Poučavanje algoritma sortiranja bez računala

Medak, Lucija

Master's thesis / Diplomski rad (sveučilišni)

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of Science / Sveučilište u Splitu, Prirodoslovno-matematički fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:166:262389

Rights / Prava: Zaštićeno autorskim pravom. / In copyright.

Download date / Datum preuzimanja: **2026-09-14**

Repository / Repozitorij:

Digital Repository of Faculty of Science in Split / Digitalni repozitorij Prirodoslovno-matematičkog fakulteta u Splitu

Dabar

SVEUČILIŠTE U SPLITU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
ODJEL ZA INFORMATIKU

DIPLOMSKI RAD

Poučavanje algoritma sortiranja bez računala

Lucija Medak

Split, rujan 2022.

Temeljna dokumentacijska kartica

Diplomski rad

Sveučilište u Splitu
Prirodoslovno-matematički fakultet
Odjel za Informatiku
Ruđera Boškovića 33, 21000 Split, Hrvatska

Poučavanje algoritma sortiranja bez računala

Lucija Medak

SAŽETAK

Algoritamska vizualizacija u podučavanju bi se trebala koristiti kao poticaj za aktivnu konstrukciju znanja učenika, umjesto da služi kao sredstvo pasivnog prijenosa znanja. U skladu s navedenim provedeno je istraživanje, opisano u ovome radu, u svrhu utvrđivanja utjecaja aktivnosti podučavanja Informatike bez računala (engl. *Computer Science Unplugged*) na usvajanje algoritma *bubble sort* kao jedne od metoda podučavanja koja potiče aktivno korištenje vizualizacije. Istraživanje je provedeno u obliku kvazi-eksperimenta u osnovnim i srednjim školama grada Splita. Sudionici su podijeljeni u dvije skupine, eksperimentalnu (CS aktivnost podučavanja) i kontrolnu (klasičan način podučavanja). U sklopu istraživanja sudionici su rješavali predtest, međutest i posttest čijom se analizom došlo do sljedećih rezultata: primjena CS aktivnosti ne utječe značajno na neposredni učinak učenika u usvajanju algoritma *bubble sort*, no utječe pozitivno na retenciju istoga, i to statistički značajno kod učenika osnovnih škola, dok kod učenica nema tako velik utjecaj.

Ključne riječi: algoritamska vizualizacija, CS aktivnosti, algoritam *bubble sort*

Rad je pohranjen u knjižnici Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu.

Rad sadrži: 55 stranica, 26 grafičkih prikaza, 18 tablica i 22 literaturna navoda.

Izvornik je na hrvatskom jeziku.

Mentor: **doc. dr. sc. Monika Mladenović,** *docent Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu*

Ocjenjivači: **doc. dr. sc. Monika Mladenović,** *docent Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu*

doc. dr. sc. Divna Krpan, *docent Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu*

doc. dr. sc. Goran Zaharija, *docent Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu*

Rad prihvaćen: rujan 2022.

Basic documentation card

Graduate thesis

University of Split
Faculty of Science
Department of computer science
Ruđera Boškovića 33, 21000 Split, Croatia

Teaching sort algorithm using CS unplugged activities

Lucija Medak

ABSTRACT

Algorithm visualization (AV) technology should be a stimulating teaching tool for the active construction of students' knowledge, rather than being an instrument for the passive transfer of teacher's knowledge. With that in mind, the research described in this paper was conducted to determine whether Computer Science (CS) Unplugged, as one of the teaching methods that encourages students' active use of visualization, has an impact on learning bubble sort. The research was conducted in the form of a quasi-experiment in primary and secondary schools in the city of Split. The participants were divided into two groups, experimental (CS Unplugged teaching method) and control (classic teaching method). As part of the research, the participants took a pre-test, a mid-test, and a post-test. Analysis of those tests led to the following results: CS Unplugged does not significantly affect the immediate students' knowledge of bubble sort, but it has a positive effect on the retention of the same, and that effect is statistically significant among primary school students.

Keywords: AV technology, CS Unplugged, bubble sort

Thesis deposited in library of Faculty of science, University of Split

Thesis consists of: 55 pages, 26 figures, 18 tables and 22 references

Original language: Croatian

Mentor: **Monika Mladenović, Ph.D.** *Assistant Professor of Faculty of Science, University of Split*

Reviewers: **Monika Mladenović, Ph.D.** *Assistant Professor of Faculty of Science, University of Split*

Divna Krpan, Ph.D. *Assistant Professor of Faculty of Science, University of Split*

Goran Zaharija, Ph.D. *Assistant Professor of Faculty of Science, University of Split*

Thesis accepted: September 2022

IZJAVA

kojom izjavljujem pod punom materijalnom i moralnom odgovornošću da sam diplomski rad s naslovom *Poučavanje algoritma sortiranja bez računala* izradila samostalno pod voditeljstvom doc. dr. sc. Monike Mladenović. U radu sam primijenila metodologiju znanstveno-istraživačkog rada i koristila literaturu koja je navedena na kraju diplomskog rada. Tuđe spoznaje, stavove, zaključke, teorije i zakonitosti koje sam izravno ili parafrazirajući navela u diplomskom radu na uobičajen, standardan način citirala sam i povezala fusnotama s korištenim bibliografskim jedinicama. Rad je pisan u duhu hrvatskog jezika.

Studentica

Lucija Medak

Zahvala

Zahvaljujem svojoj mentorici, doc. dr. sc. Moniki Mladenović, što mi je omogućila provedbu ovog iznimno zanimljivog istraživanja te na svom uloženom trudu, potrošenom vremenu i pruženoj pomoći pri provedbi istoga.

Sadržaj

Uvod 1

1. Pregled područja 2

1.1. Korištenje vizualizacije u nastavi 2

1.2. Aktivnosti podučavanja Informatike bez računala 3

1.3. Sortiranje zamjenom susjednih elemenata 4

2. Metodologija istraživanja 5

2.1. Predmet i cilj istraživanja 5

2.1.1. Istraživačka pitanja 5

2.2. Sudionici 5

2.3. Kontekst istraživanja 8

2.4. Mjerni instrumenti i analiza podataka 10

3. Rezultati 15

3.1. Rezultati učenika osnovnih škola 15

3.1.1. Ujednačenost skupina 16

3.1.2. Usporedba učinka učenika u usvajanju algoritma sortiranja prema načinu podučavanja 16

3.1.3. Usporedba retencije algoritma sortiranja prema načinu podučavanja 18

3.1.4. Usporedba učinka učenika ujednačenih po sposobnosti rješavanja problema u usvajanju algoritma sortiranja prema načinu podučavanja 19

3.1.5. Usporedba retencije algoritma sortiranja kod učenika istog spola prema načinu podučavanja 20

3.2. Rezultati učenika srednjih škola 22

3.2.1. Ujednačenost skupina 22

3.2.2. Usporedba učinka učenika u usvajanju algoritma sortiranja prema načinu podučavanja 23

3.2.3. Usporedba retencije algoritma sortiranja prema načinu podučavanja 24

3.2.4. Usporedba učinka učenika ujednačenih po sposobnosti rješavanja problema u usvajanju algoritma sortiranja prema načinu podučavanja 26

3.2.5. Usporedba retencije algoritma sortiranja kod učenika istog spola prema načinu podučavanja 27

3.3. Kvalitativna analiza istraživanja 29

3.3.1. Uočene miskoncepcije 29

3.3.2. Komentari učenika 32

4. Rasprava i preporuke za nastavu 34

4.1. Ograničenja istraživanja 36

Zaključak 37

Literatura 38

Sažetak 41

Summary 42

Popis slika i tablica 43

Prilozi 45

Uvod

Prilikom učenja novih koncepata stvaramo nove ili prilagođavamo već postojeće mentalne modele (Norman, 1986). Kako bismo mentalni model učinili što ispravnijim i održivijim, poželjno bi bilo da upoznavanje karakteristika novog koncepta započnemo konkretnom reprezentacijom istih, potom prijeđemo na slikovnu reprezentaciju, a završimo apstraktnom reprezentacijom koncepta. Ovaj proces odgovara trima fazama reprezentacije stvarnosti (Bruner, 1966): akcijskoj, ikoničkoj i simboličkoj. Programiranje u tekstualnim programskim jezicima koristi samo zadnju, simboličku, fazu reprezentacije stvarnosti što učenicima otežava proces učenja novih koncepata zbog prevelike razine apstrakcije kojom su koncepti prikazani. Prema Piagetu (1952) četvrti, najviši, stupanj kognitivnog razvoja pojavljuje se oko 12. godine života kada se kod djece počinje razvijati apstraktno mišljenje. Stoga podučavanje programiranja, pogotovo u osnovnoj školi, predstavlja velik izazov zbog visoke razine apstrakcije koncepata računarske znanosti čije razumijevanje zahtijeva razvijeno apstraktno mišljenje. Kako onda podučavati učenike, koji još nemaju razvijeno apstraktno mišljenje, programiranju koje to od njih zahtijeva? Jedna od opcija je vizualizacija, metoda podučavanja kojom se smanjuje razina apstrakcije podučavanih koncepata jer koristi ikoničku fazu reprezentacije stvarnosti za prikaz istih. Time se učenicima pomaže u stvaranju ispravnih mentalnih modela (Yehezkel, Ben-Ari, & Dreyfus, 2005). Današnji učenici pripadaju generaciji „digitalnih urođenika“ koji preferiraju učenje kroz igru (Prensky, 2001) i korištenje induktivnog zaključivanja (Naps, i dr., 2003). CS aktivnosti (engl. *Computer Science Unplugged*) predstavljaju vrstu vizualizacije koja odgovara pristupu učenju današnjih učenika pa je u sklopu ovoga rada istražen utjecaj korištenja CS aktivnosti kao pomoći u lakšem svladavanju algoritma *bubble sort*. U prvom poglavlju rada opisan je pregled područja te su navedeni rezultati nekih od istraživanja na ovu temu. U drugom poglavlju detaljno je opisana metodologija istraživanja, dok su u trećem poglavlju navedeni svi rezultati dobivenim analizom prikupljenih podataka, kao i kvalitativna analiza provedenog istraživanja. Četvrto poglavlje obuhvaća interpretaciju rezultata istraživanja, u sklopu kojeg su navedena ograničenja istraživanja te preporuke za korištenje CS aktivnosti u podučavanju algoritama sortiranja.

1. Pregled područja

U ovome poglavlju opisan je teorijski okvir provedenog istraživanja te su u sklopu istoga navedena neka od istraživanja na istu ili sličnu temu, uz naglasak na dobivene rezultate.

1.1. Korištenje vizualizacije u nastavi

Algoritamska vizualizacija slikovno prikazuje rad određenog algoritma, čime smanjuje razinu apstrakcije istoga pa se često koristi kao metoda podučavanja apstraktnih koncepata programiranja. Unatoč tome, korištenje vizualizacije u nastavi samo po sebi ne utječe na bolje usvajanje podučavanih apstraktnih koncepata. Ključnu ulogu u pozitivnom ishodu korištenja vizualizacije ima aktivni angažman učenika (Hundhausen, Douglas, & Stasko, 2002; Grissom, McNally, & Naps, 2003; Blumenkrants, Starovisky, & Shamir, 2006). Stoga, za uspješnu primjenu u edukacijske svrhe odabrana metoda vizualizacije trebala bi imati što više sljedećih karakteristika (Naps, i dr., 2002):

1. dostupan izvor pomoći u tumačenju vizualizacije kako bi učenici lakše povezali podučavani koncept sa slikovnim prikazom istoga,
2. slikovni prikaz prilagodljiv razini znanja učenika radi smanjenja njihovog kognitivnog opterećenja,
3. omogućen prikaz podučavanog koncepta na više načina pri čemu su različiti prikazi međusobno usklađeni,
4. uključene informacije o procesu izvršavanja podučavanog algoritma, kao i učinkovitosti istoga,
5. omogućeno vraćanje na prethodne korake, ali i predviđanje idućih koraka podučavanog algoritma,
6. vremenski prilagodljivo izvršavanje podučavanog algoritma,
7. podržano stvaranje vlastitih slikovnih prikaza od strane učenika radi boljeg uvida u ključne karakteristike podučavanog koncepta,
8. omogućen unos vlastitih primjera ulaznih podataka,
9. uključena pitanja o podučavanom konceptu pomoću kojih se pažnja učenika usmjerava na bitne detalje,
10. dostupne povratne informacije o razini usvojenosti podučavanog koncepta te

11. uključena popratna objašnjenja slikovnog prikaza podučavanog koncepta.

Suradničko učenje, kao i programiranje u paru, metode su podučavanja koje se mogu koristiti u sklopu nastave predmeta Informatike. Za postizanje pozitivnog utjecaja suradničkog učenja na usvajanje gradiva, učenici moraju međusobno razmjenjivati informacije i nove spoznaje o gradivu, biti koordinirani, imati dobro definiranu podjelu rada, pri čemu je svatko orijentiran na svoj dio zadatka koji mora odraditi, te se moraju međusobno dobro razumjeti (Meier, Spada, & Rummel, 2007). Prema tome, suradničko učenje dodaje novu dimenziju korištenju vizualizacije u podučavanju programiranja i to u pozitivnom smislu (Myller, Laakso, & Korhonen, 2007; Myller, Bednarik, Sutinen, & Ben-Ari, 2009).

1.2. Aktivnosti podučavanja Informatike bez računala

Aktivnosti podučavanja Informatike bez računala (engl. *Computer Science Unplugged*) predstavljaju skup aktivnosti za podučavanje različitih uzrasta učenika o brojnim konceptima računarske znanosti, bez potrebe za korištenjem digitalne opreme i učenjem programiranja (Bell & Vahrenhold, 2018). U današnje vrijeme CS aktivnosti dobivaju sve veću pozornost radi svoje usklađenosti s pristupom radu današnjih učenika, koja se očituje kroz glavne karakteristike CS aktivnosti, a to su konstruktivistički pristup učenju kroz igru te kratke i jednostavne upute (Bell & Vahrenhold, 2018). Prema taksonomiji uključenosti (Naps, i dr., 2002), CS aktivnosti obuhvaćaju četiri razine uključenosti učenika u korištenju vizualizacije, i to gledanja, odgovaranja, mijenjanja te izrade, dok klasičan način podučavanja korišten u ovome istraživanju obuhvaća dvije razine uključenosti učenika (gledanje i odgovaranje). Unatoč tome, ne postoji puno istraživanja koja su potvrdila učinkovitost primjene CS aktivnosti u školskom okruženju. Feaster, Segars, Wahba i Hallstrom (2011) u svome su istraživanju provedenom s učenicima srednje škole otkrili kako pripremljene CS aktivnosti nisu poboljšale usvajanje podučavanih koncepata, što su pripisali manjku zainteresiranosti učenika za uključenost u same aktivnosti. Thies i Vahrenhold (2012) u svome su istraživanju provedenom s učenicima osnovnih škola uočili da primjena CS aktivnosti ne zadovoljava sve razine Bloomove taksonomije znanja (Bloom, Engelhart, Furst, Hill, & Krathwohl, 1956), ali su utvrdili da primjena istih ima pozitivan utjecaj na upoznavanje novih koncepata računarske znanosti, odnosno da je primjena CS aktivnosti opravdana u uvodnim satima programiranja.

1.3. Sortiranje zamjenom susjednih elemenata

Iako se u kurikulumu za nastavni predmet Informatike (Ministarstvo znanosti i obrazovanja, 2018) u domeni „računalno razmišljanje i programiranje“ za osnovne škole nigdje ne spominje konkretan algoritam sortiranja kojega bi učenici trebali usvojiti, većina nastavnika odabire algoritam sortiranja zamjenom susjednih elemenata (engl. *bubble sort*) kao prvi algoritam sortiranja s kojim se učenici upoznaju. Unatoč činjenici da algoritam *bubble sort* nije najučinkovitiji algoritam sortiranja zbog svoje $O(n^2)$ složenosti, većina udžbenika Informatike za osmi razred osnovne škole također kao primjer algoritma sortiranja u lekciji o sortiranju opisuje algoritam *bubble sort*. S druge strane, u kurikulumu za nastavni predmet Informatike u domeni „računalno razmišljanje i programiranje“ za srednje škole navedeni su konkretni algoritmi sortiranja koje bi učenici do kraja trećeg razreda trebali usvojiti, a kao jedan od dva uvodna algoritma sortiranja naveden je algoritam *bubble sort*. Razlog tome vjerojatno je činjenica da se algoritam *bubble sort* smatra jednostavnim za razumijevanje i implementaciju (Astrachan, 2003). Zbog svega navedenog, algoritam *bubble sort* odabran je kao algoritam kojim će se u sklopu provedenog istraživanja podučavati učenike sortiranju. Bellström i Thorén (2009) proveli su pilot istraživanje o korištenju vizualizacije u svrhu podučavanja algoritma *bubble sort* te su prema dobivenim rezultatima utvrdili pozitivan utjecaj iste.

Zbog činjenice da je većina dosadašnjih istraživanja o korištenju vizualizacije provedena uz primjenu nekog od softverskih alata za vizualizaciju te malog broja istraživanja provedenih na temu korištenja CS aktivnosti u podučavanju algoritama sortiranja, u sklopu ovoga rada provedeno je jedno takvo istraživanje čiji je detaljan opis dan u nastavku.

2. Metodologija istraživanja

U sklopu ovoga rada provedeno je istraživanje u obliku kvazi-eksperimenta (Cohen, Manion, & Morrison, 2013). Za potrebe istraživanja odabran je neslučajni, prigodni uzorak (Cohen, Manion, & Morrison, 2013) populacije učenika osnovnih i srednjih škola grada Splita. Istraživanje je provedeno u prirodnom okruženju u razrednim odjelima sudionika istraživanja, u skladu s nastavnim planom i programom, odnosno kurikulumom za nastavni predmet Informatike (Ministarstvo znanosti i obrazovanja, 2018) za vrijeme redovnog školskog sata predmeta Informatike. Radi ujednačenosti provedbe nastavnog sata, sve sate u sklopu istraživanja održala je ista nastavnica. Svi materijali korišteni u ovome istraživanju priloženi su na kraju rada.

2.1. Predmet i cilj istraživanja

Predmet ovog istraživanja utjecaj je korištenja metoda vizualizacije u podučavanju algoritama koje potiču aktivnu ulogu učenika, a cilj je utvrditi učinkovitost primjene CS aktivnosti u podučavanju algoritma *bubble sort*.

2.1.1. Istraživačka pitanja

U skladu s navedenim ciljem istraživanja postavljena su sljedeća istraživačka pitanja:

1. Utječe li primjena CS aktivnosti na učinak učenika u usvajanju algoritma *bubble sort*?
2. Utječe li primjena CS aktivnosti na retenciju naučenog algoritma *bubble sort*?
3. Utječe li primjena CS aktivnosti na učinak učenika ujednačenih po sposobnosti rješavanja problema u usvajanju algoritma *bubble sort*?
4. Utječe li primjena CS aktivnosti na retenciju naučenog algoritma *bubble sort* u odnosu na spol učenika?

2.2. Sudionici

U istraživanju je sudjelovalo ukupno 204 učenika, od čega 77 učenika osnovnih škola, a 127 učenika srednjih škola. Kako je istraživanje provedeno u više etapa, neki učenici nisu

prisustvovali provedbi određenih aktivnosti pa su prilikom analize podataka u obzir uzeti samo oni učenici koji su sudjelovali u svim aktivnostima istraživanja.

Ukupno 67 učenika osmih razreda triju osnovnih škola s područja grada Splita sudjelovalo je u svim aktivnostima istraživanja, a njihova raspodjela po spolu prikazana je na Slika 2.1.

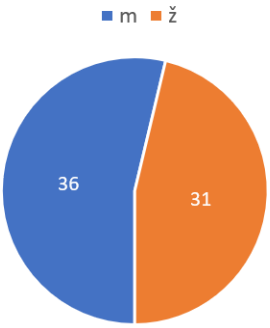

Slika 2.1 Raspodjela učenika osnovnih škola po spolu

Eksperimentalnu skupinu učenika osnovnih škola čine četiri razredna odjela s ukupno 45 učenika čija je raspodjela po spolu prikazana na Slika 2.2.

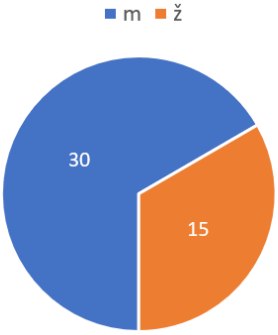

Slika 2.2 Raspodjela učenika osnovnih škola po spolu unutar Eksperimentalne skupine

Kontrolnu skupinu učenika osnovnih škola čine dva razredna odjela s ukupno 22 učenika čija je raspodjela po spolu prikazana na Slika 2.3.

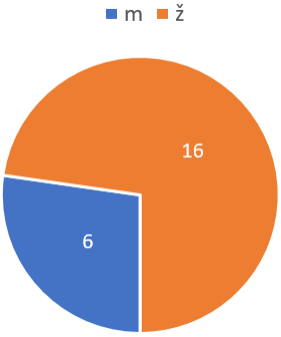

Slika 2.3 Raspodjela učenika osnovnih škola po spolu unutar Kontrolne skupine

Na isti način prikazana je raspodjela 111 učenika srednjih škola s područja grada Splita (Slika 2.4), među kojima su učenici jedne prirodoslovno-matematičke gimnazije, jedne prirodoslovne gimnazije te jedne strukovne škole.

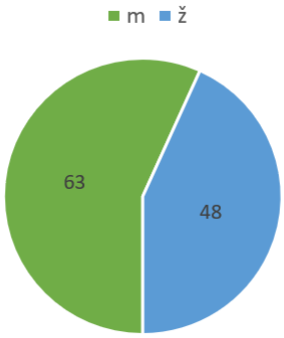

Slika 2.4 Raspodjela učenika srednjih škola po spolu

Eksperimentalnu skupinu učenika srednjih škola čine četiri razredna odjela s ukupno 74 učenika čija je raspodjela po spolu prikazana na Slika 2.5.

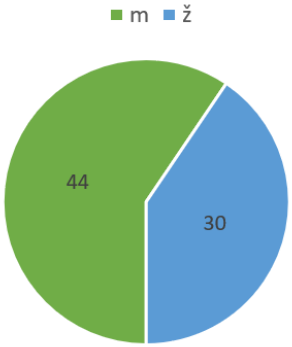

Slika 2.5 Raspodjela učenika srednjih škola po spolu unutar Eksperimentalne skupine

Kontrolnu skupinu učenika srednjih škola čine dva razredna odjela s ukupno 37 učenika čija je raspodjela po spolu prikazana na Slika 2.6.

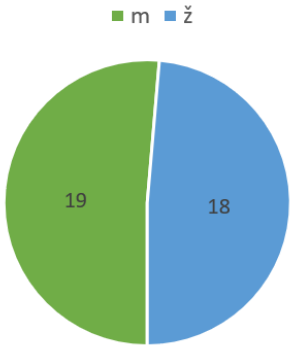

Slika 2.6 Raspodjela učenika srednjih škola po spolu unutar Kontrolne skupine

2.3. Kontekst istraživanja

Istraživanje je provedeno u šest osmih razreda triju osnovnih škola, jednom trećem razredu jedne strukovne škole, tri druga razreda jedne prirodoslovno-matematičke gimnazije te dva druga razreda jedne prirodoslovne gimnazije tijekom školske godine 2021./2022. Dva osma razreda dviju osnovnih škola podučavana su na klasičan način, čime pripadaju Kontrolnoj skupini ovog istraživanja, dok su ostali osmi razredi podučavani CS aktivnošću te pripadaju Eksperimentalnoj skupini istraživanja. Slična podjela napravljena je i kod učenika srednjih škola pa Kontrolnoj skupini pripadaju jedan drugi razred prirodoslovno-matematičke gimnazije i jedan drugi razred prirodoslovne gimnazije, dok ostali razredi pripadaju Eksperimentalnoj skupini.

Podučavanje se temeljilo na objašnjavanju algoritma *bubble sort*, uz primjenu istoga na brojevnim nizovima. Eksperimentalna skupina podučavana je CS aktivnošću na način da su učenici podijeljeni u parove, nakon čega je svaki par dobio deset kartica i list papira na kojemu su dane upute za rad, u sklopu kojih je bio napisan algoritam *bubble sort* (priloženo radu pod *Upute za Eksperimentalnu skupinu*). Na jednoj strani svake od kartica bio je zapisan po jedan broj, a na drugoj strani nalazio se po jedan simbol pomoću kojih bi učenici poredali kartice u zadani početni redoslijed elemenata brojevnog niza. Sam izgled kartica, kao i prikaz rada s istima prema priložnim uputama, moguće je pogledati na YouTube poveznici Bubble sort. Isti video prikazan je Eksperimentalnoj skupini učenika osnovnih škola radi pojašnjenja danih uputa za rad, dok su Eksperimentalnoj skupini učenika srednjih škola upute pojašnjene usmenim putem. Nakon toga učenici su započeli s radom u paru, pri čemu je jedan učenik u paru čitao dobivene upute, dok je drugi učenik sortirao dobivene kartice prema pročitanim uputama. Nastavnica je za to vrijeme provjeravala prate li učenici uspješno upute i postavljala pitanja vezana za rad algoritma kako bi dodatno potaknula njihovu aktivnu ulogu u svladavanju novoga gradiva.

Kontrolna skupina podučavana je na klasičan način, primjenom prezentacije na kojoj je bio prikazan algoritam *bubble sort* (priloženo radu pod *Upute za Kontrolnu skupinu*) i ploče koja je služila za praćenje zamjena elemenata niza. Objema skupinama dana su ista tri primjera brojevnog niza i to redom: [*74 98 45 22 67 14 90 32 1 51*], [*1 14 22 45 74 32 67 51 90 98*] te [*98 90 74 67 51 45 32 22 14 1*]. Navedeni primjeri brojevnih nizova Eksperimentalnoj skupini prikazani su pomoću simbola na spomenutim karticama (priloženo radu pod *Redoslijed simbola za Eksperimentalnu skupinu)*. Radi što

ujednačenijeg prikaza rada algoritma objema skupinama, zamjena dvaju elemenata niza Kontrolnoj je skupini simulirana brisanjem istih s njihovih trenutnih pozicija u nizu na ploči te upisivanjem na nove pozicije u nizu. U svrhu smanjenja pasivne uloge učenika Kontrolne skupine i ujednačavanja provedbe nastavnih sati nastavnica je, prilikom simulacije rada algoritma na ploči, učenicima postavljala pitanja vezana za rad algoritma.

Provedba istraživanja u svakom uključenom razrednom odjelu organizirana je kroz četiri aktivnosti, od kojih su tri odrađene u sklopu jednog školskog sata, dok je zadnja aktivnost odrađena dva tjedna nakon prve tri aktivnosti. Osim već opisane aktivnosti obrade gradiva, provedena su i tri testa, prilagođena dobi sudionika, koja su učenici rješavali na papiru. Za vrijeme provedbe istraživanja školski sat u osnovnim školama trajao je 45 minuta, a u srednjim školama 40 minuta. U skladu s tim, u nastavku su navedene sve aktivnosti, kao i njihovo trajanje, onim redoslijedom kojim su odrađene u sklopu istraživanja:

- (A1) provedba predtesta radi utvrđivanja jednakosti Eksperimentalne i Kontrolne skupine po sposobnosti rješavanja problema – prvih 15 minuta školskog sata u osmim razredima, odnosno 10 minuta u razredima srednjih škola,
- (A2) obrada gradiva – idućih 20 minuta školskog sata,
- (A3) provedba međutesta radi utvrđivanja razine usvojenosti obrađenog algoritma sortiranja – zadnjih 10 minuta školskog sata te
- (A4) provedba posttesta radi utvrđivanja razine retencije naučenog algoritma sortiranja – 2 tjedna nakon školskog sata na kojemu je gradivo obrađeno.

Aktivnosti A1 – A3 provedene su u periodu od 2. do 10. ožujka, a u periodu od 17. do 24. ožujka provedena je aktivnost A4. U periodu između provedbe aktivnosti A3 i aktivnosti A4 nastavnici s učenicima nisu ponavljali ni uvježbavali obrađeno gradivo kako ne bi utjecali na rezultate posttesta. Obzirom da su navedene aktivnosti odrađene u sklopu redovne nastave predmeta Informatike, istraživanje nije provedeno u istom periodu dana u svim razrednim odjelima što je moglo utjecati na rezultate provedenih testova. Radi etičnosti ispitivanja (Cohen, Manion, & Morrison, 2013), učenici nisu ocjenjivani ni na jednoj od navedenih aktivnosti. Iako učenici, radi lakše usporedbe njihovih rezultata na provedenim testovima, nisu rješavali testove anonimno, zajamčena im je povjerljivost te zaštita prikupljenih podataka, čime se štiti njihovo pravo na privatnost (Cohen, Manion, & Morrison, 2013).

2.4. Mjerni instrumenti i analiza podataka

Mjerni instrumenti korišteni u ovom istraživanju su već spomenuti predtest, međutest i posttest te anketa. Svrha ankete bila je dobiti povratnu informaciju od sudionika u vezi provedbe nastavnog sata u vidu njihove subjektivne procjene iste. *Anketa* nije bila anonimna, ali je sudionicima napomenuto kako anketu mogu dobrovoljno ispuniti nakon što riješe međutest. Među učenicima osnovnih škola samo njih troje nije odgovorilo na prva četiri pitanja ankete, dok je komentar (peto, zadnje, pitanje ankete) ostavilo njih ukupno 15 (22.39%), od toga 9 učenika Kontrolne skupine. Od učenika srednjih škola, samo četvero njih nije popunilo anketu, a svoje mišljenje napisala su 32 učenika (28.83%), od toga 23 učenika Eksperimentalne skupine. Neki od komentara navedeni su u poglavlju 3.3.2 gdje je dana njihova kvalitativna analiza. Obzirom da je razdioba odgovora na prva tri pitanja ankete podjednaka u odnosu na pripadnost skupini u istraživanju, kao i u odnosu na dob učenika, daljnja analiza istih nije provedena. Jedina veća razlika uočena je kod odgovora na četvrto pitanje ankete („*Je li ti draži način rješavanja problema programiranjem (u Pythonu) ili na način na koji se danas radilo (bez računala)?*“) i to između učenika osnovnih škola kojima je najčešće zaokružen odgovor bio „*Ne, draže mi je rješavanje problema bez računala*“ te učenika srednjih škola kojima je najčešće zaokružen odgovor bio „*Da, draže mi je programiranje (u Pythonu)*“. Navedena razlika u skladu je s dobi učenika, odnosno njihovom sposobnosti apstraktnog mišljenja koja je za rješavanje problema programiranjem itekako potrebna.

Predtest korišten u ovom istraživanju sastoji se od 10 zadataka logičkog tipa kojima se ispituje sposobnost rješavanja problema vezanih za sortiranje. Za uspješno rješavanje predtesta nije potrebno nikakvo znanje programiranja, a sam test osmišljen je u svrhu utvrđivanja jednakosti Eksperimentalne i Kontrolne skupine istraživanja. Obzirom da predtest ne ispituje znanje programiranja, istu verziju testa rješavali su svi sudionici istraživanja, uz jedinu razliku u vremenskom trajanju provedbe testa koja je za učenike srednjih škola iznosila 10 minuta, a za učenike osnovnih škola 15 minuta. Cronbachov alfa koeficijent za 16 čestica testa dao je vrlo dobru pouzdanost mjerne ljestvice predtesta (0.827) za učenike osnovnih škola, odnosno prihvatljivu pouzdanost mjerne ljestvice predtesta (0.757) za učenike srednjih škola. Slika 2.7 prikazuje graf s indeksima težine čestica predtesta za učenike osnovnih škola iz kojega se može iščitati da su prva tri zadatka lagana, dok su ostali zadaci predtesta umjerene težine.

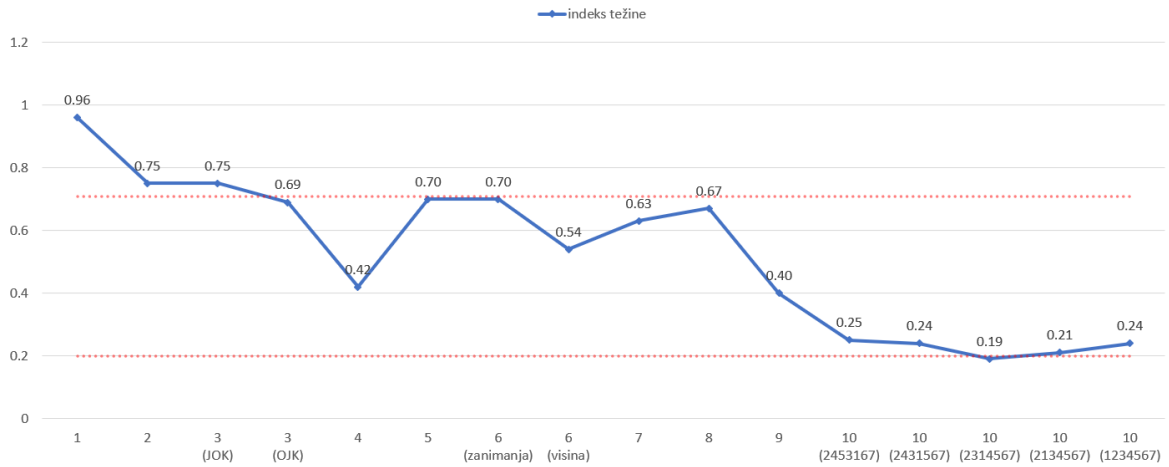

Slika 2.7 Indeks težine čestica predtesta (OŠ)

Slika 2.8 prikazuje graf s indeksima težine čestica predtesta za učenike srednjih škola iz kojega je vidljivo da je učenicima srednjih škola test bio lakši nego učenicima osnovnih škola jer samo zadnja dva zadataka pripadaju kategoriji zadataka umjerene težine, što je u skladu s dobi učenika.

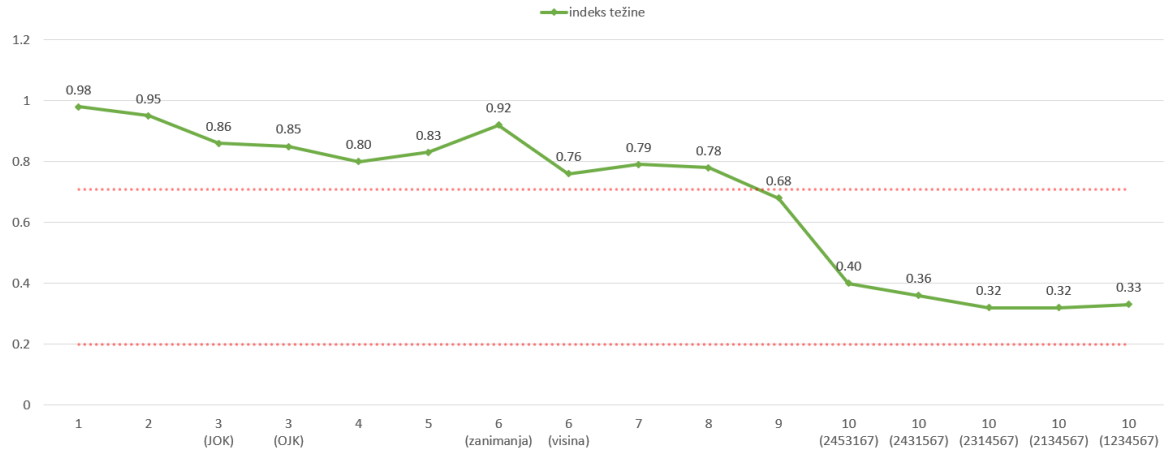

Slika 2.8 Indeks težine čestica predtesta (SŠ)

Međutest za učenike osnovnih škola sastoji se od ukupno 4 zadatka, tri tipa višestrukog izbora i jedan tipa nadopunjavanja, kojima se ispituje sposobnost primjene algoritma *bubble sort* na zadanom brojevnom nizu. Obzirom da ni Eksperimentalna ni Kontrolna skupina nije podučavana programiranju algoritma, zadaci međutesta ne ispituju sposobnost programiranja algoritma *bubble sort*, već isključivo poznavanje samog algoritma. Zbog kratkog vremenskog perioda podučavanja algoritma (20 minuta), ali i činjenice da je test pisan neposredno nakon obrade gradiva, zadaci međutesta osmišljeni su po uzoru na primjere korištene za vrijeme podučavanja algoritma *bubble sort* te su učenicima navedene prve dvije zamjene susjednih elemenata zadanog niza. Cronbachov alfa koeficijent za 7

čestica testa dao je vrlo dobru pouzdanost mjerne ljestvice međutesta (0.851) za učenike osnovnih škola. Slika 2.9 prikazuje graf s indeksima težine čestica međutesta za učenike osnovnih škola iz kojega je vidljivo da su svi zadaci međutesta umjerene težine.

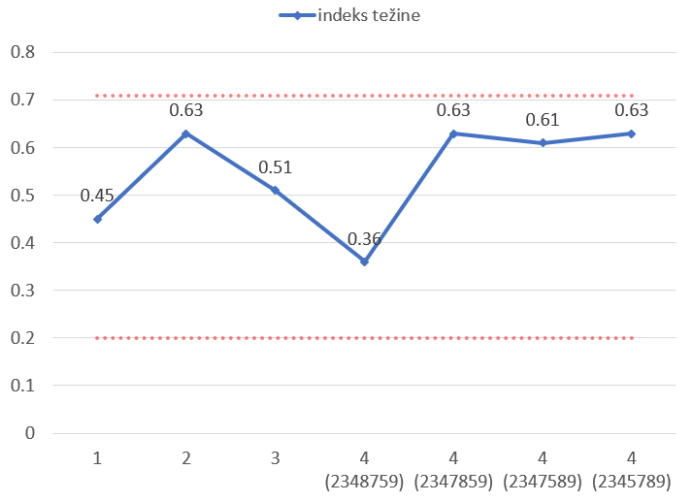

Slika 2.9 Indeks težine čestica međutesta (OŠ)

Posttest za učenike osnovnih škola sadrži ista 4 zadatka kao i međutest za učenike osnovnih škola, pri čemu je u zadacima tipa višestrukog izbora izmijenjen redoslijed ponuđenih odgovora, a prve dvije zamjene susjednih elemenata zadanog niza više nisu navedene. Svrha posttesta u ovom istraživanju bila je utvrditi razinu retencije naučenog algoritma *bubble sort* s ciljem uočavanja potencijalne razlike u odnosu na korištenu metodu podučavanja. Cronbachov alfa koeficijent za 9 čestica testa dao je izvrsnu pouzdanost mjerne ljestvice posttesta (0.918) za učenike osnovnih škola. Slika 2.10 prikazuje graf s indeksima težine čestica posttesta za učenike osnovnih škola iz kojega je vidljivo da su svi zadaci posttesta umjerene težine.

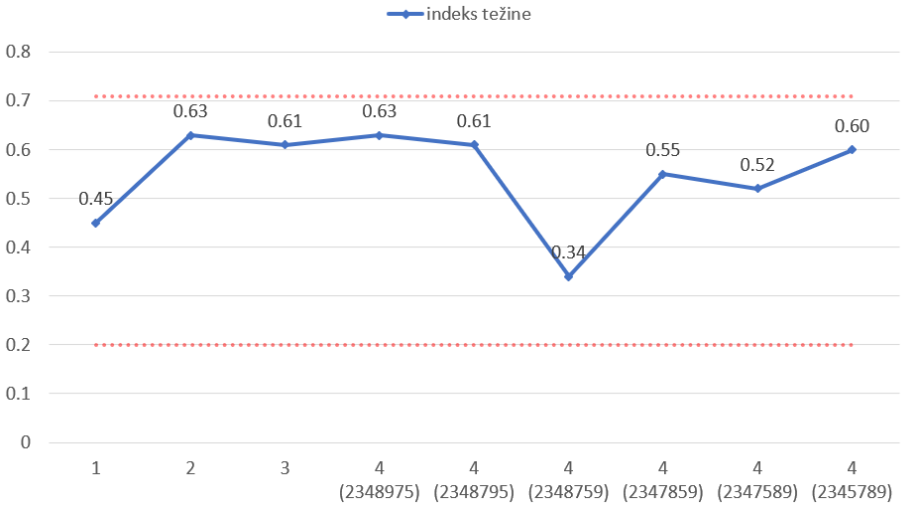

Slika 2.10 Indeks težine čestica posttesta (OŠ)

Tablica 2.1 prikazuje metrijske karakteristike opisanih testova za učenike osnovnih škola. Stupac *Max* predstavlja najveći ostvaren broj bodova na pojedinom testu, što je ujedno i ukupan broj bodova na tom testu.

Tablica 2.1 Metrijske karakteristike testova (OŠ)

Test	N	Aritmetička sredina	Medijan	Standardna devijacija	Min	Max	Broj čestica	Cronbach's α	Kolmogorov-Smirnov test
predtest	67	7.43	8	2.618	1	12	16	0.827	0.033
međutest	67	3.81	4	2.5	0	7	7	0.851	0.000
posttest	67	4.94	6	3.45	0	9	9	0.918	0.000

Međutest za učenike srednjih škola napravljen je po uzoru na međutest za učenike osnovnih škola, uz prilagodbu dobi učenika, a sastoji se od ukupno 6 zadataka, tri tipa višestrukog izbora i tri tipa nadopunjavanja. Prva tri zadatka vezana su uz isti niz brojeva zadan na početku testa, a u preostalim zadacima zadani su različiti nizovi brojeva. Za prvih pet zadataka međutesta navedene su prve dvije zamjene susjednih elemenata zadanih nizova, dok su u šestom zadatku navedene prve tri zamjene susjednih elemenata zadanog niza. Cronbachov alfa koeficijent za 12 čestica testa dao je vrlo dobru pouzdanost mjerne ljestvice međutesta (0.816) za učenike srednjih škola. Slika 2.11 prikazuje graf s indeksima težine čestica međutesta za učenike srednjih škola iz kojega je vidljivo da su drugi, treći i četvrti zadatak međutesta lagani, dok su ostali zadaci međutesta umjerene težine.

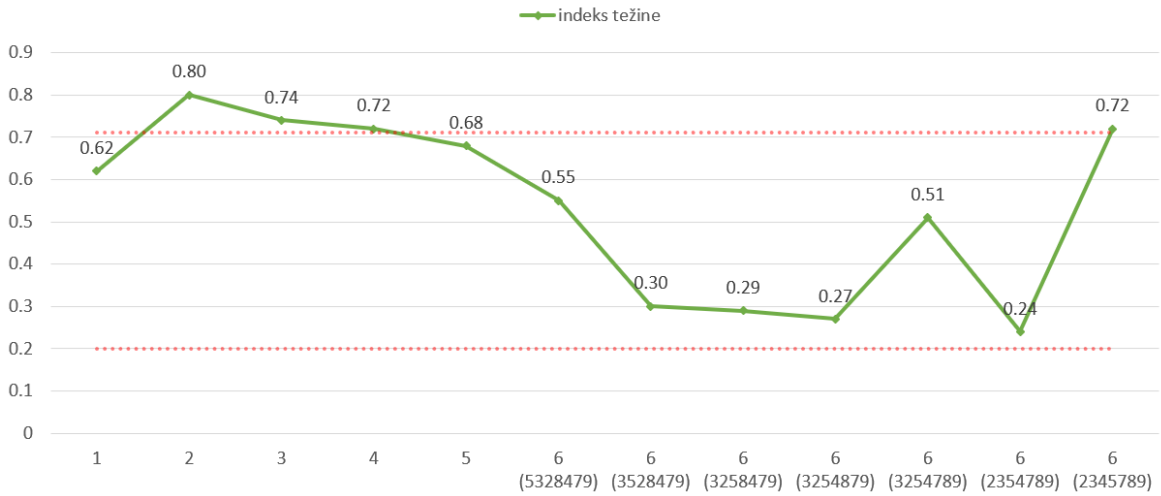

Slika 2.11 Indeks težine čestica međutesta (SŠ)

Posttest za učenike srednjih škola sadrži istih 6 zadataka kao i međutest za učenike srednjih škola, pri čemu je u zadacima tipa višestrukog izbora izmijenjen redoslijed ponuđenih odgovora, a početne zamjene susjednih elemenata zadanih nizova više nisu navedene. Cronbachov alfa koeficijent za 15 čestica testa dao je vrlo dobru pouzdanost mjerne ljestvice posttesta (0.897) za učenike srednjih škola. Slika 2.12 prikazuje graf s

indeksima težine čestica posttesta za učenike srednjih škola iz kojega je vidljivo da su drugi, treći, četvrti i peti zadatak posttesta lagani, dok su prvi i šesti zadatak posttesta umjerene težine. Isto tako, može se uočiti da su prva i zadnja čestica šestog zadatka lagane, što je u skladu s očekivanjima jer predstavljaju prvu zamjenu susjednih elemenata zadanog niza prema algoritmu *bubble sort*, odnosno sortiran niz. Vrijedi istaknuti kako je i kod učenika osnovnih škola i kod učenika srednjih škola u zadacima tipa višestrukog izbora na posttestu došlo do povećanja postotka točnih odgovora u odnosu na međutest ili je isti ostao nepromijenjen, dok je u zadacima tipa nadopunjavanja na posttestu došlo do smanjenja postotka točnih odgovora u odnosu na međutest.

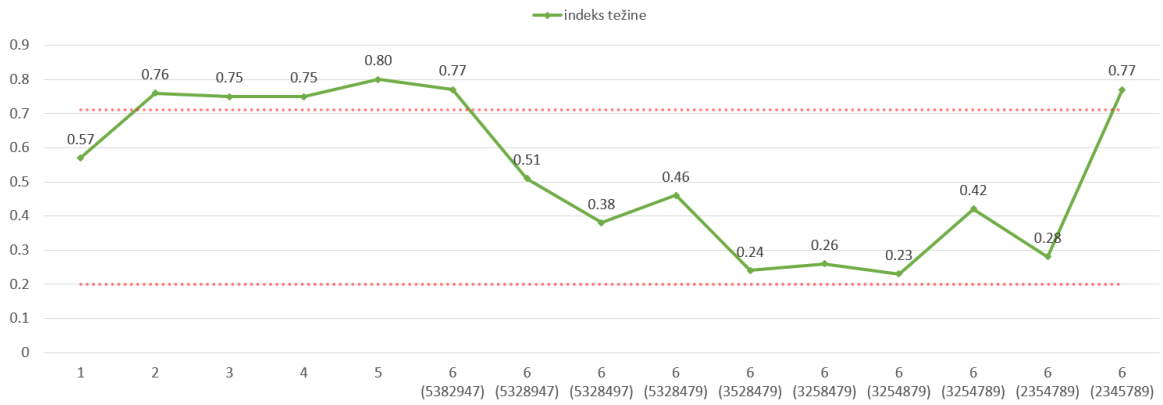

Slika 2.12 Indeks težine čestica posttesta (SŠ)

Tablica 2.2 prikazuje metrijske karakteristike opisanih testova za učenike srednjih škola. Stupac *Max* predstavlja najveći ostvaren broj bodova na pojedinom testu, što je ujedno i ukupan broj bodova na tom testu.

Tablica 2.2 Metrijske karakteristike testova (SŠ)

Test	N	Aritmetička sredina	Medijan	Standardna devijacija	Min	Max	Broj čestica	Cronbach's α	Kolmogorov-Smirnov test
predtest	111	9.59	10	1.739	5	12	16	0.757	0.000
međutest	111	6.45	6	3.162	1	12	12	0.816	0.000
posttest	111	7.94	7	4.347	0	15	15	0.897	0.000

Podaci prikupljeni ovim istraživanjem analizirani su kvantitativno i kvalitativno, a rezultati analize opisani su u poglavlju 3. U kvantitativnoj analizi podataka rezultati učenika osnovnih škola obrađeni su odvojeno od rezultata učenika srednjih škola, dok je u kvalitativnom dijelu analize, među ostalim, dana usporedba svih sudionika istraživanja.

3. Rezultati

Obzirom da prema Kolmogorov-Smirnov testu podaci dobiveni iz predtesta, međutesta i posttesta nemaju normalnu razdiobu niti kod učenika osnovnih škola (Tablica 2.1) niti kod učenika srednjih škola (Tablica 2.2), za analizu podataka provedenih testova korišteni su neparametrijski Mann-Whitney U test i Wilcoxonov test. Kao što je već ranije navedeno, testovi su prilagođeni dobi sudionika pa su iz tog razloga rezultati učenika osnovnih škola analizirani odvojeno od rezultata učenika srednjih škola. Mann-Whitney U test korišten je za provjeru ujednačenosti Eksperimentalne i Kontrolne skupine na predtestu, kao i za utvrđivanje (ne)postojanja statistički značajnih razlika između rezultata Eksperimentalne i Kontrolne skupine na međutestu te na posttestu. Wilcoxonov je test pak korišten za utvrđivanje (ne)postojanja statistički značajnih razlika između rezultata na međutestu i posttestu unutar Eksperimentalne, odnosno Kontrolne skupine, kao i za utvrđivanje (ne)postojanja statistički značajnih razlika između rezultata Eksperimentalne i Kontrolne skupine učenika ujednačenih po sposobnosti rješavanja problema. Uz navedeno, prikazane su i deskriptivne statistike predtesta, međutesta i posttesta učenika osnovnih i srednjih škola.

3.1. Rezultati učenika osnovnih škola

U ovome poglavlju navedeni su rezultati analize podataka dobivenih iz predtesta, međutesta i posttesta za učenike osnovnih škola. Obzirom da su u sklopu istraživanja postavljena četiri istraživačka pitanja, rezultati analize dobivenih podataka podijeljeni su u četiri pripadajuće cjeline. Prilikom analize dobivenih podataka, međutest i posttest za učenike osnovnih škola podijeljeni su na dva dijela i to tako da prvi dio međutesta, odnosno posttesta predstavljaju prva tri zadatka koja su tipa višestrukog izbora, a drugi dio međutesta, odnosno posttesta predstavlja zadnji zadatak koji je tipa nadopunjavanja. Navedeno je napravljeno kako bi se lakše analizirali dijelovi testa koji provjeravaju istu razinu znanja učenika.

3.1.1. Ujednačenost skupina

Rezultati predtesta učenika osnovnih škola iskorišteni su za utvrđivanje jednakosti Eksperimentalne i Kontrolne skupine učenika osnovnih škola. Prema rezultatima Mann-Whitney U testa (Tablica 3.2) nije utvrđena statistički značajna razlika između Eksperimentalne i Kontrolne skupine učenika osnovnih škola u sposobnosti rješavanja problema, čime je omogućena daljnja analiza podataka dobivenih iz međutesta i posttesta te će u istoj obje skupine biti tretirane kao jednake. Tablica 3.1 prikazuje deskriptivnu statistiku predtesta Eksperimentalne i Kontrolne skupine učenika osnovnih škola iz koje se može iščitati kako je Kontrolna skupina ostvarila prosječno bolji rezultat u odnosu na Eksperimentalnu skupinu, što će biti slučaj i kod rezultata međutesta te posttesta.

Tablica 3.1 Deskriptivna statistika predtesta (OŠ)

Skupina	N	AS	Mdn	Mod	Min	Max
E	45	7.31	7	7	2	12
K	22	7.68	8.5	9	1	12

3.1.2. Usporedba učinka učenika u usvajanju algoritma sortiranja prema načinu podučavanja

Mann-Whitney U test pokazao je statistički značajnu razliku između Eksperimentalne i Kontrolne skupine učenika osnovnih škola na međutestu u cjelini, kao i u oba dijela međutesta, i to u korist Kontrolne skupine koja je statistički značajno bolje riješila međutest u odnosu na Eksperimentalnu skupinu, dok na posttestu ta razlika nije utvrđena. Rezultati Mann-Whitney U testa za sve testove provedene u razrednim odjelima osnovnih škola dani su u Tablica 3.2.

Tablica 3.2 Rezultati Mann-Whitney U testa (OŠ)

Postotak ostvarenih bodova	Mann-Whitney U	Z	p
Predtest	439.000	-0.753	**0.452**
1. dio međutesta	341.000	-2.125	**0.034**
2. dio međutesta	258.000	-3.308	**0.001**
Međutest	265.000	-3.107	**0.002**
1. dio posttesta	379.500	-1.604	**0.109**
2. dio posttesta	487.500	-0.104	**0.917**
Posttest	453.500	-0.564	**0.573**

U Tablica 3.3 dana je deskriptivna statistika međutesta Eksperimentalne i Kontrolne skupine učenika osnovnih škola iz koje je vidljivo da je Kontrolna skupina ostvarila prosječno bolji rezultat od Eksperimentalne skupine. Najčešće ostvaren broj bodova u

Kontrolnoj skupini učenika osnovnih škola na međutestu bio je 5 bodova, dok je u Eksperimentalnoj skupini bio 0 bodova.

Tablica 3.3 Deskriptivna statistika međutesta (OŠ)

Skupina	N	AS	Mdn	Mod	Min	Max
E	45	3.13	4	0	0	7
K	22	5.18	5	5	0	7

Tablica 3.4 prikazuje deskriptivnu statistiku posttesta Eksperimentalne i Kontrolne skupine učenika osnovnih škola koja ukazuje na znatno poboljšanje prosječnog rezultata Eksperimentalne skupine u odnosu na prosječni rezultat Eksperimentalne skupine na međutestu, dok to kod Kontrolne skupine nije slučaj. Unatoč tome, Kontrolna skupina učenika osnovnih škola i na posttestu je ostvarila prosječno bolji rezultat od Eksperimentalne skupine.

Tablica 3.4 Deskriptivna statistika posttesta (OŠ)

Skupina	N	AS	Mdn	Mod	Min	Max
E	45	4.82	6	9	0	9
K	22	5.18	5.5	9	0	9

Sve navedeno vidljivo je i na grafu prikazanom Slika 3.1 koji daje detaljniji prikaz postotaka ostvarenih bodova na međutestu i posttestu učenika osnovnih škola. Na istome grafu može se uočiti kako je Eksperimentalna skupina učenika osnovnih škola samo na drugom dijelu posttesta ostvarila prosječno bolji rezultat od Kontrolne skupine.

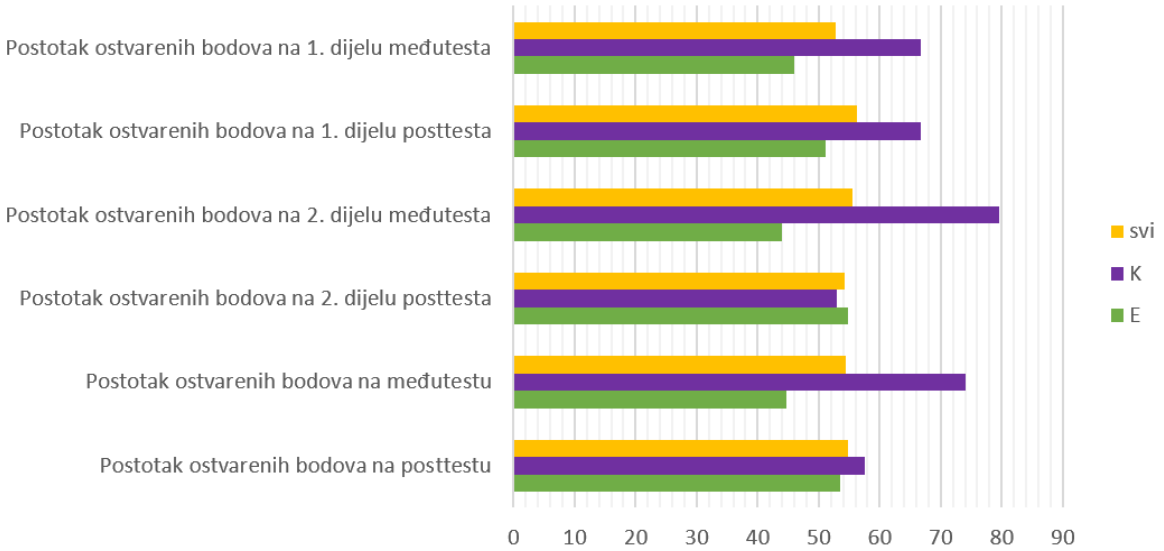

Slika 3.1 Postoci ostvarenih bodova na međutestu i posttestu (OŠ)

3.1.3. Usporedba retencije algoritma sortiranja prema načinu podučavanja

Wilcoxonov test dao je samo jednu statistički značajnu razliku kod učenika osnovnih škola, i to između rezultata Kontrolne skupine na drugom dijelu međutesta i posttesta, što je vidljivo iz Tablica 3.5 u kojoj su navedeni i ostali rezultati Wilcoxonova testa. Kontrolna skupina učenika osnovnih škola statistički je značajno lošije riješila zadnji zadatak posttesta u odnosu na rezultat ostvaren na istom zadatku međutesta.

Tablica 3.5 Rezultati Wilcoxonova testa (OŠ)

	Postotak ostvarenih bodova (Posttest - Međutest)	Z	p
Svi	**1. dio**	-0.702	**0.483**
	2. dio	-0.029	**0.977**
	Ukupno	-0.151	**0.880**
E	**1. dio**	-0.957	**0.339**
	2. dio	-1.503	**0.133**
	Ukupno	-1.417	**0.157**
K	**1. dio**	-0.058	**0.954**
	2. dio	-2.391	**0.017**
	Ukupno	-1.721	**0.085**

Zbog navedene statistički značajne razlike na Slika 3.2 prikazan je graf s postocima točnih odgovora Eksperimentalne i Kontrolne skupine učenika osnovnih škola na zadnjem zadatku međutesta i posttesta iz kojega se lako može iščitati spomenuta razlika. Svaki stupac grafa predstavlja jedan redak tablice koju su učenici u sklopu zadnjeg zadataka trebali popuniti. Osim toga, na grafu je vidljivo da je Eksperimentalna skupina zaista ostvarila prosječno bolji rezultat na posttestu u odnosu na međutest.

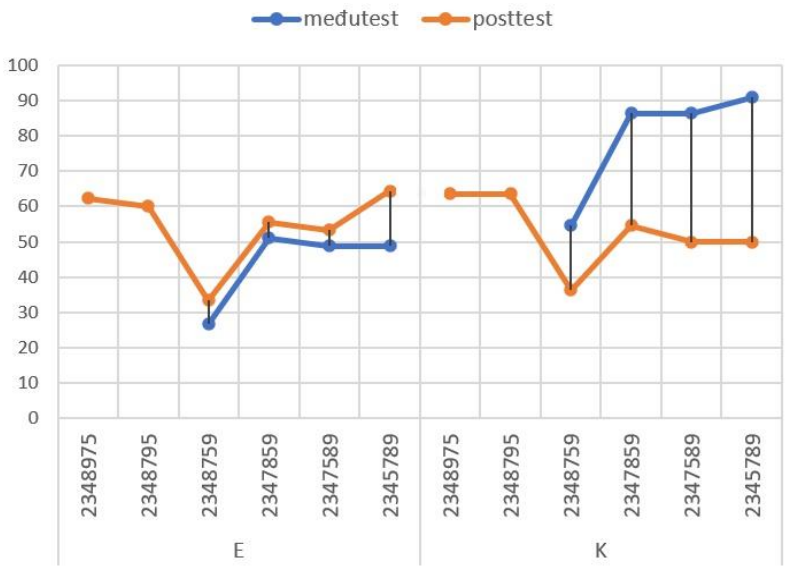

Slika 3.2 Postoci točnih odgovora na zadnjem zadatku međutesta i posttesta (OŠ)

3.1.4. Usporedba učinka učenika ujednačenih po sposobnosti rješavanja problema u usvajanju algoritma sortiranja prema načinu podučavanja

Kako bi se utvrdilo postoji li statistički značajna razlika između Eksperimentalne i Kontrolne skupine učenika osnovnih škola ujednačenih po sposobnosti rješavanja problema, proveden je dodatan Wilcoxonov test nad podacima međutesta i posttesta tih učenika. Ujednačavanje učenika napravljeno je na način da se svaki učenik Kontrolne skupine probao upariti s jednim od učenika Eksperimentalne skupine i to na način da se gledalo da njihov postotak ostvarenih bodova na predtestu bude jednak. Ako je među učenicima Eksperimentalne skupine postojalo više učenika s istim postotkom ostvarenih bodova na predtestu, izabran je onaj čiji je postotak ostvarenih bodova na međutestu bio čim bliži postotku ostvarenih bodova na međutestu učenika Kontrolne skupine. Rezultati provedenog Wilcoxonova testa za učenike osnovnih škola ujednačenih po sposobnosti rješavanja problema dani su u Tablica 3.6 iz koje je vidljivo da između Eksperimentalne i Kontrolne skupine tih učenika nema statistički značajnih razlika.

Tablica 3.6 Rezultati učenika ujednačenih po sposobnosti (OŠ)

Postotak ostvarenih bodova	Z	p
1. dio međutesta	0.000	**1.000**
2. dio međutesta	-1.745	**0.081**
Međutest	-1.260	**0.208**
1. dio posttesta	-0.360	**0.719**
2. dio posttesta	-1.524	**0.128**
Posttest	-1.380	**0.168**

Slika 3.3 prikazuje graf s postocima ostvarenih bodova Eksperimentalne i Kontrolne skupine učenika osnovnih škola ujednačenih po sposobnosti rješavanja problema na međutestu i posttestu. Na grafu se može uočiti kako je Kontrolna skupina na međutestu ostvarila prosječno bolji rezultat od Eksperimentalne skupine, dok je na posttestu situacija obrnuta, odnosno Eksperimentalna skupina na posttestu je ostvarila prosječno bolji rezultat od Kontrolne skupine. Isto tako, može se uočiti znatno pogoršanje prosječnog rezultata Kontrolne skupine na drugom dijelu posttesta u odnosu na prosječni rezultat ostvaren na istom dijelu međutesta. Kontrolna skupina učenika osnovnih škola ujednačenih po sposobnosti rješavanja problema statistički je značajno lošije riješila drugi dio posttesta u odnosu na isti dio međutesta ($Z = -2.559$, $p = 0.011$).

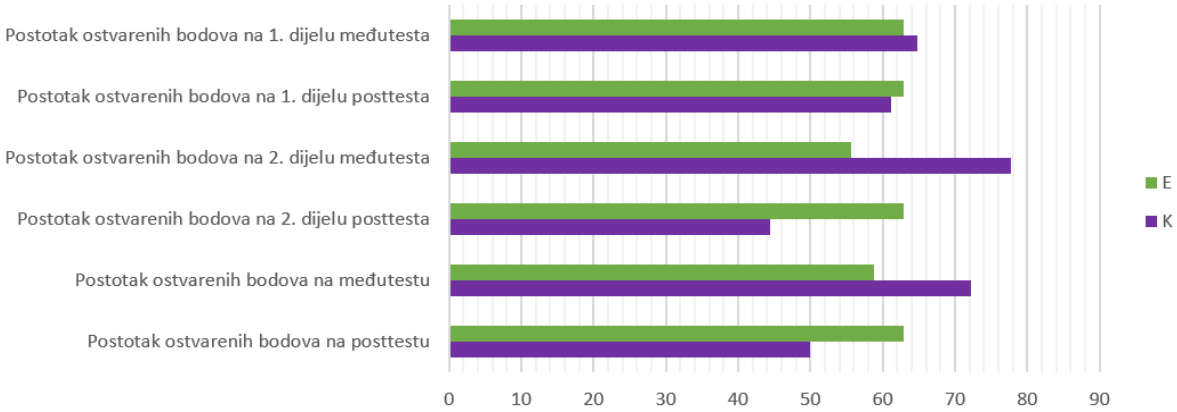

Slika 3.3 Postoci ostvarenih bodova učenika ujednačenih po sposobnosti (OŠ)

3.1.5. Usporedba retencije algoritma sortiranja kod učenika istog spola prema načinu podučavanja

U sklopu analize rezultata učenika osnovnih škola proveden je još jedan Wilcoxonov test radi utvrđivanja potencijalnih statistički značajnih razlika između rezultata međutesta i posttesta učenika istog spola unutar skupina u istraživanju.

Tablica 3.7 prikazuje rezultate Wilcoxonova testa Eksperimentalne skupine učenika osnovnih škola prema kojima je vidljivo da postoje dvije statistički značajne razlike i to između rezultata učenika na međutestu i posttestu u cjelini, kao i između rezultata učenika na drugom dijelu međutesta i posttesta, dok kod učenica Eksperimentalne skupine osnovnih škola Wilcoxonov test nije pokazao niti jednu statistički značajnu razliku. Učenici Eksperimentalne skupine statistički su značajno bolje riješili zadnji zadatak posttesta u odnosu na rezultat ostvaren na istom zadatku međutesta, čime su i ukupno statistički značajno bolje riješili posttest u odnosu na međutest.

Tablica 3.7 Rezultati Eksperimentalne skupine po spolu (OŠ)

spol	Postotak ostvarenih bodova (Posttest - Međutest)	Z	p
m	1. dio	-1.697	0.090
	2. dio	-2.010	0.044
	Ukupno	-2.151	0.031
ž	1. dio	-1.222	0.222
	2. dio	-0.358	0.720
	Ukupno	-0.864	0.388

Slika 3.4 prikazuje graf s postocima točnih odgovora učenika i učenica Eksperimentalne skupine osnovnih škola na međutestu i posttestu. Na grafu se može uočiti da su učenici Eksperimentalne skupine zaista ostvarili prosječno bolji rezultat na svim dijelovima

posttesta u odnosu na iste dijelove međutesta, dok su učenice Eksperimentalne skupine ostvarile prosječno lošiji rezultat na svim dijelovima posttesta u odnosu na iste dijelove međutesta.

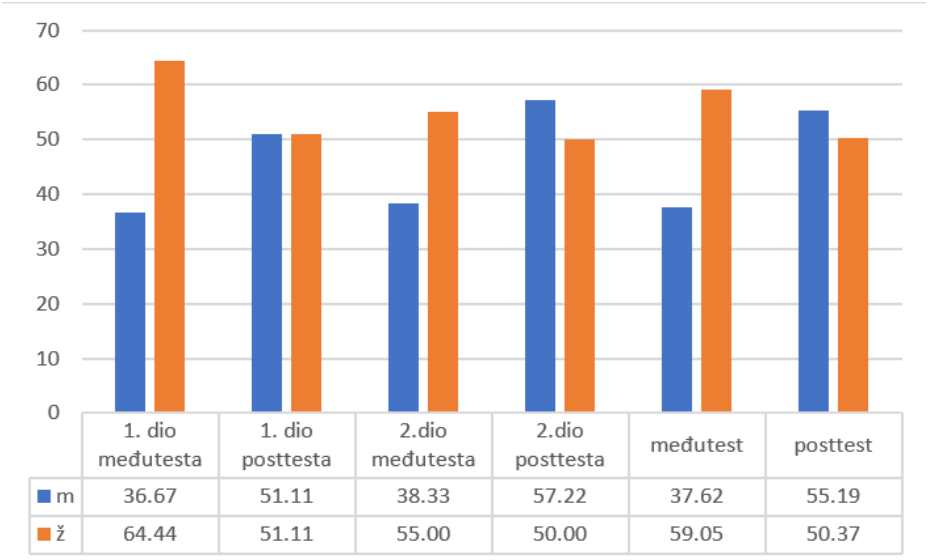

	1. dio međutesta	1. dio posttesta	2.dio međutesta	2.dio posttesta	međutest	posttest
m	36.67	51.11	38.33	57.22	37.62	55.19
ž	64.44	51.11	55.00	50.00	59.05	50.37

Slika 3.4 Postoci točnih odgovora Eksperimentalne skupine po spolu (OŠ)

Tablica 3.8 prikazuje rezultate Wilcoxonova testa Kontrolne skupine učenika osnovnih škola prema kojima je vidljivo da nema statistički značajnih razlika između ostvarenih rezultata na međutestu i posttestu niti kod učenika niti kod učenica Kontrolne skupine osnovnih škola.

Tablica 3.8 Rezultati Kontrolne skupine po spolu (OŠ)

spol	Postotak ostvarenih bodova (Posttest - Međutest)	Z	p
m	**1. dio**	-0.707	**0.480**
	2. dio	-1.841	**0.066**
	Ukupno	-1.761	**0.078**
ž	**1. dio**	-0.258	**0.796**
	2. dio	-1.604	**0.109**
	Ukupno	-0.874	**0.382**

Slika 3.5 prikazuje graf s postocima točnih odgovora učenika i učenica Kontrolne skupine osnovnih škola na međutestu i posttestu. Na grafu se može uočiti da su i učenici i učenice Kontrolne skupine ostvarili prosječno lošiji rezultat na svim dijelovima posttesta u odnosu na iste dijelove međutesta, uz iznimku prvog dijela posttesta kojega su učenice Kontrolne skupine riješile nešto bolje u odnosu na isti dio međutesta.

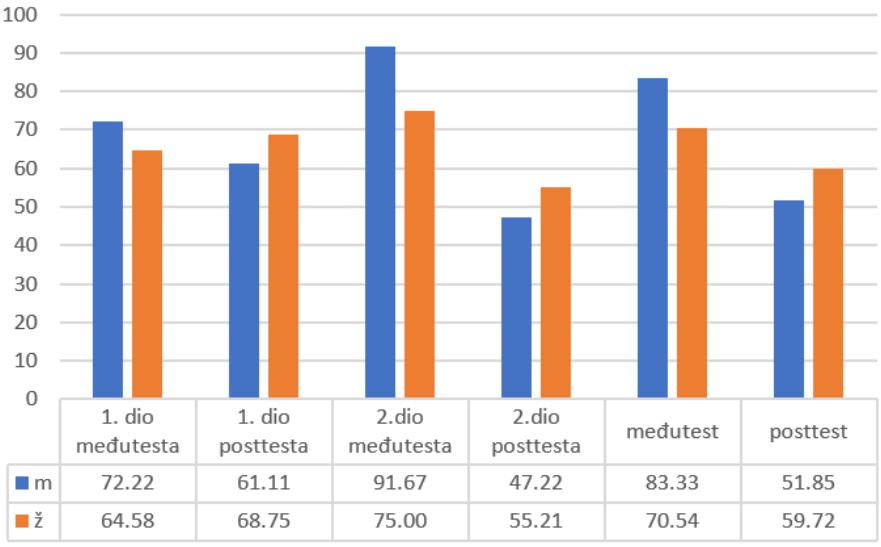

Slika 3.5 Postoci točnih odgovora Kontrolne skupine po spolu (OŠ)

3.2. Rezultati učenika srednjih škola

U ovome poglavlju navedeni su rezultati analize podataka dobivenih iz predtesta, međutesta i posttesta za učenike srednjih škola. Struktura poglavlja ista je kao i prethodnog poglavlja u kojemu su navedeni rezultati učenika osnovnih škola. Prilikom analize dobivenih podataka, međutest i posttest za učenike srednjih škola podijeljeni su na tri dijela i to tako da prvi dio međutesta, odnosno posttesta predstavljaju prva dva zadatka koja su tipa nadopunjavanja, drugi dio međutesta, odnosno posttesta predstavljaju treći, četvrti i peti zadatak koji su tipa višestrukog izbora, a treći dio međutesta, odnosno posttesta predstavlja zadnji zadatak koji je tipa nadopunjavanja. Navedeno je napravljeno kako bi se lakše analizirali dijelovi testa koji provjeravaju istu razinu znanja učenika.

3.2.1. Ujednačenost skupina

Rezultati predtesta učenika srednjih škola iskorišteni su za utvrđivanje jednakosti Eksperimentalne i Kontrolne skupine učenika srednjih škola. Prema rezultatima Mann-Whitney U testa (Tablica 3.10) nije utvrđena statistički značajna razlika između Eksperimentalne i Kontrolne skupine učenika srednjih škola u sposobnosti rješavanja problema, čime je omogućena daljnja analiza podataka dobivenih iz međutesta i posttesta te će u istoj obje skupine biti tretirane kao jednake. Tablica 3.9 prikazuje deskriptivnu statistiku predtesta Eksperimentalne i Kontrolne skupine učenika srednjih škola iz koje se

može iščitati kako je Kontrolna skupina ostvarila prosječno bolji rezultat u odnosu na Eksperimentalnu skupinu, što će biti slučaj i kod rezultata međutesta te posttesta.

Tablica 3.9 Deskriptivna statistika predtesta (SŠ)

Skupina	N	AS	Mdn	Mod	Min	Max
E	74	9.47	10	10	5	12
K	37	9.84	10	11	5	12

3.2.2. Usporedba učinka učenika u usvajanju algoritma sortiranja prema načinu podučavanja

Kod učenika srednjih škola Mann-Whitney U test pokazao je statistički značajnu razliku između Eksperimentalne i Kontrolne skupine samo na trećem dijelu međutesta, i to sa graničnom statističkom značajnosti u korist Kontrolne skupine, dok na posttestu ta razlika nije utvrđena. Rezultati Mann-Whitney U testa za sve testove provedene u razrednim odjelima srednjih škola dani su u Tablica 3.10.

Tablica 3.10 Rezultati Mann-Whitney U testa (SŠ)

Postotak ostvarenih bodova	Mann-Whitney U	Z	p
Predtest	1213.000	-0.994	**0.320**
1. dio međutesta	1277.000	-0.643	**0.520**
2. dio međutesta	1196.500	-1.154	**0.248**
3. dio međutesta	1060.500	-1.963	**0.050**
Međutest	1062.000	-1.931	**0.054**
1. dio posttesta	1246.000	-0.854	**0.393**
2. dio posttesta	1310.000	-0.408	**0.684**
3. dio posttesta	1148.000	-1.405	**0.160**
Posttest	1162.500	-1.299	**0.194**

U Tablica 3.11 dana je deskriptivna statistika međutesta Eksperimentalne i Kontrolne skupine učenika srednjih škola iz koje je vidljivo da je Kontrolna skupina ostvarila prosječno bolji rezultat od Eksperimentalne skupine, što je bio slučaj i kod učenika osnovnih škola.

Tablica 3.11 Deskriptivna statistika međutesta (SŠ)

Skupina	N	AS	Mdn	Mod	Min	Max
E	74	6.04	6	3	1	12
K	37	7.27	8	4	2	12

Tablica 3.12 prikazuje deskriptivnu statistiku posttesta Eksperimentalne i Kontrolne skupine učenika srednjih škola koja, kao i kod učenika osnovnih škola, ukazuje na znatno poboljšanje prosječnog rezultata Eksperimentalne skupine na posttestu u odnosu na prosječni rezultat Eksperimentalne skupine na međutestu, dok je kod Kontrolne skupine

poboljšanje prosječnog rezultata nešto manje značajno. Najčešće ostvaren broj bodova u Eksperimentalnoj skupini učenika srednjih škola na posttestu bio je 15 bodova, što je ujedno i najveći mogući ostvarivi broj bodova na posttestu, dok je u Kontrolnoj skupini bio 8 bodova. Unatoč tome, Kontrolna skupina učenika srednjih škola i na posttestu je ostvarila prosječno bolji rezultat od Eksperimentalne skupine.

Tablica 3.12 Deskriptivna statistika posttesta (SŠ)

Skupina	N	AS	Mdn	Mod	Min	Max
E	74	7.68	6.5	15	0	15
K	37	8.46	8	8	3	15

Sve navedeno vidljivo je i na grafu prikazanom Slika 3.6 koji daje detaljniji prikaz postotaka ostvarenih bodova na međutestu i posttestu učenika srednjih škola. Na istome grafu može se uočiti kako je Eksperimentalna skupina učenika srednjih škola samo na prvom dijelu posttesta ostvarila prosječno lošiji rezultat u usporedbi s ostvarenim prosječnim rezultatom na istome dijelu međutesta, dok je Kontrolna skupina učenika srednjih škola samo na drugom dijelu posttesta ostvarila prosječno bolji rezultat u usporedbi s ostvarenim prosječnim rezultatom na istome dijelu međutesta.

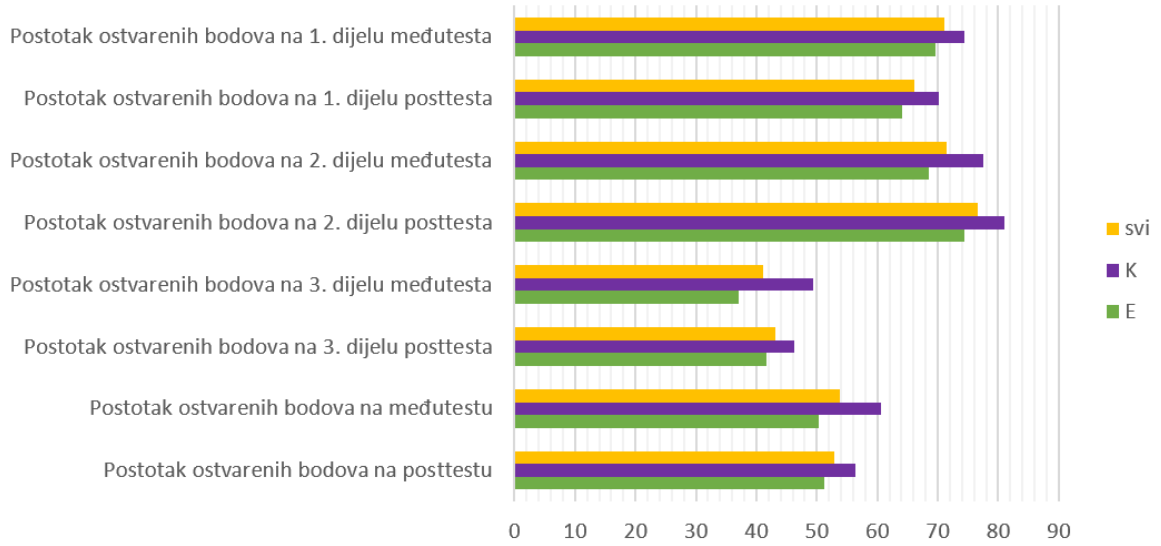

Slika 3.6 Postoci ostvarenih bodova na međutestu i posttestu (SŠ)

3.2.3. Usporedba retencije algoritma sortiranja prema načinu podučavanja

Tablica 3.13 prikazuje rezultate Wilcoxonova testa učenika srednjih škola iz kojih je vidljivo da nema statistički značajnih razlika između ostvarenih rezultata na međutestu i posttestu niti kod Eksperimentalne niti kod Kontrolne skupine učenika srednjih škola.

Tablica 3.13 Rezultati Wilcoxonova testa (SŠ)

	Postotak ostvarenih bodova (Posttest - Međutest)	Z	p
Svi	1. dio	-1.227	0.220
	2. dio	-1.699	0.089
	3. dio	-0.437	0.662
	Ukupno	-0.901	0.368
E	1. dio	-1.093	0.275
	2. dio	-1.539	0.124
	3. dio	-1.182	0.237
	Ukupno	-0.205	0.838
K	1. dio	-0.651	0.515
	2. dio	-0.722	0.470
	3. dio	-0.935	0.350
	Ukupno	-1.357	0.175

Iako Wilcoxonov test nije dao nijednu statistički značajnu razliku, na Slika 3.7, koja prikazuje graf s postocima točnih odgovora Eksperimentalne i Kontrolne skupine učenika srednjih škola na zadnjem zadatku međutesta i posttesta, ponovno je vidljiv pad u postotku točnih odgovora na posttestu kod učenika Kontrolne skupine u odnosu na međutest, dok je kod učenika Eksperimentalne skupine vidljiva mala promjena između postotaka točnih odgovora na međutestu i na posttestu. Svaki stupac grafa predstavlja jedan redak tablice koju su učenici u sklopu zadnjeg zadataka trebali popuniti.

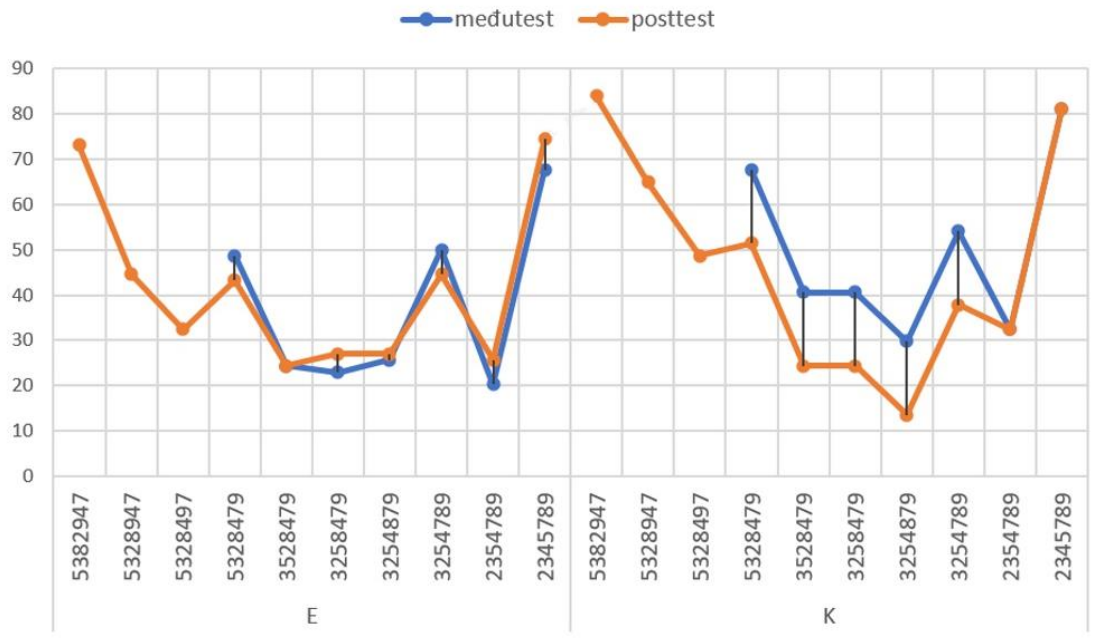

Slika 3.7 Postoci točnih odgovora na zadnjem zadatku međutesta i posttesta (SŠ)

3.2.4. Usporedba učinka učenika ujednačenih po sposobnosti rješavanja problema u usvajanju algoritma sortiranja prema načinu podučavanja

Kako bi se utvrdilo postoji li statistički značajna razlika između Eksperimentalne i Kontrolne skupine učenika srednjih škola ujednačenih po sposobnosti rješavanja problema, proveden je dodatan Wilcoxonov test nad podacima međutesta i posttesta tih učenika. Ujednačavanje učenika napravljeno je na isti način kao i kod učenika osnovnih škola (opisano u poglavlju 3.1.4). Rezultati provedenog Wilcoxonova testa za učenike srednjih škola ujednačenih po sposobnosti rješavanja problema prikazani su u Tablica 3.14 iz koje je vidljivo da između Eksperimentalne i Kontrolne skupine tih učenika nema statistički značajnih razlika.

Tablica 3.14 Rezultati učenika ujednačenih po sposobnosti (SŠ)

Postotak ostvarenih bodova	Z	p
1. dio međutesta	0.000	**1.000**
2. dio međutesta	-1.786	**0.074**
3. dio međutesta	-1.399	**0.162**
Međutest	-1.494	**0.135**
1. dio posttesta	-0.217	**0.828**
2. dio posttesta	-0.075	**0.940**
3. dio posttesta	-0.217	**0.828**
Posttest	-0.048	**0.962**

Slika 3.8 prikazuje graf s postocima ostvarenih bodova Eksperimentalne i Kontrolne skupine učenika srednjih škola ujednačenih po sposobnosti rješavanja problema na međutestu i posttestu. Na grafu se može uočiti kako je Kontrolna skupina na međutestu ostvarila prosječno bolji rezultat od Eksperimentalne skupine, dok su na posttestu Kontrolna i Eksperimentalna skupina ujednačene prema postotku ostvarenih bodova. Isto tako, može se uočiti poboljšanje prosječnog rezultata Eksperimentalne skupine na trećem dijelu posttesta u odnosu na prosječni rezultat ostvaren na istom dijelu međutesta, dok je kod Kontrolne skupine na trećem dijelu posttesta vidljivo pogoršanje prosječnog rezultata u odnosu na prosječni rezultat ostvaren na istom dijelu međutesta.

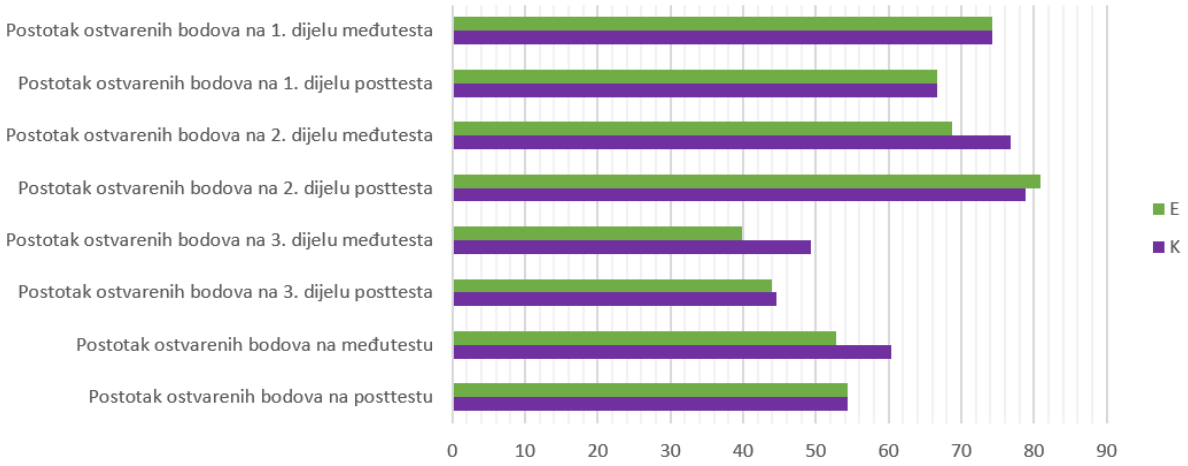

Slika 3.8 Postoci ostvarenih bodova učenika ujednačenih po sposobnosti (SŠ)

3.2.5. Usporedba retencije algoritma sortiranja kod učenika istog spola prema načinu podučavanja

U sklopu analize rezultata učenika srednjih škola proveden je još jedan Wilcoxonov test radi utvrđivanja potencijalnih statistički značajnih razlika između rezultata međutesta i posttesta učenika istog spola unutar skupina u istraživanju.

Tablica 3.15 prikazuje rezultate Wilcoxonova testa Eksperimentalne skupine učenika srednjih škola prema kojima je vidljivo da nema statistički značajnih razlika između ostvarenih rezultata na međutestu i posttestu niti kod učenika niti kod učenica Eksperimentalne skupine srednjih škola.

Tablica 3.15 Rezultati Eksperimentalne skupine po spolu (SŠ)

spol	Postotak ostvarenih bodova (Posttest - Međutest)	Z	p
m	**1. dio**	-1.519	**0.129**
	2. dio	-0.371	**0.711**
	3. dio	-1.119	**0.263**
	Ukupno	-0.733	**0.464**
ž	**1. dio**	-0.225	**0.822**
	2. dio	-1.932	**0.053**
	3. dio	-0.601	**0.548**
	Ukupno	-0.463	**0.643**

Slika 3.9 prikazuje graf s postocima točnih odgovora učenika i učenica Eksperimentalne skupine srednjih škola na međutestu i posttestu. Na grafu se može uočiti da su i učenici i učenice Eksperimentalne skupine ostvarili prosječno bolji rezultat na svim dijelovima

posttesta u odnosu na iste dijelove međutesta, uz iznimku prvog dijela posttesta kojega su učenici Eksperimentalne skupine riješili lošije u odnosu na isti dio međutesta.

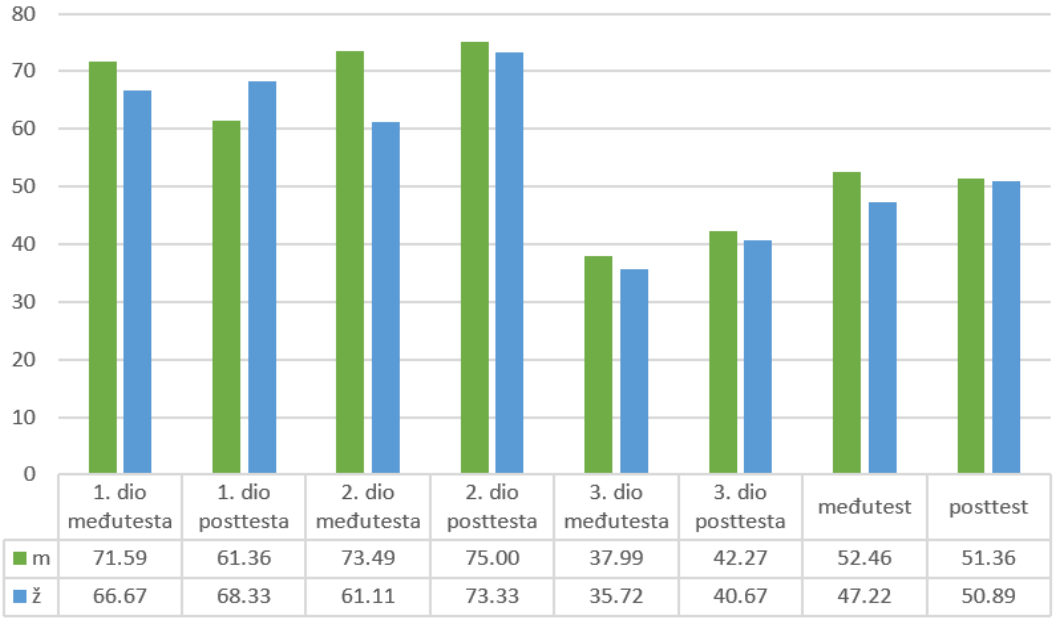

	1. dio međutesta	1. dio posttesta	2. dio međutesta	2. dio posttesta	3. dio međutesta	3. dio posttesta	međutest	posttest
m	71.59	61.36	73.49	75.00	37.99	42.27	52.46	51.36
ž	66.67	68.33	61.11	73.33	35.72	40.67	47.22	50.89

Slika 3.9 Postoci točnih odgovora Eksperimentalne skupine po spolu (SŠ)

Tablica 3.16 prikazuje rezultate Wilcoxonova testa Kontrolne skupine učenika srednjih škola prema kojima je vidljivo da postoji statistički značajna razlika između rezultata učenika na međutestu i posttestu u cjelini, dok kod učenica Kontrolne skupine srednjih škola Wilcoxonov test nije pokazao niti jednu statistički značajnu razliku. Učenici Kontrolne skupine ukupno su statistički značajno lošije riješili posttest u odnosu na rezultat ostvaren na međutestu.

Tablica 3.16 Rezultati Kontrolne skupine po spolu (SŠ)

spol	Postotak ostvarenih bodova (Posttest - Međutest)	Z	p
m	**1. dio**	-1.730	**0.084**
	2. dio	-0.087	**0.931**
	3. dio	-0.754	**0.451**
	Ukupno	-1.980	**0.048**
ž	**1. dio**	-0.437	**0.662**
	2. dio	-1.265	**0.206**
	3. dio	-0.545	**0.586**
	Ukupno	-0.218	**0.827**

Slika 3.10 prikazuje graf s postocima točnih odgovora učenika i učenica Kontrolne skupine srednjih škola na međutestu i posttestu. Na grafu se može uočiti da su i učenici i učenice Kontrolne skupine ostvarili nešto bolji rezultat na drugom dijelu posttesta u odnosu na isti dio međutesta, dok su na trećem dijelu posttesta ostvarili nešto lošiji rezultat u odnosu na

isti dio međutesta, što je uzrokovalo i ukupno lošiji rezultat i učenika i učenica Kontrolne skupine na posttestu u odnosu na rezultat ostvaren na međutestu.

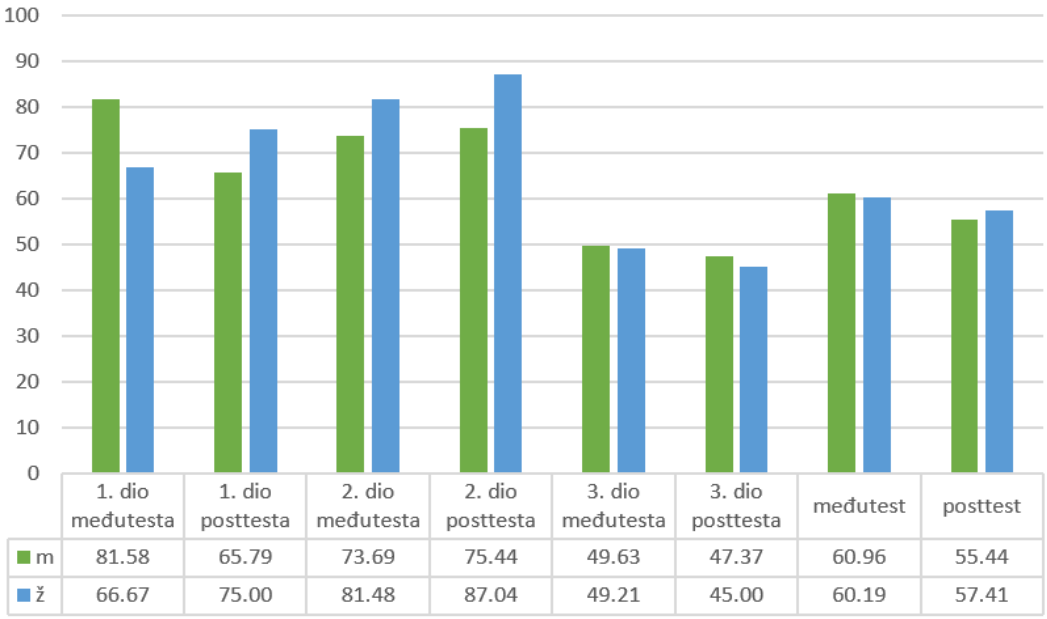

	1. dio međutesta	1. dio posttesta	2. dio međutesta	2. dio posttesta	3. dio međutesta	3. dio posttesta	međutest	posttest
m	81.58	65.79	73.69	75.44	49.63	47.37	60.96	55.44
ž	66.67	75.00	81.48	87.04	49.21	45.00	60.19	57.41

Slika 3.10 Postoci točnih odgovora Kontrolne skupine po spolu (SŠ)

3.3. Kvalitativna analiza istraživanja

Suprotno očekivanjima, učenici Eksperimentalne skupine srednjih škola pokazali su puno veću zainteresiranost za primjenu CS aktivnosti u odnosu na učenike osnovnih škola. Niti jedan razredni odjel učenika Eksperimentalne skupine osnovnih škola nije iskazao želju za ponovnim gledanjem videa o algoritmu *bubble sort* što upućuje na činjenicu da im sam video nije bio potreban, odnosno da se isti može iskoristiti u svrhu ponavljanja podučavanog algoritma, dok se dobivene upute za rad mogu pojasniti samo usmenim putem, kako je napravljeno s učenicima Eksperimentalne skupine srednjih škola. Isto tako, primijećeno je da učenice Eksperimentalne skupine osnovnih škola imaju puno ozbiljniji pristup radu u odnosu na učenike Eksperimentalne skupine osnovnih škola, što je vjerojatno utjecalo na njihov bolji prosječni rezultat na međutestu naspram ostvarenog prosječnog rezultata učenika.

3.3.1. Uočene miskoncepcije

Prilikom analize rezultata međutesta i posttesta učenika osnovnih škola uočene su dvije miskoncepcije vezane za razumijevanje algoritma *bubble sort*. Prva uočena miskoncepcija, nazvana „dva broja u neispravnom redoslijedu“, na međutestu se pojavila kod 18 učenika

osnovnih škola (26.87%). Među njima 10 je učenika Eksperimentalne skupine, a 8 pripada Kontrolnoj skupini, što znači da je navedenu miskoncepciju razvilo 22.22% učenika Eksperimentalne skupine, odnosno 36.36% učenika Kontrolne skupine. Na posttestu se ista miskoncepcija zadržala kod samo 5 učenika osnovnih škola (3 iz Eksperimentalne skupine, 2 iz Kontrolne skupine), a uočena je kod ukupno 15 učenika osnovnih škola (22.39%). Među njima 11 je učenika Eksperimentalne skupine, a 4 pripada Kontrolnoj skupini, što znači da je navedenu miskoncepciju do posttesta razvilo 24.44% učenika Eksperimentalne skupine, odnosno 18.18% učenika Kontrolne skupine. Miskoncepcija „dva broja u neispravnom redoslijedu“ (Slika 3.11) predstavlja algoritam sortiranja niza prema kojemu se, počevši od početne pozicije u nizu, uspoređuju dva susjedna elementa niza dok se ne naiđe na ona dva elementa koja nisu poredana prema zadanom kriteriju sortiranja. Nakon što se ta dva susjedna elementa niza pronađu, zamijene im se pozicije u nizu, a usporedba susjednih elemenata niza ponovno kreće od početne pozicije u nizu.

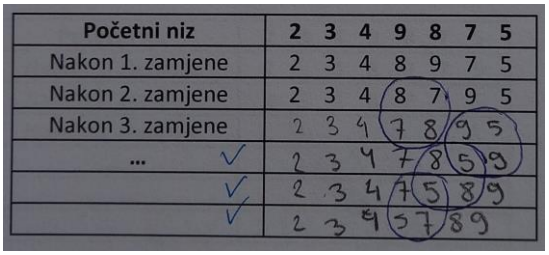

Slika 3.11 Miskoncepcija "dva broja u neispravnom redoslijedu" (OŠ)

Ista miskoncepcija uočena je i kod učenika srednjih škola. Miskoncepcija „dva broja u neispravnom redoslijedu“ na međutestu se pojavila kod samo 8 učenika srednjih škola (7.21%). Među njima 4 je učenika Eksperimentalne skupine, a 4 pripada Kontrolnoj skupini, što znači da je navedenu miskoncepciju razvilo 5.41% učenika Eksperimentalne skupine, odnosno 10.81% učenika Kontrolne skupine. Na posttestu se ista miskoncepcija zadržala kod 3 učenika srednjih škola (2 iz Eksperimentalne skupine, 1 iz Kontrolne skupine), a uočena je kod ukupno 17 učenika srednjih škola (15.32%). Među njima 12 je učenika Eksperimentalne skupine, a 5 pripada Kontrolnoj skupini, što znači da je navedenu miskoncepciju do posttesta razvilo 16.22% učenika Eksperimentalne skupine, odnosno 13.51% učenika Kontrolne skupine. Slika 3.12 prikazuje navedenu miskoncepciju na primjeru rješenja zadatka učenika srednje škole.

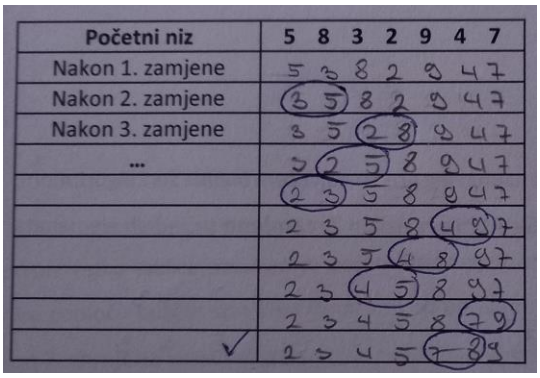

Slika 3.12 Miskoncepcija "dva broja u neispravnom redoslijedu" (SŠ)

Druga miskoncepcija uočena kod učenika osnovnih škola, nazvana „prolazak kroz red“, pojavila se tek na posttestu i to kod ukupno 12 učenika osnovnih škola (17.91%). Među njima 8 je učenika Eksperimentalne skupine, a 4 pripada Kontrolnoj skupini, što znači da je navedenu miskoncepciju razvilo 17.78% učenika Eksperimentalne skupine, odnosno 18.18% učenika Kontrolne skupine. Miskoncepcija „prolazak kroz red“ (Slika 3.13) predstavlja algoritam sortiranja niza prema kojemu se pronalazi najveći nesortirani broj, odnosno najveći broj kojemu trenutna pozicija u nizu nije ista onoj poziciji na kojoj se taj broj nalazi kada je niz sortiran. Nakon što se taj broj pronađe, postavlja se na kraj nesortiranog dijela niza, što je ujedno i početak sortiranog dijela niza. Zatim se započinje s pronalaskom novog najvećeg nesortiranog broja. Moguć uzrok pojave ove miskoncepcije kod učenika osnovnih škola zadnji je zadatak predtesta u kojemu se od učenika traži da tablicu popune na način da jedan redak tablice predstavlja prolazak kroz red, a ne zamjenu dvaju susjednih elemenata niza.

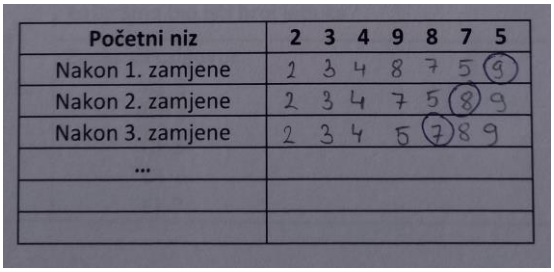

Slika 3.13 Miskoncepcija "prolazak kroz red"

Kod učenika srednjih škola, osim već spomenute miskoncepcije „dva broja u neispravnom redoslijedu“, uočena je i miskoncepcija nazvana „najveći nesortirani broj“. Ista miskoncepcija na međutestu se pojavila kod 23 učenika srednjih škola (20.72%). Među njima 15 je učenika Eksperimentalne skupine, a 8 pripada Kontrolnoj skupini, što znači da je navedenu miskoncepciju razvilo 20.27% učenika Eksperimentalne skupine, odnosno 21.62% učenika Kontrolne skupine. Na posttestu se ista miskoncepcija zadržala kod 10

učenika srednjih škola (7 iz Eksperimentalne skupine, 3 iz Kontrolne skupine), a uočena je kod ukupno 14 učenika srednjih škola (12.61%). Među njima 10 je učenika Eksperimentalne skupine, a 4 pripada Kontrolnoj skupini, što znači da je navedenu miskoncepciju do posttesta razvilo 13.51% učenika Eksperimentalne skupine, odnosno 10.81% učenika Kontrolne skupine. Miskoncepcija „najveći nesortirani broj“ (Slika 3.14) predstavlja algoritam sortiranja niza prema kojemu se pronalazi najveći nesortirani broj, odnosno najveći broj kojemu trenutna pozicija u nizu nije ista onoj poziciji na kojoj se taj broj nalazi kada je niz sortiran. Nakon što se taj broj pronađe, zamjenjuje se pozicija istoga u nizu s pozicijom desnog susjednog broja te se taj korak ponavlja dok se pronađeni broj ne postavi na kraj nesortiranog dijela niza, što je ujedno i početak sortiranog dijela niza. Zatim se započinje s pronalaskom novog najvećeg nesortiranog broja. Ova je miskoncepcija sličnija podučavanom algoritmu *bubble sort* od ranije opisane miskoncepcije „dva broja u neispravnom redoslijedu“.

Slika 3.14 Miskoncepcija "najveći nesortirani broj"

3.3.2. Komentari učenika

U nastavku su navedeni neki od komentara sudionika istraživanja koje su učenici napisali u sklopu provedene ankete.

Komentari Eksperimentalne skupine:

- OŠ
  - „*Jako mi se svidjelo što smo i mi sami mogli pokušati razmišljati poput računala.*“
  - „*Bilo je zanimljivo probati nešto drugačije.*“
  - „*Sviđa mi se današnji sat, ali problemi koje smo danas rješavali karticama bili su mi prejednostavni i ponavljajući pa nakon nekog vremena nisam na njih gledao kao na izazov, nego samo kao nešto čega se želim riješiti.*“

- SŠ
  - „*Vrlo domišljat način predavanja uz kartice, grupni rad i samostalno razmišljanje*.“
  - „*Mislim da je bilo jako zabavno proučiti kako računalo funkcionira.*“
  - „*Logički zadaci (ovo danas) je puno bolje i zanimljivije od ispisivanja naredbi (bilo na računalu ili na papiru).*“
  - „*Drago mi je što smo radili u parovima.*“
  - „*Jako zanimljiv način rada.*“

Komentari Kontrolne skupine:

- OŠ
  - „*Današnji sat mi se svidio jer je bio drugačiji i neuobičajen za sat informatike.*“
  - „*Malo dosadno.*“
  - „*Nastavnica je vrlo lijepo objasnila, ali inače nije mi ova lekcija zanimljiva.*“
- SŠ
  - „*Bili su mi ovi zadaci jako zanimljivi i zbog njih mi je bilo lakše pratiti nastavu te je bilo zabavnije.*“
  - „*Bilo je bolje bez računala jer smo imali dobre popratne zadatke i jer je sve bilo logičkim slijedom objašnjeno bez previše informacija.*“
  - „*Moj odgovor na 4. pitanje bi bio da mi je najdraža kombinacija. Ovakav način da bolje shvatimo, a zatim vidimo primjere u Pythonu.*“
  - „*Bilo je zanimljivo i dobro objašnjeno, samo proces dugo traje.*“

Iz navedenih komentara može se uočiti kako su učenici Eksperimentalne skupine osnovnih i srednjih škola izrazili pozitivan stav prema primjeni CS aktivnosti u podučavanju. Primijećeno je kako učenici koji inače idu na natjecanja iz Informatike ovu aktivnost ne doživljavaju kao dovoljno motivirajuću, odnosno nije im dovoljno kognitivno izazovna, što svakako treba uzeti u obzir prilikom primjene CS aktivnosti u podučavanju takvih učenika. S druge strane, kod učenika Kontrolne skupine osnovnih škola može se uočiti manjak interesa za temu sortiranja, što se može pripisati klasičnom načinu podučavanja koji nije dovoljno usklađen s njihovom potrebom za aktivnim učenjem kroz igru. Isto se ne može reći za učenike Kontrolne skupine srednjih škola kojima je i klasičan način podučavanja dovoljno zanimljiv ako je poduprijet njihovim angažmanom u vidu odgovaranja na pitanja o predviđanju idućeg koraka algoritma ili raspravljanja o učinkovitosti algoritma. Ova razlika između učenika Kontrolne skupine vjerojatno je posljedica razvijenijeg apstraktnog mišljenja kod učenika srednjih škola u odnosu na sposobnost apstraktnog mišljenja učenika osnovnih škola.

4. Rasprava i preporuke za nastavu

Analizom rezultata provedenog međutesta i posttesta kod učenika osnovnih (Tablica 3.2) i srednjih (Tablica 3.10) škola pokazano je da je Kontrolna skupina ostvarila prosječno bolje rezultate od Eksperimentalne skupine, što se najviše može uočiti kod usporedbe rezultata međutesta prema kojima bi se dalo pretpostaviti da je neposredna razina usvojenosti algoritma *bubble sort* bolja kod učenika podučavanih klasičnim načinom, odnosno da primjena CS aktivnosti ne utječe značajno na neposredni učinak učenika u usvajanju algoritma *bubble sort*.

Unatoč tome, usporedbom rezultata posttesta učenika osnovnih škola uočeni su znatno lošiji rezultati kod Kontrolne skupine (Tablica 3.5) što ukazuje na slabu retenciju naučenog algoritma *bubble sort*. S druge strane, isto se ne može reći za Eksperimentalnu skupinu koja je pokazala puno bolju retenciju naučenoga, uz vidljivo poboljšanje prosječnog rezultata na posttestu. Stoga, možemo pretpostaviti da je kod učenika osnovnih (Slika 3.1) i srednjih (Slika 3.6) škola primjena CS aktivnosti pozitivno utjecala na retenciju naučenog algoritma *bubble sort*. Navedeno je u skladu s istraživanjem Grissoma, McNallyja i Napsa (2003) koje je pokazalo da veća razina aktivnosti učenika u korištenju vizualizacije pozitivno utječe na njihovu retenciju naučenoga te s istraživanjem Thiesa i Vahrenholda (2012) koje je potvrdilo opravdanost primjene CS aktivnosti u uvodnim satima programiranja.

Wilcoxonov test nije dao nijednu statistički značajnu razliku između rezultata međutesta i posttesta ni kod učenika osnovnih škola ujednačenih po sposobnosti rješavanja problema (Tablica 3.6), ni kod učenika srednjih škola ujednačenih po sposobnosti rješavanja problema (Tablica 3.14), što znači da statistički značajne razlike između rezultata međutesta i posttesta učenika osnovnih (Tablica 3.2) i srednjih (Tablica 3.10) škola nije uzrokovao način podučavanja. Zbog utvrđenog statistički značajno lošijeg rezultata Kontrolne skupine učenika osnovnih škola ujednačenih po sposobnosti rješavanja problema na drugom dijelu posttesta (Slika 3.3) može se pretpostaviti da primjena klasičnog načina podučavanja kod učenika osnovnih škola uzrokuje lošu retenciju naučenog algoritma *bubble sort.*

Zbog statistički značajno boljeg rezultata učenika Eksperimentalne skupine osnovnih škola na posttestu u odnosu na ostvaren rezultat na međutestu (Tablica 3.7), može se utvrditi da primjena CS aktivnosti pozitivno utječe na retenciju naučenog algoritma *bubble sort* kod učenika, dok kod učenica primjena CS aktivnosti nema utjecaja na istu. Navedeno je u skladu s istraživanjem Myllera, Laakso-a, & Korhonena (2007) koje je pokazalo da veća razina aktivnosti učenika u kombinaciji sa suradničkim učenjem u korištenju vizualizacije pozitivno utječe na retenciju naučenoga. Kod učenika i učenica Eksperimentalne skupine srednjih škola vidljivo je poboljšanje rezultata na posttestu u odnosu na rezultat ostvaren na međutestu (Slika 3.9) pa se može pretpostaviti da kod učenika srednjih škola primjena CS aktivnosti podjednako utječe na retenciju naučenog algoritma *bubble sort* u odnosu na spol učenika. Zbog statistički značajno lošijeg rezultata učenika Kontrolne skupine srednjih škola na posttestu u odnosu na ostvaren rezultat na međutestu (Tablica 3.16), može se pretpostaviti da primjena klasičnog načina podučavanja algoritma sortiranja negativno utječe na retenciju naučenog algoritma *bubble sort* kod učenika srednjih škola.

Komentari učenika Eksperimentalne skupine srednjih škola u suprotnosti su s komentarima učenika srednje škole koji su sudjelovali u istraživanju Feaster, Segarsa, Wahba-e i Hallstroma (2011), što ukazuje na činjenicu da CS aktivnosti treba pažljivo prilagoditi dobi učenika, ali i njihovoj razini znanja, kako bi iste imale pozitivan utjecaj na motivaciju učenika za rad.

CS aktivnost osmišljena u svrhu provedbe ovog istraživanja uključuje sve stilove učenja prema Felder & Silverman modelu stilova učenja (1988). Time se podučavanje algoritama sortiranja lako može prilagoditi pojedinim stilovima učenja učenika na način da se učenici podijele u parove prema preferiranom stilu učenja. Nakon što se učenici upoznaju s algoritmom u skladu s njihovim stilom učenja, nastavnik im može dodijeliti suprotnu ulogu u CS aktivnosti kako bi uvježbavanje algoritma nastavili usporedno s uvježbavanjem usvajanja i obrade informacija prema drugačijem stilu učenja. Nakon upoznavanja učenika s algoritmom sortiranja kroz CS aktivnost, poželjno bi bilo u sklopu idućeg nastavnog sata predmeta Informatike podučavani algoritam implementirati u odabranom programskom jeziku skupa s učenicima kako bi korake algoritma napisane na dobivenim tekstualnim uputama lakše povezali s pojedinim linijama programskog koda.

4.1. Ograničenja istraživanja

Broj sati koji je bio na raspolaganju za provedbu istraživanja ograničen je brojem školskih sati predviđenih za podučavanje algoritma *bubble sort* prema nastavnom planu i programu. Rezultati istraživanja bili bi mjerodavniji, a možda i drugačiji od dobivenih, da je za provedbu istraživanja bio raspoloživ veći fond sati unutar kojih bi se mogao bolje istražiti utjecaj CS aktivnosti na podučavanje ne samo algoritma *bubble sort*, već i drugih algoritama sortiranja koji su navedeni u kurikulumu za nastavni predmet Informatike (Ministarstvo znanosti i obrazovanja, 2018). Još jedno ograničenje istraživanja bila je podjela učenika Eksperimentalne skupine u parove koja je u ovom istraživanju provedena prema željama učenika. Boljim poznavanjem učeničkih stilova učenja i sposobnosti, učenici su mogli biti drugačije upareni, čime bi se potencijalno moglo utjecati na rezultate istraživanja. Isto tako, zbog provedbe istraživanja u prirodnom okruženju učionice, nije bilo moguće dobiti ujednačen broj sudionika po skupinama istraživanja. Uz sve navedeno, kao još jedno ograničenje istraživanja može se navesti i vrijeme održavanja nastave te provedbe testova koje nije bilo isto za sve sudionike, a samim time moglo je utjecati na njihovu koncentraciju i razinu umora, što je direktno moglo utjecati na dobivene rezultate.

Zaključak

U sklopu provedenog istraživanja učenici osnovnih i srednjih škola podučavani su algoritmu *bubble sort*. Eksperimentalna skupina podučavana je primjenom CS aktivnosti, dok je Kontrolna skupina podučavana klasičnim načinom, primjenom prezentacije i ploče. Radi utvrđivanja (ne)postojanja statistički značajnih razlika između korištenih metoda podučavanja, učenici su riješili dva testa: međutest neposredno nakon obrade gradiva te posttest dva tjedna nakon međutesta. Rezultati dobiveni analizom testova nisu pokazali značajniju korist primjene CS aktivnosti naspram klasičnog podučavanja algoritma *bubble sort*, iako su učenici Eksperimentalne skupine pokazali značajnu razinu retencije naučenog algoritma *bubble sort* koja se može pripisati primjeni CS aktivnosti. Štoviše, kod učenika Eksperimentalne skupine osnovnih škola utvrđeno je statistički značajno poboljšanje rezultata posttesta u odnosu na rezultat ostvaren na međutestu. Isto tako, kod učenika Kontrolne skupine i osnovnih i srednjih škola utvrđen je statistički značajno lošiji rezultat na posttestu u odnosu na rezultat ostvaren na međutestu iz čega se može pretpostaviti da primjena klasičnog načina podučavanja algoritma sortiranja negativno utječe na retenciju naučenog algoritma *bubble sort*. Navedena saznanja otvaraju mogućnost za daljnje istraživanje pozitivnog učinka CS aktivnosti na usvajanje podučavanih algoritama sortiranja. Među ostalim, primijećeno je da učenicama podjednako odgovaraju oba korištena pristupa podučavanju, iako je i kod njih uočena puno bolja retencija naučenoga u slučaju primjene CS aktivnosti u odnosu na klasičan način podučavanja. Bilo bi zanimljivo istražiti bi li primjena CS aktivnosti ipak u konačnici dala značajno bolje rezultate kada bi se koristila kontinuirano kroz dulji vremenski period u svrhu podučavanja različitih algoritama sortiranja. U sklopu provedene kvalitativne analize, uočene su miskoncepcije učenika vezane uz algoritam *bubble sort* pa ispitivanje njihovog uzroka može biti tema nekog budućeg istraživanja. Učenički stav prema ovakvom načinu rada bio je većinom iznimno pozitivan, što također nije zanemarivo jer pruža mogućnost poticanja interesa učenika za učenjem programiranja. Zbog svega navedenog, CS aktivnosti mogle bi pronaći svoje mjesto u uvodnim satima obrade apstraktnih koncepata računarske znanosti kako bi učenicima na zabavan način olakšali razumijevanje istih te ih potaknuli na stvaranje ispravnih, održivih mentalnih modela.

Literatura

Astrachan, O. (2003). Bubble Sort: An Archaeological Algorithmic Analysis. *ACM SIGCSE Bulletin, 35*(1), 1–5.

Bell, T., & Vahrenhold, J. (2018). CS Unplugged—How Is It Used, and Does It Work? U *Adventures Between Lower Bounds and Higher Altitudes* (str. 497-521). Springer.

Bellström, P., & Thorén, C. (2009). Learning how to program through visualization: A pilot study on the Bubble Sort algorithm. *2009 Second International Conference on the Applications of Digital Information and Web Technologies* (str. 90-94). IEEE.

Bloom, B. S., Engelhart, M. D., Furst, E. J., Hill, W. H., & Krathwohl, D. R. (1956). *Taxonomy of Educational Objectives: Handbook I: Cognitive Domain.* Longmans, Green & Co.

Blumenkrants, M., Starovisky, H., & Shamir, A. (2006). Narrative Algorithm Visualization. *Proceedings of the 2006 ACM Symposium on Software Visualization*, (str. 17–26).

Bruner, J. S. (1966). *Toward a theory of instruction* (Svez. 59). Harvard University Press.

Cohen, L., Manion, L., & Morrison, K. (2013). *Research Methods in Education.* Routledge.

Feaster, Y., Segars, L., Wahba, S. K., & Hallstrom, J. O. (2011). Teaching CS Unplugged in the High School (with Limited Success). *Proceedings of the 16th Annual Joint Conference on Innovation and Technology in Computer Science Education*, (str. 248–252).

Felder, R. M., & Silverman, L. K. (1988). Learning and Teaching Styles In Engineering Education. *Engineering Education, 78*(7), 674–681.

Grissom, S., McNally, M. F., & Naps, T. (2003). Algorithm Visualization in CS Education: Comparing Levels of Student Engagement. *Proceedings of the 2003 ACM Symposium on Software Visualization*, (str. 87–94).

Hundhausen, C. D., Douglas, S. A., & Stasko, J. T. (2002). A Meta-Study of Algorithm Visualization Effectiveness. *Journal of Visual Languages & Computing, 13*(3), 259-290.

Meier, A., Spada, H., & Rummel, N. (2007). A rating scheme for assessing the quality of computer-supported collaboration processes. *International Journal of Computer-Supported Collaborative Learning, 2*(1), 63–86.

Ministarstvo znanosti i obrazovanja. (2018). *Odluka o donošenju kurikuluma za nastavni predmet Informatike za osnovne škole i gimnazije u Republici Hrvatskoj*. Dohvaćeno iz Narodne novine: https://narodne-novine.nn.hr/clanci/sluzbeni/2018_03_22_436.html

Myller, N., Bednarik, R., Sutinen, E., & Ben-Ari, M. (2009). Extending the Engagement Taxonomy: Software Visualization and Collaborative Learning. *ACM Transactions on Computing Education, 9*(1), 1-27.

Myller, N., Laakso, M., & Korhonen, A. (2007). Analyzing Engagement Taxonomy in Collaborative Algorithm Visualization. *ACM SIGCSE Bulletin, 39*(3), 251–255.

Naps, T. L., Rößling, G., Almstrum, V., Dann, W., Fleischer, R., Hundhausen, C., . . . Velázquez-Iturbide, J. Á. (2002). Exploring the Role of Visualization and Engagement in Computer Science Education. *Working Group Reports from ITiCSE on Innovation and Technology in Computer Science Education*, (str. 131–152).

Naps, T., Cooper, S., Koldehofe, B., Leska, C., Rößling, G., Dann, W., . . . McNally, M. (2003). Evaluating the Educational Impact of Visualization. *ACM SIGCSE Bulletin, 35*(4), 124–136.

Norman, D. A. (1986). Cognitive engineering. *User centered system design, 31*, 31-61.

Piaget, J. (1952). *The origins of intelligence in children.* W W Norton & Co.

Prensky, M. (2001). Digital Natives, Digital Immigrants. *On the Horizon, 9*(5), 1-6.

Thies, R., & Vahrenhold, J. (2012). Reflections on Outreach Programs in CS Classes: Learning Objectives for "Unplugged" Activities. *Proceedings of the 43rd ACM Technical Symposium on Computer Science Education*, (str. 487–492).

Yehezkel, C., Ben-Ari, M., & Dreyfus, T. (2005). Computer Architecture and Mental Models. *Proceedings of the 36th SIGCSE Technical Symposium on Computer Science Education*, (str. 101–105).

Sažetak

Poučavanje algoritma sortiranja bez računala

Algoritamska vizualizacija u podučavanju bi se trebala koristiti kao poticaj za aktivnu konstrukciju znanja učenika, umjesto da služi kao sredstvo pasivnog prijenosa znanja. U skladu s navedenim provedeno je istraživanje, opisano u ovome radu, u svrhu utvrđivanja utjecaja aktivnosti podučavanja Informatike bez računala (engl. *Computer Science Unplugged*) na usvajanje algoritma *bubble sort* kao jedne od metoda podučavanja koja potiče aktivno korištenje vizualizacije. Istraživanje je provedeno u obliku kvazi-eksperimenta u osnovnim i srednjim školama grada Splita. Sudionici su podijeljeni u dvije skupine, eksperimentalnu (CS aktivnost podučavanja) i kontrolnu (klasičan način podučavanja). U sklopu istraživanja sudionici su rješavali predtest, međutest i posttest čijom se analizom došlo do sljedećih rezultata: primjena CS aktivnosti ne utječe značajno na neposredni učinak učenika u usvajanju algoritma *bubble sort*, no utječe pozitivno na retenciju istoga, i to statistički značajno kod učenika osnovnih škola, dok kod učenica nema tako velik utjecaj.

Ključne riječi: algoritamska vizualizacija, CS aktivnosti, algoritam *bubble sort*

Summary

Teaching sort algorithm using CS unplugged activities

Algorithm visualization (AV) technology should be a stimulating teaching tool for the active construction of students' knowledge, rather than being an instrument for the passive transfer of teacher’s knowledge. With that in mind, the research described in this paper was conducted to determine whether Computer Science (CS) Unplugged, as one of the teaching methods that encourages students' active use of visualization, has an impact on learning bubble sort. The research was conducted in the form of a quasi-experiment in primary and secondary schools in the city of Split. The participants were divided into two groups, experimental (CS Unplugged teaching method) and control (classic teaching method). As part of the research, the participants took a pre-test, a mid-test, and a post-test. Analysis of those tests led to the following results: CS Unplugged does not significantly affect the immediate students' knowledge of bubble sort, but it has a positive effect on the retention of the same, and that effect is statistically significant among primary school students.

Keywords: AV technology, CS Unplugged, bubble sort

Popis slika i tablica

Slika 2.1 Raspodjela učenika osnovnih škola po spolu 6
Slika 2.2 Raspodjela učenika osnovnih škola po spolu unutar Eksperimentalne skupine 6
Slika 2.3 Raspodjela učenika osnovnih škola po spolu unutar Kontrolne skupine 6
Slika 2.4 Raspodjela učenika srednjih škola po spolu 7
Slika 2.5 Raspodjela učenika srednjih škola po spolu unutar Eksperimentalne skupine 7
Slika 2.6 Raspodjela učenika srednjih škola po spolu unutar Kontrolne skupine 7
Slika 2.7 Indeks težine čestica predtesta (OŠ) 11
Slika 2.8 Indeks težine čestica predtesta (SŠ) 11
Slika 2.9 Indeks težine čestica međutesta (OŠ) 12
Slika 2.10 Indeks težine čestica posttesta (OŠ) 12
Slika 2.11 Indeks težine čestica međutesta (SŠ) 13
Slika 2.12 Indeks težine čestica posttesta (SŠ) 14
Slika 3.1 Postoci ostvarenih bodova na međutestu i posttestu (OŠ) 17
Slika 3.2 Postoci točnih odgovora na zadnjem zadatku međutesta i posttesta (OŠ) 18
Slika 3.3 Postoci ostvarenih bodova učenika ujednačenih po sposobnosti (OŠ) 20
Slika 3.4 Postoci točnih odgovora Eksperimentalne skupine po spolu (OŠ) 21
Slika 3.5 Postoci točnih odgovora Kontrolne skupine po spolu (OŠ) 22
Slika 3.6 Postoci ostvarenih bodova na međutestu i posttestu (SŠ) 24
Slika 3.7 Postoci točnih odgovora na zadnjem zadatku međutesta i posttesta (SŠ) 25
Slika 3.8 Postoci ostvarenih bodova učenika ujednačenih po sposobnosti (SŠ) 27
Slika 3.9 Postoci točnih odgovora Eksperimentalne skupine po spolu (SŠ) 28
Slika 3.10 Postoci točnih odgovora Kontrolne skupine po spolu (SŠ) 29
Slika 3.11 Miskoncepcija "dva broja u neispravnom redoslijedu" (OŠ) 30

Slika 3.12 Miskoncepcija "dva broja u neispravnom redoslijedu" (SŠ) 31
Slika 3.13 Miskoncepcija "prolazak kroz red" 31
Slika 3.14 Miskoncepcija "najveći nesortirani broj" 32

Tablica 2.1 Metrijske karakteristike testova (OŠ) 13
Tablica 2.2 Metrijske karakteristike testova (SŠ) 14
Tablica 3.1 Deskriptivna statistika predtesta (OŠ) 16
Tablica 3.2 Rezultati Mann-Whitney U testa (OŠ) 16
Tablica 3.3 Deskriptivna statistika međutesta (OŠ) 17
Tablica 3.4 Deskriptivna statistika posttesta (OŠ) 17
Tablica 3.5 Rezultati Wilcoxonova testa (OŠ) 18
Tablica 3.6 Rezultati učenika ujednačenih po sposobnosti (OŠ) 19
Tablica 3.7 Rezultati Eksperimentalne skupine po spolu (OŠ) 20
Tablica 3.8 Rezultati Kontrolne skupine po spolu (OŠ) 21
Tablica 3.9 Deskriptivna statistika predtesta (SŠ) 23
Tablica 3.10 Rezultati Mann-Whitney U testa (SŠ) 23
Tablica 3.11 Deskriptivna statistika međutesta (SŠ) 23
Tablica 3.12 Deskriptivna statistika posttesta (SŠ) 24
Tablica 3.13 Rezultati Wilcoxonova testa (SŠ) 25
Tablica 3.14 Rezultati učenika ujednačenih po sposobnosti (SŠ) 26
Tablica 3.15 Rezultati Eksperimentalne skupine po spolu (SŠ) 27
Tablica 3.16 Rezultati Kontrolne skupine po spolu (SŠ) 28

Prilozi

Upute za Eksperimentalnu skupinu

BUBBLE SORT

Postavi kartice na stol na način da ih poredaš prema zadanom redoslijedu simbola (simbol kartice nalazi se u njezinom lijevom gornjem kutu).

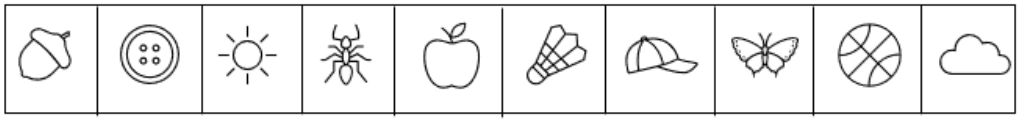

Ovako okrenute kartice predstavljaju nesortirani niz.

1. Okreni prvu karticu u nizu.
2. Ponavljaj sljedeće korake dok ne okreneš zadnju nesortiranu karticu u nizu:
    1) Okreni iduću karticu u nizu.
    2) Ako je vrijednost prve okrenute kartice veća od vrijednosti druge okrenute kartice, zamijeni im mjesta.
    3) Preokreni karticu s manjom vrijednošću.
3. U slučaju da sve kartice u nizu nisu sortirane, vrati se na korak 1.

1.

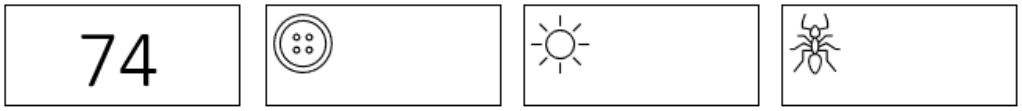

2. 1)

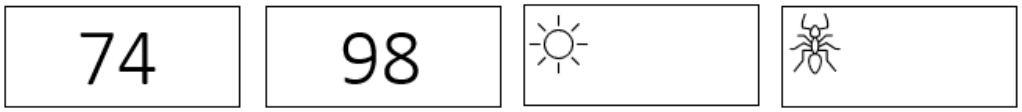

2. 2)

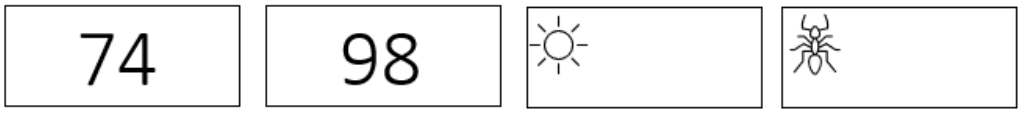

2. 3)

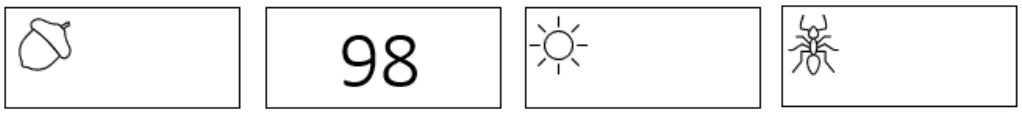

Redoslijed simbola za Eksperimentalnu skupinu

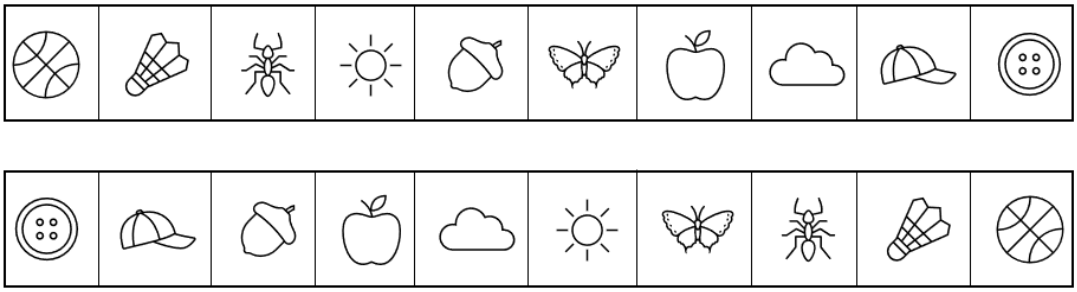

Upute za Kontrolnu skupinu

Algoritam sortiranja

1. Pročitaj prvi broj u nizu.
2. Ponavljaj sljedeće korake dok ne pročitaš zadnji nesortirani broj u nizu:
   1) Pročitaj idući broj u nizu.
   2) Ako je prvi pročitani broj veći od drugog pročitanog broja, zamijeni im mjesta.
3. U slučaju da svi brojevi u nizu nisu sortirani, vrati se na korak 1.

Predtest

Ime prezime, razred_____

	Zadaci
1.	Nastavi niz: A B A C A D A E __ __ __
2.	Nastavi niz: 3 4 6 7 9 10 12 13 15 16 ___ ___ ___
3.	Nastavi niz s dvije kombinacije slova: JKLMNO JKLMON JKLOMN JKOLMN _____ _____
4.	Ako riječ *algoritam* sadrži manje od 9 slova i više od 3 samoglasnika, napiši prvo slovo. Inače napiši zadnje slovo? _____
5.	Ako su i Ana i Frane stariji od Tomislava, a Hrvoje je mlađi od Ane, ali stariji od Frane, napiši redoslijed od najmlađeg do najstarijeg? **Odgovor**:
6.	Paula, Ana i Ivana imaju zanimanja programer, učitelj i kuhar. Paula je niža od Ane, ali viša od Ivane. Učitelj je najviši, a kuhar najniži. Kojeg su zanimanja Paula, Ana i Ivana? Tko je najviši, a tko najniži? **Odgovor**:
7.	Od šestero ljudi svatko je naručio po jednu kuglicu sladoleda. Naručili su 3 kuglice od vanilije, 2 kuglice od čokolade i jednu kuglicu od limuna. Ukrasili su sladolede s 3 trešnje, 2 vafla i jednim čokoladnim listićem, po jedan ukras na svaki sladoled. Nakon ukrašavanja nitko od njih šestero nije imao jednake sladolede. Koja od sljedećih kombinacija nije moguća? **Zaokruži odgovor**: A) čokolada s trešnjom B) vanilija s trešnjom C) limun s vaflom D) čokolada s vaflom E) vanilija s čokoladnim listićem
8.	Četiri košare sadrže redom 1, 4, 6 i 9 jabuka. Koliko najmanje jabuka treba premjestiti da bi u košarama bio isti broj jabuka? **Zaokruži odgovor**: A) 3 B) 4 C) 5 D) 6 E) 7

9.

Poredak medalja s Olimpijskih igara održanih 2016. godine prikazan je u tablici ispod. Stupci „Zlato“, „Srebro“ i „Bronca“ pokazuju količinu zlatnih, srebrnih i brončanih medalji koje je osvojila pojedina država.

Poredak	Država	Zlato	Srebro	Bronca
1	SAD	46	37	38
2	Velika Britanija	27	23	17
3	Kina	26	18	26
4	Rusija	19	18	19
5	Njemačka	17	10	15
6	Japan	12	8	21
7	Francuska	10	18	14
8	Južna Koreja	9	3	9
9	Italija	8	12	8
10	Australija	8	11	10
11	Nizozemska	8	7	4
12	Mađarska	8	3	4

Zamisli da je Nizozemska dobila još jednu zlatnu medalju. Koja bi onda Nizozemska bila po redu u konačnom poretku u tablici? _____

10.

Na Terezinom stolu nalazi se 7 olovaka. Slika ispod prikazuje početni položaj olovaka u jednom redu. Broj ispod olovke označava njenu duljinu (2 4 7 6 5 3 1).

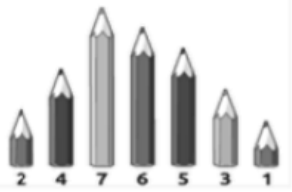

Tereza se igra olovkama uspoređujući duljinu dviju susjednih olovaka. Mijenja raspored susjednih olovaka prema sljedećem pravilu:

-ako je lijeva olovka dulja od desne olovke zamijeni njihova mjesta,
-uspoređuje sa sljedećom olovkom u nizu,
-i nastavlja usporedbu dok ne dođe do kraja reda.

Ovo nazivamo postupkom prolaska kroz red.

U prvom retku tablice navedene su duljine olovaka prema njihovom početnom položaju, a u drugom retku tablice navedene su duljine olovaka nakon što je Tereza napravila jedan prolaz kroz red. Nadopuni tablicu na način da u svaki idući redak tablice navedeš duljine olovaka nakon idućeg prolaska kroz red.

Odgovor:

Početni niz	**2**	**4**	**7**	**6**	**5**	**3**	**1**
Nakon 1. prolaska	2	4	6	5	3	1	7
Nakon 2. prolaska							
...							

Međutest za učenike osnovnih škola

Ime prezime i razred:_____

Prouči sljedeći niz i prve dvije zamjene prema bubble sort algoritmu.

Početni niz	**2**	**3**	**4**	**9**	**8**	**7**	**5**
Nakon 1. zamjene	2	3	4	8	9	7	5
Nakon 2. zamjene	2	3	4	8	7	9	5

1. Koji od ponuđenih odgovora prikazuje redoslijed brojeva nakon **3. zamjene** susjednih elemenata niza. (Zaokruži točan odgovor)

   a) 2 3 4 7 8 9 5

   b) 2 3 4 8 7 5 9

   c) 2 3 4 5 8 7 9

   d) 2 3 4 5 7 8 9

   e) 2 3 4 7 8 5 9

2. Koji od ponuđenih odgovora prikazuje redoslijed brojeva nakon **4. zamjene** susjednih elemenata niza. (Zaokruži točan odgovor)

   a) 2 3 4 7 8 9 5

   b) 2 3 4 8 7 5 9

   c) 2 3 4 5 8 7 9

   d) 2 3 4 5 7 8 9

   e) 2 3 4 7 8 5 9

3. Koliko je zamjena susjednih elemenata niza potrebno napraviti da bi niz postao sortiran? (Zaokruži točan odgovor)

   a) 7

   b) 6

   c) 5

   d) 4

   e) 3

4. U svaki idući redak tablice navedi redoslijed brojeva nakon nove zamjene susjednih elemenata niza.

Početni niz	**2**	**3**	**4**	**9**	**8**	**7**	**5**
Nakon 1. zamjene	2	3	4	8	9	7	5
Nakon 2. zamjene	2	3	4	8	7	9	5
Nakon 3. zamjene							
...							

Posttest za učenike osnovnih škola

Ime prezime i razred:_____

Zadan je početni niz brojeva koji se sortira od najmanjeg prema najvećem *bubble sort* algoritmom.

Početni niz	**2**	**3**	**4**	**9**	**8**	**7**	**5**

1. Koji od ponuđenih odgovora prikazuje redoslijed brojeva nakon **3. zamjene** susjednih elemenata niza? (Zaokruži točan odgovor)

   a) 2 3 4 7 8 5 9

   b) 2 3 4 7 8 9 5

   c) 2 3 4 8 7 5 9

   d) 2 3 4 5 8 7 9

   e) 2 3 4 5 7 8 9

2. Koji od ponuđenih odgovora prikazuje redoslijed brojeva nakon **4. zamjene** susjednih elemenata niza? (Zaokruži točan odgovor)

   a) 2 3 4 7 8 5 9

   b) 2 3 4 7 8 9 5

   c) 2 3 4 8 7 5 9

   d) 2 3 4 5 8 7 9

   e) 2 3 4 5 7 8 9

3. Koliko je zamjena susjednih elemenata niza potrebno napraviti da bi niz postao sortiran? (Zaokruži točan odgovor)

   a) 3

   b) 4

   c) 5

   d) 6

   e) 7

4. U svaki idući redak tablice navedi redoslijed brojeva nakon nove zamjene susjednih elemenata niza.

Početni niz	**2**	**3**	**4**	**9**	**8**	**7**	**5**
Nakon 1. zamjene							
Nakon 2. zamjene							
Nakon 3. zamjene							
...							

Međutest za učenike srednjih škola

Ime prezime i razred:_____

Prouči sljedeći niz i prve dvije zamjene prema bubble sort algoritmu.

Početni niz	**2**	**3**	**4**	**9**	**8**	**7**	**5**
Nakon 1. zamjene	2	3	4	8	9	7	5
Nakon 2. zamjene	2	3	4	8	7	9	5

1. Na praznu crtu ispod navedi redoslijed brojeva nakon **3. zamjene** susjednih elemenata niza.

   _____

2. Na praznu crtu ispod navedi redoslijed brojeva nakon **4. zamjene** susjednih elemenata niza.

   _____

3. Koliko je zamjena susjednih elemenata niza potrebno napraviti da bi niz postao sortiran? (Zaokruži točan odgovor)

   a) 7
   b) 6
   c) 5
   d) 4
   e) 3

4. U prvom retku tablice naveden je početni redoslijed brojeva u nizu. Ako se zadani niz brojeva sortira pomoću bubble sort algoritma, koji od ponuđenih odgovora prikazuje redoslijed brojeva nakon **7. zamjene** susjednih elemenata niza? (Zaokruži točan odgovor)

Početni niz	**9**	**2**	**7**	**8**	**5**	**4**	**3**
Nakon 1. zamjene	2	9	7	8	5	4	3
Nakon 2. zamjene	2	7	9	8	5	4	3

   a) 2 7 5 8 3 4 9
   b) 2 7 8 5 9 3 4
   c) 2 7 8 5 4 9 3
   d) 2 7 8 9 4 5 3
   e) 2 7 5 8 4 3 9

5. U prvom retku tablice naveden je početni redoslijed brojeva u nizu. Ako se zadani niz brojeva sortira pomoću bubble sort algoritma, koliko je zamjena susjednih elemenata niza potrebno napraviti da bi niz postao sortiran? (Zaokruži točan odgovor)

Početni niz	**2**	**8**	**7**	**5**	**4**	**3**	**9**
Nakon 1. zamjene	2	7	8	5	4	3	9
Nakon 2. zamjene	2	7	5	8	4	3	9

a) 7

b) 8

c) 9

d) 10

e) 11

6. U prvom retku tablice naveden je početni redoslijed brojeva u nizu. Dovrši započeto sortiranje zadanog niza brojeva pomoću bubble sort algoritma na način da u svaki idući redak tablice navedeš redoslijed brojeva nakon nove zamjene susjednih elemenata niza.

Početni niz	**5**	**8**	**3**	**2**	**9**	**4**	**7**
Nakon 1. zamjene	5	3	8	2	9	4	7
Nakon 2. zamjene	5	3	2	8	9	4	7
Nakon 3. zamjene	5	3	2	8	4	9	7
...							

Posttest za učenike srednjih škola

Ime prezime i razred:_____

Zadan je početni niz brojeva koji se sortira od najmanjeg prema najvećem *bubble sort* algoritmom.

Početni niz	2	3	4	9	8	7	5

1. Na praznu crtu ispod navedi redoslijed brojeva nakon **3. zamjene** susjednih elemenata niza.

   _____

2. Na praznu crtu ispod navedi redoslijed brojeva nakon **4. zamjene** susjednih elemenata niza.

   _____

3. Koliko je zamjena susjednih elemenata niza potrebno napraviti da bi niz postao sortiran? (Zaokruži točan odgovor)

   a) 3
   b) 4
   c) 5
   d) 6
   e) 7

4. Zadan je početni niz brojeva koji se sortira od najmanjeg prema najvećem *bubble sort* algoritmom. Koji od ponuđenih odgovora prikazuje redoslijed brojeva nakon **7. zamjene** susjednih elemenata niza? (Zaokruži točan odgovor)

Početni niz	9	2	7	8	5	4	3

   a) 2 7 5 8 4 3 9
   b) 2 7 5 8 3 4 9
   c) 2 7 8 5 9 3 4
   d) 2 7 8 5 4 9 3
   e) 2 7 8 9 4 5 3

5. Zadan je početni niz brojeva koji se sortira od najmanjeg prema najvećem *bubble sort* algoritmom. Koliko je zamjena susjednih elemenata niza potrebno napraviti da bi niz postao sortiran? (Zaokruži točan odgovor)

Početni niz	**2 8 7 5 4 3 9**

a) 11
b) 10
c) 9
d) 8
e) 7

6. U prvom retku tablice naveden je početni redoslijed brojeva u nizu. Sortiraj zadani niz brojeva od najmanjeg prema najvećem pomoću *bubble sort* algoritma na način da u svaki idući redak tablice navedeš redoslijed brojeva nakon nove zamjene susjednih elemenata niza.

Početni niz	**5 8 3 2 9 4 7**
Nakon 1. zamjene	
Nakon 2. zamjene	
Nakon 3. zamjene	
...	

Anketa

1. Koliko ti se sviđa tema današnjeg sata informatike? (zaokruži broj koji označava tvoj odabir)

   Vrlo malo 1 2 3 4 Jako mi se sviđa

2. Koliko ti se sviđa način na koji se danas radilo (bez računala)? (zaokruži broj koji označava tvoj odabir)

   Vrlo malo 1 2 3 4 Jako mi se sviđa

3. Koliko ti se sviđa način rješavanja problema programiranjem (u Pythonu)? (zaokruži broj koji označava tvoj odabir)

   Vrlo malo 1 2 3 4 Jako mi se sviđa

4. Je li ti draži način rješavanja problema programiranjem (u Pythonu) ili na način na koji se danas radilo (bez računala)?
   a) Da, draže mi je programiranje (u Pythonu)
   b) Ne, draže mi je rješavanje problema bez računala

5. Ako želiš komentirati nešto u vezi današnjeg sata informatike, napiši svoje mišljenje u nastavku.