Lewis, Joy; Dalton, David. 2016. Gamification and Multimedia for Medical Education: A Landscape Review. *The Journal of the American Osteopathic Association* 16/1. 22–34.
 113. McDonald, John H. 2014. Spearman rank correlation. *Handbook of Biological Statistics*. Sparky House Publishing. Baltimore.
 114. McEnery, Tony; Xiao, Richard; Tono, Yukio. 2006. *Corpus-based Language Studies: An Advanced Resource Book*. Routledge. New York.
 115. McHugh, Mary L. 2008. Analiza statističke snage testa u znanstvenom istraživanju. *Biochemia Medica* 18/3. 263–274
 116. Medved Krajnović, Marta. 2010. *Od jednojezičnosti do višejezičnosti – Uvod u istraživanja procesa ovladavanja inim jezikom*. Leykam International. Zagreb.
 117. Meishar-Tal, Hagit. 2015. Teachers' use of Wikipedia with their Students. *Australian Journal of Teacher Education* 40/12. 126–40.
 118. Meletiou-Mavrotheris, Mario; Mavrou, Katerina; Paparistodemou, Efi. 2015. *Integrating Touch-Enabled and Mobile Devices into Contemporary Mathematics*. IGI Global. Pennsylvania.
 119. Mendenhall, William; Beaver, Robert J.; M. Beaver, Barbara. 2009. *Introduction to Probability and Statistics*. Brooks/Cole/Cengage Learning. Belmont.
 120. Mihaljević, Josip. 2016a. Elektroničke mrežne igre za učenje glagoljice. *Baščina* 17. 35.
 121. Mihaljević, Josip. 2016b. E-učenje i hrvatski jezik. *Hrvatski jezik: znanstveno-popularni časopis za kulturu hrvatskoga jezika* 3/3. 24–27.
 122. Mihaljević, Josip. 2017a. Creation and Use of Game-Based Learning Material. *INFuture2017: Integrating ICT in Society*. Ur. Atanassova, Iana; Zaghoulani, Wajdi; Kragić, Bruno; Aas, Kuldar; Stančić, Hrvoje; Seljan, Sanja. Department of Information and Communication Sciences, Faculty of Humanities and Social Sciences. Zagreb. 317–330.
 123. Mihaljević, Josip. 2017b. Izrada multimedijiskoga mrežnog sadržaja za promoviranje arhivske djelatnosti. *Arhivska praksa* 20. 335–46.
 124. Mihaljević, Josip. 2017c. Nove mrežne igre za učenje glagoljice. *Baščina* 18. 40–41.
 125. Mihaljević, Josip. 2018. Korištenje programima otvorenoga koda u nastavi informatike. *Mipro 2018 – 41. međunarodni skup za informacijsku i komunikacijsku tehnologiju*,

- elektrotehniku i mikroelektrotehniku* 41. 965–969.
126. Mihaljević, Josip. 2019. Izrada mrežnog arhivističkog rječnika. *51. savjetovanje hrvatskih arhivista: Upravljanje elektroničkim gradivom i suvremena arhivska praksa*. Ur. Zaradić, Radoslav. Hrvatsko arhivističko društvo. Slavonski Brod. 189–206.
 127. Mihaljević, Josip. 2020a. Igrifikacija hrvatskoga mrežnog rječnika – MREŽNIKA. *Rasprave: Časopis Instituta za hrvatski jezik i jezikoslovlje* 46/2. 1–27.
 128. Mihaljević, Josip. 2021. Elektroničke obrazovne igre očima učenika i nastavnika. *Hrvatski jezik: znanstveno-popularni časopis za kulturu hrvatskoga jezika* 8/1. 17–21.
 129. Mihaljević, Josip; Mihaljević, Ana. 2019. Mrežne igre u poučavanju i učenju hrvatskoga jezika. *Dijete i jezik danas – Razvoj pismenosti u materinskom i inom jeziku*. Fakultet za odgojne i obrazovne znanosti. Osijek. 113–137.
 130. Mihaljević, Marta; Mihaljević, Milica; Stančić, Hrvoje. 2015. *Arhivistički rječnik: englesko-hrvatski / hrvatsko-engleski*. Zavod za informacijske studije. Zagreb.
 131. Mihaljević, Milica. 2017. Hrvatski u školi. *Hrvatski jezik* 4/2. 24–27.
 132. Mihaljević, Milica. 2018. Hrvatski mrežni izvor za djecu i strance. *Series Philology* 69. 75–89.
 133. Mozejko, Janina. 2012. Detecting and Estimating Trends of Water Quality Parameters. *Water Quality: Monitoring and Assessment*. Ur. Voudouris, Konstantinos; Voutsas, Dimitra. IntechOpen. London. 95–120.
 134. Munday, Pilar. 2016. The case for using DUOLINGO as part of the language classroom experience. *RIED* 19/1. 1138–2783.
 135. Novak Milić, Jasna. 2002. Učenje glagolskih oblika u hrvatskome kao drugome jeziku. *Suvremena lingvistika* 53–54. 85–101.
 136. Noymer, Andrew. 2011. Alpha, Significance Level of Test. *Encyclopedia of Survey Research Methods*. Ur. Lavrakas, Paul J. Sage Publications, Inc. Thousand Oaks. 17–19.
 137. *Odluka o mjerama ograničavanja društvenih okupljanja, rada u trgovini, uslužnih djelatnosti i održavanja sportskih i kulturnih događanja*. 2020. Stožer civilne zaštite Republike Hrvatske. Zagreb.
 138. Ortiz, Margarita; Chiluiza, Katherine; Valcke, Martin. 2016. Gamification in Higher Education and STEM: A Systematic Review of Literature. *8th Annual International Conference on Education and New Learning Technologies – Edulearn16*. Ur. Chova, L. Gómez; Martínez, A. López; Torres, Candel. The International Academy of Technology, Education and Development. Barcelona. 6548–6558.

139. Panian, Željko. 2005a. *Informatički enciklopedijski rječnik: @-L*. Jutarnji list. Zagreb.
140. Panian, Željko. 2005b. *Informatički enciklopedijski rječnik: M-Z*. Jutarnji list. Zagreb.
141. Peshkin, Alan. 1993. The Goodness of Qualitative Research. *Educational Researcher* 22/2. 23–29.
142. Petrak, Olivera. 2010. *Osnove zdravstvene statistike: Korelacija*. Zdravstveno veleučilište Zagreb. Zagreb.
143. Plantak Vukovac, Dijana; Škara, Maja; Hajdin, Goran. 2018. Korištenje i stavovi nastavnika o igrifikaciji u osnovnim i srednjim školama. *Zbornik Veleučilišta u Rijeci*. Ur. Čučković, Ribarić; Gligora Marković, Maja. Veleučilište u Rijeci. Rijeka.
144. Pobar, Miran; Martinčić-Ipšić, Sanda; Ipšić, Ivo. 2008. Računalni sustav za tvorbu hrvatskoga govora. *Engineering Review* 28/2. 31–44.
145. Posavec, Lamza. 2011. *Kvantitativne metode istraživanja: anketa i analiza sadržaja*. Hrvatski studiji Sveučilišta u Zagrebu. Zagreb.
146. *Poučavanje djece kojoj hrvatski nije prvi jezik*. 2018. Pučko otvoreno učilište, Korak po korak. Zagreb.
147. Prajapati, Bhavna; Dunne, Mark; Armstrong, Richard. 2010. Sample size estimation and statistical power analyses. *Optometry Today* 16/7. 10–18.
148. Prensky, Marc. 2001. Fun, Play and Games: What Makes Games Engaging. *Digital Game-Based Learning*. McGraw-Hill. New York. 106–144.
149. Pritchard, Boris. 2019. *Maritime Dictionary: English – Croatian (Englesko-hrvatski pomorski rječnik)*. Sveučilište u Rijeci, Pomorski fakultet. Rijeka.
150. Privitera, Gregory J. 2017. *Statistics for the Behavioral Sciences*. SAGE Publications, Inc. New York.
151. Qian, Meihua; Clark, Karen R. 2016. Game-based Learning and 21st century skills: A review of recent research. *Computers in Human Behavior* 63. 50–58.
152. Radović, Andreja. 2015. *Upoznavanje sa sintaksom jezika R i njegova primjena u osnovnoj statističkoj i grafičkoj analizi podataka*. Sveučilišni računski centar (SRCE). Zagreb.
153. Rangaswami, JP. 2015. When Peers Select Tasks and Teams. *The Gameful World: Approaches, Issues, Applications*. MIT Press. 459–461.
154. Roa-Valverde, Antonio J. 2014. Combining Gamification, Crowdsourcing and Semantics for Leveraging Linguistic Open Data. *ISWC 2014*. Ur. Mika, Peter; Tudorache, Tania; Bernstein, Abraham; Welty, Chris; Knoblock, Craig; Vrandečić, Denny; Groth, Paul; Noy, Natasha; Janowicz, Krzysztof; Goble, Carole. Springer. Trentino. 27–39.

155. Ruth, Lochar; Alexandra, Meinhold; Hildegard, Toma. 2011. *Museums of the World*. 18. izd. De Gruyter Saur. München.
156. Ryann K., Ellis. 2009. *Field Guide to Learning Management*. ASTD Learning Circuits. Alexandria.
157. Salkind, Neil J. 2010. *Encyclopedia of Research Design*. SAGE Publications, Inc. Thousand Oaks.
158. Šarić, Antonija; Obad, Lidija. 2015. Međujezik. *Život i škola: časopis za teoriju i praksu odgoja i obrazovanja* 61/2. 135–141.
159. Sawilowsky, Shlomo S. 2009. New effect size rules of thumb. *Journal of Modern Applied Statistical Methods* 8/2. 467–474.
160. Schweibenz, Werner. 1998. The ‚Virtual Museum‘: New Perspectives For Museums to Present Objects and Information Using the Internet as a Knowledge Base and Communication System. *Internationalen Symposiums für Informationswissenschaft*. Ur. Gäde, Maria; Trkulja, Violeta; Petras, Vivien. UVK Verlagsgesellschaft mbH. Prag. 185–199.
161. Shipherd, Amber M.; Burt, Daniel J. 2018. Game on! gamifying the sport psychology college classroom. *Journal of Sport Psychology in Action* 9/3. 147–158.
162. Singer, Dorothy G.; Singer, Jerome L. 2007. *Imagination and play in the electronic age*. Harvard University Press. Cambridge – London.
163. Sitzmann, Traci. 2011. A Meta-analytic Examination of the Instructional Effectiveness of Computer-Based Simulation Games. *Personnel Psychology* 64/2. 489–528.
164. Špiranec, Ivana; Pavković, Krunoslav. 2014. *Džepni rječnik za građevinare englesko-hrvatski / hrvatsko-engleski*. Tehničko veleučilište u Zagrebu. Zagreb.
165. Stålnacke Larsson, Richard. 2013. *Motivations in Sports and Fitness Gamification: A study to understand what motivates the users of sports and fitness gamification services*. Umea university. Umeå.
166. *Statistički pokazatelji osoba kojima je odobrena međunarodna zaštita u Republici Hrvatskoj*. 2019. Ministarstvo unutarnjih poslova Republike Hrvatske. Zagreb.
167. Stockwell, Glenn. 2007. A review of technology choice for teaching language skills and areas in the CALL literature. *ReCALL* 19/2. 105–120.
168. Štrkalj Despot, Kristina; Möhrs, Christine. 2015. Pogled u e-leksikografiju. *Rasprave* 41/2. 329–353.
169. Tabak, Mihaela; Ordulj, Antonia. 2015. Strategije učenja vokabulara u hrvatskome kao inome jeziku. *Jezikoslovlje* 16/1. 103–121.

170. Tadić, Marko. 2000. Hrvatski nacionalni korpus na internetu. *Jezik* 46/5. 200.
171. Udovičić, Martina; Baždarić, Ksenija; Bilić-Zulle, Lidija; Petrovečki, Mladen. 2007. Što treba znati kada izračunavamo koeficijent korelacije?. *Biochemia Medica* 17/1. 10–15.
172. Venhuizen, Noortje J.; Basile, Valerio; Evang, Kilian; Bos, Johan. 2013. Gamification for Word Sense Labeling. *Proceedings of the 10th International Conference on Computational Semantics*. Ur. Koller, Alexander; Erk, Katrin. Association for Computational Linguistics. Potsdam.
173. Vučković, Kristina; Družijanić Hajdarević, Ela; Ujdur, Ante. 2009. *Putovanje kroz znanje*. Zavod za informacijske studije. Zagreb.
174. Vučković, Kristina; Ujdur, Ante; Stojanov, Tomislav; Dovedan, Zdravko. 2005. Interaktivni dječji slikovni rječnik. *Computers in Education – 28th International Convention MIPRO 2005*. Ur. Biljanović, Petar; Skala, Karolj. MIPRO Croatian Society. Opatija. 55–59.
175. Yingling, Jason. 2017. *Getting to Know WordPress*. Amazon.com. St. Louis.
176. Yu, Linxuan; Li, Yeli; Zeng, Qingtao; Sun, Yanxiong; Bian, Yuning; He, Wei. 2020. Summary of web crawler technology research. *Journal of Physics: Conference Series* 1449. 1–7.
177. Zainuddin, Zamzami; Zhang, Yin; Li, Xiuhan; Haruna, Hussein. 2019. Gamification in a non-tech information environment, is it possible? *ASIS&T Asia-Pacific Regional Conference*. University of Cambodi. Cambodia.
178. *Zakon o međunarodnoj i privremenoj zaštiti*. 2015. Ministarstvo unutarnjih poslova Republike Hrvatske. Zagreb.
179. Zarevski, Predrag. 1995. *Provjerite pamćenje*. Naklada Slap. Zagreb.
180. Zhou, Yalun. 2016. Digital Vocabulary Competition as Motivator for Learning in CFL Classrooms. *Journal of Technology and Chinese Language Teaching* 7/2. 1–22.
181. Zrinka, Jelaska, Hržica, Gordana. 2005. In Search for a Missing Part: Identificational and Generational Motivation in Learning the L2. *15th EUROSLA*. Ur. Medved Krajnović, Marta; Mihaljević Djigunović, Jelena. Filozofski fakultet, Zagreb. Dubrovnik. 101–102.

11.2. Mrežni izvori

1. 1.7 million+ Stunning Free Images to Use Anywhere. 2015. *Pixabay*. Pristupljeno 9. travnja 2020. (<https://pixabay.com/>).
2. A Fresh Way to Do Statistics. 2014. *JASP*. Pristupljeno 3. svibnja 2020. (<https://jasp-stats.org/>).

3. About GitLab. 2018. *GitLab*. Pristupljeno 13. travnja 2020. (<https://about.gitlab.com/company/>).
4. About the project. 2018.*H5P*. Pristupljeno 6. travnja 2020. (<https://h5p.org/about-the-project>).
5. Academic Search Engine. 2013. *RefSeek*. Pristupljeno 29. rujna 2019. (<https://www.refseek.com/>).
6. adidas miCoach. 2018. *Adidas*. Pristupljeno 23. studenoga 2019. (<https://www.adidas.co.in/micoach>).
7. Adobe PhoneGap Build. 2010. *Adobe*. Pristupljeno 7. travnja 2020. (<https://build.phonegap.com/>).
8. Advanced Renamer: Batch file renaming utility for Windows. 2010. *Advanced Renamer*. Pristupljeno 16. siječnja 2020. (<https://www.advancedrenamer.com/>).
9. Albaugh, Jake. 2016. Kill Dev Words: The Game. *CodePen*. Pristupljeno 7. travnja 2020. (<https://codepen.io/jakealbaugh/full/GopoLa>).
10. Allbeck, Jan. 2010. Serious Games. *Games and Intelligent Animation*. Pristupljeno 23. studenoga 2019. (<https://cs.gmu.edu/~gaia/SeriousGames/index.html>).
11. American Government Quiz. 2010. *KidsConnect*. Pristupljeno 21. prosinca 2019. (http://kids.ocls.info/games/activities_display.asp?id=10).
12. Analytics. 2006. *Google*. Pristupljeno 11. travnja 2020. (<https://analytics.google.com/analytics/web/#/report-home/a82903134w124743851p129061764>).
13. Apache Cordova. 2015. *Apache Cordova*. Pristupljeno 18. lipnja 2019. (<https://cordova.apache.org/>).
14. Aquation: The Freshwater Access Game. 2018. *Smithsonian Science Education Center*. Pristupljeno 15. veljače 2020. (<https://ssec.si.edu/aquation>).
15. Aspinwall, Kate. 2020. Open Graph tags are your secret to good CTR on social. *Ryte Magazine*. Pristupljeno 26. svibnja 2020. (<https://en.ryte.com/magazine/open-graph>).
16. ATi Studios. 2016. Learn Croatian. Speak Croatian. *Google Play*. Pristupljeno 9. svibnja 2020. (https://play.google.com/store/apps/details?id=com.atistudios.mondly.hr&hl=en_US).
17. Atom. 2018. *Atom*. Pristupljeno 9. travnja 2020. (<https://atom.io/>).
18. Attia, Shady. 2018. Study Conceptual Framework. *YouTube*. Pristupljeno 1. ožujka 2020. (<https://www.youtube.com/watch?v=UufeuPxqBHQ>).
19. Audacity ® | Free, open source, cross-platform audio software for multi-track recording and

- editing. 2015. *Audacity*. Pristupljeno 29. travnja 2020. (<https://www.audacityteam.org/>).
20. Autentikacijska i autorizacijska infrastruktura sustava znanosti i visokog obrazovanja u Republici Hrvatskoj. 2016. *AAI@EduHr*. Pristupljeno 27. studenoga 2019. (<https://www.aaiedu.hr/>).
21. Baamboozle. 2017. *Baamboozle*. Pristupljeno 31. ožujka 2020. (<https://www.baamboozle.com/>).
22. Baker, Emelyn; Schlensker, Christian; Choxi, Roshan. 2013. Ruby-warrior. *Block*. Pristupljeno 23. rujna 2019. (<https://www.bloc.io/ruby-warrior#/>).
23. Barker, Sam. 2018. lettris. *GitHub*. Pristupljeno 21. svibnja 2020. (<https://github.com/bamsarker/lettris>).
24. Baza hrvatskih glagolskih valencija. 2016. *Institut za hrvatski jezik i jezikoslovlje*. Pristupljeno 28. svibnja 2019. (<http://valencije.ihjj.hr/>).
25. Beal, Vangie. 2008. What is Scripting Language? *Webopedia*. Pristupljeno 9. travnja 2020. (https://www.webopedia.com/TERM/S/scripting_language.html).
26. Bee-Cubed. 2020. *Merriam-Webster*. Pristupljeno 10. veljače 2020. (<https://www.merriam-webster.com/word-games/bee-cubed>).
27. Beers, Brian. 2020. P-Value Definition. *Investopedia*. Pristupljeno 5. svibnja 2020. (<https://www.investopedia.com/terms/p/p-value.asp>).
28. Best XML to JSON Converter Online to convert XML to JSON String, URL and File. 2013. *CodeBeautify*. Pristupljeno 23. siječnja 2020. (<https://codebeautify.org/xmltojson>).
29. Bettis, Ben. 2013. Gamification, Meet Gamefulness. *Learning Technologies Resource Center*. Pristupljeno 22. siječnja 2020. (<https://learningtechnologies.td.org/games-gamification/gamification-meet-gamefulness/>).
30. Bolje je hrvatski!. 2015. *bolje.hr*. Pristupljeno 28. svibnja 2019. (<http://bolje.hr/>).
31. Bolje.hr pamtilica. 2016. *Hrvatski u školi*. Pristupljeno 16. ožujka 2020. (<http://hrvatski.hr/igra/3/>).
32. Bot definition and meaning. 2010. *Collins English Dictionary*. Pristupljeno 30. siječnja 2020. (<https://www.collinsdictionary.com/dictionary/english/bot>).
33. Božić, Ivan. 2019. Odlična vijest za maturante: Na webu objavljen interaktivni kviz za vježbanje hrvatskog jezika za maturu. *srednja.hr*. Pristupljeno 28. svibnja 2020. (<https://www.srednja.hr/matura/odlicna-vijest-maturante-webu-objavljen-interaktivni-kviz-vjezbanje-hrvatskog-jezika/>).
34. Brackets – A modern, open source code editor that understands web design. *Brackets*. Pristupljeno 9. travnja 2020. (<http://brackets.io/>).

35. BSL SignBank. 2014. *BSL SignBank – practice*. Pristupljeno 7. veljače 2020. (<https://bslsignbank.ucl.ac.uk/spell/practice.html>).
36. BumperDucks. 2015. *Smithsonian Science Education Center*. Pristupljeno 15. veljače 2020. (<https://ssec.si.edu/bumperducks>).
37. Cadre européen commun de référence pour les langues. 2010. *Council of Europe*. Pristupljeno 12. travnja 2020. (<https://www.coe.int/en/web/common-european-framework-reference-languages/>).
38. CARNet lms – loomen. 2019. *loomen*. Pristupljeno 27. studenoga 2019. (<https://loomen.carnet.hr/>).
39. Catch the Robber. 2019. *The National Archives*. Pristupljeno 6. ožujka 2020. (<https://www.nationalarchives.gov.uk/education/candp/games/galleries/gallery2.htm>).
40. Chen, James. 2020. Normal Distribution Definition. *Investopedia*. Pristupljeno 12. lipnja 2020. (<https://www.investopedia.com/terms/n/normaldistribution.asp>).
41. Christopher, Joe. 2018. GDPR: Do I Really Need Consent for GA Tracking. *Blast Analytics*. Pristupljeno 11. travnja 2020. (<https://www.blastanalytics.com/blog/gdpr-need-consent-for-google-analytics-tracking>).
42. City Car Driving. 2016. *Steam*. Pristupljeno 30. ožujka 2020. (https://store.steampowered.com/app/493490/City_Car_Driving/).
43. CLARIN Slovenia. 2019. *CLARIN*. Pristupljeno 29. svibnja 2019. (<http://www.clarin.si/info/about/>).
44. cloud computing > oblačno računalstvo. 2015. *Bolje je hrvatski!* Pristupljeno 15. siječnja 2020. (<http://bolje.hr/rijec/cloud-computing-gt-oblacno-racunalstvo/26/>).
45. CodePen: Build, Test, and Discover Front-end Code. 2019. *CodePen*. Pristupljeno 10. siječnja 2020. (<https://codepen.io/>).
46. CodeWars. 2014. *CodeWars*. Pristupljeno 23. rujna 2019. (<https://www.codewars.com/>).
47. Coding Games and Programming Challenges to Code Better. 2016. *CodinGame*. Pristupljeno 23. rujna 2019. (<https://www.codinggame.com/>).
48. Common European Framework of Reference for Languages: Learning, Teaching, Assessment (CEFR). 2012. *Council of Europe*. Pristupljeno 2. svibnja 2020. (https://archive.is/20120729045710/www.coe.int/t/dg4/linguistic/CADRE_EN.asp).
49. Coppola, John. 2017. Spanish Language Quiz. *CodePen*. Pristupljeno 7. travnja 2020. (<https://codepen.io/johnnycopes/pen/LbWYgP>).
50. Coral Reef. 2019. *Funbrain*. Pristupljeno 22. prosinca 2019. (<https://www.funbrain.com/games/tinybop-schools-coral-reef>).

51. Corpus types: monolingual, parallel, multilingual. 2016. *Sketch Engine*. Pristupljeno 7. studenoga 2019. (<https://www.sketchengine.eu/corpora-and-languages/corpus-types/>).
52. Coulter, Jamie. 2019. Planets Quiz. *CodePen*. Pristupljeno 21. svibnja 2020. (<https://codepen.io/jcoulterdesign/pen/eJGoOx>).
53. Create and Share Rich HTML5 Content and Applications. 2016. *H5P*. Pristupljeno 19. veljače 2020. (<https://h5p.org/>).
54. Create games without programming – Open source HTML5 and native game creator. 2018. *GDevelop*. Pristupljeno 31. ožujka 2020. (<https://gdevelop-app.com/>).
55. Critical Values for Wilcoxon Ranked Sign Test. 2011. *Boston University*. Pristupljeno 28. rujna 2020. (https://sphweb.bumc.bu.edu/otlt/MPH-Modules/BS/BS704_Nonparametric/Critical%20Values%20for%20Wilcoxon%20Ranked%20Sign%20Test.pdf).
56. Croaticum. 2018. Free Online Croatian Courses – A1.HR and A2.HR. *Croaticum*. Pristupljeno 11. travnja 2019. (https://croaticum.ffzg.unizg.hr/?page_id=5024).
57. Crossman, Ashley. 2020. Qualitative Research Definition and Methods. *ThoughtCo*. Pristupljeno 31. ožujka 2020. (<https://www.thoughtco.com/qualitative-research-methods-3026555>).
58. crowdsourcing > masovna podrška. 2019. *Bolje je hrvatski!* Pristupljeno 8. siječnja 2020. (<http://bolje.hr/rijec/crowdsourcing-gt-masovna-podrska/18/>).
59. Daily Crossword Puzzle. 2020. *Merriam-Webster*. Pristupljeno 10. veljače 2020. (<https://www.merriam-webster.com/word-games/universal-daily-crossword>).
60. Daloukas, Vasilis. 2019. Game. *Moodle plugins directory*. Pristupljeno 31. ožujka 2020. (https://moodle.org/plugins/mod_game).
61. Dani otvorenih vrata. 2020. *Institut za hrvatski jezik i jezikoslovlje*. Pristupljeno 15. travnja 2020. (<http://ihjj.hr/stranica/dani-otvorenih-vrata/21/>).
62. Definition of Audio book. 2019. *Dictionary.com*. Pristupljeno 12. kolovoza 2019. (<https://www.dictionary.com/browse/audio-book?s=t>).
63. Definition of Gamification. 2019. *Merriam-Webster*. Pristupljeno 3. siječnja 2019. (<https://www.merriam-webster.com/dictionary/gamification>).
64. Definition of Open-source. 2016. *Dictionary.com*. Pristupljeno 31. ožujka 2020. (<https://www.dictionary.com/browse/open-source>).
65. Definition of Wiki. 2019. *Merriam-Webster*. Pristupljeno 1. rujna 2020. (<https://www.merriam-webster.com/dictionary/wiki>).
66. Definition of Zombie. 2009. *Dictionary.com*. Pristupljeno 27. studenoga 2019.

- (<https://www.dictionary.com/browse/zombie>).
67. Devčić, Karmela. 2019. HIT IZDANJE INSTITUTA ZA HRVATSKI JEZIK I JEZIKOSLOVLJE Iako dostupna i online, školska gramatika i dalje se dobro prodaje. *Jutarnji List*. Pristupljeno 28. svibnja 2020. (<https://www.jutarnji.hr/kultura/knjizevnost/hit-izdanje-instituta-za-hrvatski-jezik-i-jezikoslovlje-iako-dostupna-i-online-skolska-gramatika-i-dalje-se-dobro-prodaje/9622444/>).
 68. Dicionário Infopédia da Língua Portuguesa. 2020. *infopédia*. Pristupljeno 11. veljače 2020. (<https://www.infopedia.pt/dicionarios/lingua-portuguesa>).
 69. Dictionary and Thesaurus Pro. 2016. *App Store*. Pristupljeno 31. siječnja 2020. (<https://apps.apple.com/us/app/dictionary-and-thesaurus-pro/id492085918>).
 70. Dictionary of the dialects of Jutland. 2018. *Jysk Ordbog*. Pristupljeno 11. veljače 2020. (<http://www.jyskordbog.dk/jyskordbog/ordbog.html>).
 71. Dictionary Pro. *Apps on Google Play*. 1992. Pristupljeno 31. siječnja 2020. (https://play.google.com/store/apps/details?id=thefreedictionary.dictionary&hl=en_US).
 72. Dictionary, by web-eau.net. 2019. *Joomla Extension Directory*. Pristupljeno 24. kolovoza 2019. (<https://extensions.joomla.org/extensions/extension/directory-a-documentation/glossary/dictionary/>).
 73. Digital Library. 2015. *Calgary Public Library*. Pristupljeno 18. prosinca 2019. (<https://calgarylibrary.ca/read-learn-and-explore/digital-library/?query=>).
 74. Dimock, Michael. 2019. Where Millennials end and Generation Z begins. *Pew Research Center*. Pristupljeno 13. travnja 2020. (<https://www.pewresearch.org/fact-tank/2019/01/17/where-millennials-end-and-generation-z-begins/>).
 75. Disaster Detector. 2015. *Smithsonian Science Education Center*. Pristupljeno 15. veljače 2020. (<https://ssec.si.edu/disaster-detector>).
 76. Distance Learning. 2020. *Merriam-Webster*. Pristupljeno 31. siječnja 2020. (<https://www.merriam-webster.com/dictionary/distance%20learning>).
 77. DocsTeach. 2016. *National archives*. Pristupljeno 6. ožujka 2020. (<https://www.docsteach.org/>).
 78. Doktorand Josip Mihaljević dobio nagradu za inovativni digitalni obrazovni sadržaj. 2018. *Institut za hrvatski jezik i jezikoslovlje*. Pristupljeno 5. siječnja 2020. (<http://ihjj.hr/clanak/doktorand-josip-mihaljevic-dobio-nagradu-za-inovativni-digitalni-obrazovni-sadrzaj/731/>).

79. Domesday game. 2006. *The National Archives*. Pristupljeno 6. ožujka 2020.: (<https://www.nationalarchives.gov.uk/domesday/domesday-game/>).
80. Dubey, Priya. 2018. Just do it – As Nike+ did with Gamification. *ImaginXP*. Pristupljeno 27. studenoga 2019. (<https://imaginxp.com/whyuxblog/gamification/>).
81. Duolingo – Practice. 2019. *Duolingo*. Pristupljeno 29. studenoga 2019. (<https://www.duolingo.com/practice>).
82. Duolingo – The world's best way to learn German. 2019. *Duolingo*. Pristupljeno 23. rujna 2019. (<https://www.duolingo.com/learn>).
83. Early Learning by World Book. 2019. *YouTube*. Pristupljeno 17. veljače 2019. (<https://www.youtube.com/watch?v=LhA4TLmQjQU>).
84. EclipseCrossword – the fast, easy, and FREE way to create crossword puzzles in minutes. 2020. *EclipseCrossword*. Pristupljeno 31. ožujka 2020. (<https://eclipsecrossword.com/>).
85. Education and Outreach. 2019. *The National Archives*. Pristupljeno 6. ožujka 2020. (<https://www.nationalarchives.gov.uk/education/>).
86. Education. 2016. *The New York Public Library*. Pristupljeno 20. prosinca 2019. (<https://www.nypl.org/education>).
87. Educational Games, Books, Puzzles & Songs for Kids & Toddlers. 2010. *ABCmouse*. Pristupljeno 11. ožujka 2020. (<https://www.abcmouse.com/subscription>).
88. Educator Resources. 2018. *National Archives*. Pristupljeno 6. ožujka 2020. (<https://www.archives.gov/education>).
89. E-kolegij: Osnove e-učenja (A206). 2016. *Tečajevi SRCE*. Pristupljeno 4. ožujka 2019. (<https://lms3.srce.hr/moodle/course/view.php?id=132>).
90. eLearning. 2002. *San Francisco Public Library*. Pristupljeno 19. prosinca 2019. (<https://sfpl.org/?pg=0000026301>).
91. elexiko. *owid.de*. Pristupljeno 29. studenoga 2019. (<https://www.owid.de/docs/elex/start.jsp>).
92. Encyclopedia Britannica Quizzes. 2016. *Britannica*. Pristupljeno 15. veljače 2020. (<https://www.britannica.com/quiz/browse>).
93. Encyclopedia Britannica. 2020. *Britannica*. Pristupljeno 13. veljače 2020. (<https://www.britannica.com/>).
94. Encyclopedia Mythica. 2005. *Encyclopedia Mythica*. Pristupljeno 13. veljače 2020. (<https://pantheon.org/>).
95. Encyclopedia. 2009. *The Canadian Encyclopedia*. Pristupljeno 13. veljače 2020. (<https://www.thecanadianencyclopedia.ca/en/article/encyclopedia>).

96. Encyclopédie Universalis. 2009. *Universalis.fr*. Pristupljeno 13. veljače 2020. (<https://www.universalis.fr/>).
97. eResources Archive. 2019. *Carnegie Library of Pittsburgh*. Pristupljeno 12. kolovoza 2019. (<https://www.carnegielibrary.org/eresources/?format-id=20>).
98. E-rječnici i e-leksikografija. 2020. *Hrvatski mrežni rječnik*. Pristupljeno 21. siječnja 2020. (<http://ihjj.hr/mreznik/page/e-rjecnici-i-e-leksikografija/8/>).
99. Eryigit, Gülşen. 2020. *UML Diagram of the MWEMaster*. Pristupljeno 23. siječnja 2020. (<https://bit.ly/2NUPppL>).
100. Etnici i ktetici. 2016. *Hrvatski u školi*. Pristupljeno 23. svibnja 2020. (<http://hrvatski.hr/etnici-i-ktetici/>).
101. Europski rječnički portal: hrvatski. 2016. *Dictionary portal*. Pristupljeno 29. studenoga 2019. (<http://www.dictionaryportal.eu/hr/ctlg/?objLang=hr>).
102. Explore collections. 2016. *National Museum Scotland*. Pristupljeno 6. ožujka 2020. (<https://www.nms.ac.uk/explore-our-collections/>).
103. Explore Your Interests. 2010. *Smithsonian Institution*. Pristupljeno 15. veljače 2020. (<https://www.si.edu/explore>).
104. Fact Monster – A Trusted Reference Site for Kids. 2010. *Fact Monster*. Pristupljeno 14. veljače 2020. (<https://www.factmonster.com/>).
105. FineReader 15 The Smarter PDF Solution. 2020. *ABBYY FineReader*. Pristupljeno 1. veljače 2020. (<https://bit.ly/36pNaRK>).
106. Fitocracy. 2014. *Fitocracy*. Pristupljeno 14. 3. 2021. (<https://www.fitocracy.com/>).
107. Flashcard. 2017. *FactMonster*. Pristupljeno 17. veljače 2020. ([https://www.factmonster.com/math/flashcard?op\[0\]=addition&level=1](https://www.factmonster.com/math/flashcard?op[0]=addition&level=1)).
108. Foley, Ben. 2018. How to Choose Between Parametric & Nonparametric Tests. *SurveyGizmo*. Pristupljeno 17. lipnja 2020. (<https://www.surveygizmo.com/resources/blog/how-to-choose-between-parametric-nonparametric-tests/>).
109. Free Daily Crossword Puzzles. 2020. *Dictionary.com*. Pristupljeno 7. veljače 2020. (<https://www.dictionary.com/e/crossword/>).
110. Free English exercises. 1992. *Longman Dictionary of Contemporary English*. Pristupljeno 29. travnja 2019. (<https://www.ldoceonline.com/exercise/>).
111. Free Git GUI Client. 2016. *GitKraken*. Pristupljeno 2. travnja 2020. (<https://www.gitkraken.com/>).
112. Free Language Courses. 2020. *Duolingo*. Pristupljeno 12. travnja 2020.

- (<https://www.duolingo.com/courses>).
113. Free Online Encyclopedia. 2006. *Encyclopedia.com*. Pristupljeno 13. veljače 2020. (<https://www.encyclopedia.com/>).
114. Free Online Games, Downloads, Competitions & Videos for Kids. 2016. *Cartoon Network*. Pristupljeno 18. prosinca 2019. (<https://www.cartoonnetworkhq.com/>).
115. Free printable worksheets. 2017. *Scrabble Maker*. Pristupljeno 31. ožujka 2020. (<https://www.edu-games.org/word-games/scrabble-word-maker.php>).
116. Freesound. 2020. *Freesound*. Pristupljeno 9. travnja 2020. (<https://freesound.org/>).
117. Frost, Jim. 2015. Nonparametric Tests vs. Parametric Tests. *Statistics By Jim*. Pristupljeno 11. lipnja 2020. (<https://statisticsbyjim.com/hypothesis-testing/nonparametric-parametric-tests/>).
118. Frost, Jim. 2018. Normal Distribution in Statistics. *Statistics By Jim*. Pristupljeno 18. lipnja 2020. (<https://statisticsbyjim.com/basics/normal-distribution/>).
119. Frost, Jim. 2019a. 5 Ways to Find Outliers in Your Data. *Statistics By Jim*. Pristupljeno 9. rujna 2020. (<https://statisticsbyjim.com/basics/outliers/>).
120. Frost, Jim. 2019b. Can High P-values Be Meaningful?. *Statistics By Jim*. Pristupljeno 9. rujna 2020. (<https://statisticsbyjim.com/hypothesis-testing/high-p-values/>).
121. Full Catalog Courses & Tutorials. 2019. *Codecademy*. Pristupljeno 17. rujna 2019. (<https://www.codecademy.com/catalog/subject/all>).
122. Fun and Games. 2016. *Park Ridge Library*. Pristupljeno 10. ožujka 2020. (<https://www.parkridgelibrary.org/fun-and-games/>).
123. G*Power: Statistical Power Analyses for Windows and Mac. 2007. *Universität Düsseldorf*. Pristupljeno 15. rujna 2020. (<https://www.psychologie.hhu.de/arbeitsgruppen/allgemeine-psychologie-und-arbeitspsychologie/gpower.html>).
124. Game – The Great Fire of London. 2008. *Fire of London*. Pristupljeno 6. ožujka 2020. (<http://www.fireoflondon.org.uk/game/>).
125. Game collection. 2016. *National Archives of Australia*. Pristupljeno 3. lipnja 2020. (<http://www.guides.naa.gov.au/collection/snapshots/Games/tennis.aspx>).
126. gamefication > igrifikacija. 2016. *Bolje je hrvatski!*. Pristupljeno 22. siječnja 2020. (<http://bolje.hr/rijec/gamefication-gt-igrifikacija/99/>).
127. Games & Quizzes. 2008. *Tate Kids*. Pristupljeno 6. ožujka 2020. (<https://www.tate.org.uk/kids/games-quizzes>).
128. Games and apps. 2007. *Science Museum*. Pristupljeno 6. ožujka 2020.

- (<https://www.sciencemuseum.org.uk/games-and-apps>).
129. Games at Miniclip.com. 2006. *Miniclip.com*. Pristupljeno 10. ožujka 2020. (<https://www.miniclip.com/games/en/>).
130. Games, Videos, and Books for Kids. 2010. *Funbrain*. Pristupljeno 14. prosinca 2019. (<https://www.funbrain.com/>).
131. Games. 2007. *National Geographic Kids*. Pristupljeno 14. prosinca 2019. (<https://kids.nationalgeographic.com/games/>).
132. Games. 2019. *braillebug*. Pristupljeno 15. veljače 2020. (<http://braillebug.org/Games.asp>).
133. GAMIFICATION. 2019. *Cambridge English Dictionary*. Pristupljeno 17. siječnja 2020. (<https://dictionary.cambridge.org/dictionary/english/gamification>).
134. Gelenčir, Martina. 2019. Instagram se približava Facebooku: Evo koliko Hrvata koristi dvije najpopularnije mreže. *srednja.hr*. Pristupljeno 11. travnja 2020. (<https://www.srednja.hr/svastara/instagram-se-priblizava-facebooku-evo-koliko-hrvata-koristi-dvije-najpopularnije-mreze/>).
135. Generalic, Eni. 2004. Englesko-hrvatski kemijski rječnik & glosar. *KTF-Split*. Pristupljeno 2. veljače 2020. (<https://glossary.periodni.com/rjecnik.php>).
136. Generalic, Eni. 2013. Igra memorije. *EniG. Periodni sustav elemenata*. Pristupljeno 7. veljače 2020. (https://www.periodni.com/hr/pronadi_parove.html).
137. Getting Involved. 2013. *H5P*. Pristupljeno 14. lipnja 2019. (<https://h5p.org/getting-involved>).
138. Gillespie, Claire. 2018. What Does a Negative T-Value Mean? *Sciencing*. Pristupljeno 5. svibnja 2020. (<https://sciencing.com/negative-tvalue-mean-6921215.html>).
139. GIMP: GNU IMAGE MANIPULATION PROGRAM. 2003. *GIMP*. Pristupljeno 9. travnja 2020. (<https://www.gimp.org/>).
140. Git. 2012. *Git*. Pristupljeno 2. travnja 2020. (<https://git-scm.com/>).
141. Glen, Stephanie. 2014. Shapiro-Wilk Test: What it is and How to Run it. *Statistics How To*. Pristupljeno 17. lipnja 2020. (<https://www.statisticshowto.com/shapiro-wilk-test/>).
142. Glen, Stephanie. 2015a. Mann Whitney U Test. *Statistics How To*. Pristupljeno 15. lipnja 2020. (<https://www.statisticshowto.com/mann-whitney-u-test/>).
143. Glen, Stephanie. 2015b. Spearman Rank Correlation (Spearman's Rho): Definition and How to Calculate it. *Statistics How To*. Pristupljeno 23. lipnja 2020. (<https://www.statisticshowto.com/spearman-rank-correlation-definition-calculate/>).
144. Glen, Stephanie. 2020. Wilcoxon Signed Rank Test: Definition, How to Run. *Statistics How To*. Pristupljeno 28. rujna 2020. (<https://www.statisticshowto.com/spearman-rank->

- correlation-definition-calculate/).
145. Global Signbank. 2018. *Global Signbank*. Pristupljeno 7. veljače 2020. (<https://signbank.science.ru.nl/>).
 146. Glossary – Reference. 2012. *A-Z Animals*. Pristupljeno 29. travnja 2019. (<https://a-z-animals.com/reference/glossary/#jump-animal>).
 147. Gnade, Mike. 2010. What Exactly is an Indie Game?. *WebCite*. Pristupljeno 23. studenoga 2019. (<https://www.indiegamemag.com/what-is-an-indie-game/>).
 148. Government of Canada. 2019. Census Profile, 2016 Census. *Statistics Canada*. Pristupljeno 21. travnja 2020. (<https://www12.statcan.gc.ca/census-recensement/2016/dp-pd/prof/details/page.cfm?Lang=E&Geo1=PR&Code1=01&Geo2=PR&Code2=01&Data=Count&SearchText=canada&SearchType=Begin&SearchPR=01&B1=Language&TABID=1>).
 149. Grab Bag for Word Nerds. 2020. *Vocabulary.com*. Pristupljeno 7. veljače 2020. (<https://www.vocabulary.com/lists/ev72l5vt/grab-bag-for-word-nerds>).
 150. Habitats. 2014. *Smithsonian Science Education Center*. Pristupljeno 15. veljače 2020. (<https://ssec.si.edu/habitats>).
 151. Hangman – Play for Free By Popular Topic. 2019. *FactMonster*. Pristupljeno 15. veljače 2020. (<https://www.factmonster.com/games/hangman>).
 152. Hayes, Adam. 2020. Null Hypothesis Definition. *Investopedia*. Pristupljeno 4. svibnja 2020. (https://www.investopedia.com/terms/n/null_hypothesis.asp).
 153. Helmut Weinberger – Das Rückläufige Wörterbuch des Serbokroatischen von Josip Matešić in digitalisierter Version. 2008. *Universität Innsbruck*. Pristupljeno 19. siječnja 2020. (<https://www.uibk.ac.at/slalistik/institut/matesic.html>).
 154. Home. 2013. *Montgomery County Public Libraries*. Pristupljeno 18. prosinca 2019. (<https://www.montgomerycountymd.gov/library/>).
 155. Hoppe, Dennis. 2019. Encyclopedia / Glossary / Wiki – WordPress plugin. *WordPress.org*. Pristupljeno 25. svibnja 2019. (<https://hr.wordpress.org/plugins/encyclopedia-lexicon-glossary-wiki-dictionary/>).
 156. Hotjar: Website Heatmaps & Behavior Analytics Tools. 2014. *Hotjar*. Pristupljeno 27. svibnja 2020. (<https://www.hotjar.com/>).
 157. How Does Google Analytics Track User Age and Gender?. 2019. *Google-Analytics*. Pristupljeno 11. travnja 2020. (<https://www.google-analytics.ie/blog/how-does-google-analytics-track-user-gender-and-age/>).

158. Hrvatska jezična riznica: Naslovnica. 2010. *Institut za hrvatski jezik i jezikoslovlje*.
Pristupljeno 29. svibnja 2019. (<http://riznica.ihjj.hr/index.hr.html>).
159. Hrvatska Radiotelevizija. 2019. Jezične igrice. *Školski sat*. Pristupljeno 2. srpanj 2020.
(<https://skolski.hrt.hr/emisije/1070/jezicne-igrice>).
160. Hrvatska Radiotelevizija. 2020. Škola na Trećem: 4. RAZRED – Hrvatski Jezik. *Youtube*.
Pristupljeno 7. veljače 2020.
(<https://www.youtube.com/watch?v=5T4bgsBLZZQ&t=55m17s>).
161. Hrvatski na maturi. 2013. *Institut za hrvatski jezik i jezikoslovlje*. Pristupljeno 4. kolovoza
2020. (<http://matura.ihjj.hr/>).
162. Hrvatski pravopis. 2019. *Aplikacije na Google Playu*. Pristupljeno 31. siječnja 2020.
(<https://play.google.com/store/apps/details?id=hr.ihjj.pravopis&hl=hr>).
163. Hrvatski Školski Muzej – zbirka. 2018. *Hrvatski Školski Muzej*. Pristupljeno 6. ožujka
2020. (<http://www.hsmuzej.hr/hr/sadrzaj/zbirke/arhivska-zbirka>).
164. Hrvatski terminološki portal. 2015. *nazivlje.hr*. Pristupljeno 28. svibnja 2019.
(<http://nazivlje.hr/>).
165. Hrvatski u školi. 2016. *Institut za hrvatski jezik i jezikoslovlje*. Pristupljeno 6. siječnja
2020. (<http://hrvatski.hr/>).
166. Hrvatsko jezikoslovno nazivlje – JENA. 2020. *JENA*. Pristupljeno 1. listopada 2019.
(<http://ihjj.hr/jena/>).
167. Hrvatsko strukovno nazivlje. 2010. *Struna*. Pristupljeno 28. svibnja 2019.
(<http://struna.ihjj.hr/>).
168. hrWaC – Croatian web corpus. 2013. *Natural Language Processing group*. Pristupljeno
29. svibnja 2019. (<http://nlp.ffzg.hr/resources/corpora/hrwac/>).
169. Hudeček, Lana, Željko Jozić, Kristian Lewis, i Milica Mihaljević. 2016. Prvi školski
pravopis hrvatskoga jezika. *Institut za hrvatski jezik i jezikoslovlje*. Pristupljeno 7.
travnja 2020. (<http://knjige.ihjj.hr/knjiga/prvi-skolski-pravopis-hrvatskoga-jezika/222/>).
170. Hudeček, Lana. 2017. O Mrežniku. *Hrvatski mrežni rječnik*. Pristupljeno 19. siječnja
2020. (<http://ihjj.hr/mreznik/page/o-mrezniku/1/>).
171. Hudeček, Lana; Lazić, Daria; Mihaljević, Milica; Mihaljević, Josip. 2018. Pojmovnik.
Hrvatski mrežni rječnik – Mrežnik. Pristupljeno 3. siječnja 2020.
(<http://ihjj.hr/mreznik/page/pojmovnik/6/>).
172. Hughes, Barry. 2011. Game theory and gamification are not the same thing | Game Theory
Strategies. *Game Theory Strategies*. Pristupljeno 3. siječnja 2020.

- (<http://www.gametheorystrategies.com/2011/07/06/game-theory-and-gamification/>).
173. Imagine, Program, Share. 2019. *Scratch*. Pristupljeno 19. prosinca 2019. (<https://scratch.mit.edu/>).
 174. Inaugural Quiz!. 2019. *National Archives*. Pristupljeno 6. ožujka 2020. (<https://www.archives.gov/education/lessons/inaugural-quiz>).
 175. Inkscape. 2020. *Inkscape*. Pristupljeno 9. travnja 2020. (<https://inkscape.org/hr/>).
 176. Installation & setup. 2014. *H5P*. Pristupljeno 14. lipnja 2019. (<https://h5p.org/installation>).
 177. Institut za hrvatski jezik i jezikoslovlje. 2012. *Facebook*. Pristupljeno 11. travnja 2020. (<https://www.facebook.com/ihjj.hr/>).
 178. Institut za hrvatski jezik i jezikoslovlje. 2012. Predstavljanje institutskih izdanja na Interliberu. *IHJJ*. Pristupljeno 25. rujna 2020. (<http://ihjj.hr/clanak/predstavljanje-institutskih-izdanja-na-interliberu/528/>).
 179. iSEEK – Education. 2007. *iSEEK*. Pristupljeno 29. rujna 2019. (<http://education.iseek.com/iseek/home.page>).
 180. Istraživanja braće Seljan (pamtilica). 2018. *Etnografski muzej*. Pristupljeno 5. ožujka 2020. (<http://bracaseljan.emz.hr/Memory.aspx#>).
 181. James, Stella. 2017. Game-based learning: effective teaching driven by play. *Independent Schools Portal*. Pristupljeno 1. kolovoza 2020. (<https://www.independentschoolsportal.org/blog/game-based-learning-effective-teaching-driven-by-play>).
 182. Jezični savjetnik. 2017. *jezicni-savjetnik.hr*. Pristupljeno 28. svibnja 2019. (<http://jezicni-savjetnik.hr/>).
 183. Jones, Paige. 2019. What's the Difference Between Google Analytics and Google Search Console? *Twenty Over Ten*. Pristupljeno 27. svibnja 2020. (<https://blog.twentyoverten.com/whats-the-difference-between-google-analytics-and-google-search-console/>).
 184. jsoma/tabletop: Tabletop.js gives spreadsheets legs. 2017. *GitHub*. Pristupljeno 29. travnja 2020. (<https://github.com/jsoma/tabletop>).
 185. Jumble Solitaire. 2020. *Merriam-Webster*. Pristupljeno 10. veljače 2020. (<https://www.merriam-webster.com/word-games/jumble-solitaire>).
 186. K., M. S. 2019. Šteka ti znanje hrvatskog jezika? Ovo je odlična stvar za utvrditi gradivo za državnu maturu. *Teen385.com*. Pristupljeno 28. svibnja 2020. (<http://www.teen385.com/funzone/zanimljivosti/steka-ti-znanje-hrvatskog-jezika-ovo-je-odlicna-stvar-za-utvrditi-gradivo-za-drzavnu-maturu>).

187. Kahoot!. 2019. *Learning Games / Make Learning Awesome!* Pristupljeno 19. veljače 2020. (<https://kahoot.com/>).
188. Kassambara, Alboukadel. 2017. ggpubr: 'ggplot2' Based Publication Ready Plots. *The Comprehensive R Archive Network*. Pristupljeno 23. lipnja 2020. (<https://cran.r-project.org/web/packages/ggpubr/readme/README.html>).
189. Kenton, Will. 2020a. Statistical Significance Definition. *Investopedia*. Pristupljeno 1. svibnja 2020. (https://www.investopedia.com/terms/s/statistically_significant.asp).
190. Kenton, Will. 2020b. T-Test Definition. *Investopedia*. Pristupljeno 5. svibnja 2020. (<https://www.investopedia.com/terms/t/t-test.asp>).
191. Kids Home. 2019. *PhoenixPublicLibrary*. Pristupljeno 20. prosinca 2019. (<https://www.phoenixpubliclibrary.org/kids>).
192. Kids. 2019. *Chicago Public Library*. Pristupljeno 20. prosinca 2019. (<https://www.chipublib.org/kids/>).
193. Kids. 2019. *Contra Costa County Library*. Pristupljeno 20. prosinca 2019. (<https://ccclib.org/kids-landing-page/>).
194. Klappenbach, Michael. 2019. What is a Platform Game?. *Lifewire*. Pristupljeno 7. rujna 2020. (<https://www.lifewire.com/what-is-a-platform-game-812371>).
195. Krpan, Hrvoje. 2013. Korelacije. *Znanost Blog*. Pristupljeno 23. lipnja 2020. (<http://www.znanostblog.com/korelacije/>).
196. Kuri, Borna; Mihaljević, Josip. 2017a. Kviz o Ahileju. *Jezične igre*. Pristupljeno 24. svibnja 2020. (<https://jezicneigre.com/kviz-o-ahileju/>).
197. Kuri, Borna; Mihaljević, Josip. 2017b. mitologija – igre. *Jezične igre*. Pristupljeno 24. svibnja 2020. (<https://jezicneigre.com/mitologija/>).
198. Kurikularna reforma – Škola za život. 2019. *Ministarstvo znanosti i obrazovanja*. Pristupljeno 27. studenoga 2019. (<https://mzo.gov.hr/vijesti/kurikularna-reforma-skola-za-zivot/2049>).
199. La cultura Italiana – Enciclopedia. 2011. *Treccani*. Pristupljeno 14. veljače 2020. (<http://www.treccani.it/enciclopedia/>).
200. Language Games. 2013. *Macmillan Dictionary*. Pristupljeno 2. veljače 2020. (<https://www.macmillandictionary.com/language-games/puzzles>).
201. Language Puzzles. 2013. *Macmillan Dictionary*. Pristupljeno 7. veljače 2020. (<https://www.macmillandictionary.com/us/language-games/puzzles>).
202. Lazić, Daria; Mihaljević, Josip. 2019a. Razvrstavanje glagolskih oblika. *GitLab*. Pristupljeno 20. svibnja 2020. (<https://borna12.gitlab.io/igre-mreznik/glagoli/>).

203. Lazić, Daria; Mihaljević, Josip. 2019b. Pamtilica pomoćni glagoli. Pristupljeno 20. svibnja 2020. (<https://bornal2.gitlab.io/igre-mreznik/pamtilica-pomocni-glagoli/>).
204. Learn language in context. 2019. *Clozemaster*. Pristupljeno 29. studenoga 2019. (<https://www.clozemaster.com/dashboard>).
205. Learn languages online for free. 2016. *Mondly*. Pristupljeno 20. travnja 2020. (<https://www.mondly.com/>).
206. Learn languages online with Lingualia. 2019. *Lingualia*. Pristupljeno 29. studenoga 2019. (<https://www.lingualia.com/>).
207. Learn languages: Spanish, French, German and start for free. 2019. *Busuu*. Pristupljeno 29. studenoga 2019. (<https://www.busuu.com/>).
208. Learning Hrvatski From English. 2019. *Clozemaster*. Pristupljeno 29. studenoga 2019. (<https://bit.ly/30ws8jj>).
209. Learning tools & flashcards, for free. 2009. *Quizlet*. Pristupljeno 19. veljače 2020. (<https://quizlet.com/>).
210. leksikografija. 2014. *Hrvatska enciklopedija*. Pristupljeno 14. siječnja 2020. (<http://www.enciklopedija.hr/natuknica.aspx?ID=35936>).
211. Leksikon pojmova iz Oftalmologije i Optike. 2012. *Optometrija.net*. Pristupljeno 28. ožujka 2019. (<https://www.optometrija.net/pojmovnik/pojmovnik/>).
212. leo.org. 2020. *English ⇔ German trainer*. Pristupljeno 2. veljače 2020. (<https://dict.leo.org/trainer/index.php?lp=ende&lang=en&pos=7>).
213. Lexique Pro – Don't keep your lexicon to yourself! Share it with others!. 2012. *Lexique Pro*. Pristupljeno 25. svibnja 2019. (<http://www.lexiquepro.com/index.htm>).
214. Lexonomy – A platform for writing and publishing dictionaries. 2017. *Lexonomy*. Pristupljeno 15. siječnja 2020. (<https://www.lexonomy.eu/>).
215. Likertova ljestvica. 2013. *Hrvatska enciklopedija*. Pristupljeno 20. travnja 2020. (<https://www.enciklopedija.hr/natuknica.aspx?id=36507>).
216. Lionel, Nicolas. 2019. Crowdfest: crowdfest. *enetCollect*. Pristupljeno 13. siječnja 2020. (https://www.enetcollect.net/ilias/goto.php?target=wiki_546_crowdfest).
217. List of libraries. 2019. *Wikipedia*. Pristupljeno 12. kolovoza 2019. (https://en.wikipedia.org/wiki/List_of_libraries).
218. List of Mario educational games. 2019. *Wikipedia*. Pristupljeno 12. ožujka 2019. (https://en.wikipedia.org/wiki/List_of_Mario_educational_games#Mario's_Early_Years!_games).
219. List of online encyclopedias. 2019. *Wikipedia*. Pristupljeno 29. rujna 2019.

- (https://en.wikipedia.org/wiki/List_of_online_encyclopedias).
220. Liu, Ching-Ti; Milton, Jacqueline; McIntosh, Avery. 2016. Correlation. *Boston University School of Public Health*. Pristupljeno 21. lipnja 2020. (http://sphweb.bumc.bu.edu/otlt/MPH-Modules/BS/R/R5_Correlation-Regression/R5_Correlation-Regression3.html).
221. Load the Analysis ToolPak in Excel. 2014. *Office Support*. Pristupljeno 1. svibnja 2020. (<https://support.office.com/en-us/article/load-the-analysis-toolpak-in-excel-6a63e598-cd6d-42e3-9317-6b40ba1a66b4>).
222. Loayza, Jun. 2018. The 10 Best Educational Apps that use Gamification for adults in 2019. *Yu-kai Chou*. Pristupljeno 4. siječnja 2020. (<https://yukaichou.com/gamification-examples/top-10-education-gamification-examples/>).
223. Mackenzie, Ruairi J. 2018. One-Way vs Two-Way ANOVA: Differences, Assumptions and Hypotheses. *Technology Networks*. Pristupljeno 1. svibnja 2020. (<https://www.technologynetworks.com/informatics/articles/one-way-vs-two-way-anova-definition-differences-assumptions-and-hypotheses-306553>).
224. Make Your Own Game with RPG Maker. 2010. *RPG Maker*. Pristupljeno 6. veljače 2020. (<https://www.rpgmakerweb.com/>).
225. Marczewski, Andrzej. 2017. Gamification Elements and Mechanics. *SlideShare*. Pristupljeno 23. studenoga 2019. (<https://www.slideshare.net/daverage/gamification-elements-and-mechanics>).
226. Math Basketball. 2006. *Funbrain*. Pristupljeno 22. prosinca 2019. (<https://www.funbrain.com/games/math-basketball>).
227. Matijević, Maja; Mihaljević, Josip. 2019a. Kviz prepoznavanja slova. *Naučite hrvatski*. Pristupljeno 13. travnja 2020. (https://borna12.gitlab.io/igre-mreznik/sadrzaji_zastrance/kivz-prepoznaj-slovo/index.html).
228. Matijević, Maja; Mihaljević, Josip. 2019b. Pamtilica za učenje hrvatskih riječi. *Naučite hrvatski*. Pristupljeno 13. travnja 2020. (https://borna12.gitlab.io/igre-mreznik/sadrzaji_zastrance/pamtilica/index.html).
229. Matijević, Maja; Mihaljević, Josip. 2019c. Premetaljka. *Naučite hrvatski*. Pristupljeno 13. travnja 2020. (https://borna12.gitlab.io/igre-mreznik/sadrzaji_zastrance/premetaljka/index.html).
230. Matijević, Maja; Mihaljević, Josip. 2019d. Prepoznaj riječi. *Naučite hrvatski*. Pristupljeno 13. travnja 2020. (https://borna12.gitlab.io/igre-mreznik/sadrzaji_zastrance/kivz-prepoznaj-rijec/index.html).

231. Matijević, Maja; Mihaljević, Josip. 2019e. Vješala. *Naučite hrvatski*. Pristupljeno 13. travnja 2020. (https://borna12.gitlab.io/igre-mreznik/sadrzaji_zastrance/vjesala/index.html).
232. McLeod, Saul. 2019. Z-Score: Definition, Calculation & Interpretation. *Simply Psychology*. Pristupljeno 16. lipnja 2020. (<https://www.simplypsychology.org/z-score.html>).
233. Medical Encyclopedia. 2020. *MedlinePlus*. Pristupljeno 13. veljače 2020. (<https://medlineplus.gov/encyclopedia.html>).
234. Memori s glagoljicom. 2016. *Staroslavenski institut*. Pristupljeno 21. svibnja 2020. (https://www.stin.hr/hr/article/120/memori_s_glagoljicom).
235. Memrise. 2019. *Memrise*. Pristupljeno 29. studenoga 2019. (<https://www.memrise.com/login/?next=/home/>).
236. Mihaljević, Ana; Mihaljević, Josip. 2017a. Autori po razdobljima. *Jezične igre*. Pristupljeno 24. svibnja 2020. (<https://jezicneigre.com/autori-po-razdobljima/>).
237. Mihaljević, Ana; Mihaljević, Josip. 2017b. Dan u životu. *Jezične igre*. Pristupljeno 24. svibnja 2020. (<https://jezicneigre.com/dan-u-zivotu/>).
238. Mihaljević, Ana; Mihaljević, Josip. 2017c. Utipkaj riječ s glasovnom promjenom. Pristupljeno 21. svibnja 2020. (<https://jezicneigre.com/hr/utipkaj-rijeci-glasovne/>).
239. Mihaljević, Josip. 2016c. Arhivi u svijetu. *Hrvatsko arhivističko društvo*. Pristupljeno 6. ožujka 2020. (<https://had-info.hr/arhivi-svijet/>).
240. Mihaljević, Josip. 2016d. Arhivistički rječnik – tipkalica. *Hrvatsko arhivističko društvo*. Pristupljeno 7. veljače 2020. (<https://www.had-info.hr/tipkalica/>).
241. Mihaljević, Josip. 2016e. Informatičke igre. Pristupljeno 4. siječnja 2020. (<https://informatickeigre.com/>).
242. Mihaljević, Josip. 2016f. Leteća glagoljica. *Staroslavenski institut*. Pristupljeno 28. svibnja 2020. (<https://zci.stin.hr/games/leteca-glagoljica/>).
243. Mihaljević, Josip. 2016f. Pravopisne vježbe. *Hrvatski u školi*. Pristupljeno 16. ožujka 2020. (<http://hrvatski.hr/pravopisne-vjezbe/>).
244. Mihaljević, Josip. 2016g. Povijest arhiva u Hrvatskoj. *Hrvatsko arhivističko društvo*. Pristupljeno 6. ožujka 2020. (<https://had-info.hr/povijest/>).
245. Mihaljević, Josip. 2016h. Prvi školski pravopis – križaljka. *Hrvatski u školi*. Pristupljeno 18. siječnja 2020. (<http://hrvatski.hr/igra/5/>).
246. Mihaljević, Josip. 2016i. Utipkaj riječi. *Hrvatski u školi*. Pristupljeno 18. siječnja 2020. (<http://hrvatski.hr/igra/4/>).

247. Mihaljević, Josip. 2017d. Križić-kružić: hardverska i programska podrška računala. Pristupljeno 4. siječnja 2020. (<https://informatickeigre.com/1r/krizic-kruzic-podrska/>).
248. Mihaljević, Josip. 2017e. Binarni tetris – internet. Pristupljeno 4. siječnja 2020. (<https://informatickeigre.com/1r/binarni-tetris-internet/>).
249. Mihaljević, Josip. 2017f. Frazemi. *Jezične igre*. Pristupljeno 15. siječnja 2020. (<https://jezicneigre.com/frazemi/>).
250. Mihaljević, Josip. 2017g. Jezične igre i multimedijски prikaz jezika. *Facebook*. Pristupljeno 11. travnja 2020. (<https://www.facebook.com/jezicne>).
251. Mihaljević, Josip. 2017h. Obrazovne igre. *Staroslavenski institut*. Pristupljeno 22. siječnja 2020. (https://www.stin.hr/hr/category/obrazovne_igre/29).
252. Mihaljević, Josip. 2017i. Pravopisni kviz. *Jezične igre*. Pristupljeno 11. travnja 2020. (<https://jezicneigre.com/pravopisni-kviz/>).
253. Mihaljević, Josip. 2017j. Prepoznavaj mitološko biće. *Jezične igre*. Pristupljeno 24. svibnja 2020. (<https://jezicneigre.com/prepoznavaj-mitolosko-bice/>).
254. Mihaljević, Josip. 2018. Arhivističke igre. *Hrvatsko arhivističko društvo*. Pristupljeno 6. ožujka 2020. (<https://had-info.hr/arhivisticke-igre>).
255. Mihaljević, Josip. 2018a. Arhivi i arhivisti u filmovima. *Hrvatsko arhivističko društvo*. Pristupljeno 6. ožujka 2020. (<https://had-info.hr/filmovi/>).
256. Mihaljević, Josip. 2018b. Edukativni kutak Muzeja Mimara. Pristupljeno 5. ožujka 2020. (<http://www.mimara.hr/edukativniKutak/>).
257. Mihaljević, Josip. 2018c. Glagoljojed 2. *Jezične igre*. Pristupljeno 7. siječnja 2020. (<https://jezicneigre.com/glagoljojed-2/>).
258. Mihaljević, Josip. 2018d. Glagoljostrelka. Pristupljeno 7. siječnja 2020. (<https://jezicneigre.com/glagoljostrelka/>).
259. Mihaljević, Josip. 2018e. Muško-ženski parovi. *GitLab*. Pristupljeno 15. travnja 2020. (<https://bornal2.gitlab.io/igre-mreznik/musko-zenski-parovi/>).
260. Mihaljević, Josip. 2018f. Muško-ženski parovi. *Jezične igre*. Pristupljeno 1. listopad 2020. (<https://jezicneigre.com/hr/musko-zenski-parovi/>).
261. Mihaljević, Josip. 2018g. Odaberi ispravan glagol. *GitLab*. Pristupljeno 15. travnja 2020. (<https://bornal2.gitlab.io/igre-mreznik/glagoli-dovlacenje/>).
262. Mihaljević, Josip. 2018h. Odaberi ispravno vrijeme za glagol. *GitLab*. Pristupljeno 20. svibnja 2020. (<https://bornal2.gitlab.io/igre-mreznik/glagoli-dovlacenje/>).
263. Mihaljević, Josip. 2018i. Odostražni rječnik. *GitLab*. Pristupljeno 28. studenoga 2019. (<https://bornal2.gitlab.io/odostraznji/>).

264. Mihaljević, Josip. 2019a. Arhivistički rječnik. *Arhivistički rječnik: mrežna inačica*.
Pristupljeno 2. veljače 2020. (<https://infoz.ffzg.hr/Stancic/Arhivisticki-rjecnik/>).
265. Mihaljević, Josip. 2019b. Hrvatski mrežni rječnik – Mrežnik (prva demoinačica). *GitLab*.
Pristupljeno 28. svibnja 2019. (<https://borna12.gitlab.io/mreznik/>).
266. Mihaljević, Josip. 2019c. Igra iz drveća. *GitLab*. Pristupljeno 21. svibnja 2020.
(<https://borna12.gitlab.io/igre-mreznik/drvece/>).
267. Mihaljević, Josip. 2019d. Igra iz voća i povrća. *GitLab*. Pristupljeno 21. svibnja 2020.
(https://borna12.gitlab.io/igre-mreznik/voce_povrce/).
268. Mihaljević, Josip. 2019e. Kviz prepoznavanja cvijeća. *GitLab*. Pristupljeno 21. svibnja
2020. (<https://borna12.gitlab.io/igre-mreznik/kviz-cvijece/>).
269. Mihaljević, Josip. 2019f. Makro koda za pročišćavanje tekstova. *Google Drive*.
Pristupljeno 1. veljače 2020. (<https://bit.ly/39uqp1U>).
270. Mihaljević, Josip. 2019g. Nauči slova znakovnoga jezika – Institut za hrvatski jezik i
jezikoslovlje. *Institut za hrvatski jezik i jezikoslovlje*. Pristupljeno 21. svibnja 2020.
(<http://ihjj.hr/clanak/nauci-slova-znakovnoga-jezika/7386/>).
271. Mihaljević, Josip. 2019h. Obrazovne igre. *Staroslavenski institut*. Pristupljeno 22. svibnja
2020. (https://www.stin.hr/hr/category/obrazovne_igre/29).
272. Mihaljević, Josip. 2019i. Planeti sunčeva sustava. *GitLab*. Pristupljeno 21. svibnja 2020.
(<https://borna12.gitlab.io/igre-mreznik/planeti/>).
273. Mihaljević, Josip. 2019j. Prepoznaj brajicu. *Institut za hrvatski jezik i jezikoslovlje*.
Pristupljeno 21. svibnja 2020. (<http://ihjj.hr/brajica/>).
274. Mihaljević, Josip. 2019k. Python skripte za pročišćavanje tekst i prebacivanje u format
.txt. *GitLab*. Pristupljeno 1. veljače 2020. (<https://borna12.gitlab.io/igre-mreznik/kod%20za%20jenu/prevarac/word%20to%20txt.py>).
275. Mihaljević, Josip. 2019l. Tetris za riječi. *GitLab*. Pristupljeno 21. svibnja 2020.
(<https://borna12.gitlab.io/igre-mreznik/lettris-master/>).
276. Mihaljević, Josip. 2019m. Volim glagoljicu. *Hrvatski u školi*. Pristupljeno 18. siječnja
2020. (<http://hrvatski.hr/volim-glagoljicu/>).
277. Mihaljević, Josip. 2019n. Zadatci za državnu maturu. *Jezične igre*. Pristupljeno 7. siječnja
2020. (<https://jezicneigre.com/zadatci-za-drzavnu-maturu/>).
278. Mihaljević, Josip. 2019o. Zadatci za državnu maturu. *Matura.hr*. Pristupljeno 16. ožujka
2020. (<http://matura.ihjj.hr/kviz/>).
279. Mihaljević, Josip. 2019p. Znam glagoljicu. Pristupljeno 15. travnja 2020.
(<http://hrvatski.hr/games/kviz-glagoljica/>).

280. Mihaljević, Josip. 2020b. Dijelovi automobila. *Croaticum – igre*. Pristupljeno 6. travnja 2020. (<https://borna12.github.io/croaticum/dijelovi-automobila.html>).
281. Mihaljević, Josip. 2020c. Dopuni tekst idućim riječima. *GitHub*. Pristupljeno 23. svibnja 2020. (<https://borna12.github.io/croaticum/dovlacenje/index.html>).
282. Mihaljević, Josip. 2020d. Igra nadopunjavanja – dativ pridjeva i imenica. *Croaticum – igre*. Pristupljeno 18. travnja 2020. (<https://borna12.github.io/croaticum/nadopunjavanje/index.html>).
283. Mihaljević, Josip. 2020e. Križaljka o prometnim vozilima. *Croaticum – igre*. Pristupljeno 18. travnja 2020. (<https://borna12.github.io/croaticum/krizaljka/index.html>).
284. Mihaljević, Josip. 2020f. Kviz – značenje glagola. *Croaticum – igre*. Pristupljeno 23. travnja 2020. (<https://borna12.github.io/croaticum/kviz-glagoli/index.html>).
285. Mihaljević, Josip. 2020g. Kviz dijelovi automobila. *Croaticum – igre*. Pristupljeno 23. travnja 2020. (<https://borna12.github.io/croaticum/kviz-dijelovi-auta/index.html>).
286. Mihaljević, Josip. 2020h. Kviz razumijevanja teksta. *Croaticum – igre*. Pristupljeno 17. travnja 2020. (<https://borna12.github.io/croaticum/kviz-razumijevanje/index.html>).
287. Mihaljević, Josip. 2020i. Odaberi ispravan glagol. *Croaticum – igre*. Pristupljeno 23. travnja 2020. (<https://borna12.github.io/croaticum/glagoli-dovlacenje/index.html>).
288. Mihaljević, Josip. 2020j. Pamtilica za prometna vozila. *Pamtilica za prometna vozila (Croaticum)*. Pristupljeno 7. travnja 2020. (<https://borna12.github.io/croaticum/pamtilica-prjevozna-sredstva/index.html>).
289. Mihaljević, Josip. 2020k. Portal suvremenih hrvatskih osobnih imena. *GitLab*. Pristupljeno 15. siječnja 2020. (https://borna12.gitlab.io/plain-html/imena_rjecnik/).
290. Mihaljević, Josip. 2020l. Rječotris. *GitLab*. Pristupljeno 7. travnja 2020. (<https://borna12.gitlab.io/igre-mreznik/lettris-master/>).
291. Mihaljević, Josip. 2020m. Slagalica Bašćanska ploča. *JEZIK.HRvatski*. Pristupljeno 22. svibnja 2020. (<http://jezik.hr/bascanska-slagalica.html>).
292. Mihaljević, Josip. 2020n. Slovotris. *GitLab*. Pristupljeno 21. svibnja 2020. (<https://borna12.gitlab.io/igre-mreznik/slovotris/>).
293. Mihaljević, Josip. 2020o. Transport i komunikacija. *Croaticum – igre*. Pristupljeno 17. travnja 2020. (<https://borna12.github.io/croaticum/>).
294. Mihaljević, Josip. 2020p. Transport i komunikacija. *Croaticum – igre*. Pristupljeno 14. travnja 2020. (<https://borna12.github.io/croaticum/>).
295. Mihaljević, Josip. 2020q. Upiši ispravan oblik glagola. *Upiši ispravan oblik glagola (Croaticum)*. Pristupljeno 7. travnja 2020.

- (<https://bornal2.github.io/croaticum/nadopunjavanje-glagoli/index.html>).
296. Mihaljević, Josip. 2020r. Završavanje frazema. *GitLab*. Pristupljeno 28. siječnja 2020. (<https://bornal2.gitlab.io/igre-mreznik/crowdsourcing/>).
297. Mihaljević, Josip. 2021. *Postavi naglaske na slova*. Pristupljeno 17. ožujka 2021. (https://bornal2.github.io/mreznik_igre/odrasli/naglasci/).
298. Mihaljević, Josip; Lazić, Daria. 2019a. Kviz česte jezične pogreške. *GitLab*. Pristupljeno 15. travnja 2020. (<https://bornal2.gitlab.io/igre-mreznik/kviz-ceste-pogreske/index.html>).
299. Mihaljević, Josip; Lazić, Daria. 2019b. Upisivanje nastavaka za glagole. *Upisivanje nastavaka za glagole*. Pristupljeno 7. travnja 2020. (<https://bornal2.gitlab.io/igre-mreznik/kviz-mijesani/>).
300. Mihaljević, Josip; Matijević, Maja. 2019a. Nauči hrvatsku abecedu! *Naučite hrvatski*. Pristupljeno 9. travnja 2020. (https://bornal2.gitlab.io/igre-mreznik/sadrzaji_za_strance/).
301. Mihaljević, Josip; Matijević, Maja. 2019b. Sadržaj za učenje hrvatskoga jezika. *Nauči hrvatsku abecedu!* Pristupljeno 9. travnja 2020. (https://bornal2.gitlab.io/igre-mreznik/sadrzaji_za_strance/).
302. Mihaljević, Milica; Mihaljević, Josip; Marković, Mario. 2020. Hrvatsko jezikoslovno nazivlje – Jena korpus (veljača 2020.). *JENA*. Pristupljeno 8. rujna 2020. (<http://ihjj.hr/jena/wp-content/uploads/2020/03/Korpus-Jene.pdf>).
303. Morphy! *App Store*. 2015. Pristupljeno 15. veljače 2020. (<https://apps.apple.com/us/app/morphy/id1033580915?ls=1>).
304. Muško i žensko u hrvatskome jeziku. 2017. *Institut za hrvatski jezik i jezikoslovlje*. Pristupljeno 1. listopada 2020. (<http://ihjj.hr/projekt/musko-i-zensko-u-hrvatskome-jeziku/72/>).
305. NASA Science for Kids. 2019. *NASA Space Place*. Pristupljeno 19. prosinca 2019. (<https://spaceplace.nasa.gov/menu/play/>).
306. Nielsen, Jakob. 2012. Best Application Designs. *Nielsen Norman Group*. Pristupljeno 6. ožujka 2020. (<https://www.nngroup.com/articles/best-application-designs/>).
307. Nike Run Club. 2018. *App Store*. Pristupljeno 27. studenoga 2019. (<https://apps.apple.com/app/nike-run-club/id387771637>).
308. NooJ. 2020. *NooJ association*. Pristupljeno 16. ožujka 2021. (<http://www.nooj-association.org/>).
309. NoSketch Engine. 2017. *CLARIN.SI*. Pristupljeno 28. svibnja 2019.

- (<https://www.clarin.si/noske/>).
310. Objectives. 2018. *ELEXIS – European Lexicographic Infrastructure*. Pristupljeno 24. siječnja 2020. (<https://elex.is/objectives/>).
 311. Online English Turkish and Multilingual Dictionary. 2006. *Sesli Sözlük*. Pristupljeno 21. veljače 2020. (<https://www.seslisozluk.net/en/>).
 312. Open source & professional software for data science teams. 2011. *RStudio*. Pristupljeno 27. lipnja 2020. (<https://rstudio.com/>).
 313. Optical Character Recognition (OCR). 2017. *Techopedia*. Pristupljeno 9. rujna 2020. (<https://www.techopedia.com/definition/31623/optical-character-recognition-ocr>).
 314. Osypenko, Anastasia. 2019. Fitness Gamification in Mobile Apps: Using Game-Like Components to Boost Motivation. *Madappgang*. Pristupljeno 24. studenoga 2019. (<https://madappgang.com/blog/fitness-gamification-examples-make-your-app-fun-and-engaging>).
 315. Partridge, Matthew. 2015. 22 May 1980: Pac-Man hits the arcades. *MoneyWeek*. Pristupljeno 18. siječnja 2020. (<https://moneyweek.com/392564/22-may-1980-pac-man-hits-the-arcades>).
 316. Pedagoške djelatnosti – igre. 2017. *Gradski muzej Karlovac*. Pristupljeno 6. ožujka 2020. (<http://www.gmk.hr/Aktivnosti/Pedago%c5%a1ka%20djelatnost/Igre>).
 317. Pelling, Nick. 2011. The (short) prehistory of gamification.... *Funding Startups (& other impossibilities)*. Pristupljeno 11. studenoga 2019. (<https://nanodome.wordpress.com/2011/08/09/the-short-prehistory-of-gamification/>).
 318. Perez, Sarah. 2016. Pokémon GO becomes the fastest game to ever hit \$500 million in revenue. *TechCrunch*. Pristupljeno 3. siječnja 2020. (<https://techcrunch.com/2016/09/08/pokemon-go-becomes-the-fastest-game-to-ever-hit-500-million-in-revenue/?guccounter=1>).
 319. Perez, Sarah. 2019. 'Harry Potter: Wizards Unite' reaches 400K downloads, \$300K in consumer spend in UK and US. *TechCrunch*. Pristupljeno 29. studenoga 2019. (<https://techcrunch.com/2019/06/21/harry-potter-wizards-unite-reaches-400k-downloads-300k-in-consumer-spend-in-u-k-and-u-s/>).
 320. Petterson, Frode; Marstrander, Thomas; Jørgensen, Pål; Griff With, Svein-Tore. 2020. Moodle plugins directory: Interactive Content. *H5P*. Pristupljeno 31. ožujka 2020. (https://moodle.org/plugins/mod_hvp).
 321. Pilot Pals. 2014. *App Store*. Pristupljeno 15. veljače 2020. (<https://apps.apple.com/us/app/pilot-pals/id920173926?ls=1>).

322. PLATFORM GAME (noun) definition and synonyms. 2010. *Macmillan Dictionary*.
Pristupljeno 19. prosinca 2019.
(<https://www.macmillandictionary.com/dictionary/british/platform-game>).
323. Play Fun Games for Kids. 2019. *Sesame Street*. Pristupljeno 8. siječnja 2020.
(<https://www.sesamestreet.org/games>).
324. Početna – Hrvatski mrežni rječnik. 2018. *Hrvatski mrežni rječnik – Mrežnik*. Pristupljeno 17. siječnja 2020. (<http://ihjj.hr/mreznik/>).
325. Pojmovnik poštanske terminologije i usluga. 2012. *Hrvatska pošta*. Pristupljeno 28. ožujka 2019. (<https://www.posta.hr/pojmovnik-272/272>).
326. Pojmovnik. 2007. *agencija za znanost i visoko obrazovanje*. Pristupljeno 23. prosinca 2019. (<https://www.azvo.hr/hr/pojmovnik>).
327. Pojmovnik. 2008. *Meteo-info.hr*. Pristupljeno 28. ožujka 2019. (<http://blog.meteo-info.hr/pojmovnik/>).
328. Pojmovnik. 2012. *Hrvatski restauratorski zavod*. Pristupljeno 28. ožujka 2019.
(<http://www.h-r-z.hr/index.php/pojmovnik>).
329. Pojmovnik. 2017. *Medijska pismenost*. Pristupljeno 29. travnja 2019.
(<https://www.medijskapismenost.hr/pojmovnik/>).
330. Pokemon GO for iPhone/iPad Reviews. 2016. *Metacritic*. Pristupljeno 27. studenoga 2019. (<https://www.metacritic.com/game/ios/pokemon-go>).
331. Pokémon GO. 2016. *Pokémon GO*. Pristupljeno 27. studenoga 2019.
(<https://www.pokemongo.com/en-us/>).
332. Pokémon. 2019. *Wikipedia*. Pristupljeno 29. studenoga 2019.
(<https://en.wikipedia.org/wiki/Pok%C3%A9mon>).
333. poligon frekvencija. 2011. *Struna: Hrvatsko strukovno nazivlje*. Pristupljeno 18. lipnja 2020. (<http://struna.ihjj.hr/naziv/poligon-frekvencija/33291/>).
334. Pravopisni kviz. 2016. *Hrvatski u školi*. Pristupljeno 11. siječnja 2020.
(<http://hrvatski.hr/igra/9/>).
335. Prirodoslovni muzej Rijeka. 2005. *Prirodoslovni muzej Rijeka*. Pristupljeno 3. lipnja 2020.
(<https://www.prirodoslovni.com/hr/homepage.html>).
336. Prvi školski rječnik hrvatskoga jezika. 2015. *Institut za hrvatski jezik i jezikoslovlje*.
Pristupljeno 29. studenoga 2019. (<http://knjige.ihjj.hr/knjiga/prvi-skolski-rjecnik-hrvatskoga-jezika/201/>).
337. Publii – Open-Source CMS for Static Site. 2018. *Publii*. Pristupljeno 10. travnja 2020.
(<https://getpublii.com/>).

338. PUMATRAC – Fitness Training, Workouts & Running. 2019. *Google Play*. Pristupljeno 23. studenoga 2019. (https://play.google.com/store/apps/details?id=com.pumapumatrac&hl=en_US).
339. Python. 2014. *Python.org*. Pristupljeno 16. ožujka 2021. (<https://www.python.org/>).
340. Quizzes on Everything After Z. 2019. *Dictionary.com*. Pristupljeno 7. veljače 2020. (<https://www.dictionary.com/e/c/fun/quizzes/>).
341. R., Ivan. 2016. Croats developed a new game! Meet flappy glagoljica!. *Slavorum*. Pristupljeno 28. svibnja 2020. (<https://www.slavorum.org/croats-developed-a-new-game-meet-flappy-glagoljica/>).
342. Radionica sa studentima Croaticuma Filozofskoga fakulteta Sveučilišta u Zagrebu. 2018. *Hrvatski mrežni rječnik – Mrežnik*. Pristupljeno 15. travnja 2020. (<http://ihjj.hr/mreznik/page/usavrsavanje-i-diseminacija-2018/27>).
343. Radovi – Hrvatski mrežni rječnik. 2017. *Mrežnik*. Pristupljeno 19. siječnja 2020. (<http://ihjj.hr/mreznik/page/radovi/5/>).
344. Razredna nastava – virtualne učionice 2018./19. 2019. *Ministarstvo znanosti i obrazovanja*. Pristupljeno 26. studenoga 2019. (<https://skolazazivot.hr/razredna-nastava-virtualna-ucionica-2018-19/>).
345. Regoniel, Patrick. 2015. Conceptual Framework: A Step-by-Step Guide on How to Make One. *SimplyEducate.Me*. Pristupljeno 12. veljače 2019. (<https://simplyeducate.me/2015/01/05/conceptual-framework-guide/>).
346. Repozitorij metafora hrvatskoga jezika. 2015. *MetaNet.HR*. Pristupljeno 28. svibnja 2029. (<http://ihjj.hr/metafore/>).
347. Rhiannon, Williams. 2014. What is Flappy Bird? The game taking the App Store by storm. *Telegraph*. Pristupljeno 27. siječnja 2020. (<https://www.telegraph.co.uk/technology/news/10604366/What-is-Flappy-Bird-The-game-taking-the-App-Store-by-storm.html>).
348. Richardson, Leonard. 2015. Beautiful Soup Documentation. *Crummy*. Pristupljeno 7. veljače 2020. (<https://www.crummy.com/software/BeautifulSoup/bs4/doc/>).
349. Rochtchina, Julia. 2006. Learn Russian Online: Self study guide for Russian language learners. *Russian For Everyone*. Pristupljeno 14. travnja 2020. (<http://www.russianforeveryone.com/>).
350. Roman Numeral Challenge. 2006. *FactMonster*. Pristupljeno 17. veljače 2020. (<https://www.factmonster.com/math/roman>).
351. Rouse, Margaret. 2016. What is version control?. *WhatIs.com*. Pristupljeno 2. travnja

2020. (<https://whatis.techtarget.com/definition/version-control>).
352. Rummage Documentation. 2019. *Rummage*. Pristupljeno 21. siječnja 2020. (<https://facelessuser.github.io/Rummage/>).
353. Rychlý, Pavel. 2002. Bonito. *Centrum zpracování přirozeného jazyka*. Pristupljeno 28. siječnja 2020. (<https://nlp.fi.muni.cz/projects/bonito/>).
354. Sanders, Jessica. 2015. By the Numbers: 10 Stats on the Growth of Gamification. *Games and Learning*. Pristupljeno 14. travnja 2020. (<https://www.gamesandlearning.org/author/jessica-sanders/>).
355. Sangati, Federico. 2020. Plagio. *GitLab*. Pristupljeno 13. siječnja 2020. (<https://gitlab.com/kercos/plagio>).
356. Sangati, Federico; Monti, Johanna. 2020. PLAGIO: a multiplayer game to promote creative writing and crowdsource linguistic resources. *Twitter*. Pristupljeno 13. siječnja 2020. (<https://twitter.com/NlpUnior/status/1194935158509621248>).
357. Sauro, Jeff. 2014. What Does Statistically Significant Mean?. *MeasuringU*. Pristupljeno 4. svibnja 2020. (<https://measuringu.com/statistically-significant/>).
358. Savjeti. 2019. *Hrvatski u školi*. Pristupljeno 19. siječnja 2020. (<http://hrvatski.hr/frazemi/>).
359. Scholarpedia: the peer-reviewed open-access. 2016. *Scholarpedia*. Pristupljeno 13. veljače 2020. (http://www.scholarpedia.org/article/Main_Page).
360. Schwartz, Terri. 2016. Pokemon Go Is Secretly the Best Exercise App Out There. *IGN*. Pristupljeno 27. studenoga 2019. (<https://au.ign.com/articles/2016/07/09/pokemon-go-is-secretly-the-best-exercise-app-out-there>).
361. Science Games for Kids: OLogy. 2016. *American Museum of Natural History*. Pristupljeno 6. ožujka 2020. (<https://www.amnh.org/explore/ology/games>).
362. Scrabble Game. 2014. *Hasbro*. Pristupljeno 29. siječnja 2020. (<https://scrabble.hasbro.com/en-us/product/scrabble-game:FA04DD51-5056-9047-F5CD-53F87A967AC6>).
363. Scrabble Word Finder – Scrabble Cheat. 2018. *YourDictionary*. Pristupljeno 7. veljače 2020. (<https://wordfinder.yourdictionary.com/>).
364. Search corpus. 2013. *Hrvatski nacionalni korpus*. Pristupljeno 28. siječnja 2020. (http://filip.ffzg.hr/cgi-bin/run.cgi/first_form).
365. Search Signs. 2018. *Signbank*. Pristupljeno 2. veljače 2020. (https://signbank.science.ru.nl/signs/show_all/).
366. Sejda helps with your PDF tasks. 2018. *Sejda*. Pristupljeno 1. veljače 2020. (<https://www.sejda.com/>).

367. Shapiro-Wilkov W test. 2011. *Struna: Hrvatsko strukovno nazivlje*. Pristupljeno 17. lipnja 2020. (<http://struna.ihjj.hr/naziv/shapiro-wilkov-w-test/31012/>).
368. SignWiki. 2013. *Bólkur: Børn*. Pristupljeno 7. veljače 2020. (<https://fo.signwiki.org/index.php/B%C3%B3lkur:B%C3%B8rn>).
369. Simya Solutions Ltd. 2019a. Jednostavno naučite hrvatski. *Google Play*. Pristupljeno 9. svibnja 2020. (<https://play.google.com/store/apps/details?id=simply.learn.croatian&hl=hr>).
370. Simya Solutions Ltd. 2019b. Learn Croatian Language with Master Ling. *Google Play*. Pristupljeno 9. svibnja 2020. (<https://play.google.com/store/apps/details?id=com.simyasolutions.ling.hr&hl=hr>).
371. Školski rječnik hrvatskoga jezika. 2019. *rjecnik.hr*. Pristupljeno 28. studenoga 2019. (<http://rjecnik.hr/>).
372. slavenski jezici. 2013. *Hrvatska enciklopedija*. Pristupljeno 20. travnja 2020. (<https://www.enciklopedija.hr/natuknica.aspx?ID=56592>).
373. Sleep Card Game. 2006. *Sleep for Kids – Teaching Kids the Importance of Sleep*. Pristupljeno 15. veljače 2020. (<http://www.sleepforkids.org/html/cards.html>).
374. SM Diccionarios. 2020. *Diccionario Clave*. Pristupljeno 7. veljače 2020. (<http://clave.smdiccionarios.com/app.php>).
375. Smith, Craig. 2019. 17 Amazing Duolingo Facts and Statistics (2019) | By the Numbers. *DMR – Business Statistics*. Pristupljeno 25. studenoga 2019. (<https://madappgang.com/blog/fitness-gamification-examples-make-your-app-fun-and-engaging>).
376. Snooze Clues. 2006. *Sleep for Kids – Teaching Kids the Importance of Sleep*. Pristupljeno 15. veljače 2020. (<http://www.sleepforkids.org/html/clues.html>).
377. Socrative. 2014. *Socrative*. Pristupljeno 20. travnja 2020. (<https://socrative.com/>).
378. Soma, Jonathan. 2019. Tabletop.js gives spreadsheets legs. *GitHub*. Pristupljeno 7. travnja 2020. (<https://github.com/jsoma/tabletop>).
379. Soundcite. 2013. *Knight Lab Projects*. Pristupljeno 29. travnja 2020. (<https://soundcite.knightlab.com/>).
380. Spiele : Begriffe zuordnen!. 2020. *Bildwörterbuch*. Pristupljeno 7. veljače 2020. (http://www.bildwoerterbuch.com/static/all/spiele_zuordnen).
381. SPSS Software. 2010. *IBM*. Pristupljeno 3. svibnja 2020. (<https://www.ibm.com/analytics/spss-statistics-software>).
382. Stinging Insect Matching Game. 2011. *AAAAI*. Pristupljeno 15. veljače 2020.

- (<https://www.aaaai.org/conditions-and-treatments/just-for-kids/stinging-insect-matching-game>).
383. Što je Croaticum. 2020. *Croaticum*. Pristupljeno 14. travnja 2020. (https://croaticum.ffzg.unizg.hr/?page_id=4676&lang=hr).
384. Stories – Duolingo. 2019. *Duolingo*. Pristupljeno 25. studenoga 2019. (<https://stories.duolingo.com/>).
385. Storymaker. 2019. *Carnegie Library of Pittsburgh*. Pristupljeno 12. kolovoza 2019. (<https://www.carnegielibrary.org/storymaker/>).
386. Studie Winkler Prins. 2010. *Winkler Prins*. Pristupljeno 14. veljače 2020.t. (<http://www.winklerprins.com/>).
387. Svijet rječnika. 2016. *Rjecnici.hr*. Pristupljeno 19. veljače 2020. (<https://www.rjecnici.hr/>).
388. SweetAlert2 – a beautiful, responsive, customizable and accessible (WAI-ARIA) replacement for JavaScript’s popup boxes. 2018. *SweetAlert2*. Pristupljeno 16. lipnja 2019. (<https://sweetalert2.github.io/>).
389. SweetAlert2 – a beautiful, responsive, customizable and accessible (WAI-ARIA) replacement for JavaScript’s popup boxes. 2018. *GitHub*. Pristupljeno 29. travnja 2020. (<https://sweetalert2.github.io/>).
390. Taylor, Jeremy. 2010. Within-Subject and Between-Subject Effects: Wanting Ice Cream Today, Tomorrow, and The Next Day.... *Statistics Blog – Stats Make Me Cry*. Pristupljeno 12. svibnja 2020. (<http://jeremyjaytaylor.squarespace.com/smmctheblog/within-subject-and-between-subject-effects-wanting-ice-cream.html>).
391. Teens. 2015. *Moncton Public Library*. Pristupljeno 18. prosinca 2019. (<https://monctonpubliclibrary.ca/teens/>).
392. Telegram Messenger. 2020. *Telegram*. Pristupljeno 18. siječnja 2020. (<https://telegram.org/>).
393. The developer cloud. 2019. *DigitalOcean*. Pristupljeno 30. siječnja 2020. (<https://www.digitalocean.com/>).
394. The Food Detectives Fight BAC!. 2006. *Food Detectives*. Pristupljeno 15. veljače 2020. (<https://www.fooddetectives.com/>).
395. The Game of Lost Words. 2020. *Bisame*. Pristupljeno 6. veljače 2020. (<https://bisame.paris-sorbonne.fr/lost-words/index.html>).
396. The Git solution for professional teams. 2008. *Bitbucket*. Pristupljeno 2. travnja 2020.

- (<https://bitbucket.org/>).
397. The Most Trusted Place for Answering Life's Questions. 2020. *Answers*. Pristupljeno 13. veljače 2020. (<https://www.answers.com/>).
398. The National Archives Learning Curve. 2010. *The National Archives*. Pristupljeno 6. ožujka 2020. (<https://www.nationalarchives.gov.uk/education/focuson/domesday/activities/quiz.htm>).
399. The Wiki Game!. 2013. *App Store*. Pristupljeno 16. veljače 2020. (<https://apps.apple.com/us/app/the-wiki-game-a-wikipedia-game-of-exploration/id459318432>).
400. The Wikipedia Adventure. 2017. *Wikipedia*. Pristupljeno 16. veljače 2020. (https://en.wikipedia.org/wiki/Wikipedia:The_Wikipedia_Adventure).
401. The world's leading software development platform GitHub. 2008. *GitHub*. Pristupljeno 2. travnja 2020. (<https://github.com/>).
402. Timeline definition and meaning. 2020. Collins Dictionary. Pristupljeno 19. ožujka 2020. (<https://www.collinsdictionary.com/dictionary/english/timeline>).
403. Total Darkness. 2018. *Science Museum UK*. Pristupljeno 6. ožujka 2020. (<https://totaldarkness.sciencemuseum.org.uk/>).
404. trending on Google. 2006. *Google trends*. Pristupljeno 18. siječnja 2020. (<https://trends.google.com/trends/?geo=US>).
405. Trivia & Word. 2020. *Facebook*. Pristupljeno 21. travnja 2020. (<https://www.facebook.com/games/instantgames/?category=420>).
406. TshwaneDJe Software: TLex Lexicography, Terminology and Corpus Software. 2018. *TshwaneDJe*. Pristupljeno 28. studenoga 2019. (<https://tshwanedje.com/tshwanelex/>).
407. UMANJENICE I UVEĆANICE – ponavljanje (3.r.). 2017. *LearningApps*. Pristupljeno 24. svibnja 2020. (<https://learningapps.org/view3291524>).
408. Unity Real-Time Development Platform. 2020. *Unity*. Pristupljeno 15. veljače 2020. (<https://unity.com/>).
409. Usavršavanja i diseminacija. 2019. *Hrvatski mrežni rječnik*. Pristupljeno 21. siječnja 2020. (<http://ihjj.hr/mreznik/page/usavrsavanje-i-diseminacija-2019/26/>).
410. User Recording, Heatmaps and Analytics for Websites and Mobile Apps. 2019. *Smartlook*. Pristupljeno 27. svibnja 2020. (<https://www.smartlook.com/>).
411. Van Dale Taaltrainingen. 2020. *Van Dale*. Pristupljeno 2. veljače 2020. (<https://www.vandale.nl/taaltrainingen>).

412. Van Hien, Nguyen. 2018. tummosoft/dicmaker: Tummo Dictionary Maker. *GitHub*.
Pristupljeno 25. svibnja 2019. (<https://github.com/tummosoft/dicmaker>).
413. VAŽNO! Odgodite sve skupove na području Zagrebačke županije. 2020. *Vijesti – Zagrebačka županija*. Pristupljeno 13. ožujka 2020. (<https://www.zagrebacka-zupanija.hr/vijesti/4917/vazno-odgodite-sve-skupove-na-podrucju-zagrebacke->).
414. Video Conferencing, Web Conferencing, Webinars, Screen Sharing. 2006. *Zoom*.
Pristupljeno 17. travnja 2020. (<https://zoom.us/>).
415. Video Games. 2010. *Marathon County Public Library (MCPL)*. Pristupljeno 18. prosinca 2019. (<https://www.mcpl.us/catalogs/video-games>).
416. VRIJEME I KLIMA HRVATSKOG JADRANA – pojmovnik. 2006. *jadran.gfz.hr*.
Pristupljeno 13. veljače 2020. (<http://jadran.gfz.hr/pojmovnik.html>).
417. W. LaMorte, Wayne. 2017. Mann Whitney U Test (Wilcoxon Rank Sum Test). *Boston University School of Public Health*. Pristupljeno 15. lipnja 2020.
(http://sphweb.bumc.bu.edu/otlt/mph-modules/bs/bs704_nonparametric/BS704_Nonparametric4.html).
418. Warren, Tom. 2017. Adobe will finally kill Flash in 2020. *The Verge*. Pristupljeno 15. veljače 2020. (<https://www.theverge.com/2017/7/25/16026236/adobe-flash-end-of-support-2020>).
419. Web Speech API – Web APIs. 2019. *MDN*. Pristupljeno 29. siječnja 2020.
(https://developer.mozilla.org/en-US/docs/Web/API/Web_Speech_API).
420. Web Speech API Demonstration. 2013. *Chrome Browser*. Pristupljeno 13. travnja 2020.
(<https://www.google.com/intl/en/chrome/demos/speech.html>).
421. WebView. 2009. *Android Developers*. Pristupljeno 7. travnja 2020.
(<https://developer.android.com/reference/android/webkit/WebView>).
422. What is a Programming Language?. 2016. *Techopedia*. Pristupljeno 9. travnja 2020.
(<https://www.techopedia.com/definition/24815/programming-language>).
423. What is a Regular Expression?. 2011. *Techopedia*. Pristupljeno 19. siječnja 2020.
(<https://www.techopedia.com/definition/25843/regular-expression>).
424. What is a Static Web Page?. 2009 *Techopedia*. Pristupljeno 10. travnja 2020.
(<https://www.techopedia.com/definition/5399/static-web-page>).
425. What is a Virtual Machine (VM)?. 2011. *Techopedia*. Pristupljeno 1. veljače 2020.
(<https://www.techopedia.com/definition/4805/virtual-machine-vm>).
426. What is a Virtual Tour?. 2015. *Techopedia*. Pristupljeno 6. ožujka 2020.
(<https://www.techopedia.com/definition/4920/virtual-tour>).

427. What is an Electronic Book (E-Book)?. 2016a. *Techopedia*. Pristupljeno 12. kolovoza 2019. (<https://www.techopedia.com/definition/2193/electronic-book>).
428. What is digital watermark?. 2001. *Webopedia*. Pristupljeno 1. travnja 2020. (https://www.webopedia.com/TERM/D/digital_watermark.html).
429. What is Gameplay?. 2016b. *Techopedia*. Pristupljeno 7. rujna 2020. (<https://www.techopedia.com/definition/1911/gameplay>).
430. What is Infotainment?. 2011a. *Techopedia*. Pristupljeno 15. siječnja 2020. (<https://www.techopedia.com/definition/5520/infotainment>).
431. What is JavaScript Object Notation (JSON)?. 2011b. *Techopedia*. Pristupljeno 23. siječnja 2020. (<https://www.techopedia.com/definition/3930/javascript-object-notation-json>).
432. What is Notepad++. 2011. *Notepad++*. Pristupljeno 9. travnja 2020. (<https://notepad-plus-plus.org/downloads/>).
433. What is Open Database Connectivity (ODBC)?. 2011c. *Techopedia*. Pristupljeno 15. siječnja 2020. (<https://www.techopedia.com/definition/4517/open-database-connectivity-odbc>).
434. What is Role-Playing Game (RPG)?. 2011d. *Techopedia*. Pristupljeno 17. rujna 2019. (<https://www.techopedia.com/definition/27052/role-playing-game-rpg>).
435. Wikipedia Game – Explore Wikipedia!. 2018. *The Wiki Game*. Pristupljeno 16. veljače 2020. (<https://www.thewikigame.com/group>).
436. Wikipedia games. 2014. *Wikipedia*. Pristupljeno 16. veljače 2020.w. (https://en.wikipedia.org/wiki/Wikipedia:Wikipedia_games).
437. Wikipedia:Multilingual statistics. 2017. *Wikipedia*. Pristupljeno 21. veljače 2020. (https://en.wikipedia.org/wiki/Wikipedia:Multilingual_statistics).
438. WikiRace. 2015. *WikiRace*. Pristupljeno 16. veljače 2020. (<http://2pages.net/wikirace.php>).
439. Wiktionary. 2008. *Wiktionary: The free dictionary*. Pristupljeno 13. veljače 2020. (<https://www.wiktionary.org/>).
440. wilcox.test function. 2016. *R Documentation*. Pristupljeno 19. lipnja 2020. (<https://www.rdocumentation.org/packages/stats/versions/3.6.2/topics/wilcox.test>).
441. Wiley, Nate. 2014. Memory Game. *CodePen*. Pristupljeno 7. travnja 2020. (<https://codepen.io/natewiley/pen/HBrbL>).
442. Will, Wright. 2020. *MasterClass*. Pristupljeno 10. travnja 2020. (<https://www.masterclass.com/articles/how-to-make-a-video-game#how-to-develop-a-video-game>)

443. Word Games & Quizzes. 2020. *Merriam-Webster*. Pristupljeno 2. veljače 2020. (<https://www.merriam-webster.com/word-games>).
444. Word mill. 2013. *dexonline*. Pristupljeno 29. travnja 2019. (<https://dexonline.ro/moara>).
445. Word Roundup. 2020. *Merriam-Webster*. Pristupljeno 10. veljače 2020. (<https://www.merriam-webster.com/word-games/word-roundup>).
446. Wordia. 2008. *Crunchbase*. Pristupljeno 28. ožujka 2019. (<https://www.crunchbase.com/organization/wordia#section-overview>).
447. Wordrobe. 2018. *Wordrobe*. Pristupljeno 24. siječnja 2020. (<http://wordrobe.housing.rug.nl/Wordrobe/public/HomePage.aspx>).
448. Yap, Jaime. 2017. What's a Website Heatmap, Really? *Foreward*. Pristupljeno 27. svibnja 2020. (<https://blog.fullstory.com/what-are-web-heatmaps-how-do-they-work-pros-cons-alternatives/>).
449. Yip, Spencer. 2007. Ubisoft to teach DS owners French and Spanish? *Siliconera*. Pristupljeno 24. prosinca 2019. (<https://www.siliconera.com/ubisoft-to-teach-ds-owners-french-and-spanish/>).
450. Young Children from Birth to 4 years. 2019. *Jacksonville Public Library*. Pristupljeno 20. prosinca 2019. (<https://www.jaxpubliclibrary.org/kids-teens/young-children-birth-4-years>).
451. Z Table and Z score calculation. 2015. *Z Score Table*. Pristupljeno 19. lipnja 2020. (<http://www.z-table.com/>).
452. Zombies, Run!. 2019. *Zombies, Run!* Pristupljeno 27. studenoga 2019. (<https://zombiesrungame.com/>).
453. ZombiLingo. 2017. *ZombiLingo*. Pristupljeno 24. siječnja 2020. (<https://zombilingo.org/>).
454. Учим английский онлайн с Puzzle English: бесплатное изучение английского самостоятельно. 2012. *Puzzle English*. Pristupljeno 21. travnja 2020. (<https://puzzle-english.com/>).
455. 互动百科-百科更权威. 2011. *Baike.com*. Pristupljeno 14. veljače 2020. (<http://www.baike.com/>).
456. 百度百科_全球最大中文百科全书. 2015. *Baidu Baike*. Pristupljeno 15. veljače 2020. (<https://baike.baidu.com/>).

12. PRILOZI

12.1. PRILOG 1 – Rječnici za čije je mrežne sadržaje provjereno imaju li igrifikacijske elemente

Tablica 101. *Prisutnost igrifikacijskih elemenata na mrežnim stranicama rječnika (2019.)*

rječnik	igre	rječnik	igre	rječnik	igre
American Heritage Dictionary of the English Language	ne	e-mahashabdkosh	ne	The Free Dictionary	da
Collins Online Dictionary	da	Geiriadur Prifysgol Cymru	ne	NetLingo	ne
Dictionary.com	da	Plattmakers	ne	Arhivistički rječnik	da
Merriam-Webster	da	Van Dale	da	Multilingual Archival Terminology	ne
Oxford Dictionaries Online	da	William Whitaker's Words	ne	Acronym Finder	ne
Longman Dictionary of Contemporary English	da	Woordenboek der Nederlandsche Taal	ne	Cambridge dictionary	ne
Vocabulary.com	da	Yeminli Sözlük	ne	STANDS4 network	ne
Macmillan English Dictionary	da	Hrvatski jezični portal	ne	InvestorWord	ne
Linguee	ne	Your dictionary	da	LAW.com Dictionary	ne
Madura English-Sinhala Dictionary	ne	CroDict	ne	Merriam-Webster Visual Dictionary	da
Multitran	ne	Struna	ne	Visual Thesaurus	ne
LEO	da	Hrvatski terminološki portal	ne	webopedia	ne
WWWDIC	ne	Geografski rječnik	ne	Word Spy	ne
Reverso	ne	Englesko-hrvatski kemijski rječnik & glosar	da	Veliki rečnik; manje poznatih reči i izraza	ne
Free On-line Dictionary of Computing	ne	Leksikon Poslovnoga dnevnika	ne	Fjalor i gjuhës së sotme shqipe	ne
Logos Dictionary	ne	Google Dictionary	ne	Dictionary of Contemporary Basque	ne
Online Etymology Dictionary	ne	Hrvatski pravopis	ne	DEVRI: Le dictionnaire diachronique du breton	ne
Pseudodictionary	ne	Prehrambeni rječnik	ne	Dictionnaire historique Meurgorf	ne
Urban Dictionary	ne	Leksikoni od Plive (Medicinski rječnik, Reumatološki leksikon, Priručnik bolesti)	ne	BSL Signbank	da
Wordnik	ne	Rječnik filozofskih pojmova	ne	Dictionary of the Bulgarian Language	ne
Academic Dictionary of Lithuanian	ne	Vrijeme i klima hrvatskog Jadrana: pojmovnik	ne	Reference dictionary of the Czech language	ne
Dictionary of the Scots Language	ne			Dictionary of Contemporary Czech	ne
Ekşi Sözlük	ne				

rječnik	igre
Dictionary of Written Czech	ne
The Danish Dictionary	ne
Dictionary of the dialects of Jutland	da
Danish etymological dictionary	ne
Gammeldansk Ordbog	ne
IATE – InterActive Terminology for Europe	ne
English Dialect Dictionary	ne
Dictionary of Old English	ne
Middle English Dictionary	ne
The Historical Thesaurus of English	ne
Lexicons of Early Modern English	ne
The Explanatory Dictionary of Estonian	ne
Sprotin Online dictionaries	da
Dictionary of Contemporary Finnish	ne
Dictionary of Finnish Dialects	ne
Dictionary of Old Literary Finnish	ne
Dictionary of the Frisian language	ne
Am Faclair Beag	ne
An Etymological Dictionary of the Gaelic Language	ne
Dictionary of the Real Academia Galega	ne
Dicionario de dicionarios: Corpus lexicográfico da lingua galega	ne
Dictionary of Standard Modern Greek	ne
LOGEION	ne

rječnik	igre
BrillOnline Dictionaries	ne
Thesaurus Linguae Graecae	ne
NGT Signbank	da
The University of Wales Dictionary of the Welsh Language (GPC)	ne
A Welsh-English / English-Welsh online dictionary	ne
The Welsh Academy English-Welsh Dictionary Online	ne
Online version of Cysgair and the Terriadur Addysg	ne
Welsh-English / English-Welsh Online Dictionary	ne
Welsh National Terminology Portal	ne
Standardized terminology for the field of education	ne
Grand Turkish Dictionary	ne
The Turkish Monolingual Dictionary of "Dil Derneği"	ne
Tureng	ne
Kubbealtı Lugatı	ne
Online English Turkish and Multilingual Dictionary	da
Zargan	ne
The Sabatini Coletti – Dictionary of the Italian Language	ne
Virgilio's Italian Vocabulary Words	ne
Etymological Dictionary of the Italian Language	ne
Svenska Akademiens Ordböcker	ne

rječnik	igre
Dictionary of the Swedish dialects in Finland	ne
Swedish Etymological Dictionary	ne
Vokabular	ne
Diccionario Clave	da
Dictionary of the Royal Spanish Academy	ne
Diccionario del español coloquial	ne
Diccionario informático	ne
Diccionario médico-biológico	ne
Diccionario visual	da
DIRAE	ne
Jamieson's Etymological Dictionary of the Scottish Language Online	ne
The Historical Thesaurus of Scots	ne
Slovarji Inštituta za slovenski jezik Frana Ramovša ZRC SAZU (Fran)	ne
Dictionary of the Slovak Language	ne
Dictionary of the Skolt and Kola Lapp Languages	ne
North Saami dictionary	ne
Dictionary of the Russian Language	ne
Explanatory Dictionary of the Russian Language (Ushakov Dictionary)	ne
Dictionary of the Russian Language (Ozhegov)	ne
Etymological dictionary of the Russian language	ne
Словарь русского языка XI-XVII вв.	ne

rječnik	igre
Romanian Language Dictionaries	da
Online dictionary of Portuguese	ne
Houaiss Dictionary of the Portuguese Language	ne
Dicionário Priberam da Língua Portuguesa	ne
Infopédia Dicionários Porto Editora	da
The Corpus-based Dictionary of Polish Sign Language	ne
Słownik języka polskiego	ne
Great Dictionary of Polish	ne
Grammatical Dictionary of Polish	ne
Electronic Dictionary of the 17th and 18th-century Polish	ne
The Bokmål Dictionary	ne
The Norwegian Academy's Dictionary	ne
Dictionary of Norwegian	ne
Digital Dictionary of the Macedonian language	ne
Luxemburger Wörterbuch	ne
dizionari.lombard	ne
Dictionary of the Lithuanian language	ne
Latvian Literary Language Dictionary	ne

rječnik	igre
Latvian Dictionary	ne
Modern Latvian Dictionary	ne
Latin–Danish Dictionary	ne
Glossarium mediæ et infimæ latinitatis	ne
Dictionary of Medieval Latin from British Sources	ne
Johann Rammingen Neulateinische Wortliste	ne
Dictionary of Medieval Latin in Poland	ne
Online Dictionary of the Karelian Language	ne
Comprehensive Dictionary of Hungary	ne
New English-Irish Dictionary	ne
Pota Focal	ne
eDIL – Electronic Dictionary of the Irish Language	ne
National Terminology Database for Irish	ne
The ISLEX Dictionary	ne
A Dictionary of Modern Icelandic	ne
Snara	ne
The digital dictionary of the German language	ne
Duden Online-Wörterbuch	da
Online-Wortschatz-Informationssystem Deutsch (OWID)	ne

rječnik	igre
Swiss Idiotikon: Swiss German Dictionary	ne
German dictionary by Jacob Grimm and Wilhelm Grimm	ne
CNRTL – Centre National des Ressources Textuelles et Lexicales	ne
Dictionnaire de français Larousse	ne
Trésor de la Langue Française Informatisé	ne
Délégation Générale à la Langue Française et aux Langues de France	ne
Dictionnaire visuel	da
Expressio – Les expressions françaises décortiquées	ne
Glossaire des patois de la Suisse Romande	ne
Lexique de la comptabilité	ne
Lintern@ute – Dictionnaire des noms propres	ne
The Anglo-Norman Dictionary	ne
Dictionnaire Étymologique de l'Ancien Français	ne
Dictionnaire de la langue française, par É. Littré	ne
Bildwörterbuch	da
Wiktionary	ne

12.2. PRILOG 2 – Enciklopedije za čije je mrežne sadržaje provjereno imaju li igrifikacijske elemente

Tablica 102. *Prisutnost igrifikacijskih elemenata na mrežnim stranicama enciklopedija (2019.)*

enciklopedija	igre
Answers.com	ne
Britannica	da
The Catholic Encyclopedia	ne
Columbia Encyclopedia (prikazna kroz FactMonster)	da
Computer Desktop Encyclopedia	ne
Encyclopedia Mythica	ne
Encyclopedia of Life	ne
Encyclopedia of Philosophy	ne
Encyclopedia of Symbols	ne
Encyclopedia Smithsonian	da
How Stuff Works	ne
Medline Medical Encyclopedia	da
Reference.com	ne
Stanford Encyclopedia of Philosophy	ne
Who2	ne
Wikipedia	da
Baidu Baike	da
The Canadian Encyclopedia	ne
Citizendium	ne
Conservapedia	ne
Hrvatska enciklopedija	ne
Den Store Danske Encyklopædi	ne
Digital Universe	ne
EcuRed	ne

enciklopedija	igre
Enciclonet	ne
Encyclopedia.com	ne
Encyclopedia of China	ne
Enciclopedia Italiana di scienze, lettere ed arti	ne
Encyclopedia Sindhiana	ne
Encyclopædia Universalis	ne
Everipedia	ne
Everything2	ne
GNE	ne
Gran Enciclopèdia Catalana	ne
Grand Larousse encyclopédique	ne
Great Medical Encyclopedia	ne
Great Soviet Encyclopedia	ne
Hamichlol	ne
Baike.com	ne
Internetowa encyklopedia PWN	ne
Know Your Meme	ne
Krugosvet	da
Marathi Vishwakosh	ne
Marefa	ne
Mawdoo3	ne
Metapedia	ne
Nationalencyklopedin	da
New World Encyclopedia	ne
Open Site	ne

enciklopedija	igre
Proleksis enciklopedija	ne
Rationalwiki	ne
Sarvavijnanakosam	ne
Scholarpedia	ne
Store norske leksikon	ne
Tamil Encyclopedia	ne
Winkler Prins	ne
World Book Encyclopedia	da
Australian Dictionary of Biography	ne
Croatian Biographical Lexicon	ne
Dictionary of Canadian Biography	ne
Dictionary of Irish	ne

enciklopedija	igre
Architects	
Oxford Dictionary of National Biography	ne
The Encyclopedia of New Zealand	ne
The History of Nordic Women's Literature	ne
Oxford Art Online	ne
The Literary Encyclopedia	ne
SIKART	ne
Leksikon radija i televizije	ne
Encyclopédie Larousse en ligne	da
Le grand dictionnaire terminologique	ne
Doctissimo	ne

12.3. PRILOG 3 – Hrvatski muzeji s interaktivnim sadržajima

Tablica 103. *Interaktivni sadržaji koji se nalaze na stranicama hrvatskih muzeja (2018.)*

	interaktivne galerije	ugrađeni videozapisi i zvučni zapisi	virtualne šetnja prostorom	interaktivne karte	pregled 3D modela	vremenske lente	obrazovne igre
Arheološki muzej Istre	da	da	da	ne	ne	ne	ne
Arheološki muzej Narona	da	ne	ne	ne	ne	ne	ne
Arheološki muzej u Zagrebu	da	ne	ne	ne	da	ne	da
Arheološki muzej Zadar	ne	ne	da	ne	ne	ne	ne
Dubrovački muzeji	da	ne	da	ne	ne	ne	ne
Dvor Trakošćan	da	ne	da	ne	ne	ne	ne
Etnografski muzej	da	da	da	da	ne	ne	da
Etnografski muzej Istre / Museo etnografico dell' Istria	da	ne	ne	ne	ne	ne	ne
Etnografski muzej Split	ne	ne	da	ne	ne	ne	ne
Galerija izvorne umjetnosti Zlatar	da	ne	ne	ne	ne	ne	ne
Galerija Prica	da	ne	ne	ne	ne	ne	ne
Galerija Sikirica	da	ne	ne	ne	ne	ne	ne
Galerija umjetnina	da	ne	ne	ne	ne	ne	ne
Galerija umjetnina grada Slavonskog Broda	da	ne	ne	ne	ne	ne	ne

	interaktivne galerije	ugrađeni videozapisi i zvučni zapisi	virtualne šetnja prostorom	interaktivne karte	pregled 3D modela	vremenske lente	obrazovne igre
Gradska galerija Antun Gojak	da	ne	ne	ne	ne	ne	ne
Gradska galerija Striegl	da	ne	ne	ne	ne	ne	ne
Gradski muzej Bjelovar	da	ne	ne	ne	ne	ne	ne
Gradski muzej Karlovac	da	ne	ne	ne	ne	ne	da
Gradski muzej Korčula	da	ne	ne	ne	ne	ne	ne
Gradski muzej Nova Gradiška	ne	da	ne	ne	ne	ne	ne
Gradski muzej Novalja	da	da	ne	ne	ne	ne	ne
Gradski muzej Požega	da	da	ne	ne	ne	ne	ne
Gradski muzej Varaždin	da	ne	da	ne	da	ne	ne
Gradski muzej Vinkovci	da	ne	ne	ne	ne	ne	ne
Gradski muzej Virovitica	da	da	ne	ne	ne	ne	ne
Gradski muzej Vukovar	da	ne	da	ne	ne	ne	ne
Grafička zbirka Nacionalne i sveučilišne knjižnice	da	ne	ne	ne	ne	ne	ne
Hrvatska akademija znanosti i umjetnosti – Gliptoteka	da	ne	ne	ne	ne	ne	ne
Hrvatska akademija znanosti i umjetnosti Kabinet grafike	da	ne	ne	ne	ne	ne	ne

	interaktivne galerije	ugrađeni videozapisi i zvučni zapisi	virtualne šetnja prostorom	interaktivne karte	pregled 3D modela	vremenske lente	obrazovne igre
Hrvatski muzej naivne umjetnosti	da	da	ne	ne	ne	ne	ne
Hrvatski muzej turizma	da	da	da	da	ne	ne	da
Hrvatski pomorski muzej Split	da	ne	ne	ne	ne	ne	ne
Hrvatski povijesni muzej	da	ne	ne	ne	ne	da	ne
Hrvatski školski muzej	da	ne	ne	ne	ne	ne	ne
Hrvatski željeznički muzej	da	ne	ne	ne	ne	ne	ne
Javna ustanova Galerija Klovićevi dvori	da	ne	ne	ne	ne	ne	ne
Kninski muzej Knin	da	da	ne	ne	ne	ne	ne
Kuća Šenoa	da	da	ne	ne	ne	ne	ne
Lošinjski muzej	da	ne	ne	ne	ne	ne	ne
Moderna galerija	da	ne	ne	ne	ne	ne	ne
Muzej – Museo Lapidarium	da	da	ne	ne	ne	ne	ne
Muzej "Matija Skurjeni"	da	ne	ne	ne	ne	ne	ne
Muzej antičkog stakla u Zadru	da	ne	ne	ne	ne	ne	ne
Muzej Apoksiomena	da	da	ne	ne	ne	ne	ne
Muzej betinske	da	da	ne	ne	ne	ne	ne

	interaktivne galerije	ugrađeni videozapisi i zvučni zapisi	virtualne šetnja prostorom	interaktivne karte	pregled 3D modela	vremenske lente	obrazovne igre
drvene brodogradnje							
Muzej Brodskog Posavlja	da	ne	ne	ne	ne	ne	ne
Muzej Cetinske krajine – Sinj	da	ne	ne	ne	ne	da	ne
Muzej Croata insulanus Grada Preloga	da	ne	ne	ne	ne	ne	ne
Muzej Đakovštine	ne	da	da	da	ne	ne	ne
Muzej grada Crikvenice	da	ne	ne	ne	ne	ne	ne
Muzej Grada Đurđevca	da	ne	ne	ne	ne	ne	ne
Muzej grada Iloka	da	ne	da	ne	ne	ne	ne
Muzej grada Koprivnice	da	da	ne	ne	ne	ne	ne
Muzej grada Pakraca	ne	ne	ne	ne	ne	da	ne
Muzej grada Pazina	da	ne	ne	ne	ne	ne	ne
Muzej grada Rijeke	da	da	ne	ne	ne	ne	ne
Muzej Grada Rovinja – Museo della Citta di Rovinj- Rovigno	da	ne	ne	ne	ne	ne	ne
Muzej grada Splita	da	ne	ne	ne	ne	ne	ne
Muzej grada Šibenika	da	ne	ne	ne	ne	ne	ne
Muzej grada Trogira	da	ne	ne	ne	ne	ne	ne

	interaktivne galerije	ugrađeni videozapisi i zvučni zapisi	virtualne šetnja prostorom	interaktivne karte	pregled 3D modela	vremenske lente	obrazovne igre
Muzej grada Umaga – Museo civico di Umago	da	ne	ne	ne	ne	ne	ne
Muzej grada Zagreba	ne	da	da	da	ne	ne	ne
Muzej hrvatskih arheoloških spomenika – Split	da	ne	ne	ne	ne	ne	ne
Muzej Ivanić-Grada	da	da	ne	ne	ne	ne	ne
Muzej Like Gospić	da	da	da	ne	ne	ne	ne
Muzej Marton	da	ne	ne	ne	ne	ne	ne
Muzej Međimurja Čakovec	da	ne	ne	ne	ne	da	ne
Muzej Moslavine Kutina	ne	ne	ne	ne	ne	ne	ne
Muzej planinarstva	da	ne	ne	ne	ne	ne	ne
Muzej Prigorja	da	ne	ne	ne	ne	ne	ne
Muzej Radboa	da	ne	ne	ne	ne	ne	ne
Muzej Slavonije	da	da	ne	ne	ne	ne	ne
Muzej Staroga Grada	da	da	ne	ne	ne	ne	ne
Muzej suvremene umjetnosti	da	ne	ne	ne	ne	ne	ne
Muzej suvremene umjetnosti Istre/Museo d'Arte Contemporanea dell'Istria	da	da	ne	ne	ne	ne	ne

	interaktivne galerije	ugrađeni videozapisi i zvučni zapisi	virtualne šetnja prostorom	interaktivne karte	pregled 3D modela	vremenske lente	obrazovne igre
Muzej Sveti Ivan Zelina	da	ne	ne	ne	ne	ne	ne
Muzej Turopolja	da	ne	ne	ne	ne	ne	ne
Muzej Valpovštine	da	ne	ne	ne	ne	ne	ne
Muzej vučedolske kulture	da	ne	ne	ne	ne	ne	ne
Muzej za umjetnost i obrt	ne	ne	ne	da	ne	ne	ne
Muzeji Hrvatskog zagorja	da	ne	ne	ne	ne	ne	ne
Muzeji i galerije Konavala	da	da	ne	ne	ne	ne	ne
Muzeji Ivana Meštrovića	da	da	ne	ne	ne	ne	ne
Muzejsko-memorijalni centar Dražen Petrović	da	ne	ne	ne	ne	ne	ne
Narodni muzej Zadar	da	ne	ne	ne	ne	ne	ne
Pomorski i povijesni muzej Hrvatskog primorja Rijeka	da	da	ne	ne	ne	ne	ne
Povijesni i pomorski muzej Istre – Museo storico e navale dell Istria	da	ne	ne	ne	ne	ne	ne
Prirodoslovni muzej Dubrovnik	da	ne	ne	ne	ne	ne	ne

	interaktivne galerije	ugrađeni videozapisi i zvučni zapisi	virtualne šetnja prostorom	interaktivne karte	pregled 3D modela	vremenske lente	obrazovne igre
Prirodoslovni muzej i zoološki vrt	da	ne	ne	da	ne	da	ne
Prirodoslovni muzej Metković	ne	da	ne	ne	ne	ne	ne
Prirodoslovni muzej Rijeka	ne	da	ne	ne	ne	ne	da
Spomen galerija Ivana Meštrovića	da	ne	ne	ne	ne	ne	ne
Tehnički muzej Nikola Tesla	da	da	da	ne	ne	da	ne
Tiflološki muzej	ne	da	ne	ne	ne	ne	ne
Umjetnička galerija Dubrovnik	da	ne	ne	ne	ne	ne	ne
Umjetnički paviljon u Zagrebu	da	da	ne	ne	ne	ne	ne
Zavičajni muzej Biograd na moru	da	da	ne	ne	ne	ne	ne
Zavičajni muzej Našice	da	ne	ne	ne	ne	ne	ne
Zavičajni muzej Ozalj	da	ne	ne	ne	ne	ne	ne
Zavičajni muzej Poreštine – Museo del territorio parentino	da	ne	ne	da	ne	ne	ne
Zavičajni muzej Slatina	da	ne	ne	ne	ne	ne	ne
Zavičajni muzej Stjepana Grubera	da	ne	ne	ne	ne	ne	ne

	interaktivne galerije	ugrađeni videozapisi i zvučni zapisi	virtualne šetnja prostorom	interaktivne karte	pregled 3D modela	vremenske lente	obrazovne igre
Zavičajni muzej Varaždinske Toplice	da	ne	ne	ne	ne	ne	ne
Muzej mimara	da	ne	ne	ne	ne	ne	da
Muzej iluzija Zagreb	da	ne	ne	ne	ne	ne	ne
Muzej iluzija Zadar	da	ne	ne	ne	ne	ne	ne

12.4. PRILOG 4 – Najpopularniji strani muzeji za čije je mrežne sadržaje provjereno imaju li igrifikacijske elemente

Tablica 104. *Popis analiziranih mrežnih stranica najposjećenijih stranih muzeja (2019.)*

muzej	sadržava igre
Louvre	ne
National Museum of China	ne
Metropolitan Museum of Art[b]	ne
Vatican Museums	ne
National Air and Space Museum	ne
Tate Modern	da
British Museum	ne
National Gallery	ne
Natural History Museum	ne
American Museum of Natural History	da
National Museum of Natural History	ne
National Gallery of Art	ne
China Science and Technology Museum	ne
State Hermitage Museum	ne
Zhejiang Museum	ne
Victoria and Albert Museum	ne
Reina Sofía	ne
National Palace Museum[c]	ne
National Museum of American History	ne
Nanjing Museum	ne
Hunan Museum	ne
Centre Pompidou	ne
Shanghai Science and Technology Museum	ne
Gansu Provincial Museum	ne
National Museum of Korea	ne
London Science Museum	ne
Musée d'Orsay	ne
Somerset House	ne
National Museum of Natural Science	ne
Museo del Prado	ne
Moscow Kremlin Museums	ne
Chongqing Museum of Natural History	ne
Mevlana Museum	ne

muzej	sadržava igre
Shaanxi History Museum	ne
Tokyo Metropolitan Art Museum	ne
Chengdu Museum [zh]	ne
Museum of Modern Art	ne
National Art Center	ne
National Museum of History	ne
Royal Museums Greenwich	ne
National Museum of Nature and Science	ne
National Museum of Anthropology	ne
NGV International	ne
China Art Museum	ne
California Science Center	ne
Tokyo National Museum	ne
National Museum of African American History and Culture	ne
Suzhou Museum	ne
Houston Museum of Natural Science	ne
Donald W. Reynolds Center for American Art and Portraiture	ne
China Art Museum	ne
Rijksmuseum	ne
Three Gorges Museum	ne
Cité des Sciences et de l'Industrie	ne
Galleria degli Uffizi	ne
National Museum of Scotland	ne
Russian Museum	ne
Van Gogh Museum	ne
Tretyakov Gallery	ne
Shanghai Museum	ne
Auschwitz-Birkenau Memorial and Museum	ne
National Folk Museum of Korea	ne

12.5. PRILOG 5 – Pregled obrazovnih sadržaja na mrežnim stranicama 21 svjetskog arhiva

Tablica 105. *Obrazovni sadržaji na mrežnim stranicama 21 svjetskog arhiva (Marković i Mihaljević, 193–194: 2018)*

arhiv	obrazovni materijali	radionice	učenje na daljinu	poveznice na druge obrazovne sadržaje	interaktivni sadržaji
Arhiv Bosne i Hercegovine	ne	ne	ne	ne	ne
Državni arhiv Crne Gore	ne	ne	ne	ne	da
Arhiv Srbije	ne	ne	ne	ne	ne
Arhiv Republike Slovenije	ne	da	ne	ne	da
Njemački državni arhiv	ne	da	ne	da	da
Francuski državni arhiv	da	da	ne	da	da
Španjolski državni arhiv	ne	da	ne	ne	da
Ruski državni arhiv	ne	ne	ne	ne	da
Talijanski državni arhiv	ne	ne	ne	ne	da
Nacionalni arhiv UK-a	da	da	da	da	da
Austrijski državni arhiv	ne	ne	ne	ne	ne
Nacionalni arhiv Škotske	da	da	ne	da	da
Nacionalni arhiv Irske	ne	ne	ne	ne	da
Nacionalni arhiv Islanda	ne	da	ne	da	da
Nizozemski državni Arhiv	da	da	da	da	da

arhiv	obrazovni materijali	radionice	učenje na daljinu	poveznice na druge obrazovne sadržaje	interaktivni sadržaji
Nacionalni arhiv SAD-a	da	da	da	da	da
Knjižnica i arhiv Kanade	ne	ne	ne	ne	da
Australski državni arhiv	da	da	da	da	da
Brazilski državni arhiv	ne	da	ne	da	da
Novozelandski državni arhiv	ne	ne	ne	da	da
Japanski državni arhiv	ne	ne	ne	ne	da

12.6. PRILOG 6 – Knjižnice za čije je mrežne sadržaje provjereno imaju li igrifikacijske elemente

Tablica 106. *Popis analiziranih mrežnih stranica knjižnica koje sadržavaju igrifikacijske elemente (2019.)*

knjižnice
<ul style="list-style-type: none">● Bibliotheca Alexandrina, Egypt● Carnegie Library of Pittsburgh, Pittsburgh, Pennsylvania● Cerritos Millennium Library in Cerritos, California, United States● Chicago Public Library, Chicago, Illinois, USA● Cincinnati Public Library, Cincinnati, Ohio, United States● Clinton-Macomb Public Library, Clinton Charter Township, Michigan, United States● Contra Costa County Library, Pleasant Hill, California, United States● Kenton County Public Library, Kentucky● Los Angeles Central Library● Montgomery County Public Libraries, Rockville, Maryland● New Orleans Public Library● Orange County Library System, Orlando, Florida● Park Ridge Public Library, Park Ridge, Illinois● Pikes Peak Library District, Colorado Springs, Colorado● Prince George's County Memorial Library System, Largo, Maryland● St. Louis Public Library, St. Louis, Missouri● San Diego County Library, San Diego, California● San Francisco Public Library, San Francisco, California● San José Public Library, San Jose, California● South San Francisco Public Library● Southfield Public Library, Southfield, Michigan● Winnipeg Public Library, Winnipeg, Manitoba, Canada

Tablica 107. *Popis ostalih analiziranih mrežnih stranica knjižnica koje ne sadržavaju igrifikacijske elemente (2019.)*

knjižnice	knjižnice	knjižnice
<ul style="list-style-type: none"> • Alexandria Library • Advocates Library • Alice Springs Public Library • Allahabad Public Library • Allegheny County Library Association • Bromley House Library • Alice Springs Public Library • Amerika-Gedenkbibliothek • Ann Arbor District Library • Argostoli Public Library • Central Library of Astan Quds Razavi • Australian National University Library • Baltimore County Public Library, Baltimore, Maryland, United States • Barrow-in-Furness Main Public Library, Cumbria, England • Bayerische Staatsbibliothek, Munich, Bavaria, Germany • Beinecke Rare Book and Manuscript Library, New Haven, Connecticut, United States • Beit Ariela, Tel Aviv, Israel • Berlin Art Library (Kunstbibliothek 	<ul style="list-style-type: none"> • Berlin), Berlin, Germany • Berlin Central and Regional Library, Berlin, Germany • Berlin State Library, Berlin, Germany • Bhaikaka Library – Knowledge Resource Centre, Vallabh Vidyanagar, Gujarat-India • Biblioteca Estense, Modena, Italy • Biblioteca Nacional de Chile, Santiago, Chile • Biblioteca Nacional de España, Madrid, Spain • Biblioteca Nacional de Portugal, Lisbon, Portugal • Biblioteca Nazionale Centrale Firenze, Firenze, Italy • Biblioteca Nazionale Centrale Roma, Rome, Italy • Biblioteca Nacional, San Jose, Costa Rica • Biblioteca Pública de Pichilemu, Pichilemu, Chile • Bibliothèque nationale de France, Paris, France • Bibliothèque de l'Arsenal, Paris, France • Birmingham Central Library, England 	<ul style="list-style-type: none"> • Bizzell Memorial Library, University of Oklahoma, Norman, Oklahoma, United States • Bodleian Library, Oxford, England • Boston Public Library, United States • Botanical Research Institute of Texas Library, Fort Worth, Texas, United States • British Library, London, England • British Library of Political and Economic Science, London, England • Brooklyn Public Library, United States • Broward County Library, Fort Lauderdale, Florida • Burton Barr Central Library, Phoenix, Arizona, United States • Cal Poly Pomona University Library at Cal Poly Pomona, United States • Calgary Public Library, Calgary, Alberta, Canada • Cambridge University Library, England • CanadaInstitute for Scientific and Technical Information

knjižnice
(CISTI), Ottawa, Ontario, Canada
• Carolina Rediviva at Uppsala University, Sweden
• Center for Jewish History, Manhattan, United States
• Changhua City Library, Changhua County, Taiwan
• Charles V. Park Library at Central Michigan University, Mount Pleasant, Michigan, United States
• Chetham's Library in Manchester, England
• Chincoteague Island Library, Chincoteague Island, Virginia, United States
• Chongqing Library, Chongqing, China
• City of Playford Library Service in Adelaide, Australia
• Cleveland Public Library, Cleveland, Ohio, United States
• College of DuPage Library, Glen Ellyn, Illinois, United States
• Cologne Public Library, Cologne, Germany
• Columbia Public Library, Columbia, Missouri, United States
• Columbus Metropolitan

knjižnice
Library, Columbus, Ohio, United States
• Connemara Public Library, Chennai, India
• Cory Library for Historical Research, Rhodes University, Grahamstown, South Africa
• County of Los Angeles Public Library, Los Angeles County, California, United States
• Cuyahoga County Public Library, Cleveland, Ohio, United States
• Cosy Nook Library, Bangalore, India
• David Lubin Memorial Library, Rome, Italy
• Detroit Public Library, Detroit, Michigan
• Deutsche Bücherei Leipzig, Leipzig
• District of Columbia Public Library
• Doe Library, University of California Berkeley, Berkeley, California
• Dr. Mahmud Hussain Library, University of Karachi, Karachi, Pakistan
• Drill Hall Library, Chatham, Kent, England
• Duchess Anna Amalia Library, Weimar, Germany

knjižnice
• Edmonton Public Library, Edmonton, Alberta, Canada
• Elyachar Central Library, Haifa, Israel
• Enoch Pratt Free Library, Baltimore, Maryland
• Fairfax County Public Library, Fairfax, Virginia
• Folger Shakespeare Library, Washington, DC
• Francis Skaryna Belarusian Library and Museum, London, United Kingdom
• Frank Melville Jr. Memorial Library, State University of New York at Stony Brook, Stony Brook, New York
• Free Library of Philadelphia, Philadelphia
• German Central Library for the Blind, Leipzig, Germany
• German National Library of Economics, Kiel and Hamburg
• German National Library of Medicine, Cologne and Bonn
• German National Library of Science and Technology, Hanover
• Glasgow University Library, Scotland

knjižnice
• Göttingen State and University Library, Germany
• Grande Bibliothèque du Québec, Montreal, Quebec, Canada
• Guangzhou Library, Guangzhou, China
• Greifswald University Library, Greifswald, Germany
• Halifax Central Library
• Haskell Free Library and Opera House
• Hesburgh Library, Notre Dame, Indiana
• Hessian State Library, Wiesbaden, Germany
• Hershey Public Library, Hershey, Pennsylvania
• Hilandar Research Library, Ohio State University
• Homer Babbidge Library, University of Connecticut, Storrs
• Hong Kong Central Library, Causeway Bay, Hong Kong Island
• Houston Public Library, Houston, Texas
• Huntington Library, San Marino, California
• The International Association of Aquatic and Marine Science Libraries

knjižnice
and Information Centers
• International Library of African Music, Rhodes University, Grahamstown, South Africa
• Jenkins Law Library, Philadelphia
• John Crerar Library
• Jacksonville Public Library
• Kedermister Library
• Koninklijke Bibliotheek, Netherlands
• Leiden University Library, Leiden, Netherlands
• Library of Congress, Washington, D.C.
• Library of the Russian Academy of Sciences
• Library of Universiti Sains Malaysia, Penang, Malaysia
• Lied Library, University of Nevada, Las Vegas
• Linen Hall Library, Belfast
• London Library
• Louisville Free Public Library, Louisville, Kentucky
• Luís Ángel Arango Library, Bogotá, Colombia
• Madan Puraskar Pustakalaya, Nepal
• Makerere University Library, Uganda
• Malcolm A. Love Library (San Diego

knjižnice
State University), San Diego, California
• Malek National Library, Tehran, Iran
• Manchester Central Library, England
• Marathon County Public Library (MCPL), Wausau, Wisconsin
• Mário de Andrade Library in São Paulo
• Mark O. Hatfield Library, at Willamette University
• Marsh's Library in Dublin
• Martynas Mažvydas National Library of Lithuania, Vilnius
• McGill University Library, Montreal
• Merton College Library, at Merton College, Oxford (oldest continually functioning library in the world)
• Miami-Dade Public Library System
• Michigan State University Libraries
• Milli Kütüphane (National Library of Turkey, Ankara)
• Minneapolis Public Library, Minneapolis, Minnesota
• Mitchell Library, Glasgow
• Moncton Public Library, Moncton, New Brunswick

knjižnice
• Moreland City Libraries, City of Moreland, Australia
• Morton Grove Public Library, Morton Grove, Illinois
• Multnomah County Library, Multnomah County, Oregon
• Musical Electronics Library, Auckland, New Zealand
• National Agricultural Library
• National Central Library, Florence
• National Central Library, Rome
• National Diet Library, Tokyo and Kyoto, Japan
• National Library of Armenia, Yerevan
• National Library of Australia, Canberra
• National Library of Canada
• National Library of China, Beijing, China
• National Library of India, Kolkata
• National Library of Iran, Tehran
• National Library of Ireland, Dublin
• National Library of Israel, Jerusalem, Israel
• National Library of Malaysia, Kuala Lumpur
• National Library of Medicine

knjižnice
• National Library of New Zealand, Wellington
• National Library of Pakistan, Islamabad, Pakistan
• National Library of Public Information, Taichung, Taiwan
• National Library of Russia in St Petersburg
• National Library of Scotland, Edinburgh
• National Library of Serbia, Belgrade
• National Library of South Africa, Cape Town and Pretoria
• National Library of Wales, Aberystwyth
• National Library, Singapore
• New York Public Library, New York, New York
• Newberry Library, Chicago, Illinois
• Openbare Bibliotheek Amsterdam, Netherlands
• Oregon State Library, Salem, Oregon
• Ottawa Public Library, Ottawa, Ontario, Canada
• Palm Beach County Library System, West Palm Beach, Florida
• Parker Library, Corpus Christi College, Cambridge

knjižnice
• Peking University Library, Beijing, China
• Pepys Library, Magdalene College, Cambridge
• Perpustakaan Tun Sri Lanang, Universiti Kebangsaan Malaysia, Bangi
• Plainfield Public Library District, Plainfield, Illinois
• Powell Library, University of California Los Angeles, Los Angeles, California
• Pritzker Military Library, Chicago, Illinois
• Public Library of Charlotte and Mecklenburg County
• Quaid-e-Azam Library, Lahore
• Queens Library, New York, New York
• Regenstein Library, University of Chicago, Chicago, Illinois
• Regina Public Library, Regina, Saskatchewan, Canada
• Rhodes University Library, Rhodes University, Grahamstown, South Africa
• Rock Island Public Library, Rock Island, Illinois

knjižnice
• Robarts Library, University of Toronto, Canada
• Royal Danish Library
• Royal Library of Sweden
• Ruskin Library at Lancaster University, UK
• Russian State Library in Moscow
• Sacramento Public Library, Sacramento, California
• Salt Lake City Public Library, Salt Lake City, Utah
• San Antonio Public Library, San Antonio, Texas
• Saxon State and University Library Dresden, Dresden, Germany
• Seattle Central Library, Seattle Washington
• Shanghai Library, Shanghai, China
• Sichuan Library, Chengdu, China
• SS. Cyril and Methodius National Library, Sofia, Bulgaria
• State Central Library, Kerala, Thiruvananthapuram, India
• State Library of New South Wales, Sydney, Australia
• State Library of Queensland, Brisbane, Australia

knjižnice
• State Library of Victoria, Melbourne, Australia
• State Library of Württemberg, Stuttgart, Germany
• Stockholm Public Library, Stockholm, Sweden
• Sun Yat-sen Library of Guangdong Province, Guangzhou, China
• Texas A&M University Libraries, College Station, Texas
• Topeka & Shawnee County Public Library, Topeka, Kansas
• Toronto Public Library, Toronto
• Troy Public Library, Troy, New York
• Twinsburg Public Library
• Tribhuvan University Central Library, Kathmandu, Nepal
• U. Grant Miller Library, Washington & Jefferson College
• University of Central Florida Libraries, Orlando, Florida
• University of Coimbra General Library, Coimbra, Portugal
• University of Florida Library System

knjižnice
• University of Applied Sciences Augsburg Library
• University of Houston Libraries
• University of Queensland Library, Brisbane, Australia
• University of South Florida Tampa Library, Tampa, Florida
• University of Sydney Library, Sydney, Australia
• University of Zambia Library
• Valley Library, Oregon State University, Corvallis, Oregon
• Vancouver Public Library, Vancouver
• Vatican Library in Vatican City
• Vilnius University Library
• West German Audio Book Library for the Blind
• W.E.B. Du Bois Library, University of Massachusetts Amherst
• Wiener Library for the Study of the Nazi Era and the Holocaust, Tel Aviv, Israel
• Wellcome Library, London
• West German Audio Book Library for the Blind, Münster, Germany
• William F. Ekstrom Library, University

knjižnice
of Louisville, Louisville, Kentucky
• William T. Young Library, University of Kentucky
• Wren Library, Trinity College, Cambridge

knjižnice
• Yale University Library, Yale University
• YeungNam University Library, South Korea
• Yiu Tung Public Library, Shau Kei

knjižnice
Wan, Hong Kong Island, Hong Kong
• Younes and Soraya Nazarian Library, Haifa, Israel
• Zillur Rahman Library, Aligarh, India

12.7. PRILOG 7 – Test za studente s Croaticuma

This is a short vocabulary test that will not be graded. The same test will be given to you at the end of the same class. Two weeks later (20.4.2020) you will once again get the same test in order to assess vocabulary retention. Your results will be stored under a self-chosen anonymous username and you will not need to enter any personal data or register. The procedure will be completely anonymous so we will not collect any personal data (name, date of birth, e-mail, etc.). We will only use results from your pretest and posttest and compare them to the results from other student groups to see if gamified content helps improve vocabulary skills. Group results and a report on this research will be published on the website of the *Mrežnik* project (<http://ihjj.hr/mreznik/>).

By completing this test you agree to participate in the research Creating Conceptual framework for gamifying Croatian Web Dictionary.

Upišite svoje korisničko ime (zapamtite ga i nakon što sat završi) (Enter your username (remember it after the end of the class)): _____

Prepoznaj vozilo.

1. Ovo je:

Vozilo koje prevozi velik broj putnika u gradu i kreće se po tračnicama.

2. Ovo je:

Motorno vozilo na četiri kotača kojim se ljudi najčešće voze.

3. Ovo je:

Motorno vozilo s kotačima za plaćeni prijevoz većeg broja putnika.

4. Ovo je:

Vozilo koje se sastoji od lokomotive i vagona i koje se kreće po tračnicama.

5. Ovo je:

Cestovno vozilo za prijevoz većih tereta.

6. Ovo je:

Vozilo koje služi za vuču poljoprivrednih strojeva i oruđa.

7. Ovo je:

Vozilo veće od automobila, a manje od kamiona koje je predviđeno za prijevoz više putnika ili tereta.

8. Ovo su:

Obuća s kotačima.

9. Ovo je:

Vozilo koje ima dva ili tri kotača, a pokreće se snagom jedne noge ili električnim motorom.

10. Ovo je:

Cestovno vozilo koje ima dva kotača.

11. Ovo je:

Vozilo na dva kotača koje pokreće čovjek s pomoću pedala.

12. Ovo je:

Letjelica za prijevoz ljudi i tereta.

13. Ovo je:

Sustav za prijevoz koji se obično nalazi na uzbrdici i u kojemu se kabine za prijevoz ljudi ili tereta kreću po napetoj žici.

14. Ovo je:

Letjelica napunjena zagrijanim zrakom ili plinom lakšim od zraka.

15. Ovo je:

Letjelica za prijevoz ljudi i tereta koja na krovu i na repu ima propeler.

16. Ovo je:

Prijevozno sredstvo za prijevoz putnika i tereta morskim putem.

17. Ovo je:

Plovilo koje je manje od broda.

Ponudeni odgovori za pitanja 1 – 17

- zrakoplov (avion)
- helikopter
- balon
- žičara
- automobil (auto)
- tramvaj
- vlak
- autobus
- motor
- bicikl
- romobil
- role
- brod
- čamac

Prepoznaj dijelove automobila.

18. Ovo su:

19. Ovo je:

20. Ovo je:

21. Ovo je:

22. Ovo je:

23. Ovo je:

24. Ovo je:

25. Ovo je:

26. Ovo je:

27. Ovo je:

28. Ovo je:

Ponuđeni odgovori za pitanja 18–28:

- vrata automobila
- bočno staklo
- retrovizor
- sjedalo
- mjenjač brzina
- volan
- ručna kočnica
- kotač

- brisači stakla
- prtljažnik (razg. gepek)
- pojas za vezanje
- motor

Izaberite pravilan oblik.

29. Radujem se _____.

- darovi
- darova
- darovima
- darove

30. Pomažem _____.

- prijatelj
- prijatelja
- prijatelju
- prijateljem

31. Nadam se _____.

- pobjedi
- pobjeda
- pobjedu
- pobjede

32. Čudim se _____.

- priči
- priča
- priču
- priče

33. Veselimo se _____.

- vikendi
- vikend
- vikendu
- vikenda

34. Smijem se _____.

- situaciji
- situacije
- situacija
- situaciju

Stavite glagol u rečenicu.

35. _____ prema Zagrebu.

- Volim
- Pričam
- Putujem

36. Kada nekom _____ nešto, osjećam se sretno.

- poklonim
- radujem
- smetam

37. _____ da će uskoro biti bolje.

- Nadam se
- Volim

- Čudim se

38. _____ lijepim slikama.

- Volim
- Putujem

- Zahvaljujem

- Vozim se
- Divim se

Povežite glagole sa značenjem.

39. čuditi se

- biti u čudu, biti iznenađen čime neočekivanim
- izražavati zahvalnost
- osjećati veselje ili radost, biti radostan

- imati nadu, očekivati da će se ostvariti nešto što želimo
- pokazati da nam se tko ili što jako sviđa, da smo fascinirani kime ili čime

40. diviti se

- biti u čudu, biti iznenađen čime neočekivanim
- izražavati zahvalnost
- osjećati veselje ili radost, biti radostan

- imati nadu, očekivati da će se ostvariti nešto što želimo
- pokazati da nam se tko ili što jako sviđa, da smo fascinirani kime ili čime

41. nadati se

- biti u čudu, biti iznenađen čime neočekivanim
- izražavati zahvalnost
- osjećati veselje ili radost, biti radostan

- imati nadu, očekivati da će se ostvariti nešto što želimo
- pokazati da nam se tko ili što jako sviđa, da smo fascinirani kime ili čime

42. veseliti se

- biti u čudu, biti iznenađen čime neočekivanim
- izražavati zahvalnost
- osjećati veselje ili radost, biti radostan

- imati nadu, očekivati da će se ostvariti nešto što želimo
- pokazati da nam se tko ili što jako sviđa, da smo fascinirani kime ili čime

43. zahvaljivati

- biti u čudu, biti iznenađen čime neočekivanim
- izražavati zahvalnost

- osjećati veselje ili radost, biti radostan

- imati nadu, očekivati da će se ostvariti nešto što želimo

- pokazati da nam se tko ili što jako sviđa, da smo fascinirani kime ili čime

Povežite glagole sa značenjem.

44. imati povjerenja u koga ili što

• dati	• smetati
• govoriti	• smijati se
• pisati	• vjerovati
• pomagati	

45. razvući usta u osmijeh kao izraz veselja i opuštenosti

• dati	• smetati
• govoriti	• smijati se
• pisati	• vjerovati
• pomagati	

46. izgovarati riječi i rečenice

• dati	• smetati
• govoriti	• smijati se
• pisati	• vjerovati
• pomagati	

47. bilježiti slova i brojke na papiru, ploči ili čemu drugom

• dati	• smetati
• govoriti	• smijati se
• pisati	• vjerovati
• pomagati	

12.8. PRILOG 8 – Upitnik za prikupljanje podataka o studentima s Croaticuma

Ova anketa ne prikuplja imena studenata, datum rođenja ili bilo koje druge podatke s pomoću kojih bi se nakon objave rezultata mogao otkriti identitet sudionika. Korisničko ime studenta upotrebljava se kako bi studenti ostali anonimni, ali kako bi se rezultati iz testova mogli povezati s rezultatima iz ove ankete. Svi studenti kojima je dana ova anketa obaviješteni su o istraživanju te su pismeno potvrdili da pristaju u njemu sudjelovati.

Podatci se prikupljaju kako bi se istražilo zadovoljstvo studenta s igrama.

(This survey doesn't collect student's names, dates of birth or any other data that can be used for identifying the students. Students will use their usernames to stay anonymous but also so we can match the results of their tests with this survey. All the students who got this survey were informed about the research and confirmed in writing that they agree to participate in the survey.

The data is collected to study the students' feelings towards games.)

1. Spol (gender):

a. M (♂)

b. Ž (F) (♀)

2. Dob (age): ____

3. Zemlja podrijetla (country of origin): ____

4. Materinski jezik (jezici) (Mother tongue(s)): ____

5. Na kojemu ste se jeziku obrazovali? (What language did you use during your primary education?) ____

6. Zna li još koji jezik? Ako ne znate, ostavite polje prazno. (Do you know any other language?) ____

7. Samoprocjena znanja hrvatskoga jezika. (Self-evaluation of your knowledge of Croatian language.)

	1	2	3	4	5	
jako slabo (very weak)	☐	☐	☐	☐	☐	vrlo dobro (very good)

8. Koristite li se mrežnim rječnicima kod učenja hrvatskoga jezika? (Do you often use web dictionaries for learning Croatian?)
- a. da
 - b. ne
9. Volite li igrati elektroničke igre? (Do you like to play electronic games?)
- a. da
 - b. ne
10. Jeste li ikada igrali obrazovne elektroničke igre ili se koristili sustavima za učenje jezika (npr. Duolingo, Rosetta Stone itd.)? (Did you ever use any systems or games for learning foreign languages (e.g. Duolingo, Rosetta Stone, etc.)?)
- a. da
 - b. ne

12.9. PRILOG 9 – Upitnik za studente eksperimentalne skupine s Croaticuma povezan sa zadovoljstvom igrama

1. Je li vam draže na satu igrati ovakve igre nego raditi klasične vježbe? (Do you prefer to have a class with such games rather than the traditional class?)

- da (yes)
- ne (no)
- svejedno mi je (I don't know)

2. Igre su jednostavne za igranje. (These games are simple to play.)

- u potpunosti se slažem (strongly agree)
- slažem se (agree)
- neutralan sam (neutral)
- ne slažem se (disagree)
- uopće se ne slažem (strongly disagree)

3. Igre su dobre za učenje hrvatskoga jezika. (These games are good for learning Croatian.)

- u potpunosti se slažem (strongly agree)
- slažem se (agree)
- neutralan sam (neutral)
- ne slažem se (disagree)
- uopće se ne slažem (strongly disagree)

4. Igre su zabavne za igranje. (These games are fun to play.)

- u potpunosti se slažem (strongly agree)
- slažem se (agree)
- neutralan sam (neutral)
- ne slažem se (disagree)
- uopće se ne slažem (strongly disagree)

5. Moja je najdrža igra sa sata... (My favorite game for the class is ...)

- Kviz – značenje glagola
- Pamtilica za prometna vozila

- Glagoli (igra dovlačenja)
- Dijelovi automobila (igra dovlačenja)
- Kviz dijelovi automobila

6. Želite li igrati ove igre nakon nastavnoga sata? (Do you want to play these games after the class?)

- da (yes)
- ne (no)
- možda (maybe)

7. Imate li savjete ili primjedbe povezane s igrama? Ako nemate, ostavite polje prazno. (Do you have any advice or complaints regarding the games? If not, leave the field empty.)

12.10. PRILOG 10 – Studenti po zemlji

Tablica 108. *Broj studenata po zemlji podrijetla unutar skupina*

	kontrolna skupina	eksperimentalna skupina	sveukupno
Južna Koreja	0	3	3 (15 %)
Argentina	2	0	2 (10 %)
Čile	1	1	2 (10 %)
Brazil	2	0	2 (10 %)
Peru	0	1	1 (5 %)
Venezuela	2	1	3 (15 %)
Bolivija	0	1	1 (5 %)
Španjolska	1	0	1 (5 %)
Kanada	2	0	2 (10 %)
Ukrajna	1	0	1 (5 %)
Australija	0	1	1 (5 %)
Mauritanija	0	1	1 (5 %)
Mongolija	1	0	1 (5 %)

12.11. PRILOG 11 – Rezultati studenata Croaticuma iz predtesta, posttesta i odgođenoga posttesta

Tablica 109. *Rezultati pojedinih studenata unutar skupina iz testova*

eksperimentalna skupina			
studenti	predtest	posttest	odgođeni posttest
student 1	40	47	46
student 2	30	37	35
student 3	37	44	42
student 4	39	38	39
student 5	32	44	43
student 6	29	44	37
student 7	27	41	39
student 8	31	42	40
student 9	38	42	46
kontrolna skupina			
student 1	41	46	42
student 2	31	45	44
student 3	39	46	46
student 4	37	46	46
student 5	37	44	45
student 6	30	40	44
student 7	39	42	42
student 8	42	46	46
student 9	45	47	46
student 10	44	46	47
student 11	36	41	40
student 12	36	40	45

12.12. PRILOG 12 – Napredak u broju bodova u posttestu i odgođenome posttestu studenata Croaticuma

Tablica 110. *Napredak studenata u broju bodova na testovima*

studenti po skupinama	napredak na posttestu u odnosu na pretest	napredak na odgođenome posttestu u odnosu na pretest	napredak na odgođenome posttestu u odnosu na posttest
student 1 (kontrolna)	5	1	-4
student 2 (kontrolna)	14	13	-1
student 3 (kontrolna)	7	7	0
student 4 (kontrolna)	9	9	0
student 5 (kontrolna)	7	8	1
student 6 (kontrolna)	10	14	4
student 7 (kontrolna)	3	3	0
student 8 (kontrolna)	4	4	0
student 9 (kontrolna)	2	1	-1
student 10 (kontrolna)	2	3	1
student 11 (kontrolna)	10	4	-1
student 12 (kontrolna)	4	9	5
student 1 (eksperimentalna)	7	6	-1
student 2 (eksperimentalna)	7	5	-2
student 3 (eksperimentalna)	7	5	-2
student 4 (eksperimentalna)	-1	0	1
student 5 (eksperimentalna)	12	11	-1
student 6 (eksperimentalna)	15	8	-7
student 7 (eksperimentalna)	14	12	-2
student 8 (eksperimentalna)	11	9	-2

studenti po skupinama	napredak na posttestu u odnosu na pretest	napredak na odgođenome posttestu u odnosu na pretest	napredak na odgođenome posttestu u odnosu na posttest
student 9 (eksperimentalna)	4	8	4

12.13. PRILOG 13 – Natuknice *Mrežnika* koje će sadržavati poveznice na igre

Tablica 111. *Trenutačne natuknice s poveznicama na igru*

osnovni modul	modul za učenike nižih razreda osnovne škole	modul za neizvorne govornike
točka	cvijeće	abeceda
zarez	drvo	latinica
imenica	životinje	jezik
glagol	boja	kultura
zamjenica	broj	rječnik
pridjev	č	gramatika
pravopis	ć	pravopis
anglizam	država	tekst
brajica	dž	govor
frazem	đ	
glagoljica	hrana	
rječnik	ije	
znakovni jezik (podnatuknica uz natuknicu <i>jezik</i>)	je	
	odjeća	
glagolski oblici (podnatuknica uz natuknicu <i>oblik</i>)	planet	
	slovo	
	tijelo	
	točka	
	vozilo	
	zanimanje	
	zarez	

12.14. PRILOG 14 – Konceptualni okvir igrifikacije mrežnoga rječnika

Slika 90. Prikaz prvih triju koraka konceptualnoga okvira (ostali povezani koraci nalaze se u slici 91)

Slika 91. Prikaz posljednjih četiriju koraka konceptualnoga okvira

13. POPIS SLIKA

Slika 1. <i>Primjer konceptualnoga okvira za izradu alata za analizu klimatskih promjena</i>	6
Slika 2. <i>Prikaz pretraživanja riječi igrifikacija na Google tražilici od 2004. godine</i>	7
Slika 3. <i>Primjer primjene igrifikacije s bodovanjem, značkama te praćenje razvoja različitih vještina u aplikaciji CARROT Fit</i>	22
Slika 4. <i>Sučelje za učenje logike programiranja na stranici Ruby-warrior</i>	25
Slika 5. <i>Igra križić-kružić, u kojoj je zadatak da igrač odabere točan odgovor na pitanje, što će mu omogućiti da na polje stavi svoju oznaku</i>	26
Slika 6. <i>Primjer značke za tečaj Hrvatski jezik OŠ I za koji pišu aktivnosti koje se moraju izvršiti te obrazovni ishodi koje nastavnici stječu uspješnim završavanjem tih aktivnosti</i>	27
Slika 7. <i>Prikaz elemenata igrifikacije u sučelju sustava Duolingo</i>	28
Slika 8. <i>Prikaz zadatka u sustavu Clozemaster</i>	30
Slika 9. <i>Daktilografska igra u kojoj igrači trebaju utipkati padajuće riječi koje sadržavaju č, ć, dž, đ, ije i je prije nego udare brod</i>	32
Slika 10. <i>Prikaz zadatka u igri Zombilingo</i>	36
Slika 11. <i>Igra za upisivanje frazema u kojoj se boduju frazemi na temelju tuđih odgovora</i> ...	39
Slika 12. <i>Prikaz različitih scenarija igre MWExpress</i>	41
Slika 13. <i>Prikaz strukture rječničkoga članka u osnovnome modulu u Mrežniku</i>	52
Slika 14. <i>Prikaz obrade natuknice broj u osnovnome modulu u Mrežniku</i>	53
Slika 15. <i>Prikaz obrade natuknice igrifikacija u osnovnome modulu</i>	54
Slika 16. <i>Prikaz demoinačice općega odostražnog rječnika za hrvatski jezik</i>	56
Slika 17. <i>Članak Hrvatska, Hrvat, Hrvatica, hrvatski s portala Etnici i ktetici</i>	60
Slika 18. <i>Primjer frazema s objašnjenjima na portalu Hrvatski u školi</i>	61
Slika 19. <i>Igra za učenje frazema u kojoj se dovlače slike kako bi se dobili odgovarajući frazemi</i>	61
Slika 20. <i>Dijelovi grafičkoga sučelja u programu TLex</i>	67
Slika 21. <i>Mrežni prikaz natuknice breskva u modulu za učenike nižih razreda osnovne škole u demoinačici Mrežnika</i>	70
Slika 22. <i>Igra u kojoj igrači trebaju unijeti slova kako bi dovršili riječ koja je prikazana slikom</i>	75
Slika 23. <i>Primjer pitanja iz kviza na stranici rječnika Merriam-Webster</i>	84
Slika 24. <i>Kviz za učenje riječi na temelju niza slika koje prikazuju pokrete ruku znakovnoga jezika</i>	89

Slika 25. Pamtilica za učenje naziva i kratica kemijskih elemenata koja se nalazi na stranici Englesko-hrvatski kemijski rječnik & glosar	91
Slika 26. Prikaz sustava nagrađivanja na stranicama Vocabulary.com, koji se zasniva na značkama koje se spremaju na avatar korisnika.....	94
Slika 27. Prikaz podjele igre na razine po sadržaju unutar rječnika Longman Dictionary of Contemporary English.....	95
Slika 28. Izbor kvizova na temelju različitih sadržaja	101
Slika 29. Pamtilica iz igre Food detectives	102
Slika 30. Prikaz situacije u igri Aquation: The Freshwater Access Game u kojoj je ulaganje u istraživanje u Rusiji dovelo do otkrića nove metode za pročišćavanje kišnice.....	103
Slika 31. Prikaz razina te značka i razvoja vještina koje igrač stječe igrajući igru The Wikipedia Adventure	105
Slika 32. Prikaz avatara u ljestvici poretka u enciklopediji Baidu Baike.....	108
Slika 33. Primjer scenarija u igri Great Fire of London, u kojem igrač mora odabrati predmete za gašenje požara koji su bili dostupni 1666.	118
Slika 34. Primjer statusa avatara za aktivnosti u sustavu ABCmouse.com.....	128
Slika 35. Prikaz postavljanja scene u priči	130
Slika 36. Igra u kojoj se dovlače dijelovi automobila napravljena s pomoću H5P-a.....	147
Slika 37. Prikaz dizajna Prvi školski pravopis – križaljka.....	148
Slika 38. Prikaz tablice rezultata s medaljama koje se daju najboljim igračima	149
Slika 39. Prikaz izmjene izvornoga dizajna za igru Utipkaj riječi.....	150
Slika 40. Primjer kviza koji daje raznovrsna pitanja, komentare na odgovore te tablicu rezultata	151
Slika 41. Primjer pamtilice u kojoj se povezuju nazivi sa slikama te se ispiše definicija predmeta sa slike	152
Slika 42. Statistika pregleda objava Instituta koje se odnose na igre.....	158
Slika 43. Prikaz pregleda stranice Jezične igre i multimedijски prikaz jezika od 4. travnja 2018. do 10. travnja 2020.	159
Slika 44. Prikaz stranice koja objedinjuje igre kojima se koristi u ovome istraživanju	167
Slika 45. Kviz za dijelove automobila	172
Slika 46. Pitanje u igri Kviz – značenje glagola.....	173
Slika 47. Pitanje u igri Glagoli igra dovlačenja.....	174
Slika 48. Prikaz prvoga korka konceptualnoga okvira igriifikacije mrežnoga rječnika.....	231
Slika 49. Primjer odabira i podjele sadržaja koji se žele igriificirati za Mrežnik.....	232

Slika 50. <i>Prikaz cijeloga drugog koraka konceptualnoga okvira igrifikacije mrežnoga rječnika</i>	237
Slika 51. <i>Pitanja u pravopisnome kvizu za učenike nižih razreda osnovne škole</i>	238
Slika 52. <i>Primjer križaljke s pitanjem u desnome kutu i poljima za odgovor u lijevome kutu</i>	239
Slika 53. <i>Igra nadopunjavanja u kojoj se mora točno napisati riječ koja sadržava ije ili je</i>	240
Slika 54. <i>Primjer pitanja iz fonologije u kvizu za maturu</i>	241
Slika 55. <i>Igra razvrstavanja glagolskih oblika</i>	243
Slika 56. <i>Primjer pitanja iz igre pisanja glagolskih oblika</i>	244
Slika 57. <i>Primjer pitanja u kvizu s čestim jezičnim pogreškama</i>	245
Slika 58. <i>Napomena koja se pojavljuje na kraju pitanja u kvizu Česte jezične pogreške</i>	245
Slika 59. <i>Razina pamtilice za glagol biti</i>	246
Slika 60. <i>Pitanje u igri u kojoj treba upisati dativ zadanih riječi i izraza u rečenici</i>	247
Slika 61. <i>Pamtilica s profesijskim imenicama</i>	248
Slika 62. <i>Prikaz pitanja u kvizu za učenje naziva cvijeća</i>	249
Slika 63. <i>Igra dovlačenja u kojoj treba poredati planete Sunčeva sustava</i>	250
Slika 64. <i>Igra dovlačenja u kojoj se razvrstava drveće na bjelogoricu i crnogoricu</i>	251
Slika 65. <i>Pamtilica u kojoj se spajaju hrvatske riječi s anglicizmima</i>	252
Slika 66. <i>Igra dovlačenja u kojoj se nadopunjavaju rečenice ponuđenim riječima</i>	252
Slika 67. <i>Igra tetris u kojoj se spajaju slova u riječima te se za određene riječi dobivaju definicije</i>	253
Slika 68. <i>Igra u kojoj se spajaju blokovi slova u riječi s pomoću miša</i>	254
Slika 69. <i>Prikaz pitanja s objašnjenjem odgovora iz kviza za maturu hrvatskoga jezika</i>	255
Slika 70. <i>Prikaz teksta upotrijebljenoga u kvizu razumijevanja teksta</i>	256
Slika 71. <i>Prikaz pitanja koje se odnosi na tekst o prvim tramvajima i automobilima</i>	256
Slika 72. <i>Prikaz igre Dan u životu u kojoj se uče izrazi za dnevne aktivnosti</i>	257
Slika 73. <i>Glagoljična pamtilica na portalu Hrvatski u školi</i>	258
Slika 74. <i>Pitanje u kvizu za učenje oble glagoljice</i>	259
Slika 75. <i>Slagalica s Bašćanskom pločom</i>	260
Slika 76. <i>Tekst o Bašćanskoj ploči koji se pojavljuje nakon što se složi slagalica</i>	260
Slika 77. <i>Jedinstvene igre za učenje glagoljice</i>	261
Slika 78. <i>Pitanje u kvizu za učenje slova brajice</i>	262
Slika 79. <i>Prikaz igre Autori po razdobljima u kojoj se dovlače imena autora u odgovarajuća razdoblja</i>	263

Slika 80. <i>Prikaz cijeloga trećeg koraka konceptualnoga okvira igrifikacije mrežnoga rječnika</i>	264
Slika 81. <i>Prikaz cijeloga četvrtog koraka testiranje igara</i>	265
Slika 82. <i>Prikaz kategorija i oznaka koje se pojavljuju na Googleovoj tražilici za stranicu Informatičke igre</i>	267
Slika 83. <i>Prikaz izgleda analize toplinskih mapa za različite stranice</i>	268
Slika 84. <i>Prvi koraci koji se trebaju napraviti prije izdavanja igre</i>	269
Slika 85. <i>Pregled kategorija i potkategorija za igre unutar svakoga modula na stranici Mrežnika</i>	270
Slika 86. <i>Mogući načini integracije igre u rječnik</i>	271
Slika 87. <i>Prikaz cijeloga petog koraka povezanoga s objavom igara</i>	271
Slika 88. <i>Prikaz cijeloga šestog koraka povezanoga s objavom igre</i>	274
Slika 89. <i>Prikaz cijeloga sedmog koraka povezanoga s praćenjem zadovoljstva korisnika igrama</i>	275
Slika 90. <i>Prikaz prvih triju koraka konceptualnoga okvira</i>	385
Slika 91. <i>Prikaz posljednjih četiriju koraka konceptualnoga okvira</i>	386

14. POPIS TABLICA

Tablica 1. <i>Indeksirane stranice koje sadržavaju nazive gemifikacija, gamifikacija i igrifikacija</i>	8
Tablica 2. <i>Objašnjenje osnovnih igrifikacijskih elemenata</i>	11
Tablica 3. <i>Prednosti i nedostaci e-učenja</i>	13
Tablica 4. <i>Tjedni rezultati eksperimentalne skupine</i>	19
Tablica 5. <i>Tjedni rezultati kontrolne skupine</i>	19
Tablica 6. <i>Značajke aplikacija i sustava</i>	33
Tablica 7. <i>Primjeri kolokacijskih pitanja</i>	38
Tablica 8. <i>Natuknica regularni izraz u Jeni i Pojmovniku Mrežnika</i>	59
Tablica 9. <i>Kriteriji podjele korpusa</i>	63
Tablica 10. <i>Objašnjenje dijelova sučelja u programu TLex</i>	68
Tablica 11. <i>Prednosti i nedostaci programa za izradu rječnika</i>	72
Tablica 12. <i>Razredba leksikografskih djela</i>	78
Tablica 13. <i>Različiti kriteriji podjele rječnika</i>	79
Tablica 14. <i>Rječnici prema vrsti i jeziku</i>	81
Tablica 15. <i>Broj rječnika s igrama po tipovima podjele</i>	83
Tablica 16. <i>Igrivi materijali na stranicama rječnika</i>	86
Tablica 17. <i>Broj e-rječnika koji sadržavaju igre</i>	88
Tablica 18. <i>Igrifikacijski elementi u rječnicima</i>	92
Tablica 19. <i>Broj rječnika koji sadržavaju određene igrifikacijske elemente</i>	93
Tablica 20. <i>Različiti kriteriji podjele enciklopedija</i>	96
Tablica 21. <i>Enciklopedije po tipovima podjele i jezicima</i>	97
Tablica 22. <i>Broj enciklopedija po opsegu obuhvaćenoga sadržaja i broju jezika</i>	98
Tablica 23. <i>Igrivi materijali na stranicama e-enciklopedija</i>	100
Tablica 24. <i>Tipovi igara koji se nalaze u e-enciklopedijama</i>	100
Tablica 25. <i>Igrifikacijski elementi u enciklopedijama</i>	106
Tablica 26. <i>Prikaz elemenata igrifikacije prisutnih u enciklopedijama</i>	107
Tablica 27. <i>Zastupljenost tipova igara na stranicama rječnika i enciklopedija</i>	108
Tablica 28. <i>Broj mrežnih rječnika i enciklopedija s obzirom na zastupljenost određenoga igrifikacijskog elementa</i>	110
Tablica 29. <i>Zastupljenost interaktivnih sadržaja na stranicama hrvatskih muzeja</i>	112
Tablica 30. <i>Tipovi igara i igrifikacijskih elemenata na stranicama hrvatskih muzeja</i>	113

Tablica 31. Tipovi igara i igrifikacijskih elemenata svjetskih muzeja	115
Tablica 32. Rjeđi tipovi obrazovnih materijala.....	119
Tablica 33. Tipovi obrazovnih igara	120
Tablica 34. Tipovi igara i igrifikacijski elementi knjižnica koje sadržavaju vlastite obrazovne igre	125
Tablica 35. Tipovi obrazovnih igara i igrifikacijski elemenati koji se nalaze na vanjskim poveznicama kojima se koriste knjižnice.....	125
Tablica 36. Broj određenih tipova igara na mrežnim stranicama arhiva, knjižnica i muzeja.....	131
Tablica 37. Igrifikacijski elementi mrežnih stranica arhiva, knjižnica i muzeja.....	131
Tablica 38. Proučavanje pedagoških aspekata tipova obrazovnih igara	133
Tablica 39. Proučavanje tehničkih aspekata obrazovnih igara	137
Tablica 40. Najčešće vrijednosti za jedinice analize za pedagoški aspekt i tehnički aspekt za sve tipove igara	142
Tablica 41. Programi, mrežne stranice i programski kodovi korišteni za razvoj igara	156
Tablica 42. Plan istraživanja	165
Tablica 43. Tipovi igara za poučavanje određenih nastavnih sadržaja.....	167
Tablica 44. Igrifikacijski elementi za svaku igru.....	169
Tablica 45. Broj studenata u skupinama	176
Tablica 46. Broj studenata po generacijama u skupinama	177
Tablica 47. Materinski jezik studenata.....	178
Tablica 48. Poznavanju drugih jezika	179
Tablica 49. Samoprocjena znanja hrvatskoga jezika	179
Tablica 50. Korištenje mrežnim rječnicima za učenje hrvatskoga jezika	180
Tablica 51. Mišljenje studenata o elektroničkim igrama	180
Tablica 52. Broj studenata koji su se koristili obrazovnim igrama i sustavima za učenje jezika	181
Tablica 53. Spomenute obrazovne igre te sustavi za učenje jezika	182
Tablica 54. Odgovori studenata na pitanje o zadovoljstvu igrama	183
Tablica 55. Odgovori studenata na pitanje o složenosti igara	183
Tablica 56. Odgovori studenata na pitanje o tome jesu li igre dobre za učenje hrvatskoga jezika	184
Tablica 57. Odgovor studenata na pitanje o tome smatraju li igre zabavnima	184
Tablica 58. Najdraža igra studenata	184
Tablica 59. Odgovor studenata na pitanje žele li igrati igre nakon nastavnoga sata	185

Tablica 60. <i>Opisna statistika za rezultate predtesta u obje skupine</i>	186
Tablica 61. <i>Postotak točnih odgovara i prosjek bodova u dijelovima predtesta</i>	188
Tablica 62. <i>Opisna statistika za rezultate posttesta u objema skupinama</i>	189
Tablica 63. <i>Postotak točnih odgovara i prosjek bodova u dijelovima posttesta</i>	190
Tablica 64. <i>Opisna statistika za rezultate odgođenoga posttesta u objema skupinama</i>	191
Tablica 65. <i>Postotak točnih odgovara i prosjek bodova u dijelovima odgođenoga posttesta</i>	193
Tablica 66. <i>Opisna statistika rezultata studenata i studentica eksperimentalne i kontrolne skupine u predtestu</i>	193
Tablica 67. <i>Opisna statistika za rezultate studenata i studentica kontrolne skupine u predtestu, posttestu i odgođenome posttestu</i>	194
Tablica 68. <i>Opisna statistika za rezultate studenata i studentica eksperimentalne skupine u predtestu, posttestu i odgođenome posttestu</i>	195
Tablica 69. <i>Opisna statistika za rezultate studenata obiju skupina na temelju generacija u predtestu, posttestu i odgođenome posttestu</i>	195
Tablica 70. <i>Opisna statistika za studente kontrolne skupina na temelju generacije u predtestu, posttestu i odgođenome posttestu</i>	196
Tablica 71. <i>Opisna statistika za studente eksperimentalne skupine na temelju generacije u predtestu, posttestu i odgođenome posttestu</i>	197
Tablica 72. <i>Kod za dobivanje rezultata Shapiro-Wilkova testa kod predtesta kontrolne skupine</i>	198
Tablica 73. <i>Rezultati Shapiro-Wilkova testa za obje skupine za predtest, posttest i odgođeni posttest</i>	199
Tablica 74. <i>Statistika za rangove studenata po testovima</i>	203
Tablica 75. <i>U-vrijednosti po skupinama</i>	204
Tablica 76. <i>Naredba u R za dobivanje snage korelacijskoga testa</i>	208
Tablica 77. <i>Naredba u R-u za dobivanje rezultata Mann-Whitneyjeva U-testa za dokazivanje hipoteze H_a</i>	210
Tablica 78. <i>Naredba u R-u za dobivanje rezultata Mann-Whitneyjevim U-testom za dokazivanje hipoteze H_b</i>	211
Tablica 79. <i>Statističke vrijednosti dobivene Mann-Whitneyjevim U-testom iz rezultata posttesta i odgođenoga posttesta</i>	211
Tablica 80. <i>Opisna statistika napretka studenata u posttestu u odnosu na predtest</i>	213
Tablica 81. <i>Opisna statistika napretka studenata u odgođenome posttestu u odnosu na predtest</i>	214

Tablica 82. Opisna statistika napretka studenata u odgođenome posttestu u odnosu na posttest	214
Tablica 83. Naredba u R-u za dobivanje rezultata Mann-Whitneyjeva U-testa za dokazivanje hipoteze H_c	215
Tablica 84. Statističke vrijednosti dobivene Mann-Whitneyjevim U-testom za napredak bodova kod posttesta i odgođenoga posttesta u odnosu na pretest	215
Tablica 85. Naredba u R-u za dobivanje rezultata Wilcoxonova test sume rangova za dokazivanje hipoteze H_d	217
Tablica 86. Statističke vrijednosti dobivene Wilcoxonovim testom sume rangova za usporedbe rezultata pretesta i posttesta te pretesta i odgođenoga posttesta.....	218
Tablica 87. Opisna statistika kod pretesta za studente koji vole igrati igre i studente koji ih ne vole ili su neutralni.....	219
Tablica 88. Opisna statistika kod posttesta za studente koji vole igrati igre i studente koji ih ne vole ili su neutralni.....	220
Tablica 89. Opisna statistika kod odgođenoga posttesta za studente koji vole igrati igre i studente koji ih ne vole ili su neutralni	220
Tablica 90. Naredba u R-u za dobivanje rezultata Mann-Whitneyjeva U-testa za dokazivanje hipoteze H_e	220
Tablica 91. Statističke vrijednosti dobivene Mann-Whitneyjevim U-testom za dokazivanje hipoteze H_e	221
Tablica 92. Snaga i veličina učinka za provedene Mann-Whitneyjeve U-testove kod dokazivanja hipoteze H_e	221
Tablica 93. Opisna statistika rezultata studenata u svim trima testovima svrstanih na temelju njihove samoprocjene znanja hrvatskoga jezika	223
Tablica 94. Naredba u R-u za dobivanje rezultata Spearmanove korelacije za dokazivanje hipoteze H_f	223
Tablica 95. Rezultati Spearmanove korelacije između samoprocjene znanja studenata i rezultat pretesta, posttesta i odgođenoga posttesta.....	224
Tablica 96. Naredba u R-u za dobivanje snage korelacijskih testova	226
Tablica 97. Igrificirani sadržaji Mrežnika u pojedinim modulima	232
Tablica 98. Primjeri izrađenih tipova igara za Mrežnik na temelju jezičnih razina	234
Tablica 99. Igrifikacijski elementi koji se planiraju primijeniti za svaki tip igre u Mrežniku.....	235
Tablica 100. Trenutačna statistika (svibanj 2020.) reakcija korisnika na objave povezane s igrama Instituta za hrvatski jezik i jezikoslovlje	272

Tablica 101. <i>Prisutnost igrifikacijskih elemenata na mrežnim stranicama rječnika (2019.)</i>	343
Tablica 102. <i>Prisutnost igrifikacijskih elemenata na mrežnim stranicama enciklopedija (2019.)</i>	346
Tablica 103. <i>Interaktivni sadržaji koji se nalaze na stranicama hrvatskih muzeja (2018.)</i>	348
Tablica 104. <i>Popis analiziranih mrežnih stranica najposjećenijih stranih muzeja (2019.)</i>	356
Tablica 105. <i>Obrazovni sadržaji na mrežnim stranicama 21 svjetskog arhiva</i>	358
Tablica 106. <i>Popis analiziranih mrežnih stranica knjižnica koje sadržavaju igrifikacijske elemente (2019.)</i>	360
Tablica 107. <i>Popis ostalih analiziranih mrežnih stranica knjižnica koje ne sadržavaju igrifikacijske elemente (2019.)</i>	361
Tablica 108. <i>Broj studenata po zemlji podrijetla unutar skupina</i>	380
Tablica 109. <i>Rezultati pojedinih studenata unutar skupina iz testova</i>	381
Tablica 110. <i>Napredak studenata u broju bodova na testovima</i>	382
Tablica 111. <i>Trenutačne natuknice s poveznicama na igru</i>	384

15. POPIS GRAFIKONA

Grafikon 1. <i>Odabir najdražih igara sa stranice Informatičke igre i multimedijски prikaz znanja</i>	44
Grafikon 2. <i>Broj hrvatskih muzeja s određenim tipom igre</i>	113
Grafikon 3. <i>Broj hrvatskih muzeja s obzirom na zastupljenost određenoga igrifikacijskog elementa</i>	114
Grafikon 4. <i>Broj stranih muzeja s određenim tipom igre</i>	116
Grafikon 5. <i>Zastupljenost igrifikacijskih elementa na stranicama najposjećenijih stranih muzeja</i>	116
Grafikon 6. <i>Broj stranih arhiva s određenim tipom igre</i>	121
Grafikon 7. <i>Zastupljenost određenih igrifikacijskih elementa na stranicama arhiva</i>	121
Grafikon 8. <i>Broj obrazovnih igara koje se nalaze na stranicama knjižnice i vanjskim poveznicama</i>	124
Grafikon 9. <i>Vanjske poveznice na stranice s obrazovnim igrama koje se pojavljuju na stranicama knjižnica</i>	126
Grafikon 10. <i>Knjižnice s poveznicom na određeni tip igre</i>	127
Grafikon 11. <i>Zastupljenost određenih igrifikacijskih elementa</i>	127
Grafikon 12. <i>Tipovi igara koji se lako upotrebljavaju</i>	139
Grafikon 13. <i>Tipovi igara po mogućnosti primjene pri poučavanju različitih obrazovnih sadržaja</i>	140
Grafikon 14. <i>Tipovi igara koji se mogu izraditi s pomoću grafičkih sučelja dostupnih programa</i>	140
Grafikon 15. <i>Tipovi igara čiji se razvojni kodovi mogu prilagoditi nakon njihove izrade u grafičkome sučelju programa</i>	141
Grafikon 16. <i>Tipovi igara koji se mogu igrati na mobilnim uređajima manjih zaslona</i>	141
Grafikon 17. <i>Studenti kontrolne skupine po dobi</i>	177
Grafikon 18. <i>Studenti eksperimentalne skupine po dobi</i>	177
Grafikon 19. <i>Raspon bodova studenata na predtestu</i>	186
Grafikon 20. <i>Raspon bodova studenata na posttestu</i>	189
Grafikon 21. <i>Raspon bodova studenata u odgođenome posttestu</i>	192
Grafikon 22. <i>Poligon frekvencija za rezultate predtesta</i>	199
Grafikon 23. <i>Poligon frekvencija za rezultate posttesta</i>	199
Grafikon 24. <i>Poligon frekvencija za rezultate odgođenoga posttesta</i>	200

Grafikon 25. <i>Dijagrama rasipanja koji prikazuje vezu između bodova u predtestu sa samoprocjenom znanja studenata Croaticuma</i>	224
Grafikon 26. <i>Dijagrama rasipanja koji prikazuje vezu između bodova u posttestu sa samoprocjenom znanja studenata Croaticuma</i>	224
Grafikon 27. <i>Dijagram rasipanja koji prikazuje vezu između bodova u odgođenoj posttestu sa samoprocjenom znanja studenata Croaticuma</i>	225

16. ŽIVOTOPIS S POPISOM RADOVA

Josip Mihaljević rođen je 1992. godine u Zagrebu. Godine 2011. završio je Klasičnu gimnaziju u Zagrebu i upisao studij Informacijskih i komunikacijskih znanosti na Filozofskome fakultetu u Zagrebu. Preddiplomski studij završio je godine 2014. te je upisao diplomski studij arhivistike i nastavnički smjer informatike. Oba smjera diplomirao je godine 2016. sa zajedničkim težinskim prosjekom 4,87. Za stranicu *Informatičke igre* 2018. dobio je nagradu Ministarstva znanosti i obrazovanja za inovativni digitalni sadržaj⁴⁸⁸.

Godine 2016. upisao je doktorski studij Informacijskih i komunikacijskih znanosti. Godine 2017. dobio je stipendiju grada Zagreba za postignut uspjeh na doktorskome studiju i objavljene radove. Godine 2016. zaposlio se u Školi za medicinske sestre Vrapče kao nastavnik informatike. Položio je stručni ispit. Od ožujka 2018. do 31. kolovoza 2018. radio je u Školi za primalje u Zagrebu te je od 1. rujna zaposlen u Institutu za hrvatski jezik i jezikoslovlje kao doktorand na projektu *Hrvatski mrežni rječnik – MREŽNIK*. Unutar projekta razvija različite igre za sadržaje rječnika. Godine 2019. za portal *Hrvatski u školi* razvio je nove igre i sadržaje za učenje glagoljice⁴⁸⁹ te abecede znakovnoga jezika⁴⁹⁰ i brajice⁴⁹¹. Iste godine razvio je mrežnu inačicu rječnika *Arhivistički rječnik: HRVATSKO-ENGLESKI / ENGLESKO-HRVATSKI* te je dogovorio prebacivanje naziva iz rječnika na *Hrvatski terminološki portal*. U *Odjelu za hrvatski standardni jezik* osim na projektu *Mrežnik* sudjeluje na projektu *Hrvatsko jezikoslovno nazivlje – JENA*, na kojemu je radio na izradi specijaliziranoga jezičnog korpusa te održavanju mrežnih stranica te na projektu *Muško i žensko u hrvatskome jeziku*, na kojemu je radio na izradi specijaliziranih odostražnih rječnika. U suradnji s *Odjelom za onomastiku i etnologiju* izradio je stranicu portala za osobna hrvatska imena⁴⁹² te u suradnji s *Odjelom za povijest hrvatskoga jezika i povijesnu leksikografiju* interaktivnu vremensku lentu koja prikazuje povijest hrvatskoga jezika⁴⁹³. Aktivno sudjeluje na znanstvenim skupovima i radionicama te objavljuje stručne i znanstvene radove. Bio je tajnik znanstvenoga skupa *E-rječnici i e-leksikografija* te je trenutačno tajnik časopisa *Rasprave: časopis Instituta za hrvatski jezik i jezikoslovlje*. Član je

⁴⁸⁸ URL: <http://ihjj.hr/clanak/doktorand-josip-mihaljevic-dobio-nagradu-za-inovativni-digitalni-obrazovni-sadrzaj/731/> (18. 5. 2020.)

⁴⁸⁹ URL: <http://hrvatski.hr/volim-glagoljicu/> (18. 5. 2020.)

⁴⁹⁰ URL: <http://ihjj.hr/znakovni/> (18. 5. 2020.)

⁴⁹¹ URL: <http://ihjj.hr/brajica/> (18. 5. 2020.)

⁴⁹² URL: <http://osobno-ime.hr/> (18. 5. 2020.)

⁴⁹³ URL: <http://ihjj.hr/iz-povijesti-hrvatskoga-jezika/> (18. 5. 2020.)

dviju COST akcija: *European Network for Combining Language Learning with Crowdsourcing Techniques* i *European Network for Game Theory*.

Popis radova:

1. Mihaljević, Josip. 2021. Elektroničke obrazovne igre očima učenika i nastavnika. *Hrvatski jezik: znanstveno-popularni časopis za kulturu hrvatskoga jezika* 8/1. 17–21.
2. Mihaljević, Josip. 2020. Igrifikacija hrvatskoga mrežnog rječnika – *Mrežnika*. *Rasprave: Časopis Instituta za hrvatski jezik i jezikoslovlje* 46/2. 407–434.
3. Matijević, Maja; Mihaljević, Josip. 2020. Mrežne igre prilagođene arapskim govornicima kao potpora učenju hrvatskoga. *HINIZ – Hrvatski inojezični*. Ur Jelaska, Zrinka; Gligorić, Igor Marko. Hrvatsko filološko društvo – Institut für Slawistik. Zagreb – Klagenfurt. 153–174.
4. Mihaljević, Josip; Marković, Mario. 2020. Korpus Jene – jednojezični terminološki korpus. *Hrvatsko jezikoslovno nazivlje – JENA*. Ur. Mihaljević, Milica; Hudeček, Lana; Jozić, Željko. Institut za hrvatski jezik i jezikoslovlje. Zagreb. 110–123.
5. Mihaljević, Josip. 2020. Programska rješenja u projektu Jena. *Hrvatsko jezikoslovno nazivlje – JENA*. Ur. Mihaljević, Milica; Hudeček, Lana; Jozić, Željko. Institut za hrvatski jezik i jezikoslovlje. Zagreb. 124–135.
6. Lazić, Daria; Mihaljević, Josip. 2020. Morfološke igre na primjeru igara za učenje glagolskih oblika. *Jezik, književnost i obrazovanje – suvremeni koncepti* 4. Međimurski filološki i pedagoški dani. Ur. Kolar-Billege, Martina i dr. Učiteljski fakultet Sveučilišta u Zagrebu. Čakovec. 122–135.
7. Marković, Mario; Mihaljević, Josip; Mihaljević, Milica. 2020. Kako pronaći jezikoslovni naziv. *Hrvatski jezik* 7/1. 18–22.
8. Matijević, Maja; Mihaljević, Josip. 2019. Arabic Speakers as Croatian Language Learners Electronic Educational Games as a Support for Learning. *INFuture2019: Knowledge in the Digital Age*. Ur. Bago, Petra; Hebrang Grgić, Ivana; Ivanjko, Tomislav; Juričić, Vedran; Miklošević, Željka; Stublić, Helena. Department of Information and Communication Sciences, Faculty of Humanities and Social Sciences. Zagreb. 135–145.
9. Mihaljević, Josip. 2019. Gamification in E-Lexicography. *INFuture2019: Knowledge in the Digital Age*. Ur. Bago, Petra; Hebrang Grgić, Ivana; Ivanjko, Tomislav; Juričić, Vedran; Miklošević, Željka; Stublić, Helena. Department of Information and Communication Sciences, Faculty of Humanities and Social Sciences. Zagreb. 155–164.

10. Mihaljević, Ana; Mihaljević, Josip. 2019. Mrežne igre u poučavanju i učenju hrvatskoga jezika. *Dijete i jezik danas – Razvoj pismenosti u materinskom i inom jeziku* Zbornik radova sa znanstvenoga skupa s međunarodnim sudjelovanjem. Ur. Majdenić, Valentina; Trtanj, Ivana; Živković Zebec, Vedrana. Fakultet za odgojne i obrazovne znanosti. Osijek. 113–137.
11. Mihaljević, Josip. 2019. Analysis and Creation of Free Sentiment Analysis Programs. *Medijska istraživanja* 25/1. 83–105.
12. Mihaljević, Josip. 2019. Games for Learning Old and Special Alphabets – The Case Study of Gamifying *Mrežnik*. *CLiC-it 2019: Italian Conference on Computational Linguistics*. Ur. Bernardi, Raffaella; Navigli, Roberto; Semeraro, Giovanni. AILC. Bari.
13. Mihaljević, Josip. 2019. Izrada mrežnog arhivističkog rječnika. *51. savjetovanje hrvatskih arhivista: Upravljanje elektroničkim gradivom i suvremena arhivska praksa*. Ur. Zaradić, Radoslav. Hrvatsko arhivističko društvo. Slavonski Brod. 189–206.
14. Mihaljević, Josip. 2019. Jezične tehnologije i mrežni izvori Instituta za njemački jezik. *Hrvatski jezik: znanstveno-popularni časopis za kulturu hrvatskoga jezika* 6/2. 22–25.
15. Mihaljević, Josip. 2019. Volim glagoljicu. *Baščina* 20. 81–82.
16. Mihaljević, Josip. 2019. Zaštita i upravljanje metapodacima u PDF dokumentima. *Archive Material in Theory and Practice*. Ur. Dučić, Miroslav. Arhivističko društvo Srbije. Beograd. 109–122.
17. Lewis, Kristian; Mihaljević, Josip. 2018. Odostražni rječnik – što je, kako ga izraditi i čemu služi. *Hrvatski jezik : znanstveno-popularni časopis za kulturu hrvatskoga jezika* 5/2. 21–24.
18. Marković, Mario; Mihaljević, Josip. 2018. Elektronički arhivski obrazovni sadržaji. *50. savjetovanje hrvatskih arhivista: privatno arhivsko gradivo i koncept sveobuhvatnog arhiva*. Ur. Zaradić, Radoslav. Hrvatsko arhivističko društvo. Osijek. 181–201.
19. Mihaljević, Josip. 2018. Korištenje programima otvorenoga koda u nastavi informatike. *Mipro 2018 – 41. međunarodni skup za informacijsku i komunikacijsku tehnologiju, elektrotehniku i mikroelektrotehniku*. Ur. Skala, Karolj. MIPRO. Rijeka. 965–969.
20. Mihaljević, Josip. 2017. Creation and Use of Game-Based Learning Material. *INFuture2017: Integrating ICT in Society*. Ur. Atanassova, Iana; Zaghouani, Wajdi; Kragić, Bruno; Aas, Kuldar; Stančić, Hrvoje; Seljan, Sanja. Department of Information and Communication Sciences, Faculty of Humanities and Social Sciences. Zagreb. 317–330.

21. Mihaljević, Josip. 2017. Izrada multimedijiskoga mrežnog sadržaja za promoviranje arhivske djelatnosti. *Arhivska praksa* 20. 335–346.
22. Mihaljević, Josip. 2017. Korištenje besplatnih usluga za izradu mrežnih obrazaca u svrhu poboljšavanja djelatnosti škole. *Školski vjesnik* 66/4. 589–602.
23. Mihaljević, Josip. 2017. Može li računalo pročitati tekst na hrvatskome jeziku?. *Hrvatski jezik: znanstveno-popularni časopis za kulturu hrvatskoga jezika* 4/4. 19–23.
24. Mihaljević, Josip. 2017. Mrežna vidljivosti hrvatskih arhiva. *5. kongres hrvatskih arhivista: Arhivi u Hrvatskoj (retro)perspektiva*. Ur. Babić, Silvija. Hrvatsko arhivističko društvo. Zadar. 449–462.
25. Mihaljević, Josip. 2017. Nove mrežne igre za učenje glagoljice. *Baščina* 18. 42–43.
26. Mihaljević, Josip. 2017. Proces obnove mrežnih stranica Hrvatskoga arhivističkog društva. *Arhivski vjesnik* 60/1. 313–336.
27. Mihaljević, Josip; Goluža, Nikolina. 2017. Mrežne igre za učenje osnovne razine njemačkog jezika. *Život i škola* 63/2. 161–168.
28. Mihaljević, Josip; Kuri, Borna. 2017. Glagoljica u komercijalnim videoigrama. *Baščina* 18. 40–41.
29. Mihaljević, Josip. 2016. Elektroničke mrežne igre za učenje glagoljice. *Baščina* 17. 35–35.
30. Mihaljević, Josip. 2016. E-učenje i hrvatski jezik. *Hrvatski jezik: znanstveno-popularni časopis za kulturu hrvatskoga jezika* 3/3. 24–27.
31. Mihaljević, Josip. 2016. Mrežne stranice arhivskih ustanova kao suvremeni informacijski izvor i podrška za poslovanje. *Arhivska praksa* 19. 330–346.
32. Zlodi, Goran; Mihaljević, Josip; Šimunec, Anica; Mikeli, Paula; Rudić, Ivana. 2015. Cooperation of a museum institution and students in creating virtual exhibitions using the MOVIO tool. *INFuture2015: e-Institutions – Openness, Accessibility, and Preservation*. Ur. Anderson, Karen; Duranti, Luciana; Stančić, Hrvoje; Seljan, Sanja; Mateljan, Vladimir. Department of Information and Communication Sciences, Faculty of Humanities and Social Sciences. Zagreb. 271–284.