Fluentnost računanja kod studenata Učiteljskog studija

Karega, Lucija

Master's thesis / Diplomski rad

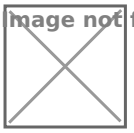
2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zadar / Sveučilište u Zadru**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:162:272402

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

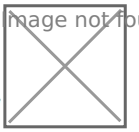
Download date / Datum preuzimanja: **2024-03-28**



Repository / Repozitorij:

University of Zadar Institutional Repository





Sveučilište u Zadru

Odjel za izobrazbu učitelja i odgojitelja - Odsjek za razrednu nastavu
Integrirani preddiplomski i diplomski sveučilišni studij za učitelje



Lucija Karega

Fluentnost računanja kod studenata Učiteljskog studija

Diplomski rad

Zadar, 2018.

Sveučilište u Zadru

Odjel za izobrazbu učitelja i odgojitelja - Odsjek za razrednu nastavu
Integrirani preddiplomski i diplomski sveučilišni studij za učitelje

Fluentnost računanja kod studenata Učiteljskog studija

Diplomski rad

Studentica:
Lucija Karega

Mentorica:
Doc.dr.sc. Maja Cindrić

Zadar, 2018.

Izjava o akademskoj čestitosti

Ja, **Lucija Karega,** ovime izjavljujem da je moj **diplomski** rad pod naslovom **Fluentnost računanja kod studenata Učiteljskog studija** rezultat mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na izvore i radove navedene u bilješkama i popisu literature. Ni jedan dio mojega rada nije napisan na nedopušten način, odnosno nije prepisan iz necitiranih radova i ne krši bilo čija autorska prava.

Izjavljujem da ni jedan dio ovoga rada nije iskorišten u kojem drugom radu pri bilo kojoj drugoj visokoškolskoj, znanstvenoj, obrazovnoj ili inoj ustanovi.

Sadržaj mojega rada u potpunosti odgovara sadržaju obranjenoga i nakon obrane uređenoga rada.

Zadar, 31. listopada 2018.

Zahvala

Veliku zahvalnost u prvom redu dugujem svojoj mentorici doc. dr. sc. Maji Cindrić koja je prihvatila mentorstvo te mi svojim stručnim savjetima omogućila realizaciju teme diplomskog rada. Kao izvrsnom mentoru i najboljem predavaču hvala joj na pomoći, dostupnosti i strpljenju koje mi je pružila tijekom izrade diplomskog rada.
Također, zahvalu upućujem svim studentima koji su sudjelovali u istraživanju te na taj način pripomogli u realizaciji ovog diplomskog rada.

Zahvaljujem i svojoj obitelji i prijateljima koji su bili uz mene te me uvijek upućivali na pravi put.
Na kraju, najveću zaslugu za ono što sam postigla pripisujem svojim roditeljima koji su uvijek bili uz mene. Hvala im na svemu što su mi omogućili.

Veliko hvala svima!

Sadržaj

UVOD…… 7

1. STJECANJE MATEMATIČKOG UMIJEĆA – CILJ NASTAVE MATEMATIKE…… 9

1.1. Konceptualno i proceduralno znanje…… 12

1.1.1. Definicija..... 12

1.1.2. Povezanost proceduralnog i konceptualnog znanja..... 13

1.1.3. Provjeravanje konceptualnog i proceduralnog znanja..... 15

1.2. Fluentnost u računanju…… 18

1.2.1. Fluentnost u ranoj dobi..... 18

1.2.2. Matematička anksioznost i fluentnost računanja..... 19

1.3. Put razvoja fluentnosti u računanju kod učenika OŠ…….. 22

1.3.1. Učenje činjeničnog znanja u matematici..... 22

1.3.2. Mentalno računanje..... 24

1.3.2.1. Strategije mentalnog računanja..... 24

1.3.2.2. Procjena kod mentalnog računanja..... 28

1.3.2.3. Pogreške kod mentalnog računanja..... 28

1.4. Fluentnost računanja kao dio matematičkog umijeća učitelja..... 29

2. METODA ISTRAŽIVANJA…….. 31

2.1. Cilj i problemi istraživanja.....,..... 31

2.2. Sudionici istraživanja..... 32

2.2.1. Uzorak kvantitativnog dijela istraživanja..... 32

2.2.2. Uzorak kvalitativnog dijela istraživanja..... 32

2.3. Mjerni instrumenti..... 32

2.3.1. Instrumenti kvantitativnog dijela istraživanja..... 32

2.3.2. Instrumenti kvalitativnog dijela istraživanja..... 33

2.4. Postupak istraživanja..... 33

2.4.1. Kvantitativni dio istraživanja..... 33

2.4.2. Kvalitativni dio istraživanja..... 33

3. REZULTATI ISTRAŽIVANJA……. 34

3.1. Kvantitativni dio istraživanja..... 34

3.2. Kvalitativni dio - tematska analiza…….. 40

4. REZULTATI ISTRAŽIVANJA I RASPRAVA……..…… 41
5. ZAKLJUČAK..... 43
6. SAŽETAK..... 45
7. ABSTRACT..... 46
8. LITERATURA..... 47
9. PRILOZI..... 51
10. ŽIVOTOPIS..... 57

UVOD

U ovom diplomskom radu polazimo od ideje da je fluentnost bitna stavka za svakog obrazovanog čovjeka. S tom idejom smo u kvantitativnom dijelu sastavili Test mentalnog računanja čiji je cilj proučiti fluentnost računanja kod studenata Učiteljskog studija.
Postavili smo tri problema i tri hipoteze koje su na kraju potvrđene.
Pretpostavili smo da će s obzirom na različite težine zadatak (jednostavnije i kompleksnije) uspješnost studenata biti prosječna, zatim da će studenti diplomskog studija biti uspješniji u Testu mentalnog računanja nego studenti preddiplomskog studija te da strategije računanja kod studenata nisu uniformne.

U kvalitativnom dijelu provedeno je 5 intervjua, a cilj je bio ispitati individualne strategije računanja te mišljenje o vlastitom mentalnom računanju i riješenosti testa mentalnog računanja. Iz intervjua smo saznali jesu li studenti koristili različite strategije odnosno tehnike kao bi došli do točnog rješenja. U obradi podataka korištena je deskriptivna statistika, te jednosmjerna analiza varijance i Fisher LSD-test.
U teorijskom dijelu rada bavili smo se pitanjem matematičkog umijeća, numeričkog smisla, pitanjem proceduralnog i konceptualnog znanja te njihove međusobne povezanosti i utjecaja na fluentnost.
Potom smo definirali pojam same fluentnosti te put njezinog razvoja čije je postizanje bitan dio osnovnog matematičkog obrazovanja studenata.

Zbog potpunosti cjeline teorijskog dijela te bolje razumijevanja istraživanja objašnjena je i uloga mentalnog računanja kod djece koja na taj način razviju matematičke osnovne činjenica kako bi ih mogli primijeniti u složenijim računskim radnjama te interakcije između učitelja i učenika. S obzirom da je nastava „živ proces“, usredotočenje na mentalno računanje ključno je za revitalizaciju školske matematike. Kao što McIntosh (2000) u svojem radu navodi, mentalno računanje može se jednostavno i učinkovito procijeniti pisanim testom. On objašnjava da ako se od djece traži da riješe problem i napišu detaljno objašnjenje postupka i strategija koje su koristili za rješavanje, nastavnici mogu lako procijeniti dubinu njihovog znanja o mentalnom računanju.

Teorijski dio podupire problemski dio istraživanja, objašnjava zašto je nužno raditi na mentalnom računanju te stavlja naglasak na fluentnost računanja.

1. STJECANJE MATEMATIČKOG UMIJEĆA – CILJ NASTAVE MATEMATIKE

Danas je prisutno nepodijeljeno mišljenje o velikoj važnosti matematičkog obrazovanja u dječjoj ranoj dobi. Matematički sadržaji se kao neprimjetna nit provlače kroz sve dječje igre i aktivnosti. Shvaćanje kvantitativnih odnosa, prostornih odnosa, uočavanje oblika predmeta i dimenzija predmeta, korištenje raznovrsnih načina mjerenja i dr. postaje jedan od osnovnih uvjeta za obavljanje niza praktičnih radnji u ovoj dobi. Naime, razvoj matematičkih pojmova je sredstvo od iznimne važnosti za razumijevanje prirodnih i društvenih fenomena koji okružuju dijete ove dobi.

U proteklih 20 godina velik broj edukacijskih politika potiče učitelje i odgojitelje da učenicima pruže priliku za aktivno sudjelovanje u vlastitom učenju od samih početaka te naglašavaju kako se djetetov razvoj najbolje odvija kroz igru. Upravo iskustvo igre potiče razvoj mozga pa se služeći procesom prirodnog učenja, koji ide kroz igru, postavljamo i temelje matematičkog razvoja.

Uvodeći dijete u percipiranje i razumijevanje odnosa u bliskom okruženju, matematika pomaže razvijanju dječjeg mišljenja što je jedan od glavnih matematičkih ciljeva.

Cilj nastave matematike je stjecanje temeljnih matematičkih znanja potrebnih za razumijevanje pojava i zakonitosti u prirodi i društvu, stjecanje osnovne matematičke pismenosti i razvijanje sposobnosti i umijeća rješavanja matematičkih problema.

Djeca se vrlo rado bave matematikom, a već u ranoj dobi počinju razvijati svijest o brojevima i količini predmeta. Vrlo rano počinju prebrojavati, razvrstavati, uočavati odnose u prostoru, stjecati smisao za količinu te upravo tada možemo čuti kako ljudi upotrebljavaju termin „smisao za brojanje“. Točniji naziv bio bi numerički smisao.

Ono što ljudi ponekad nazivaju *numeričkim smislom* zapravo je skupina vještina koje djeci omogućuju rad s brojevima.

To uključuje sposobnosti:

- razumijevanje količine
- razumijevanje odnosa veće, manje ili jednako
- prepoznavanje veze između pojedinačnih stavki i skupina stavki

- razumijevanje simbola koji predstavljaju količine (na primjer, *7* znači istu stvar kao *sedam*).
- uspoređivanje brojeva (na primjer, 13 je veći od 10, a 6 polovina od 12).
- razumijevanje redoslijeda brojeva na popisu: 1., 2., 3. itd.

Neki ljudi imaju izraženiji numerički smisao od drugih.
Ideje o numeričkom smislu nisu jednostavne za razumijevanje jer su teoretičari tek nedavno započeli istraživanja o tome što zaista znači imati i koristiti znanje o broju.
Svakako čini se da postoji opći konsenzus da se numerički smisao bavi razmišljanjem o broju, kreativnosti broja, razvoju organizacijskih procesa koji pomažu povezati ideje o brojevima i njihovu razumnost u različitim kontekstima (Howden, 1989).
Neki primjeri koji bi ukazivali da djeca imaju numerički smisao:

- dijete zna da je 45 jednako 3 pomnoženo s 10 i 3 pomnoženo s 5
- znati da je razlika brojeva 12 i 8 jednaka razlici brojeva 125 i 121
- razumjeti da je 73-29 isto što i 74-30 (dodavajući 1 na 73 treba dodati i 1 na 29)

Ovi primjeri o numeričkom smislu jasno ističu značenje razumijevanja brojeva, njihovog sastava i odnosa pri rješavanju problema. Kako bi dijete što bolje razvilo numerički smisao i razumjelo bilo koji oblik računanja potrebno ga je poticati na razvoj vještina mentalnog računanja (Hope & Sherrill, 1987). Kada učenici ne uspiju savladati računanje, to je često zato što ne razumiju numeričko značenje, ali kada rade na bogatoj matematici i problemima razvijaju numerički smisao te se mogu prisjetiti matematičkih činjenica. Usredotočujući se na često pamćenje formula zapamte činjenice bez numeričkog smisla što dovede do pogreške kao one koja je dovela do nacionalnog ismijavanja britanskog političara (7 pomnoženo s 8 jest 54). Općenito, manjak numeričkog smisla je doveo do više katastrofalnih pogrešaka, kao što je Hubbleov teleskop koji je namjeravao fotografirati zvijezde u svemiru. Teleskop je tražio zvijezde u određenom klasteru, ali zbog toga nije uspio - netko je napravio aritmetičku pogrešku u programiranju teleskopa (LA Times, 1990). Općenito, što više ističemo memoriranje učenicima oni su manje spremni razmišljati o brojevima i njihovim odnosima te koristiti i razvijati osjećaj za broj.
Više o važnosti mentalnog računanja saznat ćemo u idućim stranicama.

Djeca postaju svjesna brojeva kroz igru, istraživanje i brojne svakodnevne aktivnosti.

Buduće razumijevanje matematike mladih učenika zahtijeva rano znanje temeljeno na visokokvalitetnom, zahtjevnom i pristupačnom obrazovanju matematike.

Mala djeca u svakoj sredini trebaju doživjeti matematiku kroz djelotvorne, istraživačke nastavne planove i nastavne prakse. Takve prakse zauzvrat zahtijevaju da nastavnici imaju potporu organizacijskih struktura i resursa koji im omogućuju uspjeh u ovom izazovnom i važnom radu.

Istraživanja o učenju djece u prvih šest godina života pokazuju važnost ranih iskustava u matematici. Odgojitelji ranog djetinjstva trebaju aktivno uvoditi matematičke pojmove, metode i jezik kroz niz odgovarajućih iskustava i strategija podučavanja na temelju istraživanja. Učitelji trebaju voditi djecu kako bi vidjeli povezanost ideja unutar matematike, kao i kod drugih predmeta, razvijajući svoje matematičko znanje te također moraju potaknuti djecu da komuniciraju, objašnjavajući svoje razmišljanje kad su u interakciji s drugim učenicima.

Upravo efektivni profesionalni programi tkaju zajedno matematiku, pedagogiju i znanje o razvoju djeteta i obiteljskim odnosima (Ball & Cohen, 1999) te angažirajuća i ohrabrujuća klima za dječje rane susrete s matematikom razvija svoje povjerenje u njihovu sposobnost razumijevanja i korištenja matematike.

Ova pozitivna iskustva pomažu djeci da razviju dispozicije poput znatiželje, mašte, fleksibilnosti, točnosti, brzine, inventivnosti i upornosti, što doprinosi njihovom budućem uspjehu u školi i izvan nje (Clements & Conference Working Group, 2004).

1.1. Konceptualno i proceduralno znanje

1.1.1. Definicija

„Klasifikaciju matematičkog znanja na konceptualno i proceduralno uvodi James Hiebert (1986). Definira ih na sljedeći način:

„Konceptualno znanje karakterizira se kao znanje bogato u odnosima. Možemo ga shvatiti kao mrežu znanja koja povezuje odvojene dijelove informacija. Ti su odnosi prožeti pojedinačnim činjenicama i pravilima tako da smisleno umrežavaju sve dijelove informacija.“

„Proceduralno znanje sačinjeno je od dva različita dijela. Prvi se dio odnosi na formalni jezik, odnosno uporabu matematičkih simbola. Drugi se dio sastoji od pravila, algoritama ili postupaka kojima se rješava matematički zadatak. To su korak-po-korak upute koje propisuju kako rješavati zadatak. Ključna je značajka tih postupaka da se provode unaprijed određenim slijedom.“

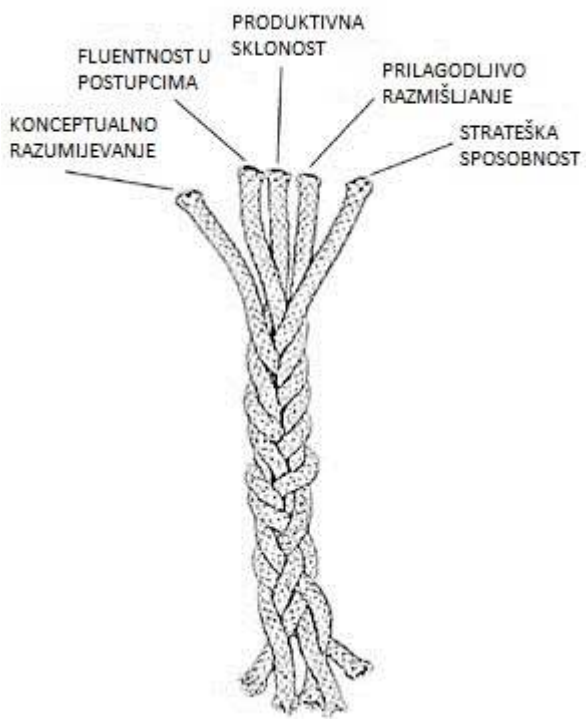
Iz ovog se može izvesti zaključak kako konceptualno znanje omogućava razumijevanje pojmova, ideja i koncepata dok nam proceduralno znanje, koje uključuje vještine, algoritme i strategije, omogućava brzo i efikasno rješavanje problema.

Ove navedene definicije naišle su na velik broj kritika jer je najveća zamjerka ta da je proceduralno znanje površno u odnosu na konceptualno znanje koje s smatra dubinskim.

Star (2000) prema Dijanić i Debelec (2015) smatra da je dubinska razina znanja povezana s razumijevanjem, apstrakcijom, kritičkom prosudbom i procjenom te je ta razina strukturirana i pohranjena u memoriji na način koji ga čini neizmjerno korisnim za izvođenje postupka rješavanja zadataka, dok je površinska razina znanja povezana s pogreškama, reprodukcijom i učenjem napamet. Također naglašava da se koncepti usvajaju kada se postojeće činjenično znanje može prepoznati, objasniti, stvoriti i usporediti.

1.1.2. Povezanost proceduralnog i konceptualnog znanja

Fluentnost računanja, o kojoj je u ovom radu riječ, spona je konceptualnog i proceduralnog matematičkog znanja, a potječe od aktivnosti u samim početcima učenja matematike i ovisi o razvoju osjećaja za brojeve. Matematičko znanje sastoji se od 5 niti (slika 1) koje su međusobno isprepletene i međusobno povezane, a ukazuju nam na to da matematička vještina nije jednodimenzionalna osobina i ne može se postići fokusiranjem na samo jednu ili dvije od ovih niti (National Research Council, 2001).



Slika 1. Niti matematičkog umijeća

- konceptualno razumijevanje - razumijevanje matematičkih pojmova, operacija i odnosa

- sposobnost postupka fluentnosti u obavljanju postupaka fleksibilno, precizno, učinkovito i na odgovarajući način

- strateška sposobnost - sposobnost formuliranja, predstavljanja i rješavanja matematičkih problema

- sposobnost prilagodljivog rasuđivanja za logičku misao, razmišljanje, objašnjenje i opravdanje

- produktivna sklonost - uobičajena sklonost da matematika bude razumna, korisna i vrijedna, zajedno s vjerovanjem u marljivost i vlastitu učinkovitost

Konceptualno i proceduralno znanje matematike predstavlja razliku koja je godinama doživljavala velike rasprave. Pitanja o tome kako učenici uče matematiku, a posebno kako bi trebali biti podučeni, uključuje spekulacije o tome koja je vrsta znanja važnija ili koja bi mogla biti odgovarajuća ravnoteža između njih. Osim toga, rasprave o konceptualnom i proceduralnom znanju proširuju se izvan granica matematičkog obrazovanja. Razlika između koncepata i postupaka igra važnu ulogu u općenitijim pitanjima stjecanja znanja. U nekim teorijama učenja i razvoja, razlika zauzima središnje mjesto. Iako su vrste znanja koja se identificiraju od teorije do teorije nisu identične, postoji mnogo preklapanja. Razlike su prvenstveno u naglasku, a ne prema vrsti.
Na primjer, Piaget (1978) prema Hiebert (1987) razlikuje pojmovno razumijevanje i uspješnu akciju; Tulving (1983) razlikuje semantičku memoriju i epizodnu memoriju; Anderson (1983) razlikuje deklarativno i procesno znanje. Paralele se razlikuju u filozofskim teorijama znanja. Na primjer, Scheffler (1965) razlikuje propozicionalnu uporabu "znajući to" i postupnu uporabu "znajući kako".

U *Principima i standardima za nastavu matematike* (NCTM, 2000) velika se važnost pridaje ravnoteži proceduralnog i konceptualnog znanja kao temelja za obrazovanje u nastavi matematike: *"Razvoj perfektnog znanja zahtijeva ravnotežu i vezu između konceptualnog razumijevanja i vještina računanja. S jedne strane, metode računanja koje su previše uvježbane bez razumijevanje se često zaboravljaju ili krivo pamte. S druge strane, razumijevanje bez tečnosti u računanju može sputavati proces rješavanja problema.“*
Već duže vrijeme vodi se rasprava o tome koje je znanje važnije i kojim redoslijedom bi ih se trebalo usvajati. Empirijskim istraživanjima (Haapasalo i Kadijevich, 2000 prema Dijanić i

Debelec 2015) pokazano je da postoje četiri značajke koje povezuju proceduralno i konceptualno znanje: (1) proceduralno i konceptualno znanje nisu povezani, (2) proceduralno je znanje nužno i dovoljno za stjecanje konceptualnog, (3) konceptualno je znanje nužno, ali ne i dovoljno za stjecanje proceduralnog, (4) proceduralno je znanje nužno, ali ne i dovoljno za stjecanje konceptualnog.

Također, Rittle-Johnson, Siegler i Alibali (2001) utvrđuju da postoji, ne samo pozitivna korelacija između proceduralnog i konceptualnog znanja, nego i prognostička povezanost. To znači da je stjecanje jedne vrste znanja preduvjet za stjecanje one druge, a redoslijed ovisi o vrsti područja. Njihova istraživanja pokazala su da je razvoj konceptualnog razumijevanja i proceduralnih vještina vrsta procesa u kojima se proceduralno i konceptualno znanje razvijaju uzastopno i tako se međusobno i zajednički nadopunjuju. Viša razina usvojenosti jednoga vodi do više razine usvojenosti drugoga što opet izaziva višu razinu onoga prvoga i tako dalje Uz sve to iznimno je važno da učenici aktivno rade na zadanom problemu, traže slične zadatke, slušaju upute učitelja, raspravljaju s drugim učenicima te provode refleksiju vlastitog znanja.

1.1.3. Provjeravanje proceduralnog i konceptualnog znanja

Proceduralno znanje provjerava se praćenjem rješavanja zadatka u kojima se primjenjuje naučeni algoritam, a naglasak je na točnosti rješenja i brzini rješavanja zadataka.

U hrvatskim udžbenicima i zbirkama zadataka prevladavaju takvi zadatci – zadatci zatvorenog tipa bez konteksta s naglaskom na računanje i izvođenje operacija koji ujedno dominiraju i u pisanim provjerama. Međutim i o zadatcima za provjeru konceptualnog znanja u posljednje se vrijeme u Hrvatskoj sve više govori (Banić, 2013, Trupčević i Glasnović Gracin, 2014 prema Debelec 2015).

Hiebert i Lefevre (1986) provjeravali su ih usmeno kako bi ispitali u kojoj su mjeri pojmovi, ideje i koncepti međusobno povezani, ali brojni su autori nakon njih počeli uvoditi neke nove specifične zadatke za provjeru konceptualnog znanja. Rittle-Johnson i Schneider (2015) sistematiziraju tipove zadataka kojima se konceptualno znanje može provjeravati implicitno ili eksplicitno. Implicitno provjeravanje provodi se zadacima kategoričkog izbora (alternativnog, višestrukog), procjenama (procijeniti nepoznate postupke, procijeniti primjer nekog koncepta, procijeniti kvalitetu tuđeg odgovora), zadatcima prevođenja iz jednog prikaza u drugi, uspoređivanjem količina, pronalaženjem prečica za dani postupak i sl.

Eksplicitno mjerenje konceptualnog znanja uključuje provjeru poznavanja definicije, obrazloženje neke tvrdnje, izradu konceptualne mape i sl.

Još jedna bitna razlika između zadataka za provjeravanje ovih dviju vrsta znanja jest koliko su učenici s njima upoznati ranije. Nepisanim pravilom proceduralno znanje provjerava se zadatcima kakve su učenici već prije vidjeli te takve slične rješavali.

Konceptualno znanje se provjerava zadatcima koji su učenicima novi, nepoznati, dotad neviđeni kako bi se doista ispitalo poznavanje koncepata, a ne naučenih pravila ili postupaka. Zanimljivo je primijetiti kako jedan te isti zadatak kod jednog učenika može provjeriti konceptualno, a kod drugog proceduralno znanje. Ako učenik nikada prije nije vidio takav ili sličan zadatak, pri rješavanju će do izražaja doći njegovo konceptualno znanje. Međutim, ukoliko je učenik već rješavao takav ili slične zadatke, ne možemo biti sigurni provjeravamo li „poznatim“ zadatkom konceptualno znanje, uvježbani postupak ili bez razumijevanja naučene činjenice.

Dosadašnja praksa nastave matematike u Hrvatskoj pokazuje kako je naglasak najčešće na proceduralnom znanju, dok se ono konceptualno podrazumijeva samo po sebi i na neki način zapostavlja. Opće poznata je činjenica da učenici, ako se od njih traži rješavanje zadataka zatvorenoga tipa (očekuje se točno izvođenje postupaka rješavanja zadatka) onda će oni takvu (proceduralnu) matematiku učiti jer ih se tako ispituje. No, međutim bitno je i konceptualno znanje matematike. Na primjer, učenici koji razumiju vrijednost broja i druge koncepte imaju veću vjerojatnost od učenika bez takvog razumijevanja da izmisle vlastite postupke za rješavanje, te isto tako i veću vjerojatnost za lakšim usvajanjem točnih metoda koje su drugi prezentirali njima.

Dakle, učenje kako zbrajati i oduzimati brojeve ne mora uključivati sasvim nove i nepovezane ideje. Isti se pristup može primijeniti i za množenje i dijeljenje.

Ako učenici razumiju da je zbrajanje komutativno (npr. 7 + 5 = 5 + 7), njihovo učenje osnovnih dodatnih kombinacija smanjuje se za gotovo polovicu. Iskorištavajući svoje znanje o drugim odnosima kao što je to između parova (npr., 5 + 5 i 6 + 6) i drugih suma, oni mogu još više smanjiti broj dodatnih kombinacija koje su im potrebne za učenje.

Budući da mala djeca prilično rano nauče parove, mogu ih koristiti za srodne parove. Na primjer, mogu vidjeti da je 6 + 7 samo za jedan više od 6 + 6. Ovi odnosi omogućuju učenicima da nauče nove kombinacije zbrajanja jer stvaraju nova znanja, a ne oslanjaju se na ono što su naučili napamet. Konceptualno razumijevanje, stoga, je mudra investicija koja se isplati za učenike na mnoge načine.

Ono je, uz poznavanje pravila i postupaka, nužno za rješavanje složenijih matematičkih problema i zadataka otvorenoga tipa kakvi se susreću u svakodnevnom životu.
Poučeni s ovim, na nastavi bi trebalo više inzistirati na pitanju „zašto?“ pri rješavanju zadataka i općenito na verbalnoj matematičkoj komunikaciji u razredu. U pisane provjere znanja trebalo bi uvoditi nove tipove zadatka kojima bi se uz dosadašnje proceduralno provjeravalo i konceptualno znanje učenika.

Pokret „New math“ šezdesetih godina u SAD-u (koji mnogi vide kao odgovor na brz znanstveni napredak koji je napravio sovjetski režim) usredotočio se gotovo isključivo na konceptualno razumijevanje; zahtijevajući od studenata da usvajaju matematičke pojmove, opravdavajući svaku pretpostavku s jasno naznačenom logikom. Potrebno je reći da je taj pokušaj nametanja strožih nastavnih planova i programa bio toliko ekstrem da je rezultat samo bio zbunjenost roditelja, učitelja i učenika.
S druge strane zagovornici proceduralne fluentnosti žestoko su se protivili bilo kakvom naglašavanju konceptualnog razumijevanja. Osim za računanje, neki su algoritmi važni kao samostalni koncepti, što ponovo ilustrira vezu između konceptualnog razumijevanja i proceduralne fluentnost.
Točnost i učinkovitost mogu se poboljšati praksom, što također može pomoći učenicima da održavaju fluentnost. Ponekad je procjena dovoljno dobra, kao kod izračuna napojnice na računu u restoranu ili vraćanja ostatka u trgovini, ali proceduralna fluentnost i konceptualno razumijevanje često se „gledaju“ kao dva natjecatelja.

No, kada bi suprotstavili umijeće i razumijevanje dobili bi lažnu podjelu jer kao što smo ranije spomenuli, ova su dva pojma međusobno isprepletena.
Razumijevanje čini vještine učenja lakše, manje podložne uobičajenim pogreškama i manje sklone zaboravljanju. Isto tako, određena razina vještine potrebna je za učenje mnogih matematičkih pojmova s razumijevanjem, a upotreba postupaka može pomoći u jačanju i razvijanju tog razumijevanja.

1.2. Fluentnost u računanju

1.2.1. Fluentnost u ranoj dobi

Mnogi od nas učili su matematiku kao skup nepovezanih pravila, činjenica i postupaka.
Učenici moraju biti fleksibilni kako bi mogli odabrati odgovarajuću strategiju za problem tj. koristiti različite metode za rješavanje problema.
Kada vrlo malena djeca prvo nauče računati, koriste svoje prste kao manipulative.
Međutim, mnoga djeca i dalje se oslanjaju na svoje prste kao primarne alate za računanje nakon što se presele na svladavanje dodavanja i oduzimanja. Na tom je koraku brojanje prsta problematično. Iako ta metoda računanja može biti djelotvorna, ona u konačnici obuzdava matematički razvoj djeteta tako da ih zadržava u ograničavajućem prostoru glave od jednog do drugog brojanja.
Kao takvi, „brojači prsta“ uskoro će ustanoviti da ova tehnika brzo postaje težak, neučinkovit i netočan put kada počnu raditi s većim brojem. Dugoročno je daleko učinkovitije potaknuti učenike na razvoj numeričke tečnosti odnosno fluentnosti. Što je numerička fluentnost? Kao što je rečeno to je sposobnost učenika da se podsjeti na osnovne činjenice mentalno i bez napora. Na primjer, osnovni kamen temeljac numeričke fluentnosti jest rad s brojevima mentalno.
Kad djeca prelaze na tehnike u kojima ne koriste svoje prste za računanje, njihovo povjerenje brojanjem i brojevima općenito će eksponencijalno rasti, a njihova sposobnost da bez napora napreduju slijedi. Kako vrijeme odmiče i oprašta se od osnovne prakse zbrajanja i oduzimanja, fluentni učenici lakše će rješavati složenije operacije poput množenja i dijeljenja. Tijekom izgradnje numeričke fluentnosti koja se neće dogoditi preko noći (zahtijeva stalnu i dosljednu praksu koja će raditi s tim okvirima tijekom vremena), učenici će kontinuirano uživati u prednostima te postati jači matematički mislioci.

1.2.2. Matematička anksioznost i fluentnost računanja

Kada spomenemo riječ matematika mnogima prva misao bude rješavanje velike količine stereotipnih zadataka, nerazumljivo gradivo koje potiče uvrštavanje brojeva u već predviđene formule za to bez ikakvog smisla i zapravo životne koristi.
Neka istraživanja (Widmer i Chavez, 2001) govore da učitelji u osnovnoj školi gaje negativne stavove o matematici.
Istraživanja stavova o anksioznosti prema matematici ranih 70-ih godina prošlog stoljeća osvijestili su činjenicu da u modernom društvu koje se bori za ravnopravnost muškaraca i žena, žene ipak ne sudjeluju u velikom broju zanimanja koja su usko povezana sa matematikom i srodnim predmetima. Čini se da filter koji upravo žene odvaja od visoko plaćenih i prestižnih zanimanja jest matematika (prema Hyde i sur., 1990).
S obzirom na navedeno, opravdana je važnost koja se pridaje istraživanjima straha od matematike, budući da mnogi znanstvenici drže da upravo stavovi, vjerovanja i osjećaji koje pojedinac ima o matematici utječu na njegov strah od matematike i njeno izbjegavanje.
Također se pokazalo da takvi učitelji svoja stajališta prenose i na učenike, a kako se među tim učenicima možda nalaze budući profesori matematike krug negativnih mišljenja, razmišljanja i stavova zatvara se na samom početku školovanja.
Anksioznost matematike definirana je kao osjećaj napetosti koja ometa manipulaciju brojevima i rješavanje matematičkih problema (Tobias, 1993).

Istraživanja su pokazale da učenici najbolje uče kada su aktivni, a ne pasivni (Spikell, 1993). Svatko je sposoban učiti, ali može naučiti na različite načine. Stoga, lekcije moraju biti predstavljene na različite načine. Na primjer, različiti načini za podučavanje novog koncepta mogu biti kroz glumačke, kooperativne skupine, vizualne pomagala, tehnologiju itd. Nadalje učenici su različitiji nego prije četrdeset godina. Današnji postavljaju pitanja zašto se nešto radi na taj način ili na onaj način i zašto ne na ovaj način?

Dok god učenici nisu postavili pitanje zašto je nešto takvo i takvo te zašto je matematički pojam takav i takav jednostavno su memorirali i mehanički obavili potrebne operacije, bez razumijevanja. Danas učenici imaju potrebu za praktičnom matematikom stoga matematika mora biti relevantna za njihov svakodnevni život. Da bi naučili matematiku, moraju se

angažirati u istraživanju, pretpostavljanju i razmišljanju, a ne samo u učenju pravila i postupaka. Prijašnja negativna iskustva učenika u matematici i kod kuće u učenju matematike često se prenose i uzrokuju nedostatak razumijevanja, a opće poznata činjenica jest da je matematika najčešće povezana s boli i frustracijom.

Na primjer, neplaćeni računi, nepredviđeni dugovi samo su neka od negativnih iskustava povezanih s brojevima. Roditelji bi trebali pokazati svojoj djeci kako se brojevi uspješno koriste u pozitivnim ugodnim načinima, kao što su kuhanje, šivanje, sport, rješavanje problema u hobijima i popravke u kući. Matematika se mora promatrati u pozitivnom svjetlu kako bi se smanjila anksioznost. Stanje uma osobe ima veliki utjecaj na njegov uspjeh.

Učenici uče matematiku najbolje kad pristupaju temi kao nešto što vole. Postoji zajednička i štetna zabluda u matematici - ideja da su odlični studenti matematike učenici koji matematičke probleme rješavaju brzo. No, je li to istina?

Novi standardi nacionalnog kurikuluma naglašavaju memoriju matematičkih činjenica.
Matematičke činjenice su temeljne pretpostavke o matematici, kao što je (2 • 2 = 4), na primjer.
Dok istraživanje pokazuje da je poznavanje matematičkih činjenica važno, Boaler (2015) navodi da je najbolji način da učenici znaju matematičke činjenice redovito korištenje i razvijanje numeričkih odnosa.
S druge strane, osobe s "numeričkim smislom" su one koje fleksibilno mogu koristiti brojeve.. Na primjer, kada se traži rješenje problema 6 • 8, netko s numeričkim smislom možda je zapamtio 48, ali će također moći koristiti strategiju kao što je 10 • 5 i oduzimanje dva. Nadalje, u kritičnom istraživačkom projektu istraživači su proučavali učenike dok su rješavali brojne probleme (Gray & Tall,1994).
Istraživači su otkrili važnu razliku između učenika: učenici s visokim uspjehom koristili su numerički smisao, učenici s niskim uspjehom nisu uspjeli. Učenici visokih postignuća pristupili su problemu 19 + 7 promjenom problema u, na primjer, 20 + 6. Kada su učenici s niskim uspjehom došli na red, došli su i problemi s oduzimanjem kao što su 21-16; Broje unazad, s početkom 21 i odbrojavanje, što je izuzetno teško učiniti. Učenici visokih postignuća koriste strategije kao što su promjena brojeva 20 - 15 što je puno lakše. Istraživači su zaključili da su niski uspjesi često povezani s niskim postignućima ne zato što znaju manje, već zbog toga što ne upotrebljavaju brojeve fleksibilno, usmjereni su na krivi put, često od

ranog doba, pokušavajući zapamtiti metode umjesto da stvore fleksibilnu interakciju s brojevima.

Nadalje, u svom radu, "*Fluency without the Fear*", Boaler nudi aktivnosti za učitelje i roditelje koji pomažu učenicima u učenju činjenica matematike istodobno s razvojem numeričkog smisla. To uključuje razgovore o broju, zbrajanje i množenje itd. Važno je da ove aktivnosti uključuju fokus na vizualni prikaz broja. Kada učenici povezuju vizualne i simboličke prikaze brojeva, koriste različite putove u mozgu, koji produbljuju svoje učenje, što je pokazano nedavnim istraživanjima mozga.

"*Matematičke činjenice su vrlo mali dio matematike, ali nažalost učenici koji ne upamte matematičke činjenice često vjeruju da nikada ne mogu biti uspješni s matematikom i okrenu se od matematike kao predmeta*", nadodala je. Prethodna istraživanja pokazala su da studenti koji su lakše zapamtili nisu bili bolji u postizanju rezultata, nisu imali ono što su istraživači opisali kao viša sposobnost matematike ili više IQ bodova. Istraživajući ulogu mozga jedine razlike koje su pronašli istraživači bili su u regiji mozga pod nazivom hipokampus. No, prema profesorici Boaler, kada su učenici pod stresom - kao kad rješavaju matematička pitanja pod pritiskom vremena - radna memorija postaje blokirana i učenici se ne mogu lako sjetiti matematičkih činjenica koje su prethodno učili. Neke procjene upućuju na to da barem trećina učenika doživljava ekstremni stres ili "anksioznost matematike" tokom vremenskog testa.

Boaler suprotstavlja zajednički pristup poučavanju matematike s onim poučavanja engleskog jezika. Na engleskom jeziku učenik čita i razumije romane ili poeziju, bez potrebe za pamćenjem značenja riječi kroz testiranje. Oni uče riječi u različitim situacijama - razgovor, čitanje i pisanje. "*Nijedan engleski student ne bi rekao niti misli da učenje o engleskom govori o brzom pamćenju i brzom prisjećanju riječi*", dodala je.

"Matematička fluentnost" često se pogrešno tumači, s prekomjernim naglaskom na brzinu i pamćenje, rekla je. *"Radim s puno matematičara, i jedna stvar koju primijetim o njima jest da oni nisu osobito brzi s brojevima; u stvari neki od njih su prilično spori. Ovo nije loša stvar; oni su spori jer duboko i pažljivo razmišljaju o matematici*.“

Nadalje osvrnula se na poznatog francuskog matematičara Laurenta Schwartza, koji je u svojoj autobiografiji napisao da se često u školi često osjećao glupo, budući da je bio jedan od najsporijih matematičara u razredu, navodeći kako anksioznost i strah od matematike igraju veliku ulogu u odustajanju od matematike“.

Učenici vole pokazati različite strategije i obično su potpuno angažirani i fascinirani različitim metodama koje se pojavljuju. Uče mentalnu matematiku, imaju priliku pamtiti matematičke činjenice, a također razvijaju konceptualno razumijevanje brojeva i aritmetičkih svojstava koja su ključna za uspjeh u algebri i šire. Ukratko jačaju vlastito mentalno računanje.
Na primjer, učitelj može postaviti zadatak 18 • 5 i reći učenicima da rješavaju problem na ove različite načine:

20•5=100	10•5=50	18•5=9•10	18•2=36	9•5=45
2•5=10	8•5=40	9•10=90	2•36=72	45•2=90
100-10=90	50+40=90		18+72=90	

1.3. Put razvoja fluentnosti u računanju kod učenika OŠ

1.3.1. Učenje činjeničnog znanja u matematici

U činjenično znanje ubrajamo temeljne elemente (poznavanje terminologije te poznavanje specifičnih detalja i elemenata) koje učenici moraju poznavati kako bi se upoznali s određenom disciplinom ili riješili problem (Anderson, Krathwohl i suradnici 2001).

U kognitivnom području Gagné, Briggs i Wager (1992) izdvajaju tri kategorije znanja: deklarativno, proceduralno i metakognitivno. Deklarativno znanje uključuje poznavanje činjenica i razumijevanje odnosa među njima. Anderson i Krathwohl (2001) deklarativno znanje raščlanjuju na činjenično i konceptualno čime se dobivaju četiri različite kategorije znanja opisane u Tablici 1.

Kao što smo naveli u prethodnom dijelu o konceptualnom znanju poznavanje koncepata omogućuje učenicima da uspostavljaju veze između elemenata znanja.
Kada studenti steknu konceptualno razumijevanje u području matematike, vide veze između koncepata i postupaka i mogu dati argumente da objasne zašto su neke činjenice posljedice drugih. Na taj način stječu povjerenje u svoje znanje i matematičko umijeće, koje onda pruža osnovu iz koje se mogu preseliti na drugu razinu razumijevanja.

Učenje matematike uključuje pamćenje činjenica, ovladavanje rutinama, usvajanje i razumijevanje pojmova te razvijanje sposobnosti rješavanja problema.
Rješavanje problema je središnji cilj, a često i sredstvo za podučavanje matematike. Kako bi ih riješili potrebno je primijeniti matematičko znanje o činjenicama, vještinama i postupcima. Budući da su povezane činjenice i metode s razumijevanjem, lakše ih je pamtiti i koristiti, a ako učenici razumiju metodu, vjerojatno je se neće sjetiti pogrešno. Prate ono čega se sjećaju i pokušavaju shvatiti ima li smisla.
Znanje koje je naučeno razumijevanjem pruža osnovu za stvaranje novih znanja i za rješavanje novih i nepoznatih problem. Usvajanje činjeničnog znanja je najniži obrazovni cilj, a odnosi se na temeljna znanja koja student mora steći kako bi shvatio smisao predmeta koji uči. To se prisjećanje može odnositi na široki raspon sadržaja: od usvajanja terminologije, preko prisjećanja na činjenice, pa sve do sjećanja na složene teorije. Sve što treba postići na toj razini znanja jest prisjetiti se određene informacije.

Općenito, činjenice i rutine kognitivno su lakše, kako učenicima koji njima trebaju ovladati tako i učiteljima koji ih učenicima trebaju prenijeti. Osim toga, razinu njihove usvojenosti iznimno je lakše provjeriti. Učenici mnogo teže ovladavaju pojmovima i problemima, učiteljima ih je teže podučavati, a i mnogo je teže provjeriti razinu njihove usvojenost. Gledano objektivno, ovo su razlozi zbog kojih obrazovanje matematike uglavnom ne ide dalje od činjenica i pojednostavljenih pojmova, iako bi njegov glavni cilj trebalo biti razvijanje sposobnosti i stjecanje sigurnosti u rješavanju problema.

Kada bi ovo sve sumirali u jedno, glavna karakteristika činjenica jest da ih treba pamtiti.
Nakon 12 godina školovanja, trebali bi znati osnovne matematičke formule, ali nažalost kako se inzistira na desecima i više formula, učenici na kraju ne znaju primijeniti niti osnovne formule zbog „nezapamćenih“.

Tablica 1. Četiri različite kategorije znanja

Dimenzije znanja	Podvrste znanja
činjenično znanje	• Znanje pojmova (terminologije) • Znanje specifičnih detalja i elemenata
konceptualno znanje	• Znanje klasifikacija i kategorija • Znanje principa i generalizacija • Znanje teorija modela i struktura
proceduralno znanje	• Znanje sadržajno specifičnih postupaka i algoritama • Znanje specifičnih tehnika i metoda • Znanje kriterija koji uvjetuju uporabu primjerenih postupaka
metakognitivno znanje	• Strategijsko znanje • Znanje o kognitivnim ciljevima, uključujući i odgovarajuće kontekstualno uvjetovano znanje • Znanje o sebi

1.3.2. Mentalno računanje

1.3.2.1. Strategije mentalnog računanja

Strateška kompetencija odnosi se na sposobnost formuliranja matematičkih problema, njihovo predstavljanje i rješavanje.

Iako u školi učenici često imaju jasno navedene probleme za rješavanje, izvan škole susreću se situacijama u kojima je teško shvatiti srž problema.

Trebali bi znati različite strategije rješavanja, kao i koje strategije mogu biti korisne za rješavanje određenog problema. Primjerice, učenike bi se moglo pitati da na prste izračunaju 7+2. Problem nastaje kada trebaju broj 7 pokazati na obje ruke i nadodati još 2.

Prema (Liebeck,1984) što prije treba prebrojavanje kao strategiju računanja izbaciti te do kraja prvog razreda zadatke računanja u skupu brojeva do 20 rješavati ne prebrojavajući, ali za neke učenike to je nemoguća misija. Ponekad kada nekog učenika pitate koji je rezultat zbroja neka dva broja, npr. 5 + 4, ono nakon nekoliko sekundi gledajući u vas automatski izrekne odgovor: „9!“ To je dokaz da je dijete negdje u glavi pohranilo informaciju koliko je to „četiri“ i koliko je to „pet“, samo je trebalo vrijeme da u glavi vizualizira slike četiri prsta i

pet prstiju te izračuna zbroj. Dijete je moglo koristiti dvije strategije pri tom računanju – dinamičku (odbrojavati drugi pribrojnik) ili statičku (zamisliti prikaze oba pribrojnika i odmah na pogled znati koliko je to). U početnoj fazi bitno je u zadatcima računanja do 10 produktivno koristiti prste, što znači pri rješavanju zadatka 4 + 3 broj 7 postaviti kao 4 prsta i 3 prsta, ne brojeći ih nego pokazujući odmah "četiri na hrpi" i „tri na hrpi".

Pavlin-Bernardić (2006) navodi da se različite strategije pojavljuju ne samo kod različite djece iste dobi, nego i kod istog djeteta pri rješavanju sličnih zadataka.

S formuliranim problemom u ruci, učenikov prvi korak u rješavanju je matematički problem prikazati na neki način, bilo numerički, simbolički, verbalno ili grafički. Predstavljanje problemske situacije zahtijeva, prvo, da učenik gradi mentalnu sliku svojih bitnih sastavnica.
Kako bi postali strateški kompetentni, učenici prvo moraju razumjeti situaciju, uključujući njezine ključne značajke.

"Mentalno računanje: Strategijski pristup" (McIntosh, 2004) vodi učitelje korak po korak za uvođenje strategija koje najviše pomažu učenicima da postanu "fleksibilni korisnici" mentalnog računanja. Heirdsfield i Lamb (2007) opisuju fleksibilnost u mentalnom računanju kao "zapošljavanje raznih učinkovitih mentalnih strategija, uzimajući u obzir kombinacije brojeva za informiranje o izboru mentalne strategije".
McIntoshov program predstavlja "razne učinkovite mentalne strategije" te se one vide kao sastavni dijelovi razvijanja "fleksibilnosti" koju smatra kao ključ za pomoć djeci da razumiju mentalno računanja. Budući da djeca dolaze u školu s prirodnim računalnim strategijama, važno je započeti raspravu o njima već u vrijeme pripreme.
Nakon što su ove osnovne strategije uvedene i ovladale, važno je da djeca razviju sofisticirane strategije. McIntoshovo istraživanje (HREF2, 2004) naglašava važnost razvoja opsega strategija mentalnog računanja i uključuje strategije dvoznamenkastog računanja. To podupiru Beishuizen i Anghileri (1998) koji sugeriraju da su se u prošlosti istraživanja strategija zbrajanja i oduzimanja gotovo koncentrirala na manje brojeve do 20. Danas strategije s većim dvoznamenkastim brojevima do 100 dobivaju više pozornosti.

Ove dvoznamenkaste strategije uključuju:

• Zbrajanje (npr. 28 + 35; 28 + 5 = 33, 33 + 30 = 63)

- Oduzimanje (npr. 28 + 35; 30 + 35 = 65, 65-2 = 63)
- Odvajanje desno na lijevo (npr. 28 + 35; 8 + 5 = 13, 20 + 30 = 50, 13 + 50 = 63)
- Odvajanje slijeva udesno (npr. 28 + 35; 20 + 30 = 50, 8 + 5 = 13, 50 + 13 = 63)

Kao i kod osnovnih strategija, dvoznamenkaste strategije moraju se izričito predavati djeci. Thompson i Smith (1999) razmatraju zbrajanje i oduzimanje kao najsofisticiraniji način korištenja za djecu. Ovo podupire i istraživanje Beishuizen (1993) koje je objasnilo da "slabiji učenici imaju tendenciju da koriste manje učinkovite strategije.“'

Razvijanje mentalnih strategija putem rasprava trebalo bi pomoći djeci da dobiju veću fleksibilnost u svom pristupu rješavanja problema i pružiti više uvida u svojstva numeričkog sustava.

Djeca će također saznati da postoji više od jednog načina da dođu do rješenja problema.

Varijacija na ***Kako ste to učinili?***

1. Kako biste to učinili *?* - U glavi, na papiru ili s kalkulatorom.

Postavlja se pitanje i svako dijete izabere način na koji bi riješili zadatak. Potom se od djece traži objašnjenje metode i zašto su je odabrali.

Drugi pristup uključuje traženje od djece da navedu izračun koji bi obavili u glavi, na papiru ili kalkulatoru i objasniti zašto bi to učinili .

2. Ako znam ..., tada znam i ...

Nudimo djeci izračun za primjer 10 • 5 = 50. Zatim pokazuju da ako znam 10 • 5 je 50 onda znam također 9 • 5, 11 • 5, 5 • 5, 10 • 50 i tako dalje.

Prezentira se djeci drugi izračun i zamoli ih se da pokažu kako je svaki izračun povezan s ostalima.

3. Mogu vidjeti.

Na primjer 12 • 18. Tada se može reći djeci: „Ja mogu vidjeti 2 • 6 • 18“, i također

2 • 6 • 9 • 2

4 • 6 • 9

4 • 3 • 2 • 9

4 • 3 • 2 • 3 • 3 i tako dalje.

Može ih se pitati je li neki od gore navedenih izračuna lakše izračunati i objasniti svoje razloge.

4. To je jednostavno!

Zamoli se djecu da razmisle o izračunu koji izgleda teško, ali je lako rješiv.

(Objasniti im zašto izračun izgleda teško).

npr. 3 • 2 • 7 • 5 • 5 • 2

Primjer ove aktivnosti može biti sljedeći.

To izgleda teško jer postoji mnogo brojeva, ali kad umnožite izgleda ovako 2 • 5 (što je 10) pomnožen s 2 • 5 ili 10, 10 • 10 je 100. Ostaje samo 3 • 7 dio, koji je 21, a ovo se pomnoži sa 100 da bi se dobio odgovor od 2100.

5. Izaberi!

„Ako imate jednu želju i mogli biste promijeniti jedan broj u sljedećem pitanju koji biste se promijenili ?“ Objasni zašto.

17 • 9

Promijenio bih devet u deset jer mi to olakšava množenje. Razvijajući svijest o metodi računanja i brojevima koji su uključeni, djeci se pomaže da dobiju smisao za izračun.

Visoka razina učinkovitosti u računanju je cilj kurikuluma matematike.

Put do računalne fluentnosti nije lagan za većinu studenata no međutim, jasno je da je predstavljanje numeričkog smisla i mentalnog računanja ključno za osnovu razumijevanja matematike i sposobnosti djeteta da lako računa.

1.3.2.2. Procjena kod mentalnog računanja

Neki nastavnici smatraju da je procjena mentalnog računanja izazov jer se to događa u dječjim glavama, ali to ne mora biti slučaj. Zapravo, djeca koja imaju čvrste vještine mentalnog računanja trebala bi imati znanje kako bi pružila puno detaljnije odgovore nego *'upravo sam to znala'*. Ako se redovita rasprava o strategijama podržava i vrednuje u učionicama, djeca će razviti vještine za jasno poznavanje metoda koje koriste za rješavanje problema. Kao što McIntosh (HREF2, 2004) navodi, "mentalno računanje može se jednostavno i učinkovito procijeniti pisanim testom“. On objašnjava da ako se od djece traži da riješe problem i napišu detaljno objašnjenje postupka i strategija koje su koristili za rješavanje, učitelji mogu lako procijeniti dubinu njihovog znanja o mentalnom računanju.
Pokazalo se da mentalno računanje ima snažne veze s razvojem numeričkog smisla u djece.
Kao što je već navedeno numerički smisao je opće razumijevanje o broju i operacijama, uz sposobnost i sklonost korištenja tog shvaćanja na fleksibilne načine.

1.3.2.3. Pogreške kod mentalnog računanja

Iako je znatan istraživački interes više usredotočen na strategije koje učenici koriste, vrlo malo istraživanja provedeno je na razinama sposobnosti u mentalnom računanju ili pogrešaka koje su učenici napravili u mentalnom računanju.
Prije tridesetak godina u osnovnim školama u mnogim zemljama diljem svijeta pojma mentalno računanje označavao je „računanje u glavi“.
U istraživanju tvrtke Biggs (1967) sudjelovalo je 69 razreda osnovnih škola, a zadatci su bili bazirani na mentalnom izračunu (osnovne računske operacije). Pitanja su uglavnom bila ograničena na osnovne činjenice, tj. na mentalne izračune u kojima se naglašava brzina i točnost. Istraživanje je pokazalo porast anksioznosti prema mentalnoj matematici i kako raspodjela vremena za rješavanje zadataka nije utjecala na rezultate.
U svom trogodišnjem istraživanju učenika u Tasmaniji u australskom glavnom području, McIntosh je otkrio obrasce u pogreškama računalnog računanja djece.
Jasno razlikujući dječje proceduralne i konceptualne pogreške, objašnjava da je "konceptualna pogreška napravljena zato što učenik ne razumije dovoljno prirodu brojeva ili operaciju koja je uključena" (HREF2, 2004), dok je "proceduralna pogreška ona u kojem učenik iako ima ukupni strateško razumijevanje ne zna što učiniti.

Na primjer, 0,1 • 0,1 = 0,2 i 3 ÷ 1/2 =1 1/2 bile su konceptualne pogreške, dok će 58 + 34 = 82 i 3 • 5 = 18 bile primjeri proceduralnih pogrešaka. Dok su proceduralne pogreške povezane s pisanim i mentalnim računanjem, sami postupci, a time i vrste pogrešaka, često su različiti.

Kao primjer, 74 - 30, česta pogreška bila je odgovor 36. Vjerojatno je da su učenici koji su napravili tu pogrešku imali ispravan cjelokupni postupak ili strategiju oduzimanja 4 od 74, oduzimanje 30 od 70, a zatim zamjena 4; ali postupak je doveo do oduzimanja, a ne dodavanja 4.

Ovo istraživanje pokazalo je da se mentalno računanje može jednostavno i učinkovito procijeniti pomoću pisanog testa.

Ostale pogreške su zabilježene kada djeca pokušavaju zamisliti i dovršiti pisani algoritam u svom umu jer im je za to potrebno previše vremena što će također biti vidljivo u istraživanju provedenom u ovom diplomskom radu.

1.4. Fluentnost računanja kao dio matematičkog umijeća učitelja

U odnosu na prošlost kada su učenici samo pasivno upijali objašnjenje učitelja o postupku rješavanja zadatka, a cilj nastavniku je bio samo istumačiti gradivo, danas se uloga nastavnika i učitelja promijenila. Sada se očekuje da djeca imaju vlastiti pristup rješavanja problema (Hiebert i sur., 1996).

Jedan od najučinkovitijih načina za uvođenje mentalnog računanja djeci je kroz cijeli školski pristup. Istraživanja (Heirdsfield i Lamb's 2007) su pokazala da ciljani program može rezultirati brzim poboljšanjem razvoja strategija za mentalno računanje. Takvi "ciljani programi" potiču učitelje i učenike da vide važnost mentalnog računanja u osnovnoj školi.

Jedan od najvažnijih rezultata cijelog školskog pristupa značajno je povećanje znanja nastavnika i razumijevanje eksplicitnog poučavanja o mentalnom računanju.

Callingham (2005) primijetio je da su "svi učitelji pokazali kako su promijenili svoje poučavanje na više eksplicitni način rješavanja mentalnih računanja, s manje naglaska na vježbu i praksu pisanih algoritama".

Očigledno, kako bi se poboljšali ishodi učenika u mentalnom računanju, razvoj pedagoškog znanja o sadržaju nastavnika treba biti fokus. Škole također trebaju imati strateški pristup

implementaciji tj. provedbi programa mentalnog računanja. Beishuizen i Anghileri (1998) primjećuju da "međunarodni rad sugerira da se strategije mentalnog računanja mogu podučavati stoga nastavnici i učitelji moraju koristiti i razvijati programe koji osiguravaju da se to ne dogodi.

Moraju pažljivo slušati, razumjeti dječje mišljenje i procijeniti je li to razmišljanje logično. Zatim, na temelju takve analize, učitelji moraju formulirati nova pitanja ili zadaće kako bi produbili razumijevanje, promakli djecu na učinkovitije ili sofisticirane metode ili ih osporili da konsolidiraju svoje postupke. Priprema učitelja za ovu novu ulogu nije jednostavna. Poticanje na razmišljanja da razvijaju računalnu fluentnost i njihovo analiziranje, generaliziranje i proširivanje strategija djeteta pomaže im da postignu mnoge ciljeve. Oni dobivaju fleksibilnost, produbljuju svoje razumijevanje problema i počinju cijeniti prednosti razvoja računalne fluentnosti djece.

2. METODA ISTRAŽIVANJA

2.1. Cilj i problemi istraživanja

Cilj ovog diplomskog rada je proučiti fluentnost računanja u matematici kod studenata učiteljskog studija.

Primarni cilj podučavanja matematike te moderni nastavni plan i program temeljen je na standardima matematičkog razmišljanja i razumijevanja, konceptualnog razumijevanja i rješavanja problema u realnim kontekstima. Prema tradicionalnoj matematici učenje sadržaja definiranog kao „fiksni i nepromjenjivi program“ mora se realizirati u određenom vremenu, a udžbenike se strogo slijedi. Naglasak je stavljen na računanje, brzinu i točnost rezultata kao glavnu svrhu i značajke matematike, a automatizacija računalnih operacija jedan je od glavnih ciljeva, osobito u početnoj nastavi matematike.

U suvremenom pristupu podučavanju matematike potiče se neovisnost i kreativnost u odabiru načina koji dovode do rješavanja zadanog problema. Rješavanje situacije problema postavljeno je na sredinu matematičke nastave, a od svih učenika očekuje se da će naučiti i koristiti matematičko razmišljanje, zaključivanje, dokazivanje, brinu i točnost.

Problem 1 – ispitati točnost rješavanja matematičkih zadataka studenata Učiteljskog studija Sveučilišta u Zadru (generalno)

Hipoteza 1 – s obzirom na različite težine zadatak (jednostavnije i kompleksnije) pretpostavlja se da će uspješnost studenata biti prosječna

Problem 2 – ispitati razlike među studentima u točnosti rješavanja matematičkih zadataka

Hipoteza 2 – s obzirom da se pokazalo da u testovima sposobnosti i inteligencije postoji efekt uvježbavanja u zadatcima (Pennequin, Sorel, Nanty i Fontaine 2010), a studenti Učiteljskog studija su odslušali kolegij *Metodika matematike* te se na taj način uvježbali u određenim matematičkim zadatcima, pretpostavlja se da će studenti diplomskog studija biti uspješniji u Testu mentalnog računanja nego studenti preddiplomskog studija

Problem 3 – ispitati individualne razlike u strategijama računanja (prilog intervju)

Hipoteza 3 – strategije računanja kod studenata nisu uniformne

2.2. Sudionici istraživanja

2.2.1. Uzorak kvantitativnog dijela istraživanja

U istraživanju je sveukupno sudjelovalo 139 studenata Učiteljskog studija sa Odjela za izobrazbu učitelja i odgojitelja Sveučilišta u Zadru (N_m =8, $N_ž$=131). Prosječna dob ispitanika u uzorku iznosila je 21 godinu (M=21.49, SD=1.66). Uzorak su sačinjavali studenti svih studijskih godina, pri čemu je bilo: 29 studenata prve godine (M_{dob} =19.69, $SD_{dob=}$ 0.76), 28 studenata druge (M_{dob} =20.32, $SD_{dob=}$ 0.61) i 28 studenata treće godine (M_{dob} =21.62, $SD_{dob=}$ 1.06), 33 studenta četvrte godine (M_{dob} =22.64, $SD_{dob=}$ 0.82) te 21 student pete godine studija (M_{dob} =23.57, $SD_{dob=}$ 1.33). Ispitanici su regrutirani tijekom predavanja u dogovoru s njihovim profesorima, što čini ovaj uzorak prigodnim.

2.2.2. Uzorak kvalitativnog dijela istraživanja

Provedeno je 5 intervjua u kojem su sudjelovali volonteri od prve do 5 godine.

Intervjuirano je 5 osoba ženskog spola (sa svake godine po 1 volonter) u dobi od 18-23 godine.

2.3. Mjerni instrumenti

2.3.1. Instrumenti kvantitativnog dijela istraživanja

U testu mentalnog računanja bilo je 70 zadataka koji su koncipirani po težini te ujedno tako i poredani (prilog). Ideja je dobivena od prethodnih istraživanja koja su slično izgledala (McIntosh, Bana, Farrell 1995).

Cilj ovo testa mentalnog računanja jest proučiti fluentnost računanja kod studenata Učiteljskog studija. S obzirom da je ovaj test konstruiran za potrebe ovog istraživanja, vrlo je visoke pouzdanosti unutarnje konzistencije, s Cronbach alpha koeficijentom od 0.90 na korištenom uzorku ispitanika“ – Maksimalna pouzdanost je 1.

2.3.2. Instrumenti kvalitativnog dijela istraživanja

Cilj intervjua je bio ispitati individualne strategije računanja od studenata Učiteljskog studija. Postavljeno je 5 pitanja: **„Kakvi su ti bili zadatci?“, „Što misliš o svom načinu rješavanja i kao si riješila ovaj test?“, „Prilikom rješavanja jesi li poznavala neke tehnike ili strategije i koje?“, „Misliš li da zapravo puno lošije mentalno računamo nego pismeno?“, „Misliš li da tehnologija ima utjecaja?“**

Svih 5 pitanja nalaze se u prilogu, sumirani su svi u jedan, ali ne radi se o fokus grupi jer volonteri su intervjuirani pojedinačno radi ekonomičnosti (utjecaj jednih na druge) obrade podataka.

2.4. Postupak istraživanja

2.4.1. Kvantitativni dio istraživanja

Istraživanje je provedeno u periodu svibnja 2018. godine na području Zadarske županije. Ispitanici su bili raspoređeni po godinama studija te ih se također zamolilo za sudjelovanje u istraživanju te im je rečeno da u bilo kojem trenutku mogu pitati ispitivača ako im je nešto nejasno ili odustati od istraživanja ako to žele. Naglasak je bio usmjeren na anonimnost testa te molbu za neprepisivanjem i rješavanjem zadatka pismeno. Svim ispitanicima su detaljno objašnjene upute (koje su i napisane na početku obje prezentirane skale) te im je zajamčena povjerljivost podataka i anonimnost. Ispunjavanje samog upitnika trajalo je od 10 do 15 minuta. Testiranje je obavljeno kroz jutro (9:00 h) nakon prvog predavanja.

2.4.2. Kvalitativni dio istraživanja

Volonteri su bili ispitani jedan po jedan (jutro). Cilj je bio ispitati individualne strategije računanja te mišljenje o vlastitom mentalnom računanju i riješenosti testa mentalnog računanja. Kako bi intervju bio što više pouzdaniji obavljen je odmah nakon testa mentalnog računanja.

3. REZULTATI ISTRAŽIVANJA

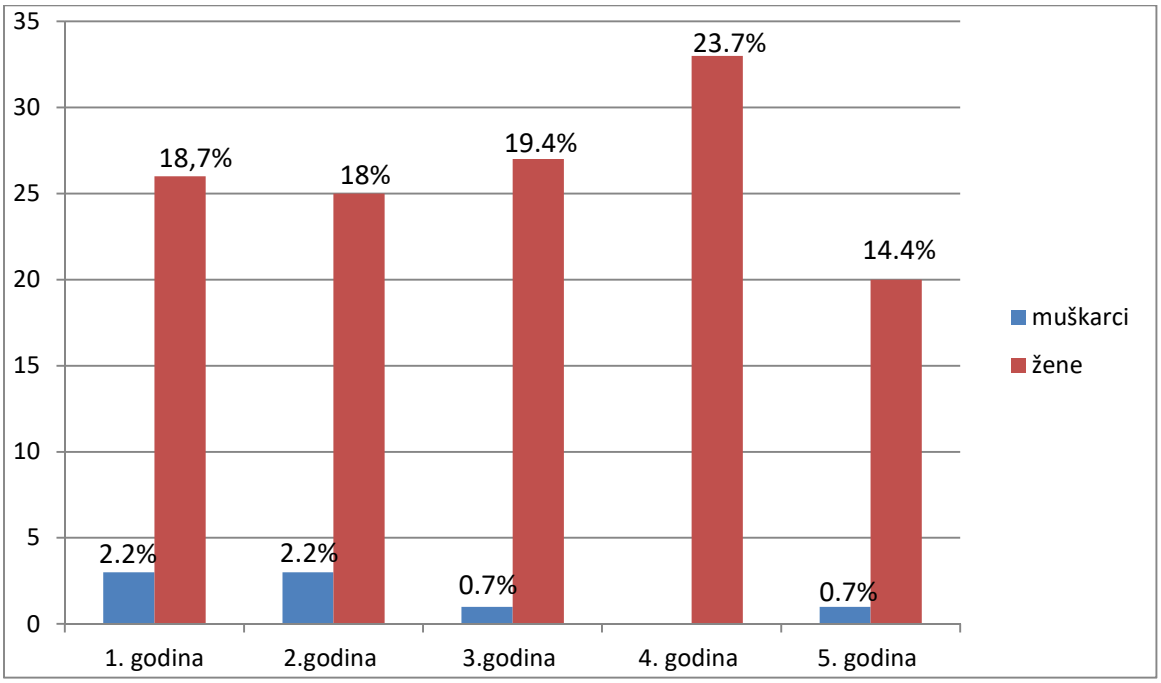
3.1. Kvantitativni dio istraživanja

Cilj ovog istraživanja bio je ispitati, proučiti matematičku fluentnost studenata učiteljskog studija, a problem ispitati točnost rješavanja matematičkih zadataka studenata Učiteljskog studija Sveučilišta u Zadru). U svrhu opisivanja korištenog uzorka, na istome su prvenstveno izračunati neki osnovni neparametrijski podaci.

1. **Problem – ispitati točnost rješavanja matematičkih zadataka**

   Tablica 2- Osnovni neparametrijski podaci (N, %) uzorka studenata Učiteljskog studija Sveučilišta u Zadru škola (N_m=8, $N_ž$=131).

Studijska Godina	Muškarci	Žene	Ukupno
1.	3 (2.2%)	26 (18.7%)	29 (20.9%)
2.	3 (2.2%)	25 (18%)	28 (20.1%)
3.	1 (0.7%)	27 (19.4%)	28 (20.1%)
4.	0	33 (23.7%)	33 (23.8%)
5.	1 (0.7%)	20 (14.4%)	21 (15.1%)
Ukupno	8 (5.8%)	131 (94.2%)	139



Slika 2 Grafički prikaz neparametrijskih podataka uzorka studenata svih studijskih godina Učiteljskog studija Sveučilišta u Zadru (N_m=8, $N_ž$=131).

Nadalje, prvenstveno kako bi se ispitala generalna točnost tj. uspješnost u Testu mentalnog računanja te razlike u točnosti rješavanja između pojedinih zadataka na testu, odnosno jesu li studenti rješavali neke zadatke uspješnije od drugih zadataka (u svakom zadatku je bilo 10 podzadataka), izračunata je jednosmjerna analiza varijance (ANOVA) za ponovljena mjerenja (svi studenti su rješavali svih sedam zadataka) na cjelokupnom uzorku studenata.

Tablica 3 Prikaz rezultata jednosmjerne analize varijance (ANOVA-e) za ponovljena mjerenja rezultatima za pojedine zadatke u testu na uzorku studenata Učiteljskog studija (N_m =8, $N_ž$=131).

	F	*df*	*p*
tip zadatka	141.509	6	0

Tablica 4 Prikaz prosječne riješenosti (*M, %, SD*) zadataka Testa mentalnog računanja na uzorku studenata Učiteljskog studija (N_m=8, $N_ž$=131).

Redni broj zadatka	*M*	*SD*
1.	9.37 (93.7%)	1.17
2.	8.98 (89.8%)	1.57
3.	7.22 (72.2%)	2.76
4.	7.96 (79.6%)	2.75
5.	6.14 (61.4%)	3.07
6.	6.58 (65.8%)	3.14
7.	3.60 (36,0%)	2.04
Prosječna riješenost po zadatku	7.12 (71.2%)	1.69

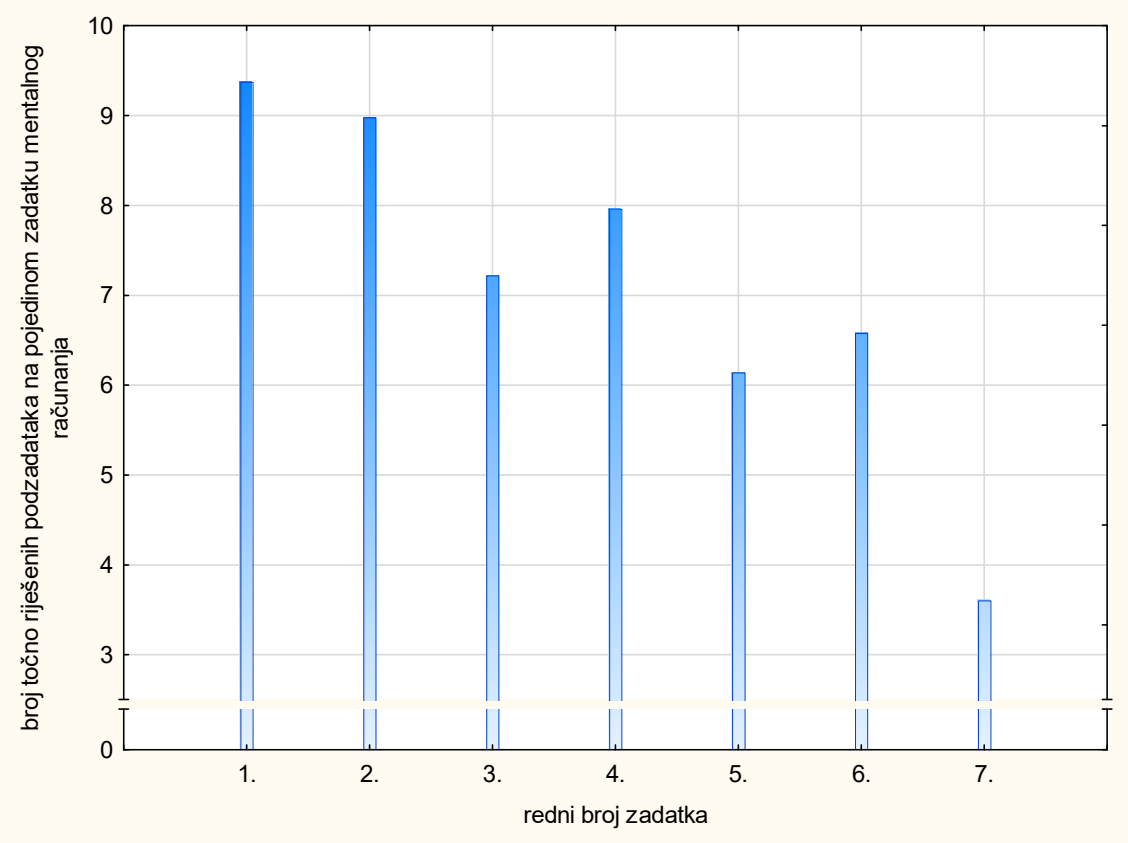
Izračunom jednosmjerne analize varijance (ANOVA-e) za ponovljena mjerenja, na razini cjelokupnog uzorka utvrđena je statistički značajna razlika u uspješnosti na različitim zadacima testa, uz razinu rizika manju od 1%. Drugim riječima, studenti su neke zadatke rješavali uspješnije od drugih zadataka. Međutim, kako bi se provjerilo koje su zadatke studenti rješavali uspješnije od drugih zadataka, odnosno koji zadaci su rješavani s većom točnošću, proveden je Fisher LSD post-hoc test na rezultatima studenata Učiteljskog studija.

Tablica 5 Prikaz rezultata Fisher LSD post hoc testa na pojedinim zadatcima Testa mentalnog računanja (N_m =8, $N_ž$=131).

redni broj zadatka	1. (9.37)	2. (8.98)	3. (7.22)	4. (7.96)	5. (6.14)	6. (6.58)	7. (3.6)
1.		0,0879	**0,0000**	**0,0000**	**0,0000**	**0,0000**	**0,0000**
2.	0,0879		**0,0000**	**0,0000**	**0,0000**	**0,0000**	**0,0000**
3.	**0,0000**	**0,0000**		**0,0014**	**0,0000**	**0,0060**	**0,0000**
4.	**0,0000**	**0,0000**	**0,0014**		**0,0000**	**0,0000**	**0,0000**
5.	**0,0000**	**0,0000**	**0,0000**	**0,0000**		0,0580	**0,0000**
6.	**0,0000**	**0,0000**	**0,0060**	**0,0000**	0,0580		**0,0000**
7.	**0,0000**	**0,0000**	**0,0000**	**0,0000**	**0,0000**	**0,0000**	

Provedbom Fisher LSD post-hoc testa utvrđene su statistički značajne razlike u točnosti odgovora između prva dva zadatka i svih ostalih zadataka; studenti su prva dva zadatka rješavali uspješnije u odnosu na sve ostale zadatke, s time da su prva dva zadatka riješeni s jednakom uspješnošću, što ih čini zadacima s najvećom točnošću rješavanja u cjelokupnom testu. Nadalje, što je veći broj rednog zadatka, to je bila manja uspješnost rješavanja tog zadatka, osim što su studenti s jednakim uspjehom rješavali peti i šesti zadatak testa. Može se zaključiti da su studenti najtočnije riješili prva dva zadatka, nešto manje uspješno treći zadatak, još manje uspješno četvrti zadatak, manje uspješno od četvrtog riješili su peti i šesti zadatak (jednaka uspješnost), a najmanji uspjeh su ostvarili na sedmom zadatku.

Rezultati post-hoc analize, odnosno obrazac razlika među rezultatima na pojedinim zadacima, vidljivi su na dolje prikazanom grafičkom prikazu.



Slika 3 Grafički prikaz razlika u uspješnosti studenata na pojedinim zadacima mentalnog računanja (N_m=8, $N_ž$=131).

2. Problem

Kako bi se istražilo s kojom točnošću su studenti pojedine studijske godine rješavali matematičke zadatke u testu, prvenstveno su izračunati deskriptivni podaci o uspjehu na matematičkom testu – prosječan rezultat na testu (broj točno riješenih zadaka od sveukupnih 70 zadataka) po studijskoj godini (*M, SD*).

Tablica 6 Prikaz prosječne riješenosti (*M, %, SD*) Testa mentalnog računanja po studijskoj godini Učiteljskog studija (N_m=8, $N_ž$=131).

Studijska Godina	*M*	*SD*
1.	41.31 (59,0%)	11.22
2.	42.22 (60.3%)	10.81
3.	50.23 (71.7%)	8.66
4.	56.66 (80.9%)	7.24
5.	60.57 (86.5%)	7.90
Prosječna riješenost testa	49.84 (71.2%)	11.83

Iako se iz deskriptivnih podataka o rezultatima testa mogu uočiti generalni trendovi razlika među studijskim godinama, potrebno je relevantnim statističkim analizama provjeriti postoje li razlike među studentima pojedinih studijskih godina u rezultatima, odnosno u uspješnosti na matematičkom testu. U tu svrhu, izračunata je jednosmjerna analiza varijance (ANOVA) za nezavisne uzorke.

Tablica 7 Prikaz rezultata jednosmjerne analize varijance (ANOVA-e) za nezavisne uzorke na ukupnim rezultatima matematičkog testa na uzorku studenata različitih studijskih godina (N_m =8, $N_ž$=131).

	F	*df*	*p*
godina studija	22.161	4	0

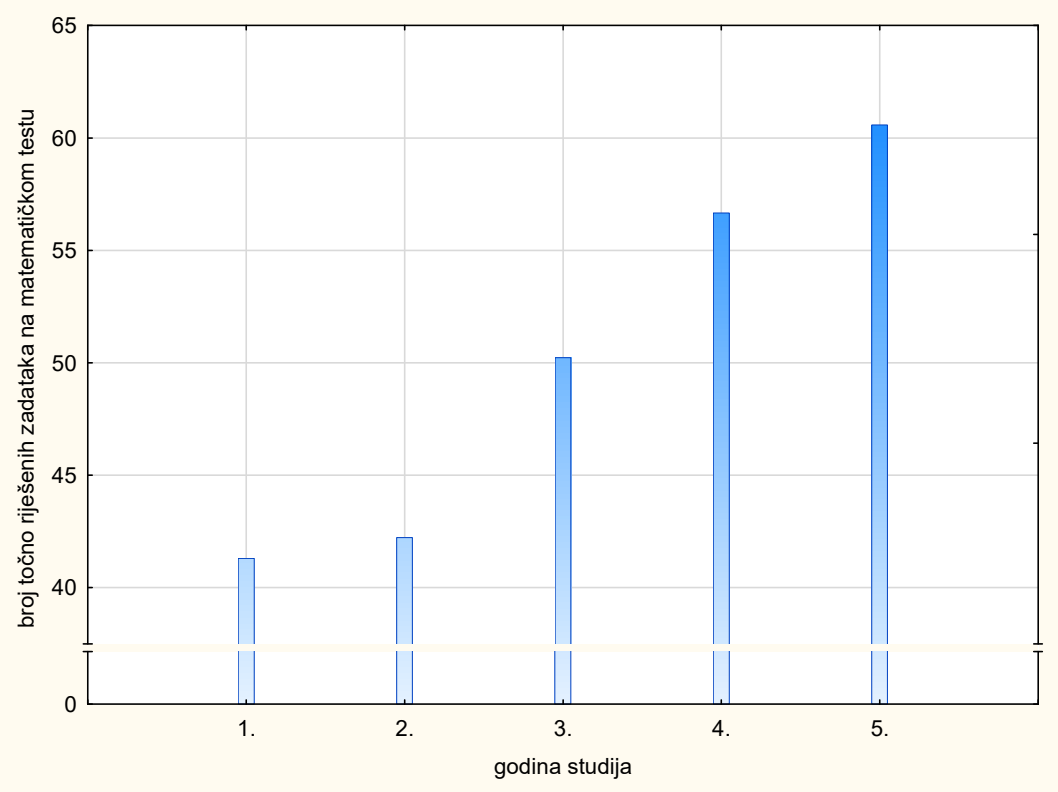
Izračunom jednosmjerne analize varijance (ANOVA-e) za nezavisne uzorke, utvrđena je statistički značajna razlika u uspješnosti na matematičkom testu između studenata različitih studijskih godina Učiteljskog studija, uz razinu rizika manju od 1%. Međutim, kako bi se provjerilo između kojih točno studijskih godina postoji razlika u uspješnosti na testu te u kojem smjeru, proveden je Fisher LSD post-hoc test na rezultatima testa pet studijskih godina (grupa) Učiteljskog studija.

Tablica 8 Prikaz rezultata Fisher LSD post-hoc testa na rezultatima matematičkog testa studenata pet studijskih godina Učiteljskog studija (N_m =8, $N_ž$=131).

godina studija	1. (41.31)	2. (42.22)	3. (50.23)	4. (56.66)	5. (60.57)
1.		0,7128	**0,0004**	**0,0000**	**0,0000**
2.	0,7128		**0,0016**	**0,0000**	**0,0000**
3.	**0,0004**	**0,0016**		**0,0081**	**0,0002**
4.	**0,0000**	**0,0000**	**0,0081**		0,1350
5.	**0,0000**	**0,0000**	**0,0002**	0,1350	

Provedbom Fisher LSD post-hoc testa utvrđene su statistički značajne razlike u rezultatima matematičkog testa između studenata prve dvije godine studija te treće, četvrte i pete godine studija; generalno, studenti prve i druge godine studija su bili manje uspješni na matematičkom testu od studenata treće, četvrte i pete godine studija. S druge strane, među studentima prve i druge godine studija nije bilo razlike u broju točno riješenih zadataka, tj. postigli su jednake rezultate na ovom testu. Također, među studentima treće, četvrte i pete godine studija ipak postoje neke razlike u uspješnosti na testu; studenti četvrte godine su bili uspješniji od studenata treće godine, no nisu se po rezultatima razlikovali od studenata pete godine. Uvidom u gore prezentiranu tablicu te u aritmetičke sredine rezultata studenata pojedine studijske godine, može se zaključiti da su studenti prve i druge godine studija postigli najniže rezultate na ovom testu, studenti treće godine su bili nešto uspješniji, dok su studenti četvrte i pete godine postigli jednak uspjeh na matematičkom testu te tako postigli najviše rezultate na matematičkom testu (u odnosu na studente prve tri godine studija).

Rezultati post-hoc analize, odnosno obrazac razlika među rezultatima studenata pojedine godine studija, vidljivi su na dolje prikazanom grafičkom prikazu.



Slika 4 Grafički prikaz razlika u uspješnosti studenata pojedine studijske godine na matematičkom testu mentalnog računanja (N_m=8, $N_ž$=131).

3.2. Kvalitativni dio – tematska analiza

U svrhu odgovora na posljednji problem ovog istraživanja napravljena je tematska analiza provedenih intervjua koja se nalazi u prilogu.

4. REZULTATI ISTRAŽIVANJA I RASPRAVA

Premda smo kroz dobivene rezultate paralelno i izvodili zaključke, potrebno je sažeti dobivene rezultate u jednu smislenu cjelinu. Cilj ovog istraživanja bio je proučiti fluentnost računanja u matematici kod studenata učiteljskog studija. Prvi problem bio je ispitati točnost rješavanja matematičkih zadataka studenata Učiteljskog studija Sveučilišta u Zadru (generalno). Prvenstveno kako bi se ispitala generalna točnost tj. uspješnost u Testu mentalnog računanja te razlike u točnosti rješavanja između pojedinih zadataka na testu jednosmjernom analizom varijance (ANOVA) utvrđena je statistički značajna razlika u uspješnosti na različitim zadacima testa, uz razinu rizika manju od 1%. Drugim riječima, studenti su neke zadatke rješavali uspješnije od drugih zadataka. Fisher LSD testom provjerili smo koje zadatke su studenti rješavali s većom točnošću (najlošije riješen sedmi zadatak).
S obzirom da se dobilo da je 7 zadatak riješen s najmanjom točnošću, prva tri s najvećom točnošću te, izjave studenta kako je sedmi zadatak bio najteži, kako im teže ide dijeljenje i oduzimanje u odnosu na zbrajanje i množenje hipoteza ,da će s obzirom na različite težine zadataka (jednostavnije i kompleksnije) uspješnost studenata biti prosječna, je potvrđena.

Zatim drugi problem bio je ispitati razlike među studentima u točnosti rješavanja matematičkih zadataka. Prvenstveno su izračunati deskriptivni podaci o uspjehu na matematičkom testu – prosječan rezultat na testu po studijskoj godini (prosječna riješenost 70.1%).
Fisher LSd testom i jednosmjernom analizom varijance može se zaključiti da su studenti prve i druge godine studija postigli najniže rezultate na ovom testu, studenti treće godine su bili nešto uspješniji, dok su studenti četvrte i pete godine postigli jednak uspjeh na matematičkom testu te tako postigli najviše rezultate na Testu mentalnog računanja (u odnosu na studente prve tri godine studija). Kako u testovima sposobnosti i inteligencije postoji efekt uvježbavanja u zadatcima (Pennequin, Sorel, Nanty i Fontaine 2010), a studenti diplomskog studija su odslušali kolegij *Metodika matematike* te se na taj način uvježbali u određenim matematičkim zadatcima, pretpostavilo se da će studenti diplomskog studija biti uspješniji u Testu mentalnog računanja nego studenti preddiplomskog studija. Rezultati su očekivani i hipoteza je potvrđena.
Treći problem bio je ispitati individualne razlike u strategijama računanja (prilog intervju).

Provedeno je 5 intervjua, a cilj je bio ispitati individualne strategije računanja te mišljenje o vlastitom mentalnom računanju i riješenosti testa mentalnog računanja. Iz intervjua se saznalo jesu li studenti koristili različite strategije odnosno tehnike kao bi došli do točnog rješenja. Studenti prve, druge i treće godine uglavnom se nisu mogli sjetiti i nekih osnovnih strategija ili ih uopće nisu znali: „*To su tehnike pisanje jednog ispod drugog koje nismo smjeli koristiti , isto tako onaj primjer 99 pomnoženo s 40, izgledalo je nemoguće. Tek kasnije u raspravi sam shvatila koliko je jednostavno, mislim da sam kad bilo gdje vidim takav primjer rezultata neću morati posegnuti za kalkulatorom. Onaj primjer 18 pomnoženo s 40 izgledao je kao tko će to sad na pamet u biti mogli smo 20 pomnožiti s 40 i oduzeti 80. Nakon razgovara s vama poslije testa shvatila sam koliko ne znam i koliko su naizgled teši zadatci bili lagani za mentalno izračunati.*“

„Iskreno i nisam baš, rješavala sam školski potpisivanje i to bi si zamislila u glavi, oduzelo mi je previše vremena... Trebalo bi imati razvijene memotehnike kako bi brže došli do rješenja.“

Studenti 4. i 5. godine pokazali su veće iskustvo s korištenjem strategija u čemu im je uvelike pomogao kolegij Metodika matematike. Kako kažu kroz taj kolegij osvježili su znanje o strategijama tako da im u svakodnevnom životu olakšavaju.

„Prilično jesam, otkako nam je profesorica Cindrić rekla da rastavljamo brojeve, ne potpisujem ih i ne zamišljam način kako da ih potpišem (410+352), nego ih rastavim npr. 400 +300, pa 10+52 pa sve zbrojim. Oni zadatci sa 99 su bili poznati još od metodike i neki za dijeljenje, ali velike brojeve poput 6125:125 nisam znala izračunati, došlo mi je da ih potpišem sa strane.

S obzirom da su studenti koristili različite strategije prilikom rješavanja hipoteza koja je glasila „strategije računanja kod studenata nisu uniformne“ jest potvrđena.

5. ZAKLJUČAK

Na početku samog diplomskog rada naglašeno je da se u rezultatima istraživanja očekuje da će studenti (ispitanici) prosječno riješiti Test mentalnog računanja, zatim da će studenti diplomskog studija bolje riješiti test od studenata preddiplomskog studija te da će studenti koristiti različite tehnike prilikom rješavanja.

Principles and Standards for School Mathematics *(*NCTM 2000) navodi: "*Fluentnost se odnosi na učinkovite i precizne metode računanja. Studenti pokazuju fluentnost kada pokazuju fleksibilnost u računalnim metodama koje odabiru, razumiju i mogu objasniti te metode i učinkovito izvesti precizne odgovore. Računalne metode koje učenik koristi trebaju se temeljiti na matematičkim idejama koje student dobro razumije, uključujući svojstva brojevnih odnos*a."
Kakav divan opis fluentnosti!

Naša sposobnost razmišljanja bila bi ograničena, ukoliko ne bi bilo načina da se prevladaju prostorna ograničenja radne memorije. Jedan od važnijih mehanizama je razvoj automatizma. Kada kognitivni procesi postaju automatski, zahtijevaju vrlo malo prostora u radnoj memoriji, brzo se javljaju i često se javljaju bez svjesnog napora. S obzirom da su mnogi od nas učili matematiku kao skup nepovezanih pravila, činjenica i postupaka profesor Daniel Wellington smatra da kao učitelj vjeruje da je učiteljska odgovornost osigurati da se radi sve što je u njihovoj moći kako bi se osiguralo da učenici napuste učionicu matematike na kraju godine koja se osposobljava za zahtjevima fluentnosti. Svaki put kad dijete napusti razred bez potrebne fluentnosti, matematički jaz počinje i nastavlja rasti tijekom godina dok učenici i dalje „padaju" u svojoj automatizaciji činjenica i razumijevanju brojeva. Dok nastavljamo podučavati matematiku, pobrinimo se da radimo svoj dio kako bismo podučavali fluentnost potrebnu na svakoj razini razreda (Daniel Willingham, 2004).
Potrebno je učenike od samih početaka uvoditi u fluentnost, raditi na mentalnom računanju, provoditi testove mentalnog računanja bez ocjenjivanja i obraćati pozornost. Prilikom provođenja istraživanja i pisanja svog diplomskog rada iznimno me se dojmila izjava jedne studentice: „ *Iako je anonimno, neugodno mi je, na 3. sam godini studija, ne znam oduzeti dva broja bez kalkulatora, sram me je*."
Shvaćajući prilikom pisanja kolika je važnost fluentnosti te kolika je važnost mentalnog računanja smatram da buduća nastava matematike mora transformirati način na koji se gradi

fluentnost i numerički smisao tj. mentalno računanje. S brojnim razgovorima, pristupom i radom na matematičkoj fluentnosti pomoći će se studentima i učenicima razviti samopouzdanje s brojevima, napustiti češće kalkulator i umjesto toga koristiti svoje vlastite alate za mentalne strategije.

6. SAŽETAK

U ovom diplomskom radu ispitivali smo fluentnost računanja kod studenata Učiteljskog studija. Teorijski dio rada bavi se pitanjem konceptualnog i proceduralnog znanja, mentalnog računanja, korištenja strategija i na kraju same fluentnosti.
Istraživanje o fluentnosti računanja studenata Učiteljskog studija provedeno je među studentima prve, druge, treće, četvrte i pete godine Učiteljskog studija Sveučilišta u Zadru. U istraživanju je sudjelovalo 139 sudionika.

Istraživanje koje je podijeljeno na kvalitativno i kvantitativno provedeno je u periodu svibnja 2018. godine na području Zadarske županije. U kvantitativnom dijelu istraživanja ispitanici su bili raspoređeni po godinama studija, a u kvalitativnom dijelu volonteri su bili ispitani jedan po jedan. Cilj je bio ispitati individualne strategije računanja te mišljenje o vlastitom mentalnom računanju i riješenosti testa mentalnog računanja.

Dobiveni podatci su obrađeni kvantitativno, tj. rezultati su dobiveni parametrijskim statističkim postupcima, konkretnije jednosmjernim analizama varijance (ANOVA) kojima je utvrđena statistički značajna razlika u uspješnosti na različitim zadacima testa, uz razinu rizika manju od 1%, a Fisher LSD testom provjerili smo koje zadatke su studenti rješavali s većom točnošću.
Zaključili smo da su postavljene hipoteze potvrđene.

ključne riječi: proceduralno i konceptualno znanje, mentalno računanje, strategije, fluentnost, studenti učiteljskog studij

7. ABSTRACT

The fluency of computing in the students of the Master's Degree

In this graduate thesis we were examining the fluency of computing in the students of the Master's Degree. The theoretical part of the paper deals with the concept of conceptual and procedural knowledge, mental computing, the use of strategies and at the end of fluency.
The study on fluency of computing students of the Master's Study was conducted among the students of the first, second, third, fourth and fifth year of the Master's Studies at the University of Zadar. The study was attended by 139 participants.
The research carried out qualitatively and quantitatively was carried out in the period of May 2018 in the area of Zadar County. In the quantitative part of the survey, the respondents were divided into years of study, and in the qualitative part of the volunteers were examined one at a time. The aim was to examine the individual calculation strategies and the opinion on their own mental computing and the resolution of the mental computation test.

The obtained data were quantitatively analyzed, using descriptive statistics, one-way analysis of variance (ANOVA) showed a statistically significant difference in performance on different test tasks, with a risk level of less than 1%. The Fisher LSD test examined which tasks the students had solved with with greater accuracy.
We conclude that hypotheses have been verified.

keywords: procedural and conceptual knowledge, mental computing, strategy, fluency, students of the Master's degree

8. LITERATURA

1. Anderson, L. W., & Krathwohl, D. R. (2001.) A Taxonomy for Learning, Teaching and Assessing: A Revision of Bloom's Taxonomy of Educational Objectives: Complete Edition. New York: Longman.
2. Ball, D. L., & Cohen, D. K. (1999.) *Developing practice, developing practitioners: Toward a practice-based theory of professional education*. In L. Darling-Hammond & G. Sykes (Eds.), *Teaching as the learning profession*, pp. 3–32. San Francisco: Jossey-Bass
3. Beishuizen, M. (1993.) *Mental strategies and materials or models for addition and subtraction up to 100 in Dutch second grades*. Journal for Research in Mathematics Education, 24(4), 294-323.
4. Beishuizen, M., & Angileri, J. (1998.) *Which Mental Strategies in the Early Number Curriculum*? A comparison of British ideas and Dutch Views. British Educational Research Journal, 24(5), 519-538
5. Biggs, J.B. (1967.) *Mathematics and the conditions of learning.* Slough: National Foundation for Educational Research
6. Boaler, J. (2015.) *Fluency Without Fear*: Research Evidence on the Best Ways to Learn Math Facts
7. Callingham, R. & Watson, J. M. (2005.) *Measuring statistical literacy*. Journal of Applied Measurement, 6(1), 19–47. Dostupno na: https://iase-web.org/documents/SERJ/SERJ16(1)_Callingham.pdf (31.8.2018.)
8. Clements, D. H., & Conference Working Group. (2004.) Part 1: Major themes and recommendations. In D. H. Clements, J. Sarama, & A.-M. DiBiase (Eds.), *Engaging young children in Mathematics: Standards for early childhood mathematics education*, pp. 7–76. Mahwah, NJ: Lawrence Erlbaum.
9. Dijanić, Ž. i Debelec T. (2015.) *Proceduralno i konceptualno znanje*, Čazma, Čakovec
10. *Finger Counting, Numerical Fluency, and Confidence*. Dostupno na: https://www.mathnasium.com/number-fluency (30.08.2018.)
11. Gagne, R., Briggs, L. & Wager, W. (1992.) *Principles of Instructional Design (4th Ed.).* Fort Worth, TX: HBJ College Publishers.
12. Gray, E., & Tall, D. (1994). *Duality, ambiguity and flexibility: A proceptual view of Simple arithmetic*. Journal for Research in Mathematics Education, 25, 115-141.

13. Heibert, James, et al. "*Problem Solving as a Basis for Reform in Curriculum and Instruction: The Case of Mathematics*." Educational Researcher 25 (May 1996): 12-21
14. Heirdsfield, A. & Lamb, J. (2007.) *Year 2 inaccurate but flexible mental computers: teacher actions supporting growth*. In Proceedings Australian Association for Research in Education, Adelaide,
15. Hiebert, J. & Lefevre, P. (1986.) *Conceptual and Procedural Knowledge in Mathematics: An Introductory Analysis*. In J. Hiebert (Ed.), Conceptual and Procedural Knowledge: The Case of Mathematics (pp. 1-27). Hillsdale, NJ: Erlbaum. Dostupno na https://www.unitrier.de/fileadmin/fb1/prof/PSY/PAE/Team/Schneider/Rittle-JohnsonEtAl2015.pdf (1.10.2018.)
16. Hope, J. A. & Sherrill, J. M. (1987.) *Characteristics of unskilled and skilled mental calculators*. Journal for Research in Mathematics Education. Dostupno na:
17. Howden, Hilde (1989.) *The Arithmetic Teacher*; Reston
18. HREF2: McIntosh, A. (2004.) *Mental Computation of School-Aged Students*: Assessment, Performance Levels and Common Errors. Dostupno na: http://www.mai.liu.se/SMDF/madif5/papers/McIntosh.pdf (3.09.2018.)
19. *https://www.researchgate.net/publication/249721343_PEDAGOGY_THAT_MAKES_NUMBER_SENSE_A_CLASSROOM_TEACHING_EXPERIMENT_AROUND_MENTAL_MATH (3.09.2018.)*
20. Hyde, J.S., Fennema, E., Ryan, M., Frost i L.A., Hopp, C. (1990.) *Gender comparisons of mathematics attitudes and affect. A meta-analysis*. Psychology of women Quarterly, 14
21. Jo Russell, S. (2000.) *Developing computational fluency with whole number*
22. L. W. Anderson, D. R. Krathwohl i suradnici, *A Taxonomy for Learning, Teaching, and Assessing; A Revision of Bloom's Taxonomy of Educational Objectives*, 2001).
23. LA Times (1990.) Dostupno na: http://articles.latimes.com/1990-05-10/news/mn-1461_1_math-error *(14.06.2018.)*
24. Liebeck, P. (1984.) *Kako djeca uče matematiku*, Zagreb.
25. Marendić, Z. (2009). *Teorijski okvir razvoja matematičkih pojmova u dječjem vrtiću*, 10, 1, 129-14

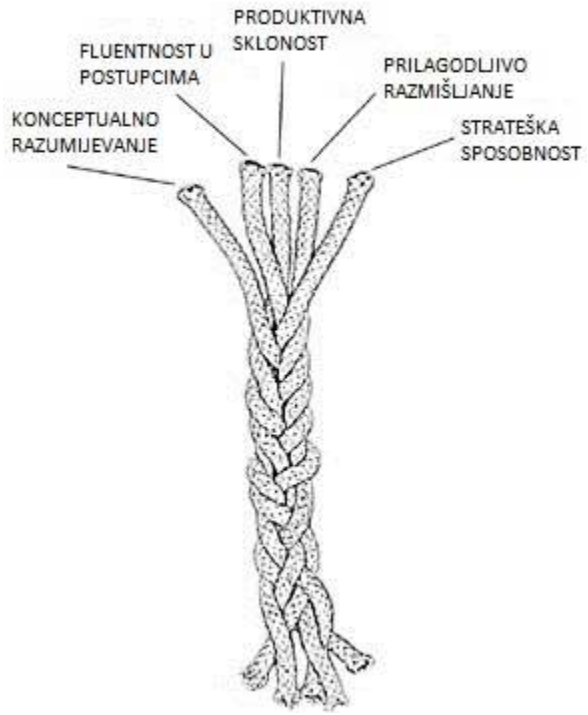
26. *Maths concepts in teaching: Procedural and conceptual knowledge*. Dostupno na: https://www.researchgate.net/publication/228337258_Maths_concepts_in_teaching_Procedural_and_conceptual_knowledge. (21.07.2018.)
27. McIntosh, A (2004.) *Mental Computation a Strategies Approach. Hobart*: Department of Education
28. McIntosh, A., & Dole, S. (2000.) Mental computation, number sense and general mathematics ability - are they linked? *Proceedings of the twenty-third annual conference of the Mathematics Education Research Group of Australasia (MERGA).*
29. McIntosh, A.J., Bana, J., & Farrell, B. (1995.) *Mental computation in Western Australian schools.* Perth, Western Australia: Edith Cowan University. (ISBN 0-7298-0204-3:70pp)
30. National Council of Teachers of Mathematics (NCTM). *Principles and Standards for School Mathematics*. Reston, Va.: NCTM, 2000.
31. National Council of Teachers of Mathematics. Dostupno na: https://www.nctm.org/Standards-and-Positions/Position-Statements/Mathematics-in-Early-Childhood-Learnin (21.07.2018.)
32. National Research Council. 2001. Adding It Up: Helping Children Learn Mathematics. Washington, Dostupno na: https://doi.org/10.17226/9822 (27.09.2018.)
33. NCTM (2000.), *Principles and standards for school mathematics.* Reston, VA: NCTM.
34. Pavlin-Bernardić, N. (2006.) *Modeli dječjeg odabira strategija rješavanja aritmetičkih zadataka*. Suvremena psihologija, 9 (1/2006.), 47-61.
35. Rittle-Johnson, B., & Schneider, M. (2015.) *Developing conceptual and procedural knowledge of mathematics*. In R. C. Kadosh & A. Dowker (Eds.), Oxford handbook of numerical cognition (pp. 1102–1118.) Oxford: Oxford University Press.
36. Spikell, M. (1993.) *Teaching mathematics with manipulatives: A resource of activities for the K-12 teacher.* New York: Allyn and Bacon.
37. Thompson, I., & Smith, F. (1999.) *Mental calculation strategies for the addition and subtraction of 2-digit numbers*. Final report. University of Newcastle, Newcastle upon Tyne. Dostupno na https://mav.vic.edu.au/files/conferences/2009/18Rogersb.pdf (3.09.2018.)
38. Tobias, S. (1993.) *Overcoming math anxiety*. New York: W.W: Norton Company.
39. Valérie Pennequin, Olivier Sorel, Isabelle Nanty & Roger Fontaine (2010.)

Metacognition and low achievement in mathematics: The effect of training in the use of metacognitive skills to solve mathematical word problems, Thinking & Reasoning, 16:3.
Dostupno na https://www.tandfonline.com/doi/abs/10.1080/13546783.2010 (21.9.2018.)

40. Widmer, C.C. i Chavez, A. (2001.) *Math anxiety and elementary school teachers*. Journal of experimental education, Vol. 102, Issue 3, 272-276

9. PRILOZI

Prilog 1 - Niti matematičkog umijeća



Prilog 2 - Kategorije činjeničnog znanja

Dimenzije znanja	Podvrste znanja
činjenično znanje	• Znanje pojmova (terminologije) • Znanje specifičnih detalja i elemenata
konceptualno znanje	• Znanje klasifikacija i kategorija • Znanje principa i generalizacija • Znanje teorija modela i struktura
proceduralno znanje	• Znanje sadržajno specifičnih postupaka i algoritama • Znanje specifičnih tehnika i metoda. • Znanje kriterija koji uvjetuju uporabu primjerenih postupaka.
metakognitivno znanje	• Strategijsko znanje • Znanje o kognitivnim ciljevima, uključujući i odgovarajuće kontekstualno uvjetovano znanje • Znanje o sebi

Prilog 3 - TEMATSKA ANALIZA

Teme:

1) **DOŽIVLJAJ ZADATAKA**

„Zadatci su bili onako, prvi lakši zadnji teži. Teži su mi bili s dijeljenjem i množenjem, također oduzimanje troznamenkastih brojeva,
Neugodno mi je iako je anonimno s obzirom koliko nisam riješila zadataka, lakši zadatci su bili ok.
Definitivno da, nikad o tom nisam razmišljala jer samo izvučem kalkulator i izračunamo ono što nam treba“

2) **METAKOGNICIJA O RJEŠAVANJU MATEMATIČKIH ZADATAKA**

- percepcija svog rješavanja - jednostavnije operacije lakše, složenije teže
- korištenje tehnika: *„To su tehnike pisanje jednog ispod drugog koje nismo smjeli koristiti, isto tako onaj primjer 99 pomnoženo s 40, izgledalo je nemoguće tek kasnije u raspravi sam shvatila koliko je jednostavno, mislim da sam kad bilo gdje vidim takav primjer rezultata neću morati posegnuti za kalkulatorom. Onaj primjer 18 pomnoženo s 40 izgledao je kao tko će to sad na pamet u biti mogli smo 20 pomnožiti s 40 i oduzeti 80. Nakon razgovara s vama poslije testa shvatila sam koliko ne znam i koliko su naizgled teši zadatci bili lagani za mentalno izračunati.“*

- mentalno vs. Pismeno računanje -
„*Iskreno i nisam baš, rješavala sam školski potpisivanje i to bi si zamislila u glavi, oduzelo mi je previše vremena..*
Trebali bi imati razvijene memotehnike da brže dođemo do rješenja.

3) **UTJECAJ TEHNOLOGIJE NA MENTALNO RAČUNANJE**

- pozitivan - brže i jednostavnije do rješenja

- negativan - zaglupljuje, usporavanje razvoja vještina mentalnog računanja *„Da, mislim da je ovo pokazatelj da sam na 2. godini faksa i mislim se kako izračunati 121-89 bez kalkulatora. Ne razmišljamo uopće i ne razvijamo mozak.*

Prilog 4. TRANSKRIPCIJA

1. **Pitanje: Kakvi su ti bili zadatci?**

1. godina: „Zadatci su bili onako, prvi lakši zadnji teži. Teži su mi bili s dijeljenjem i množenjem, također oduzimanje troznamenkastih brojeva.“
2. godina: „Početak lagan, kraj težak. Previše vremena mi je oduzelo to što sam veće brojeve npr. 643-117 zamišljala kako bi oduzela pismeno.“
3. godina: „Zadatci su bili okej, samo sam se šokirala koliko ne znam računati. 1. zadatak mi je bio najlakši, zadnji preteški.“
4. godina: „Zadnji zadatci teški, nisam stigla izračunati, prvi puno lakši.“

2. **Pitanje: Što misliš o svom načinu rješavanja?**

1. godina: „Neugodno mi je iako je anonimno s obzirom koliko nisam riješila zadataka, lakši zadatci su bili ok.“
2. godina: „Ovisi o vrsti zadataka, puno vremena mi je otišlo na to da zamislim kako to sve izgleda.“
3. godina: „Mislim da sam oke napisala, jutro je pa možda mi je i to utjecalo, nisam mogla vjerovati da ne mogu oduzeti dva broja bez da zamislim da ih potpisujem. Došlo mi je svaki put da ih sa strane potpišem.“
4. godina: „Mislim da sam dobro riješila, zadnji zadatak nisam sve, zadatci prije toga su bili ok, da smo mogli pismeno rješavati bilo bi puno lakše, nisam ni svjesna nego tek sad koliko sporo mentalno računam.“
5. godina: „S obzirom da sam zadnja godina faksa mislim da sam neke stvari mogla puno bolje riješiti, u početku prelagano, a kasnije sve teže, definitivno bi trebala početi vježbati mentalno računanje, tek sam sada svjesna koliko ne znam.“

3. Pitanje: Prilikom rješavanja jesi li poznavala neke tehnike ili strategije?

1. godina: „To su tehnike pisanje jednog ispod drugog koje nismo smjeli koristiti ,isto tako onaj primjer 99 pomnoženo s 40, izgledalo je nemoguće tek kasnije u raspravi sam shvatila koliko je jednostavno, mislim da sam kad bilo gdje vidim takav primjer rezultata neću morati posegnuti za kalkulatorom. Onaj primjer 18 pomnoženo s 40 izgledao je kao tko će to sad na pamet u biti mogli smo 20 pomnožiti s 40 i oduzeti 80. Nakon razgovara s vama poslije testa shvatila sam koliko ne znam i koliko su naizgled teši zadatci bili lagani za mentalno izračunati.“
2. godina: „Iskreno i nisam baš, rješavala sam školski potpisivanje i to bi si zamislila u glavi, oduzelo mi je previše vremena, trebala bi imati razvijene memotehnike da brze dođemo do rješenja.“
3. godina: „Većinom nisam.“
4. godina: „U dijeljenju 810:90 podijelila sam 81 s 9, nekih se tehnika uopće nisam mogla sjetiti.“
5. godina: „Prilično jesam, otkako nam je profesorica Cindrić rekla da rastavljamo brojeve, ne potpisujem (410+352), nego ih rastavim npr. 400 +300, pa 10+52 pa sve zbrojim.

   Oni zadatci sa 99 su bili poznati još od metodike, i neki za dijeljenje.

   One velike brojeve 6125 nisam znala izračunati, došlo mi je da ih potpišem sa strane.“

4. Pitanje: Misliš li da puno lošije mentalno računamo u odnosu na pismeno?

1. godina: „Definitivno da, nikad o tom nisam razmišljala jer samo izvučem kalkulator i izračunamo ono što nam treba.
2. godina: „Da, mislim da je ovo pokazatelj da sam na 2. godini fakulteta i mislim se kako izračunati 121-89 bez kalkulatora. Ne razmišljamo uopće i ne razvijamo mozak.
3. godina: „U potpunosti da jer smo u osnovno-školskom obrazovanju učili potpisivati i bazirali smo se samo na taj način, kad sam došla na faks shvatila sam koliko sam zaboravila računati, nakon 4. razreda dopuštaju nam se kalkulator zaboravim sve što znamo. Možda bi trebalo uvesti neke kratke provjerice koje se ne ocjenjuju kao bi djeca stekla navike misaonog računanja.“
4. godina: „Definitivno da, ovo je živi pokazatelj.“

5. godina: "Apsolutno, ovo je dobra stvar, kad budem raditi u školi definitivno ćemo vježbati misaono računanje. Imamo 23 godine i problem je oduzeti dva troznamenkasta broja, a da ih ne potpišemo, to nije dobro.“

5. pitanje: „Misliš li da tehnologija ima utjecaja?“

1. godina: „Naravno da ima, previše se oslanjam na nju. Lijena sam izračunati „napamet“, posežem uglavnom za kalkulatorom.“
2. godina: „Da, mislim da je ovo pokazatelj da sam na 2. godini faksa i mislim se kako izračunati 121-89 bez kalkulatora. Ne razmišljamo uopće i ne razvijamo mozak.“
3. godina: „Nažalost ima, tek sam sad svjesna koliko zapravo ne znam računati. Ne vjerujem, da mi je teško oduzeti od troznamenkastog broja dvoznamenkasti.“
4. godina: „Prevelikog, ovo je čisti primjer koliko smo loši.“
5. godina: „Nažalost ima, ali slušajući metodiku naučila sam neke stvari pa se ponekad trudim računati mentalno i prisiliti sebe da više koristim svoj mozak. U svakom slučaju utjecaj je ogroman i mislim da bi se trebali zapitati o korištenju i treniranju vlastitog mozga.“

Prilog 5. Zadatci

1.	**2.**	**3.**	**4.**
a) 4+13	a) 5•9	a) 82-19	a) 20+30
b) 9+7	b) 7•8	b) 17+16	b) 200-40
c) 6+9	c) 4•8	c) 61-23	c)12400+700
d) 4+7	d) 7•9	d) 38+27	d) 7000-600
e) 19-6	e) 3•6	e) 45-17	e) 300+900
f) 15-7	f) 5•8	f) 29+41	f) 11100-300
g) 14-6	g) 0•1	g) 91-42	g) 7900+700
h) 17-9	h) 3•8	h) 37+49	h) 8800-900
i) 15-11	i) 2•7	i) 82-47	i) 13500+800
j) 11-4	j) 6•9	j) 39+21	j) 17400-900

5.	**6.**	**7.**
a) 135+246	a) 34 •20	a) 16•9•12
b) 754-123	b) 156 •5	b) 46•99
c) 291+311	c) 240:12	c) 99•53
d) 751-122	d) 251•7	d) 4125:25
e) 296+57	e) 560:80	e) 152-87
f) 643-117	f) 56•30	f) 198+387
g) 347+291	g) 630:90	g) (20•21)+ (15•15)
h) 856+117	h) 95•20	h) 25+39+105
i) 555-456	i) 810:9	i) 41•40
j) 888-279	j) 81•40	j) 620:125

10. ŽIVOTOPIS

Ime i prezime: Lucija Karega

Datum rođenja: 11. 04. 1995.

Mjesto rođenja: Šibenik, Hrvatska

Državljanstvo: hrvatsko

Adresa prebivališta: Rupe 44 A, 22222 Skradin

Telefonski broj(evi): 0994147586

E-mail: lucija0507@gmail.com

NAOBRAZBA:

Studentica pete godine Sveučilišta u Zadru – Odjel za izobrazbu učitelja i odgojitelja:

Učiteljski studij (godina upisa: 2013.)

Gimnazija Antuna Vrančića, Šibenik (2009. - 2013.)

Osnovna škola Petra Krešimira IV. (2001. – 2009.)

PERIOD	MJESTO RADA
2012.	Slastičarna “Ka grom”
2016.	Pizzeria “Mrak”
2017.	“Mali caffe”
2018.	Restoran “Mamma mia “

JEZIK	GOVOR	ČITANJE	PISANJE
Engleski	Aktivno	Aktivno	Aktivno
Španjolski	Aktivno	Aktivno	Aktivno
Talijanski	Neaktivno	Aktivno	Aktivno

OSTALO:

Iskustvo rada na računalu: Microsoft Office, Internet

Vozačka dozvola (B kategorija)