Utjecaj vršnjačke procjene i samoprocjene na pristup učenju i primjenu informacijske i komunikacijske tehnologije kod budućih učitelja

Dobi Barišić, Karolina

Doctoral thesis / Disertacija

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Organization and Informatics Varaždin / Sveučilište u Zagrebu, Fakultet organizacije i informatike Varaždin**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:211:905006

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

PODACI O DOKTORSKOM RADU

I. AUTOR

Ime i prezime	Karolina Dobi Barišić
Datum i mjesto rođenja	22.12.1984. u Osijeku
Naziv fakulteta i datum diplomiranja na VII/II stupnju	Sveučilište J. J. Strossmayera u Osijeku - Odjel za matematiku, 7. veljače 2008.
Sadašnje zaposlenje	Sveučilište J. J. Strossmayera u Osijeku - Fakultet za odgojne i obrazovne znanosti

II. DOKTORSKI RAD

Naslov	Utjecaj vršnjačke procjene i samoprocjene na pristup učenju i primjenu informacijske i komunikacijske tehnologije kod budućih učitelja
Broj stranica, slika, tabela, priloga, bibliografskih podataka	226 stranica, 78 slika, 102 tablica, 8 priloga, 192 bibliografska podatka
Znanstveno područje i polje iz kojeg je postignut doktorat znanosti	Društvene znanosti/Informacijske i komunikacijske znanosti
Mentori ili voditelji rada	Prof.dr.sc. Blaženka Divjak Izv.prof.dr.sc. Valentina Kirinić
Fakultet na kojem je obranjen doktorski rad	Sveučilište u Zagrebu – Fakultet organizacije i informatike
Oznaka i redni broj rada	143

III. OCJENA I OBRANA

Datum sjednice Fakultetskog vijeća na kojoj je prihvaćena tema	26. siječnja 2016.
Datum predaje rada	10. studenog 2017.
Datum sjednice Fakultetskog vijeća na kojoj je prihvaćena pozitivna ocjena rada	19. lipnja 2018.
Sastav povjerenstva koje je rad ocijenilo	Prof. dr.sc. Diana Šimić, predsjednica Doc.dr.sc. Predrag Oreški, član Izv. prof. dr.sc. Igor Balaban, član
Datum obrane doktorskog rada	13. srpnja 2018.
Sastav povjerenstva pred kojim je rad obranjen	Prof. dr.sc. Diana Šimić, predsjednica Doc.dr.sc. Predrag Oreški, član Izv. prof. dr.sc. Igor Balaban, član
Datum promocije	

Sveučilište u Zagrebu

Fakultet organizacije i informatike

Karolina Dobi Barišić

UTJECAJ VRŠNJAČKE PROCJENE I SAMOPROCJENE NA PRISTUP UČENJU I PRIMJENU INFORMACIJSKE I KOMUNIKACIJSKE TEHNOLOGIJE KOD BUDUĆIH UČITELJA

DOKTORSKI RAD

Mentori:

Prof.dr.sc. Blaženka Divjak

Izv.prof.dr.sc. Valentina Kirinić

Varaždin, 2018.

Sveučilište u Zagrebu

Faculty of Organization and Informatics

Karolina Dobi Barišić

THE INFLUENCE OF PEER AND SELF-ASSESSMENT ON FUTURE TEACHERS' APPROACH TO LEARNING AND USE OF INFORMATION AND COMMUNICATION TECHNOLOGY

DOCTORAL DISSERTATION

Supervisors:

Full Prof. Blaženka Divjak, Ph.D.

Assoc. Prof. Valentina Kirinić, Ph.D.

Varaždin, 2018

ZAHVALA

Mnogi divni ljudi trebaju biti spomenuti u ovoj zahvali.

Prvenstveno hvala mojoj mentorici prof.dr.sc. Blaženki Divjak i sumentorici izv.prof.dr.sc. Valentini Kirinić na trudu, znanju i vremenu koje su uložile pomažući mi i savjetujući me tijekom izrade ove disertacije.

Veliko hvala svim divnim ljudima koji su me pustili u svoje predavaonice i na svoje kolegije kako bih provela ovo istraživanje. Isto tako hvala svima onima koji su u svakom trenutku bili spremni učiniti mi tu veliku uslugu. Hvala svima koji su mi pomogli u prijevodu i lekturi, svima koji su mi pomogli svojim savjetima, prijedlozima i vlastitim iskustvima.

Mojoj dragoj Ivanki Đeri koja mi je bila velika moralna podrška na početku izrade ove disertacije.

Obitelji, hvala mojoj obitelji, što su me podupirali, trpjeli i uskakali u svakom trenutku potrebe, a bilo ih je puno. Hvala vam.

SAŽETAK

Bolonjska deklaracija (Bologna Declaration, 1999), Hrvatski kvalifikacijski okvir (Ministartsvo znanosti, obrazovanja i sporta RH, 2013), Strategija obrazovanja, znanosti i tehnologije (Vlada Republike Hrvatske, 2014), te Okvir nacionalnoga kurikuluma (Ministarstvo znanosti, obrazovanja i sporta RH, 2016) su strateški dokumenti Europske Unije i Vlade Republike Hrvatske koji promiču važnost reforme obrazovanja u smjeru stjecanja kompetencija temeljenih na ishodima učenja. U ovom istraživanju predložen je dizajn okoline za poučavanje koji potiče stjecanje kompetencija navedenih u prethodnim dokumentima, poput rješavanja problema, timski rad, digitalna i informacijska pismenost, razvoj kritičkog i analitičkog mišljenja.

U ovom istraživanju razmatra se razvoj studentskog kritičkog mišljenja i sposobnost rješavanja problema u novonastalim situacijama kroz sudjelovanje studenata u procesu procjene znanja te uz primjenu IKT-a u nastavi. Istraživanje je podijeljeno na teorijski i empirijski dio. U teorijskom dijelu istraživanja dan je pregled relevantne literature dok empirijski dio istraživanja obuhvaća: (i) istraživanje trenutnog stanja u znanjima nastavnika i učitelja u praksi u Republici Hrvatskoj o primjeni informacijsko komunikacijske tehnologije u nastavi, (ii) proširenje i validaciju upitnika RASI (*Revised Approach to Study Inventory*) u kontekstu složenih i problemskih zadataka, (iii) validaciju upitnika SPTKTT (*Survey of Preservice Teachers' Knowledge of Teaching and Technology*) u kontekstu hrvatskog obrazovnog sustava, (iv) eksperiment s faktorskim dizajnom kojim se ispitivao utjecaj sudjelovanja u procesima vršnjačke kriterijske procjene i/ili samoprocjene rješenja problemskog i/ili složenog zadatka u okviru online suradničkog učenja na percepciju budućih učitelja i nastavnika o napretku njihovog znanja o primjeni tehnologije u nastavi, kao i utjecaj spomenutih procesa na razvoj dubinskog pristupa učenju u promatranom kontekstu. Dobiveni podaci analizirali su se uz pomoć programa za statističku obradu podataka Statistica 13, SPSS 24 te programa za strukturalno programiranje Lisrel 9.1.

Rezultati istraživanja pokazali su: (i) da učitelji i nastvanici u Republici Hrvatskoj percipiraju slabija vlastita znanja o primjeni tehnologije u nastvai u odnosu na pedagoška i sadržajna znanja; (ii) prošireni upitnik RASI odgovara predloženom teorijskom modelu i prikladan je za korištenje u kontekstu složenih i problemskih zadataka; (iii) upitnik SPTKTT odgovara predloženom teorijskom modelu i prikladan je za korištenje u kontekstu hrvatskog obrazovnog sustava i (iv) Utjecaj niti jedne promatrane varijable nije statistički značajan u pomaku prema

dubokom pristupu učenju; ne postoji povezanost između pristupa učenju koji student uobičajeno primjenjuje i dijametra kvazi - pouzdanosti i studentske procjene; nezavisna varijabla *Vrijeme* ima statistički značajan utjecaj na percepciju budućih učitelja i nastavnika o napretku njihovog znanja o primjeni tehnologije u nastavi, ali utjecaj se dodatno ne objašnjava niti jednom varijablom promatranom u ovom istraživanju.

Ključne riječi: informacijsko komunikacijska tehnologija, TPACK, kvazi eksperiment, vršnjačka procjena, samoprocjena, kriterijska procjena, učitelj, pristup učenju.

SUMMARY

The Bologna Declaration (1999), the Croatian Qualification Framework (Ministry of Science, Education and Sport of the Republic of Croatia, 2013), the Education, Science and Technology Strategy (Government of the Republic of Croatia, 2014), and the National Curriculum Framework (Ministry of Science, Education and Sports , 2016) are the strategic documents of the European Union and the Government of the Republic of Croatia that promote the importance of education reform in the direction of acquiring learning-based competencies. In this research, the design of the learning environment has been suggested, which encourages the acquisition of competences mentioned in the previous documents, such as problem solving, teamwork, digital and information literacy, and critical and analytical thinking.

This research considers the development of student critical thinking and ability to solve problems in emerging situations through the participation of students in the process of assessment of knowledge and the use of ICT in teaching. The research is divided into a theoretical and empirical part. In the theoretical part of the study, a review of the relevant literature is provided, while the empirical part of the research includes: (i) research into the current state of knowledge of teachers and teachers in practice in the Republic of Croatia on the application of information communication technology in teaching; (ii) extension and validation of the RASI (Revised Approach to Study Inventory) in the context of complex and problematic tasks, (iii) validation of the Survey of Preserving Teachers' Knowledge of Teaching and Technology (SPTKTT) questionnaire in the context of the Croatian educational system, (iv) a experiment with factor design investigating the influence of participation in Peer criterion assessments and / or self-assessment of a problem-solving and / or complex task in the context of online collaborative learning on the perception of future teachers and teachers on the progress of their knowledge on the application of technology in teaching, as well as the impact of these processes on the development of deep approaches to learning in the observed context. The data obtained were analyzed with the help of statistical data processing software Statistica 13, SPSS 24 and Structural Programming Lisrel 9.1.

The results of the research showed that: (i) teachers in the Republic of Croatia perceived lesser own knowledge about the application of technology in teaching in regards to own pedagogical and content knowledge; (ii) the extended RASI questionnaire corresponds to the proposed theoretical model and is suitable for use in the context of complex and problematic tasks; (iii) the SPTKTT questionnaire corresponds to the proposed theoretical model and is suitable for

use in the context of the Croatian education system; and (iv) the impact of none of the observed variables is statistically significant in the move towards a deep approach to learning; there is no correlation between the learning approach that a student normally applies and the quasi-reliability of student assessment; independent variable *Time* has a statistically significant impact on the perception of future teachers on the progress of their knowledge on applying technology to teaching, but the impact is not additionally explained by any variables observed in this research.

Keywords: information and communication technologies, TPACK, quasi experiment, peer assessment, self assessment, criteria assessment, teacher, approach to learning.

SADRŽAJ

1 UVOD 1
1.1 Definiranje osnovne svrhe istraživanja 2
1.2 Ciljevi i hipoteze istraživanja 3
1.3 Sažeti prikaz istraživanja i metodologije 4
1.4 Struktura disertacije 5
2 TEORIJSKI OKVIR 7
2.1 Ishodi učenja i procjena znanja 7
2.2 Pristup učenju 14
2.3 Informacijsko komunikacijska tehnologija u obrazovanju 18
3 PREGLED LITERATURE 25
3.1 Procjena znanja 25
3.2 Pristup učenju 27
3.3 Informacijsko komunikacijska tehnologija u obrazovanju 32
4 METODOLOGIJA 39
4.1 Ispitanici i uzorci 39
4.2 Instrumenti 42
4.3 Postupci 44
4.4 Varijable 59
4.5 Pilot istraživanje 66
4.6 Analiza podataka 68
4.7 Mišljenje studenata o sudjelovanju u procesu procjene i samoprocjene 80
5 REZULTATI ISTRAŽIVANJA 83
5.1 Proširenje i validacija upitnika RASI 83
5.2 Upitnik SPTKTT 89
5.3 Hipoteza H1 93

5.4 Multivarijantna analiza varijance varijabli *Duboki* i *TPACK* u odnosu na *Samoprocjenu, Vršnjačku procjenu i Vrijeme* 96
5.5 Hipoteza H2 104
5.6 Hipoteza H3 123
5.7 Hipoteza H4 139
5.8 Mišljenje studenata 158
6 RASPRAVA O REZULTATIMA ISTRAŽIVANJA 163
6.1 Proširenje i validacija RASI upitnika 163
6.2 Validacija upitnika SPTKTT 164
6.3 Ispitivanje trenutnog stanja u znanjima nastavnika i učitelja u Hrvatskoj o primjeni tehnologije u nastavi 165
6.4 Kvazi eksperiment koji istražuje utjecaj vršnjačke procjene i/ili samoprocjene na pristup učenju i primjenu tehnologije u nastavi 166
6.5 Prikupljanje mišljenja studenata o sudjelovanju u procesu procjene i samoprocjene 167
7 ZAKLJUČAK 169
7.1 Znanstveni doprinosi istraživanja 169
7.2 Ograničenja istraživanja 170
LITERATURA 172
PRILOZI 191
ŽIVOTOPIS 227

POPIS TABLICA

Tablica 1. Razine znanja prema Bloomovoj taksonomiji (prema (Bloom i sur., 1956)) 9
Tablica 2. Taksonomska tablica revidirane Blomove taksonomije (prema (Anderson i sur., 2001)) 10
Tablica 3. Broj ispitanika iz Uzorka 1 po županijama 40
Tablica 4. Raspodjela ispitanika iz Uzorka 2 po kolegijima na kojima je istraživaje provedeno 41
Tablica 5. Broj ispitanika u uzorku 2 - rasipanje uzorka..... 52
Tablica 6. Veličine grupa unutar kolegija na kojem se provodio eksperiment 53
Tablica 7. Vremenski okvir po koracima za istraživanje u okviru kolegija Programiranje na Učiteljskom fakultetu u Zagrebu, Odsjeku u Čakovcu 57
Tablica 8. Popis varijabli, vrsta i indikatori za svaku pojedinu varijablu 60
Tablica 9. Broj ispitanika u uzorku 4 - rasipanje uzorka..... 67
Tablica 10. Vremenski slijed Pilot istraživanja..... 69
Tablica 11. Faktorijalna 2x2x2 anova s faktorima: Samoprocjena (S) s nivoima uključna (u) i nije uključena (nu), Vršnjačka procjena (V) s nivoima uključna (u) i nije uključena (nu) te ponovljenim mjerenjem na faktoru Vrijeme_poslije-Vrijeme_prije ($T_{poslije}$-T_{prije}) te zavisnim varijablama Duboki (D) i TPACK 75
Tablica 11. Faktorijalna 2x2x2 anova s faktorima: Samoprocjena (S) s nivoima uključna (u) i nije uključena (nu), Vršnjačka procjena (V) s nivoima uključna (u) i nije uključena (nu) te ponovljenim mjerenjem na faktoru Vrijeme (T) s nivoima prije i poslije te zavisnom varijabom Duboki (D) 76
Tablica 12. Faktorijalna 2x2x2 anova s faktorima: Samoprocjena (S) s nivoima uključna (u) i nije uključena (nu), Vršnjačka procjena (V) s nivoima uključna (u) i nije uključena (nu) te ponovljenim mjerenjem na faktoru Vrijeme (T) s nivoima prije i poslije te zavisnom varijabom TPACK (TPACK) 79
Tablica 13. Prikaz broja studenata, po kolegijima, koji su sudjelovali u eksperimentu i broj studenata koji su iskazali svoje mišljenje o sudjelovanju 82
Tablica 14. Čestice dodane u upitnik RASI u kontekstu problemskih i složenih zadataka grupirane u odnosu na pristup učenju na koji se odnose..... 83
Tablica 15. Raspon koeficijenata opterećenja za svaku domenu i poddomenu upitnika RASI85

Tablica 16. Matrica korelacija među domenama SPTKTT upitnika..... 85
Tablica 17. Deskriptivna statistika čestica i podskala upitnika RASI (aritmetička sredina, standardna devijacija, mjeru asimentričnosti s pripadnom standardnom pogreškom, mjeru zaobljenosti s pripadnom standardnom pogreškom, item-total korelacija u odnosu na cijelu skalu te item-total korelacija u odnosu na odgovarajuću podskalu) na uzorku od N=685 ispitanika 87
Tablica 18. Cronbachov koeficijent α za svaku podskalu upittnika RASI 89
Tablica 19. Raspon koeficijenata opterećenja za svaku domenu upitnika SPTKTT 90
Tablica 20. Matrica korelacija među domenama SPTKTT upitnika..... 90
Tablica 21. Deskriptivna statistika čestica i podskala upitnika SPTKTT (aritmetička sredina, standardna devijacija, mjeru asimentričnosti s pripadnom standardnom pogreškom, mjeru zaobljenosti s pripadnom standardnom pogreškom, item-total korelacija u odnosu na cijelu skalu te item-total korelacija u odnosu na odgovarajuću podskalu) na uzorku od N=337 ispitanik 92
Tablica 22. Cronbachov koeficijent α za svaku podskalu upittnika SPTKTT 93
Tablica 23. Deskriptivna statistika za varijable Tehnologija i Bez Tehnologije na uzorku od N=260 slučajeva 94
Tablica 24. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijable Duboki i TPACK u odnosu na vrijeme, samoprocjenu i vršnjačku procjenu, na uzorku od N=195 ispitanika 101
Tablica 25. Deskriptivna statistika za varijable Duboki i TPACK u odnosu na vrijeme, samoprocjenu i vršnjačku procjenu, na uzorku od N=195 ispitanika, koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima 102
Tablica 26. Pearsonov r koeficijent za zavisne varijable TPACK i Duboki u odnosu na vrijeme prije i poslije sudjelovanja u procjeni 103
Tablica 27. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisne varijable TPACK i Duboki u odnosu na nezavisne varijable Samoprocjena, Vršnjačka procjena i Vrijeme 104
Tablica 28. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Duboki u odnosu na samoprocjenu, vršnjački procjenu i vrijeme .. 105

Tablica 29. Deskriptivna ststistika za varijablu Duboki u odnosu na samoprocjenu, vršnjački procjenu i vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i njihovim omjerom 105
Tablica 30. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu Duboki u odnosu na nezavisne varijable Samoprocjena, Vršnjačka procjena i Vrijeme 106
Tablica 31. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Duboki u odnosu na vrijeme i spol 107
Tablica 32. Deskriptivna ststistika za varijablu Duboki u odnosu na Spol i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima 109
Tablica 33. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu Duboki u odnosu na nezavisne varijable Spol i Vrijeme 110
Tablica 34. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Duboki u odnosu na vrijeme i studijsku godinu 110
Tablica 35. Deskriptivna ststistika za varijablu Duboki u odnosu na Studijsku godinu i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima 111
Tablica 36. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu Duboki u odnosu na nezavisne varijable Studijska godina i Vrijeme 114
Tablica 37. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Duboki u odnosu na vrijeme i razinu studija 114
Tablica 38. Deskriptivna ststistika za varijablu Duboki u odnosu na Razinu studija i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima 115
Tablica 39. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu Duboki u odnosu na nezavisne varijable Razina studija i Vrijeme 117
Tablica 40. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Duboki u odnosu na vrijeme i znanstveno područje kolegija 118

Tablica 41. Deskriptivna ststistika za varijablu Duboki u odnosu na Znasntveno područje kolegija i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima 119
Tablica 42. Razine vjerojatnosti F vrijednosti u analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu Duboki u odnosu na nezavisne varijable Znanstveno područje kolegija i Vrijeme 122
Tablica 43. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Pristup učenju 124
Tablica 44. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Pristup učenju koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima 124
Tablica 45. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Procjenu na uzorku od N=148 ispitanika 126
Tablica 46. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Procjenu koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=148 ispitanika 127
Tablica 47. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Samoprocjenu na uzorku od N=150 ispitanika 128
Tablica 48. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Samoprocjenu koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=150 ispitanika 129
Tablica 49. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Vršnjačku procjenu na uzorku od N=150 ispitanika 130
Tablica 50. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Vršnjačku procjenu koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=150 ispitanika 130
Tablica 51. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Spol na uzorku od N=150 ispitanika 132

Tablica 52. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Spol koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=150 ispitanika 132
Tablica 53. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Studijsku godinu na uzorku od N=147 ispitanika 134
Tablica 54. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Studijsku godinu koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=147 ispitanika 134
Tablica 55. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Razinu studija na uzorku od N=150 ispitanika 136
Tablica 56. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Razinu studija koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=150 ispitanika 136
Tablica 57. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Znanstveno područje kolegija na uzorku od N=149 ispitanika 137
Tablica 58. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Znanstveno područje kolegija koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=149 ispitanika 137
Tablica 59. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu TPACK u odnosu na samoprocjenu, vršnjački procjenu i vrijeme, na uzorku od N=195 ispitanika 140
Tablica 60. Deskriptivna statistika za varijablu TPACK u odnosu na samoprocjenu, vršnjački procjenu i vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i njihovim omjerom na skupu podataka od N=195 140
Tablica 61. Razine vjerojatnosti F vrijednosti u faktorskoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu TPACK u odnosu na nezavisne varijable Samoprocjena, Vršnjačka procjena i Vrijeme 141

Tablica 62. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu TPACK u odnosu na vrijeme i spol na skupu podataka od N=195 ispitanika 142
Tablica 63. Deskriptivna ststistika za varijablu TPACK u odnosu na Spol i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima na uzorku od N=195 ispitanika 142
Tablica 64. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu TPACK u odnosu na nezavisne varijable Spol i Vrijeme..... 145
Tablica 65. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu TPACK u odnosu na vrijeme i studijsku godinu na skupu podataka od N=195 ispitanika 148
Tablica 66. Deskriptivna ststistika za varijablu TPACK u odnosu na Studijsku godinu i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima na uzorku od N=195 ispitanika..... 148
Tablica 67. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu TPACK u odnosu na nezavisne varijable Studijska godina i Vrijeme 149
Tablica 68. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu TPACK u odnosu na vrijeme i razinu studija, na uzorku od N=195 ispitanika 150
Tablica 69. Deskriptivna ststistika za varijablu TPACK u odnosu na Razinu studija i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=195 ispitanika..... 152
Tablica 70. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu TPACK u odnosu na nezavisne varijable Razina studija i Vrijeme 153
Tablica 71. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu TPACK u odnosu na vrijeme i znanstveno područje kolegija..... 154
Tablica 72. Deskriptivna ststistika za varijablu TPACK u odnosu na Znanstveno područje kolegija i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=196 ispitanika 157

Tablica 73. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu TPACK u odnosu na nezavisne varijable Znanstveno područje kolegija i Vrijeme 158
Tablica 74. Usporedba u parovima varijable TPACK_poslije-TPACK_prije u odnosu na znanstveno područje kolegija 158
Tablica 75. Konstruktivno poravnanje za kolegij Programski jezik Logo 192
Tablica 76. Popis kriterija i raspona bodova za svaki pojedini kriterij za Programski jezik LOGO 193
Tablica 77. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Programski jezik LOGO 193
Tablica 78. Konstruktivno poravnanje za kolegij Statistika 194
Tablica 79. Popis kriterija i raspona bodova za svaki pojedini kriterij za Statistiku 195
Tablica 80. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Statistika 195
Tablica 81. Konstruktivno poravnanje za kolegij Prirodno geografska obilježja Hrvatske... 196
Tablica 82. Popis kriterija i raspona bodova za svaki pojedini kriterij za Prirodno geografska obilježja Hrvatske 197
Tablica 83. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Prirodno geografska obilježja Hrvatske 197
Tablica 84. Konstruktivno poravnanje za kolegij Metodika matematike I 198
Tablica 85. Popis kriterija i raspona bodova za svaki pojedini kriterij za Metodiku matematika I 199
Tablica 86. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Metodika matematike I 199
Tablica 87. Konstruktivno poravnanje za kolegij Metodologija pedagoškog istraživanja. ... 200
Tablica 88. Popis kriterija i raspona bodova za svaki pojedini kriterij za Metodologiju pedagoškog istraživanja 201
Tablica 89. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Metodologija pedagoškog istraživanja 201
Tablica 90. Konstruktivno poravnanje za kolegij Programiranje 202
Tablica 91. Popis kriterija i raspona bodova za svaki pojedini kriterij za Programiranje..... 203

Tablica 92. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Programiranje 204
Tablica 93. Konstruktivno poravnanje za kolegij Uvod u baze podataka 205
Tablica 94. Popis kriterija i raspona bodova za svaki pojedini kriterij za Uvod u baze podataka 205
Tablica 95. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Uvod u baze podataka 206
Tablica 96. Konstruktivno poravnanje za kolegij Engleski jezik I 207
Tablica 97. Popis kriterija i raspona bodova za svaki pojedini kriterij za Engleski jezik I ... 207
Tablica 98. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Engleski jezik I..... 208
Tablica 99. Koraci istraživanja i odgovarajuće aktivnosti na Moodlu 210
Tablica 100. Primjer računanja pouzdanosti - rang kriterija 211
Tablica 101. Primjer za računanje pouzdanosti - procjene po svakom pojedinom kriteriju .. 211
Tablica 102. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Oblikovanje teksta i slike tijekom Pilot istraživanja 217

POPIS SLIKA

Slika 1.Teorijski model za koncept Pristupa učenju s pripadnim komponentama..... 16
Slika 2. Usklađivanje ciljanih ishoda učenja, metoda poučavanja te procjene ostvarenosti ishoda učenja (prema (Biggs i Tang, 2007)) 18
Slika 3. Percepcija procjene znanja od strane nastavnika i studenata (prema (Biggs i Tang, 2007)) 18
Slika 4. TPACK teorijski okvir i njegove komponente znanja (reproducira se uz dopuštenje izdavača, ©tpack.org)..... 22
Slika 5. Raspored čestica SPTKTT upitnika po komponentama TPACK teorijskog okvira ... 38
Slika 6. Prošireni teorijski model za koncept Pristupa učenju s pripadnim komponentama u kontekstu složenih i problemskih zadataka 43
Slika 7. Raspored čestica SPTKTT upitnika po komponentama TPACK teroijskog okvira u k ontekstu hrvatskog obrazovnog sustava 44
Slika 8. Blok aktivnosti vezanih uz istraživanje u okviru kolegija Metodika Matematike I na Fakultetu za odgojne i obrazovne znanosti u Osijeku 58
Slika 9. Aktivnost Radionica unutar sustava za upravljanje učenjem Moodle 59
Slika 10. Otvoreno pitanje postavljeno na sustav za upravljanje učenjem Moodle u svrhu prikupljanja mišljenja studenata 81
Slika 11. Konfirmatorna faktorska analiza proširenog RASI upitnika, na temelju17 podsala grupiranih u tri pristupa učenju: **Duboki pristup (DEEP)** – traženje smisla (SM), povezivanje ideja (RI), upotreba dokaza (UE), zanimanje za ideje (II), praćenje apretka (ME) i prblemski_duboki (PS_deep); **Strateški pristup (STRATEGI)** – organizacija učenja (OS), upravljanjevremenom (TM), postignće ACH), oprez u odnosu na procjenu (AAD) i problemski_strateški (PS_stra); **Površinski pristup (SURFACE)** – nedostatak svrhe (LP), nepovezano memorranje (UM), ograničenja programa (SB), strah od neuspjeha (FF) i problemski_površinski (PS_surf). Čestice proširenog upitnika RASI označe su redom R1-R66 86
Slika 12. Konfirmatorna faktorska analiza SPTKTT upitnika, na temelju teorijskog modela prikazanog na slici 7., pri čemu su čestice upitnika označene redom T1-T47 : Tehnološka znanja (TK: T1-T7), Sadržajna znanja (CK) (Matematika (CKMATH:T8-T10), Priroda i društvo (CKSSiSC: T11-T16), Pismenost (CKLIT:T17-T19), Pedagoška znanja (PK: T20-T25),

Pedgoško sadržajna znanja (PCK: T26-T30), Tehnološko sadržajna znanja (TCK: T31-T34), Tehnološko pedagoška znanja (TPK: T35-T39), Tehnološko pedagoško sadržajna znanja TPACK: T40 – T47). 91
Slika 13. Q-Q prikaz za varijablu Tehnologija na uzorku od N=260 slučajeva..... 95
Slika 14. Q-Q prikaz za varijablu Tehnologija - Bez tehnologije na uzorku od N=260 slučajeva 95
Slika 15. Kutijasti dijagrami za varijable Tehnologija i Bez Tehnologije na uzorku od N=260 slučajeva 95
Slika 16. Kutijasti dijagrami za varijablu Duboki za sve promatrane skupine ispitanika koji su sudjelovali u samoprocjeni i vršnjačkoj procjeni, prije sudjelovanja u eksperimentu 96
Slika 17. Kutijasti dijagrami za varijablu Duboki za sve promatrane skupine ispitanika koji su sudjelovali u samoprocjeni i vršnjačkoj procjeni, poslije sudjelovanja u eksperimentu 97
Slika 18. Kutijasti dijagrami varijable Duboki_poslije - Duboki_prije za sve promatrane skupine ispitanika koji su sudjelovali u samoprocjeni i vršnjačkoj procjeni 97
Slika 19. Kutijasti dijagrami za varijablu TPACK za sve promatrane skupine ispitanika koji su sudjelovali u samoprocjeni i vršnjačkoj procjeni, prije sudjelovanja u eksperimentu 98
Slika 20. Kutijasti dijagrami za varijablu TPACK za sve promatrane skupine ispitanika koji su sudjelovali u samoprocjeni i vršnjačkoj procjeni, poslije sudjelovanja u eksperimentu 98
Slika 21. Kutijasti dijagrami varijable TPACK_poslije-TPACK_prije za sve promatrane skupine ispitanika koji su sudjelovali u samoprocjeni i vršnjačkoj procjeni 99
Slika 22. Q-Q prikazi varijable TPACK_poslije - TPACK_prije u odnosu na sudjelovanje u samoprocjeni i vršnjačkoj procjeni..... 100
Slika 23. Q-Q prikazi varijable Duboki_poslije - Duboki_prije u odnosu na sudjelovanje u samoprocjeni i vršnjačkoj procjeni..... 100
Slika 24. Dijagram raspršenosti za varijablu TPACK u odnosu na varijable Samoprocjena, Vršnjačka procjena i Vrijeme, na uzorku od N=195 ispitanika 101
Slika 25. Dijagram raspršenosti za varijablu Duboki u odnosu na varijable Samoprocjena, Vršnjačka procjena i Vrijeme, na uzorku od N=195 ispitanika 103
Slika 26. . Q-Q prikazi varijable Duboki_poslije-Duboki_prije za obje skupinu ispitanika u odnosu na Spol 107
Slika 27. Kutijasti dijagrami varijable Duboki za obje skupine ispitanika u odnosu na Spol prije sudjelovanja u eksprimentu 108

Slika 28. Kutijasti dijagrami varijable Duboki za obje skupine ispitanika u odnosu na Spol poslije sudjelovanja u eksprimentu 108
Slika 29. Kutijasti dijagrami varijable Duboki_poslije – Duboki_prije za obje skupine ispitanika u odnosu na Spol 109
Slika 30. Kutijasti dijagrami varijable Duboki za sve skupine ispitanika u odnosu na Studijsku godinu prije sudjelovanja u eksprimentu 111
Slika 31. Kutijasti dijagrami varijable Duboki za sve skupine ispitanika u odnosu na Studijsku godinu poslije sudjelovanja u eksprimentu 112
Slika 32. Kutijasti dijagrami varijable Duboki_poslije – Duboki_prije za sve skupine ispitanika u odnosu na Studijsku godinu 112
Slika 33. Q-Q prikazi varijable Duboki_poslije-Duboki_prije za sve skupine ispitanika u odnosu na Studijsku godinu 113
Slika 34. Kutijasti dijagrami varijable Duboki za sve skupine ispitanika u odnosu na Razinu studija prije sudjelovanja u eksprimentu 115
Slika 35. Kutijasti dijagrami varijable Duboki za sve skupine ispitanika u odnosu na Razinu studija poslije sudjelovanja u eksprimentu 116
Slika 36. Kutijasti dijagrami varijable Duboki_poslije – Duboki_prije za sve skupine ispitanika u odnosu na Razinu studija 116
Slika 37. Q-Q prikazi varijable Duboki_poslije-Duboki_prije za sve skupine ispitanika u odnosu na Razinu studija 117
Slika 38. Q-Q prikaz varijable Duboki za skupinu ispitanika na kolegijima iz područja društvenih znanosti u odnosu na vrijeme poslije sudjelovanja u eksperimentu 120
Slika 39. Kutijasti dijagrami varijable Duboki za sve skupine ispitanika u odnosu na Znanstveno područje kolegija prije sudjelovanja u eksprimentu 120
Slika 40. Kutijasti dijagrami varijable Duboki za sve skupine ispitanika u odnosu na Znanstveno područje kolegija poslije sudjelovanja u eksprimentu 120
Slika 41. Kutijasti dijagrami varijable Duboki_poslije – Duboki_prije za sve skupine ispitanika u odnosu na Znanstveno područje kolegija 121
Slika 42. Q-Q prikazi varijable Duboki_poslije-Duboki_prije za sve skupine ispitanika u odnosu na Znanstveno područje kolegija 121
Slika 43.Dijagram razmještaja varijable Dijametar kvazi - pouzdanosti i Pistup učenju, na uzorku od N=150 ispitanika 123

Slika 44. Kutijasti dijagrami varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na Pristup učenju 124
Slika 45. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na Pristup učenju 125
Slika 46. Kutijasti dijagrami varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu procjenu 126
Slika 47. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na procjenu 127
Slika 48. Kutijasti dijagrami varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na sudjelovanje u samoprocjeni 128
Slika 49. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na sudjelovanje u samoprocjeni 129
Slika 50. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na sudjelovanje u vršnjačkoj procjeni, na uzorku od N=150 ispitanika 131
Slika 51. Kutijasti dijagram varijable Dijametar kvazi - pouzdanosti u odnsou na sudjelovanje u vršnjačkoj procjeni, na uzorku od N=150 ispitanika 131
Slika 52. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na spol, na uzorku od N=150 ispitanika 132
Slika 53. Kutijasti dijagram varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na spol, na uzorku od N=150 ispitanika 133
Slika 54. Kutijasti dijagrami varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na studijsku godinu, na uzorku od N=147 ispitanika 134
Slika 55. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na studijsku godinu, na uzorku od N=147 ispitanika 135
Slika 56. Kutijasti dijagrami varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na razinu studija, na uzorku od N=150 ispitanika 136
Slika 57. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na razinu studija, na uzorku od N=150 ispitanika 137
Slika 58. Kutijasti dijagrami varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na znanstveno područje kolegija, na uzorku od N=150 ispitanika 138
Slika 59. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na znantveno područje kolegija, na uzorku od N=150 ispitanika 138

Slika 60. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na spol, na skupu podataka od N=195 ispitanika, prije sudjelovanja u eksperimentu 143
Slika 61. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na spol, na skupu podataka od N=195 ispitanika, poslije sudjelovanja u eksperimentu 143
Slika 62. Kutijasti dijagrami varijable TPACKposlije-TPACK_prije za sve skupine ispitanika u odnosu na spol, na skupu podataka od N=195 ispitanika 144
Slika 63. Q-Q prikazi varijable TPACKposlije-TPACK_prije za sve skupine ispitanika u odnosu na spol, na skupu podataka od N=195 ispitanika 144
Slika 64. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na Studijsku godinu, na skupu podataka od N=195 ispitanika, prije sudjelovanja u eksperimentu 146
Slika 65. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na Studijsku godinu, na skupu podataka od N=195 ispitanika, poslije sudjelovanja u eksperimentu 146
Slika 66. Kutijasti dijagrami varijable TPACK_poslije-TPACK_prije za sve skupine ispitanika u odnosu na Studijsku godinu, na skupu podataka od N=195 ispitanika 147
Slika 67. Q-Q prikazi varijable TPACKposlije-TPACK_prije za sve skupine ispitanika u odnosu na studijsku godinu, na skupu podataka od N=195 ispitanika..... 147
Slika 68. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na Razinu studija, na skupu podataka od N=196 ispitanika, prije sudjelovanja u eksperimentu..... 150
Slika 69. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na Razinu studija, na skupu podataka od N=196 ispitanika, poslije sudjelovanja u eksperimentu 151
Slika 70. Kutijasti dijagrami varijable TPACK_poslije-TPACK_prije za sve skupine ispitanika u odnosu na Razinu studija, na skupu podataka od N=196 ispitanika 151
Slika 71. Q-Q prikazi varijable TPACKposlije-TPACK_prije za sve skupine ispitanika u odnosu na razinu studija, na skupu podataka od N=195 ispitanika 152
Slika 72. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na znnanstveno područje kolegija, na skupu podataka od N=196 ispitanika, prije sudjelovanjau eksperimentu 154
Slika 73. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na znnanstveno područje kolegija, na skupu podataka od N=196 ispitanika, poslije sudjelovanjau eksperimentu 155
Slika 74. Kutijasti dijagrami varijable TPACK_poslije-TPACK_prije za sve skupine ispitanika u odnosu na Znanstveno područje kolegija, na skupu podataka od N=196 ispitanika..... 155

Slika 75. Q-Q prikazi varijable TPACKposlije-TPACK_prije za sve skupine ispitanika u odnosu na znanstveno pdručje kolegij, na skupu podataka od N=196 ispitanika 156
Slika 76. Q-Q prikaz varijable TPACK_prije za skupinu ispitanika koji su pohađali kolegije iz društvenih znanosti, na skupu podataka od N=196 ispitanika 156
Slika 77. Udio pozitivnih i negativnih elemenata u komentarima studenata na zadani zadatak, njegovo rješavanje i procjenjivanje 159
Slika 78. Suglasnost za sudjelovanja u istraživanju u sklopu aktivnosti Survey unutar sustava za upravljanje učenjem Moodle 191

1 UVOD

Posljednjih godina velika pažnja posvećuje se kvaliteti obrazovanja, kako u cijelom svijetu tako i u Europi, te se osnivaju mnoge agencije i tijela kojima je primarna uloga osiguranje kvalitete visokog školstva. Cijeli taj proces začetak pronalazi u Bolonjskoj deklaraciji (Bologna Declaration, 1999) i Berlinskom priopćenju (Berlin Communiqué, 2003) koje su otvorile mogućnost za mobilnost i razmjenu znanja na području Europe te razvoj standarda, postupaka i smjernica za osiguravanje kvalitete. Konačan cilj prethodno spomenutih dokumenata je, između ostalog, i stvaranje jedinstvenih obrazovnih kriterija visokog školstva na svim sveučilištima u Europi, odnosno na europskom prostoru visokog obrazovanja (EHEA) (European Association for Quality Assurance in Higher Education, 2009).

Procjena znanja je sastavni dio učenja (Carless, 2003), a u kontekstu visokog obrazovanja smatra se jednim od najvažnijih elemenata procesa učenja i poučavanja (European Association for Quality Assurance in Higher Education, 2009). Pristup učenju jedan je od najznačajnijih koncepata koji opisuje učenje, a razlikuju se dubinski, strateški i površinski pristup (Entwistle, 2009a, str. 41). Za razvoj akademskog razumijevanja istaknuta je važnost usvajanja dubinskog pristupa učenju (Marton i Säljö, 1984.) koji podrazumijeva usmjeravanje na zadatak s namjerom da onaj koji uči razvije vlastito razumijevanje ideja (Entwistle, 2009a, str. 33).

Kvalitetna povratna informacija potiče usvajanje dubinskog pristupa učenju (Entwistle, 2009a, str. 88), a njezinu važnost ističe i Vygotsky u okviru socio-konstruktivističke teorije učenja koja, uz izgradnju znanja, naglašava potrebu za interakcijom i suradnjom (Harasim, 2012, str. 68). Teorija suradničkog učenja u virtualnom okruženju podrazumijeva upotrebu online tehnologija i pomiče fokus s prijenosa na izgradnju znanja u skladu s obrazovnim zahtjevima 21. stoljeća koji podrazumijevaju inovativnost, kreativnost, sposobnost rješavanja problema te globalnu komunikaciju (Harasim, 2012, str. 170).

U Sintezi izvješća o procjeni znanja i povratnoj informaciji uz podršku tehnologije (Gilbert, Whitelock i Gale, 2011) u kojem je analizirano 142 članka na promatranu temu, istaknuto je kako upotreba tehnologije u nastavi omogućuje efektivnije načine poučavanja, pod čime se podrazumijevaju i česti testovi formativne procjene uz povratnu informaciju. Bez upotrebe tehnologije, ograničenja poput vremena, troškova, broj studenata, geografska i vremenska udaljenost, učinili bi takve efektivne oblike poučavanja teško ostvarivima. U Republici

Hrvatskoj je 2014.g. donesena Strategija obrazovanja, znanosti i tehnologije (Vlada Republike Hrvatske, 2014) koja treba osigurati fleksibilnost i prilagodljivost sustava obrazovanja i istraživanja kako bi se mogle pratiti promjene u globaliziranom svijetu temeljene na razvoju novih tehnologija.

Iako je integracija tehnologije u nastavu najčešće osobni poduhvat učitelja, osobna upotreba tehnologije, odnosno samo znanje o tehnologiji, nedostatno je za njezinu uspješnu integraciju u proces poučavanja i učenja (Keating i Evans, 2001). Kako bi IKT služio boljem i lakšem svladavanju gradiva, učitelji moraju posjedovati tehnička znanja o upotrebi IKT-a, kao i znanja o njegovoj pravilnoj pedagoškoj integraciji u nastavni proces (Koehler i Mishra, 2009).

1.1 Definiranje osnovne svrhe istraživanja

Okvir nacionalnoga kurikuluma (Ministarstvo znanosti, obrazovanja i sporta RH, 2016) ističe da je prethodnih 15 godina obrazovna politika Republike Hrvatske, bez obzira na političku pripadnost, pokušala usmjeriti strateški razvoj ranog i predškolskog, osnovnoškolskog i srednjoškolskog sustava odgoja i obrazovanja prema razvoju kompetencija, promjeni načina učenja i poučavanja te jasnom usmjerenju na potrebu definiranja odgojno-obrazovnih ishoda (ishoda učenja). Ishode učenja, u svrhu osiguranje kvalitete nastave visokog obrazovanja, promovira i Bolonjska deklaracija (Bologna Declaration, 1999). Hrvatski kvalifikacijski okvir (Ministartsvo znanosti, obrazovanja i sporta RH, 2013) uređuje cjelokupni sustav kvalifikacija na svim obrazovnim razinama u Republici Hrvatskoj kroz standarde kvalifikacija temeljene na ishodima učenja i usklađene s potrebama tržišta rada, pojedinca i društva u cjelini. Iz prethodno navedenog jasno je da se na svim razinama obrazovanja u Republici Hrvatskoj radi zaokret prema poučavanju temeljenom na ishodima učenja i kompetencijama.

Strategija obrazovanja, znanosti i tehnologije (Vlada Republike Hrvatske, 2014) ističe potrebu za uvođenjem suvremenih metoda poučavanja temeljenih na informacijskoj i komunikacijskoj tehnologiji (IKT), i to na svim razinama i u svim vrstama obrazovanja.

Usavršavanje učitelja u korištenju i primjeni obrazovnih tehnologija ima pozitivan utjecaj na razvoj pedagoškog i predmetnog tehnološkog znanja (Shin T. i dr.., 2009), a veće pedagoško i predmetno tehnološko znanje rezultira većim znanjem i boljim vještinama nastavnika u kombiniranju tehnologije i pedagogije u praktičnoj nastavi (Altun, 2013). Prvo istraživačko pitanje u ovoj disertaciji odnosi se na samoprocjenu znanja o primjeni tehnologije u nastavi kod hrvatskih učitelja i nastavnika u praksi.

Uključivanje studenata u postupak procjene doprinosi razvoju njihovih kompetencija (Dochy, Segers i Sluijsman, 1999) i utječe na pristup učenju koji će student usvojiti (Entwistle, 2009a, str. 145). Rješavanje autentičnih problema i grupni rad potiču dubinski pristup učenju i suradničko učenje (Entwistle, 2009a, str. 159) te se ističu kao kritične i iznimno potrebne vještine, kako za obrazovanje, tako i buduće sudjelovanje na tržištu rada (OECD, 2013).

U ovoj doktorskoj disertaciji predložen je online dizajn okoline za poučavanje temeljen na prethodno navedenim smjernicama te je istražen utjecaj takve okoline na elemente obrazovanja istaknute kao važne u kontekstu obrazovanja za 21. stoljeće. Drugo istraživačko pitanje obuhvaća utjecaj prethodno navedenih elemenata poput grupnog rada, problemskih i/ili složenih zadataka te sudjelovanja u postupku procjene, koji su uključeni u predloženi dizajn okoline za poučavanje, na znanja o primjeni IKT-a u nastavi te pristup učenju koji student primjenjuje.

1.2 Ciljevi i hipoteze istraživanja

U provedenom istraživanju promatraju se sljedeći osnovni problemi:

- primjena IKT-a u nastavi te
- sudjelovanje studenata u procesu procjene znanja
- razvoj studentskog kritičkog mišljenja i sposobnosti rješavanja problema u novonastalim situacijama.

U skladu s prethodno identificiranim problemima, postavljaju se sljedeći ciljevi istraživanja:

- ispitati trenutno stanje u znanjima nastavnika i učitelja u praksi u Republici Hrvatskoj o primjeni informacijsko komunikacijske tehnologije u nastavi,
- istražiti utjecaj vršnjačke procjene i/ili samoprocjene, uz pomoć IKT-a, na primjenu tehnologije u nastavi,
- istražiti utjecaj vršnjačke procjene i/ili samoprocjene, uz pomoć IKT-a, na pristup učenju koji student uobičajeno primjenjuje,
- istražiti postoji li veza između pristupa učenju koji student uobičajeno primjenjuje i točnosti samoprocjene i/ili vršnjačke procjene,

- proširiti upitnik RASI o pristupu učenju u kontekstu rješavanja problema i složenijih zadatka te validirati proširenu verziju upitnika,
- validirati upitnik SPTKTT o samoprocjenu vlastitih znanja o primjeni tehnologije u nastavi u kontekstu hrvatskog obrazovnog sustava.

U okviru istraživanja postavljene su sljedeće hipoteze:

H1: Učitelji i nastavnici u Hrvatskoj percipiraju slabija vlastita znanja o primjeni IKT-a u nastavi u odnosu na vlastita pedagoška i predmetna znanja.

H2: Sudjelovanje u procesu vršnjačke procjene i/ili samoprocjene rješenja problemskog zadatka u okviru online suradničkog učenja pozitivno utječe na pomak prema dubinskom pristupu učenju.

H3: Postoji povezanost između pristupa učenju koji student uobičajeno primjenjuje i pouzdanosti kriterijske procjene rješenja problemskog zadatka.

H4: Sudjelovanje u procesu vršnjačke procjene i/ili samoprocjene rješenja problemskog zadatka u okviru online suradničkog učenja utječe na percepciju budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi.

1.3 Sažeti prikaz istraživanja i metodologije

Istraživanje provedeno u sklopu ove doktorske disertacije je podijeljeno na teorijski i empirijski dio. U teorijskom dijelu istraživanja dan je pregled istraživanja na temu procjene znanja, pristupa učenju i primjeni tehnologije u nastavi. Empirijski dio istraživanja sastoji se od sljedećih dijelova:

- istraživanje o percepciji vlastitih znanja o primjeni IKT-a u nastavi među hrvatskim učiteljima i nastavnicima u praksi,
- proširenje upitnika RASI o pristupu učenju u kontekstu rješavanja problemskih i složenih zadataka, nakon čega je provedena validacija istog,
- validacija upitnika SPTKTT o primjeni tehnologije u nastavi u kontekstu hrvatskog obrazovnog sustava,

- analiza utjecaja sudjelovanja u procesu samoprocjene i vršnjačke procjene rješenja problemskog ili složenog zadatka na pristup učenju koji studenti uobičajeno primjenjuju i percepciju vlastitih znanja o primjeni IKT-a u nastavi.

1.3.1 Ispitanici

S obzirom da empirijski dio istraživanja obuhvaća nekoliko različitih segmenata, skup ispitanika koji su sudjelovali u ovom istraživanju sastoji se od: (a) učitelja i nastavnika u praksi u Republici Hrvatskoj i (b) studenata u Republici Hrvatskoj.

1.3.2 Instrumenti i postupci

Instrumenti korišteni u ovom istraživanju su upitnik SPTKTT (*Survey of Preservice Teachers' Knowledge of Teaching and Technology*) o samoprocjeni vlastitih znanja o primjeni tehnologije u nastavi među budućim učiteljima te upitnik RASI (*Revised Approach to Study Inventory*) o pristupu učenju studenata. Primjenjene su sljedeće znanstveno-istraživačke metode: anketa, metoda dvostrukog prijevoda upitnika, fokus grupa, eksperiment.

1.3.3 Analiza podataka

Prikupljeni podaci obrađeni su pomoću programa za statističku obradu podataka Statistica 13 i Lisrel 9.2. Za određivanje valjanosti upitnika korištena je konfirmatorna faktorska analiza, a za određivanje pouzdanosti korištena je metoda unutarnje konzistencije koja uključuje određivanje vrijednosti Cronbachova koeficijenta pouzdanosti α. T-testom za zavisne uzorke, na razini značajnosti $\alpha=0.05$, ispitala se percepcija vlastitih znanja o primjeni IKT-a u nastavi među hrvatskim učiteljima i nastavnicima u praksi. Tro-faktorskom analizom varijance, na razini značajnosti $\alpha=0.05$, ispitalo se postoji li razlika u pomaku prema dubokom pristupu učenju u odnosu na sudjelovanje u procesu samoprocjene i vršnjačke procjene. Tro-faktorska analiza varijance korištena je i za analizu promjene percepcije budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi u odnosu na sudjelovanje u procesu samoprocjene i vršnjačke procjene. Povezanost između pristupa učenju koji student uobičajeno primjenjuje i pouzdanosti kriterijske procjene rješenja problemskog i/ili složenog zadatka ispitalo se eta koeficijentom.

1.4 Struktura disertacije

Disertacija je podijeljena u sedam poglavlja.

Uvodno poglavlje donosi uvodna razmatranja o promatranoj temi, osnovnoj svrsi, ciljevima i hipotezama istraživanja te kratki prikaz metodologije.

Drugo poglavlje navodi važne pojmove i ideje koje se povezuju s procjenom znanja. Važni pojmovi za ovo istraživanje su: ishodi učenja, procjena, povratna informacija, vršnjačka procjena i samoprocjena. Također, predstavljeni su i teorijski okviri, na kojima se temelji istraživanje u ovoj doktorskoj disertaciji.

Treće poglavlje predstavlja pregled literature važne za razumijevanje promatranih tema. Pregled literature podijeljen je u tri dijela. Prvi dio odnosi se na procjenu znanja, drugi dio na pristup učenju i treći dio na informacijsku i komunikacijsku tehnologiju u obrazovanju.

Metodološki pristup objašnjen je u četvrtom poglavlju. Ovo poglavlje navodi uzorke istraživanja, kao i mjerne instrumente, objašnjene su znanstvene metode koje su bile upotrijebljene, kao i metode prikupljanja podataka, opisane su varijable istraživanja i analiza podataka. U ovom poglavlju također je predložen dizajn online okoline za poučavanje.

Rezultati istraživanja predstavljeni su u poglavlju pet.

Šesto poglavlje sadrži raspravu o dobivenim rezultatima. Rasprava je podijeljena u pet dijelova: proširenje i validacija RASI upitnika, validacija SPTKTT upitnika, razmatranje trenutnog stanja integracije tehnologije u obrazovanje u Republici Hrvatskoj, utjecaj vršnjačke procjene i/ili samoprocjene na pristup učenju i primjeni tehnologije u nastavi te studentska mišljenja o ovakvom načinu procjene znanja.

Zaključak donosi završna razmatranja te također obuhvaća i znanstvene doprinose, kao i ograničenja provedenog istraživanja.

Ova doktorska disertacija završava popisom literature i životopisom.

2 TEORIJSKI OKVIR

U prethodnom stoljeću veliki naglasak stavljao se u obrazovanju na aktivno učenje u kojem se, za razliku od pasivnog prenošenja znanja, ističu aktivnosti koje zanimaju učenika, a svrha im je izgradnja znanja i kompetencija. Scardamalia i Bereiter (2006) vjeruju kako će intenzitet promjena u obrazovanju u ovom stoljeću biti barem jednak, a vjerojatno i veći. Promoviranje programa kritičke pedagogije te obrazovne reforme na europskom području visokog obrazovanja rezultirale su zahtjevima za alternativnim oblicima poučavanja i učenja koji, umjesto nastavnika, u centar stavljaju studenta. Nastavniku, osim prenošenja znanja, cilj treba biti olakšavanje procesa učenja i omogućavanje studentu da sudjeluje u procesu procjene znanja kako bi stekao vještine potrebne za cjeloživotno učenje, čija važnost postaje sve istaknutija (Boud, 2000; Lorent-Catalan i Kirk, 2014).

2.1 Ishodi učenja i procjena znanja

2.1.1 Ishodi učenja

Jedan od instrumenata osiguranja kvalitete nastave, koji promovira Bolonjski proces, su ishodi učenja. Ishodi učenja (engl. learning outcomes) su tvrdnje o tome što se očekuje od učenika da zna, razumije, može napraviti ili vrednovati kao rezultat procesa učenja (Divjak i sur., 2008, str. 4), (European Commission, 2015). Prema Zakonu o Hrvatskom kvalifikacijskom okviru (Ministarstvo znanosti, obrazovanja i športa RH, 2013) ishodi učenja su kompetencije koje je osoba stekla učenjem i dokazala nakon postupka učenja.

Ostvarenost ishoda učenja provjerava se procjenom znanja na temelju jasnih i transparentnih kriterija. Ishodi učenja se pripisuju pojedinim obrazovnim komponentama i studijskom programu u cjelini (European Commission, 2015). Tijekom izrade kurikuluma potrebno je znati na koji će se način mjeriti znanje i vještine koje želimo razviti kod učenika. Ta znanja i vještine se izražavaju kao ishodi učenja (Cox, 2003).

Adam (2008) navodi kako su ishodi učenja u središtu promjena koje se događaju na području obrazovanja u Europi i nešto manje na području obrazovanja u cijelom svijetu. Ishodi učenja su alat i metodološki pristup koji se treba provoditi u kombinaciji s drugim reformama i tijekom vremenskog intervala kako bi se ostvarile sve prednosti ovakvog pristupa poučavanju. Velik dio europskih zemalja poziva se na ishode učenja tijekom kreiranja ciljeva obrazovnog sustava,

kao i definiranja kvalifikacija u kvalifikacijskim okvirima. Izražavanje ciljeva obrazovnog sustava kroz ishode učenja rezultira snažnim pomakom u obrazovanju koji skreće fokus s trajanja, lokacije i sadržaja prema onome što učenik zna i može napraviti na kraju procesa učenja.

Europska komisija (European Commission, 2015) navodi da, uz definiranje ishoda učenja i radnog opterećenja studenta tijekom izrade i provedbe kurikuluma, fokus procesa obrazovanja treba biti stavljen na studenta te tada govorimo o učenju usmjerenom prema učeniku (*Student-centered learning - SCL*). Učenje usmjereno prema učeniku proces je kvalitativne transformacije usmjerene prema učeniku i svim sudionicima procesa poučavanja s ciljem unaprjeđenja njihove autonomije i mogućnosti kritičkog mišljenja kroz pristup baziran na ishodima učenja. Učenje usmjereno prema učeniku može se sumirati u sljedećim elementima:

- zasniva se na aktivnom, umjesto pasivnom učenju,
- ističe kritičko i analitičko učenje i razumijevanje,
- povećava odgovornost studenta,
- povećava autonomiju studenta,
- predstavlja refleksivni pristup učenju, i od strane učenika, i od strane učitelja.

S obzirom da se koncept ishoda učenja koristi pri postavljanju ciljeva obrazovanja, kao i u različitim procjenama i evaluacijama, njegova definicija može imati različite oblike, a također može varirati i raspon definicije. Bez obzira na način definiranja, ishodi učenja moraju povezivati proces učenja i rezultat tog procesa te se ne smiju odnositi na školovanje, poučavanje, način izvedbe nastavnog procesa i slično (Žiljak, 2013).

2.1.1.1 Taksonomije ishoda učenja

Taksonomija ishoda učenja opisuje razine postignuća kod izricanja ishoda učenja (Divjak, 2011). Cox (2003) navodi da taksonomija daje formalizirane postupke poučavanja i metoda procjene dizajniranih u svrhu ispitivanja ostvarenosti ishoda učenja. Zabilježeni su brojni pokušaji razvijanja taksonomija ishoda učenja, ali većina njih nije zaživjela u praksi jer su bile komplicirane za upotrebu. Prema Bloomu i suradnicima (1956., str. 58) tvorci

kurikuluma trebali bi uz pomoć taksonomije kreirati ciljeve poučavanja kako bi bilo lakše kreirati nastavu i instrumente za evaluaciju.

Po uzoru na taksonomije u biologiji koje razvrstavaju žive organizme u skupine, Bloom i suradnici (1956) razvili su taksonomiju ciljeva poučavanja čija je namjena klasifikacija ciljeva obrazovnog sustava, danas poznatu kao Bloomova taksonomija znanja. Ova taksonomija zamišljena je kao cjelina sastavljena od tri dijela (kategorije): kognitivna, afektivna i psihomotorička domena. Kako Bloom u svojoj knjizi navodi, kognitivno područje je najzastupljenije u kurikulumu i iz tog razloga taksonomija se bazira na toj domeni. Kognitivna domena podijeljena je dodatno na 6 detaljnijih razina: znanje, razumijevanje, primjena, analiza, sinteza i evaluacija (Tablica 1) .

Tablica 1. Razine znanja prema Bloomovoj taksonomiji (prema (Bloom i sur., 1956))

Razina	**Pojašnjenje**
Znanje	*Dosjetiti se relevantnih činjenica iz dugoročne memorije*
Razumijevanje	*Konstruirati značenje iz onoga što je predavano, uključujući usmenu, pisanu i grafičku komunikaciju*
Primjena	*Provesti ili upotrijebiti proceduru u danoj situaciji*
Analiza	*Rastaviti na sastavne dijelove i utvrditi kako ti dijelovi utječu jedan na drugi i na cjelokupnu strukturu*
Sinteza	*Povezati elemente u funkcionalnu cjelinu, reorganizirati elemente u novi uzorak ili strukturu*
Evaluacija	*Prosuditi na temelju kriterija i normi*

Izvorna je Bloomova taksonomija po svojoj prirodi jednodimenzionalna što je rezultiralo objavljivanjem revidirane Bloomove taksonomije (Anderson, Krathwohl i Bloom, 2001) koja je dvodimenzionalna. Osim dimenzije znanja, revidirana taksonomija ima i dimenziju kognitivnog procesa. Također, u revidiranoj taksonomiji tri kategorije promijenile su nazive, redoslijed dviju kategorija promijenjen je i svi nazivi kategorija dani su u obliku glagola kako bi odgovarale načinu kako se upotrebljavaju u ciljevima. Revidirana je Bloommova taksonomija danas široko rasprostranjena, a kao pomoć pri definiranju ishoda učenja koristi se taksonomska tablica (Tablica 2).

2.1.2 Procjenjivanje ili vrednovanje znanja?

U području IKT-a, kada je riječ o kritičkoj procjeni informacija dostupnih putem Interneta, engleski jezik razlikuje barem šest različitih glagola koji označavaju prosudbu

Tablica 2. Taksonomska tablica revidirane Blomove taksonomije (prema (Anderson i sur., 2001))

	Šest kategorija kognitivnih procesa					
Dimenzija znanja i njezine potkategorije	1. *Zapamti*	2. *Objasni*	3. *Primijeni*	4. *Analiziraj*	5. *Vrednuj*	6. *Kreiraj*
A. *Činjenično*						
B. *Konceptualno*						
C. *Proceduralno*						
D. *Meta-kognitivno*						

vrijednosti ili značaja takvih informacija (Dragulanescu, 2002). Svi oni imaju isto osnovno značenje, prosudbu vrijednosti ili značaja, ali također i dodatno značenje koje treba uzeti u obzir. Riječ je o sljedećim glagolima:

- *to evaluate* – podrazumijeva prosudbu u postavljanju vrijednosti osobi ili stvari,
- *to rate* - uključuje određivanje položaja osobe ili stvari u situacijama kada se sudi u odnosu na druge iste vrste,
- *to estimate* - može značiti prosuđivanje na temelju prilično grubih izračuna (ali taj pojam manjka određenošću u odnosu na druge pojmove),
- *to appraise* – naglašava stručnu prosudbu,
- *to assess* - podrazumijeva mjerodavne prosudbe (poput određivanja novčane vrijednosti za nešto kao osnove za oporezivanje),
- *to assay* - odnosi se na pažljivo ispitivanje (kao što je kemijska analiza rude za određivanje njegovog sadržaja).

Jelaska i Cvikić (2008) raspravljaju o odgovarajućim hrvatskim izrazima za engleske riječi *assessment* i *evaluation* u kontekstu jezika. *Assessment* i *evaluation* u hrvatskom jeziku odgovaraju riječima procjenjivanje i vrednovanje, ali se pojavljuju i druge mogućnosti poput provjeravanje, evaluacija i vrjednovanje. Ta dva pojma se u engleskom jeziku ponekad koriste kao da imaju isto, a ponekad kao da imaju različito značenje. Slična situacija sa zamjenom pojmova je i u hrvatskom jeziku.

U Rječniku jezičnoga ispitivanja (Davies, 1999) assessment se određuje kao nadređen pojam za sve metode ispitivanja (engl. testing) i procjenjivanja (engl. assessment), iako neki učitelji (engl. teachers) i ispitivači (engl. testers) rabe naziv ispitivanje (engl. testing) za formalne ili standardizirane ispite (engl. tests) kao što je Test of English as a Foreign Language (TOEFL), a procjenjivanje (engl. assessment) za postupke (engl. methods) koji su više neformalni.

U Hrvatskom enciklopedijskom rječniku (Anić, 2003) pojmovi procjena i vrednovanje navode se na sljedeći način:

Procjena: utvrđena cijena, vrijednosti čega; mišljenje, sud o svojstvima, vrijednostima itd. koga/čega.

Vrednovanje: odrediti vrijednost koga ili čega, ocijeniti/ ocjenjivati koliko vrijedi (o osobama, predmetima, idejama itd.).

Iz navedenog je vidljivo da se ove dvije riječi razlikuju u mišljenju, sudu (za procjenu) te dodjeljivanje ocjene (za vrednovanje).

Iako je u hrvatskom prijevodu Zajedničkog europskog referentnog okvira za jezike (Vijeće Europe, 2005) riječ assessment prevedena kao vrednovanje, Jelaska i Cvikić (2008) ističu nedosljednosti u prijevodu spomenutog dokumenta te ističu potrebu za prikladnim nazivljem koje će se dosljedno koristiti.

Davies (1999) predlaže da se engleska riječ assessment (procjenjivanje) odnosi na ljude, njome se uostalom redovito bave i sami učitelji, dok bi se riječ evaluation (vrednovanje) odnosila na programe.

U ovoj disertaciji se, za englesku riječ *assessment*, koristi riječ procjena.

2.1.3 Procjena znanja

Standardi i smjernice za osiguravanje kvalitete u europskom prostoru visokog obrazovanja navode kako je procjenjivanje znanja studenata jedan od najvažnijih elemenata visokog obrazovanja. Procjenjivanje, osim potvrde znanja, također rezultira vrijednim informacijama za instituciju o učinkovitosti nastave i podrške studentima (European Association for Quality Assurance in Higher Education, 2009).

Više je godina glavni cilj visokog obrazovanja bio stvaranje studenata sa širokim znanjem unutar neke domene. S razvojem novih znanstvenih spoznaja te informacijske i komunikacijske

tehnologije došlo je i do razvoja novih metoda poučavanja poput problemskog učenja i učenja na stvarnim, svakodnevnim situacijama pri čemu se ističu vještine rješavanja problema, profesionalne vještine te se uči u kontekstu stvarnih životnih situacija. U skladu s time i procjena znanja se treba provoditi na nivou višem od čiste reprodukcije znanja (Dochy, Segers i Sluijsman, 1999). Osim toga, vještine rješavanja problema, kao i timski rad, su vještine koje su vrlo cijenjene od strane današnjih poslodavaca (Divjak i Spahić, 2008).

Još 1999. su Dochy i sur. (1999) zaključili kako doživljaj procjene studentovih postignuća kao nečega što jednostavno dolazi na kraju procesa učenja, neće moći još dugo biti održiv.

Adamson i Berry (2011) navode kako je procjena znanja oblik obrazovnog istraživanja jer se promatra kao vjerodostojna, provjerljiva informacija o ostvarenju ishoda učenja onih koji su procjenjivani. Procjena znanja može imati formativnu ulogu pružanja pomoći prilikom učenja (Boud, 2000). Utjecaj formativne procjene znanja tijekom procesa poučavanja ima pozitivne učinke i na učenika i na nastavnika (Bell i Cowie, 2001).

Očekivanja od procjene znanja, iz perspektive studenata, su, prije svega, transparentnost koja omogućuje shvaćanje dobivene ocjene te pravednost, odnosno osjećaj da ocjene prezentiraju jasnu razliku između različitih razina izvedbe. Studenti prosuđuju pravednost uspoređujući vlastiti rad s radom drugih studenata (Entwistle, 2009, str. 15).

Postoje mnoge različite metode procjene znanja i one jako variraju po pitanju potrebnih vještina i razina mišljenja te također imaju različit utjecaj na studentovo učenje. Brown ((1997) prema (Entwistle, 2009, str. 159)) navodi niz metoda, a ovdje su izdvojene dvije koje su važne za ovo istraživanje:

- Problemi – mogu ukazati na prednosti u primjeni i analizi kao i strategije rješavanja problema. Rutinska rješenja problema se mogu lako ocijeniti ili čak samo-ocijeniti, ali pružanje povratne informacije je vremenski zahtjevno. Ponavljanje sličnih problema može postati zamorno i činiti se nepovezano sa stvarnim svijetom. Autentični problemi su teži za ocjenjivanje, ali vjerojatnije potiču duboko razmišljanje.
- Vršnjačka procjena: može se upotrijebiti u humanističkim i društvenim znanostima kako bi se pomoglo studentima u razumijevanju kriterija koji se koriste u procjeni eseja te kako bi se izazvala rasprava o postupcima razmišljanja i pisanja koji su uključeni.

Pristup poučavanju koji se koristi u ovom istraživanju, a koji podupire konstruktivistički pogled na učenje je učenje kroz rad (Harasim, 2012). Socio-konstruktivizam ističe da su socijalno grupno učenje i vršnjačka suradnja korisni (Ratner, Foley i Gimpert, 2002). U okviru socio-konstruktivističkog poučavanja postoje istraživanja koja su usredotočena na fizičke aktivnosti učenika, poput eksperimenata ili rada na računalu, koji olakšavaju ili prinuđuju na intelektualnu obradu i izgradnju znanja. Iako prividno ovakva istraživanja nisu društvena, ove fizičke aktivnosti i sredstva se opisuju kao socio-kulturalni alati koji u sebi imaju ugrađenu vlastitu kulturalnu povijest (Nuthall, 2002). Računala se promatraju kao optimalan medij za primjenu konstruktivističkih principa u obrazovnoj praksi (Harasim, 2012, str. 128).

2.1.3.1 Povratna informacija procjene znanja

Carless (2003) procjenu znanja definira kao sastavni dio učenja s ciljem da osigura povratnu informaciju koja će omogućiti učeniku da prati tijek i evaluira efikasnost strategije učenja. Procjena znanja ima dvije glavne uloge: potvrdu znanja (sumativna procjena) i pružanje pomoći pri učenju (formativna procjena) i ove dvije uloge je u praksi nemoguće promatrati odvojeno (William i Black, 1996; Boud, 2000). Ključni element formativne procjene znanja je povratna informacija (Sadler, 1989).

Važnost povratne informacije ističe i Vygotsky u okviru konstruktivističke teorije učenja (Harasim, 2012, str. 68). U skladu s njegovom teorijom, novi koncepti se grade kroz interakciju s drugima i primanjem povratne informacije o hipotezama ili zadatku koji se pokušava svladati, uz vodstvo odrasle osobe (eksperta) ili u suradnji s vršnjacima.

Cramp (2011) ističe da je povratna informacija ključni dio cjelokupnog pristupa učenju. Povratna informacija naglasak treba staviti na učinak umjesto informativni kontekst (Sadler, 1989). U smislu učinka, cilj povratne informacije je premostiti jaz između trenutnog stupnja učinka i ostvarivanja željenog cilja učenja (Draper, 2009b). U ovom radu, povratna informacija se definira prema (Hattie i Timperley, 2007) kao informacija pružena od strane agenta (primjerice: učitelj, kolega, vršnjak, knjiga, roditelj, sama osoba, iskustvo) o aspektima nečije izvedbe ili razumijevanja.

2.1.4 Izvor procjene

Dochy i sur. (1999) istaknuli su da su povećani zahtjevi po pitanju cjeloživotnog učenja i provođenja refleksivnog pristupa učenju potaknuli preispitivanje veze između učenja i njegove

procjene te su u velikoj mjeri utjecali na razvoj novih oblika procjene poput samoprocjene i vršnjačke procjene.

Samoprocjena se odnosi na učešće učenika u stvaranju mišljenja o vlastitom učenju, posebno o postignućima i ishodima vlastitog učenja (Boud i Falchikov, 1989). Samoprocjena se pokazala korisnom u obrazovnoj praksi, najčešće se koristi kako bi se unaprijedilo učenje vještina i sposobnosti, odražava se na učenikov vlastiti rad, više standarde ishoda učenja, odgovornosti za vlastito učenje i povećava razumijevanje rješavanja problema (Boud i Falchikov, 1989). Ističe se pozitivna povezanost između samoprocjene i akademskog učinka, te povećanje intrinzičnog interesa za vježbu čak i kada vježba nije za ocjenu (Ibabe i Jauregizar, 2009).

Vršnjačka je procjena, prema Falchikovu (1995), proces u kojem grupa individualaca ocjenjuje svoje vršnjake. Prema Somerwellu (1993) je vršnjačka procjena dio procesa učenja tijekom kojeg se razvijaju vještine i studenti imaju mogućnost promatrati vršnjake u procesu učenja i dobiti detaljniji uvid u rad drugih. Topping (2009) vršnjačku procjenu definira kao proces u kojem osoba, koja također uči, promišlja i ističe stupanj, vrijednost ili kvalitetu rezultata rada druge osobe u procesu učenja koja je istog statusa.

Kada se govori o vršnjačkoj procjeni i povratnoj informaciji, razlikuju se procesi pružanja povratnih informacija i uloge procjenitelja te proces primanja povratnih informacija i uloge procjenitelja, s time da pružanje povratnih informacija ima veći učinak nego primanje istih (Kim, 2009). Sudjelovanje u procesu procjene važno je kako bi studenti postali svjesni vrijednosti koju ono ima jer je procjenjivane kolega studenata aspekt iz kojeg studenti najviše nauče (Mulder, Pearce i Bail, 2014).

2.2 Pristup učenju

Jedan je od najutjecajnijih koncepata koji opisuje učenje pristup učenju. Koncept se u stručnoj literaturi počinje spominjati sredinom 1970-ih godina. Istraživanja pristupa učenju istražuju se među tri različite i neovisne skupine istraživača. U Švedskoj, na Gotenburgh Sveučilištu, Roger Säljö i Ferenc Marton vode istraživačku skupinu koja istražuje pristupe učenja tijekom čitanja teKsta. Njihov pristup temelji se na promjeni fokusa sa kvantitativne mjere na kvalitativnu. Oni ne mjere količinu naučenog gradiva već kvalitetu naučenog gradiva i njegovu obrazovnu primjenu. U Australiji, na Newcastle Sveučilištu, John Biggs opisuje motive i strategije studenata, kao i tri procesa koji studenti primjenjuju tijekom učenja. Njegov pristup se temelji na obradi informacija u području kognitivne psihologije. Noel Entwistle u

Ujedinjenom Kraljevstvu, na Lancaster Sveučilištu, predvodi skupinu istraživača koji pomoću intervjua i upitnika istražuju spomenuti koncept. On se fokusira na učenje iz perspektive studenta (Trigwell i Prosser, 1991, str. 88).

Znači, koncept pristupa učenju promatra se kroz dva teorijska stajališta, a to su kognitivna psihologija i obrazovna istraživanja (Trigwell i Prosser, 1991, str. 88; Entwistle i Waterstone, 1988).

S obrazovnog stajališta, koncept su pristupa učenju prvi uveli Marton i Säljö (1984.) koji su razlikovali duboki i površinski pristup učenju koji opisuju kako namjera studenta utječe na njegovo učenje kao i na razinu razumijevanja koju postiže. Oni su studentima dodijelili zadatak da pročitaju akademski članak i najavili im raspravu o njegovu sadržaju. Neki studenti su članak uspjeli shvatiti, dok neki nisu.

Površinski pristup uključuje namjeru reprodukcije materijala za učenje, uključuje ograničeni angažman i može se pronaći u gotovo istom obliku u svim predmetnim područjima. Duboki pristup ovisi o vlastitoj namjeri razumijevanja, uključuje povezivanje ideja i upotrebu dokaza (Entwistle, 2009, str. 41). Tijekom kasnijih istraživanja o pristupu učenju (Entwistle i Ramsden, 1983) uočena je potreba za definiranjem dodatnog pristupa učenju koji je nazvan strateškim pristupom. Strateški pristup učenju odlikuje se činjenicom da student napravi zadatak najbolje moguće, ali vođeni sviješću o kriterijima procjene (Entwistle i Peterson, 2004).

Koncept pristupa učenju odnosi se na tri osnovne komponente: duboki, strateški i površinski pristup učenju. Duboki pristup učenju promatra se kroz: traženje smisla, povezivanje ideja, upotrebu dokaza, zanimanje za ideje i praćenje napretka. Strateški pristup učenju promatra se kroz organizaciju učenja, upravljanje vremenom, postignuće i oprez u odnosu na procjenu. Površinski pristup učenju promatra se u odnosu na nedostatak svrhe, nepovezano memoriranje, ograničenja programa i strah od neuspjeha (Slika 1).

Svaki od ovih pristupa učenju može se ostvariti na različitim razinama samopouzdanja i s različitim količinama uloženog napora. Neovisno o tome koji pristup student uobičajeno ostvaruje, pristup učenju može varirati, ovisno o temi (smatra li student promatranu temu važnom i zanimljivom) i kontekstu (ovisno je li podržavajuć ili izaziva tjeskobu). Važnu ulogu igra i iskustvo u poučavanju i procjeni znanja (Entwistle, 2009, str. 41).

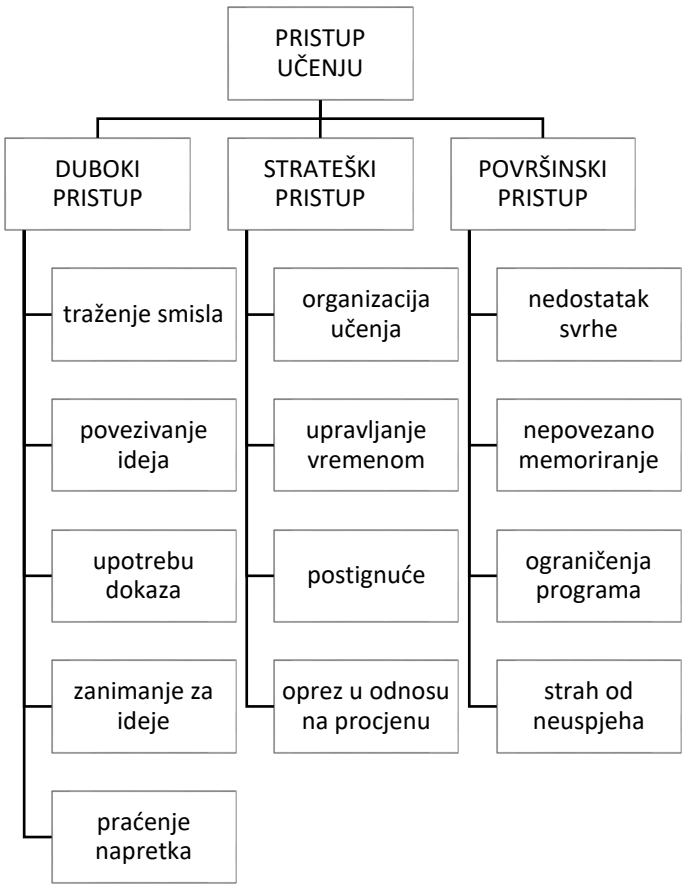

Slika 1.Teorijski model za koncept Pristupa učenju s pripadnim komponentama

Pristup učenju je pod utjecajem studentovog iskustva s procjenom znanja i kvalitetom povratne informacije. Iako poučavanje i procjena znanja utječu na cjelokupan pristup učenju, percepcija studenta, a ne namjera nastavnika, je ta koja utječe na način na koji student uči (Entwistle, 2009, str. 88).

Marton i Säljö (Marton i Säljö, 1984) u svojim istraživanjima jasno navode važnost usvajanja dubokog pristupa u razvoju akademskog razumijevanja. Duboki pristup učenju uključuje kritičku analizu novih ideja povezujući ih s već poznatim konceptima i načelima te dovodi do razumijevanja i dugotrajnog zadržavanja koncepata, tako da se oni mogu koristiti za rješavanje problema u nepoznatim situacijama (Vos, van der Meijden i Denessen, 2011).

2.2.1 Konstruktivno poravnanje

Konstruktivno poravnanje dizajn je poučavanja koji se temelji na dvama načinima razmišljanja koja imaju veliki utjecaj na poučavanje u visokom obrazovanju. Prvi je konstruktivizam, a drugi instrukcijski dizajn. Riječ „konstruktivno“ u konstruktivnom poravnanju upućuje da se pojam temelji na konstruktivističkoj teoriji poučavanja u kojoj učenik

vlastitom aktivnošću kreira znanje ili ostvaruje neki drugi ishod učenja. Riječ „poravnanje“ u konstruktivnom poravnanju temelji se na instrukcijskom dizajnu, a odražava činjenicu da aktivnost učenja u predviđenim ishodima treba biti aktivirana, kako u poučavanju, tako i u postupku procjene, kako bi se utvrdilo da je ishod učenja uistinu i ostvaren (Biggs J., 1996; Biggs i Tang, 2007, str. 52).

Ukoliko procjena znanja nije usklađena s postavljenim ishodima učenja, ili ukoliko metode poučavanja ne potiču odgovarajuće aktivnosti učenja, učenici se okreću učenju neprikladnim aktivnostima te primjenjuju površinski pristup učenju. Konstruktivno poravnanje predstavlja čvrstu vezu između konstruktivističkog razumijevanja prirode učenja i usklađenog dizajna za nastavu s ciljem trajne primjene dubokog pristupa učenju (Biggs i Tang, 2007, str. 54).

Ciljani ishodi učenja ključni su za cijeli sustav. Ciljani ishodi učenja trebaju uključivati glagole koje studenti trebaju ostvariti, a koji odgovaraju kontekstu sadržaja područja poučavanja. Nakon što se utvrde ciljani ishodi učenja, slijedi promišljanje o tome kako ih treba poučavati i procjenjivati njihovu ostvarenost. Aktivnosti učenja i poučavanja trebaju biti osmišljene tako da potiču učenike da provode radnje iskazane glagolima u ishodima učenja. U sljedećem koraku definiraju se zadaci za procjenu pomoću kojih se ispituje je li, i u kolikoj mjeri, svaki pojedini učenik ostvario postavljene ishode učenja. Naglašava se potreba za ugradnjom glagola, korištenih u postavljanju ishoda učenja, u definiranje načina procjene ishoda učenja. Na ovaj način usklađuju se postavljeni ishodi učenja, metode poučavanja i procjene, koristeći glagole sadržane u ishodima učenja kao sredstvo usklađivanja (Slika 2) (Biggs i Tang, 2007, str. 60).

Učitelji najčešće postavljene ishode učenja promatraju kao središnji dio u poravnatom sustavu poučavanja, dok studenti procjenu doživljavaju kao središnji dio kurikuluma (Slika 3) ((Ramsden, 1992, str. 187) prema (Biggs i Tang, 2007, str. 169)). Studenti uče ono za što misle da će biti procjenjivano.

Ovu pojavu opisao je Elton ((Elton, 1987, str. 92) prema (Biggs i Tang, 2007, str. 169)) i nazvao je *backwash* ističući kako procjena znanja može imati veći utjecaj na način na koji studenti uče nego sami kurikulum. *Backwash* se često doživljava u negativnom smislu, ali zapravo on može djelovati pozitivno ako se koristi za poticanje primjerenog načina učenja. Konstruktivno poravnanje predstavlja primjenu *backwasha* u pozitivnom smislu (Biggs i Tang, 2007, str. 169).

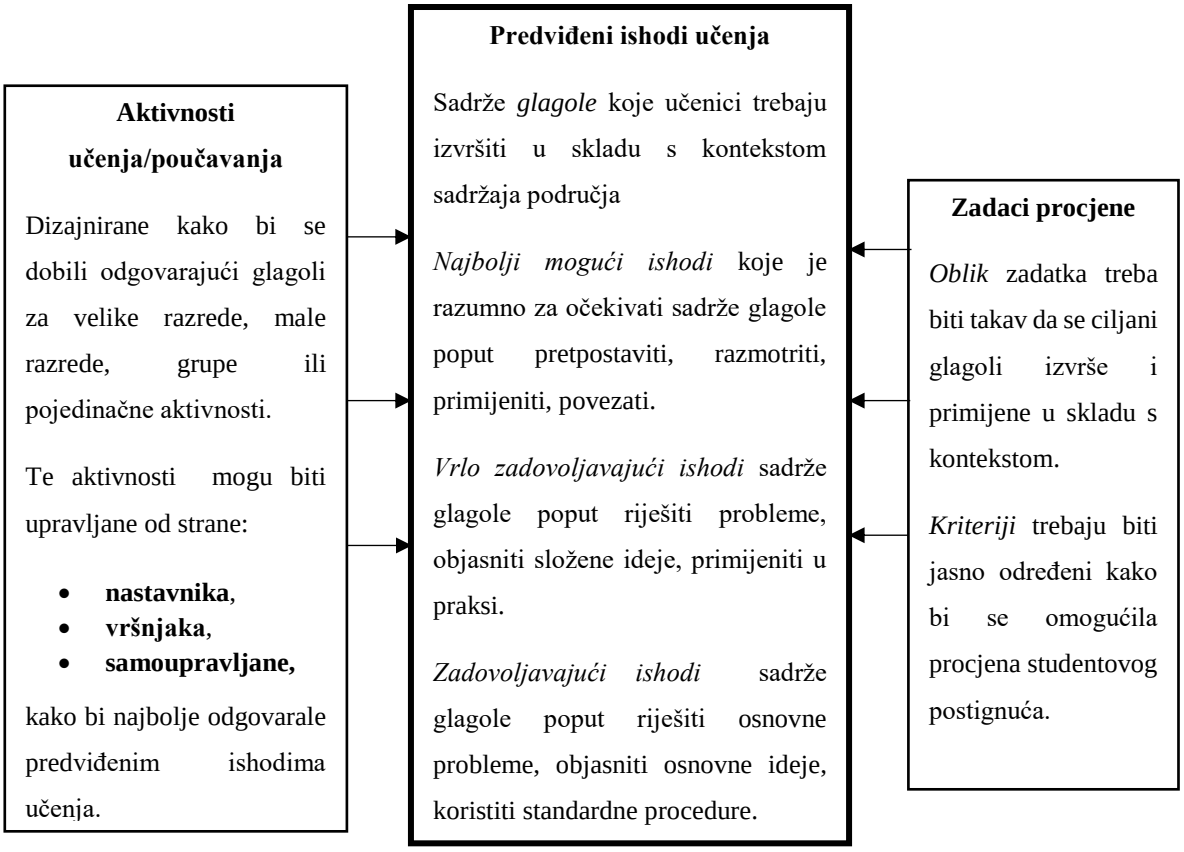

Slika 2. Usklađivanje ciljanih ishoda učenja, metoda poučavanja te procjene ostvarenosti ishoda učenja (prema (Biggs i Tang, 2007))

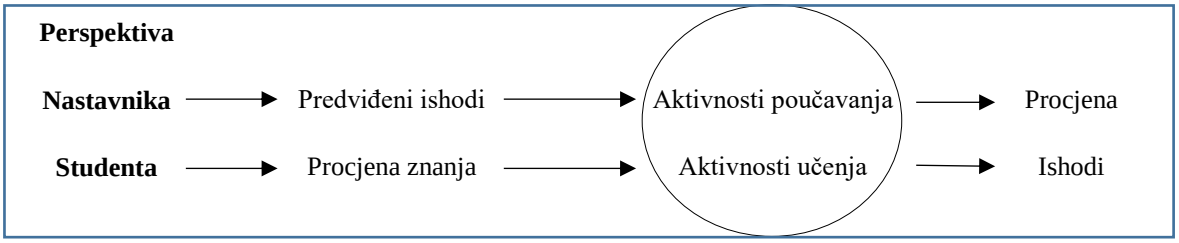

Slika 3. Percepcija procjene znanja od strane nastavnika i studenata (prema (Biggs i Tang, 2007))

2.3 Informacijsko komunikacijska tehnologija u obrazovanju

Razvoj društva temeljenog na znanju i proces globalizacije, naročito jačanje svjetskog tržišta i konkurencije na globalnoj razini, stvaraju nove potrebe na razini društvenog života i života pojedinca u svim područjima. Suvremeno društvo brzih promjena i oštre konkurencije zahtijeva nove kompetencije pojedinca. Njih nije moguće ostvariti u tradicionalnom odgojno-obrazovnom sustavu koji djeluje kao sredstvo prenošenja znanja (Ministratstvo znanosti, obrazovanja i športa, 2010). U kontekstu visokog obrazovanja informacijska pismenost smatra

se jednom od najznačajnijih kompetencija potrebnih za uspješno studiranje (Saunders, 2012). Američko knjižničarsko društvo (American Library Association, 2000) informacijsku pismenost definira kao skup sposobnosti potrebnih pojedincu kako bi mogao prepoznati potrebu za informacijom te mogućnost pronalaženja, vrjednovanja i učinkovitog korištenja informacija. Informacijska pismenost smatra se temeljem cjeloživotnog učenja i zajednička je svim područjima poučavanja, okolinama za poučavanje kao i svim stupnjevima obrazovanja. S obzirom na sve veću ulogu tehnologije u obrazovanju i svakodnevnom životu, informacijska se pismenost usko veže uz pojam informatičke pismenosti, iako u svojoj definiciji i djelovanju predstavlja različito i šire područje kompetencija. Pojedinci koji posjeduju informacijsku pismenost nužno razvijaju i informatičku pismenost (American Library Association, 2000).

U Nacionalnom okvirnom kurikulumu (Ministarstvo znanosti, obrazovanja i športa, 2010) navodi se osam temeljnih kompetencija koje je odredila Europska Unija (Education Councile, 2006) u svrhu uspješnog razvoja društva znanja i svjetskog tržišta. Obrazovna politika Republike Hrvatske prihvatila je iste temeljne kompetencije:

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

Digitalna kompetencija odnosi se na osposobljenost za sigurnu i kritičku upotrebu informacijsko-komunikacijske tehnologije za rad, u osobnom i društvenom životu te u komunikaciji. Ključni elementi osnovne informacijsko-komunikacijske vještine i sposobnosti su: upotreba računala za pronalaženje, procjenu, pohranjivanje, stvaranje, prikazivanje i razmjenu informacija te razvijanje suradničkih mreža putem Interneta (Ministarstvo znanosti, obrazovanja i športa, 2010). Važnost razvoja digitalne kompetencije u okviru digitalnog društva istaknuta je i u strateškom dokumentu Europa 2020: strategija za pametan, održiv i uključiv razvoj (Europea Commission, 2010).

Izum i široka rasprostranjenost Interneta predstavljaju glavni socio-ekonomski skok u ljudskom razvoju s velikim utjecajem na poučavanje (Harasim, 2012, str. 124). Komunikacijsko-informacijske tehnologije i potreba cjeloživotnog učenja predstavljaju nezaobilaznu realnost današnjeg doba. Naša je zadaća iskoristiti tehnologiju u svrhu unaprjeđenja kvalitete nastavnog procesa i osiguravanju ispunjavanja ishoda učenja, imajući isključivo na umu metodičko-didaktičke potrebe, a ne imperativ primjene suvremenih tehnologija (Divjak i sur., 2008, str. 80). Upotreba tehnologije čini mogućim provesti valjanu procjenu studentskih kompetencija na način koji ne bi bio moguć bez tehnologije (Jönsson i sur., 2007).

U posljednjih se 20 godina u visokom obrazovanju znatno povećao broj studenata, dok broj nastavnika ne prati jednaku putanju rasta (Prosser i Trigwell, 2014). Metodologija rada u malim skupinama neodrživa je u smislu potrebnog vremena nastavnika, a također izlaže nastavnika dodatnom stresu (de-la-Fuente-Valentin i sur., 2013) te se iz tog razloga nastava izvodi u velikim skupinama studenata. Jedan je od načina prevladavanja negativnih aspekata povećanja veličine studentskih grupa upotreba tehnologije (Hornsby i Osman, 2014).

Razvoj obrazovanja podrazumijeva prihvaćanje svake novine koja je poduzeta s namjerom unaprjeđenja samog poučavanja ili učenikovog učenja određenog sadržaja. U posljednjih su stotinu godina nastavnici do određene mjere prihvatili i upotrebljavali film, radio, televiziju, video kao dodatnu pomoć prilikom realiziranja nastave licem u lice, seminara ili individualizirane nastave. Falows i Bhanot (2002) tvrde da je sada došao red na informacijsko-komunikacijsku tehnologiju.

Jimoyiannis (2012) također navodi kako je posljednjih desetljeća jasno vidljiva simbiotska povezanost obrazovanja i informacijsko- komunikacijske tehnologije. Utjecaj IKT-a na obrazovanje značajan je, osim zbog razvoja novih metoda i pristupa poučavanju, i zbog razvijanja znanja i vještina potrebnih studentima kako bi bili uspješni u društvu 21. stoljeća. Osim spomenutih koristi, potrebna je svijest i o izazovima koje tehnologija stavlja pred obrazovanje i sudionike obrazovanja. Kombinacija IKT-a i Interneta predstavlja potencijal koji povećava mogućnosti učenja, kako za učenike, tako i za nastavnike, s ciljem razvijanja cjeloživotnih kompetencija.

U Hrvatskoj je 2014. g. usvojena Strategija obrazovanja, znanosti i tehnologije (Vlada Republike Hrvatske, 2014) koja treba osigurati fleksibilnost i prilagodljivost sustava obrazovanja i istraživanja kako bi se mogle pratiti promjene u globaliziranom svijetu temeljene

na razvoju novih tehnologija. Prema Strategiji, provest će se cjelovita informatizacija poslovnih i obrazovnih procesa unutar odgojno-obrazovnih ustanova te se predviđaju mjere za razvoj i širenje primjene e-učenja, uvođenje ekspertnih sustava za poučavanje te drugih suvremenih metoda poučavanja temeljenih na informacijskoj i komunikacijskoj tehnologiji, i to na svim razinama i u svim vrstama obrazovanja. Također, razvijat će se i organizirati otvoreni obrazovni sadržaji i pomagala sa slobodnim pristupom. Strategija se posebno dotiče obrazovanja odraslih te ističe da će se snažnijim i širim uvođenjem novih digitalnih pomagala za učenje na daljinu te otvorenim i slobodnim pristupom postojećim i novim resursima znanja i obrazovnim pomagalima proširiti, racionalizirati, učiniti kvalitetnijim i ubrzati procesi obrazovanja, osposobljavanja i usavršavanja odraslih.

Najznačajniji napredak, po pitanju integracije informacijsko-komunikacijske tehnologije u proces poučavanja, prepoznavanje je vrijednosti hibridnog učenja koja predstavlja pronalaženje najprikladnijeg načina na koji e-obrazovanje i tradicionalno poučavanje mogu raditi zajedno u svrhu potpore dubokom učenju (Entwistle, 2009, str. 138). Prednosti upotrebe tehnologije u poučavanju trebaju se dobro proučiti, ali pedagoška vrijednost bilo kojeg novog programa ili uređaja treba biti u potpunosti utemeljena i procijenjena u odnosu na ono što se zna o učenju studenata, prije nego što se primijeni. Kao i u svim ostalim pristupima poučavanju, potrebno je razjasniti kako bilo koji novi način poučavanja potiče, kako razumijevanje studenata, tako i željeni način razmišljanja (Entwistle, 2009, str. 139).

2.3.1 Tehnološko pedagoško predmetna znanja

Teorijski okvir Tehnološko pedagoško predmetnih znanja (eng. Technological Pedagogical Content Knowledge (TPACK)) zasniva se na Shulmanovom teorijskom okviru pedagoško predmetnih znanja u svrhu opisivanja načina kako nastavnici razumiju interakciju između obrazovne tehnologije i pedagoško predmetnih znanja. Koncept TPACK opisan je i razrađen u nizu publikacija, ali najznačajniji doprinos teorijskom okviru dali su Koehler i Mishra (Koehler i Mishra, 2009).

TPACK teorijski okvir temelji se na Shulmanovom opisu pedagoško sadržajnih znanja i opisuje međusobni utjecaj učiteljevog razumijevanja obrazovne tehnologije i pedagoško sadržajna znanja u svrhu efektivne primjene obrazovne tehnologije u poučavanju. U ovom modelu postoje tri osnovne komponente učiteljeva znanja : predmetni sadržaj, pedagogija i tehnologija (Slika 4Slika 4).

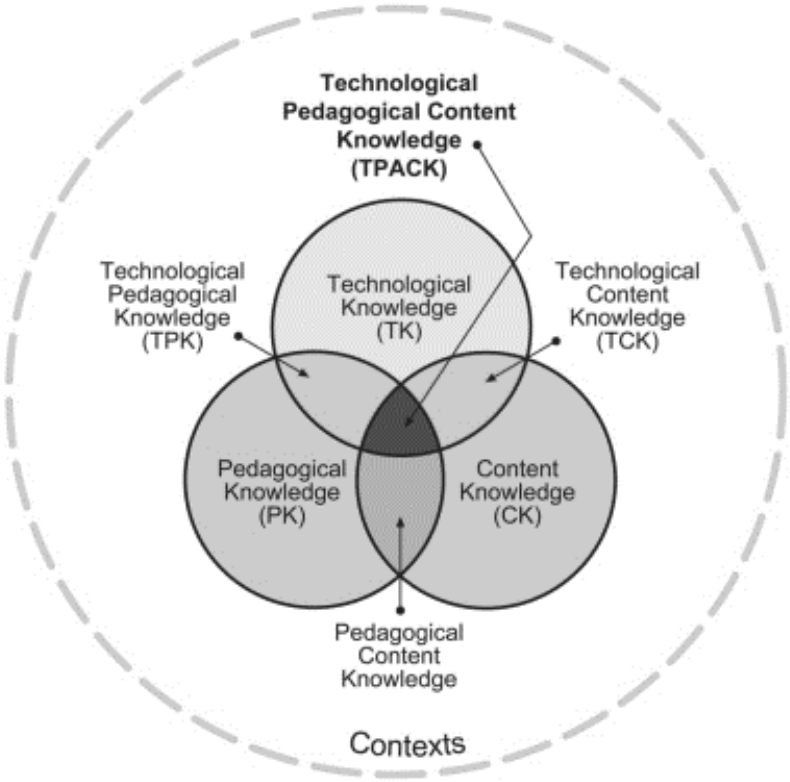

Slika 4. TPACK teorijski okvir i njegove komponente znanja (reproducira se uz dopuštenje izdavača, ©tpack.org)

Za model su jednako važni i presjeci između tih glavnih komponenti: pedagoško sadržajno znanje (*Pedagogical Content Knowledge* (PCK)), tehnološko sadržajno znanje (*Technological Content Knowledge* (TCK)), tehnološko pedagoško znanje (*Technological Pedagogical Knowledge* (TPK)) te tehnološko pedagoško sadržajno znanje (*Technological Pedagogical Content Knnowledge* (TPACK)) (Koehler i Mishra, 2009).

Predmetno sadržajno znanje (*Content Knowledge* (CK)) znanje je učitelja koje se treba naučiti ili shvatiti. Znanje sadržaja predmeta koji se poučava je od kritične važnosti za učitelja. Naravno da nije isto poučava li se neki sadržaj u nižim razredima osnovne škole ili u srednjoj školi, ali sadržaje koje predaje učitelj trebao bi znati na jednoj višoj razini. Prema Shulmanu ((Shulman, 1986) prema (Mishra i Koehler, 2006)) ovo znanje će uključivati znanje o konceptima, teorijama, uključivat će ideje, organizacijske okvire, dokaze, kao i utvrđene prakse i pristupe za razvoj takvog znanja.

Pedagoško je znanje (*Pedagogical Knowledge* (PK)) znanje učitelja o procesima, praksama ili metodama učenja i poučavanja. Ono obuhvaća, između ostalog, cjelokupnu svrhu obrazovanja, njegove vrijednosti i ciljeve. Odnosi se na razumijevanje procesa učenja, vještine upravljanja

razredom, planiranje nastavnog sata i procjenu znanja. Učitelj s visokim pedagoškim znanjima razumije kako učenik gradi znanje i stječe vještine, kako razvija radne navike i posjeduje pozitivan stav prema učenju. Kao takvo, pedagoško znanje zahtijeva razumijevanje kognitivnih, socijalnih i razvojnih teorija učenja i kako se one primjenjuju na učenike u razredu.

Pedagoško sadržajno znanje (*Pedagogical Content Knowledge* (PCK)) slično je Shulmanovoj ideji o pedagoškim znanjima primjenjivim na poučavanje određenih sadržaja. Ovdje se veliki naglasak stavlja na transformaciju nastavne teme za poučavanje koja se događa tijekom njezine interpretacije, nalaženja različitih načina njezine interpretacije i prilagođavanja instrukcijskih materijala alternativnim konceptima i prijašnjim znanjima. PCK pokriva samu srž posla poučavanja, učenja, kurikuluma, procjene znanja i izvještavanja.

Tehnološka je znanja (*Technological Knowledge* (TK)) teško definirati jer uvijek postoji mogućnost da će predložena definicija biti zastarjela. TK unutar TPACK teorijskog okvira vrlo su bliska definiciji Tečnog znanja informacijske tehnologije (*FITness*) koju je predložio Odbor za informacijsko tehnološku pismenost Nacionalnog istraživačkog vijeća Sjedinjenih Američkih Država (National Research Council, 1999). FITness zahtijeva da osoba poznaje informacijske tehnologije dovoljno široko da ih može produktivno primijeniti na poslu i u svakodnevnom životu, da može prepoznati kada tehnologija ima mogućnost unaprijediti ili ometati postizanje ciljeva i da se kontinuirano prilagođava promjenama u informacijskoj tehnologiji. Za razliku od tradicionalne definicije računalne pismenosti, FITness zahtijeva dublje razumijevanje informacijske tehnologije u svrhu obrade informacija, komunikaciju i rješavanje problema.

Tehnološko sadržajno znanje (*Technological Content Knowledge* (TCK)) predstavlja povijesnu vezu između tehnologije i predmetnog znanja. Napredak u poljima raznolikim poput medicine, povijesti, arheologije ili fizike poklopile su se s razvojem novih tehnologija što je rezultiralo predstavljanjem i obradom podataka na mnogobrojne nove načine. Razumijevanje utjecaja tehnologije na praksu i znanja danih disciplina ključan je za razvoj odgovarajućih tehnoloških alata za obrazovne svrhe. TCK je razumijevanje načina na koje tehnologija i sadržaj međusobno djeluju i ograničavaju se. Nastavnici trebaju razumjeti koje su tehnologije najprikladnije za učenja sadržaja u njihovim domenama i kako sadržaj određuje ili možda čak i mijenja tehnologiju, i obratno.

Tehnološko pedagoško znanje (*Technological Pedagogical Knowledge* (TPK) je razumijevanje kako se poučavanje i učenje mogu mijenjati kada se određene tehnologije upotrebljavaju na specifičan način. Za izgradnju TPK potrebno je dublje razumijevanje ograničenja i međusobnog utjecaja tehnologije i konteksta djelovanja. Većina tehnologije koja je danas u upotrebi nije namijenjena za obrazovne svrhe i zadatak je učitelja prilagoditi ih za obrazovne svrhe. Stoga TPK zahtijeva progresivnost, kreativnost i otvorenost prema upotrebi tehnologije, ne kako bi tehnologija bila svrha sama sebi, već kako bi unaprijedila studentovo učenje i razumijevanje.

Tehnološko pedagoško sadržajno znanje (*Technological Pedagogical Content Knowledge* (TPACK)) je združeni oblik znanja koji sadržava sve tri glavne komponente (sadržaj, pedagogiju i tehnologiju). TPACK je temelj učinkovitog poučavanja uz pomoć tehnologije, zahtijeva razumijevanje koncepata primjene tehnologije, pedagoške tehnike koje koriste tehnologiju na konstruktivne načine u svrhu poučavanja gradiva, znanje o tome što čini određene koncepte teškima ili laganima za naučiti te na koji način tehnologija može koncepte prikazati na drugačiji način kako bi se postiglo razumijevanje kod studenata. Istovremenom integracijom znanja o tehnologiji, pedagogiji i sadržaju, iskusan učitelj koristi TPACK svaki put kada poučava. Svaka situacija predstavljena učitelju jedinstvena je kombinacija tih triju faktora, i sukladno tome, ne postoji jedinstveno tehnološko rješenje koje je primjenjivo za svakog učitelja, svaki predmet i nastavni sat. Kvalitetno poučavati uz pomoć tehnologije teško je za ostvariti i zahtijeva stalno stvaranje, održavanje i ponovno uspostavljanje ravnoteže među trima osnovnim komponentama.

3 PREGLED LITERATURE

U ovom poglavlju prikazan je pregled literature u odnosu na sljedeće tri teme:

- procjena znanja,
- pristup učenju i
- informacijsko komunikacijska tehnologija u obrazovanju.

3.1 Procjena znanja

Još 1999.g. Dochy i suradnici u svom preglednom radu, koji obuhvaća 63 istraživanja, zaključili su da uključivanje studenata u postupak procjene doprinosi razvoju njihovih kompetencija (Dochy, Segers i Sluijsman, 1999) jer primjena vršnjačke procjene znanja omogućuje aktivnije sudjelovanje studenta u procesu poučavanja (Campbell i sur., 2001).

Uočena je razlika utjecaja procjene na budući učinak kada se radi o primanju i pružanju procjene, s time da primanje povratnih informacija procjene ima manji učinak nego pružanje istih (Kim, 2009). Foley (2013) je u svom istraživanju postavio sljedeće istraživačko pitanje: ima li vršnjačka procjena jednaku ili veću važnost za procjenitelja ili osobu koja je procjenjivana? Rezultati njegovog istraživanja pokazali su da su koristi za procjenitelje veće nego za osobe čiji se rad procjenjivao. Prije procesa procjene i davanja/primanja povratnih informacija neki su studenti očekivali da će najviše naučiti upravo iz pružanja povratnih informacija, broj studenata s tim mišljenjem naglo je porastao nakon što je proces procjene završio (Mulder, Pearce i Bail, 2014). Također, istaknuto je kako se procjena eksperta (nastavnika) bezrezervno uzimala točnom, dok se o procjeni vršnjaka kritički promišljalo (Foley, 2013).

U istraživanjima se kao elementi vršnjačke procjene koji najviše doprinose negativnom stavu prema vršnjačkim povratnim informacijama navode: poštenje i kvalifikacija (Hovardas, Tsivitanidou i Zacharia, 2014), varijacija u kvaliteti procjene (Mulder, Pearce i Bail, 2014), nevjerodostojnost ocjene zbog različitih odnosa među vršnjacima, moguća nedovoljna razvijenost metakognitivnih vještina za sudjelovanje u vršnjačkoj procjeni, nagrađivanje svih studenata istim ocjenama te dodatno vrijeme koje takav oblik procjene zahtijeva i od studenata i od nastavnika (Divjak i Maretić, 2017). Vjerodostojnost se vršnjačke procjene može povećati kombinacijom vršnjačke procjene i samoprocjene ili kombinacijom vršnjačke i nastavničke

procjene (Dochy i sur., 1999). S obzirom na zabrinutost studenata zbog varijacija u kvaliteti procjene od strane svojih vršnjaka predlaže se upotreba rubrika za procjenu (Mulder i sur., 2014) u kombinaciji s vršnjačkom i samoprocjenom (Panadero i Jonsson, 2013), a kriteriji bi trebali biti utvrđeni prije početka procjene (Dochy i sur., 1999). Prednost rubrika je i u tome da studenti uz pomoć njih imaju uvid i u vlastiti učinak (Sendziuk, 2010). U istraživanju De Greza, Valcke i Roozen (2012) u postupku procjene koristile su se rubrike, a usporedba vršnjačke i samoprocjene s nastavnikovim provodila se na temelju usporedbe ukupne sume ostvarenih bodova po svakom kriteriju u rubrici. Zaključak njihova istraživanja je da su studenti skloni dodijeliti veći broj bodova sebi i vršnjacima, u odnosu na procjenu nastavnika. Drugačiji pristup usklađenosti vršnjačke i nastavničke procjene predlažu Divjak i Maretić (2015) uspoređujući bodove na nivou kriterija pri čemu svaki kriterij ima određenu težinu u ukupnom broju bodova. Kriteriji se promatraju kao točke u n-dimenzionalnom prostoru, a njihova normirana udaljenost predstavlja mjeru pouzdanosti.

Mali je broj studenata koji su imali mogućnost ocijeniti svog vršnjaka ili biti ocijenjeni od strane vršnjaka (Liu i Carless, 2010). Iako se očekivanja studenata, s obzirom na proces procjene i kompetentnost vršnjaka kao procjenitelja, nakon sudjelovanja u procesu vršnjačke procjene mogu smanjiti, vršnjačka se procjena ipak doživljava kao pozitivno iskustvo (Mulder i sur., 2014). Pregled literature (Dochy i sur., 1999) utemeljen na analizi 63 istraživanja pokazao je da kombinacija samoprocjene i vršnjačke procjene kod studenata povećava odgovornost i refleksivnost.

U svrhu usporedbe povratne informacije u odnosu na nastavnikovu procjenu, rezultati istraživanja provedenog u Alabami (Lew, Alwis i Schmidt, 2010) sugeriraju da je samoprocjena loša zamjena za povratnu informaciju nastavnika. Za iste zadatke, ocjene koje si dodjeljuju studenti veće su nego ocjene koje im dodijeli nastavnik (De Grez i sur., 2012). Vršnjačka procjena pokazuje veće podudaranje s nastavnikovom. Uz pretpostavku odgovarajuće obuke za proces evaluacije, vršnjaci bi mogli pružati relevantnu povratnu informaciju koja bi doprinijela povećanju kvalitete uratka (Lew i sur., 2010).

U literaturi je istaknuta potreba za istraživanjem longitudinalnih promjena u sposobnostima samoprocjene studenta kroz kurikulum. Takva istraživanja potrebna su za razumijevanje kako se te vještine razvijaju kako bi nastavnici mogli provesti odgovarajuću intervenciju u svrhu ranog otkrivanja i potpore studentima sa slabijim sposobnostima samoprocjene (Jönsson i sur.,

2007) jer samoprocjena povećava razumijevanje prilikom rješavanja problema i ima pozitivan utjecaj na proces učenja (Lew i sur., 2010). Rezultati longitudinalnih istraživanja o točnosti samoprocjene nisu dosljedni. Usporedba studentske samoprocjene u četiri uzastopna razdoblja, u istraživanju koje je proveo Lew i sur. (2010), pokazala je da se realnost samoprocjene ne poboljšava s vremenom, dok Dochy i sur. (1999) navode kako se točnost samoprocjene povećava s vremenom, posebno ako je popraćeno nastavnikovom povratnom informacijom.

Upravo je procjena znanja najslabija točka u domeni problemskog učenja. Rubrike s opisanim stupnjevima prihvatljive i neprihvatljive izvedbe predložene su kao jedan od načina procjene kod problemskog učenja (Jonassen, 2011).

S obzirom na masovnost visokog obrazovanja, teško je održavati kvalitetu povratne informacije prema studentima, ali postoje načini za unaprjeđenje. Povratna informacija cijelom razredu o najčešćim slabostima i boljim načinima učenja može biti dopunjena vršnjačkom diskusijom o nacrtu zadatka ili strategiji rješavanja problema, dok samoprocjena pomaže studentima u praćenju vlastitog učenja (Entwistle, 2009, str. 163). Proučavajući literaturu, Hovardas i sur. (2014) zaključili su kako je način za utvrđivanjem kvalitete kvalitativne povratne informacije vrlo nejasan i ne postoji okvir na temelju kojeg bi se kvaliteta mogla utvrditi, osim nekih elemenata koje bi kvalitetna povratna informacija trebala sadržavati. Pravovremenost povratne informacije, korektivni karakter, usmjerenost prema višim ciljevima poučavanja i sadržavanje pohvalnog elementa neki su aspekti povratne informacije koje su Nicol i Macfarlane-Dick (2006) uočili pregledom relevantne literature. Kada se procjena znanja provodi u svrhu certificiranja dostignutih standarda, važno je da su upotrijebljene metode procjene pouzdane. Nepouzdanost tradicionalnih metoda poučavanja dovela je do razvoja testova temeljenih na pitanjima višestrukog izbora koji se mogu lako i točno ispravljati. Međutim, svako pretjerivanje u činjenicama i detaljima kod takvih testova rezultira primjenom površinskog učenja (Entwistle, 2009, str. 163). U slučaju kada postoji problem s procjenom znanja koja se temelji na klasičnim testovima, predlaže se primjena konstruktivnog poravnanja kako bi se procjena uskladila s ishodima učenja i potakla nastavnike da promisle o alternativnim načinima procjene znanja (Nightingale, Carew i Fung, 2007).

3.2 Pristup učenju

Tijekom dubinskih intervjua, koje je Entwistle u okviru svog istraživanja provodio sa studentima, zaključio je da je duboki pristup učenju povezan s višim razinama akademskog

uspjeha samo ukoliko proces procjene znanja ističe i nagrađuje osobno razumijevanje naučenog (Entwistle, 2000b). Iako rješavanje autentičnih problema i grupni rad potiču duboki pristup učenju i suradničko učenje, istovremeno i otežavaju proces procjene i ocjenjivanja (Entwistle, 2009, str. 159). Jedan je od načina poticanja studenata da primjene duboki pristup učenju svakako i njihovo uključivanje u proces procjene znanja (Entwistle, 2009, str. 88).

U obrazovnom okruženju temeljenom na konstruktivizmu u kojem se provodi problemsko učenje, veći broj studenata primjenjuje dublje strategije promišljanja (kompleksnije strategije) dok manji broj primjenjuje površinske strategije promišljanja (jednostavne strategije) (Galand, Bourgeois i Frenay, 2003). Iako studenti koji sudjeluju u konstruktivističkoj okolini za poučavanje mijenjaju svoju percepciju o zahtjevima procjene znanja prema zahtjevima na dubljem nivou to ne znači nužno da oni mijenjaju i svoj pristup učenju prema dubokom pristupu. U istraživanju koje su proveli Gijbels i suradnici (Gijbels, Segers i Struyf, 2008) u okviru kolegija, koji se može okarakterizirati kao konstruktivistička okolina za poučavanje, pokazalo se da iako su studenti shvatili zahtjeve postavljenog zadatka na dubljem nivou, to nije rezultiralo primjenom dubljeg pristupa učenju tijekom istog zadatka (Gijbels i sur., 2008).

Duboki pristup učenju rezultira boljim pamćenjem, transferom, integracijom i primjenom znanja te vodi prema ishodima učenja višeg nivoa (Byrne, Flood i Willis, 1999; Watkins i Hattie, 1981; Biggs J., 2001). U površinskom se pristupu učenju studenti fokusiraju na memoriranje materijala na nepovezani način čime su ograničeni na specifični zadatak. Ovaj pristup vodi nerazumijevanju važnih koncepata te rezultira ishodima učenja niske kvalitete (Booth, Luckett i Maldenovic, 1999; Watkinsi i Hattie, 1981; Biggs J. , 2001). Studenti koji primjenjuju strateški pristup učenju usmjereni su prvenstveno na postizanje najbolje moguće ocjene. Njihova motivacija je kompetitivne i stručne prirode te često od nastavnika traže savjete u vezi procjene (Duff, 2004).

Empirijska istraživanja u kontekstu visokog obrazovanja o utjecaju poučavanja usmjerenog prema studentu na duboki pristup učenju ne pokazuju konzistentnost (Baeten i sur., 2010) te se ističe potreba za većim brojem takvih istraživanja, posebice eksperimentalnih istraživanja na području procjene znanja i povratnih informacija (Panadero i Jonsson, 2013). Inovativnost u području procjene znanja, koja je vrlo česta u okolinama za učenje usmjerenim prema studentu, rezultira većim prihvaćanjem površinskog pristupa učenju (Beaten, Dochy i Struyven, 2008; Gijbels i Dochy, 2006; Struyven i sur., 2006). Nasuprot tome, studenti koji primjenjuju duboki

pristup učenju preferiraju izgradnju znanja i suradničko učenje, dok studenti koji primjenjuju površinski pristup preferiraju nastavnikovo vođenje i pasivno učenje (Baeten i sur., 2016).

Studenti u različitim disciplinama upotrebljavaju različite pristupe učenju. U području humanističkih i društvenih znanosti poput umjetnosti, psihologije, književnosti, zdravstva, politike, filozofije studenti u većem broju primjenjuju duboki pristup učenju, dok u područjima prirodnih i tehničkih znanosti poput biokemije, mikrobiologije, matematike, statistike, ekonomije, računovodstva u većem broju primjenjuju površinski stil učenja (Eley, 1992; Kember, Leung i McNaught, 2008). Ukoliko se studentima pruži više prilika za neovisno učenje pristup učenju bit će usmjereniji prema dubokom pristupu učenju (Trigwell i Prosser, 1991; Willson, Lizzio i Ramsden, 1997). Studenti koji smatraju da je procjena znanja prikladna (Lawless i Richardson, 2002) te da unaprjeđuje njihove vještine potrebne u poslu za koji se obrazuju (Gulikers i sur., 2008) u većoj mjeri primjenjuju duboki pristup učenju. Studenti starije životne dobi također češće primjenjuju duboki pristup učenju (Chamorro-Premuzic i Furnham, 2009; Christie i sur., 2006).

Nastava organizirana na temelju konstruktivnog poravnanja potiče studente na primjenu dubokog pristupa učenju (Vanfretti i Milano, 2012; Wang i sur., 2013; McCann, 2016). Osim na pristup učenju, konstruktivno poravnanje ima pozitivan utjecaj na uspjeh studenata (Larkin i Richardson, 2012; Azasu i Berggren, 2015), autonomiju (McCann, 2016), zadovoljstvo nastavom (Azasu i Berggren, 2015; McCann, 2016), kako na preddiplomskoj i diplomskoj razini (Larkin i Richardson, 2012; Cain i Babar, 2016; McCann, 2016) tako i na poslijediplomskoj razini (Azasu i Berggren, 2015).

3.2.1 Mjerni instrumenti za ispitivanje pristupa učenju i percepciju okoline za učenje i poučavanje

Razvoj mjernih instrumenata u svrhu određivanja stila i strategije učenja studenta temelje se na dvama različitim teoretskim stajalištima, a to su kognitivna psihologija i obrazovna istraživanja. Usporedba dvaju takvih instrumenata, jedan temeljen na konceptima kognitivne psihologije i jedan temeljen na obrazovnim istraživanjima, rezultirala je značajnim slaganjem između glavnih koncepata preuzetih iz spomenute dvije teorijske tradicije, a usporedba je provedena korelacijom i faktorskom analizom (Entwistle i Waterstone, 1988).

Marton i Säljö (1984) u svojim istraživanjima jasno navode važnost usvajanja dubokog pristupa učenju u razvoju akademskog razumijevanja. Mjerni instrument, kojim bi se ispitivala strategija

učenja, a koji bi identificirao učenje u odnosu na tri osnovne dimenzije: duboko, strateško i površinsko, razvijen je krajem 1970-ih godina pod imenom *Approaches to Study Inventory (ASI)* (Entwistle i Ramsden, 1983). Razvijena je i revidirana verzija upitnika pod nazivom *Revised ASI (RASI)* (Entwistle, Tait i McCune, 2000). Rekonceptualizacijom *ASI* upitnika dobiven je *Approaches and Study Skills Inventory for Students (ASSIST)* upitnik.

Upitnik ASSIST sastoji se od tri dijela:

(A) u prvom dijelu ispituje se shvaćanje pojma učenja, ali ovaj dio upitnika još uvijek nije u potpunosti razvijen,

(B) u drugom dijelu upitnika ispituju se pristupi učenju i ovaj dio upitnika sastoji se od 52 čestice te predstavlja revidiranu verziju upitnika ASI (RASI). Također je razvijena i kraća verzija upitnika RASI koja se sastoji od 18 čestica. Ovaj dio upitnika ASSIST često se koristi samostalno,

(C) u trećem dijelu upitnika pozivaju se studenti da iskažu vlastite preferencije u odnosu na različite načine poučavanja.

Najveća razlika između upitnika ASI i ASSIST je razvoj prvog i trećeg dijela upitnika. Postoji i *Shorted ASSIST* kod kojeg se dio upitnika koji se odnosi na pristupe učenju sastoji od 18 elemenata (Entwistle i Tait, 2013).

Izbor prikladnog dizajna kolegija, metoda poučavanja i način procjene znanja može pobuditi željeni pristup učenju kod studenata (Richardson, 2005). Zajedno s mjernim instrumentima za ispitivanje pristupa učenju studenata, razvijani su i mjerni instrumenti kojima se ispituje percepcija studenata o okolini akademskog poučavanja. Provedena su brojna istraživanja o međusobnom utjecaju ovih dvaju fenomena (Meyer i Muller, 1990; Richardson, 2005; Kreber, 2003). Ramsden i Entwistle razvili su *Course Perceptions Questionnaire (CPQ)* (Richardson, 1990), na temelju kojeg je Ramsden (Ramsden, 1991) razvio Course Experience Questionnaire (CEQ).

U okviru ETL projekta (*Enhancing Teaching-Learning Environments in Undergraduate Courses Project*), koji se provodio na Sveučilištu u Edinburgu, Coventyju i Durhamu u Ujedinjenom Kraljevstvu, razvijena su dva upitnika *Learning and Studying Questionnaire (LSQ)* te *Experiences of Teaching and Learning Questionnaire (ETLQ)*. *LSQ* upitnikom ispituju se razlozi za odabir studijskog programa, razlozi pohađanja konkretnog kolegija ili modula te

dio o pristupu učenju. *ETLQ* upitnik sastoji se od četiri dijela. Prvi je dio skraćeni *LSQ* upitnik kojim se ispituje pristup učenju, zatim dio o aspektima studentove percepcije okoline za učenje i poučavanja unutar konkretnog kolegija ili nastavne teme, treći dio odnosi se na percepciju studenata o zahtjevima nastavne teme te četvrti dio o percepciji studenata o znanju stečenom u okviru nastavne teme. *LSQ* i *ETLQ* upitnici ne predstavljaju razvoj niti ASSIST niti RASI upitnika.

3.2.1.1 Upitnik RASI

Upitnik RASI mjeri tri osnovne komponente: duboki, strateški i površinski pristup učenju. Duboki pristup učenju promatra se kroz sljedeće podskale upitnika: traženje smisla (seeking meaning), povezivanje ideja (relating ideas), upotrebu dokaza (use of evidence), zanimanje za ideje (interest in ideas) i praćenje napretka (monitoring effectiveness). Strateški pristup učenju promatra se kroz organizaciju učenja (organised studying), upravljanje vremenom (time management), postignuće (achieving) i oprez u odnosu na procjenu (alertness to assessment demands). Površinski pristup učenju promatra se u odnosu na nedostatak svrhe (lack of purpose), nepovezano memoriranje (unrelated memorising), ograničenja programa (syllabus-boundness) i strah od neuspjeha (fear of failure). Odgovori se nalaze na 5-razinskoj semantičkoj ordinalnoj skali na kojoj 1 označava *Uopće se ne slažem*, dok 5 označava *U potpunosti se slažem*.

3.2.1.1.1 Pouzdanost upitnika RASI

Pouzdanosti upitnika RASI najopsežnije je ispitana u istraživanju koje je proveo Long 2000. g. na 4138 studenata ((Long, 2000) prema (Entwistle i Tait, 2013)) Cronbachov koeficijent α za podskale upitnika je u intevalu od 0.61 – 0.85. Cronbachov koeficijent α osnovnih skala upitnika je 0.65 za površinski pristup učenju, 0.83 za strateški pristup učenju i 0.82 za duboki pristup učenju.

Po pitanju test-retest unutarnje konzistencije upitnika RASI, Entwistle i Tait (2013) navode da je tets-retest pouzdanost teže dobiti zbog obrazovnog okruženja u kojem postoje različiti utjecaji na studente u vidu drugih kolegija i sadržaja. Ipak istraživanje koje su proveli Ballantine i sur. (2008), na uzorku od 286 studenata, pokazalo je da je pouzdanost upitnika RASI stabilna.

3.2.1.1.2 Faktorska struktura upitnika RASI

Najopsežnije istraživanje upitnika RASI ((Long, 2000) prema (Entwistle i Tait, 2013)) pokazalo je da upitnik RASI ima strukturu od tri faktora na cijelom uzorku od 4138 studenata. U ovom istraživanju su bili uključeni studenti s osam različitih studijskih smjerova. Faktorska analiza na poduzorcima (po studijskim smjerovima) pokazala je da faktorska analiza RASI upitnika provedenog među studentima medicinskog smjera na prve tri godine studija daje 4 ili 5 faktora.

3.3 Informacijsko komunikacijska tehnologija u obrazovanju

Poučavanje uz pomoć IKT-a pojavljuje se u svim teorijskim okvirima poučavanja za 21. stoljeće. IKT se koristi kao kognitivno, metakognitivno i epistemološko sredstvo koje potiče kritičko, kreativno i inventivno mišljenje, rješavanje autentičnih problema, dakle, podrazumijeva sve ono što predstavlja sastavni dio teorijskih okvira koji se usmjeravaju na obrazovanje za 21. stoljeće (Voogt i Roblin, 2012). Upotreba IKT-a u nastavi pomaže u transformaciji okoline za poučavanje usmjerene prema nastavniku u okolinu za poučavanje usmjerenu prema studentu. Pomaže studentima u učinkovitom i djelotvornom pristupu digitalnim informacijama, podupire samousmjerenje u učenju, kao i učenje usmjereno prema studentu. Omogućuje stvaranje kreativnog okruženja za poučavanje, unaprjeđuje kvalitetu učenja i poučavanja te olakšava pristup materijalima za nastavu. Osim što promiče suradničko učenje u okolini poučavanja na daljinu, također nudi i veće mogućnosti za razvoj kritičkog mišljenja koje predstavlja vještinu višeg reda (Shan Fu, 2013).

Okolina za učenje, koja uključuje online procjenu znanja, utječe na samopouzdanje i intrinzičnu motiviranost studenata (Tseng i Tsai, 2010). Povezanost procjene i povratnih informacija te IKT-a Vonderwell, Liang i Alderman (2007) vide u online suradničkom učenju, koje studentima pruža dinamičnu i smislenu interakciju s drugim sudionicima (nastavnicima i vršnjacima).

U Sintezi izvješća o procjeni znanja i povratnoj informaciji uz podršku tehnologije (Gilbert i sur., 2011), u kojem je referencirano 142 članka na promatranu temu, istaknuto je kako upotreba tehnologije u nastavi poboljšava poučavanje omogućavajući efektivne načine poučavanja. Osim toga čini obrazovanje dostupnijim jer omogućuje 24-satni pristup sedam dana u tjednu (Shan Fu, 2013). Bez upotrebe tehnologije, ograničenja poput vremena, troškova, broja studenata, geografske i vremenske raspodjele učinili bi takve efektivne oblike poučavanja

nepraktičnima za izvođenje (Gilbert i sur., 2011). Kada je riječ o informacijsko-komunikacijskog tehnologiji, mogući problem može biti nerazumijevanje zbog tehničkog žargona, nečitke ili nečujne informacije (ovisno o mediju) (Handley, Price i Millar, 2008).

Graesser, Chipmann i King (2008) navode neke od klasa tehnologija koje se koriste u poučavanju kao što su Computer-Based Trainig (CBT), multimedija, hipertekst i hipermedija, interaktivne simulacije, animirani pedagoški agenti, inteligentni tutorski sustavi, računalom podržano suradničko učenje, upiti temeljeni na pretraživanju informacija, virtualne okoline s agentima i igre. Različiti softverski alati nude brojne načine na koje se može pristupiti pojedinim aspektima promatrane teme.

World Wide Web (WWW), kao najpopularniji internetski servis, ima vrlo važnu ulogu kada se govori o IKT-u u obrazovanju. Razvojem Web 2.0 i njegovih alata, uloga se korisnika mijenja iz pasivnog konzumenta sadržaja u aktivnog sudionika koji stvara i kreira sadržaj. Sudionici i korisnici Weba najvažniji su resurs koje ovaj servis ima, najbolji primjer su Web 2.0 alati Wikipedia i Youtube koji, bez dodavanja i stvaranja sadržaja od strane njihovih korisnika, ne bi ispunjavali svoju svrhu (Karasavvidis i Theodosiou, 2012).

Važno je spomenuti i sustave za upravljanje učenjem (LMS) kao široko rasprostranjen i upotrebljavan sustav (Johnson-Wilder i Primm, 2004). Manjak interakcije sa studentima navodi se kao glavni uzrok slabe iskorištenosti potencijala tehnologije, tehnologiju treba prilagoditi individualiziranim potrebama pojedinca i u tu svrhu predlažu se sustavi za upravljanje učenjem poput WebCT-a, Moodla i ostalih ((Iahad i Dafoulas, 2004) prema (Hutinski i Aurer, 2009)).

Pitanja su s višestrukim izborom jedan od najčešćih načina provjere znanja uz upotrebu tehnologije (Draper, 2009a), međutim takav način procjene povezuje se s nižim razinama prema Bloomovoj taksonomiji jer ne omogućuje studentima demonstraciju vještina kroz objašnjavanje, analizu, sintezu ili stvaranje novih koncepata (Draper, 2009b). Otvorena pitanja zahtijevaju od studenata da se prisjete, organiziraju i integriraju ideje i predstavljaju najprikladniji oblik za procjenu obrazovnih vještina i kompetencija. Provjera znanja koja zadovoljava ovim zahtjevima, u okviru procjene znanja uz pomoć tehnologije, bila bi pitanja sa slobodnim unosom teksta (Rodrigues i Oliveira, 2014). Primjena IKT-a u poučavanju u kombinaciji s raznovrsnim pristupima i metodama poučavanja, posebno onima temeljenim na konstruktivizmu, omogućuju uspješnije postizanje ishoda učenja. Ističe se potreba za daljnjim istraživanjima u kojima se ispituju koristi i izazovi u poučavanju uz pomoć IKT-a u kombinaciji

s drugim pristupima poučavanju usmjerenim prema studentu, poput suradničkog učenja (Whealan, 2008).

Pérez-Sanagustín i suradnici (2017) su na temelju pregleda članka objavljenih u časopisu Computers & Education na temu IKT-a u obrazovanju, u razdoblju 2011.-2015. iznijeli zapažanja i predložili smjernice za daljnja istraživanja u području integracije IKT-a u nastavi. Većina je objavljenih istraživanja provedena u Sjevernoj Americi, zapadnoj Europi i Aziji, dok su Južna Amerika, Afrika, Oceanija i Istočna Europa slabije zastupljeni te ističu važnost veće regionalne raznolikosti u istraživanjima. Naglašena je potreba za većim brojem istraživanja u području društvenih znanosti, prirodnih znanosti i formalnih znanosti poput matematike jer se premalo istražuje u kontekstu specifičnih područja, posebno onih obuhvaćenih PISA programom, dok se više ispituju transverzalna područja. Mnoga istraživanja bave se kompetencijama i vještinama istaknutima kao važnima za obrazovanje u 21. stoljeću, ali oni također ističu da treba više istraživanja o načinima kako procijeniti vještine za koje mislimo da su važne za obrazovanje. Istraživanja u predškolskom odgoju i obrazovanju slabo su zastupljena. Većina radova orijentirana je na studentsku perspektivu dok je perspektiva nastavnika zapostavljena. Većina kvantitativnih istraživanja temelji se na eksperimentu i kvazi eksperimentu s brojem sudionika manjim od 100. Većina istraživanja provode se u području obrazovanja dok je privatan sektor zanemaren.

IKT pruža mogućnost prilagođavanja osobnom stilu učenja, suradničko učenje i stjecanje vještina timskog rada, a u smislu poučavanja podrazumijeva interakciju između onog što nastavnik zna i načina na koji primjenjuje vlastita znanja u razredu. Poučavanje uz pomoć tehnologije podrazumijeva tri osnovne komponente: predmetni sadržaj, pedagogiju i tehnologiju te sve njihove međusobne veze i utjecaje, što je objedinjeno u teorijskom okviru pod nazivom Tehnološko Pedagoško Predmetno znanje (TPACK) (Koehler i Mishra, 2009). Najveću primjenu TPACK teorijski okvir ima u području obrazovanja i usavršavanja učitelja. Najveće je ograničenje teorijskog okvira neutralnost u odnosu na šire ciljeve obrazovanja, npr. ne navodi se koje sadržaje treba obraditi niti na koji način ih učitelj treba poučavati (Koehler i sur., 2014, str. 109).

U istraživanju Messine i Tabonea (Messina i Tabone, 2013) ispitanici, studenti učiteljskih studija, pokazali su visoku razinu znanja iz pojedinačnih područja znanja: tehnološko znanje (TK), pedagoško znanje (PK), predmetno znanje (CK) kao i pedagoško sadržajno znanje

(PCK), dakle razina tehnoloških znanja je visoka kada se znanje o tehnologiji ne veže uz sadržaj područja poučavanja. Razina tehnološkog znanja niža je kada je riječ o tehnološko pedagoškim znanjima (TPK), tehnološko predmetnim znanjima (TCK) kao i tehnološko pedagoško predmetnim znanjima (TPACK).

Iako nastavnici informatike imaju dobro pedagoško znanje i dobro predmetno znanje, ističu da se ne osjećaju dovoljno sposobnima transformirati i učinkovito primijeniti svoja znanja tijekom poučavanja (Giannakos i sur., 2015). Osim tehnoloških pitanja, implementacija inovativnih metoda poučavanja uz npr. upotrebu virtualnih svjetova, dovodi do dodatnih pitanja u području pedagogije kao i primjeni dizajna efektivnog poučavanja. Ističe se nepobitna povezanost pedagogije i tehnologije prilikom integracije IKT-a u nastavu (Potkonjak i sur., 2016). Kontekst je važan aspekt obrazovnih istraživanja, kao i TPACK teorijskog okvira, ali je često izostavljen u istraživanjima TPACK-a ili njegovo značenje nije jasno naznačeno (Rosenberg i Koehler, 2015).

Pregledom literature uočilo se da postoje različiti načini na koje se može mjeriti tehnološko pedagoško predmetno znanje: skala samoprocjene, upitnik s otvorenim pitanjima, procjena izvedbe, intervju i promatranje (Koehler, Shin i Mishra, 2012). Najčešći su način skale samoprocjene. Neki istraživači uspjeli su u svojim istraživanjima na temelju različitih mjernih instrumenata potvrditi faktorsku strukturu TPACK teorijskog okvira od sedam faktora (Schmidt i sur., 2009; Pamuk i sur., 2013), dok su drugi utvrdili drugačiji broj faktora: tri (Archambault i Barnett, 2010), četiri (Chai, Koh i Tsai, 2010), pet (Koh, Chai i Tsai, 2010; Lee i Tsai, 2010; Chai i sur., 2011; Baser, Kopcha i Ozden, 2015), šest (Valtonen i sur,2015) i osam (Shinas i sur., 2013).

3.3.1 Mjerni instrumenti za ispitivanje Tehnološko pedagoško predmetnog znanja (TPACK) kod budućih učitelja

Istraživači su prilazili problemu preciznog mjerenja TPACK-a budućih učitelja na razne načine koji pokazuju da postoje poteškoće u razumijevanju kako znanje učitelja utječe na njegovo poučavanje, kao i na sveobuhvatne izazove efikasnosti, pouzdanosti i valjanosti provedene metode mjerenja (Abbitt, 2011). Mishra i Koehler ((2005) prema (Abbitt, 2011)) dizajnirali su anketu u svrhu mjerenja percepcije sudionika o vremenu i uloženom trudu, percepciju iskustva učenja i razmišljanja sudionika o online učenju u kontekstu kolegija fokusiranog na razvoj online kolegija. Iako su odgovori analizirani na razini čestice umjesto u

obliku podskala, slične čestice grupirane su u šest grupa: (a) vrijeme i trud, (b) učenje i užitak, (c) grupno funkcioniranje, (d) percepcija online poučavanja, (e) mišljenje ispitanika o TPACK-u, (f) mišljenje ispitanikovih suradnika o TPACK-u. Jedinstvena je karakteristika ove ankete fokusiranje na kognitivne procese.

U istraživanju suradničkih grupa uključenih u zadatak razvoja online tečaja Koehler, Mishra i Yahya (2007) fokusirali su se na analizu procesa kolegija. Podatke su prikupljali iz grupnih rasprava, razmjene elektroničke pošte između članova skupine, ankete provedene tijekom semestra i ostalih artefakata grupa. Za prikupljene podatke razvili su protokol kodiranja koji uključuje domene znanja TPACK teorijskog okvira kao i kodove za grupnu dinamiku i socijalnu interakciju nevezanu uz samo istraživanje. Rezultati su pokazali promjene u prisutnosti tri osnovne komponente TPACK teorijskog okvira tijekom semestra. Iako je specifični kontekst u kojem je metoda primijenjena rezultirao mnoštvom informacija, javlja se problem usporedbe podataka ukoliko takvo istraživanje bude ponovljeno u nekom drugom kontekstu ((Koehler i sur., 2007) prema (Abbitt, 2011)).

Jedan su od načina procjene TPACK-a i mjere bazirane na izvedbi, odnosno ispitujući dizajn i planiranje procesa moguće je procijeniti znanje o TPACK domenama budućih učitelja. Graham, Burgoyne i Borup (2010) tražili su studente da opišu dvije instrukcijske strategije koje bi koristili za poučavanje sadržaja na temelju unaprijed dobivenog scenarija. Jedna strategija trebala je sadržavati upotrebu tehnologije, dok je druga trebala biti bez tehnologije. Za podatke dobivene na temelju opisa instrukcijskih strategija 133 studenta tijekom cijelog semestra, razvili su kodnu shemu za podatke koji uključuju tehnološka znanja, tehnološko pedagoška znanja i tehnološko pedagoško sadržajna znanja. Rezultati su pokazali da se slučajevi instrukcijskog dizajna bazirani na tehnološkim znanjima vremenom smanjuju, dok se slučajevi bazirani na tehnološko pedagoškim znanjima povećavaju. Također, u kasnijim odgovorima primijećeni su mnogo složeniji razlozi za primjenu tehnologije u nastavi ((Graham i sur., 2010) prema (Abbitt, 2011)).

Ispitivanje studentskog rada u svrhu dokazivanja TPACK-a koristi se i u istraživanju Harrisa, Grandgenetta i Hofera (2010). Oni su razvili rubriku za procjenu TPACK-a na temelju izrade nastavne lekcije od strane studenta. Opisana rubrika bila je sažeta i fokusirana na Tehnološko pedagoška znanja, Tehnološko sadržajna znanja i tehnološko pedagoško sadržajna znanja TPACK teorijskog okvira. Rubrika se više fokusira na dijelove TPACK teorijskog okvira za

koje je vjerojatnije da su obuhvaćeni programom pripreme budućih učitelja, poput pedagoške primjene tehnologije u odnosu na razvoj tehnoloških znanja zasebno ((Harris i sur., 2010) prema (Abbitt, 2011)).

3.3.1.1 SPTKTT upitnik

Upitnik SPTKTT korišten u ovom istraživanju kreiran je za buduće učitelje i nastavnike nižih razreda osnovne škole te odgojitelje predškolske djece s ciljem ispitivanja razvoja TPACK-a budućih učitelja. Upitnik se sastoji od 47 čestica s odgovorima koji se nalaze na 5-razinskoj semantičkoj ordinalnoj skali na kojoj 1 označava *Uopće se ne slažem*, dok 5 označava *U potpunosti se slažem*, a čestice su raspoređene po komponentama teorijskog okvira na sljedeći način (Slika 5):

- tehnološka znanja – 7 čestica,
- sadržajna znanja: matematika (3 čestice), društvene znanosti (3 čestice), znanost (3 čestice), pismenost (3 čestice),
- pedagoška znanja – 7 čestica,
- pedagoško sadržajna znanja – 4 čestice,
- tehnološko sadržajna znanja – 4 čestice,
- tehnološko pedagoška znanja – 5 čestica,
- tehnološko pedagoško sadržajna znanja – 8 čestica.

3.3.1.1.1 Pouzdanost upitnika SPTKTT

Cronbachovim koeficijentom α ispitana je pouzdanost čestica i podskala upitnika (Schmidt i sur., 2009) . Sve skale upitnika, osim pismenosti, imale su Cronbachov koeficijent α veći ili jednak 0.8 što ukazuje na viskou pouzdanost. Pouzdanost podskale Pismenost procijenjena je na 0.76.

3.3.1.1.2 Faktorska struktura upitnika SPTKTT

Odgovara li struktura upitnika teorijskom okviru provjereno je eksploratornom faktorskom analizom nad svakom podskalom upitnika. Potvrđena je faktorska struktura upitnika, a faktorska opterećenja za sve čestice upitnika kreću se od 0.59 do 0.92.

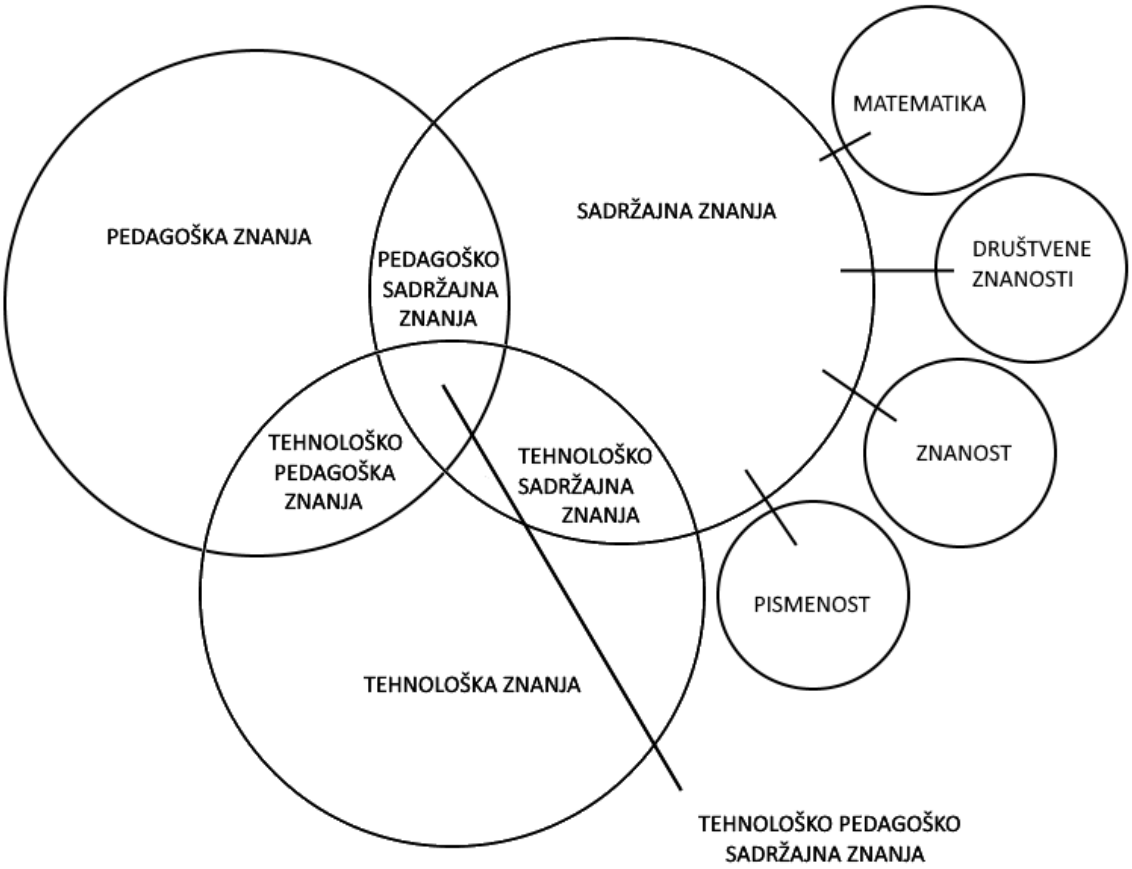

Slika 5. Raspored čestica SPTKTT upitnika po komponentama TPACK teorijskog okvira

Kao i svaka mjera samoprocjene, mogućnost instrumenta da precizno predstavi znanje domena TPACK-a ograničeno je mogućnostima ispitanika da procjeni vlastita znanja i prikladno odgovori na čestice upitnika (Abbitt, 2011). Najveća kritika, ne samog instrumenta, već procesa njegove validacije provedene od strane autora upitnika, je što je eksploratorna faktorska analiza napravljena za svaku od sedam domena zasebno (Chai i sur., 2011).

4 METODOLOGIJA

Istraživanje je podijeljeno na teorijski i empirijski dio. U teorijskom dijelu istraživanja dan je pregled istraživanja na temu procjene znanja i primjene tehnologije u nastavi. Empirijski dio istraživanja sastoji se od sljedećih dijelova:

- proširenje upitnika RASI o pristupu učenju u kontekstu rješavanja problemskih i složenih zadataka, nakon čega je provedena validacija istog,
- validacija upitnika SPTKTT o primjeni tehnologije u nastavi u kontekstu hrvatskog obrazovnog sustava,
- istraživanje o percepciji vlastitih znanja o primjeni IKT-a u nastavi među hrvatskim učiteljima i nastavnicima,
- eksperiment putem kojeg je ispitan utjecaj predloženog dizajna okoline za poučavanje na znanja o primjeni tehnologije u nastavi i pristup učenju.

4.1 Ispitanici i uzorci

S obzirom da empirijski dio istraživanja ima nekoliko dijelova, skup ispitanika koji su sudjelovali u ovom istraživanju sastoji se od: (a) učitelja i nastavnika u praksi u Republici Hrvatskoj i (b) studenata u Republici Hrvatskoj. Uzorci za istraživanje prikupljeni su iz nekoliko različitih izvora, ovisno o dijelu istraživanja za koji su bili potrebni.

4.1.1 Uzorak 1

Uzorak 1 prikupljen je iz populacije učitelja i nastavnika koji su zaposleni u osnovnim školama u Republici Hrvatskoj i predstavlja uzorak dobrovoljaca. Ovaj uzorak prikupljen je iz dva izvora. Prvi izvor je bio međužupanijski stručni skup za učitelje održan 1. travnja 2015. g. na Fakultetu za odgojne i obrazovne znanosti u Osijeku. Iz ovog izvora prikupljeno je 56 ispitanika. Za drugi dio uzorka odabrana je po jedna škola iz svake županije u koju su poslani upitnici koje su nastavnici i učitelji dobrovoljno ispunili. Škole su odabrane uz pomoć portala za škole www.skole.hr[1] bez nekog posebnog kriterija ili načina odabira. Odgovori iz pet

[1] http://www.skole.hr/skole/popis

županija nisu stigli. Na ovaj način prikupljeno je 210 ispitanika. Tablica 3 prikazuje broj ispitanika po svakoj pojedinoj županiji.

Tablica 3. Broj ispitanika iz Uzorka 1 po županijama

Županija	**Broj ispitanika**
Sisačko-moslavačka županija	12
Varaždinska županija	8
Šibensko-kninska županija	12
Brodsko-posavska županija	18
Požeško-slavonska županija	16
Zagrebačka županija	19
Dubrovačko-neretvanska županija	8
Karlovačka županija	12
Splitsko-dalmatinska županija	10
Grad Zagreb	18
Vukovarsko-srijemska županija	13
Koprivničko-križevačka županija	19
Primorsko-goranska županija	12
Osječko-baranjska županija	18
Bjelovarsko-bilogorska županija	14
Virovitičko-podravska županija	7
Ličko-senjska županija	Nisu stigli popunjeni upitnici
Istarska županija	Nisu stigli popunjeni upitnici
Krapinsko-zagorska županija	Nisu stigli popunjeni upitnici
Međimurska županija	Nisu stigli popunjeni upitnici
Zadarska županija	Nisu stigli popunjeni upitnici
UKUPNO	**266**

Ukupno, Uzorak 1 je sastavljen od 266 ispitanika.

4.1.2 Uzorak 2

Uzorak 2 prikupljen je iz populacije studenata učiteljskih, odgojiteljskih i nastavničkih studija koji su ak. god. 2015./16. slušali navedene kolegije na sljedećim ustanovama:

- Programiranje na Učiteljskom fakultetu u Zagrebu, Odsjek u Čakovcu,
- Uvod u baze podataka na Učiteljskom fakultetu u Zagrebu, Odsjek u Čakovcu,
- Uvod u baze podataka na Učiteljskom fakultetu u Zagrebu,
- Engleski jezik I na Filozofskom fakultetu u Osijeku,
- Logo na Fakultetu za odgojne i obrazovne znanosti u Osijeku,
- Statistika na Fakultetu za odgojne i obrazovne znanosti u Osijeku,

- Metodika matematike I na Fakultetu za odgojne i obrazovne znanosti u Osijeku,
- Prirodno geografska obilježja Hrvatske na Fakultetu za odgojne i obrazovne znanosti u Osijeku,
- Metodologija pedagoškog istraživanja na Fakultetu za odgojne i obrazovne znanosti u Osijeku,
- Metodika matematike I na Fakultetu za odgojne i obrazovne znanosti u Osijeku, te dislociranom studiju u Slavonskom Brodu.

Uzorak 2 činilo je ukupno 495 studenata (Tablica 4).

Tablica 4. Raspodjela ispitanika iz Uzorka 2 po kolegijima na kojima je istraživaje provedeno

Kolegij	**Ukupan broj studenata na kolegiju**
Programiranje na Učiteljskom fakultetu u Zagrebu, Odsjek u Čakovcu	21
Uvod u baze podataka na Učiteljskom fakultetu u Zagrebu, Odsjek u Čakovcu	20
Uvod u baze podataka na Učiteljskom fakultetu u Zagrebu	20
Engleski jezik I na Filozofskom fakultetu u Osijeku	68
Logo na Fakultetu za odgojne i obrazovne znanosti u Osijeku	74
Statistika na Fakultetu za odgojne i obrazovne znanosti u Osijeku	76
Metodika matematike I na Fakultetu za odgojne i obrazovne znanosti u Osijeku	81
Prirodno geografska obilježja Hrvatske na Fakultetu za odgojne i obrazovne znanosti u Osijeku	78
Metodologija pedagoškog istraživanja na Fakultetu za odgojne i obrazovne znanosti u Osijeku	28
Metodika matematike I na Fakultetu za odgojne i obrazovne znanosti u Osijeku, dislocirani studij u Slavonskom Brodu	29

4.1.3 Uzorak 3

Uzorak 3 prikupljen je iz populacije studenata i čine ga studenti koji su ak. god. 2015/16 slušali kolegije:

- Diskretna matematika,
- Projektni ciklusi i
- Matematika I

na Fakultetu organizacije i informatike u Varaždinu. Ovaj uzorak broji 298 ispitanika.

4.1.4 Uzorak 4

Uzorak 4 prikupljen je iz populacije studenata i čine ga studenti koji su ak. god. 2014./15. pohađali kolegij Oblikovanje teksta i slike na prvoj godini sveučilišnog preddiplomskog studija Informacijski/Poslovni sustavi Fakulteta organizacije i informatike u Varaždinu. Kolegij Oblikovanje teksta i slike slušalo je ukupno 223 studenta što ujedno čini i broj ispitanika u Uzorku 4.

4.1.5 Uzorak 5

Uzorak 5 prikupljen je iz populacije studenata učiteljskog studija i čine ga studenti koji su ak. god. 2014./15. pohađali drugu i četvrtu godinu integriranog preddiplomskog i diplomskog Učiteljskog studija na Fakultetu za odgojne i obrazovne znanosti u Osijeku. Drugu studijsku godinu pohađalo je 109 studenata, a četvrtu godinu 91 student. Ukupan broj ispitanika u uzorku 5 bio je 200 studenata.

4.2 Instrumenti

Instrumenti korišteni u istraživanju su prošireni upitnik RASI (Revised Approach to Studing Inventory) i upitnik SPTKTT (Survey of Preservice Teachers' Knowledge of Teaching and Technology).

4.2.1 Prošireni upitnik RASI

Prošireni upitnik RASI predstavlja originalni upitnik RASI (opisan u poglavlju 3.2.1.1) proširen u kontekstu problemskih i složenih zadataka. Osnovni upitnik RASI sastoji se od 52 čestice grupirane u podskale po četiri čestice koje opisuju tri glavna konstrukta: duboki, strateški i površinski pristup učenju (Slika 6). Postojeći model proširen je s dodatne tri komponente koje se odnose na složene i problemske zadatke, i to za svaki od tri pristupa učenju zasebno (Slika 6): Problemski_duboki, Problemski_strateški i Problemski-površinski. Dodano je 14 novih čestica koje su također grupirane u podskale, po jedna podskala za duboki pristup učenju, jedna za strateški i jedna za površinski. U konačnici, prošireni upitnik RASI sastoji se od 66 čestica.

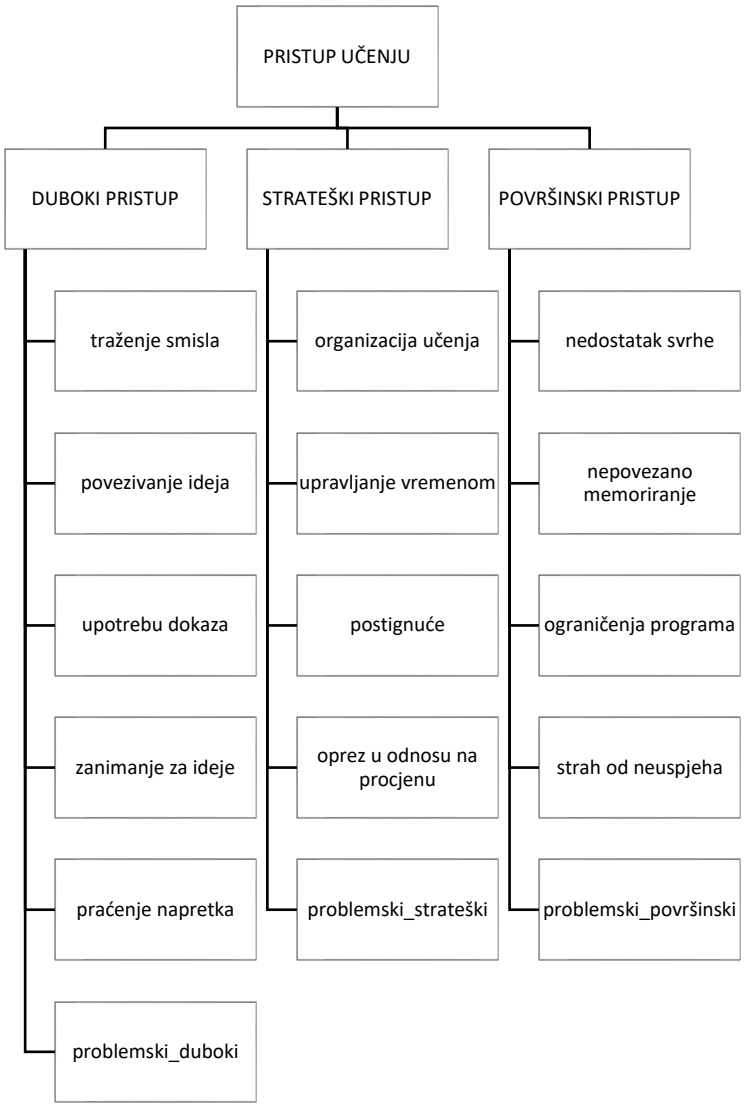

Slika 6. Prošireni teorijski model za koncept Pristupa učenju s pripadnim komponentama u kontekstu složenih i problemskih zadataka

4.2.2 Upitnik SPTKTT

Originalni upitni SPTKTT, koji se sastoji od 47 čestica, razvijen je s ciljem ispitivanja percepcije budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi za obrazovni sustav Sjedinjenih Američkih Država. Obrazovni sustav u Republici Hrvatskoj je osmišljen na drugačiji način. U Sjedinjenim Američkim Državama se u prvim razredima osnovne škole uče sljedeća područja: Matematika, Pismenost, Znanost i Društvene znanosti. U Republici Hrvatskoj se uči Hrvatski jezik, Matematika te Priroda i društvo. Hrvatski jezik odgovarao bi Pismenosti, dok se Znanost i Društvene znanosti, u hrvatskom obrazovnom sustavu, proučavaju

u sklopu predmeta Priroda i društvo. Iz tog razloga se, u kontekstu hrvatskog obrazovnog sustava, predlaže model za raspored čestica SPTKTT upitnika u kojem su Sadržajna znanja iz predmeta Znanost i Društvene znanosti objedinjena u jednu komponentu (Slika 7).

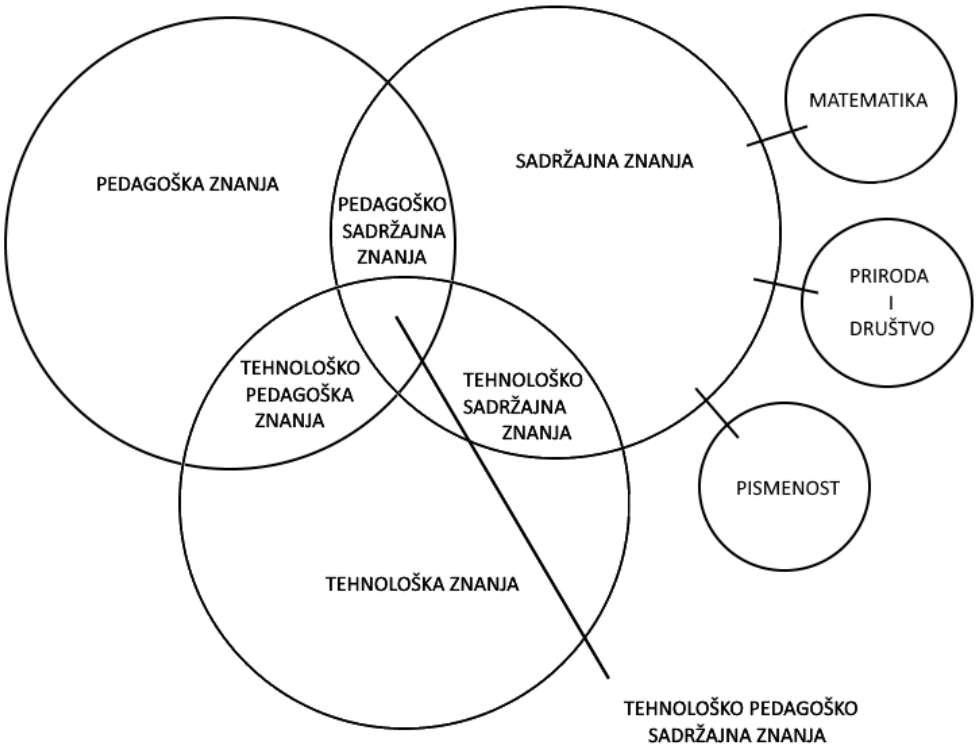

Slika 7. Raspored čestica SPTKTT upitnika po komponentama TPACK teroijskog okvira u k ontekstu hrvatskog obrazovnog sustava

Upitnik SPTKTT korišten u ovom istraživanju sadržajno nije drugačaji od upitnika kojeg su kreirali Schmidt i sur. (2009), samo je predložen drugačiji teoretski model za upitnik.

4.3 Postupci

Za razumijevanje i rješavanje definiranih ciljeva istraživanja i postavljenih hipoteza, koristit će se kvantitativna i kvalitativna metodologija istraživanja. U ovom poglavlju predstavljeni su postupci te instrumenti korišteni u provedenom istraživanju.

4.3.1 Anketa

Anketa je oblik kvantitativnog istraživanja u kojem istraživač definira uzorak i populaciju, prikuplja podatke putem upitnika ili intervjua te donosi zaključke o populaciji. Koristan je u situacijama kada je potrebno brzo prikupiti podatke ili prikupiti podatke sa šireg zemljopisnog područja (Cresswel, 2012, str. 405).

U provedenom istraživanju metoda ankete je korištena:

- Za prikupljanje podataka o percepciji vlastitih znanja o primjeni IKT-a u nastavi među populacijom hrvatskih učiteljima i nastavnika u praksi obuhvaćenih Uzorkom 1. Podaci su prikupljeni uz pomoć upitnika SPTKTT o samoprocjeni vlastitih znanja o primjeni tehnologije u nastavi.

- Za prikupljanje podataka o percepciji vlastitih znanja o primjeni IKT-a u nastavi među populacijom studenta učiteljskih, nastavničkih i odgojiteljskih studija obuhvaćenih Uzorkom 2. Podaci su prikupljeni uz pomoć upitnika SPTKTT o samoprocjeni vlastitih znanja o primjeni tehnologije u nastavi.

- Za prikupljanje podataka o pristupu učenju koji studenti uobičajeno primjenjuju među populacijom studenata obuhvaćenih Uzorkom 2, Uzorkom 3 i Uzorkom 4. Podaci su prikupljeni uz pomoć upitnika RASI koji je za potrebe ovog istraživanja proširen u kontekstu problemskih i složenih zadataka (prošireni upitnik RASI).

- Prikupljanje mišljenja studenata o provedenom istraživanju u obliku jednog otvorenog pitanja među populacijom studenata učiteljskih, nastavničkih i odgojiteljskih studija obuhvaćenih Uzorkom 2.

Tijekom prikupljanja podataka putem ankete, treba voditi računa o povjerljivosti podataka ispitanika i njihovih odgovora. Povezanost između odgovora i samih ispitanika treba biti svedena na minimum (Cresswel, 2012, str. 405). Ispitanici su prije popunjavanja upitnika obaviješteni da popunjavanjem istog daju suglasnost za sudjelovanje u istraživanju, kao i korištenje kumulativnih podataka istraživanja u svrhu objavljivanja znanstvenih radova (PRILOG I).

4.3.1.1 Metoda dvostrukog prijevoda

Originalni upitnici RASI i SPTKTT prevedeni su na hrvatski jezik postupkom dvostrukog prijevoda kroz sljedeće korake: (1) prijevod upitnika s engleskog na hrvatski jezik, (2) prvi prijevodi upitnika pregledani su od strane dva sveučilišna profesora, (3) ponovni prijevod upitnika s hrvatskog na engleski jezik, od strane diplomiranog nastavnika engleskoj jezika zaposlenog na fakultetu, (4) usporedba engleskih verzija (originala i prijevoda) i usuglašavanje konačnih prijevoda od strane obaju prevoditelja, (5) prevedene upitnike lektorirala je diplomirana profesorica hrvatskog jezika i književnosti.

4.3.2 Proširenje RASI upitnika

Nakon prijevoda originalni upitnik RASI proširen je novim česticama u kontekstu složenijih i problemskih zadatka. Dodavanje čestica provodilo se kroz sljedeće korake: (1) tri osobe upućene u problematiku pristupa učenju kod studenata osmislile su dodatne čestice u kontekstu problemskih i složenih zadataka za svaku osnovnu podskalu upitnika RASI (dubinski, strateški i površinski), (2) dodane čestice pregledao je autor upitnika i složio se s formulacijom dodanih čestica u kontekstu složenih i problemskih zadataka, (3) održane su tri fokus grupe s ispitanicima iz Uzorka 5 s ciljem provjere razumljivosti 13 dodanih čestica i dodavanja dodatnih čestica.

4.3.2.1 Fokus grupa

Metoda fokus grupe pripada kvalitativnim oblicima istraživanja te predstavlja proces prikupljanja podataka putem intervjua s grupom ljudi (Cresswel, 2012, str. 218). Najčešće se primjenjuje u obrazovnim istraživanjima i njome se prikupljaju stavovi o promatranoj temi na grupnoj, a ne na individualnoj razini (Cohen, Manion i Morrison, 2007, str. 376). Tijekom ovog postupka istraživač postavlja grupna pitanja o mjernom instrumentu i snima i/ili bilježi razgovor grupe (Cresswel, 2012, str. 384).

U kvantitativnim istraživanjima, u kojima se kreiraju novi ili razvijaju postojeći upitnici kao mjerni instrumenti, često se koriste fokus grupe (Cohen i sur., 2007). U tom slučaju saziva se fokus grupu (najčešće 4-6 osoba) koja će odgovoriti na pitanja iz upitnika te će iste komentirati, a komentari će se zabilježiti (zapisati i/ili snimiti). Cilj fokus grupa, održanih u sklopu istraživanja u ovoj disertaciji, bio je raspraviti sa studentima jasnoću čestica koje su definirane u originalnom upitniku RASI (52 čestice), čestica koje su dodane u kontekstu rješavanja složenih i problemskih zadataka od strane osoba upoznatih s tim područjem, kao i definiranje novih, dodatnih čestica u promatranom kontekstu.

U svrhu ostvarivanja prethodnog cilja održane su tri fokus grupe.

4.3.2.1.1 Sudionici fokus grupa

Sudionici fokus grupa bili su ispitanici iz Uzorka 5 (studenti druge i četvrte godine Integriranog preddiplomskog i diplomskog Učiteljskog studija na Fakultetu za odgojne i obrazovne znanosti u Osijeku). Sudionici prve dvije fokus grupe bili su studenti druge godine koji su imali iskustva s upitnikom RASI (originalni upitnik s 52 čestice), te grupnim

rješavanjem i procjenom složenog ili problemskog zadatka. S obzirom da integrirani preddiplomski i diplomski učiteljski studij na Fakultetu za odgojne i obrazovne znanosti u Osijeku traje deset semestara, treća fokus grupa održana je sa iskusnijim studentima koji također posjeduju i veće iskustvo neposrednog rada s učenicima. U tu svrhu odabrani su studenti četvrte godine koji su u trenutku održavanja fokus grupe bili na kraju osmog semestra i tijekom prethodne dvije studijske godine su odradili metodičke vježbe u školama. Kako je RASI upitnik namijenjen ispitivanju pristupa učenju kod studenata, sudionici u fokus grupi u potpunosti su odgovarali skupini ispitanika za koje je upitnik kreiran, kao i populaciji cjelokupnog istraživanja, a to su budući učitelji.

4.3.2.1.2 Rasipanje Uzorka 5

Ukupan broj ispitanika u uzorku 5 bio je 200 studenata. Ispitanici iz Uzorka 5 sudjelovali su u fokus grupama prilikom proširenja upitnika RASI. Sudjelovanje u fokus grupama bilo je dobrovoljno i na sudjelovanje se odlučilo 13 ispitanika sa druge godine i 4 ispitanika sa četvrte godine integriranog preddiplomskog i diplomskog Učiteljskog studija Fakulteta za odgojne i obrazovne znanosti u Osijeku.

4.3.2.1.3 Tijek fokus grupa

Uvodni dio fokus grupe obuhvatio je predstavljanje moderatora i napomenu sudionicima o snimanju fokus grupe u svrhu kasnijeg bilježenja podataka. Istaknuto je da u ovom razgovoru nema točnih i netočnih odgovora, već da je naglasak na iznošenju vlastitog mišljenja. S obzirom da je riječ o grupnoj raspravi u kojoj je bitno mišljenje svakog sudionika naglašeno je da je međusobna komunikacija dozvoljena i poželjna, ali uz napomenu da vode računa da se fokus grupa snima i da iz tog razloga treba govoriti samo jedna osoba u trenutku. Također, naglašeno je i da njihova mišljenja iznesena tijekom fokus grupe neće imati nikakvog utjecaja na njihove ocjene niti na bilo koji aspekt njihovog studija te da će se podaci iz ove fokus grupe koristiti u svrhu izrade doktorske disertacije. Na kraju su uvodnog dijela sudionici zamoljeni da se predstave svojim imenom i prezimenom kako bi se kasnije prilikom bilježenja podataka na temelju audio snimke mogli razlikovati njihovi glasovi.

Nakon uvodnog dijela predstavljen im je upitnik. U fokus grupama u kojima su sudionici bili studenti druge godine, upitnik je predstavljen na način da su se trebali prisjetiti upitnika koji su popunjavali u okviru zadaće, dok je u fokus grupi u kojoj su sudionici bili studenti četvrte godine, upitnik predstavljen na način da je moderator ukratko objasnio strukturu i namjenu

upitnika. Kako bi stekli sud o jasnoći postojećih čestica sudionici su zamoljeni da pogledaju i popune upitnik, a popunjavanje upitnika trajalo je između 10 i 20 minuta, prosječno 15 minuta, koliko je i predviđeno za njegovo popunjavanje. Prilikom ispunjavanja upitnika napomenuto im je da slobodno zapišu komentare uz pitanja.

Glavni dio fokus grupe, nakon popunjavanja upitnika, obuhvatio je iznošenje mišljenja sudionika o jasnoći pitanja te su trebali pročitati komentare koje su zapisali. Sudionici su trebali istaknuti one čestice upitnika koje su im bile nejasne te je za njih trebala biti raspravljena drugačija formulacija i u konačnici određen konačni oblik promatrane čestice. Za čestice za koje su sudionici smatrali da bi se trebale dodati u upitnik, također je raspravljena njezina formulacija. Nakon rasprave o formulaciji čestica sudionici su zamoljeni da povežu čestice koje su dodane u upitnik s aspektima koji se u upitniku procjenjuju. Za kraj glavnog dijela fokus grupe sudionici su upitani imaju li oni prijedlog čestice koja bi se trebala dodati u upitnik. Na ovaj način dodana je jedna čestica tijekom provođenja druge fokus grupe.

U završnom dijelu izneseni su konačni zaključci fokus grupe te su sudionici upitani o eventualnim nejasnoćama. U znak zahvale svaki sudionik fokus grupe dobio je čokoladu.

4.3.2.1.4 Provođenje fokus grupa

Ukupno je održano tri fokus grupe. Sudionici prve dvije fokus grupe bili su studenti druge godine integriranog preddiplomskog i diplomskog Učiteljskog studija Fakulteta za odgojne i obrazovne znanosti u Osijeku koji su tijekom semestra sudjelovali u grupnom rješavanju i procjeni problemskog zadatka u okviru kolegija Informatika u obrazovanju, dok je treća fokus grupa održana sa studentima četvrte godine istog studija. Sudjelovanje u fokus grupama bilo je isključivo dobrovoljno. Prve dvije fokus grupe održane su 14. svibnja 2015. Prva fokus grupa obuhvatila je 7 ispitanika i trajala je oko 30 min, dok je druga fokus grupa imala 6 ispitanika i trajala je oko 20 min. Treća fokus grupa održana je 15. svibnja 2015., prisustvovalo je 4 sudionika i trajala je oko 30 min. Promjene nakon fokus grupa održanih sa studentima druge godine unesene su u upitnik te se o tako dorađenom upitniku raspravljalo tijekom fokus grupe 3.

4.3.3 Dizajn online okoline za poučavanje

U ovom istraživanju predložen je dizajn online okoline za poučavanje koji se temelji na primjeni IKT-a u nastavi, grupnom radu, rješavanju problemskih i/ili složenih zadataka,

sudjelovanju studenata u postupku procjene te kriterijskoj procjeni uz pomoć unaprijed definiranih rubrika.

Dizajn okoline poučavanja osmišljen u ovom istraživanju provodi se putem sustava za upravljanje učenjem na daljinu što ga čini dizajnom online okoline poučavanja. Studentima se dodijeljuje zadatak u formi problemskog ili složenog zadatka kojeg rješavaju u grupama. Rješenje zadatka predaju također putem sustava za upravljanjem učenjem na daljinu. Nadalje, dodjeljuje im se rješenje zadatka koje trebaju procijeniti prema unaprijed definiranoj rubrici. Procjena dodijeljenog rješenja može biti samoprocjena (tada im se dodjeljuje njihovo rješenje zadatka), vršnjačka procjena (tada im se dodjeljuje rješenje zadatka neke druge grupe) ili kombinacija obje procjene (tada im se dodjeljuje i vlastito rješenje i rješenje neke druge grupe). Na ovaj način se svako rješenje procjenjuje od strane nekoliko studenata. Ukoliko procjene nisu međusobno previše različite, tada se srednja vrijednost procjena uzima kao konačna. Ukoliko postoji procjena/procjene koje značajno odudaraju od ostalih procjena, tada je nužna intervencija nastavnika čija procjena se uzima kao konačna.

4.3.4 Eksperiment

Eksperiment proveden u ovom istraživanju je eksperiment s faktorskim dizajnom. U faktorskom dizajnu istraživačka pitanja i/ili hipoteze oblikuju se na način da obuhvaćaju dvije nezavisne i jednu zavisnu varijablu (Creswel, str. 311). Faktori, odnosno nezavisne varijable, s pripadajućim kategorijama, definirani u ovom faktorskom dizajnu su sljedeći:

- Samoprocjena
    - Uključena
    - Nije uključena
- Vršnjačka procjena
    - Uključena
    - Nije uključena

Creswell (2012, str. 304) navodi sljedeće čimbenike rizika za eksperiment s faktorskim dizajnom: *povijest, maturacija, regresija, odabir uzorka, odustajanje, interakcije s uzorkom*. S obzirom da je provedba eksperimenta trajala prosječno 4 tjedna, čimbenici rizika poput *povijesti, maturacije* i *regresije* smatraju se kontroliranima. Svi uzorci korišteni u istraživanju su prigodni slučajni uzorci čime se minimizira čimbenike rizika *odabir uzorka* te *interakcija s*

uzorkom. Čimbenik rizik *odustajanja* predstavlja najveću prijetnju, ali s obzirom na veličine odabranih uzoraka, smatra se kontroliranim čimbenikom rizika.

4.3.4.1 Opis i protokol eksperimenta

Eksperiment je proveden na pet fakulteta u Republici Hrvatskoj:

- Fakultet za odgojne i obrazovne znanosti Sveučilišta J. J. Strossmayera u Osijeku,
- Fakultet za odgojne i obrazovne znanosti Sveučilišta J. J. Strossmayera u Osijeku, dislocirani studij u Slavonskom Brodu,
- Učiteljski fakultet Sveučilišta u Zagrebu, Središnjica
- Učiteljski fakultet Sveučilišta u Zagrebu, Odsjek u Čakovcu,
- Filozofski fakultet Sveučilišta J. J. Strossmayera u Osijeku,

tijekom ak. god. 2015./16. u okviru sljedećih kolegija:

- *Programski jezik Logo* koji se izvodi na četvrtoj godini u okviru Integriranog preddiplomskog i diplomskog sveučilišnog učiteljskog studija Fakulteta za odgojne i obrazovne znanosti Sveučilišta J. J. Strossmayera u Osijeku,
- *Statistika* koji se izvodi na petoj godini u okviru Integriranog preddiplomskog i diplomskog sveučilišnog učiteljskog studija Fakulteta za odgojne i obrazovne znanosti Sveučilišta J. J. Strossmayera u Osijeku,
- *Prirodno geografska obilježja Hrvatske* koji se izvodi na prvoj godini u okviru Integriranog preddiplomskog i diplomskog sveučilišnog učiteljskog studija Fakulteta za odgojne i obrazovne znanosti Sveučilišta J. J. Strossmayera u Osijeku,
- *Metodika Matematike I* koji se izvodi na trećoj godini u okviru Integriranog preddiplomskog i diplomskog sveučilišnog učiteljskog studija Fakulteta za odgojne i obrazovne znanosti Sveučilišta J. J. Strossmayera u Osijeku,
- *Metodika Matematike I* koji se izvodi na trećoj godini u okviru Integriranog preddiplomskog i diplomskog sveučilišnog učiteljskog studija Fakulteta za odgojne i obrazovne znanosti Sveučilišta J. J. Strossmayera u Osijeku, dislociranog studija u Slavonskom Brodu,

- *Metodologija pedagoškog istraživanja* koji se izvodi na trećoj godini u okviru preddiplomskog sveučilišnog studija Ranog i predškolskog odgoja i obrazovanja Fakulteta za odgojne i obrazovne znanosti Sveučilišta J. J. Strossmayera u Osijeku,
- *Programiranje* koji se izvodi na četvrtoj godini u okviru Integriranog preddiplomskog i diplomskog sveučilišnog učiteljskog studija Učiteljskog fakulteta Sveučilišta u Zagrebu, Odsjeka u Čakovcu,
- *Uvod u baze podataka* koji se izvodi na trećoj godini u okviru Integriranog preddiplomskog i diplomskog sveučilišnog učiteljskog studija Učiteljskog fakulteta Sveučilišta u Zagrebu, Odsjeka u Čakovcu,
- *Uvod u baze podataka* koji se izvodi na trećoj godini u okviru Integriranog preddiplomskog i diplomskog sveučilišnog učiteljskog studija Učiteljskog fakulteta Sveučilišta u Zagrebu, Središnjica u Zagrebu,
- *Engleski jezik I* koji se izvodi na prvoj godini u okviru sljedećih studija na Filozofskom fakultetu Sveučilišta J. J. Strossmayera u Osijeku: dvopredmetnog preddiplomskog sveučilišnog studija Hrvatskog jezika i književnosti, dvopredmetnog preddiplomskog sveučilišnog studija mađarskog jezika i književnosti, dvopredmetnog preddiplomskog sveučilišnog studija pedagogije, dvopredmetnog preddiplomskog sveučilišnog studija filozofije te dvopredmetnog preddiplomskog sveučilišnog studija povijesti.

U eksperimentu su sudjelovali ispitanici iz Uzorka 2.

4.3.4.1.1 Rasipanje Uzoka 2

Eksperiment je proveden na Uzorku 2 kojeg čini 495 studenata koji su pohađali kolegije na kojima je eksperiment proveden. S obzirom da je sudjelovanje u eksperimentu bilo dobrovoljno, rasipanje ispitanika tijekom samog istraživanja je bilo značajno. Tablica 5 prikazuje broj ispitanika koji su pohađali svaki od kolegija iz eksperimenta te broj ispitanika koji su uredno izvršavali sve obveze, po fazama istraživanja. Ukupan broj podataka, prikupljenih na temelju ispitanika koji su odradili sve faze eksperimenta, je N=196.

4.3.4.1.2 Podjela ispitanika u grupe i skupine

Ispitanici su se dijelili u grupe unutar kolegija na kojem se provodio eksperiment. Na nekim kolegijima dozvoljeno je samostalno formiranje grupa, dok je na nekim kolegijima nastavnik odredio grupe. Broj ispitanika u grupi varira od kolegija do kolegija, ovisno o

Tablica 5. Broj ispitanika u uzorku 2 - rasipanje uzorka

Kolegij	**Ukupan broj studenata na kolegiju**	**Faza I istraživanja (popunjavanje upitnika prije intervencije)**	**Faza II (predaja rada)**	**Faza III istraživanja (obavljanje dodijeljenih procjena)**	**Faza IV istraživanja (popunjavanje upitnika poslije intervencije)**	**Broj ispitanika u konačnom uzorku 2**		
						N	**% (kolegij)**	**%(uzorak 2)**
Programiranje na Učiteljskom fakultetu u Zagrebu, Odsjek u Čakovcu	21	15	21	20	18	12	57%	6%
Uvod u baze podataka na Učiteljskom fakultetu u Zagrebu, Odsjek u Čakovcu	20	20	20	19	18	17	85%	9%
Uvod u baze podataka na Učiteljskom fakultetu u Zagrebu	20	19	20	19	13	12	60%	6%
Engleski jezik I na Filozofskom fakultetu u Osijeku	68	38	42	42	24	19	28%	10%
Logo na Fakultetu za odgojne i obrazovne znanosti u Osijeku	74	32	17	17	14	12	16%	6%
Statistika na Fakultetu za odgojne i obrazovne znanosti u Osijeku	76	9	3	3	3	3	4%	2%
Metodika matematike I na Fakultetu za odgojne i obrazovne znanosti u Osijeku	81	59	59	57	43	40	49%	20%
Prirodno geografska obilježja Hrvatske na Fakultetu za odgojne i obrazovne znanosti u Osijeku	78	71	77	65	42	37	47%	19%
Metodologija pedagoškog istraživanja na Fakultetu za odgojne i obrazovne znanosti u Osijeku	28	26	28	25	22	20	71%	10%
Metodika matematike I na Fakultetu za odgojne i obrazovne znanosti u Osijeku, dislocirani studij u Slavonskom Brodu	29	27	29	28	26	24	83%	12%

ukupnom broju studenata koji pohađaju kolegij (Tablica 6). Broj grupa treba biti veći nego broj ispitanika u grupi. Podjela u grupe se bazira na broju članova koji je određen u odnosu na broj studenata koji pohađaju kolegij, ali ako ne mogu biti formirane isključivo grupe s tim određenim brojem članova, tada se formira potreban broj grupa s manjim brojem članova. Najmanja grupa u eksperimentu broji troje ispitanika, a najveća sedmero ispitanika.

Formirane grupe su slučajnim odabirom podijeljene u četiri skupine: skupinu s vršnjačkom procjenom, skupinu sa samoprocjenom, skupinu s vršnjačkom procjenom i samoprocjenom te skupinu u kojoj ispitanici nisu sudjelovali u postupku procjene.

Tablica 6. Veličine grupa unutar kolegija na kojem se provodio eksperiment

Kolegij	**Broj članova grupe**
Programski jezik Logo	4
Statistika	4
Prirodno geografska obilježja Hrvatske	7
Metodika Matematike I (Osijek i Slavonski Brod)	4
Programiranje	4
Uvod u baze podataka u Čakovcu (Čakovec i Zagreb)	4
Engleski jezik I	4

Ispitanici koji su bili u skupini samoprocjene trebali su procijeniti rješenje zadatka svoje grupe prema zadanoj rubrici. Ispitanicima koji su bili u skupini vršnjačke procjene nastavnik je dodijelio rješenje zadatka neke druge grupe za procjenu, s time da niti jedan student iz ove skupine nije mogao procjenjivati vlastito rješenje zadatka. Ispitanicima koji su bili u skupini s vršnjačkom procjenom i samoprocjenom nastavnik je dodijelio rješenje zadtka druge grupe za procjenu, ali istovremeno su trebali procijeniti i vlastito rješenje zadatka. Ovakav način procjene osigurao je da svako rješenje zadatka bude procijenjena od strane nekoliko studenta.

Osim studenata svaku predanu zadaću procijenio je i nastavnik prema istoj rubrici.

4.3.4.1.3 Zadaci

Za svaki kolegij na kojem je proveden eksperiment osmišljen je problemski ili složeni zadatak. Tekstovi osmišljenih zadataka nalaze se u PRILOGU II. Zadaci su osmišljeni na temelju konstruktivnog poravnanja. Rješenja problemskih zadataka teško se mogu procjeniti klasičnim testovima (Jonassen, 2011) i iz tog razloga se primjenjuje konstruktivno poravnanje kako bi se procjena uskladila s definiranim ishodima učenja (Nightingale i sur., 2007). U PRILOGU II se nalaze i tablice s konstruktivnim poravnanjem za svaki pojedini kolegij na kojem je proveden eksperiment. Tablice koje prikazuju konstruktivno poravnanje napravljene su za potrebe ove doktorske disertacije, one nisu u stvarnoj primjeni prilikom realizacije promatranih kolegija.

Prvi stupac tablice koja prikazuje konstruktivno poravnanje trebao bi sadržavati ishode učenja studijskog programa. Međutim, nemaju svi studijski programi, na kojima je provedeno istraživanje, ishode učenja definirane na takav način. U tu svrhu umjesto ishoda učenja programa korištene su kompetencije, ciljevi programa ili kolegija. Konkretno, Fakultet za odgojne i obrazovne znanosti Sveučilišta J. J. Strossmayera u Osijeku (koji je promijenio naziv 2015. godine iz Učiteljskog fakulteta u Fakultet za odgojne i obrazovne znanosti) je promatrani problem i istaknuo u Samoanalizi iz 2014. g. (Učiteljski fakultet u Osijeku, 2014):

Studijski programi integriranog preddiplomskog i diplomskog učiteljskog studija, preddiplomskoga i diplomskoga sveučilišnoga studija Ranog i predškolskog odgoja i obrazovanja izrađeni su prema Uputama za sastavljanje prijedloga preddiplomskih i diplomskih studijskih programa Rektorskog zbora od 14. prosinca 2004. u kojima nisu bili ishodi učenja. Za sve kolegije u studijskom programu definirani su kompetencije, znanje, vještine koje kolegij razvija te ciljevi kolegija (Učiteljski fakultet u Osijeku, 2014).

4.3.4.1.4 Rubrika

Kako navodi Entwistle (2009, str. 15) procjena znanja treba biti transparentna, odnosno, takva da omogućuje shvaćanje dobivene ocjene. Iz tog razloga Mulder i sur. (2014) predlažu korištenje rubrike tijekom procjene. Jonassen (2011) predlaže upravo rubrike kao jedan od načina procjene rješenja problemskih zadataka.

Za svaki osmišljeni zadataka, u sklopu eksperimenta, definirana je rubrika u kojoj su navedeni kriteriji procjene te su za svaki kriterij procjene definirani prihvatljivi i neprihvatljivi stupnjevi

izvedbe. Svaki stupanj izvedbe za svaki pojedini kriterij nosio je određeni broj bodova. Definirane rubrike za svaki zadatak na svakom kolegiju prikazane su u PRILOGU II.

Dochy i sur. (1999) navode kako bi kriteriji trebali biti utvrđeni prije početka procjene. Iz tog razloga je ispitanicima omogućen uvid u rubriku odmah čim im je zadan zadatak.

4.3.4.1.5 Pokazni rad

Mali je broj studenata koji su imali mogućnost sudjelovati u procesu procjene znanja (Liu i Carless, 2010).

Kako bi stekli iskustvo procjene uz pomoć rubrike na Moodlu ispitanicima je omogućeno procjenjivanje pokaznog rada prije nego započnu procjenu dodjeljenih radova u sklopu istraživanja. Pokazni rad napravio je i postavio nastavnik koji ga je ujedno i procjenio. Procjena pokaznog rada obavlja se uz pomoć iste rubrike kojom su se procjenjivli dodijeljeni radovi. Pokazni rad i njegova procjena od strane nastavnika postavljeni su na Moodle kako bi ispitanici imali uvid u primjer ekspertne procjene, a zahtjev za procjenu istog rada od strane ispitanika postavljen je kako bi stekli iskustvo procjene uz pomoć rubrike na Moodlu i kako bi mogli usporediti svoju i nastavnikovu procjenu na danom primjeru.

4.3.4.1.6 Povratna informacija

Povratna informacija istaknuta je kao važan dio procesa procjene znanja (Carless, 2003; Sadler, 1989; Harasim, 2012, str. 68; Cramp 2011).

Prilikom procjene dodijeljenih radova ispitanici su bili obvezni pružiti povratnu informaciju u kojoj su trebali pojasniti razlog odabira pojedinog stupnja za svaki procjenjivani kriterij. Ovakvim zahtjevom za oblikovanjem povratne informacije željelo se osigurati da povratna informacija bude opširnija i kvalitetnija. Kvaliteta povratne informacije povećava se time što se sadržaj povratne informacije direktno veže na odabrane stupnjeve izvedbe procjenjivanih kriterija.

4.3.4.1.7 Faze eksperimenta

Eksperiment je proveden u nekoliko faza:

- na samom početku ispitanici su popunjavali prošireni RASI upitnik o vlastitom pristupu učenju te SPTKTT upitnik o percepciji vlastitih znanja o primjeni tehnologije u nastavi,

- nakon popunjavanja upitnika otvorila se aktivnost Radionica i njezina uvodna faza u kojoj se ispitanici razvrstavaju u grupe. U uvodnoj fazi radionice je također zadan zadatak u formi problemskog ili složenog zadatka. Naglašeno je da će se procjena vršiti uz pomoć rubrike. Rubrika s kriterijima procjene i pripadnim stupnjevima izvedbe bila je dostupna ispitanicima odmah po zadavanju zadatka. Ispitanicima je dodijeljen rok od nekoliko dana da riješe zadatak i predaju rješenje, pri čemu ih je nastavnik nekoliko puta podsjećao na krajnji rok za predaju rješenja zadatka.

- Nakon predane zadaće započela je faza procjene rješenja dodijeljenih zadaća. Ispitanici su dodijeljena rješenja procjenjivali uz pomoć definirane rubrike. Prije procjene dodijeljenih rješenja zadataka ispitanici su trebali procijeniti pokazni rad. Tek nakon obavljene procjene pokaznog rada mogli su pristupiti procjeni dodijeljenih radova u sklopu eksperimenta. Koliko rješenja im je dodijeljeno za procjenu ispitanici su saznali tek kada su odradili procjenu pokaznog rada. Tijekom procjene dodijeljenih radova, odnosno popunjavanja rubrike za procjenu, ispitanici su morali pružiti i povratnu informaciju.

- Nakon završetka faze procjene ispitanicima je omogućen uvid u procjene njihovih radova obavljene od strane drugih ispitanika.

- Ispitanici ponovno popunjavaju prošireni upitnik RASI o vlastitom pristupu učenju i upitnik SPTKTT o percepciji vlastitih znanja o primjeni tehnologije u nastavi te daju vlastito mišljenje o sudjelovanju u vršnjačkoj kriterijskoj procjeni i samoprocjeni rješenja problemskog zadatka putem otvorenog pitanja.

Tablica 7 prikazuje primjer vremenskog okvira za istraživanje, po koracima, koje je provedeno u okviru kolegija Programiranje na Učiteljskom fakultetu u Zagrebu, Odsjeku u Čakovcu.

4.3.4.1.1 Aktivnosti na Moodlu

Eksperiment se provodio uz pomoć sustava za upravljanje učenjem na daljinu Moodle. Neki od fakulteta na kojima se provodilo istraživanje imaju vlastiti Moodle na svom serveru, dok npr. Fakultet za odgojne i obrazovne znanosti u Osijeku koristi Loomen, Moodle instaliran na Carnetovom serveru dostupan svim korisnicima AAI@Edu.hr elektroničkog identiteta.

Na svakom kolegiju, na kojem je eksperiment proveden, aktivnosti na Mooodlu, vezane uz istraživanje, bile su postavljene u zaseban blok (Slika 88).

Postavljen je forum (Slika 8) putem kojeg su ispitanici mogli pratiti obavijesti o tijeku istraživanja. Putem foruma ispitanici su podsjećani na nadolazeće krajnje rokove te su bili pozvani postavljati pitanja o istraživanju, nejasnoćama ili tehničkim poteškoćama. Za bilo kakav problem ili pitanje pozvani su, također, obratiti se i putem maila. Kao sredstvo komunikacije ispitanici su u većoj mjeri koristili mail u odnosu na forum.

Tablica 7. Vremenski okvir po koracima za istraživanje u okviru kolegija Programiranje na Učiteljskom fakultetu u Zagrebu, Odsjeku u Čakovcu

Korak u istraživanju		**Tjedan provedbee eksperimenta**
1.	Studenti popunjavaju upitnike o pristupu učenju i primjeni tehnologije u nastavi.	3. tjedan nastave
2.	• Formiranje skupina studenata (ovisno o broju studenata u studijskoj grupi) • Zadavanje zadatka i prikaz kriterija procjene (dovoljno je da mogu vidjeti samo kriterije, bez stupnjeva).	1. tjedan istraživanja 1. tjedan istraživanja
3.	Predaja rješenja zadatka. Svaki student iz skupine treba predati rješenje. Predana rješenja unutar skupine trebaju biti jednaka.	2 . tjedan istraživanja
4.	Procjenjivanje zadaća. Studenti će biti raspoređeni u četiri eksperimentalne skupine po četiri ili pet studenata: studenti koji procjenjuju rješenje svoje zadaće (samoprocjena), studenti koji procjenjuju rješenja kolega (vršnjačka procjena), studenti koji procjenjuju i rješenje svoje zadaće i rješenje zadaće kolega (samoprocjena i vršnjačka procjena) i kontrolna skupina koja ne sudjeluje u procjeni.	3. tjedan istraživanja (okvirno)
5.	• Davanje mišljenja o ovoj zadaći i ovakvom načinu procjene. • Studenti ponovno popunjavaju upitnike o pristupu učenju i primjeni tehnologije u nastavi.	4. tjedan istraživanja 4. tjedan istraživanja

Ispitanicima je, od samog početka istraživanja, bio dostupan dokument u kojem se ukratko opisuje samo istraživanje, kao i razlog njegova provođenja (PRILOG III).

Upitnici su postavljeni kao aktivnost Questionnaire ili Survey, ovisno o tome koji je dodatak bio dostupan na Moodlu.

Podjela ispitanika u skupine vršila se pomoću aktivnosti Odabir ili Registration Date, također ovisno o tome koja je aktivnost bila dostupna na Moodlu koji se koristio.

Slika 8. Blok aktivnosti vezanih uz istraživanje u okviru kolegija Metodika Matematike I na Fakultetu za odgojne i obrazovne znanosti u Osijeku

Sve aktivnosti vezane uz pregled, predaju i procjenu rješenja zadatka odvijale su se uz pomoć aktivnosti *Radionica*. Aktivnost *Radionica* sastojala se od 5 faza (Slika 9):

- *Faza uređivanja postavki radionice* u kojoj ispitanici vide uvodni tekst koji je postavio nastavnik. U ovoj fazi radionice ispitanici vide i zadani zadatak te imaju mogućnost pogledati i rubriku pomoću koje će se vršiti procjena.
- *Faza predaje zadaća* u kojoj je moguće postaviti točno određeno vrijeme kao krajnji rok za predaju.
- *Faza procjene rješenja zadatka* za koju je moguće postaviti automatsku raspodjelu rješenja zadatka ispitanicima za procjenu ili ručno odrediti koji će ispitanik procjenjivati koje rješenje zadatkau. Također, u ovoj fazi moguće je odabrati strategiju procjenjivanja rješenja zadatka te se može izabrati između: zbirno ocjenjivanje, komentar, broj pogrešaka ili rubrika. Nakon što ova faza postane aktivna ispitanici nemaju više mogućnost predavati niti mijenjati predano rješenje.

  Prije nego pristupe procjenjivanju dodijeljenih rješenja zadatka, ispitanici moraju isprobati i provježbati sami postupak procjene. U tu svrhu, aktivnost *Radionica* omogućuje nastavniku postavljanje pokaznog rada kojeg ispitannici trebaju procijeniti uz pomoć iste rubrike pomoću koje će vršiti procjenu dodijeljenih rješenja zadatka. Pokazni rad procijenjen je i od strane nastavnika, tako da ispitanici mogu usporediti vlastitu i nastavnikovu procjenu.

- *Faza evaluacije procjena* u kojoj se dodjeljuju konačne ocjene. Riječ je o fazi u kojoj nastavnik odrađuje svoj dio posla vezano uz ocjene i ispitanici tijekom ove faze nemaju mogućnost nikakvog sudjelovanja niti intervencije, nije im vidljiva konačna ocjena iako im je možda već dodijeljena.
- *Zatvaranje radionice* u kojoj konačna ocjena postaje vidljiva ispitanicima.

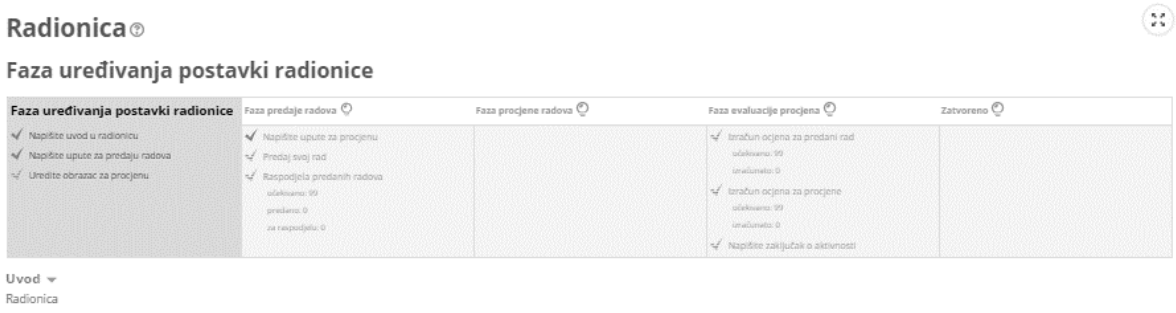

Slika 9. Aktivnost Radionica unutar sustava za upravljanje učenjem Moodle

Nakon što je rješenje zadatka procijenjeno i nakon što su ispitanici dobili uvid u procjene vlastitog rješennja zadatka, mogli su iskazati svoje mišljenje o samoj zadaći i cijelom postupku procjene uz pomoć aktivnosti Journal ili Zadaća, ovisno koja aktivnost je bila dostupna na korištenom Moodlu.

4.4 Varijable

Varijable definirane u ovom istraživanju sljedeće su:

– Zavisne varijable: Duboki, Pristup učenju, Dijametar kvazi-pouzdanosti, TPACK, Tehnologija, Bez tehnolgije

– Nezavisne varijable: Samoprocjena, Vršnjačka procjena, Procjena, Spol, Studijska godina, Razina studija, Znanstveno područje kolegija.

Tablica 8 za svaku varijablu prikazuje koja je vrsta varijable, kao i njezine indikatore.

4.4.1 Tehnologija

Varijabla *Tehnologija* odnosi se na samoprocjenu podskala SPTKTT upitnika koje opisuju znanja koja uključuju tehnologiju. To je zavisna intervalna varijabla koja se računa kao srednja vrijednost bodova ostvarenih za svaku pojedinu česticu na podskalama SPTKTT upitnika koje se odnose na tehnologiju (TK, TCK, TPK, TPACK). S obzirom da se vrijednost varijable računa kao srednja vrijednost bodova ostvarenih za svaku česticu, a svaka čestica

može primiti vrijednosti iz skupa {1, 2, 3, 4, 5}, tada se vrijednost varijable kreće u rasponu [1, 5].

Tablica 8. Popis varijabli, vrsta i indikatori za svaku pojedinu varijablu

NAZIV VARIJABLE	VRSTA VARIJABLE	INDIKATORI
Tehnologija	Zavisna Intervalna	[1,5]
Bez tehnologije	Zavisna Intervalna	[1,5]
Samoprocjena	Nezavisna Kategorijska	Uključena Nije uključena
Vršnjačka procjena	Nezavisna Kategorijska	Uključena Nije uključena
Duboki	Zavisna Intervalna	[1,5]
Pristup učenju	Zavisna Ordinalna	Dubinski Strateški Površinski
Dijametar kvazi-pouzdanosti	Zavisna Intervalna	[0,1]
TPACK	Zavisna Intervalna	[1,5]
Procjena	Nezavisna Kategorijska	S procjenom Bez procjene
Spol	Nezavisna Kategorijska	Ženski Muški
Studijska godina	Nezavisna Ordinalna	Prva Druga Treća Četvrta Peta
Razina studija	Nezavisna Kategorijska	Preddiplomska Diplomska
Znanstveno područje kolegija	Nezavisna Kategorijska	Prirodno Društveno Tehničko Humanističko Umjetničko područje Biomedicina i zdravstvo Biotehničko područje

4.4.2 Bez tehnologije

Varijabla *Bez Tehnologije* odnosi se na samoprocjenu podskala SPTKTT upitnika koje opisuju isključivo pedagoška i predmetna znanja. To je zavisna intervalna varijabla koja se računa kao srednja vrijednost bodova ostvarenih za svaku pojedinu česticu na podskalama SPTKTT upitnika koje se odnose isključivo na pedagoška i predmetna znanja (CK, PK, CPK).

S obzirom da se vrijednost varijable računa kao srednja vrijednost bodova ostvarenih za svaku česticu, a svaka čestica može primiti vrijednosti iz skupa {1, 2, 3, 4, 5}, tada se vrijednost varijable kreće u rasponu [1, 5].

4.4.3 Samoprocjena

Varijabla S*amoprocjena* opisuje sudjelovanje u procesu samoprocjene problemskog zadatka u okviru online suradničkog učenja. *Samoprocjena* je nezavisna kategorijska varijabla koja ima dvije kategorije i može primiti sljedeće vrijednosti:

a) Uključena i
b) Nije uključena.

4.4.4 Vršnjačka procjena

Varijabla *Vršnjačka procjena* opisuje sudjelovanje u procesu vršnjačke procjene problemskog zadatka u okviru online suradničkog učenja. *Vršnjačka procjena* je nezavisna kategorijska varijabla koja ima dvije kategorije i može primiti sljedeće vrijednosti:

c) Uključena i
d) Nije uključena.

4.4.5 Duboki

Varijabla *Duboki* opisuje usvojenost dubokog pristupa učenju. To je zavisna intervalna varijabla koja se računa kao aritmetička sredina svih podskala upitnka RASI koje pripadaju dubokom pristupu učenju. Pošto svaka čestica iz upitnika RASI može primiti vrijednosti iz skupa {1, 2, 3, 4, 5}, svaka podskala pa samim time i varijabla *Duboki_prije* može primiti bilo koju vrijednost iz intervala [1,5].

4.4.6 Pristup učenju

Varijabla *Rasi_prije* predstavlja pristup učenju koji student uobičajeno primjenjuje. To je zavisna ordinalana varijabla koja može primiti sljedeće vrijednosti:

a) duboki,
b) strateški i
c) površinski

Od svih je mogućih vrijednosti najmanje poželjan površinski, a najpoželjniji je duboki pristup učenju.

4.4.7 Dijametar kvazi - pouzdanosti

Varijabla *Dijametar kvazi - pouzdanosti* predstavljat će pouzdanost studentske kriterijske procjene rješenja problemskog zadatka. To je zavisna intervalna varijabla čija se vrijednost računa na sljedeći način: usporedba vršnjačke procjene i samoprocjene u odnosu na nastavnikovu procjenu vrši se po svakom pojedinom kriteriju. Ukoliko se procjena vrši na temelju *n* kriterija, tada pojedinačne procjene promatramo kao točke u n-dimenzionalnom prostoru i računa se njihova međusobna udaljenost.

Ocjene iz rubrike za procjenu prikažu se kao točke u n-dimenzionalnom prostoru. Neka su A i B dvije ocjene od dva različita procjenitelja:

$$A = (x_1, \dots, x_n),$$

$$B = (y_1, \dots, y_n).$$

Uobičajeno je za udaljenost koristiti euklidsku udaljenost. Divjak, Grabar i Maretić (2016) predlažu upotrebu taxicab geometrije i udaljenosti te predlažu i način određivanja pouzdanosti procjene kada su procjenitelji studenti. Njihov način, koji se koristi pri izračunu ove varijable, opisan je niže.

Kada bi se uspoređivalo euklidsku i taxicab geometriju po pitanju udaljenosti između dviju točaka, taxicab geometriju mogli bismo shvatiti kao mjeru udaljenosti koju prijeđe auto u gradu čije ulice čine kvadratnu mrežu pri čemu najkraći put u taxicab geometriji nije jedinstven. S druge strane udaljenost u euklidskoj geometriji predstavlja zračnu udaljenost između točaka A i B. Taxicab metrika ekvivalentna je topološki euklidskoj geometriji, ali jednostavnija. Ona je linearna, tj. udaljenost na razini kriterija jednako doprinosi ukupnoj taxicab udaljenosti.

Ukoliko promatramo procjenu A, tada je suma ostvarenih bodova po svakom pojedinom kriteriju upravo taxicab norma od A:

$|A|_1 = |x_1| + \cdots + |x_n|.$

Usporedba dviju procjena računa se kao njihova taxicab udaljenost, odnosno 1-norma:

$d_1(A, B) = \sum_{i=1}^{n} |x_i - y_i|.$

U slučaju kada imamo nekoliko procjena (više od dvije), tada se pouzdanost računa tako da

međusobno, u paru, usporedimo sve procjene i kao konačnu pouzdanost uzmemo najveću od dobivenih vrijednosti. U tu se svrhu uvodi pojam dijametra skupa procjena, odnosno diam*S*.

Neka je $S = \{S_1, \dots, S_n\}$ skup procjena određene zadaće. Tada dijametar tog skupa procjena definiramo na sljedeći način:

$$\text{diam } S = \max_{i,j} d(S_i, S_j)$$

Skup procjena smatra se pouzdanim ukoliko je konačni dijametar manji od 2*e*, pri čemu je *e* prihvatljiva pogreška koja se definira prije samog postupka procjene. Prilikom računanja pouzdanosti u ovom istraživanju, korištena je prihvatljiva pogreška *e* = 0.1, odnosno, ukoliko je izračunati dijametar < 0.2, tada se smatra da je procjena pouzdana i nema potrebe za intervencijom nastavnika, a konačna ocjena računala bi se kao srednja vrijednost studentskih procjena. U suprotnom slučaju, ukoliko je izračunati dijametar ≥ 0.2, pristupa se eliminaciji stršila, odnosno eliminaciji onih studentskih procjena koje se bitno razlikuju od ostalih te samim time uzrokuju nepouzdanost jer su i same nepouzdane. Stršila se eliminiraju tako da se pokuša pronaći podskup od N procjena čiji dijametar će biti manji od 2e. Pri tome je N kritična vrijednost i određuje se prije provođenja postupka procjene i ovisi o ukupnom broju procjenitelja za pojedini rad. U istraživanju provedenom u okviru ove disertacije se kod radova s 2 ili 3 procjenitelja ovaj korak ne provodi, dok je kod radova s većim brojem procjenitelja kritični N određen kao cjelobrojna vrijednost od $\frac{n}{2} + 1$, pri čemu je n broj procjenitelja po promatranom radu. Na primjer, ukoliko je rad procijenilo 9 studenata, tada je n=9 i

$$N = \frac{n}{2} + 1 = \frac{9}{2} + 1 = 4 + 1 = 5$$

Ukoliko takav podskup postoji, tada procjene iz tog podskupa ulaze u izračun konačne ocjene. Ukoliko takav podskup ne postoji, zahtjeva se intervencija nastavnika koji obavlja procjenu i čija ocjena se uzima kao konačna.

Divjak i sur. (2016) predlažu da vrijednost prihvatljive pogreške *e* bude određena za normaliziranu skalu, odnosno, za normaliziranu taxicab metriku. Postupak normaliziranja provodi se skaliranjem norme uz pomoć vektora ranga *r*. Pretpostavimo da se rubrika za procjenu sastoji od n kriterija $\{C_1, \dots, C_n\}$ i da svaki kriterij poprima samo pozitivne vrijednosti. Neka je $[0, r_i]$ rang kriterija C_i. Vektor ranga definiramo na sljedeći način:

$$r = (r_1, \dots, r_n).$$

Skaliranjem norme dobivamo vrijednosti taxicab norme u rasponu [0,1], što je i raspon vrijednosti koje možete primiti varijabla *Dijametar kvazi - pouzdanosti*.

Primjer računanja *Dijametra kvazi - pouzdanosti* dostupan je u PRILOGU IV.

4.4.8 TPACK

Varijabla *TPACK* predstavlja percepciju budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi. To je zavisna intervalna varijabla koja se računa kao aritmetička sredina svih podskala upitnika SPTKTT. Pošto svaka čestica iz upitnika SPTKTT može primiti vrijednosti iz skupa {1, 2, 3, 4, 5}, svaka podskala pa samim time i varijabla *TPACK_prije* može primiti bilo koju vrijednost iz intervala [1,5].

4.4.9 Procjena

Varijabla *Procjena* predstavlja sudjelovanje u postupku procjene. To je nezavisna kategorijska varijabla koja može primiti dvije vrijednosti:

a) Bez procjene,
b) S procjenom.

Vrijednost *Bez procjene* znači da student uopće nije sudjelovao u postupku procjene, tj. bio je dio kontrolne skupine. Vrijednost *S procjenom* znači da je student sudjelovao u bilo kojoj od triju mogućih vrsta procjene, samoprocjeni, vršnjačkoj procjeni ili kombinaciji samoprocjene i vršnjačke procjene.

4.4.10 Spol

Spol je nezavisna kategorijska varijabla koja može primiti sljedeće vrijednosti:

a) Ženski spol,
b) Muški spol.

4.4.11 Studijska godina

Studijska godina je nezavisna kategorijska varijabla koja predstavlja studijsku godinu koju je student pohađao u vrijeme sudjelovanja u istraživanju. Može primiti sljedeće vrijednosti:

a) Prva studijska godina,
b) Druga studijska godina,
c) Treća studijska godina,
d) Četvrta studijska godina,
e) Peta studijska godina.

S obzirom da je istraživanje provedeno i u okviru preddiplomskih, diplomskih, ali i integriranih studija, prve tri studijske godine ujedno predstavljaju i prve tri godine preddiplomskog i integriranog preddiplomskog i diplomskog studija. Četvrta se godina integriranog studija ujedno promatra kao i prva godina diplomskog studija, dok se peta godina integriranog studija odnosi i na drugu godinu diplomskog studija.

4.4.12 Razina studija

Varijabla *Razina studija* nezavisna je kategorijska varijabla koja može primiti sljedeće vrijednosti:

a) Preddiplomska razina,
b) Diplomska razina.

S obzirom da je istraživanje provedeno i u okviru integriranih preddiplomskih i diplomskih studija, preddiplomska razina obuhvaća prve tri godine preddiplomskog studija i prve tri godine integriranih studija. Diplomska razina obuhvaća prve dvije godine diplomskih studija te četvrtu i petu godinu integriranih studija.

4.4.13 Znanstveno područje kolegija

Znanstveno područje kolegija je nezavisna kategorijska varijabla koja, prema Pravilniku o znanstvenim i umjetničkim područjima, poljima i granama (Nacionalno Vijeće za Znanost, 2009), može primiti sljedeće vrijednosti:

a) Prirodne znanosti,
b) Tehničke znanosti,
c) Biomedicina i zdravstvo,
d) Biotehničke znanosti,
e) Društvene znanosti,
f) Humanističke znanosti,
g) Umjetničko područje,

h) Interdisciplinarna područja znanosti,

i) Interdisciplinarna područja umjetnosti.

4.5 Pilot istraživanje

Pilot istraživanje provedeno je u ljetnom semestru ak. god. 2014./15. u okviru kolegija Oblikovanje teksta i slike na prvoj godini sveučilišnog preddiplomskog studija Informacijski/Poslovni sustavi Fakulteta organizacije i informatike u Varaždinu Sveučilišta u Zagrebu. Sudjelovanje u istraživanju bilo je u potpunosti dobrovoljno. Iako u aktivnosti Radionica postoji mogućnost dodjele bodova za obavljenu procjenu, ta se mogućnost tijekom ovog istraživanja nije koristila.

Kolegij se izvodi uz podršku sustava za upravljanje učenjem Moodle. Sadržaj kolegija čine sljedeće nastavne cjeline:

- Klasično i digitalno tiskarstvo,
- Tipografija,
- Fontovi,
- Uređivanje teksta,
- Boja,
- Modeli boja,
- Raster,
- Računalna grafika,
- Formati grafičkih datoteka,
- Tehnike obrade slike,
- Oblikovanje/prijelom stranice,
- Primjena,
- Oblikovanje digitalnih publikacija,
- Oblikovanje web stranica,
- Web kvaliteta.

Pilot istraživanje provedeno je u okviru Kolokvija II na laboratorijskim vježbama na ispitanicioma iz Uzorka 4. Laboratorijske vježbe organizirane su u 15 studentskih skupina s 13-17 članova.

4.5.1 Rasipanje Uzorka 4

Uzorak 4 sastojao se od 223 isptanika. Sudjelovanje u pilot istraživanju bilo je dobrovoljno. Za sudjelovanje u istraživanju odlučilo se 88 ispitanika. Tijekom provedbe pilot istraživanja, broj ispitanika koji su završavali svaku fazu eksperimenat se smanjivao (Tablica

9). U konačnici, sve faze eksperimenta odradilo je 50 ispitanika čiji podaci su uzeti za daljnu analizu podataka.

4.5.2 Opis pilot istraživanja

Kolegij Oblikovanje teksta i slike slušalo je ukupno 223 studenta. Studenti su se trebali po vlastitom nahođenju podijeliti u skupine od po tri studenta unutar svoje skupine za laboratorijske vježbe i dobrovoljno odlučiti žele li ili ne žele sudjelovati u istraživanju. U konačnici za sudjelovanje u istraživanju odlučilo se 88 studenata. Kako se tijekom faza eksperimenta uzorak rasipao, do kraja istraživanja je ostalo 50 ispitanika.

Tablica 9. Broj ispitanika u uzorku 4 - rasipanje uzorka

	Ukupan broj studenata na kolegiju	**Faza I istraživanja (popunjavanje upitnika prije intervencije)**	**Faza II (predaja rada)**	**Faza III istraživanja (obavljanje dodijeljenih procjena)**	**Faza IV istraživanja (popunjavanje upitnika poslije intervencije)**	**Broj ispitanika u konačnom uzorku 2**	
						N	***% (uzorak4)***
Pilot istraživanje	***223***	**88**	**74**	**71**	**55**	***50***	*22%*

Tablica 10 prikazuje vremenski slijed Pilot istraživanja.

Nakon krajnjeg roka za popunjavanje upitnika, otvoren je pristup zadacima koje su studenti trebali rješavati u kolokviju. Za rješavanje zadatka na raspolaganju su imali više od dva tjedna. S obzirom da je bila riječ o kolokviju, velikom broju studenata i činjenici da se kolokvij nije rješavao u ustanovi pod kontrolom nastavnika, osmišljeno je pet različitih zadataka i studentima je bilo jasno naznačeno koje skupine rješavaju koji zadatak.

Zadaci zadani u kolokviju nalaze se u PRILOGU V.

Svi studenti trebali su predati rješenja svojih zadataka putem aktivnosti Zadaća na Moodlu. Za potrebe Pilot istraživanja II otvorene su Radionice u kojima su studenti, koji su se odlučili za sudjelovanje u istraživanju, trebali predati rješenje svoje zadaće. Nakon krajnjeg roka za predaju rješenja, studenti su trebali rješenje zadatka prezentirati. Prezentacija je rješenja također bila sastavni dio rješenja i također se procjenjivala. Studenti koji su sudjelovali u istraživanju pristupili su postupku samoprocjene i/ili vršnjačke procjene, ovisno u kojoj eksperimentalnoj grupi su bili, dok studenti koji nisu pristupili istraživanju nisu imali obvezu obaviti procjenu. Svi studenti procijenjeni su od strane nastavnika. Sve procjene provodile su se putem rubrike za procjenu koja je dostupna u PRILOGU VI.

Nakon provedene procjene studenti su ponovno pristupili popunjavanju upitnika te su zamoljeni da putem otvorenog pitanja iznesu svoje mišljenje o ovakvom načinu provođenja kolokvija, timskom radu i procjeni. Komentari su bili uglavnom pozitivni. Negativni osvrti odnosili su se uglavnom na upitnik SPTKTT, što je i razumljivo s obzirom da ispitanici u ovom Pilot istraživanju nisu obrazovnog usmjerenja.

Također, nekolicina se dotakla i negativne strane vezano uz nejasnoće samog istraživanja, koraka koji slijede i općenito upućenosti u proceduru istraživanja. Iz tog je razloga tijekom glavnog istraživanja na raspolaganje stavljen dokument u kojem se opisuje samo istraživanje i njegovi koraci, kao i forum putem kojeg su sve nejasnoće mogle biti riješene.

Uzorak prikupljen ovim Pilot istraživanjem bio je dovoljan da se ispita faktorska struktura proširenog RASI upitnika i dodatno razmotri statistička obrada podataka.

4.6 Analiza podataka

U svrhu potvrđivanja ili odbacivanja hipoteza istraživanja provedena je statistička analiza prikupljenih podataka. Podaci prikupljeni u istraživanju obrađeni su pomoću programa za statističku obradu podataka SPSS 24.0 te programa za strukturalno programiranje Lisrel 9.1.

4.6.1 Validacija

Validacija upitnika RASI i SPTKTT provedena je faktorskom analizom te je određena njihova pouzdanost. Za određivanje konstruktne valjanosti upitnika korištena je konfirmatorna faktorska analiza, a za određivanje pouzdanosti korištena je metoda unutarnje konzistencije koja uključuje određivanje vrijednosti Cronbachova koeficijenta pouzdanosti α.

Validacija upitnika RASI je provedena na temelju podataka prikupljenih od ispitanika iz Uzorka 2, Uzorka 3 i Uzorka 4. Iako ova tri uzorka zajedno broje 1016 ispitanika, zbog značajnog rasipanja Uzorka 2 i Uzorka 4 tijekom istraživanja, statistička analiza je provedena na podacima prikupljenim od ispitanika koji su barem jednom popunili upitnik RASI, bilo prije ili poslije provedbe eksperimenta. Ukoliko je ispitanik popunio upitnik RASI oba puta, za validaciju su uzeti podaci iz prvog popunjavanja upitnika. U konačnici podaci za validaciju upitnika RASI dobiveni su od 337 ispitanika iz Uzorka 2, 298 ispitanika iz Uzorka 3 i 50 ispitanika iz Uzorka 4, odnosno na podacima prikupljenim od ukupno 685 ispitanika.

Validacija upitnika SPTKTT provedena na temelju podataka prikupljenih od ispitanika iz Uzorka 2. Zbog rasipanaj Uzorka 2 tijekom provedbe eksperimenta, statistička analiza je provedena na podacima prikupljenim od ispitanika koji su barem jednom popunili upitnik SPTKTT, bilo prije ili poslije provedbe eksperimenta. Ukoliko je ispitanik popunio upitnik oba puta, za validaciju su uzeti podaci iz prvog popunjavanja upitnika. U konačnici podaci za validaciju upitnika SPTKTT dobiveni su od 337 ispitanika iz Uzorka 2.

Tablica 10. Vremenski slijed Pilot istraživanja

Korak u istraživanju		**Krajni rok**
1.	Studenti popunjavaju upitnike o pristupu učenju i primjeni tehnologije u nastavi.	21. svibnja 2015.
2.	• Formiranje skupina studenata (ovisno o broju studenata u studijskoj grupi[2]) • Zadavanje zadatka[3] i prikaz kriterija procjene (dovoljno je da mogu vidjeti samo kriterije, bez stupnjeva).	21. svibnja 2015. 22. svibnja 2015.
3.	Predaja rješenja zadatka. Svaki student iz skupine treba predati rješenje. Predana rješenja unutar skupine trebaju biti jednaka.	7. lipnja 2015.
4.	Procjenjivanje zadaća. Studenti će biti raspoređeni u četiri eksperimentalne skupine po četiri ili pet studenta: studenti koji procjenjuju rješenje svoje zadaće (samoprocjena), studenti koji procjenjuju rješenja kolega (vršnjačka procjena), studenti koji procjenjuju i rješenje svoje zadaće i rješenje zadaće kolega (samoprocjena i vršnjačka procjena) i kontrolna skupina koja ne sudjeluje u procjeni.	8. – 12. lipnja 2015.
5.	• Davanje mišljenja o ovoj zadaći i ovakvom načinu procjene. • Studenti ponovno popunjavaju upitnike o pristupu učenju i primjeni tehnologije u nastavi.	19. lipnja 2015.

[2] Broj skupina treba biti veći nego broj studenata u skupini. Podjela se može bazirati na skupinama od po pet studenta, ali ako ne mogu biti formirane isključivo skupine od po pet studenta, tada se formira potreban broj skupina od po četiri studenta.

[3] Nastavni sadržaj bi trebao započeti zadatkom, jer je to suština problemskog učenja: prvo se zada zadatak pa se onda tek uči sve ono što im treba da riješe zadatak.

4.6.2 Podaci koji nedostaju

Prvo su se analizirali podaci koji nedostaju. Svi oni slučajevi u kojima je nedostajalo dva ili više podataka u nizu uklonjeni su iz daljne analize (Meyers, Gans i Guarino, 2006, str. 60). Slučajevi u kojima su nedostajali pojedinačni podaci su ostavljeni, ali su podaci koji nedostaju nadopunjeni podacima dobivenim na temelju linearne interpolacije (Meyers, Gans i Guarino, 2006, str. 63). Za lineranu interpolaciju korištena je funkcija ugrađena u program SPSS 24.0.

4.6.3 Normalna distribucija podataka

Normalna distribucija podatak jedan je od osnovnih uvjeta za provođenje parametrijske statistike.

Prilikom utvrđivanja odudara li promatrana distribucija značajno od normalne distribucije razlikujemo: statistički i grafički pristup. Osim toga razlikujemo i univarijatnu i multivarijatnu normalnu distribuciju.

Statistički pristup obuhvaća Kolmogorov-Smirnovljev i Shapiro-Wilkov test nivoa značajnosti $\alpha=0.05$, kojim se provjerava nulta hipoteza da varijabla ima normalnu distribuciju u promatranom uzorku. Osim spomenutih testova, za utvrđivanje normalne distribucije podataka koristila se i analiza deskriptivnih mjera poput mjere asimetričnosti i zakrivljenosti (Ghasemi i Zahediasl, 2012; Meyers, Gans i Guarino, 2006, str. 67.) te njihovih omjera s pripadnim standardnim pogreškama, koji je za normalnu distribuciju između -1.96 i 1.96 (Ghasemi i Zahediasl, 2012).

Grafički pristup obuhvaća Q-Q prikaz promatrane varijable u kojem je normalna distribucija podataka prikazana dijagonalnim pravcem i grafički prikaz podataka iz uzorka se uspoređuje s promatranim pravcem. Ukoliko podaci prate pravac, pretpostavlja se da distribucija podataka ne odudara značajno od normalne distribucije (Meyers, Gans i Guarino, 2006, str. 68.).

Multivarijatni pristup, osim utvrđivanja univarijatne normalne distribucije, podrazumijeva i analizu dijagrama raspršenosti za parove promatranih varijabli. Ukoliko grafički prikaz podataka na dijagramu ima elipsasti i/ili ovalni oblik smatra se da varijable zadovoljavaju uvjet multivarijatne normalne distribucije (Meyers, Gans i Guarino, 2006, str. 69.)

Također, analizirala su se stršila u promatranom skupu podataka koja mogu znatno utjecati na distribuciju, posebno kod utvrđivanja distribucije putem statističkih testova. Analizom

kutijastog dijagrama provjeravalo se postoje li stršila za promatrani skup podataka i ukoliko su postojala, ti slučajevi su uklonjeni (Meyers, Gans i Guarino, 2006, str. 67). Ukoliko su testovi, nakon uklanjanja, pokazali da promatrana distribucija ne odudara značajno od normalne, daljna analiza je nastavljena na uzorku bez stršila. U suprotnom, pristupalo se analizi mjera simetričnosti i spljoštenosti te Q-Q prikaza nad početnim skupom podataka.

Ukoliko se pokazalo da distribucija varijable značajno odudara od normalne distribucije, daljni statistički postupci temeljili su se na neparametrijskoj statistici ili je parametrijski test dodatno provjeren neparametarskim testovima.

4.6.4 Linearna povezanost varijabli

U svrhu ispitivanja linearne povezanosti dviju varijabli računa se Pearsonov koeficijent *r* koji se za srednje jaku povezanost kreće između 0.2 i 0.6 (Meyers, Gans i Guarino, 2006, str. 114.). Ukoliko je koeficijent veći od 0.6, to ukazuje da promatrane zavisne varijable mjere zajednički konstrukt i da bi se eventualno mogli spojiti u jednu mjeru (Meyers, Gans i Guarino, 2006, str. 445). Drugi način ispitivanja linearne povezanosti je analiza dijagrama raspršenosti. Ukoliko par promatranih varijabli ima normalnu distribuciju i linearnu povezanost, tada će dijagram raspršenosti ima ovalan i eliptičan oblik (Meyers, Gans i Guarino, 2006, str. 69).

4.6.5 Homogenost varijanci

Homogenost varijanci podrazumijeva jednake varijance zavisne/zavisnih varijabli kroz sve nivoe nezavisne/nezavisnih varijabli i možemo ju promatrati u univarijatnom i multivarijatnom kontekstu. Ukoliko je riječ o univarijatnoj homogenosti variance, ona se provjeravala Levenovim testom kojim se testira nulta hipoteza o jednakosti varijancu, na nivou značajnosti od α=0.05. U multivarijatnom kontekstu koristi se Boxov M test koji u svrhu utvrđivanja homogenosti varijanci ispituje jednakost matrica varijanci-kovarijanci. Boxovim M testom testira se nulta hipoteza o jednakosti matrica varijanci-kovarijanci, na nivou značajnosti od α=0.05 (Meyers, Gans i Guarino, 2006, str. 70).

4.6.6 T-test

T-testom se analizira da li dva uzorka predstavljaju dvije različite populacije s različitim srednjim vrijednostima. T-test zahtjeva podatke iz intervalne skale i ispunjavanje sljedećih uvjeta:

- Normalna distribucija podataka,

- Homogenost varijanci.

Razlikujemo t-test za zavisne i t-test za nezavisne uzorke.

4.6.7 Wilcoxonov test

U slučaju kada, tijekom provođenja t-testa za zavisne uzorke, nije ispunjen uvjet normalne distribucije, koristi se neparametrijska inačica t-testa za zavisne uzorke, odnosno, Wilcoxonov test (Moder, 2010). Wilcoxonovim testom analizira se jednakost medijana dvaju simetrično raspoređenih osnovnih skupova.

4.6.8 Analiza varijance (ANOVA)

Analiza varijance je korištena kako bi se utvrdio utjecaj nezavisnih varijabli na jednu zavisnu varijablu. Nezavisne varijable najčešće su kategorijske varijable s barem dva nivoa, dok je zavisna varijabla numerička varijabla mjerena na racionalnoj ili intervalnoj skali (Sheskin, 2004, str. 655). Ukoliko se u analizi koristi samo jedna nezavisna varijabla, tada je riječ o jednosmjerrnoj analizi varijance, a ukoliko je riječ o dvije ili više nezavisnih varijabli, tada se radi o faktorskoj analizi varijance.

Preduvjeti za provedbu ANOVE (Sheskin, 2004, str. 655):

- Univarijatna normalna distribucija podataka,
- Homogenost varijanci.

Nakon utvrđivanja jesu li potrebni uvjeti zadovoljeni, analizirani su dobiveni rezultati za glavne efekte i interakcije. Ukoliko se pokaže da postoji statistički značajan glavni efekti i ukoliko barem jedna nezavisna varijabla ima više od dvije kategorije, tada se provode post-hoc testovi kako bi se utvrdilo između kojih točno skupina postoji statistički značajna razlika. Najčešće korišten post-hoc test je Tukeyev test (Sheski, 2004, str. 885).

4.6.8.1 Faktorska analiza varijance s ponovljenim mjerenjima

ANOVA s ponovljenim mjerenjima podrazumijeva da je barem jedna nezavisna varijabla mjerena u barem dva vremenska intervala, čime se ta nezavisna varijabla definira kao ponavljajući faktor, odnosno varijabla mjerena unutar subjekata. Preostale nezavisne varijable tada predstavljaju varijable mjerene između subjekata (Sheskin, 2004, str. 910).

4.6.8.2 Welchova ANOVA

U slučaju kada, tijekom analize varijance, nije ispunjen uvjet o homogenosti varijanci, a podaci ne odudaraju značajno od normalne distribucije, koristi se neparametrijska inačica ANOVE, odnosno, Welchova ANOVA (Moder, 2010).

4.6.8.3 Kruskal-Wallis test

U slučaju kada, tijekom analize varijance, nije ispunjen uvjet normalne distribucije, koristi se neparametrijska inačica ANOVE sa podacima koji su zamjenjei rangovima, odnosno, Kruskal-Wallis test (Moder, 2010).

4.6.9 Faktorska multivarijatna analiza varijance (MANOVA) s ponovljenim mjerenjima

Faktorska multivarijatna analiza varijance (MANOVA) s ponovljenim mjerenjima korištena je kako bi se ispitao istovremeni utjecaj dvije ili više nezavisnih varijabli na dvije ili više zavisnih varijabli (Meyers, Gans i Guarino, 2006, str. 439). Nezavisne varijable najčešće su kategorijske varijable s barem dva nivoa, dok su zavisne varijable numeričke s racionalnim ili intervalnim skalama (Meyers, Gans i Guarino, 2006, str.25). MANOVA s ponovljenim mjerenjima podrazumijeva da je barem jedna nezavisna varijabla mjerena u barem dva vremenska intervala, čime se ta nezavisna varijabla definira kao ponavljajući faktor, odnosno varijabla mjerena unutar subjekata. Preostale nezavisne varijable tada predstavljaju varijable mjerene između subjekata (Meyers, Gans i Guarino, 2006, str. 28).

Potrebni uvjeti za provođenje MANOVE su (Meyers, Gans i Guarino, 2006, str. 67):

- Univarijatna i multivarijatna normalna distribucija podataka,
- Linerana povezanost varijabli,
- Homogenost varijanci.

Nakon utvrđivanja jesu li potrebni uvjeti zadovoljeni, analizirani su dobiveni rezultati za multivarijatne glavne efekte i interakcije. Ukoliko Boxov M test nije statistički značajan, u analizi je moguće koristiti bilo koji od ponuđenih testova, iako je Wilksov lambda test najčešće korišten (Meyers i sur., 2006, str. 456). Ukoliko se pokaže da postoji statistički značajan glavni efekt, tada se provode zasebne analize varijance (ANOVE) (Meyers i sur., 2006, str. 459).

4.6.10 Eta (η) koeficijent korelacije

Eta (η) koeficijent predstavlja mjeru nelinearne povezanosti između kategorijske i intervalne varijable, dok kvadrirana eta (η^2) predstavlja indeks koji se koristi za procjenu u kojoj mjeri se varijanca zavisne varijable može objasniti pomoću nezavisne varijable (Kennedy, 1970). Eta (η) koeficijent manji od 0.3 smatra se pokazateljem slabe povezanosti[4].

4.6.11 Hipoteza H1

Analiza se provela na temelju podataka prikupljenih uz pomoć upitnika SPTKTT o samoprocjeni vlastitih znanja o primjeni tehnologije u nastavi među populacijom hrvatskih učiteljima i nastavnika u praksi obuhvaćenih Uzorkom 1.

Nakon popunjavanja podatka koji nedostaju, varijable su grupirane u podskale upitnika: TK, CK, PK, PCK, TCK, TPK, TPACK. Definirane su dvije varijable *Tehnologija* i *Bez tehnologije* koje objedinjuju podskale upitnika koje se odnose na znanja o primjeni tehnologije (TK, TCK, TPK, TPACK), odnosno podskale upitnika koje se odnose isključivo na pedagoška i predmetna znanja (CK, PK, CPK).

T-testom za zavisne uzorke, na razini značajnosti $\alpha=0.05$ ispitala se percepcija vlastitih znanja o primjeni IKT-a u nastavi među hrvatskim učiteljima i nastavnicima, a rezultati su, zbog neodređenosti po pitanju normalne distribucije podataka, dodatno provjereni neparametrijskom inačicom t-testa za zavisne uzorke, Wilcoxonovim testom.

4.6.12 Multivarijantna analiza varijance

Multivarijantnom analizom varijance, na razini značajnosti $\alpha=0.05$, ispitalo se postoji li razlika u pomaku prema dubokom pristupu učenju i percepciji budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi, u odnosu na sudjelovanje u procesu samoprocjene i vršnjačke procjene, prije i poslije sudjelovanja u samoprocjeni i vršnjačkoj procjeni.

Analiza se provela na podacima iz Uzorka 2 prikupljenih tijekom provedbe eksperimenta s faktorskim dizajnom te na temelju podataka prikupljenih uz pomoć upitnika RASI i upitnika SPTKTT provedenog prije i poslije provedbe eksperimenta. Iako se Uzorak 2 sastojao od 495 ispitanika, rasipanje uzorka tijekom eksperimenat je bilo značajno te su u analizu uključeni samo oni podaci koji su prikupljeni na temelju ispitanika koji su odradili sve faze eksperimenta

[4] https://psytistics.com/tests/eta

i popunili upitnik i prije i poslije eksperimenta, tj. na temelju podataka dobivenih od 196 ispitanika iz Uzorka 2.

Multivarijantna analiza varijance provedena je nad nezavisnim varijablama *Samoprocjena (S)*, *Vršnjačka procjena (V)* i *Vrijeme (T)* te zavisnim varijablama *Duboki (D) i TPACK*. Varijable *Samoprocjena* i *Vršnjačka procjena* imaju dva nivoa: *uključena (u)* i *nije uključena (nu)*, varijabla *Vrijeme (T)* također ima dva nivoa: *prije* i *poslije*. Varijable *Samoprocjena* i *Vršnjačka procjena* mjere se između subjekata, dok se varijabla *Vrijeme* mjeri unutar subjekata. Iz navedenog zaključujemo da je riječ o faktorskoj 2x2x2 anovi s ponovljenim mjerenjem na varijabli *Vrijeme* (Tablica 11).

Tablica 11. Faktorijalna 2x2x2 anova s faktorima: Samoprocjena (S) s nivoima uključna (u) i nije uključena (nu), Vršnjačka procjena (V) s nivoima uključna (u) i nije uključena (nu) te ponovljenim mjerenjem na faktoru Vrijeme_poslije-Vrijeme_prije ($T_{poslije}$-T_{prije}) te zavisnim varijablama Duboki (D) i TPACK

PROCJENA		$T_{poslije}$-T_{prije}	
S_u	V_u	$D_{u,u,\ poslije}$- $D_{u,u,\ prije}$	$TPACK_{u,u,\ poslije}$- $TPACK_{u,u,\ prije}$
	V_{nu}	$D_{u,nu,\ poslije}$- $D_{u,nu,\ prije}$	$TPACK_{u,nu,\ poslije}$- $TPACK_{u,nu,\ prije}$
S_{nu}	V_u	$D_{nu,u,\ poslije}$- $D_{nu,u,\ prije}$	$TPACK_{nu,u,\ poslije}$- $TPACK_{nu,u,\ prije}$
	V_{nu}	$D_{nu,nu,\ poslije}$- $D_{nu,nu,\ prije}$	$TPACK_{nu,nu,\ poslije}$- $TPACK_{nu,nu,\ prije}$

4.6.13 Hipoteza H2

Tro-faktorskom analizom varijance s ponovljenim mjerenjem, na razini značajnosti α=0.05 ispitalo se postoji li razlika u pomaku prema dubokom pristupu učenju u odnosu na sudjelovanje u procesu samoprocjene i vršnjačke procjene, prije i poslije sudjelovanja u samoprocjeni i vršnjačkoj procjeni.

Analiza se provela na podacima iz Uzorka 2 prikupljenih tijekom provedbe eksperimenta s faktorskim dizajnom te na temelju podataka prikupljenih uz pomoć upitnika RASI provedenog prije i poslije provedbe eksperimenta. Iako se Uzorak 2 sastojao od 495 ispitanika, rasipanje uzorka tijekom eksperimenat je bilo značajno te su u analizu uključeni samo oni podaci koji su prikupljeni na temelju ispitanika koji su odradili sve faze eksperimenta i popunili upitnik i prije i poslije eksperimenta, tj. na temelju podataka dobivenih od 196 ispitanika iz Uzorka 2.

Faktore u ovoj tro-faktorskoj analizi varijance predstavljaju nezavisne varijable *Samoprocjena (S)*, *Vršnjačka procjena (V)* i *Vrijeme (T)* te zavisna varijabla *Duboki (D).* Varijable *Samoprocjena* i *Vršnjačka procjena* imaju dva nivoa: *uključena (u)* i *nije uključena (nu)*, varijabla *Vrijeme (T)* također ima dva nivoa: *prije* i *poslije*. Varijable *Samoprocjena* i *Vršnjačka*

procjena mjere se između subjekata, dok se varijabla *Vrijeme* mjeri unutar subjekata. Iz navedenog zaključujemo da je riječ o faktorskoj 2x2x2 anovi s ponovljenim mjerenjem na varijabli *Vrijeme* (Tablica 11).

Tablica 12. Faktorijalna 2x2x2 anova s faktorima: Samoprocjena (S) s nivoima uključna (u) i nije uključena (nu), Vršnjačka procjena (V) s nivoima uključna (u) i nije uključena (nu) te ponovljenim mjerenjem na faktoru Vrijeme (T) s nivoima prije i poslije te zavisnom varijabom Duboki (D)

		T_{prije}	$T_{poslije}$
S_u	V_u	$D_{u,u,\ prije}$	$D_{u,u,\ poslije}$
	V_{nu}	$D_{u,nu,\ prije}$	$D_{u,nu,\ poslije}$
S_{nu}	V_u	$D_{nu,u,\ prije}$	$D_{nu,u,\ poslije}$
	V_{nu}	$D_{nu,nu,\ prije}$	$D_{nu,nu,\ poslije}$

Ispitan je i utjecaj spola, studijske godine, razine studija i znanstvenog područja kolegija na duboki pristup učenju prije i poslije sudjelovanja u procesu samoprocjene i/ili vršnjačke procjene. Za svaku od navedenih varijabli provedena je zasebna dvo-faktorska analiza varijance s ponovljenim mjerenjima, na nivou značajnosti α=0.05:

- Dvo-faktorskom analizom varijance s ponovljenim mjerenjem se ispitalo postoji li razlika u pomaku prema dubokom pristupu učenju u odnosu na spol, prije i poslije sudjelovanja u eksperimentu. Faktore u ovoj dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Spol* i *Vrijeme* te zavisna varijabla *Duboki*. Varijabla *Spol* ima dva nivoa: *muški* i *ženski*. Varijabla *Spol* mjeri se između subjekata, dok se varijabla *Vrijeme* mjeri unutar subjekata. Iz navedenog zaključujemo da je riječ o faktorijalnoj 2x2 anovi s ponovljenim mjerenjem na varijabli *Vrijeme*.

- Dvo-faktorskom analizom varijance s ponovljenim mjerenjem se ispitalo postoji li razlika u pomaku prema dubokom pristupu učenju u odnosu na studijsku godinu, prije i poslije sudjelovanja u eksperimentu. Faktore u ovoj dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Studijska godina* i *Vrijeme* te zavisna varijabla *Duboki*. Varijabla *Studijska godina* ima pet nivoa: *prva, druga, treća, četvrta i peta*. Varijabla *Studijska godina* mjeri se između subjekata, dok se varijabla *Vrijeme* mjeri unutar subjekata. Iz navedenog zaključujemo da je riječ o faktorijalnoj 2x2 anovi s ponovljenim mjerenjem na varijabli *Vrijeme*.

- Dvo-faktorskom analizom varijance s ponovljenim mjerenjem se ispitalo postoji li razlika u pomaku prema dubokom pristupu učenju u odnosu na razinu studija, prije i

poslije sudjelovanja u eksperimentu. Faktore u ovoj dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Razina studija* i *Vrijeme* te zavisne varijable *Duboki*. Varijabla *Razina studija* ima dva nivoa: *preddiplomski i diplomski*. Varijabla *Razina studija* mjeri se između subjekata, dok se varijabla *Vrijeme* mjeri unutar subjekata. Iz navedenog zaključujemo da je riječ o faktorijalnoj 2x2 anovi s ponovljenim mjerenjem na varijabli *Vrijeme*.

- Dvo-faktorskom analizom varijance s ponovljenim mjerenjem se ispitalo postoji li razlika u pomaku prema dubokom pristupu učenju u odnosu na znanstveno područje kolegija, prije i poslije sudjelovanja u eksperimentu. Faktore u ovoj dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Znanstveno područje kolegija* i *Vrijeme* te zavisna varijabla *Duboki*. Varijabla *Znanstveno područje kolegija* ima devet nivoa: *Prirodne znanosti, Tehničke znanosti, Biomedicina i zdravstvo, Biotehničke znanosti, Društvene znanosti, Humanističke znanosti, Umjetničko područje, Interdisciplinarna područja znanosti* i *Interdisciplinarna područja umjetnosti*. Varijabla *Znanstveno područje kolegija* mjere se između subjekata, dok se varijabla *Vrijeme* mjeri unutar subjekata. Iz navedenog zaključujemo da je riječ o faktorijalnoj 2x2 anovi s ponovljenim mjerenjem na varijabli *Vrijeme*.

Ukoliko je pitanje normalne distribucije varijable neodređeno, statistička značajnost dodatno je ispitana neparametrijskim testom za zavisne uzorke, Kruskal Wallis testom nad razlikom varijabli prije i poslije sudjelovanjau eksperimentu. Ukoliko nije zadovoljen uvjet homogenosti varijance statistička značajnost je ispitana neparametrijskom inačicom ANOVE, Welch ANOVOM.

4.6.14 Hipoteza H3

U svrhu ispitivanja povezanost između pristupa učenju koji student uobičajeno primjenjuje, odnosno kategorijske varijable *Pristup učenju*, i pouzdanosti kriterijske procjene rješenja problemskog zadatka, odnosno intervalne varijable *Dijametar kvazi - pouzdanosti*, koristili su se eta koeficijent i kvadrirani eta koeficijent.

Analiza podataka za Hipotezu H3 se provela na ispitanicima iz Uzorka 2 prikupljenih tijekom provedbe eksperimenta s faktorskim dizajnom. Iako se Uzorak 2 sastoji od 495 ispitanika, rasipanje uzorka tijekom eksperimenat je bilo značajno te su u analizu uključeni samo oni podaci koji su prikupljeni na temelju ispitanika koji su odradili sve faze eksperimenta i popunili

upitnik i prije i poslije eksperimenta. Pošto se za ispitanike koji nisu sudjelovali niti u samoprocjeni niti u vršnjačkoj procjeni ne može odrediti Dijametar kvazi - pouzdanosti, oni su također isključeni iz skupa podataka na kojima je testirana ova hipoteza. U konačnici, hipoteza H3 testirana je na temelju podataka dobivenih od 150 ispitanika iz Uzorka 2.

Osim eta i kvadriranim eta koeficijentom, utjecaj pristupa učenju na *Dijametar kvazi - pouzdanosti* ispitan je i analizom varijance, na razini značajnosti od α=0.05.

Ispitan je i utjecaj oblika procjene u kojoj su studenti sudjelovali, sudjelovanja u samoprocjeni i vršnjačkoj procjeni kao i utjecaj spola, studijske godine, razine studija i znanstvenog područja kolegija na *Dijametar kvazi - pouzdanosti*. Za svaku od navedenih varijabli provedena je zasebna analiza varijance, na nivou značajnosti od α=0.05.

4.6.15 Hipoteza H4

Tro-faktorskom analizom varijance s ponovljenim mjerenjima, na razini značajnost od α=0.05, ispitalo se postoji li razlika u percepciju budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi u odnosu na sudjelovanje u procesu samoprocjene i vršnjačke procjene.

Kao i kod Hipoteze H2, analiza podataka za Hipotezu H4 se provela na podacima iz Uzorka 2 prikupljenih tijekom provedbe eksperimenta s faktorskim dizajnom te na temelju podataka prikupljenih uz pomoć upitnika SPTKTT provedenog prije i poslije provedbe eksperimenta. Iako se Uzorak 2 sastoji od 495 ispitanika, rasipanje uzorka tijekom eksperimenat je bilo značajno te su u analizu uključeni samo oni podaci koji su prikupljeni na temelju ispitanika koji su odradili sve faze eksperimenta i popunili upitnik i prije i poslije eksperimenta, tj. na temelju podataka dobivenih od 196 ispitanika iz Uzorka 2.

Faktore u ovoj tro-faktorskoj analizi varijance predstavljaju nezavisne varijable *Samoprocjena (S), Vršnjačka procjena (V)* i *Vrijeme (T)* te zavisna varijabla *TPACK (TPACK).* Varijable *Samoprocjena* i *Vršnjačka procjena* imaju dva nivoa: *uključena (u)* i *nije uključena (nu)*, varijabla *Vrijeme (T)* također ima dva nivoa: *prije* i *poslije*. Varijable *Samoprocjena* i *Vršnjačka procjena* mjere se između subjekata, dok se varijabla *Vrijeme* mjeri unutar subjekata. Iz navedenog zaključujemo da je riječ o faktorskoj 2x2x2 anovi s ponovljenim mjerenjem na varijabli *Vrijeme* (Tablica 12).

Tablica 13. Faktorijalna 2x2x2 anova s faktorima: Samoprocjena (S) s nivoima uključna (u) i nije uključena (nu), Vršnjačka procjena (V) s nivoima uključna (u) i nije uključena (nu) te ponovljenim mjerenjem na faktoru Vrijeme (T) s nivoima prije i poslije te zavisnom varijabom TPACK (TPACK)

		T_{prije}	$T_{poslije}$
S_u	V_u	$TPACK_{u,u,\ prije}$	$TPACK_{u,u,\ poslije}$
	V_{nu}	$TPACK_{u,nu,\ prije}$	$TPACK_{u,nu,\ poslije}$
S_{nu}	V_u	$TPACK_{nu,u,\ prije}$	$TPACK_{nu,u,\ poslije}$
	V_{nu}	$TPACK_{nu,nu,\ prije}$	$TPACK_{nu,nu,\ poslije}$

Ispitan je i utjecaj spola, studijske godine, razine studija i znanstvenog područja kolegija na percepciju budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi, prije i poslije sudjelovanja u procesu samoprocjene i/ili vršnjačke procjene. Za svaku od navedenih varijabli provedena je zasebna dvo-faktorska analiza varijance s ponovljenim mjerenjima, na nivou značajnosti od α=0.05:

- Dvo-faktorskom analizom varijance s ponovljenim mjerenjem se ispitalo postoji li razlika u percepciju budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi u odnosu na spol, prije i poslije sudjelovanja u eksperimentu. Faktore u ovoj dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Spol* i *Vrijeme* te zavisna varijabla *TPACK*. Varijabla *Spol* ima dva nivoa: *muški* i *ženski*. Varijabla *Spol* mjeri se između subjekata, dok se varijabla *Vrijeme* mjeri unutar subjekata. Iz navedenog zaključujemo da je riječ o faktorijalnoj 2x2 anovi s ponovljenim mjerenjem na varijabli *Vrijeme*.

- Dvo-faktorskom analizom varijance s ponovljenim mjerenjem se ispitalo postoji li razlika u percepciji budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi u odnosu na studijsku godinu, prije i poslije sudjelovanja u eksperimentu. Faktore u ovoj dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Studijska godina* i *Vrijeme* te zavisna varijabla *TPACK*. Varijabla *Studijska godina* ima pet nivoa: *prva, druga, treća, četvrta i peta*. Varijabla *Studijska godina* mjeri se između subjekata, dok se varijabla *Vrijeme* mjeri unutar subjekata. Iz navedenog zaključujemo da je riječ o faktorijalnoj 2x2 anovi s ponovljenim mjerenjem na varijabli *Vrijeme*.

- Dvo-faktorskom analizom varijance s ponovljenim mjerenjem se ispitalo postoji li razlika u percepciji budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi u odnosu na razinu studija, prije i poslije sudjelovanja u eksperimentu. Faktore u ovoj

dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Razina studija* i *Vrijeme* te zavisne varijable *TPACK*. Varijabla *Razina studija* ima dva nivoa: *preddiplomski i diplomski*. Varijabla *Razina studija* mjeri se između subjekata, dok se varijabla *Vrijeme* mjeri unutar subjekata. Iz navedenog zaključujemo da je riječ o faktorijalnoj 2x2 anovi s ponovljenim mjerenjem na varijabli *Vrijeme*.

- Dvo-faktorskom analizom varijance s ponovljenim mjerenjem se ispitalo postoji li razlika u percepciji budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi u odnosu na znanstveno područje kolegija, prije i poslije sudjelovanja u eksperimentu. Faktore u ovoj dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Znanstveno područje kolegija* i *Vrijeme* te zavisna varijabla *TPACK*. Varijabla *Znanstveno područje kolegija* ima devet nivoa: *Prirodne znanosti, Tehničke znanosti, Biomedicina i zdravstvo, Biotehničke znanosti, Društvene znanosti, Humanističke znanosti, Umjetničko područje, Interdisciplinarna područja znanosti* i *Interdisciplinarna područja umjetnosti*. Varijabla *Znanstveno područje kolegija* mjere se između subjekata, dok se varijabla *Vrijeme* mjeri unutar subjekata. Iz navedenog zaključujemo da je riječ o faktorijalnoj 2x2 anovi s ponovljenim mjerenjem na varijabli *Vrijeme*.

Ukoliko je pitanje normalne distribucije varijable neodređeno, statistička značajnost dodatno je ispitana neparametrijskim testom za zavisne uzorke, Kruskal Wallis testom nad razlikom varijabli prije i poslije sudjelovanjau eksperimentu. Ukoliko nije zadovoljen uvjet homogenosti varijance statistička značajnost je ispitana neparametrijskom inačicom ANOVE, Welch ANOVOM.

4.7 Mišljenje studenata o sudjelovanju u procesu procjene i samoprocjene

Na kraju je istraživanja studentima pružena mogućnost iskazivanja vlastitog mišljenja o sudjelovanju u vršnjačkoj kriterijskoj procjeni i/ili samoprocjeni rješenja problemskog zadatka putem otvorenog pitanja (Slika 1010).

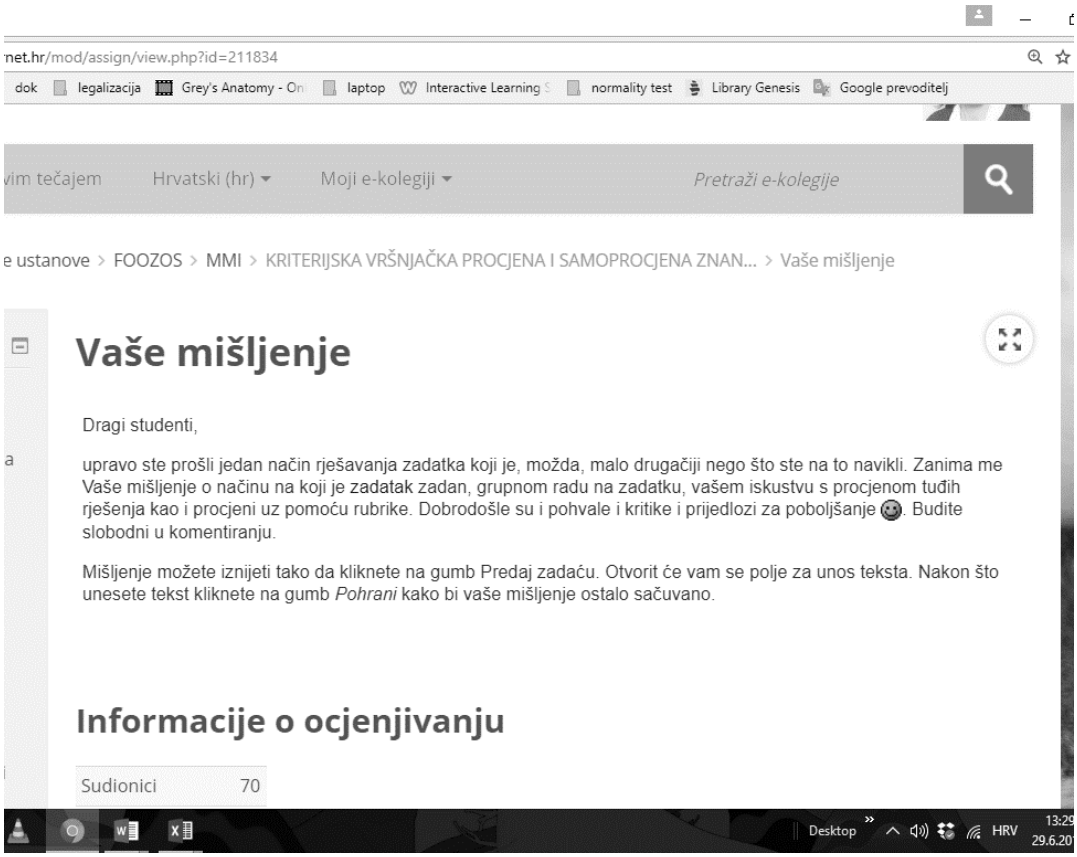

Slika 10. Otvoreno pitanje postavljeno na sustav za upravljanje učenjem Moodle u svrhu prikupljanja mišljenja studenata

Mišljene studenata prikupljeno je od ispitanka iz Uzorka 2. Od ukupno 299 studenata, koji su sudjelovali u nekom od koraka kvazi eksperimenta, svoje mišljenje o zadatku i procjeni iskazalo je njih 82 (Tablica 13).

Općeniti dojam o zadatku, načinu rješavanja i procjeni prikazan je pomoću tri kategorije:

- Pozitivan – u komentaru su istaknuti samo pozitivni elementi
- Negativan - u komentaru su istaknuti samo negativni elementi
- Pozitivan i negativan - u komentaru su istaknuti i pozitivni i negativni elementi.

Tablica 14. Prikaz broja studenata, po kolegijima, koji su sudjelovali u eksperimentu i broj studenata koji su iskazali svoje mišljenje o sudjelovanju

KOLEGIJ	BROJ STUDENATA KOJI JE SUDJELOVAO U NEKOM KORAKU KVAZI EKSPERIMENTA	BROJ STUDENATA KOJI JE ISKAZAO SVOJE MIŠLJENJE
Programski jezik Logo	17	4
Statistika	3	0
Engleski jezik	19	3
Metodologija pedagoškog istraživanja	28	5
Prirodno geografska obilježja Hrvatske	78	20
Metodika matematika I (Osijek)	63	13
Metodika matematike I (Slavonski Brod)	29	12
Uvod u baze podataka (Zagreb)	21	5
Uvod u baze podataka (Čakovec)	20	12
Programiranje (Čakovec)	21	8
UKUPNO	**299**	**82**

5 REZULTATI ISTRAŽIVANJA

5.1 Proširenje i validacija upitnika RASI

U ovom poglavlju predstavljani su rezultati proširenja upitnika RASI, deskriptivni podaci svih čestica proširenog upitnika RASI te rezultati validacije istog.

5.1.1 Proširenje upitnika RASI

Nakon prijevoda originalnog upitnika RASI isti je proširen česticama koje se odnose na složenije i problemske zadatke. Sveukupno je dodano 14 čestica (Tablica 14), 13 čestica dodano je od strane tri osobe upućene u problematiku pristupa učenju kod studenata dok je jedna čestica dodana tijekom fokus grupa od strane studenta. Čestice su grupirane u odnosu na pristup učenju na koji se odnose. U konačnici, prošireni upitnik RASI sastojao se od 66 čestica.

Tablica 15. Čestice dodane u upitnik RASI u kontekstu problemskih i složenih zadataka grupirane u odnosu na pristup učenju na koji se odnose

Čestica	Tekst čestice
DUBOKI PRISTUP UČENJU	
R54	Tijekom rješavanja problema i zadataka pokušavam upotrijebiti ideje i teoriju naučenu u ovom i ostalim kolegijima.
R55	Ponekad se uhvatim da oko sebe tražim probleme koje bih riješio uz pomoć teorije i vještina koje sam stekao tijekom učenja.
R56	Rad na problemima i zadacima inspirira me za istraživanje novih ideja i izvora.
R63	Važno mi je da je rješenje danog problema ili složenog zadatka kreativno.
R65	Rješavanje problema često me vodi do nekoliko različitih rješenja.
STRATEŠKI PRISTUP UČENJU	
R53	Pažljivo razmatram zadani problem i pokušam pronaći vlastitu strategiju njegovog rješavanja.
R59	Smatram da je rad na problemima i zadacima koristan za moje učenje i profesionalni razvoj.
R61	Volim raspraviti problem s kolegama/nastavnicima prije nego odredim vlastitu strategiju.
R62	Uspoređujem vlastitu strategiju rješavanja problema sa strategijama drugih.
POVRŠINSKI PRISTUP UČENJU	
R57	Rješavanje problema ne nagrađuje se dovoljnim brojem bodova.
R58	Frustrira me kada me traže da riješim problem ili složeni zadatak jer ne mogu isplanirati vrijeme koje ću utrošiti na njegovo rješavanje.
R60	Teško mi je objasniti vlastitu strategiju rješavanja problema i njegove rezultate.
R64	Rješavanje problema i ostalih složenih zadataka mi je vrlo stresno.
R66	Teško mi je fokusirati se na zadani zadatak ako ne vidim osobni interes u njemu.

5.1.1 Validacija upitnika RASI

Validacija upitnika RASI provedena je konfirmatornom faktorskom analizom uz pomoć softvera za strukturalno programiranje LISREL 9.1.

Prije provedbe konfirmatorne faktorske analize, izračunati su Kaiser-Meyer-Olkinova mjera (KMO) te Bartlettov test sfericiteta kako bi se utvrdilo je li uzorak valjan za primjenu faktorske analize. Za promatrani uzorak Kaiser-Meyer-Olkinova mjera (KMO= 0.917) (Kaiser, 1974.) i Bartlettov test sfericiteta (χ^2=14835.403, df=2145, p=0.00) ukazuju da postoje preduvjeti za provedbu faktorske analize.

Nakon prvotno provedene konfirmatorne faktorske analize, koeficijenti opterećenja su se kretali od -0.04 do 0.83, pri čemu su faktorska opterećenja za tri čestice bila manja od 0.32, za R28 je faktorsko opterećenje bilo 0.28, za R38 je bilo -0.04 te za R51 je bilo 0.19. Dobiveni su sljedeći pokazatelji dobrog pristajanja modela i empirijskih podataka: $\chi2$ = 4973.29, p = 0.0000, df = 1871, $\chi2$/df = 2.66, RMSEA = 0.049s intervalom pouzdanosti (0.0475; 0.0509), SRMR = 0.0744, CFI = 0.756, PNFI = 0.633. Čestice s faktorskim opterećenjima manjim od 0.32 isključene su iz upitnika (Tabarnich i Fidel, 2013) te je ponovno provedena konfirmatorna faktorska analiza nad preostalim česticama.

Nakon isključenja čestica R28, R38 te R51, koeficijenti opterećenja su se kretali od 0.32 do 0.83 (Tablica 15) te su dobiveni sljedeći pokazatelji dobrog pristajanja modela i empirijskih podataka: χ^2 = 4973.29, p = 0.0000, df = 1871, $\chi2$/df = 2.66, RMSEA = 0.049 s intervalom pouzdanosti (0.0475 ; 0.0509), SRMR = 0.074, CFI = 0.756, PNFI = 0.633. Pošto su RMSEA ≤ 0,06 i SRMR ≤ 0,09, prema Hu i Bentler (1999), ovi empirijski podaci dobro odgovaraju predloženoj faktorskoj strukturi, čime je ovaj model potvrđen (Slika 11).

Matrica korelacija (Tablica 16) sugerira da postoji određena povezanost između pojedinih faktora, odnosno domena upitnika. U tablici su istaknute statistički značajne korelacije ($p<0.05$). Uočena je korelacije između domena Strateški i Dubinski koja upućuje na visoku korelaciju (Hinkle i sur., 2003).

5.1.2 Deskriptnivni podaci čestica proširenog upitnika RASI

Tablica 17 prikazuje deskriptivnu statistiku uzorka za svaku česticu i podskalu upitnika RASI te uključuje aritmetičku sredinu, standardnu devijaciju, mjeru asimentričnosti s pripadnom standardnom pogreškom, mjeru zaobljenosti s pripadnom standardnom pogreškom,

item-total korelacija u odnosu na cijelu skalu te item-total korelacija u odnosu na odgovarajuću podskalu.

Tablica 16. Raspon koeficijenata opterećenja za svaku domenu i poddomenu upitnika RASI

Domena upitnika RASI	***Raspon koeficijenata opterećenja***
Traženje smisla (SM)	0.38 – 0.59
Povezivanje ideja (RI)	0.35 – 0.66
Upotreba dokaza (UE)	0.45 – 0.49
Zanimanje za ideje (II)	0.59 – 0.65
Praćenje napretka (ME)	0.49 – 0.55
Rješavanje problema_dubinski (PS_DEEP)	0.36 – 0.75
Duboki pristup (DEEP)	**0.86 – 1.0**
Organizacija učenja (OS)	0.45 – 0.60
Upravljanje vremenom (TM)	0.45 – 0.68
Postignuće (ACH)	0.33 – 0.62
Oprez u odnosu na procjenu (AAD)	0.32 – 0.69
Rješavanje problema_STRATEŠKI (PS_STRAT)	0.41 – 0.55
Starteški pristup (STRATEGIC)	**0.76 -1.03**
Nedostatak svrhe (LP)	0.57 – 0.61
Nepovezano memoriranje (UM)	0.36 – 0.64
Strah od neuspjeha (FF)	0.59 – 0.68
Ograničenja programa (SB)	0.72 – 0.85
Rješavanje problema_POVRŠINKI (PS_SURF)	0.35 – 0.68
Površinski pristup (SURFACE)	**0.54 – 0.92**

Tablica 17. Matrica korelacija među domenama SPTKTT upitnika

	Duboki (DEEP)	**Strateški (STRAT)**	**Površinski (SURF)**
Duboki (DEEP)	1.00		
Strateški (STRAT)	**0.782 (0.025)**	1.00	
Površinski (SURF)	-0.242 (0.052)	-0.298 (0.052)	1.00

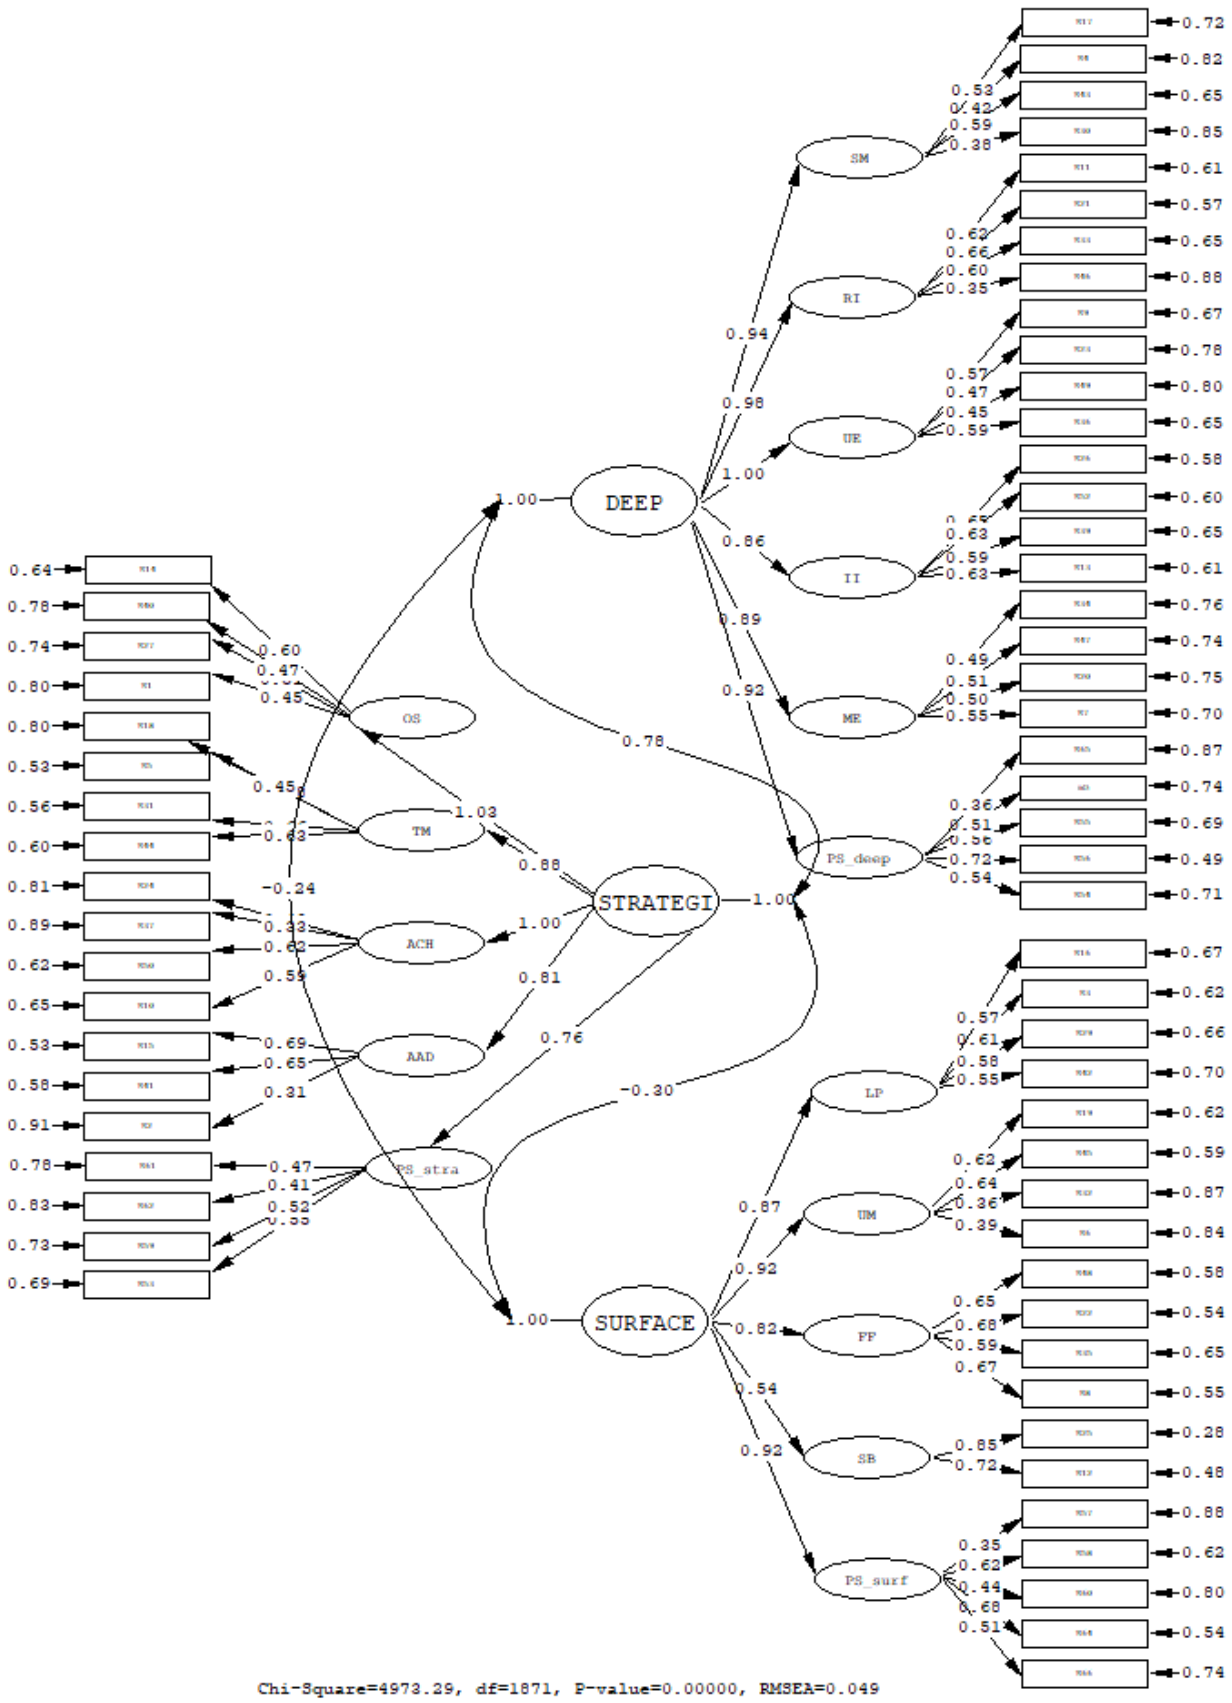

Slika 11. Konfirmatorna faktorska analiza proširenog RASI upitnika, na temelju17 podsala grupiranih u tri pristupa učenju: ***Duboki pristup (DEEP)*** *– traženje smisla (SM), povezivanje ideja (RI), upotreba dokaza (UE), zanimanje za ideje (II), praćenje apretka (ME) i prblemski_duboki (PS_deep);* ***Strateški pristup (STRATEGI)*** *– organizacija učenja (OS), upravljanjevremenom (TM), postignće ACH), oprez u odnosu na procjenu (AAD) i problemski_strateški (PS_stra);* ***Površinski pristup (SURFACE)*** *– nedostatak svrhe (LP), nepovezano memorranje (UM), ograničenja programa (SB), strah od neuspjeha (FF) i problemski_površinski (PS_surf). Čestice proširenog upitnika RASI označe su redom R1-R66*

Tablica 18. Deskriptivna statistika čestica i podskala upitnika RASI (aritmetička sredina, standardna devijacija, mjeru asimentričnosti s pripadnom standardnom pogreškom, mjeru zaobljenosti s pripadnom standardnom pogreškom, item-total korelacija u odnosu na cijelu skalu te item-total korelacija u odnosu na odgovarajuću podskalu) na uzorku od N=685 ispitanika

Čestica/ podskala	Aritmetička sredina	Standardna devijacija	Mjera asimetričnosti (SE=0.133)	Mjera zaobljenosti (SE=0.265)	Item-total korelacija (skala)	Item-total korelacija (podskala)
R4	4.36	0.69	-1.22	2.59	0.24	0.87
R17	3.79	0.85	-0.95	0.96	0.34	0.87
R30	3.49	1.00	-0.66	-0.19	0.35	0.87
R43	3.45	0.89	-0.50	-0.26	0.37	0.87
Traženje smisla (SM)	3.77	0.56	-0.67	1.51		
R11	3.81	0.87	-0.76	0.39	0.41	0.87
R21	3.60	0.85	-0.78	0.25	0.47	0.87
R33	2.94	0.96	0.07	-0.68	0.47	0.87
R46	3.63	0.96	-0.49	-0.47	0.28	0.87
Povezivanje ideja (RI)	3.50	0.63	-0.31	0.21		
R9	3.79	0.84	-0.79	0.53	0.39	0.87
R23	3.22	0.94	-0.13	-0.56	0.44	0.87
R36	3.48	0.82	-0.58	-0.23	0.50	0.87
R49	3.72	0.76	-0.85	0.73	0.34	0.87
Upotreba dokaza (UE)	3.55	0.56	-0.51	1.14		
R13	3.28	0.97	-0.31	-0.68	0.47	0.87
R26	3.56	0.91	-0.67	0.07	0.38	0.87
R39	3.80	0.78	-0.88	1.13	0.40	0.87
R52	3.14	1.02	-0.16	-0.72	0.42	0.87
Zanimanje za ideje (II)	3.44	0.68	-0.40	0.41		
R7	4.00	0.75	-0.79	1.00	0.37	0.87
R20	3.72	0.79	-0.76	0.66	0.43	0.87
R34	3.85	0.76	-1.03	1.63	0.34	0.87
R47	3.88	0.72	-0.94	1.55	0.39	0.87
Praćenje napretka (ME)	3.86	0.50	-0.61	1.72		
R54	3.77	0.74	-0.91	1.20	0.33	0.87
R55	3.36	0.96	-0.47	-0.45	0.43	0.87
R56	3.16	0.92	-0.08	-0.56	0.48	0.87
R63	3.34	0.99	-0.32	-0.43	0.42	0.87
R65	3.47	0.81	-0.58	0.02	0.40	0.87
Rješavanje problema_dubinski (PS_DEEP)	3.42	0.58	-0.25	0.51		
Duboki pristup (DEEP)	**3.59**	**0.46**	**-0.38**	**1.65**		
R1	3.91	0.70	-0.89	1.72	0.25	0.87
R14	3.43	0.99	-0.44	-0.58	0.36	0.87
R27	3.00	0.96	-0.01	-0.54	0.39	0.87
R40	3.69	1.11	-0.76	-0.23	0.36	0.87
Organizacija učenja (OS)	3.51	0.63	-0.52	0.59		
R5	3.48	1.07	-0.34	-0.78	0.41	0.87
R18	3.51	0.99	-0.46	-0.39	0.31	0.87
R31	3.06	1.10	-0.05	-0.82	0.34	0.87
R44	3.20	1.06	-0.33	-0.73	0.34	0.87
Upravljanje vremenom (TM)	3.31	0.76	-0.38	-0.34		
R10	3.75	0.98	-0.75	0.06	0.44	0.87
R24	4.17	0.77	-1.16	2.26	0.36	0.87
R37	3.99	0.82	-0.94	1.14	0.30	0.87
R50	3.01	1.06	-0.06	-0.77	0.32	0.87
Postignuće (ACH)	3.73	0.61	-0.48	0.68		
R2	3.11	1.06	-0.05	-0.96	0.32	0.87
R15	3.77	0.84	-0.85	0.74	0.46	0.87

R41	3.79	0.80	-0.71	0.49	0.41	0.87
Oprez u odnosu na procjenu (AAD)	3.56	0.64	-0.43	0.47		
R53	3.56	0.87	-0.61	0.05	0.38	0.87
R59	3.96	0.77	-0.86	1.34	0.29	0.87
R61	3.45	0.96	-0.65	-0.16	0.37	0.87
R62	3.62	0.87	-0.88	0.49	0.33	0.87
Rješavanje problema_strateški (PS_STRAT)	3.65	0.58	-0.57	1.01		
Strateški pristup (STRATEGIC)	**3.55**	**0.49**	**-0.49**	**0.93**		
R3	3.20	1.17	-0.13	-1.05	0.11	0.87
R16	2.35	0.94	0.76	0.18	-0.05	0.88
R29	2.61	1.26	0.40	-0.93	0.06	0.88
R42	2.56	1.04	0.31	-0.60	0.06	0.87
Nedostatak svrhe (LP)	2.68	0.78	0.14	-0.43		
R6	3.20	1.07	-0.24	-0.81	0.17	0.87
R19	2.40	0.88	0.55	0.14	0.05	0.87
R32	2.82	1.07	0.19	-0.89	0.28	0.87
R45	2.97	0.99	0.04	-0.72	0.08	0.87
Nepovezano memoriranje (UM)	2.85	0.66	-0.11	-0.10		
R8	3.51	1.08	-0.35	-0.76	0.21	0.87
R22	3.38	1.05	-0.48	-0.56	0.23	0.87
R53	3.45	1.19	-0.49	-0.76	0.30	0.87
R48	3.16	1.22	-0.20	-1.05	0.31	0.87
Strah od neuspjeha (FF)	3.37	0.86	-0.41	-0.36		
R12	2.90	1.11	0.04	-0.91	-0.04	0.88
R25	2.85	1.07	0.07	-0.85	-0.05	0.88
Ograničenja programa (SB)	2.87	0.98	0.03	-0.70		
R57	3.24	0.91	-0.02	-0.41	0.26	0.87
R58	3.08	1.01	-0.03	-0.68	0.26	0.87
R60	3.15	1.01	-0.05	-0.74	0.12	0.87
R64	2.91	0.98	0.15	-0.60	0.20	0.87
R66	3.24	1.10	-0.09	-0.88	0.01	0.88
Rješavanje problema_površinski (PS_SURF)	3.12	0.64	0.12	0.07		
Površinski pristup (SURFACE)	**2.98**	**0.57**	**-0.23**	**0.08**		

5.1.3 Pozdanost upitnika RASI

Unutarnja konzistencija upitnika RASI prikazana je Cronbachovim koeficijentom α u odnosu na sve podskale upitnika (Tablica 18). Cronbachov koeficijent α za cjelokupni upitnik je 0.88 što sugerira visoku pouzdanost mjernog instrumenta. Za podskale se Cronbachov koeficijent α kreće između 0.52 i 0.88 što sugerira privatljivu pouzdanost mjernog instrumenta. Cronbachov koeficijent α za tri osnovne podskale, duboki, strateški i površinski, su redom 0.88, 0.81 i 0.77 što predstavlja visoku pouzdanost tih skala.

Tablica 19. Cronbachov koeficijent α za svaku podskalu upittnika RASI

Podskala upitnika RASI	**Cronbachov koeficijent α**
Traženje smisla (SM)	0.52
Povezivanje ideja (RI)	0.64
Upotreba dokaza (UE)	0.59
Zanimanje za ideje (II)	0.72
Praćenje napretka (ME)	0.59
Rješavanje problema_dubinski (PS_DEEP)	0.66
Duboki pristup (DEEP)	0.88
Organizacija učenja (OS)	0.57
Upravljanje vremenom (TM)	0.69
Postignuće (ACH)	0.57
Oprez u odnosu na procjenu (AAD)	0.52
Rješavanje problema_STRATEŠKI (PS_STRAT)	0.57
Starteški pristup (STRATEGIC)	0.81
Nedostatak svrhe (LP)	0.66
Nepovezano memoriranje (UM)	0.55
Strah od neuspjeha (FF)	0.74
Ograničenja programa (SB)	0.76
Rješavanje problema_POVRŠINKI (PS_SURF)	0.64
Površinski pristup (SURFACE)	0.77

5.2 Upitnik SPTKTT

U ovom poglavlju predstavljani su rezultati validacije, deskriptivni podaci svih čestica i podskala te pouzdanosti upitnika SPTKTT.

5.2.1 Validacija upitnika SPTKTT

Validacija upitnika SPTKTT provedena je konfirmatornom faktorskom analizom uz pomoć softvera za strukturalno programiranje LISREL 9.1.

Prije provedbe konfirmatorne faktorske analize, izračunati su Kaiser-Meyer-Olkinova mjera (KMO) te Bartlettov test sfericiteta kako bi se utvrdilo je li uzorak valjan za primjenu faktorske analize. Za promatrani uzorak Kaiser-Meyer-Olkinova mjera (KMO= 0.916) (Kaiser, 1974.) i Bartlettov test sfericiteta (χ^2=10599.87, df=1081, p=0.00) ukazuju da postoje preduvjeti za provedbu faktorske analize.

Nakon prvotno provedene konfirmatorne faktorske analize, koeficijenti opterećenja su se kretali od 0.45 do 0.94 te su dobiveni sljedeći pokazatelji dobrog pristajanja modela i empirijskih podataka: $\chi2$ = 2900.28, p = 0.0000, df = 1010, $\chi2$/df = 2.87, RMSEA = 0.074 s intervalom pouzdanosti (0.0714 ; 0.0777), SRMR = 0.067, CFI = 0.81, PNFI = 0.69. Pokazatelji

modifikacije modela sugerirali su dodavanje pogreške kovarijance među pojedinim varijablama. U obzir su uzete samo pogreške kovarijance između varijabli koje pripadaju istom faktoru. Ovim unesenim promjenama popravili su se pokazatelji dobrog pristajanja.

Nakon dodavanja pogrešaka kovarijance, koeficijenti opterećenja su se kretali od -0.79 do 0.89 (Tablica 19) te su dobiveni sljedeći pokazatelji dobrog pristajanja modela i empirijskih podataka: $\chi2$ = 2255.94, p = 0.0000, df = 991, $\chi2$/df = 2.27, RMSEA = 0.061 s intervalom pouzdanosti (0.0582 ; 0.0649), SRMR = 0.061, CFI = 0.87, PNFI = 0.73.Pošto su RMSEA ≤ 0,06 i SRMR ≤ 0,09, prema Hu i Bentler (1999), ovi empirijski podaci dobro odgovaraju predloženoj faktorskoj strukturi, čime je ovaj model potvrđen.

Tablica 20. Raspon koeficijenata opterećenja za svaku domenu upitnika SPTKTT

Domena SPTKTT upitnika	***Raspon koeficijenata opterećenja***
Tehnološko Znanje (TK)	0.58 – 0.75
Sadržajno znanje (CK)	-0.79 – 0.57
Sadržajno Znanje – Matematika (CK_MATH)	0.67– 0.86
Sadržajno Znanje – Društvene znanosti i Znanost (CK_SSiSC)	0.52 – 0.85
Sadržajno Znanje – Pismenost (CK_LIT)	0.82 – 0.86
Pedagoško Znanje (PK)	0.56 – 0.79
Pedagoško Sadržajno Znanje (PCK)	0.69 – 0.89
Tehnološko Sadržajno Znanje (TCK)	0.72 – 0.83
Tehnološko Pedagoško Znanje (TPK)	0.49 – 0.79
Tehnološko Pedagoško Sadržajno Znanje (TPACK)	0.65 – 0.79

Matrica korelacija (Tablica 20) sugerira da postoje određena povezanost između pojedinih faktora, odnosno domena upitnika. U tablici su istaknute statistički značajne korelacije ($p<0.05$). Koeficijent korelacije između domena Pedagoška znanja i Pedagoško sadržajna znanja te Tehnološko Sadržajna znanja i Tehnološko Pedagoško Sadržajna znanja (TPACK) upućuje na visoku korelaciju, dok domene Tehnološko Pedagoška Znanja (TPK) i Tehnološko Pedagoško Sadržajna Znanja (TPACK) koreliraju s vrlo visokim koeficijentom korelacije. Domene Tehnološko Pedagoško Sadržajna Znanja (TPACK) i Tehnološka Znanja (TK) koreliraju s niskim do umjerenim koeficijentom korelacije (Hinkle i sur., 2003).

Tablica 21. Matrica korelacija među domenama SPTKTT upitnika

	TK	**CK**	**TPK**	**PK**	**PCK**	**TCK**	**TPACK**
TK	1.000						
CK	-0.562 (0.068)	1.000					
TPK	0.547 (0.051)	-0.517 (0.080)	1.000				
PK	0.286 (0.057)	-0.400 (0.082)	0.632 (0.057)	1.000			
PCK	0.382 (0.053)	-0.616 (0.067)	0.637 (0.056)	**0.807 (0.039)**	1.000		
TCK	0.465 (0.058)	-0.613 (0.076)	0.727 (0.063)	0.499 (0.068)	0.605 (0.057)	1.000	
TPACK	**0.497 (0.045)**	-0.474 (0.073)	**0.968 (0.022)**	0.615 (0.054)	0.631 (0.050)	**0.747 (0.043)**	1.000

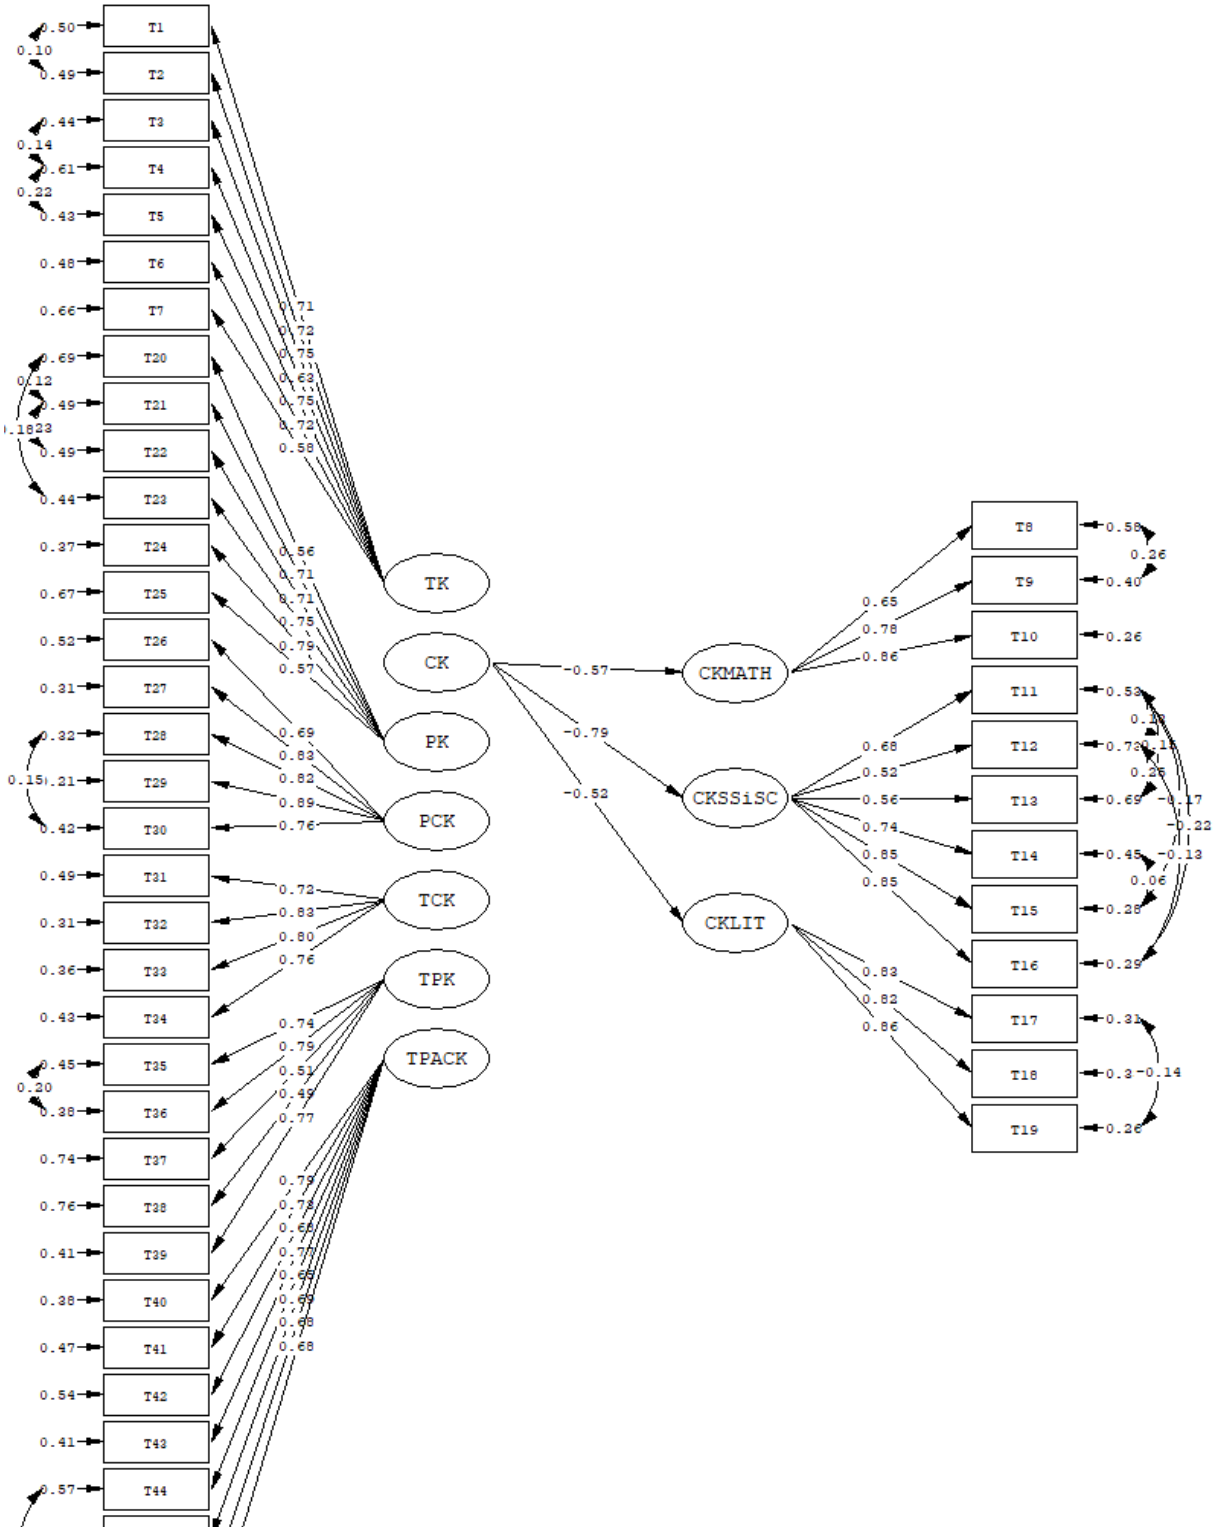

Slika 12. Konfirmatorna faktorska analiza SPTKTT upitnika, na temelju teorijskog modela prikazanog na slici 7., pri čemu su čestice upitnika označene redom T1-T47 : Tehnološka znanja (TK: T1-T7), Sadržajna znanja (CK) (Matematika (CKMATH:T8-T10), Priroda i društvo (CKSSiSC: T11-T16), Pismenost (CKLIT:T17-T19), Pedagoška znanja (PK: T20-T25), Pedgoško sadržajna znanja (PCK: T26-T30), Tehnološko sadržajna znanja (TCK: T31-T34), Tehnološko pedagoška znanja (TPK: T35-T39), Tehnološko pedagoško sadržajna znanja TPACK: T40 – T47).

5.2.1 Deskriptivni podaci čestica i podskala upitnika SPTKTT

Tablica 21 prikazuje deskriptivnu statistiku uzorka za svaku česticu i podskalu upitnika SPTKTT te uključuje aritmetičku sredinu, standardnu devijaciju, mjeru asimentričnosti s pripadnom standardnom pogreškom, mjeru zaobljenosti s pripadnom standardnom pogreškom, item-total korelaciju u odnosu na cijelu skalu te item-total korelaciju u odnosu na odgovarajuću podskalu.

Tablica 22. Deskriptivna statistika čestica i podskala upitnika SPTKTT (aritmetička sredina, standardna devijacija, mjeru asimentričnosti s pripadnom standardnom pogreškom, mjeru zaobljenosti s pripadnom standardnom pogreškom, item-total korelacija u odnosu na cijelu skalu te item-total korelacija u odnosu na odgovarajuću podskalu) na uzorku od N=337 ispitanik

Čestica/ podskala	**Aritmetička sredina**	**Standardna devijacija**	**Mjera asimetričnosti (SE=0.133)**	**Mjera zaobljenosti (SE=0.265)**	**Item-total korelacija (skala)**	**Item-total korelacija (podskala)**
T1	3.76	0.74	-,475	,433	,511	0.63
T2	3.88	0.75	-,620	,723	,468	0.65
T3	3.71	0.83	-,502	-,041	,447	0.71
T4	3.11	0.96	,199	-,589	,412	0.67
T5	2.98	0.87	,019	-,343	,515	0.74
T6	3.72	0.83	-,848	1,267	,459	0.65
T7	3.36	0.93	-,278	-,608	,442	0.53
TK	**24.52**	**4.48**	-,228	,290		
T8	3.33	0.88	-,466	-,198	,347	,711
T9	3.25	0.83	-,347	-,442	,355	,808
T10	3.27	0.95	-,348	-,395	,386	,646
CK_M	**9.85**	**2.34**	-,423	-,334		
T11	3.80	0.68	-,641	1,121	,463	,588
T12	3.30	0.94	-,125	-,316	,357	,553
T13	3.66	0.76	-,333	,309	,420	,620
T14	3.03	0.78	-,133	-,361	,468	,697
T15	2.95	0.81	,193	-,209	,516	,718
T16	3.06	0.82	-,052	-,268	,483	,641
CK_SSiS	**19.81**	**3.64**	-,028	,210		
T17	4.18	0.66	-,833	2,167	,414	,688
T18	4.05	0.68	-,574	1,139	,433	,777
T19	3.97	0.68	-,533	1,100	,444	,694
CK_L	**12.20**	**1.80**	-,408	,969		
CK	**61.68**	**9.30**	-,147	,163		
T20	3.66	0.68	-,259	,343	,434	,610
T21	3.94	0.67	-,418	,911	,501	,708
T22	3.92	0.70	-,572	1,335	,470	,681
T23	3.73	0.70	-,193	,222	,499	,736
T24	3.70	0.71	-,315	,630	,568	,672
T25	3.60	0.73	-,313	,372	,415	,509
T26	3.50	0.74	,005	-,054	,551	,607
PK	**26.05**	**3.68**	-,374	1,935		
T27	3.44	0.73	-,008	,247	,651	,761
T28	3.61	0.71	-,084	,373	,647	,834
T29	3.44	0.71	,117	,350	,711	,801
T30	3.66	0.72	-,177	,363	,619	,759
PCK	**14.15**	**2.53**	-,086	,972		
T31	3.55	0.78	-,479	,525	,545	,658
T32	3.64	0.73	-,464	,838	,621	,754

T33	3.47	0.78	-,397	,568	,637	,717
T34	3.74	0.76	-,668	1,207	,584	,673
TCK	**14.41**	**2.54**	-,414	1,330		
T35	3.85	0.70	-,730	1,575	,638	,618
T36	3.80	0.71	-,684	1,545	,676	,676
T37	3.85	0.83	-,538	,197	,407	,530
T38	3.76	0.84	-,388	,093	,424	,492
T39	3.76	0.68	-,423	,698	,627	,673
TPK	**19.02**	**2.83**	-,540	1,926		
T40	3.76	0.66	-,493	,881	,588	,661
T41	3.81	0.60	-,470	1,331	,569	,650
T42	3.68	0.69	-,621	1,020	,613	,609
T43	3.81	0.68	-,665	1,543	,614	,670
T44	3.43	0.74	-,212	,570	,581	,701
T45	3.64	0.66	-,195	,322	,608	,755
T46	3.58	0.67	-,121	,211	,634	,736
T47	3.47	0.67	-,171	,468	,621	,749
TPACK	**29.18**	**4.15**	-,292	1,776		

5.2.2 Pouzdanost upitnika SPTKTT

Unutarnja konzistencija upitnika SPTTT prikazana je Cronbachovim koeficijentom α u odnosu na svih 9 podskala upitnika (Tablica 22). Cronbachov koeficijent α za cjelokupni upitnik je 0.92, dok se za podskale kreće između 0.81 i 0.91 što sugerira visoku pouzdanost mjernog instrumenta.

Tablica 23. Cronbachov koeficijent α za svaku podskalu upittnika SPTKTT

Podskala upitnika SPTKTT	**Cronbachov koeficijent α**
Tehnološka znanja (TK)	0.87
Sadržajna znanja – matematika (CK_MATH)	0.85
Sadržajna znanja – prioroda i društvo (CK_SSiSC)	0.85
Sadržajna znanja – pismenost (CK_LIT)	0.85
Sadržajna znanja (CK)	0.85
Pedagoška znanja (PK)	0.87
Pedagoško sadržajna znana (PCK)	0.91
Tehnološko sadržajna znanja (TCK)	0.86
Tehnološko pedagoška znanja (TPK)	0.81
Tehnnološko pedagoško sadržajna znanja (TPACK)	0.90

5.3 Hipoteza H1

H1: Učitelji i nastavnici u Hrvatskoj percipiraju slabija vlastita znanja o primjeni IKT-a u nastavi u odnosu na vlastita pedagoška i predmetna znanja.

Ispitivanje hipoteze H1 provedeno je na podacima dobivenim iz Uzorka 1 kojeg čini 266 ispitanika. Nakon unošenja podataka uočeno je da pojedini podaci nedostaju. Svi oni slučajevi

u kojima je nedostajalo dva ili više podataka u nizu izbrisani su, što je bilo slučaj sa 6 ispitanika. Slučajevi u kojima su nedostajali pojedinačni podaci su ostavljeni, ali su podaci koji nedostaju nadopunjeni podacima dobivenim na temelju linearne interpolacije ugrađene unutar softvera Statistica 24.0, takvih podataka je bilo ukupno 13 kroz 10 varijabli: T5 (3 podatka), T6 (1 podatak),T24 (22 podatka), T26 (1 podatak), T34 (1 podatak), T36 (1 podatak), T37 (1 podatak), T38 (1 podatak), T40 (1 podatak), T47 (1 podatak).

U Tablici 23 prikazani su deskriptivni podaci za varijable *Tehnologija*, *Bez tehnologije i Tehnologija-Bez tehnologije*.

U svrhu ispitivanja normalnosti distribucije provedni su Kolmogorov-Smirnovljen i Shapiro-Wilkov test. Za varijablu *Bez tehnologije*, rezultati su pokazali da ima normalnu distribuciju podataka (K-S: stat.=0.039, p=0.2; S-W: stat=0.99, p=0.087),dok za varijable *Tehnologija*, rezultati pokazuju da odstupa od normalne distribucije podataka (**K-S: stat.=0.063, p=0.014**; **S-W: stat=0.98, p=0.026**), te također i za variablu *Tehologija-BezTehnologije* (**K-S: stat.=0.057, p=0.042; S-W: stat=0.98, p=0.003**). Stoga je izvršena analiza simetričnosti i spljoštenoti za promatrane varijable koje ukazuju da distribucija varijable *Tehnologija* ne odstupa značajnije od normalne distribucije, dok su vrijednosti za varijablu *Tehologija-BezTehnologije* veće od 1.96 (Tablica 23). Q-Q prikaz za varijablu *Tehnologija* (Slika 13) pokazuje da distribucija varijable ne odstupa značajnije od normalne distribucije, dok Q-Q prikaz za varijablu *Tehnologija-BezTehnologije* (Slika 14) pokazuje malu asimetričnost distribucije, čime je pitanje distribucije neodređeno. Slika 15 prikazuje kutijaste dijagrame za varijable *Tehnologija i Bez Tehnologije.*

Tablica 24. Deskriptivna statistika za varijable Tehnologija i Bez Tehnologije na uzorku od N=260 slučajeva

Varijabla N=260	**Aritmetička sredina**		**Mjera asmetričnosti**			**Mjera spljoštenosti**		
	vrijednost	standardna pogreška	vrijednost	standardna pogreška	vrijednost/ standardna pogreška	vrijednost	standardna pogreška	vrijednost/ standardna pogreška
Tehnologija	3.87	0.031	0.028	0.151	0.19	-0.190	0.301	-0.63
Bez tehnologije	4.10	0.026	0.018	0.151	0.17	-0.485	0.301	-0.61
Tehnologija – Bez tehnologije	-0.23	0.03	-0.430	0.151	**2.85**	1.081	0.301	**3.59**

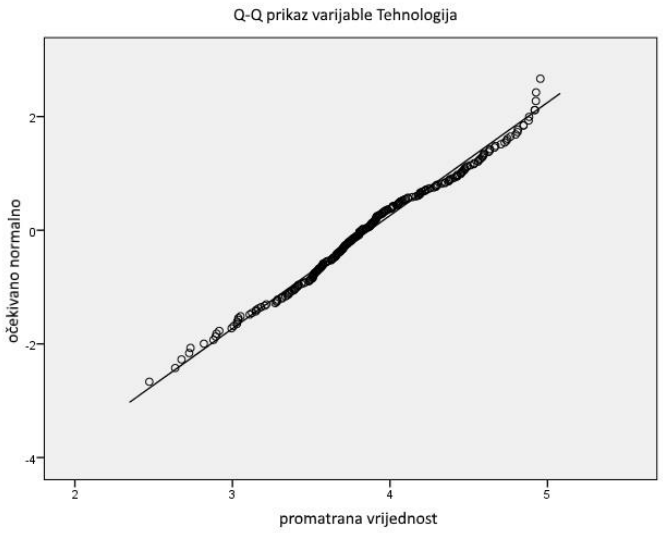

Slika 13. Q-Q prikaz za varijablu Tehnologija na uzorku od N=260 slučajeva

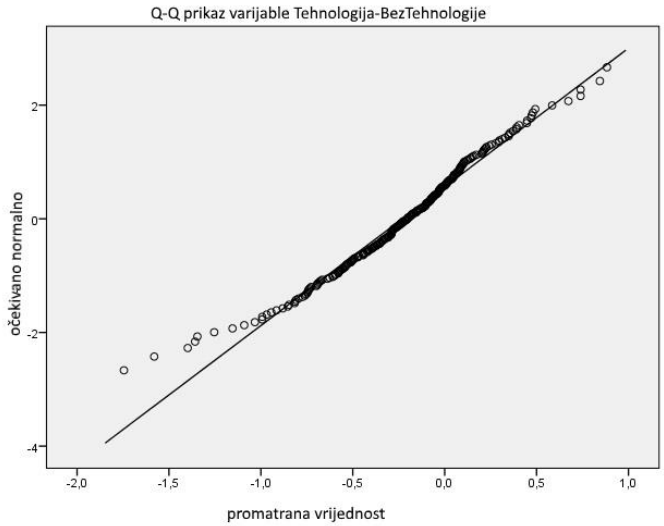

Slika 14. Q-Q prikaz za varijablu Tehnologija - Bez tehnologije na uzorku od N=260 slučajeva

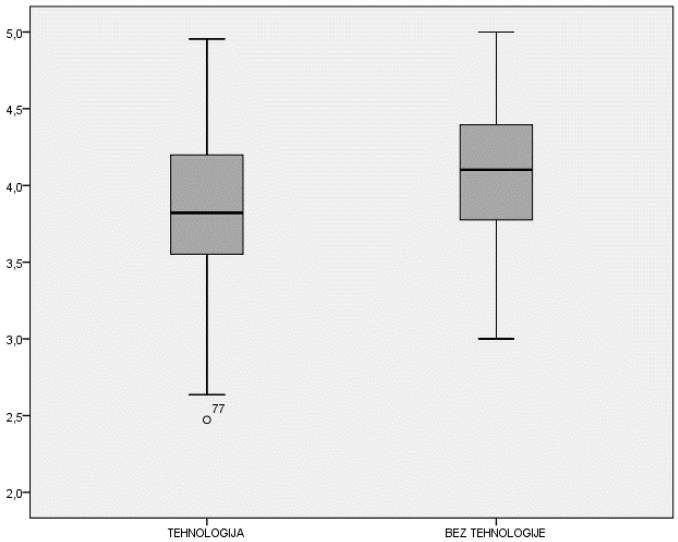

Slika 15. Kutijasti dijagrami za varijable Tehnologija i Bez Tehnologije na uzorku od N=260 slučajeva

S obzirom na neodređenost distribucije varijable *Tehnologija - BezTehnologije,* statistička značajnost razlike promatranih varijabli provjerena je t-testom za zavisne uzorke te dodatno testirana neparametrijskim testom za zavisne uzorke, Wilcoxonovim testom usklađenih parova. T-test za zavisne uzorke je pokazao da se odbacuje nul hipoteza (t = -9.06, p = 0.00) te se zaključuje da postoji statistički značajna razlika između promatranih aritmetičkih sredina varijabli *Tehnologija* i *Bez tehnologije.* Iste rezultate je pokazao i Wilcoxonov test usklađenih parova (z = -8.267, p = 0.00).

Dobiveni rezultati potvrđuju hipotezu H1 da učitelji i nastavnici u Hrvatskoj percipiraju slabija vlastita znanja o primjeni IKT-a u nastavi u odnosu na vlastita pedagoška i predmetna znanja.

5.4 Multivarijantna analiza varijance varijabli *Duboki* i *TPACK* u odnosu na *Samoprocjenu, Vršnjačku procjenu i Vrijeme*

Utjecaj nezavisnih varijabli *Samoprocjena i Vršnjačka procjena* na zavisne varijable *Duboki i TPACK* ispitao se tro-faktorskom multivarijantnom analizom varijance s ponovljenim mjerenjem, na razini značajnosti α=0.05. Faktore u ovoj tro-faktorskoj analizi varijance predstavljaju nezavisne varijable *Samoprocjena, Vršnjačka procjena* i *Vrijeme* te zavisne varijable *Duboki i TPACK.*

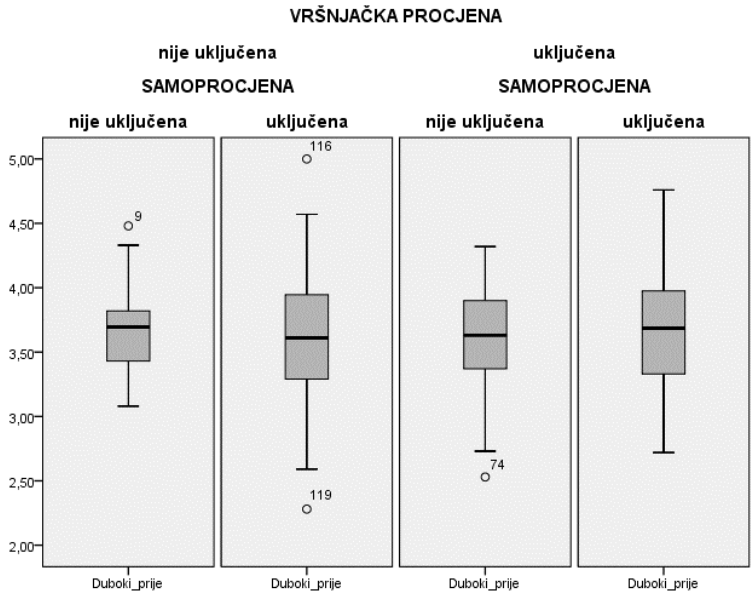

Slika 16. Kutijasti dijagrami za varijablu Duboki za sve promatrane skupine ispitanika koji su sudjelovali u samoprocjeni i vršnjačkoj procjeni, prije sudjelovanja u eksperimentu

Po pitanju distribucije varijabli TPACK i Duboki, rezultati Kolmogorov-Smirnovljeva i Shapiro-Wilkova testa su pokazali da je hipoteza H_0 prihvaćena za sve skupine ispitanika osim za varijablu *TPACK* za skupinu ispitanika koji su sudjelovali i u vršnjačkoj procjeni i u samoprocjeni prije sudjelovanja u istima (K-S=0.093, p=0.2; **S-W=0.242, p=0.008**).

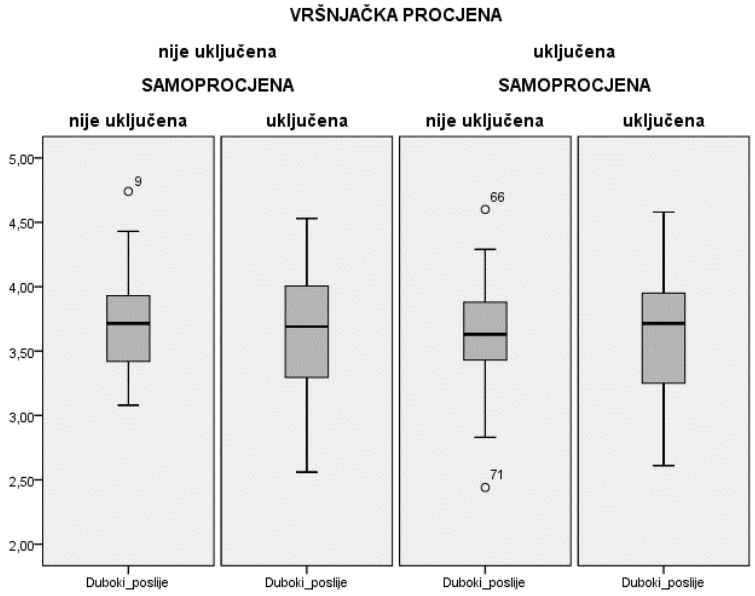

Slika 17. Kutijasti dijagrami za varijablu Duboki za sve promatrane skupine ispitanika koji su sudjelovali u samoprocjeni i vršnjačkoj procjeni, poslije sudjelovanja u eksperimentu

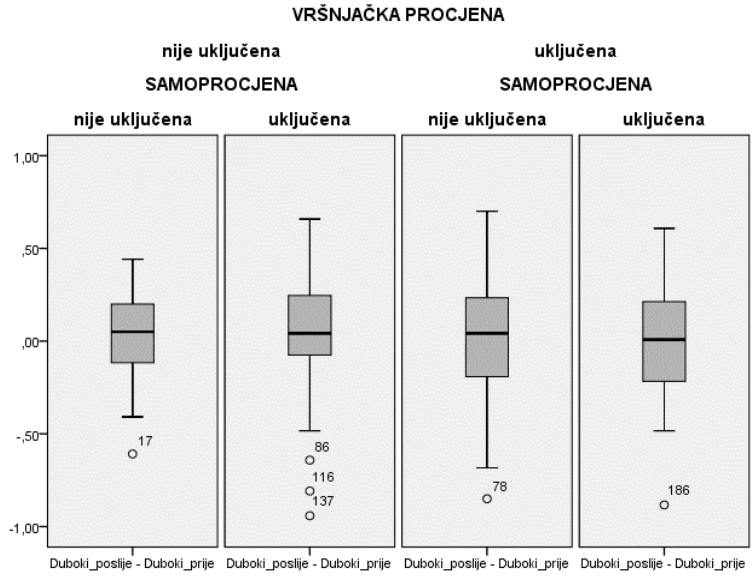

Slika 18. Kutijasti dijagrami varijable Duboki_poslije - Duboki_prije za sve promatrane skupine ispitanika koji su sudjelovali u samoprocjeni i vršnjačkoj procjeni

Iz skupa podataka za analizu isključen je slučaj 189 koji je predstavljao stršilo za promatrani skup podataka. Rezultati Kolmogorov-Smirnovljeva i Shapiro-Wilkova testa su pokazali da je hipoteza H_0 prihvaćena za obje zavisne varijable i za sve promatrane skupine ispitanika u odnosu na sudjelovanje u samoprocjeni i vršnjačkoj procjeni (K-S=0.008, p=0.2; S-W=0.98, p=0.46), odnosno da distribucija promatranih skupina varijabli ne odstupa značajno od normalne distribucije podataka na uzorku od N=195 ispitanika.

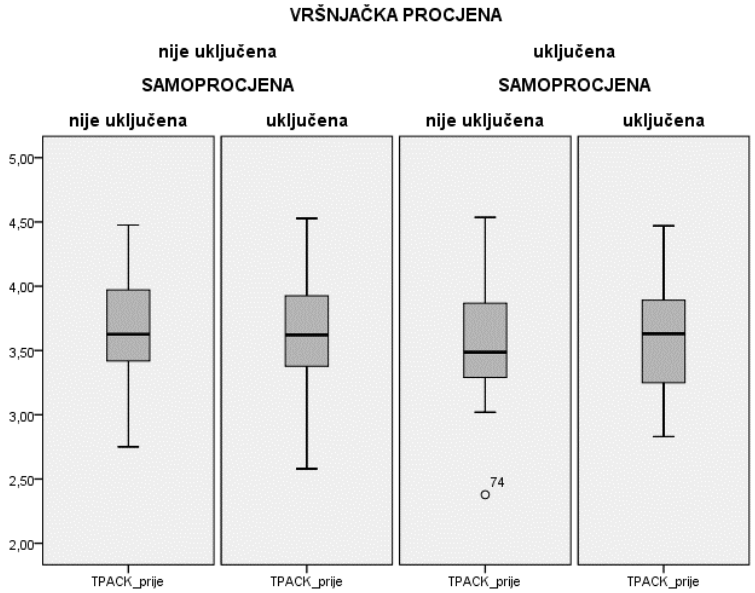

Slika 19. Kutijasti dijagrami za varijablu TPACK za sve promatrane skupine ispitanika koji su sudjelovali u samoprocjeni i vršnjačkoj procjeni, prije sudjelovanja u eksperimentu

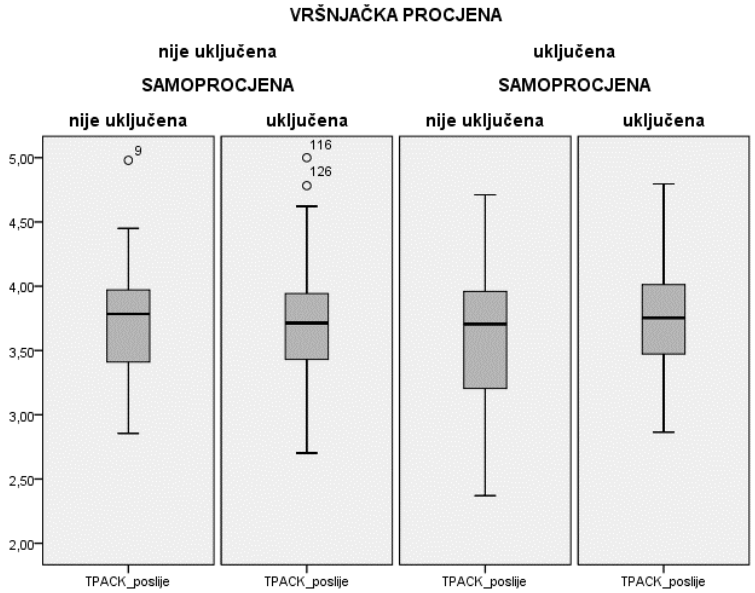

Slika 20. Kutijasti dijagrami za varijablu TPACK za sve promatrane skupine ispitanika koji su sudjelovali u samoprocjeni i vršnjačkoj procjeni, poslije sudjelovanja u eksperimentu

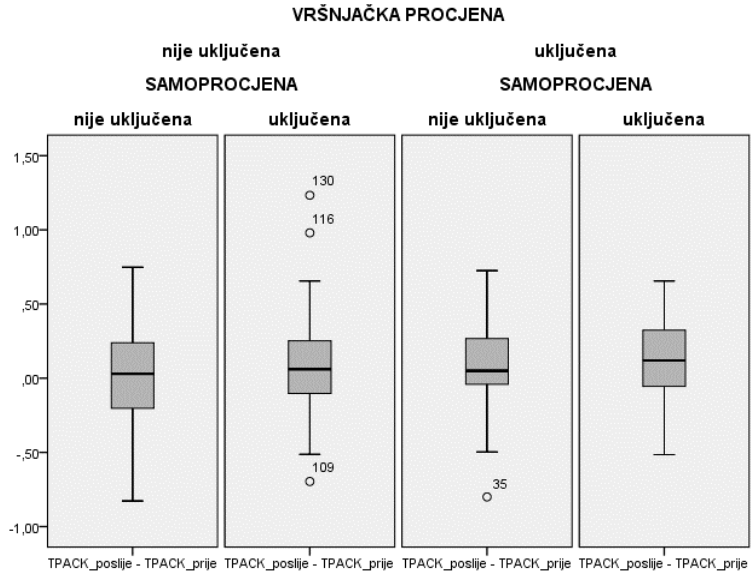

Slika 21. Kutijasti dijagrami varijable TPACK_poslije-TPACK_prije za sve promatrane skupine ispitanika koji su sudjelovali u samoprocjeni i vršnjačkoj procjeni

Po pitanju distribucije razlike varijabli TPACK i Duboki, prije i poslije sudjelovanja u eksperimentu, rezultati Kolmogorov-Smirnovljeva i Shapiro-Wilkova testa su pokazali da je hipoteza H_0 prihvaćena za sve skupine ispitanika osim za varijablu *Duboki_poslije-Duboki_prije* za skupinu ispitanika koji nisu sudjelovali niti u vršnjačkoj procjeni niti u samoprocjeni (**K-S=0.15, p=0.05**; S-W=0.96, p=0.24) te za varijablu *TPACK_poslije-TPACK_prije* za skupinu ispitanika koji nisu sudjelovali u samoprocjeni, ali su sudjelovali u vršnjačkoj procjeni (**K-S=0.14, p=0.03**; S-W=0.98, p=0.58). S obzirom da promatrane skupina obuhvaćaju manje od 50 ispitanika, kao relevantni rezultati uzeti su rezultati Shapiro-Wilkova testa iz čega zaključujemo da distribucija obje promatrane skupine ne odstupaju značajno od normalne distribucije. Distribucija varijable *Duboki_poslije-Duboki_prije* za skupinu ispitanika koji su sudjelovali u samoprocjeni, ali nisu sudjelovali u vršnjačkoj procjeni, prema Kolmogorov-Smirnovljevom i Shapiro-Wilkovom testu, pokazuje da odstupa od normalne distribucije (**K-S=0.15, p=0.01; S-W=0.95, p=0.02**), dok mjere asimetričnosti (-1.81) i zakrivljenosti (1.87) pokazuju da distribucija ne odstupa značajno od normalne, kao i q-q prikaz (Slika 23).

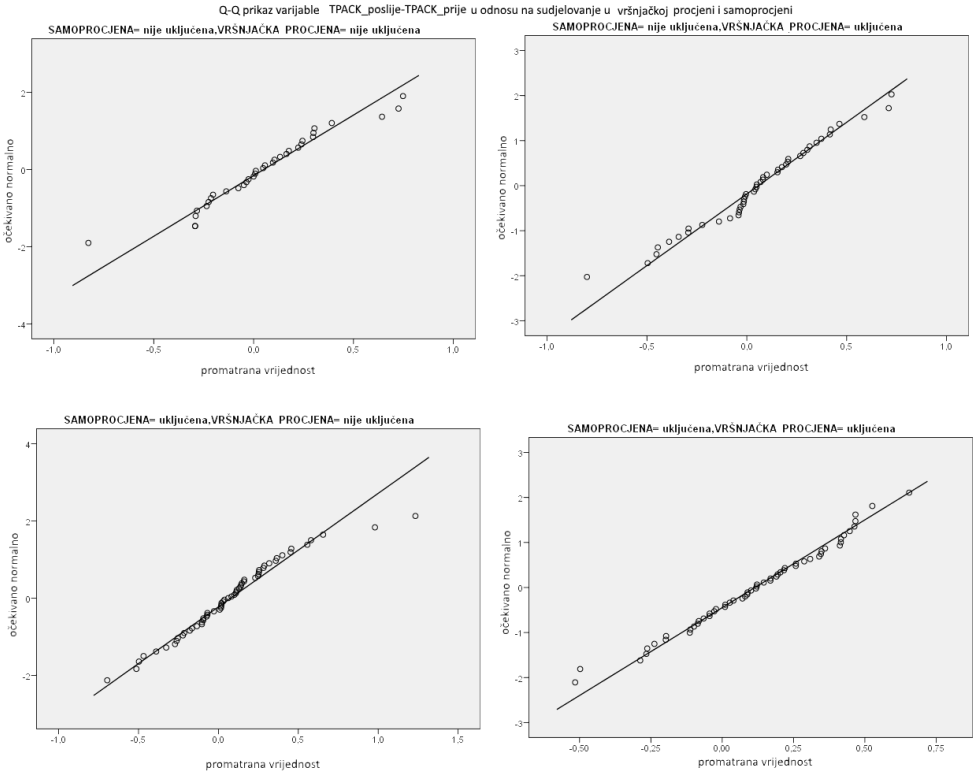

Slika 22. Q-Q prikazi varijable TPACK_poslije - TPACK_prije u odnosu na sudjelovanje u samoprocjeni i vršnjačkoj procjeni

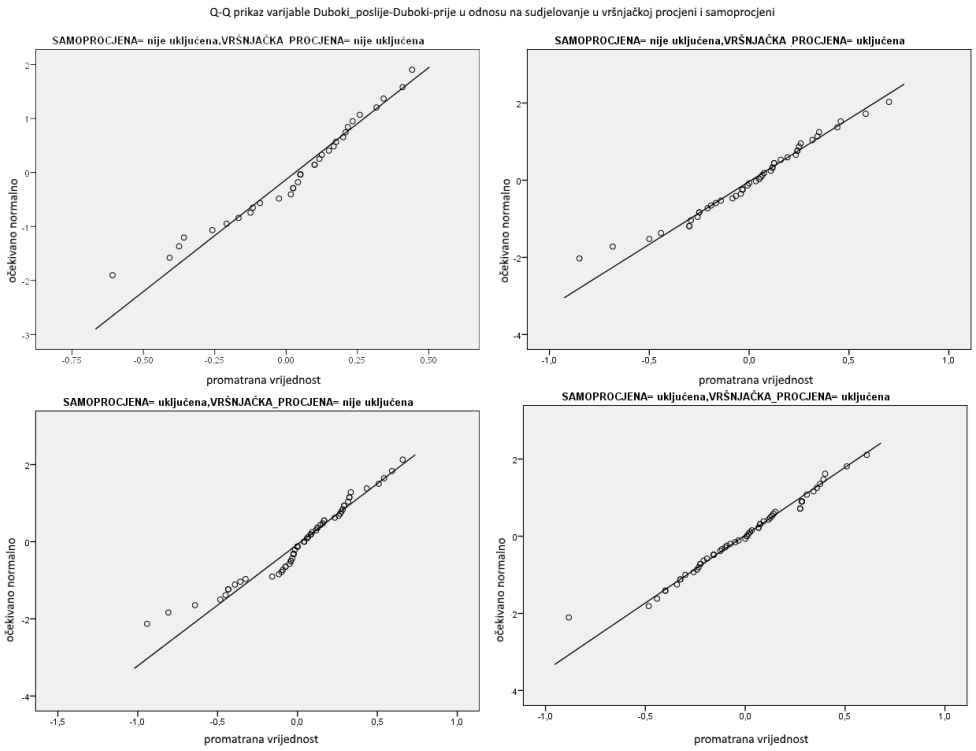

Slika 23. Q-Q prikazi varijable Duboki_poslije - Duboki_prije u odnosu na sudjelovanje u samoprocjeni i vršnjačkoj procjeni

Dijagram raspršenosti za varijable *TPACK (Slika 24) i Duboki (Slika 25)* u odnosu na *Vrijeme*, *Samoprocjenu* i *Vršnjačku procjenu*, na uzorku od N=195 ispitanika, pokazuje da je zadovoljen uvjet multivarijatne normalne distribucije.

Tablica 25. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijable Duboki i TPACK u odnosu na vrijeme, samoprocjenu i vršnjačku procjenu, na uzorku od N=195 ispitanika

Samoprocjena	**Vršnjačka procjena**	**Zavisna varijabla**	**Vrijeme**	**N**	**KOLMOGOROV SMIRNOV**		**SHAPIRO WILK**	
					vrijed.	*p*	*vrijed.*	*p*
nije uključena	**nije uključena**	**TPACK**	**prije**	34	0.09	0.20	0.98	0.90
		TPACK	**poslije**	34	0.10	0.20	0.97	0.51
		TPACK_poslije-TPACK_prije		34	0.11	0.20	0.96	0.21
		Duboki	**prije**	34	0.09	0.20	0.98	0.69
		Duboki	**poslije**	34	0.09	0.20	0.97	0.34
		Duboki_poslije-Duboki_prije		34	**0.15**	**0.05**	0.96	0.24
	uključena	**TPACK**	**prije**	46	0.10	0.20	0.97	0.35
		TPACK	**poslije**	46	0.09	0.20	0.98	0.58
		TPACK_poslije-TPACK_prije		46	**0.14**	**0.03**	0.98	0.58
		Duboki	**prije**	46	0.10	0.20	0.97	0.40
		Duboki	**poslije**	46	0.11	0.20	0.98	0.61
		Duboki_poslije-Duboki_prije		46	0.08	0.20	0.98	0.72
uključena	**nije uključena**	**TPACK**	**prije**	59	0.06	0.20	0.99	0.91
		TPACK	**poslije**	59	0.08	0.20	0.98	0.49
		TPACK_poslije-TPACK_prije		59	0.10	0.20	0.96	0.07
		Duboki	**prije**	59	0.05	0.20	0.99	0.98
		Duboki	**poslije**	59	0.09	0.20	0.98	0.50
		Duboki_poslije-Duboki_prije		59	**0.15**	**0.01**	**0.95**	**0.02**
	uključena	**TPACK**	**prije**	56	0.08	0.20	0.98	0.46
		TPACK	**poslije**	56	0.07	0.20	0.99	0.90
		TPACK_poslije-TPACK_prije		56	0.06	0.20	0.99	0.69
		Duboki	**prije**	56	0.07	0.20	0.99	0.89
		Duboki	**poslije**	56	0.10	0.20	0.97	0.22
		Duboki_poslije-Duboki_prije		56	0.09	0.20	0.98	0.62

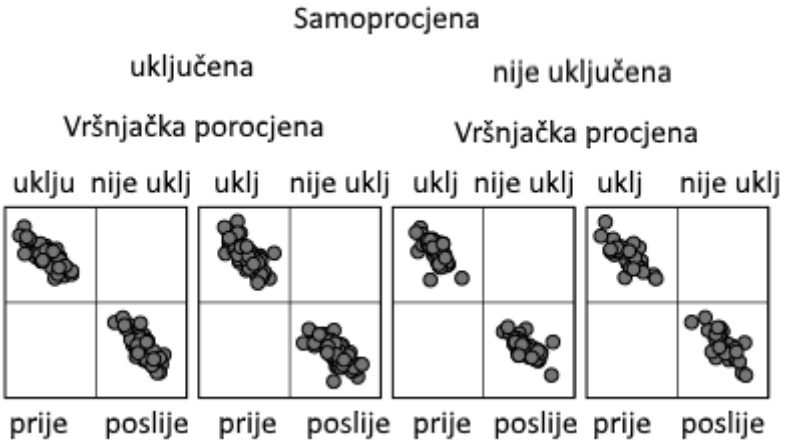

Slika 24. Dijagram raspršenosti za varijablu TPACK u odnosu na varijable Samoprocjena, Vršnjačka procjena i Vrijeme, na uzorku od N=195 ispitanika

Deskriptivna statistika za varijable *Duboki*, *TPACK* u odnosu na vrijeme, samoprocjenu i vršnjačku procjenu, na uzorku od N=195 ispitanika, prikazana je u Tablici 25.

Tablica 26. Deskriptivna statistika za varijable Duboki i TPACK u odnosu na vrijeme, samoprocjenu i vršnjačku procjenu, na uzorku od N=195 ispitanika, koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima

Samoprocjena	**Vršnjačka procjena**	**Zavisna varijabla**	**Vrijeme**	**N**	**ARITMETIČKA SREDINA**		**MJERA ASIMETRIČNOSTI**			**MJERA SPLJOŠTENOSTI**		
					vrijed.	*st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed./st.pog.*	*vrijed.*	*st.pogr.*	*vrijed./st.pog*
nije uključena	**nije uključena**	**TPACK**	**prije**	34	3.66	0.07	-0.19	0.40	-0.48	-0.20	0.79	-0.25
		TPACK	**poslije**	34	3.71	0.08	0.25	0.40	0.63	0.64	0.79	0.81
		TPACK_poslije-TPACK_prije		34	0.05	0.05	0.04	0.40	0.10	1.19	0.79	1.51
		Duboki	**prije**	34	3.66	0.06	0.46	0.40	1.15	0.13	0.79	0.16
		Duboki	**poslije**	34	3.70	0.07	0.49	0.40	1.23	0.31	0.79	0.39
		Duboki_poslije-Duboki_prije		34	0.03	0.04	-0.71	0.40	-1.78	0.38	0.79	0.48
	uključena	**TPACK**	**prije**	46	3.58	0.06	0.08	0.35	0.23	0.68	0.69	0.99
		TPACK	**poslije**	46	3.62	0.07	-0.29	0.35	-0.83	-0.02	0.69	-0.03
		TPACK_poslije-TPACK_prije		46	0.06	0.05	-0.25	0.35	-0.71	0.50	0.69	0.72
		Duboki	**prije**	46	3.61	0.06	-0.41	0.35	-1.17	0.10	0.69	0.14
		Duboki	**poslije**	46	3.61	0.06	-0.36	0.35	-1.03	1.10	0.69	1.59
		Duboki_poslije-Duboki_prije		46	0.01	0.05	-0.40	0.35	-1.14	0.76	0.69	1.10
uključena	**nije uključena**	**TPACK**	**prije**	59	3.64	0.06	-0.01	0.31	-0.03	-0.14	0.61	-0.23
		TPACK	**poslije**	59	3.72	0.06	0.32	0.21	1.52	0.37	0.61	0.61
		TPACK_poslije-TPACK_prije		59	0.08	0.04	0.59	0.31	1.90	0.95	0.61	1.56
		Duboki	**prije**	59	3.63	0.06	-0.02	0.31	-0.06	0.58	0.61	0.95
		Duboki	**poslije**	59	3.65	0.06	-0.32	0.31	-1.03	-0.44	0.61	-0.72
		Duboki_poslije-Duboki_prije		59	0.02	0.04	-0.56	0.31	-1.81	1.14	0.61	1.87
	uključena	**TPACK**	**prije**	56	3.61	0.05	0.10	0.32	0.31	-0.67	0.63	-1.06
		TPACK	**poslije**	56	3.72	0.05	0.03	0.32	0.09	-0.15	0.63	-0.24
		TPACK_poslije-TPACK_prije		56	0.11	0.03	-0.28	0.32	-0.88	-0.44	0.63	-0.70
		Duboki	**prije**	56	3.66	0.06	0.10	0.32	0.31	-0.38	0.63	-0.60
		Duboki	**poslije**	56	3.64	0.06	-0.36	0.32	-1.13	-0.44	0.63	-0.70
		Duboki_poslije-Duboki_prije		56	-0.01	0.04	-0.29	0.32	-0.91	0.41	0.63	0.65

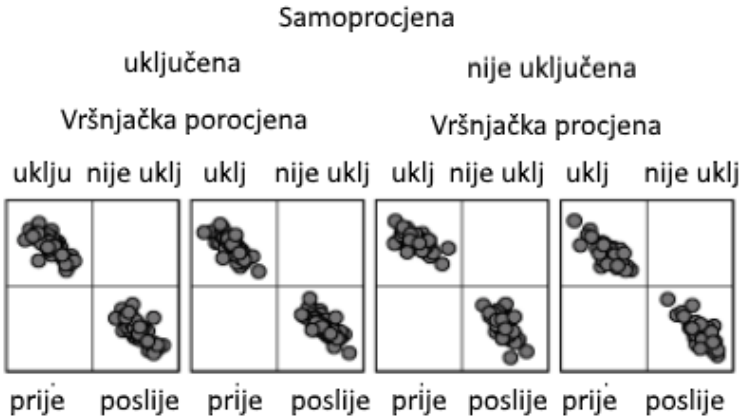

Slika 25. Dijagram raspršenosti za varijablu Duboki u odnosu na varijable Samoprocjena, Vršnjačka procjena i Vrijeme, na uzorku od N=195 ispitanika

Iz Tablice 26 je vidljivo da se Pearsonov r koeficijent kreće između 0.42 i 0.74 za sve promatrane parove zavisnih varijabli što ukazuje na srednje jaku do jaku povezanost, odnosno da je uvjet linearne povezanosti varijabli ispunjen. Pearsonov r koeficijent je veći od 0.7 za parove koji mjere isti konstrukt (TPACK i Duboki) prije, odnosno poslije sudjelovanja u procjeni, što je i za očekivati s obzirom da se radi o istom upitniku provedenom u dva vremenska intervala.

Tablica 27. Pearsonov r koeficijent za zavisne varijable TPACK i Duboki u odnosu na vrijeme prije i poslije sudjelovanja u procjeni

			TPACK		**Duboki**	
			prije	**poslije**	**prije**	**poslije**
TPACK	**prije**	**Pearson *r***	1	0.73	0.43	0.42
		p		<0.001	<0.001	<0.001
	poslije	**Pearson *r***	0.73	1	0.44	0.53
		p	<0.001		<0.001	<0.001
Duboki	**prije**	**Pearson *r***	0.43	0.44	1	0.74
		p	<0.001	<0.001		<0.001
	poslije	**Pearson *r***	0.42	0.53	0.74	1
		p	<0.001	<0.001	<0.001	

Statistički nesignifikantan Boxov M test (Box M=29.34, F(30, 70980)=0.94, p=0.561) ukazuje na jednakost matrica kovarijance zavisne varijable kroz sve nivoe nezavisne varijable.

Prvo su testirani efekti između subjekata i rezultati su pokazali da niti jedan efekt nije statistički značajan. Glavni efekt za varijablu *Samoprocjena* pokazao je da nema statistički značajne razlike po pitanju sudjelovanja u postupku samoprocjene (Wilkov λ=0.998, F(2,190)=0.144,

p=0.866, η_p=0.002). Također, glavni efekt za varijablu *Vršnjačka procjena* je pokazao da nema statistički značajne razlike po pitanju sudjelovanja u postupku vršnjačke procjene (Wilkov λ=0.996, F(2,190)=0.344, p=0.709, η_p=0.004). Međusobna interakcija spomenutih efekata također nije statistički značajna (Wilkov λ=0.997, F(2,190)=0.314, p=0.731, η_p=0.003).

Efekti unutar subjekata su pokazali da je efekt za varijablu *Vrijeme* statistički značajan (Wilkov λ=0.957, F(2,190)=4.271, p=0.015, η_p=0.043). Efekti interakcije varijable *Vrijeme* s varijablama *Samoprocjena* i *Vršnjačka procjena* nisu statistički značajni (Tablica 27).

Tablica 28. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisne varijable TPACK i Duboki u odnosu na nezavisne varijable Samoprocjena, Vršnjačka procjena i Vrijeme

	Stupnjevi slobode	**Wilkov λ**	**F**	**p**	**η_p**
VRIJEME	**2, 190**	**0.957**	**4.271**	**0.015**	**0.043**
VRIJEME * SAMOPROCJENA	2, 190	0.992	0.810	0.446	0.008
VRIJEME * VRŠNJAČKA PROCJENA	2, 190	0.995	0.4400	0.645	0.005
VRIJEME * SAMOPROCJENA * VRŠNJAČKA PROCJENA	2, 190	0.998	0.201	0.818	0.002

5.5 Hipoteza H2

H2: Sudjelovanje u procesu vršnjačke procjene i/ili samoprocjene rješenja problemskog zadatka u okviru online suradničkog učenja pozitivno utječe na pomak prema dubinskom pristupu učenju.

Promatrana hipoteza testirana je tro-faktorskom analizom varijance s ponovljenim mjerenjem, na razini značajnosti od α=0.05.

Za utvrđivanje normalne distribucije varijable *Duboki* u odnosu na samoprocjenu, vršnjačku procjenu i vrijeme, korišteni su Kolmogorov-Smirnovljev i Shapiro-Wilkov test nivoa značajnosti α=0.05 kojim se testirala nulta hipoteza da distribucija varijable *Duboki* u danom uzorku ne odstupa značajno od normalne za promatrani izvor procjene i vrijeme. Rezultati su pokazali da je hipoteza H_0 prihvaćena za svaku skupinu ispitanika u odnosu na izvor procjene i vrijeme (Tablica 28), odnosno da distribucija promatranih skupina varijabli ne odstupa značajno od normalne distribucije podataka. Detaljnije je distribucija varijable *Duboki_poslije-*

Duboki_prije raspravljena u poglavlju 5.4 kojem su prikazani i kutijasti dijagrami (Slike 16, 17 i 18) i q-q- prikazi (Slika 23) varijable *Duboki_poslije-Duboki_prije* u odnosu na sudjelovanje u samoprocjeni i vršnjačkoj procjeni.

Tablica 29. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Duboki u odnosu na samoprocjenu, vršnjački procjenu i vrijeme

SAMO PROCJENA	VRŠNJAČKA PROCJENA	VRIJEME	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
				vrijed.	*p*	*vrijed.*	*p*
nije uključena	*nije uključena*	*prije*	34	0.09	0.20	0.98	0.69
		poslije	34	0.09	0.20	0.97	0.34
		Duboki_poslije-Duboki_prije	34	**0.15**	**0.05**	0.96	0.24
	uključena	*prije*	46	0.10	0.20	0.97	0.40
		poslije	46	0.11	0.20	0.98	0.61
		Duboki_poslije-Duboki_prije	46	0.08	0.20	0.98	0.72
uključena	*nije uključena*	*prije*	59	0.05	0.20	.099	0.98
		poslije	59	0.09	0.20	0.98	0.50
		Duboki_poslije-Duboki_prije	59	**0.15**	**0.01**	**0.95**	**0.02**
	uključena	*prije*	57	0.07	0.20	0.99	0.80
		poslije	57	0.10	0.20	0.97	0.20
		Duboki_poslije-Duboki_prije	57	0.09	0.20	0.98	0.62

Deskriptivna statistika za varijablu *Duboki* u odnosu na izvor procjene (uključenost u samoprocjenu i vršnjačku procjenu te vrijeme mjerenja varijable *Duboki*) prikazana je u Tablici 29.

Tablica 30. Deskriptivna ststistika za varijablu Duboki u odnosu na samoprocjenu, vršnjački procjenu i vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i njihovim omjerom

SAMO PR.	VRŠNJAČ. PR.	VRIJEME	N	ARITMETIČKA SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
				vrij	*st.p*	*vrij*	*st. p*	*vrij/ st.p.*	*vrij*	*st. p*	*vrij/ st.p.*
nije uključena	*nije uključena*	*prije*	34	3.66	0.06	0.46	0.40	1.15	0.13	0.79	0.16
		poslije	34	3.67	0.07	0.48	0.40	1.20	0.31	0.79	0.39
		Duboki_poslije-Duboki_prije	34	0.03	0.04	-0.71	0.40	-1.78	0.38	0.79	0.48
	uključena	*prije*	46	3.61	0.06	-0.41	0.35	-1.17	0.10	0.69	0.14
		poslije	46	3.61	0.06	-0.36	0.35	-1.03	1.10	0.69	1.59
		Duboki_poslije-Duboki_prije	46	0.01	0.05	-0.40	0.35	-1.14	0.76	0.69	1.10
uključena	*nije uključena*	*prije*	59	3.63	0.06	-0.15	0.31	-0.48	0.58	0.61	0.95
		poslije	59	3.65	0.06	-0.32	0.31	-1.03	-0.44	0.61	-0.72
		Duboki_poslije-Duboki_prije	59	0.02	0.04	-0.56	0.31	-1.81	1.14	0.61	1.87
	uključena	*prije*	57	3.65	0.06	0.09	0.32	0.28	-0.44	0.62	-0.71
		poslije	57	3.63	0.06	-0.32	0.32	-1.00	-0.54	0.62	-0.87
		Duboki_poslije-Duboki_prije	57	-0.01	0.04	-0.29	0.32	-0.91	0.41	0.63	0.65

Homogenost varijanci provjerena je Levenovim testom homogenosti varijanci. Rezultati su pokazali da ne postoji statistički značajna razlika u varijancama varijable *Duboki* prije

sudjelovanja u samoprocjeni i/ili vršnjačkoj procjeni (F=2.03, df=3/192, p=0.11), odnosno poslije sudjelovanja u samoprocjeni i/ili vršnjačkoj procjeni (F=0.77, df=3/192, p=0.51).

Provedena je trofaktorska ANOVA s ponovljenim mjerenjem, na nivou značajnosti od α=0.05, u svrhu ispitivanja utjecaja nezavisnih varijabli *Samoprocjena* i *Vršnjačka procjena* na duboki pristup učenju, prije i poslije sudjelovanja u postupku samoprocjene i vršnjačke procjene.

Prvo su testirani efekti između subjekata i rezultati su pokazali da niti jedan efekt nije statistički značajan. Glavni efekt za varijablu *Samoprocjena* pokazao je da nema statistički značajne razlike po pitanju sudjelovanja u postupku samoprocjene (F(1,192)=0.012, p=0.912). Također, glavni efekt za varijablu *Vršnjačka procjena* je pokazao da nema statistički značajne razlike po pitanju sudjelovanja u postupku vršnjačke procjene (F(1,192)=0.410, p=0.523). Međusobna interakcija spomenutih efekata također nije statistički značajna (F(1,192)=0.384, p=0.536).

Efekti unutar subjekata su pokazali da niti jedan efekt nije statistički značajan, kao niti međusobne interakcije efekata. Glavni efekt za varijablu *Vrijeme* kao i efekti interakcije varijable *Vrijeme* s varijablama *Samoprocjena* i *Vršnjačka procjena* prikazani su u Tablici 30

Tablica 31. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu Duboki u odnosu na nezavisne varijable Samoprocjena, Vršnjačka procjena i Vrijeme

Duboki	**Stupnjevi slobode**	**Wilks' Lambda (pogreška = 192)**		
		vrijednost	F	p
VRIJEME	1	0.999	0.140	0.708
VRIJEME * SAMOPROCJENA	1	0.999	0.141	0.708
VRIJEME * VRŠNJAČKA PROCJENA	1	0.997	0.641	0.424
VRIJEME * SAMOPROCJENA * VRŠNJAČKA PROCJENA	1	1.000	0.024	0.877

5.5.1 Pomak prema dubokom pristupu učenju u odnosu na spol

Utjecaj nezavisnih varijabli *Spol* i *Vrijeme* na zavisnu varijablu *Duboki* ispitao se dvo-faktorskom analizom varijance s ponovljenim mjerenjem, na razini značajnosti α=0.05. Faktore u ovoj dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Spol* i *Vrijeme* te zavisna varijabla *Duboki*.

Rezultati Kolmogorov-Smirnovljenova testa su pokazali da distribucija varijable *Duboki* za skupinu ispitanika ženskog spola u odnosu na vrijeme poslije sudjelovanja u eksperimentu značajno odstupa od normalne distribucije, dok rezultati Shapiro-Wilkova testa pokazuju da distribucija promatranih podataka ne odstupa značajno od normlane distribucije (**K-S: vrijed= 0.07, p=0.04;** S-W: vrijed=0.99, p=0.36). Također, distribucija varijable *Duboki_poslije-Dubok_prije* za skupinu ispitanika ženskog spola značajno odstupa od normalne distribucije za oba promatrana testa (**K-S: vrijed= 0.09, p=0.001; S-W: vrijed=0.98, p=0.002**) Za ostale skupine ispitanika promatrane distribucije podataka ne odstupaju značajno od normalne distribucije u odnosu na rezultate oba testa (Tablica 31).

Tablica 32. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Duboki u odnosu na vrijeme i spol

VRIJEME	SPOL	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
			vrijed.	*p*	*vrijed.*	*p*
prije	***muški***	11	0.11	0.20	0.97	0.90
	ženski	185	0.03	0.20	0.99	0.98
poslije	***muški***	11	0.15	0.20	0.92	0.34
	ženski	185	**0.07**	**0.04**	0.99	0.36
Duboki_poslije-Dubok_prije	***muški***	11	0.18	0.20	0.94	0.53
	ženski	185	**0.09**	**0.001**	**0.98**	**0.002**

S obzirom da rezultati testova distribucije podataka pokazuju određena odstupanja od normalne distribucije, izvršena je analiza simetričnosti i spljoštenosti (Tablica 32) i Q-Q prikaza (Slika 26) koje ukazuju da distribucija ne odstupa značajnije od normalne distribucije.

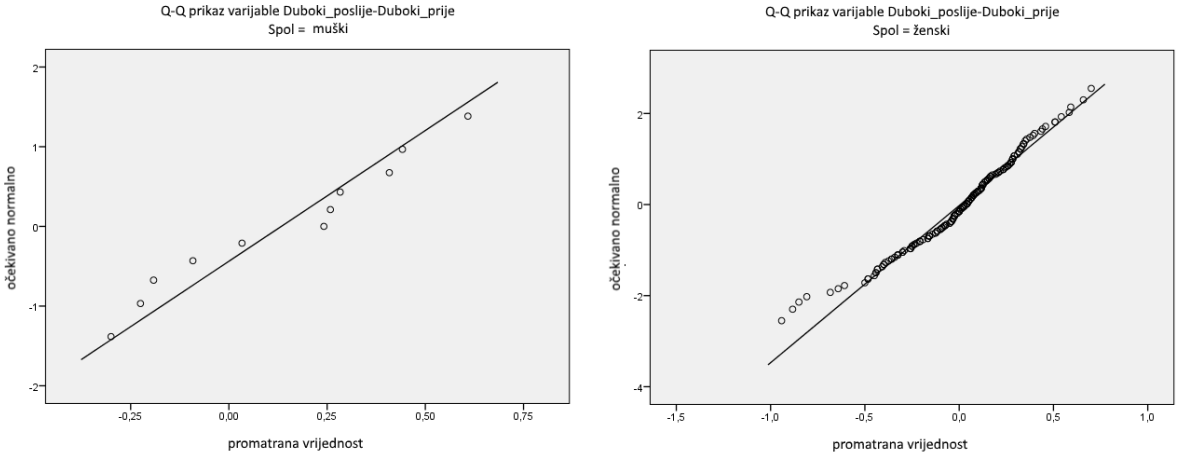

Slika 26. . Q-Q prikazi varijable Duboki_poslije-Duboki_prije za obje skupinu ispitanika u odnosu na Spol

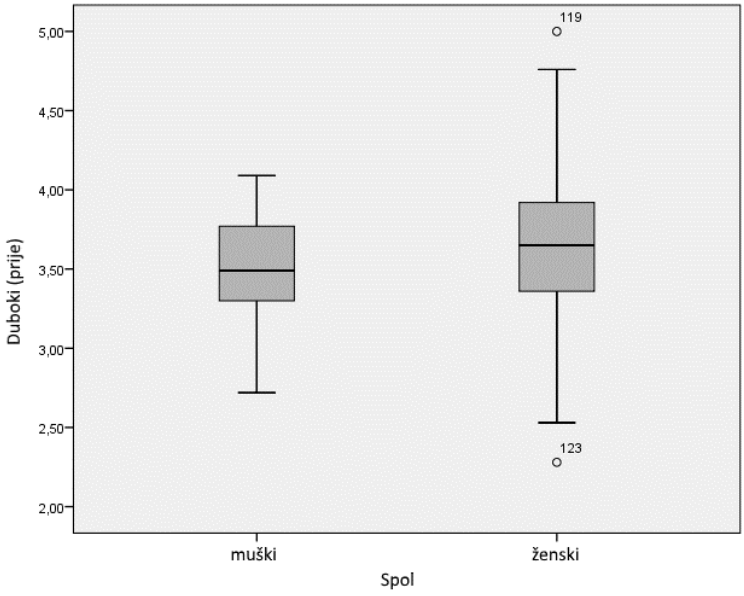

Slika 27. Kutijasti dijagrami varijable Duboki za obje skupine ispitanika u odnosu na Spol prije sudjelovanja u eksprimentu

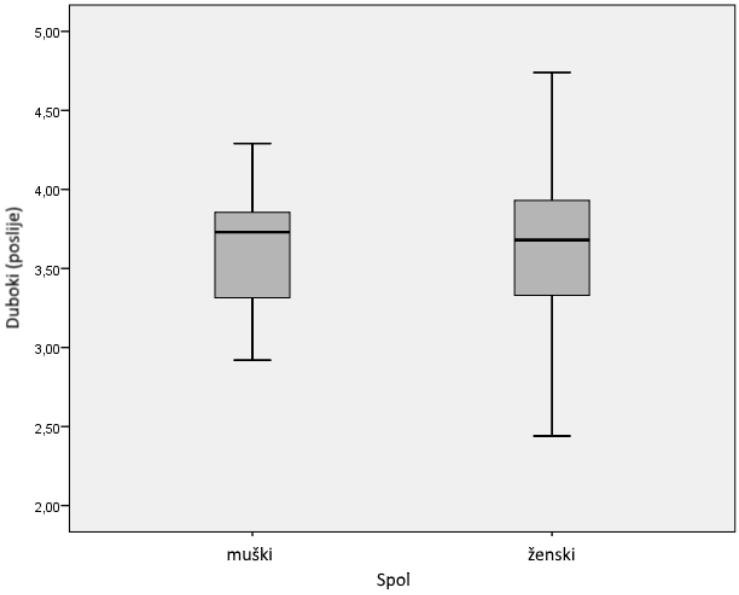

Slika 28. Kutijasti dijagrami varijable Duboki za obje skupine ispitanika u odnosu na Spol poslije sudjelovanja u eksprimentu

Deskriptivna statistika za varijablu *Duboki*, u odnosu varijable *Spol* i *Vrijeme*, prikazana je u Tablici 32.

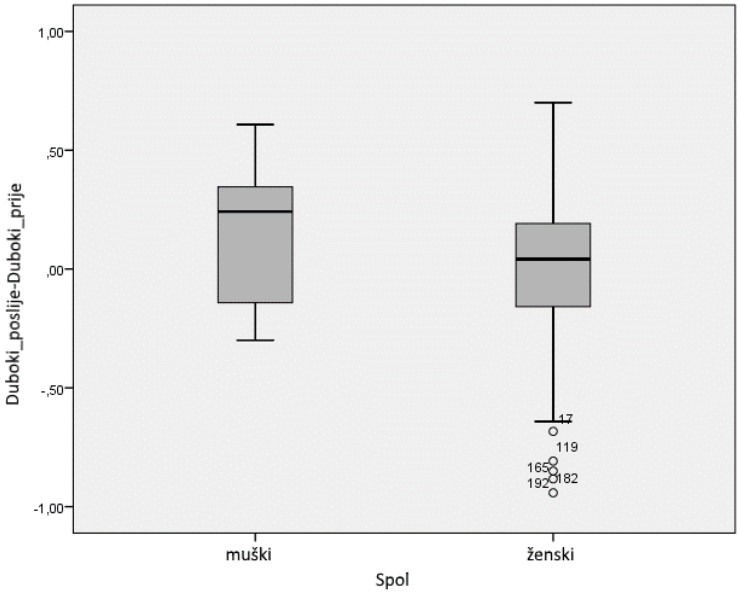

Slika 29. Kutijasti dijagrami varijable Duboki_poslije – Duboki_prije za obje skupine ispitanika u odnosu na Spol

Tablica 33. Deskriptivna ststistika za varijablu Duboki u odnosu na Spol i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima

VRIJ.	SPOL	N	ARITMETIČKA SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
			vrijed.	*st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed./st. pogr.*	*vrijed.*	*st.pogr.*	*vrijed./st. pogr.*
prije	***muški***	11	3.50	0.13	-0.40	0.66	-0.61	-0.25	1.28	-0.20
	ženski	185	3.64	0.03	-0.01	0.18	-0.06	0.32	0.36	0.89
poslije	***muški***	11	3.64	0.14	-0.26	0.66	-0.40	-0.84	1.28	-0.66
	ženski	185	3.64	0.03	-0.22	0.18	-1.22	-0.02	0.36	-0.06
Duboki_poslije – Duboki_prije	***muški***	11	0.13	0.14	-0.25	0.66	-0.38	-1.36	1.28	-1.06
	ženski	185	0.01	0.02	-0.58	0.18	**3.22**	0.84	0.36	**2.33**

Rezultati Levenova testa su pokazali da ne postoji statistiki značajna razlika u varijancama varijable Duboki u odnosu spol i vrijeme prije sudjelovanja u eksperimentu (F=0.046, df=1/194, p=0.830), odnosno poslije sudjelovanja u eksperimentu (F=0.180, df=1/194, p=0.672).

Provedena je dvo-faktorska ANOVA s ponovljenim mjerenjem, na nivou značajnosti od α=0.05, u svrhu ispitivanja utjecaja nezavisne varijable *Spol* na duboki pristup učenju, prije i poslije sudjelovanja u eksperimentu.

Prvo su testirani efekti između subjekata i rezultati su pokazali da promatrani efekt nije statistički značajan. Glavni efekt za varijablu *Spol* je pokazao da nema statistički značajne razlike u usvajanju dubokog pristupa učenju prije i nakon sudjelovanja u eksperimentu (F=0.324, df=(1,194), p=0.570).

Efekti unutar subjekata su pokazali da niti jedan efekt nije statistički značajan, kao niti međusobne interakcije efekata. Glavni efekt za varijablu *Vrijeme* kao i efekt interakcije varijable *Vrijeme* s varijablom *Spol* prikazani su u Tablici 33.

Tablica 34. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu Duboki u odnosu na nezavisne varijable Spol i Vrijeme

Duboki	**Stupnjevi slobode**	**Wilks' Lambda (pogreška = 194)**		
		vrijednost	*F*	*p*
VRIJEME	1	0.010	1.920	0.167
VRIJEME * SPOL	1	0.010	1.997	0.159

5.5.2 Pomak prema dubokom pristupu učenju u odnosu na studijsku godinu

Utjecaj nezavisnih varijabli *Studijska godina* i *Vrijeme* na zavisnu varijablu *Duboki* ispitao se dvo-faktorskom analizom varijance s ponovljenim mjerenjem, na razini značajnosti od α=0.05. Faktore u ovoj dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Studijska godina* i *Vrijeme* te zavisna varijabla *Duboki*.

Rezultati Kolmogorov-Smirnovljenova i Shapiro-Wilkova testa su pokazali da distribucije promatranih podataka ne odstupaju značajno od normalne distribucije u odnosu na rezultate oba testa, osim za varijablu *Duboki_poslije-Duboki_prije* za ispitanike s treće studijske godine preddiplomskog studija (Tablica 34).

Tablica 35. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Duboki u odnosu na vrijeme i studijsku godinu

VRIJ.	**ST.GOD.**	**N**	**KOLMOGOROV SMIRNOV**		**SHAPIRO WILK**	
			vrijed.	*p*	*vrijed.*	*p*
Prije	***prva***	53	0.08	0.200*	0.98	0.46
	druga	0	-	-	-	-
	treća	116	0.04	0.200*	0.99	0.79
	četvrta	24	0.11	0.200*	0.95	0.32
	peta	3	0.25	-	0.97	0.66
poslije	***prva***	53	0.06	0.20	0.98	0.49
	druga	0	-	-	-	-
	treća	116	0.08	0.056	0.99	0.49
	četvrta	24	0.13	0.200*	0.97	0.81
	peta	3	0.18	-	1.00	1.00
Duboki_poslije – Duboki_prije	***prva***	53	0.06	0.20	0.99	0.98
	druga	0	-	-	-	-
	treća	116	**0.10**	**0.006**	**0.96**	**0.002**
	četvrta	24	0.08	0.20	0.98	0.92
	peta	3	0.37	-	0.78	0.08

Stoga je izvršena analiza simetričnosti i spljoštenoti za promatranu varijablu koje ukazuju da je vrijednost omjera mjere asimetričnosti i pripadne pogreške, za varijablu *Duboki_poslije-Duboki_prije* za ispitanike s treće studijske godine preddiplomskog studija, veća od 1.96

(Tablica 35). Q-Q prikaz za promatranu varijablu (Slika 33) pokazuje malu asimetričnost distribucije, čime je pitanje distribucije neodređeno.

Deskriptivna statistika za varijablu *Duboki*, u odnosu varijable *Studijsku godinu* i *Vrijeme* prikazana je u Tablici 35.

Tablica 36. Deskriptivna ststistika za varijablu Duboki u odnosu na Studijsku godinu i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima

VRIJ.	ST.GOD.	N	ARITMETIČKA SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
			vrijed.	*st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed./st. pogr.*	*vrijed.*	*st.pogr.*	*vrijed./st. pogr..*
prije	***prva***	53	3.66	0.06	-0.39	0.38	-1.03	0.13	0.64	0.20
	druga	0	-	-	-	-	-	-	-	-
	treća	116	3.62	0.04	0.12	0.23	0.52	0.53	0.45	1.18
	četvrta	24	3.62	0.08	0.21	0.47	0.45	-0.95	0.92	-1.03
	peta	3	3.73	0.08	0.88	1.23	0.72	-	-	-
poslije	***prva***	53	3.67	0.06	-0.43	0.33		0.46	0.64	0.72
	druga	0	-	-	-	-	-	-	-	-
	treća	116	3.63	0.04	-0.18	0.23	-1.30	-0.23	0.45	-0.51
	četvrta	24	3.62	0.09	0.09	0.47	0.19	-0.11	0.92	-0.12
	peta	3	3.75	0.05	0.00	1.225	0.00	-	-	-
Duboki_poslije – Duboki_prije	***prva***	53	0.02	0.04	-0.16	0.33	-0.48	-0.08	0.64	-0.125
	druga	0	-	-	-	-	-	-	-	-
	treća	116	0.002	0.03	-0.73	0.23	**-3.17**	0.86	0.45	1.91
	četvrta	24	0.06	0.05	0.39	0.47	0.83	0.63	0.92	0.68
	peta	3	0.02	0.06	1.72	1.23	1.40	-	-	-

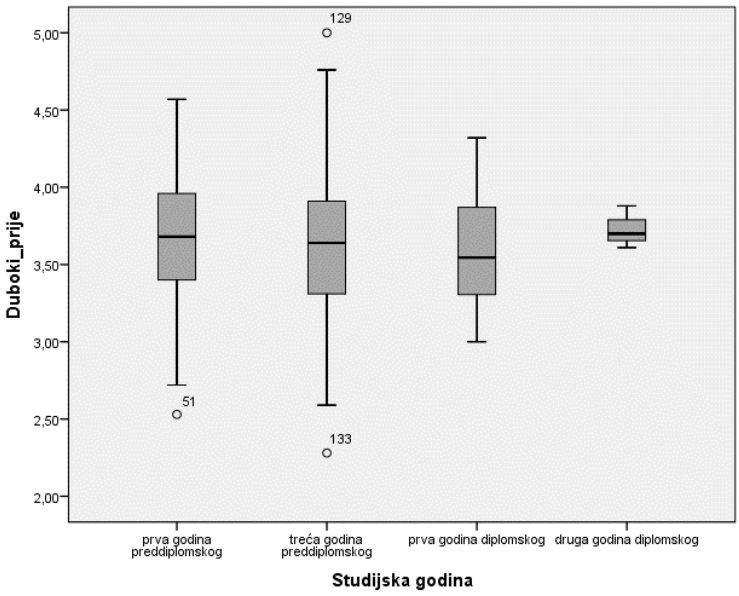

Slika 30. Kutijasti dijagrami varijable Duboki za sve skupine ispitanika u odnosu na Studijsku godinu prije sudjelovanja u eksprimentu

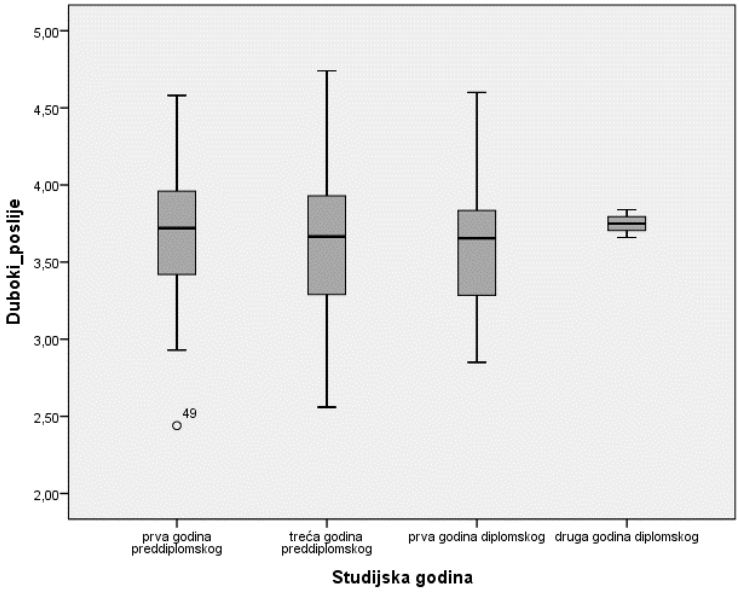

Slika 31. Kutijasti dijagrami varijable Duboki za sve skupine ispitanika u odnosu na Studijsku godinu poslije sudjelovanja u eksprimentu

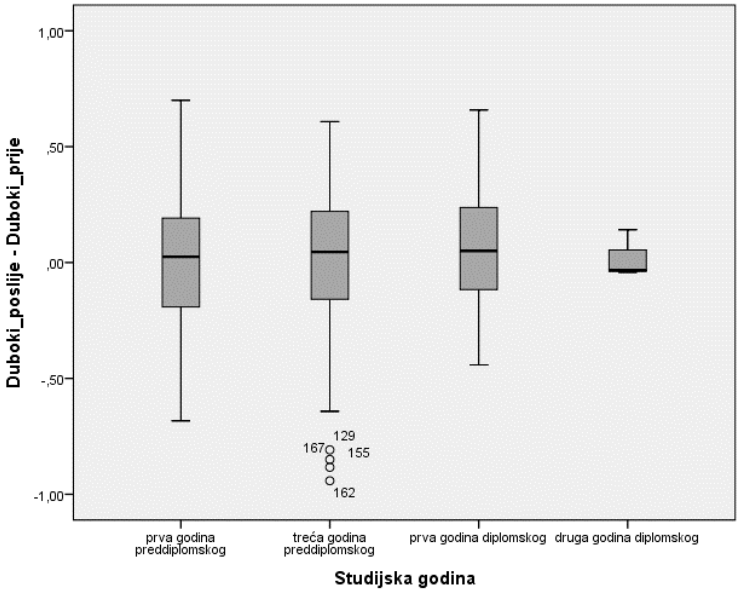

Slika 32. Kutijasti dijagrami varijable Duboki_poslije – Duboki_prije za sve skupine ispitanika u odnosu na Studijsku godinu

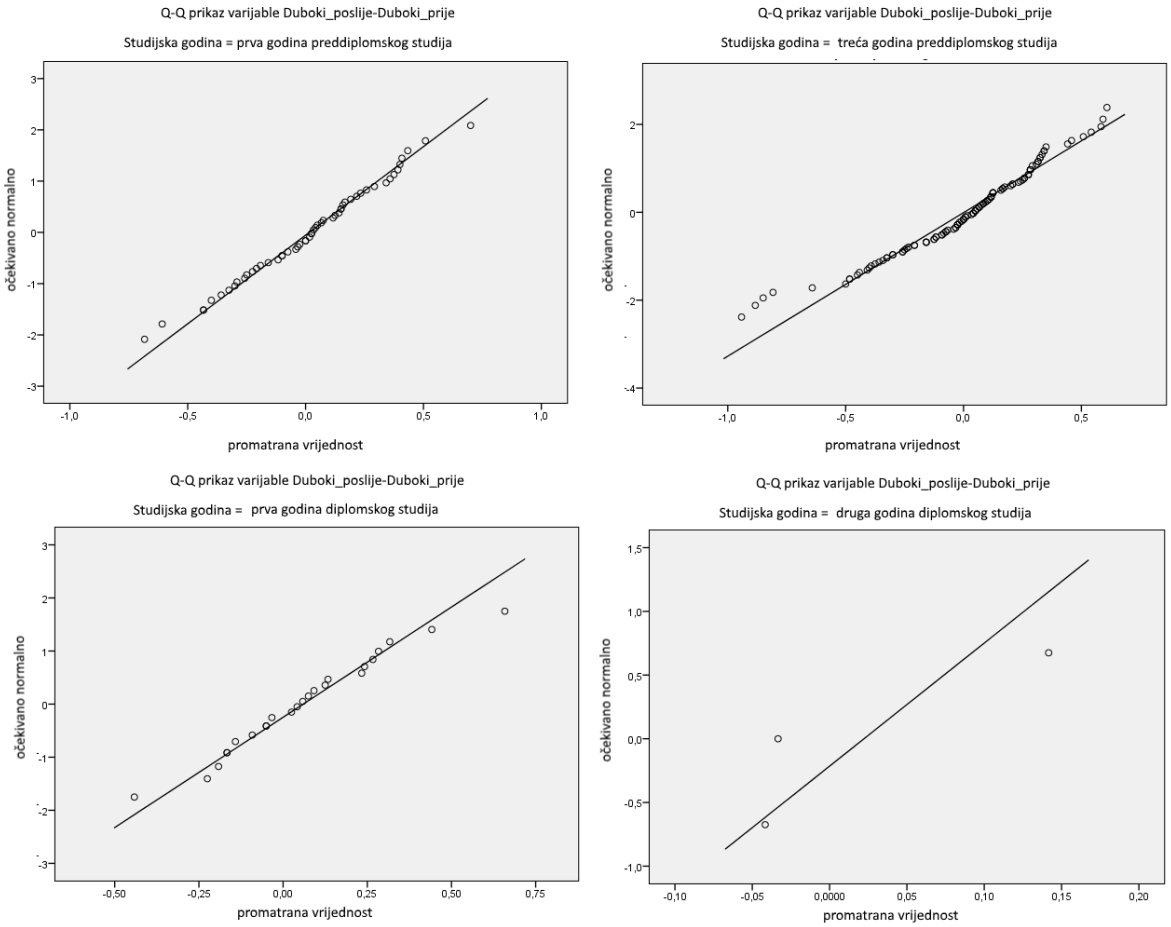

Slika 33. Q-Q prikazi varijable Duboki_poslije-Duboki_prije za sve skupine ispitanika u odnosu na Studijsku godinu

Rezultati Levenova testa su pokazali da ne postoji statistiki značajna razlika u varijancama varijable *Duboki* u odnosu studijsku godinu i vrijeme prije sudjelovanja u eksperimentu (F=0.897, df=3/192, p=0.444), odnosno poslije sudjelovanja u eksperimentu (F=1.217, df=3/192, p=0.305).

Provedena je dvo-faktorska ANOVA s ponovljenim mjerenjem, na nivou značajnosti od α=0.05, u svrhu ispitivanja utjecaja nezavisne varijable *Studijska godina* na duboki pristup učenju, prije i poslije sudjelovanja u eksperimentu.

Prvo su testirani efekti između subjekata i rezultati su pokazali da promatrani efekt nije statistički značajan. Glavni efekt za varijablu *Studijska godina* je pokazao da nema statistički značajne razlike u usvajanju dubokog pristupa učenju prije i nakon sudjelovanja u eksperimentu (F=0.183, df=(3,192), p=0.908).

Efekti unutar subjekata su pokazali da niti jedan efekt nije statistički značajan, kao niti međusobne interakcije efekata. Glavni efekt za varijablu *Vrijeme* kao i efekt interakcije varijable *Vrijeme* s varijablom *Studijska godina* prikazani su u Tablici 36.

Tablica 37. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu Duboki u odnosu na nezavisne varijable Studijska godina i Vrijeme

Duboki	**Stupnjevi slobode**	**Wilks' Lambda (pogreška = 192)**		
		vrijednost	F	p
VRIJEME	1	1.000	0.450	0.832
VRIJEME * ST. GOD.	3	1.000	0.270	0.994

Dobiveni rezultati su potvrđeni Kruskal Wallis testom (χ^2=0.21, p=0.98).

5.5.3 Pomak prema dubokom pristupu učenju u odnosu na razinu studija

Utjecaj nezavisnih varijabli *Razina studija* i *Vrijeme* na zavisnu varijablu *Duboki* ispitao se dvo-faktorskom analizom varijance s ponovljenim mjerenjem, na razini značajnosti α=0.05. Faktore u ovoj dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Razina studija* i *Vrijeme* te zavisna varijabla *Duboki.*

Rezultati Kolmogorov-Smirnovljenova i Shapiro-Wilkova testa su pokazali da distribucije promatranih podataka ne odstupaju značajno od normalne distribucije u odnosu na rezultate oba testa, osim za varijablu *Duboki_poslije-Duboki_prije* za ispitanike preddiplomskog studija (Tablica 37). Stoga je izvršena analiza simetričnosti i spljoštenoti za promatranu varijablu koje ukazuju da je vrijednost omjera mjere asimetričnosti i pripadne pogreške, za promatranu varijablu, veća od 1.96 (Tablica 38). Q-Q prikaz za promatranu varijablu (Slika 37) pokazuje da distribucija ne odudara značajno od normalne.

Tablica 38. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Duboki u odnosu na vrijeme i razinu studija

VRIJEME	**RAZINA STUDIJA**	**N**	**KOLMOGOROV SMIRNOV**		**SHAPIRO WILK**	
			vrijed.	*p*	*vrijed.*	*p*
prije	***preddiplomski***	169	0.03	0.20	1.00	0.97
	diplomski	27	0.08	0.20	0.97	0.52
poslije	***preddiplomski***	169	0.06	0.20	0.99	0.37
	diplomski	27	0.15	0.10	0.97	0.56
Duboki_poslije – Duboki_prije	***preddiplomski***	169	**0.09**	**0.003**	**0.98**	**0.007**
	diplomski	27	0.10	0.20	0.98	0.80

Deskriptivna statistika za varijablu *Duboki*, u odnosu varijable *Razina studija* i *Vrijeme*, prikazana je u Tablici 38.

Tablica 39. Deskriptivna ststistika za varijablu Duboki u odnosu na Razinu studija i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima

VRIJEME	RAZINA STUDIJA	N	ARITMETIČKA SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
			vrijed.	*st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed./st. pogr.*	*vrijed.*	*st.pogr.*	*vrijed./st. pogr.*
prije	***preddiplomski***	169	3.63	0.34	-0.03	0.19	-0.16	0.35	0.37	0.95
	diplomski	27	3.63	0.73	0.13	0.45	0.29	-0.76	0.87	-0.87
poslije	***preddiplomski***	169	3.64	0.03	-0.25	0.19	-1.32	-0.09	0.37	-0.24
	diplomski	27	3.64	0.08	-0.01	0.45	-0.02	0.16	0.87	0.18
Duboki_poslije – Duboki_prije	***preddiplomski***	169	0.01	0.02	-0.57	0.19	**-3.00**	0.61	0.37	1.65
	diplomski	27	0.06	0.04	0.46	0.45	1.02	0.96	0.87	1.10

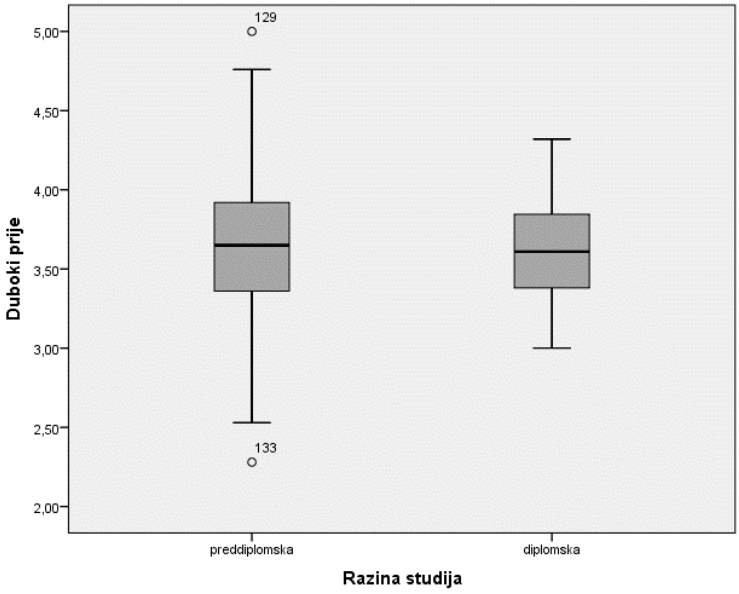

Slika 34. Kutijasti dijagrami varijable Duboki za sve skupine ispitanika u odnosu na Razinu studija prije sudjelovanja u eksprimentu

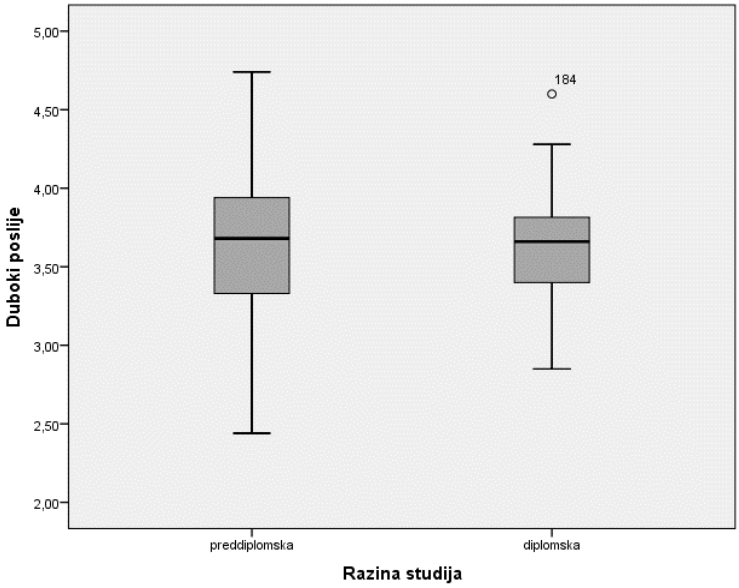

Slika 35. Kutijasti dijagrami varijable Duboki za sve skupine ispitanika u odnosu na Razinu studija poslije sudjelovanja u eksprimentu

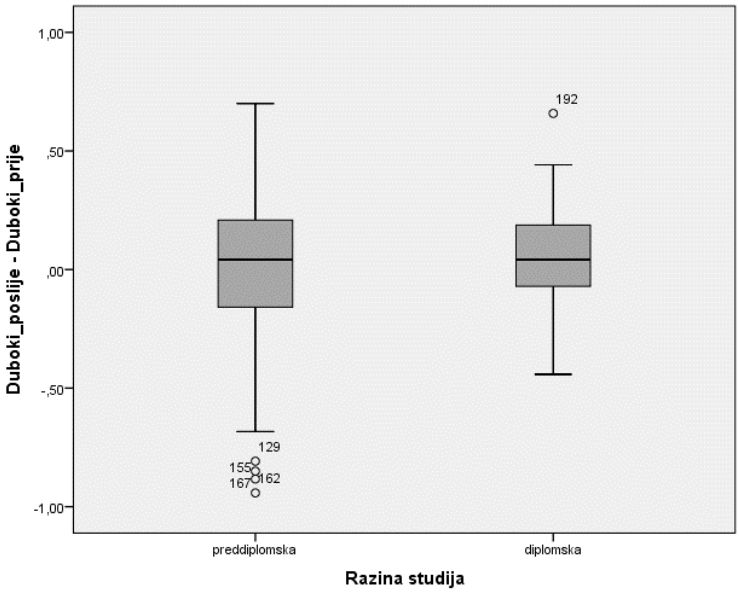

Slika 36. Kutijasti dijagrami varijable Duboki_poslije – Duboki_prije za sve skupine ispitanika u odnosu na Razinu studija

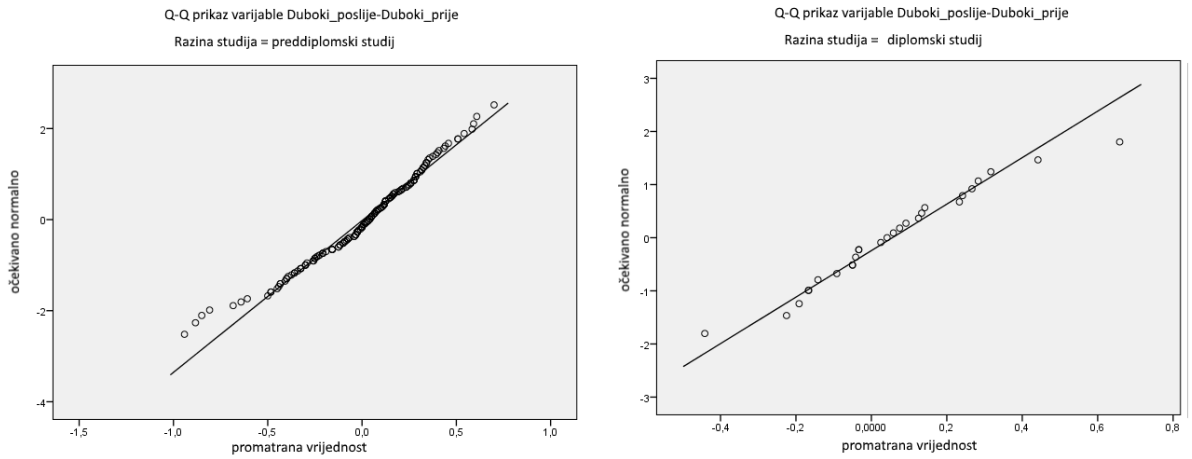

Slika 37. Q-Q prikazi varijable Duboki_poslije-Duboki_prije za sve skupine ispitanika u odnosu na Razinu studija

Rezultati Levenova testa su pokazali da ne postoji statistiki značajna razlika u varijancama varijable Duboki u odnosu spol i vrijeme prije sudjelovanja u eksperimentu (F=0.466, df=1/194, p=0.495), odnosno poslije sudjelovanja u eksperimentu (F=0.351, df=1/194, p=0.554).

Provedena je dvo-faktorska ANOVA s ponovljenim mjerenjem, na nivou značajnosti od α=0.05, u svrhu ispitivanja utjecaja nezavisne varijable *Razina studija* na duboki pristup učenju, prije i poslije sudjelovanja u eksperimentu.

Prvo su testirani efekti između subjekata i rezultati su pokazali da promatrani efekt nije statistički značajan. Glavni efekt za varijablu *Razina studija* je pokazao da nema statistički značajne razlike u usvajanju dubokog pristupa učenju prije i nakon sudjelovanja u eksperimentu (F=0.000, df=(3,192), p=0.992).

Efekti unutar subjekata su pokazali da niti jedan efekt nije statistički značajan, kao niti međusobne interakcije efekata. Glavni efekt za varijablu *Vrijeme* kao i efekt interakcije varijable *Vrijeme* s varijablom *Studijska godina* prikazani su u Tablici 39.

Tablica 40. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu Duboki u odnosu na nezavisne varijable Razina studija i Vrijeme

Duboki	**Stupnjevi slobode**	**Wilks' Lambda (pogreška = 194)**		
		vrijednost	F	p
VRIJEME	1	1.000	0.026	0.871
VRIJEME * RAZ.ST.	1	1.000	0.002	0.963

5.5.4 Pomak prema dubokom pristupu učenju u odnosu na znanstveno područje kolegija

Utjecaj nezavisnih varijabli *Znanstveno područje kolegija* i *Vrijeme* na zavisnu varijablu *Duboki* ispitao se dvo-faktorskom analizom varijance s ponovljenim mjerenjem, na razini značajnosti od α=0.05. Faktore u ovoj dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Znanstveno područje kolegija* i *Vrijeme* te zavisna varijabla *Duboki.*

Rezultati Shapiro-Wilkova testa su pokazali da distribucija skupine ispitanika na kolegijima iz područja društvenih znanosti u odnosu na vrijeme poslije sudjelovanja u eksperimentu značajno odstupa od normalne distribucije, dok rezultati Kolmogorov-Smirnovljeva testa pokazuju da distribucija promatranih podataka ne odstupa značajno od normalne distribucije. Također, prema rezultatima testova, distribucija varijable *Duboki_poslije-Duboki_prije* za ispitanike koji su pohađali kolegije iz društvenih znanosti i prirodnih znanosti odstupa od normalne distribucije (Tablica 40).

Tablica 41. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Duboki u odnosu na vrijeme i znanstveno područje kolegija

VRIJEME	ZNAN. POD. KOL.	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
			vrijed.	*p*	*vrijed.*	*p*
prije	Društvene znanosti	52	0.08	0.20	0.98	0.38
	Prirodne znanosti	105	0.05	0.20	0.99	0.95
	Humanističke znanosti	15	0.17	0.20	0.94	0.40
	Tehničke znanosti	24	0.11	0.20	0.95	0.32
poslije	**Društvene znanosti**	**52**	**0.11**	**0.14**	**0.95**	**0.02**
	Prirodne znanosti	105	0.07	0.20	0.987	0.43
	Humanističke znanosti	15	0.16	0.20	0.94	0.36
	Tehničke znanosti	24	0.13	0.20	0.98	0.81
Duboki_poslije – Duboki_prije	**Društvene znanosti**	**52**	**0.10**	**0.20**	**0.94**	**0.008**
	Prirodne znanosti	**105**	**0.10**	**0.009**	**0.98**	**0.05**
	Humanističke znanosti	15	0.12	0.20	0.97	0.89
	Tehničke znanosti	24	0.09	0.20	0.98	0.92

Stoga je izvršena analiza simetričnosti i spljoštenoti za promatrane varijable koje ukazuju da je vrijednost omjera mjere asimetričnosti i pripadne pogreške, za skupinu ispitanika na kolegijima iz područja društvenih znanosti u odnosu na vrijeme poslije sudjelovanja u eksperimentu manja od |1.96|, odnosno da distribucija ne odstupa načajno od normlane, dok je za varijablu *Duboki_poslije-Duboki_prije* prije za ispitanike koji su pohađali kolegije iz društvenih znanosti i prirodnih znanosti, veća od |1.96| (Tablica 41). Q-Q prikazi za promatrane varijable (Slika 38

i Slika 42) pokazuje da ne dodiruju sve promatrane točke liniju koja predstavlja normalnu distribuciju pa pitanje normalne distribucije možemo smatrati neodređenim.

Tablica 42. Deskriptivna ststistika za varijablu Duboki u odnosu na Znasntveno područje kolegija i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima

VRIJEME	ZNAN. POD. KOL.	N	ARITMETIČKA SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
			Vrij..	*st.p.*	*vrij*	*st.p.*	*vrij./st.p.*	*vrij*	*st.p.*	*vrij./st.p.*
prije	Društvene znanosti	52	3.55	0.05	0.31	0.33	0.94	0.69	0.65	1.06
	Prirodne znanosti	105	3.66	0.05	-0.16	0.24	-0,67	0.35	0.47	0.74
	Humanističke znanosti	15	3.76	0.08	-0.34	0.58	-0.59	-0.73	1.12	-0.65
	Tehničke znanosti	24	3.62	0.08	0.21	0.47	0.47	-0.95	0.92	-1.03
poslije	Društvene znanosti	52	3.60	0.06	-0.26	0.33	-0.79	-1.08	0.65	-1.66
	Prirodne znanosti	105	3.66	0.04	-0.30	0.24	-1.25	0.43	0.47	0.91
	Humanističke znanosti	15	3.67	0.10	0.09	0.47	0.19	-0.14	0.92	-0.15
	Tehničke znanosti	24	3.62	0.09	-0.14	0.58	-0.24	-1.16	1.12	-1.03
Duboki_poslije – Duboki_prije	**Društvene znanosti**	**52**	**0.05**	**0.04**	**-0.94**	**0.33**	**-2.84**	**2.27**	**0.65**	**3.49**
	Prirodne znanosti	**105**	**-0.01**	**0.03**	**-0.48**	**0.24**	**-2.0**	**0.25**	**0.47**	**0.57**
	Humanističke znanosti	15	-0.09	0.08	-0.20	0.58	-0.34	0.05	1.12	0.04
	Tehničke znanosti	24	0.06	0.05	0.39	0.47	0.83	0.63	0.92	0.68

Q-Q prikaz promatrane skupine ispitanika pokazuje da podaci ne prate liniju koja predstavlja normalnu distribuciju podataka.

Slika 38. Q-Q prikaz varijable Duboki za skupinu ispitanika na kolegijima iz područja društvenih znanosti u odnosu na vrijeme poslije sudjelovanja u eksperimentu

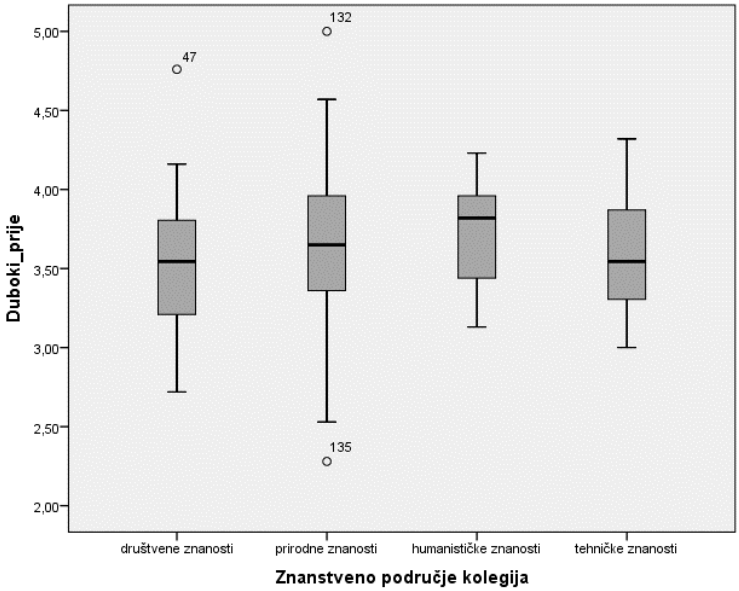

Slika 39. Kutijasti dijagrami varijable Duboki za sve skupine ispitanika u odnosu na Znanstveno područje kolegija prije sudjelovanja u eksprimentu

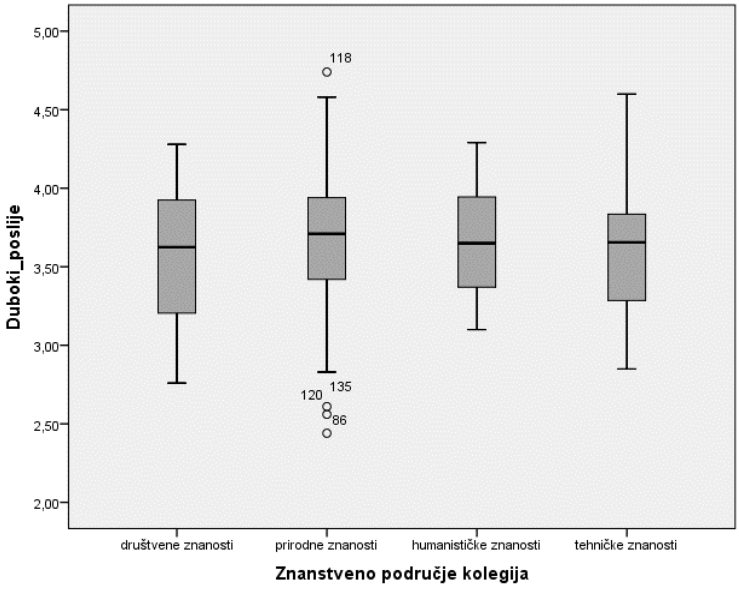

Slika 40. Kutijasti dijagrami varijable Duboki za sve skupine ispitanika u odnosu na Znanstveno područje kolegija poslije sudjelovanja u eksprimentu

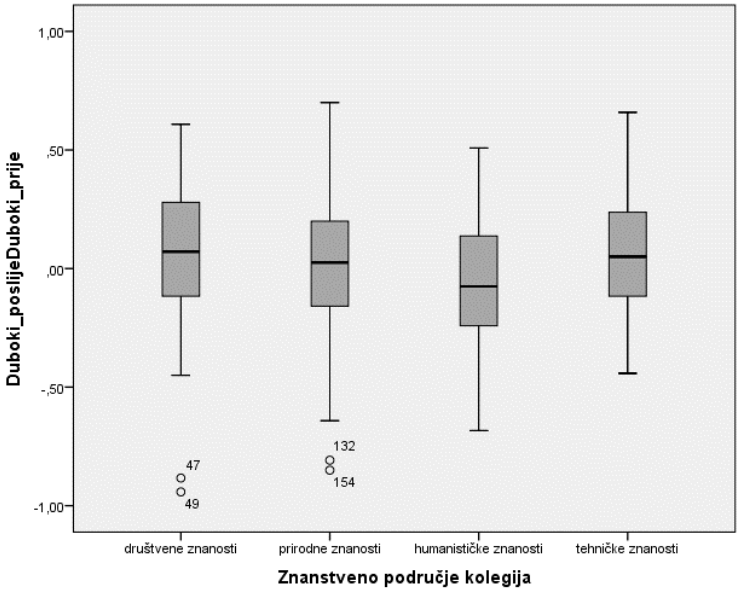

Slika 41. Kutijasti dijagrami varijable Duboki_poslije – Duboki_prije za sve skupine ispitanika u odnosu na Znanstveno područje kolegija

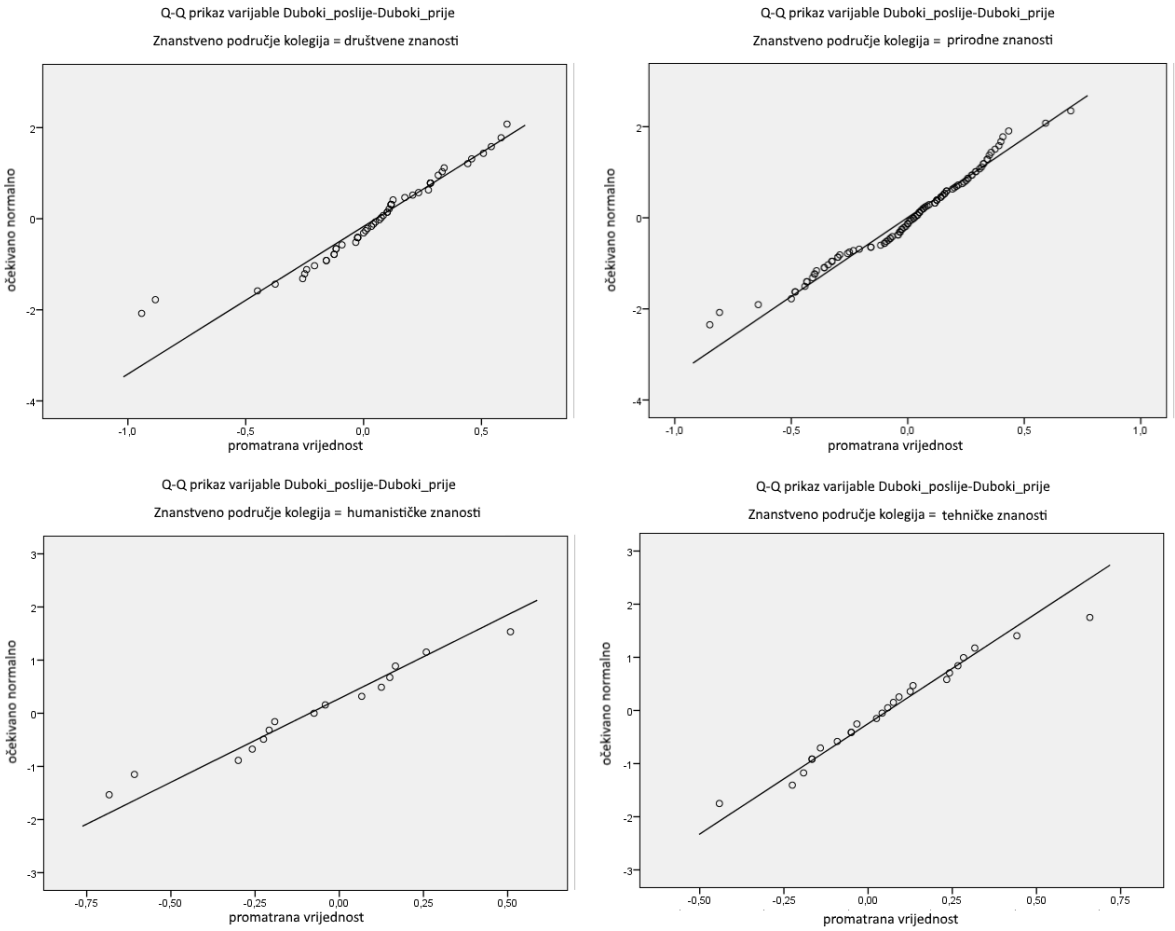

Slika 42. Q-Q prikazi varijable Duboki_poslije-Duboki_prije za sve skupine ispitanika u odnosu na Znanstveno područje kolegija

Rezultati Levenova testa su pokazali da ne postoji statistiki značajna razlika u varijancama varijable Duboki u odnosu na znanstveno područje kolegija i vrijeme prije sudjelovanja u eksperimentu (F=1.27, df=3/192, p=0.285), odnosno poslije sudjelovanja u eksperimentu (F=0.024, df=3/192, p=0.995).

S obzirom na neodređenost distribucije varijable *Duboki* za skupinu ispitanika na kolegijima iz područja društvenih znanosti u odnosu na vrijeme poslije sudjelovanja u eksperimentu, te za varijable *Duboki_poslije-Duboki_prije* za ispitanike koji su pohađali kolegije iz društvenih znanosti i prirodnih znanosti, statistička značajnost razlike promatranih varijabli provjerena je dvo-faktorskom ANOVOM s ponovljenim mjerenjem. Statistička značajnost dodatno je ispitana odgovarajućim neparametrijskim testom, Kruskal Wallis testom nad varijablom *Duboki_poslije-Duboki_prije*.

Provedena je dvo-faktorska ANOVA s ponovljenim mjerenjem, na nivou značajnosti od α=0.05, u svrhu ispitivanja utjecaja nezavisne varijable *Znasntveno područjekolegija* na duboki pristup učenju, prije i poslije sudjelovanja u eksperimentu.

Prvo su testirani efekti između subjekata i rezultati su pokazali da promatrani efekt nije statistički značajan. Glavni efekt za varijablu *Razina studija* je pokazao da nema statistički značajne razlike u usvajanju dubokog pristupa učenju prije i nakon sudjelovanja u eksperimentu (F=0.732, df=(3,192), p=0.534).

Efekti unutar subjekata su pokazali da niti jedan efekt nije statistički značajan, kao niti međusobne interakcije efekata. Glavni efekt za varijablu *Vrijeme* kao i efekt interakcije varijable *Vrijeme* s varijablom *Znasntveno područje kolegija* prikazani su u Tablici 42.

Tablica 43. Razine vjerojatnosti F vrijednosti u analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu Duboki u odnosu na nezavisne varijable Znanstveno područje kolegija i Vrijeme

Duboki	**Stupnjevi slobode**	**Wilks' Lambda (pogreška = 192)**		
		vrijednost	F	p
VRIJEME	1	0.999	0.111	0.739
VRIJEME * ZNAN.POD.KOL.	1	0.987	0.857	0.464

Dobiveni rezultati su potvrđeni Kruskal Wallis testom (χ^2=3.12, p=0.37).

5.6 Hipoteza H3

H3: Postoji povezanost između pristupa učenju koji student uobičajeno primjenjuje i pouzdanosti studentske kriterijske procjene rješenja problemskog zadatka.

Iz dijagrama razmještaja (Slika 43) je vidljivo da veza između varijabli *Dijametar kvazi - pouzdanosti* i Pristup učenju nije linearna niti monotona. Uz pomoć eta i kvadriranog eta koeficijenta analizirana je povezanost kategorijske varijable *Pristup učenju* i intervalne varijable *Dijametar kvazi - pouzdanosti*.

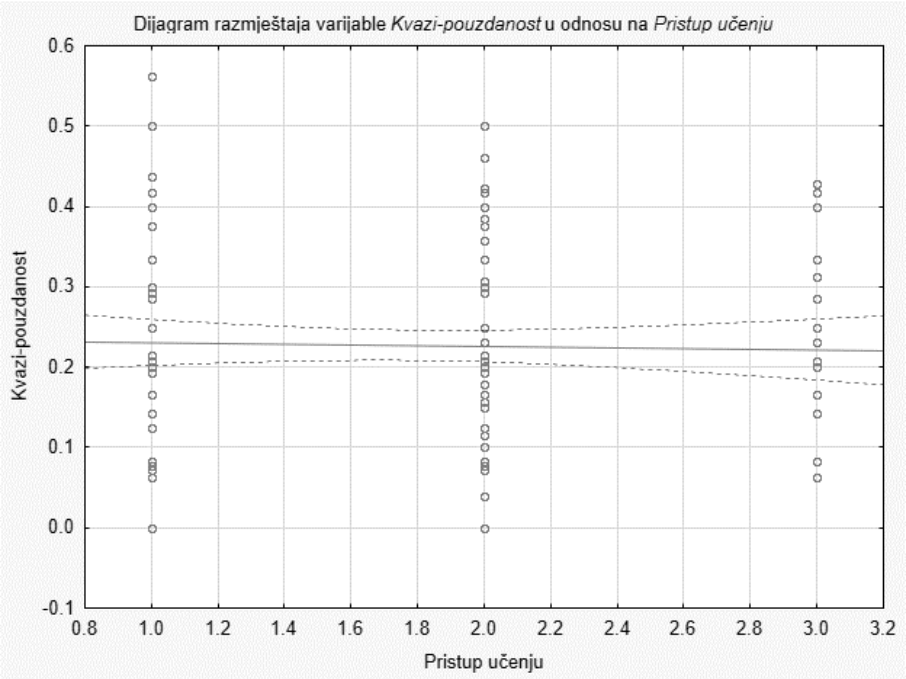

Slika 43.Dijagram razmještaja varijable Dijametar kvazi - pouzdanosti i Pistup učenju, na uzorku od N=150 ispitanika

Eta koeficijenta za *Kvazi pouzdanost* u odnosu na *Pristup učenju* koji student uobičajeno primjenjuje: duboki pristup učenju (M=0.24, SD=0.11), strateški pristup učenju (M=0.22, SD=0.12); površinski pristup učenju (M=0.23, SD=0.10) pokazuje da je jačina analizirane veze slaba η=0.075, odnosno njihova veza objašnjava samo 0.5% zajendičke varijance (η^2=0.005).

5.6.1 Dijametar kvazi - pouzdanosti u odnosu na pristup učenju koji student uobičajeno primjenjuje

Utjecaj nezavisne varijable *Pristup učenju* na zavisnu varijablu *Dijametar kvazi - pouzdanosti* ispitao se analizom varijance, na razini značajnosti od α=0.05.

Rezultati Kolmogorov-Smirnovljenova i Shapiro-Wilkova testa su pokazali da distribucije promatranih podataka ne odstupaju značajno od normalne distribucije u odnosu na rezultate oba testa (Tablica 43).

Tablica 44. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Pristup učenju

PRISTUP UČENJU	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
		vrijed.	*p*	*vrijed.*	*p*
duboki	55	0.11	0.20	0.98	0.33
strateški	72	0.09	0.20	0.98	0.16
površinski	23	0.14	0.20	0.96	0.48

Deskriptivna statistika za varijablu *Dijametar kvazi - pouzdanosti* u odnosu na *Pristup učenju*, prikazana je u Tablici 44.

Tablica 45. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Pristup učenju koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima

PRISTUP UČENJU	N	ARITMETIČKA SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
		vrijed.	*st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed./st. pogr.*	*vrijed.*	*st.pogr.*	*vrijed./st. pogr..*
duboki	55	0.24	0.02	0.44	0.32	1.38	0.45	0.63	0.71
strateški	72	0.22	0.01	0.10	0.28	0.36	-0.57	0.56	1.02
površinski	23	0.23	0.02	0.29	0.48	0.60	-0.46	0.94	0.49

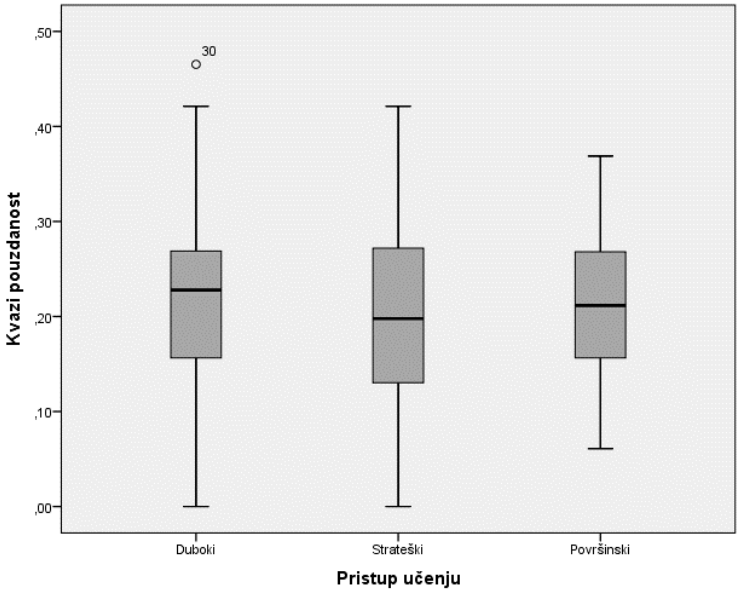

Slika 44. Kutijasti dijagrami varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na Pristup učenju

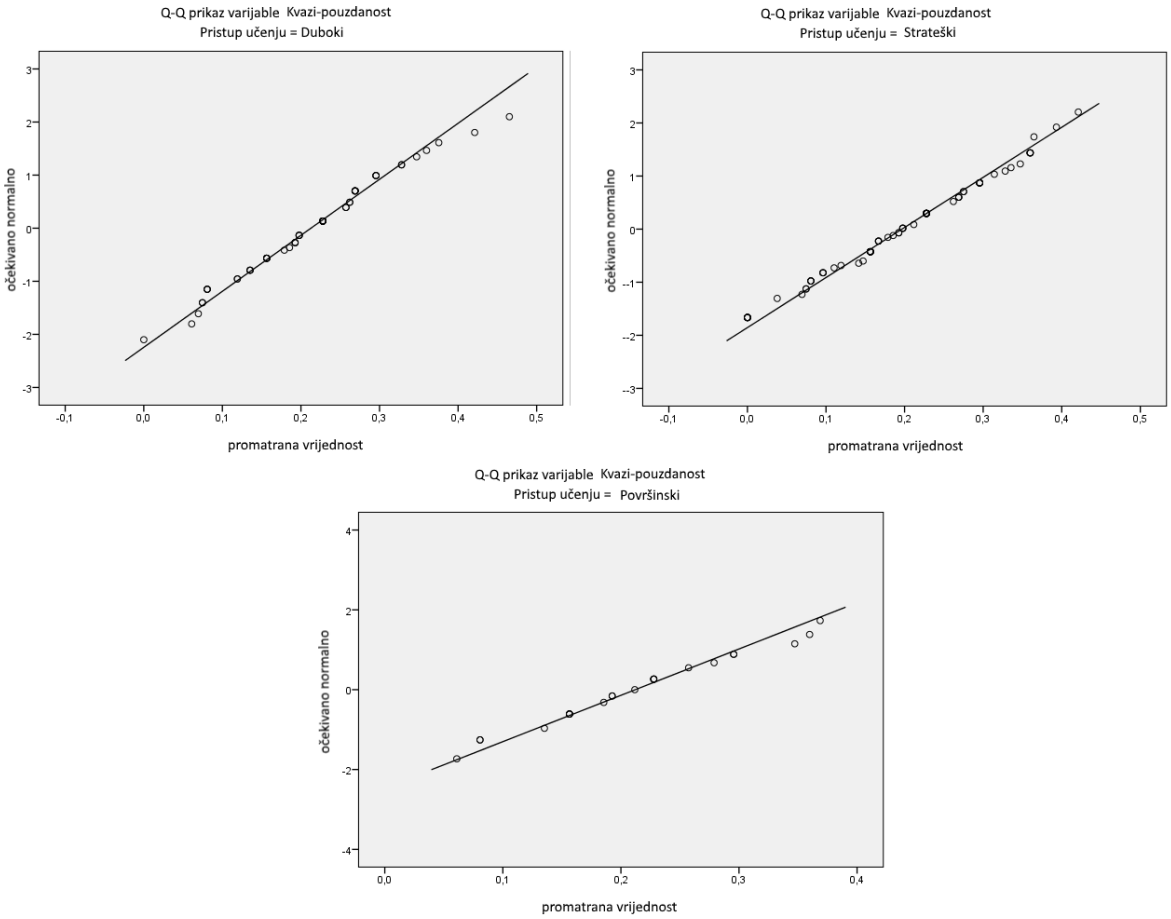

Slika 45. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na Pristup učenju

Rezultati Levenova testa su pokazali da ne postoji statistiki značajna razlika u varijancama varijable *Dijametar kvazi - pouzdanosti* u odnosu na *Pristup učenju* (F=0.857, df=2/147, p=0.427).

Rezultati jednosmjerne analize varijance pokazali su da nema statistički značajne razlike za *Dijametar kvazi - pouzdanosti* u odnosu na *Pristup učenju* (F=0.418, p=0.659).

5.6.2 Dijametar kvazi - pouzdanosti u odnosu na sudjelovanje u procjeni

Utjecaj nezavisne varijable *Procjena* na zavisnu varijablu *Dijametar kvazi – pouzdanosti* ispitao se Welchovom analizom varijance, na razini značajnosti od α=0.05 te dodatno provjerio Kruskal Walis testom.

Rezultati Kolmogorov-Smirnovljeva i Shapiro-Wilkova testa su pokazali da hipoteza H_0 nije prihvaćena za skupinu ispitanika koja je sudjelovala u samoprocjeni (**K-S=0.12, p=0.03;** S-**W=0.96, p=0.03**) te za skupinu ispitanika koji su sudjelovali i samorpocjeni i u vršnjačkoj

procjeni (**K-S=0.15, p=0.002;** S-W=0.97, p=0.12) (Tablica 45). Nakon što je iz skupa podataka za analizu isključen slučaj 145 koji je predstavljao stršilo za promatrani skup podataka, rezultat Kolmogoorv-Smirnovljeva testa i dalje je pokazivao da distribucija značajno odstupa od normalne distribucije (**K-S=0.16, p=0.001;** S-W=0.97, p=0.15), stoga je daljnja analiza provedena na početnom skupu od N=148 podataka.

Tablica 46. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Procjenu na uzorku od N=148 ispitanika

PROCJENA	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
		vrijed.	*p*	*vrijed.*	*p*
vršnjačka procjena	33	0.11	0.20	0.96	0.26
samoprocjena	**59**	**0.12**	**0.03**	**0.96**	**0.03**
vršnjačka i samoprocjena	**56**	**0.15**	**0.002**	**0.97**	**0.12**

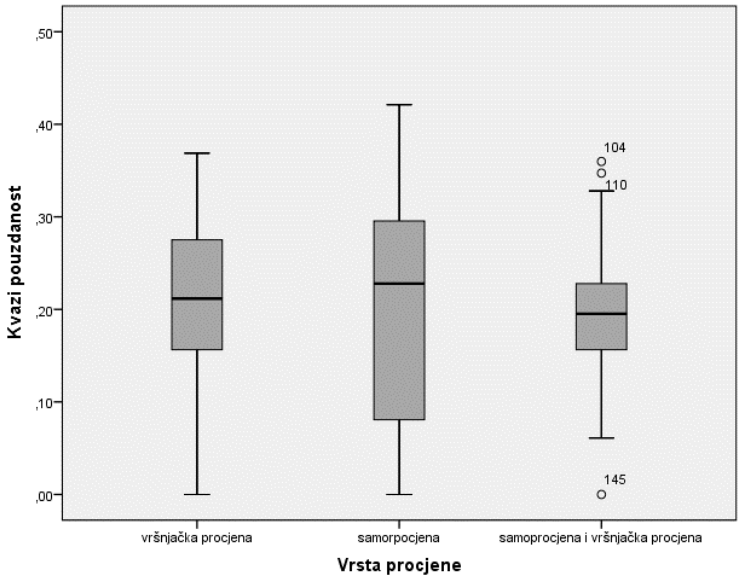

Slika 46. Kutijasti dijagrami varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu procjenu

S obzirom da rezultati testova distribucije podataka za varijablu *Dijametar kvazi - pouzdanosti* u odnosu na sudjelovanje u samoprocjeni, na uzorku od N=148 ispitanika, ne pokazuje konzistentne rezultate, izvršena je analiza simetričnosti i spljoštenosti (Tablica 46) i Q-Q prikaza (Slika 47).

Tablica 47. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Procjenu koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=148 ispitanika

PROCJENA	N	ARITMETIČKA SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
		vrijed.	*vrijed.*	*vrijed.*	*st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed.*	*st.pogr.*
vršnjačka procjena	33	1.20	0.02	-0.33	0.41	-0.80	-0.61	0.80	-0.76
samoprocjena	59	0.20	0.02	-0.04	0.31	-0.13	-1.08	0.61	-1.77
vršnjačka i samoprocjena	56	0.20	0.01	-0.10	0.32	-0.31	1.14	0.63	1.81

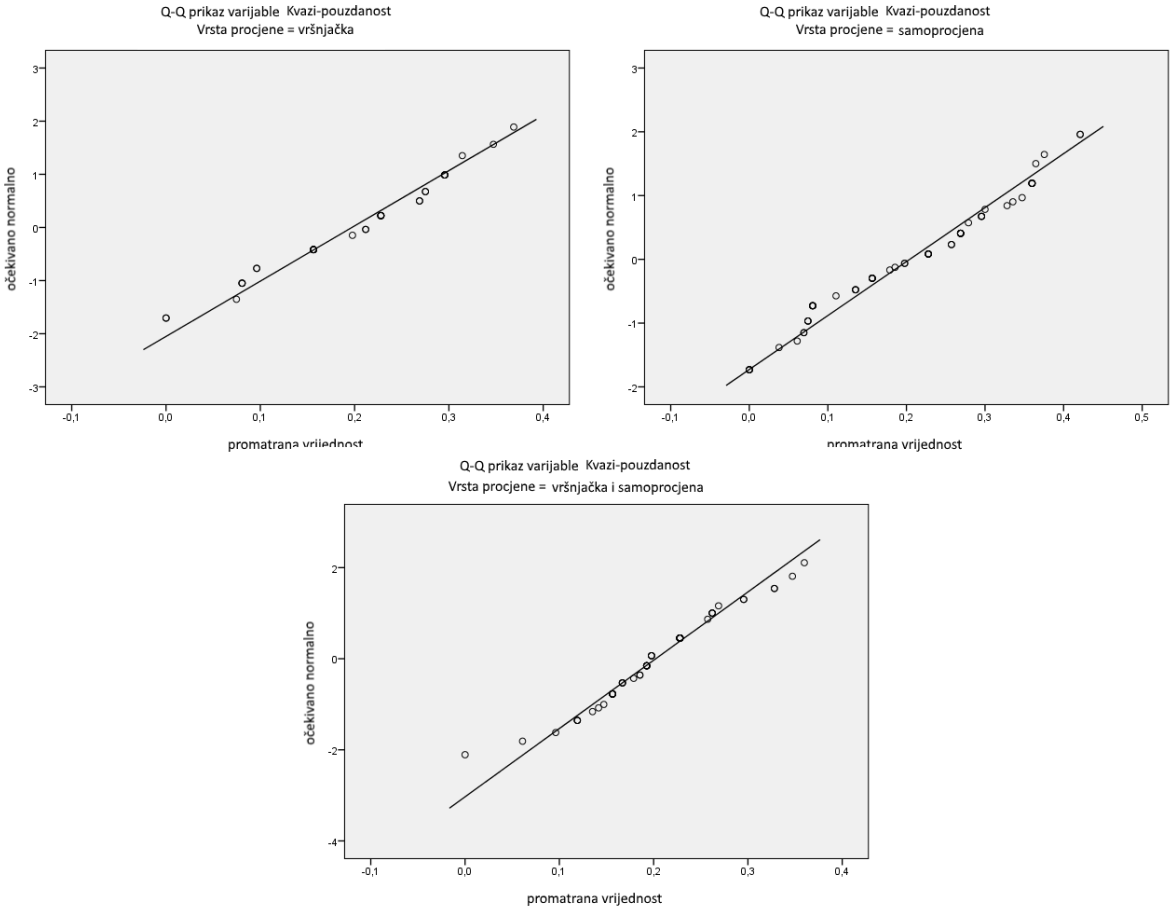

Slika 47. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na procjenu

Omjeri mjera asimetričnosti i spljoštenosti s pripadnim standardnim pogreškama su manje od |1.96| što ukazuje da distribucije svih promatranih skupina podataka ne odudaraju značajno od normalne distribucije. Q-Q prikaz za varijablu *Dijametar kvazi - pouzdanosti* u odnosu na Samoprocjenu pokazuje da podaci ne prate liniju normalne distribucije u potpunosti što ukazuje da je pitanje normalne distribucije podataka neodređeno.

Rezultati Levenova testa su pokazali da postoji statistiki značajna razlika u varijancama varijable *Dijametar kvazi - pouzdanosti* u odnosu na *Procjenu* (F=14.23, df=2/145, p=0.00).

Rezultati Welchove analize varijance pokazali su da nema statistički značajne razlike za *Dijametar kvazi - pouzdanosti* u odnosu na *Procjenu* (F=0.050, df=2/76.72, p=0.951).

Dobiveni rezultati su potvrđeni Kruskal Wallis testom (χ^2=0.20, p=0.96).

5.6.3 Dijametar kvazi - pouzdanosti u odnosu na sudjelovanje u samoprocjeni

Utjecaj nezavisne varijable *Samoprocjena* na zavisnu varijablu *Dijametar kvazi - pouzdanosti* ispitao se analizom varijance, na razini značajnosti od α=0.05.

Rezultati Kolmogorov-Smirnovljeva i Shapiro-Wilkova testa su pokazali da hipoteza H_0 nije prihvaćena za skupinu ispitanika koja je sudjelovala u samoprocjeni (**K-S=0.11, p=0.002;** S-W=0.98, p=0.09) (Tablica 47).

Tablica 48. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Samoprocjenu na uzorku od N=150 ispitanika

SAMOPROCJENA	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
		vrijed.	*p*	*vrijed.*	*p*
nije uključena	35	0.10	0.20	0.97	0.44
uključena	**115**	**0.11**	**0.002**	**0.98**	**0.09**

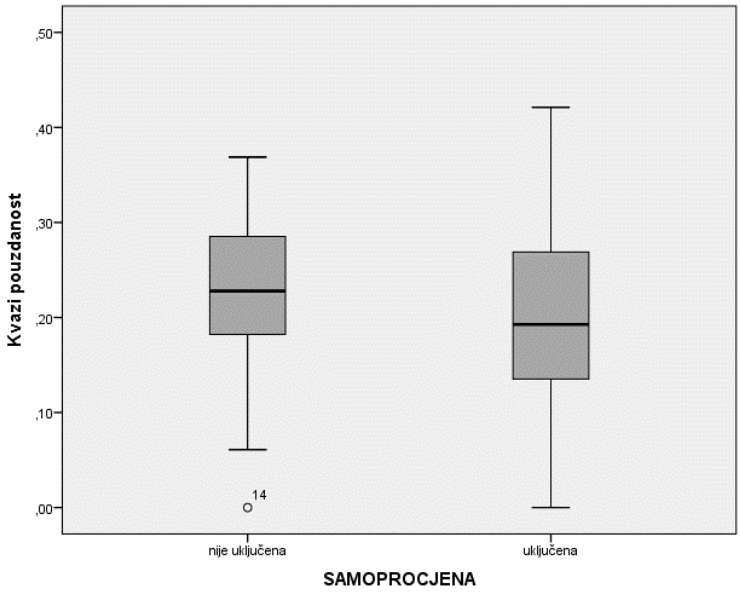

Slika 48. Kutijasti dijagrami varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na sudjelovanje u samoprocjeni

Nakon što je iz skupa podataka za analizu isključen slučaj 84 koji je predstavljao stršilo za promatrani skup podataka, rezultat Kolmogoorv-Smirnovljeva testa i dalje je pokazivao da distribucija značajno odstupa od normalne distribucije (**K-S=0.10, p=0.005;** S-W=0.98, p=0.09), stoga je daljnja analiza provedena na početnom skupu od N=150 podataka.

S obzirom da rezultati testova distribucije podataka za varijablu *Dijametar kvazi - pouzdanosti* u odnosu na sudjelovanje u samoprocjeni, na uzorku od N=150 ispitanika, ne pokazuje konzistentne rezultate, izvršena je analiza simetričnosti i spljoštenosti (Tablica 48) i Q-Q prikaza (Slika 49).

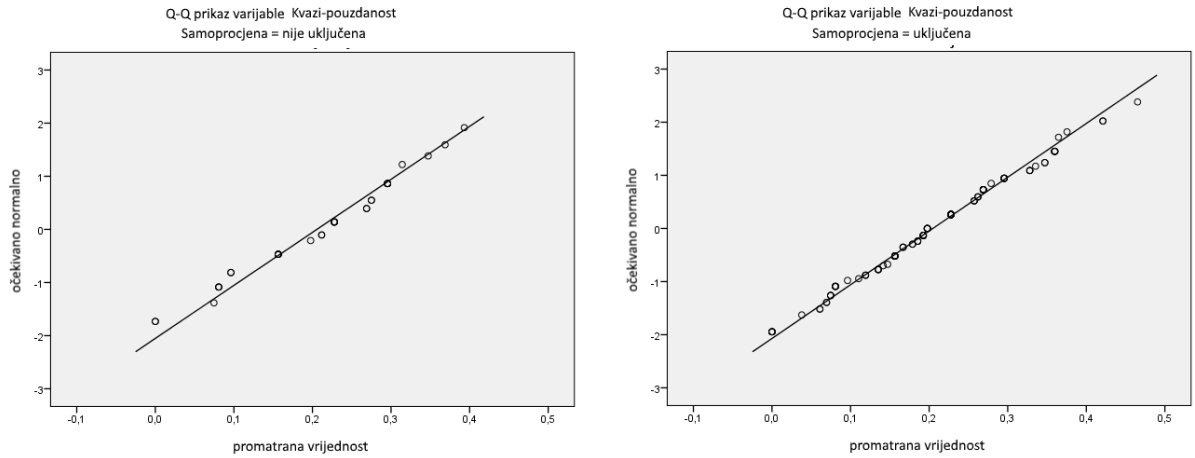

Slika 49. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na sudjelovanje u samoprocjeni

Omjeri mjera asimetričnosti i spljoštenosti s pripadnim standardnim pogreškama ukazuju da distribucije svih promatranih skupina podataka ne odudaraju značajno od normalne distribucije, kao i Q-Q prikazi.

Tablica 49. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Samoprocjenu koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=150 ispitanika

SAMOPROCJENA	**N**	**ARITMETIČKA SREDINA**		**MJERA ASIMETRIČNOSTI**			**MJERA SPLJOŠTENOSTI**		
		vrijed.	*vrijed.*	*vrijed.*	*st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed.*	*st.pogr.*
nije uključena	35	0.23	0.02	-0.12	0.40	0.30	0.29	0.23	1.26
uključena	115	0.23	0.01	-0.61	0.78	-0.78	-0.50	0.48	-1.04

Rezultati Levenova testa su pokazali da ne postoji statistiki značajna razlika u varijancama varijable *Dijametar kvazi - pouzdanosti* u odnosu na *Samoprocjenu* (F=0.071, df=1/148, p=0.791).

Rezultati jednosmjerne analize varijance pokazali su da nema statistički značajne razlike za *Dijametar kvazi - pouzdanosti* u odnosu na *Samoprocjenu* (F=0.002, p=0.961).

5.6.4 Dijametar kvazi - pouzdanosti u odnosu na sudjelovanje u vršnjačkoj procjeni

Utjecaj nezavisne varijable *Vršnjačka procjena* na zavisnu varijablu *Dijametar kvazi - pouzdanosti* ispitao se Welchovom analizom varijance, na razini značajnosti α=0.05.

Rezultati Kolmogorov-Smirnovljeva testa su pokazali da hipoteza H_0 nije prihvaćena za obje skupine ispitanika, i ispitanike koji nisu sudjelovali u vršnjačkoj procjeni (**K-S=0.12, p=0.03; S-W=0.96, p=0.02**) i ispitanike koji su sudjelovali u vršnjačkoj procjeni (**K-S=0.12, p=0.005;** S-W=0.98, p=0.10).

S obzirom na rezultati testova distribucije podataka za varijablu *Dijametar kvazi - pouzdanosti* u odnosu na sudjelovanje u vršnjačkoj procjeni, na uzorku od N=150 ispitanika, izvršena je analiza simetričnosti i spljoštenosti (Tablica 49) i Q-Q prikaza (Slika 50). Omjeri mjera asimetričnosti i spljoštenosti s pripadnim standardnim pogreškama ukazuju da distribucije svih promatranih skupina podataka ne odudaraju značajno od normalne distribucije, kao i Q-Q prikazi.

Tablica 50. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Vršnjačku procjenu na uzorku od N=150 ispitanika

VRŠNJAČKA PROCJENA	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
		vrijed.	*p*	*vrijed.*	*p*
nije uključena	61	0.12	0.03	0.96	0.02
uključena	89	0.12	0.005	0.98	0.10

Tablica 51. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Vršnjačku procjenu koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=150 ispitanika

VRŠNJAČKA PROCJENA	N	ARITMETIČKA SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
		vrijed.	*st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed./st.pog.*	*vrijed.*	*st.pog.*	*vrijed./st.pog.*
nije uključena	61	0.24	0.02	0.15	0.31	0.48	-0.94	0.60	-1.57
uključena	89	0.22	0.01	-0.09	0.26	-0.35	0.11	0.51	0.22

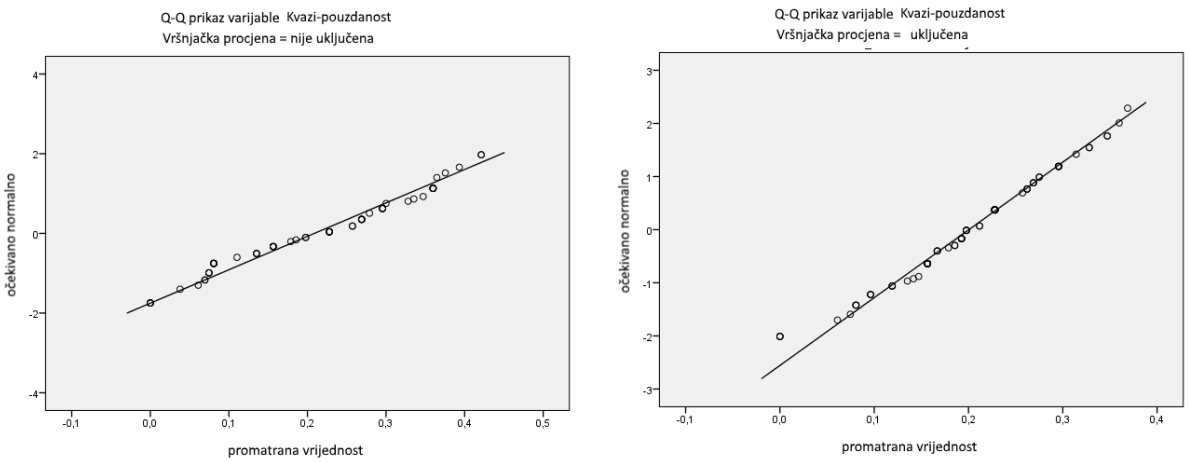

Slika 50. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na sudjelovanje u vršnjačkoj procjeni, na uzorku od N=150 ispitanika

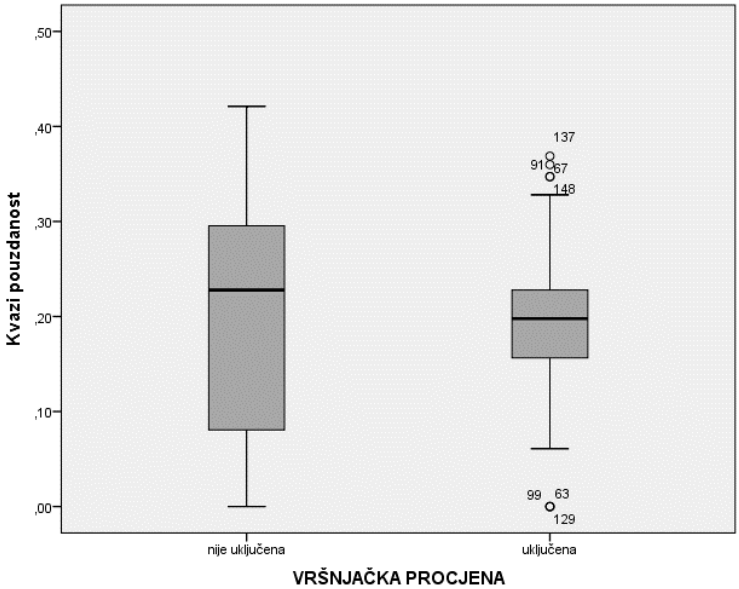

Slika 51. Kutijasti dijagram varijable Dijametar kvazi - pouzdanosti u odnsou na sudjelovanje u vršnjačkoj procjeni, na uzorku od N=150 ispitanika

Rezultati Levenova testa su pokazali da postoji statistiki značajna razlika u varijancama varijable *Dijametar kvazi - pouzdanosti* u odnosu na *Vršnjačku procjenu* (F=24.287, df=1/148, p=0.000).

Rezultati Welchove analize varijance pokazali su da nema statistički značajne razlike za *Dijametar kvazi - pouzdanosti* u odnosu na *Vršnjačku procjenu* (F=0.669, df=1/91.93, p=0.416).

5.6.5 Dijametar kvazi - pouzdanosti u odnosu na Spol

Utjecaj nezavisne varijable *Spol* na zavisnu varijablu *Dijametar kvazi - pouzdanosti* ispitao se analizom varijance, na razini značajnosti od α=0.05.

Rezultati Kolmogorov-Smirnovljeva testa su pokazali da hipoteza H_0 nije prihvaćena za skupinu ispitanika ženskog spola (**K-S=0.09, p=0.004; S-W=0.98, p=0.04**) (Tablica 51).

S obzirom na rezultati testova distribucije podataka za varijablu *Dijametar kvazi - pouzdanosti* u odnosu na *Spol*, na uzorku od N=150 ispitanika, izvršena je analiza simetričnosti i spljoštenosti (Tablica 52) i Q-Q prikaza (Slika 52).

Tablica 52. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Spol na uzorku od N=150 ispitanika

SPOL	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
		vrijed.	*p*	*vrijed.*	*p*
muški	6	0.22	0.20	0.88	0.25
ženski	**144**	**0.09**	**0.004**	**0.98**	**0.04**

Tablica 53. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Spol koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=150 ispitanika

SPOL	N	ARITMETIČKA SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
		vrijed.	*st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed./ st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed./st.pogr.*
muški	6	0.14	0.02	-0.58	0.85	-0.68	-1.65	1.74	-0.95
ženski	144	0.23	0.01	0.15	0.20	0.75	-0.21	0.40	-0.53

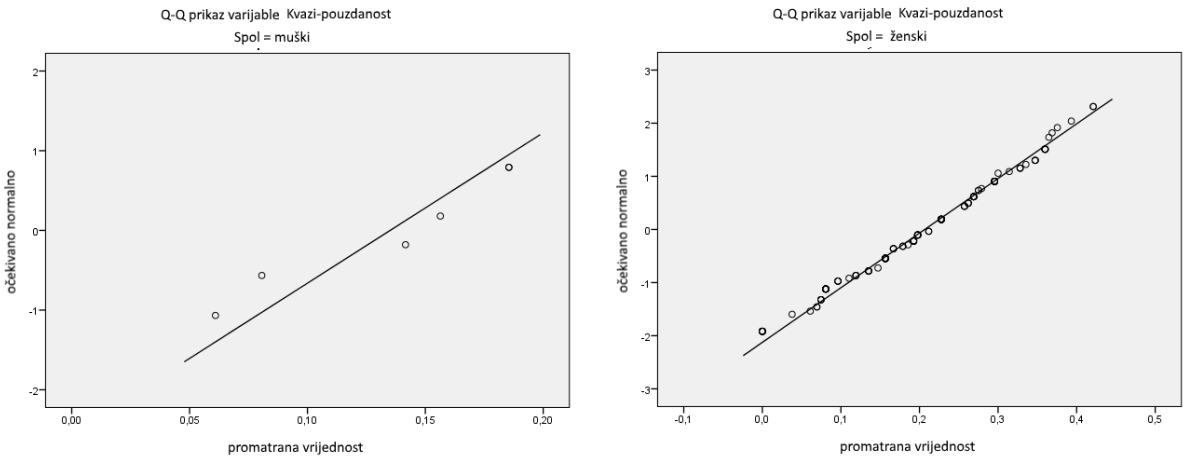

Slika 52. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na spol, na uzorku od N=150 ispitanika

Omjeri mjera asimetričnosti i spljoštenosti s pripadnim standardnim pogreškama ukazuju da distribucije svih promatranih skupina podataka ne odudaraju značajno od normalne distribucije, kao i Q-Q prikaz (Slika 52).

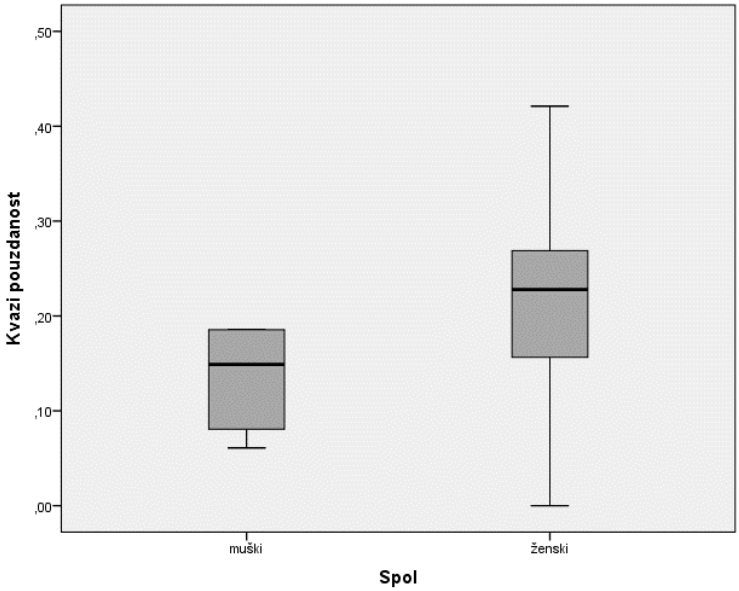

Slika 53. Kutijasti dijagram varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na spol, na uzorku od N=150 ispitanika

Rezultati Levenova testa su pokazali da ne postoji statistiki značajna razlika u varijancama varijable *Dijametar kvazi - pouzdanosti* u odnosu na *Spol* (F=2.552, df=1/148, p=0.112).

Rezultati jednosmjerne analize varijance pokazali su da nema statistički značajne razlike za *Dijametar kvazi - pouzdanosti* u odnosu na *Spol* (F=3.240, df=1/149, p=0.074).

5.6.6 Dijametar kvazi - pouzdanosti u odnosu na Studijsku godinu

Utjecaj nezavisne varijable *Studijska godina* na zavisnu varijablu *Dijametar kvazi - pouzdanosti* ispitao se analizom varijance, na razini značajnosti α=0.05.

Rezultati Kolmogorov-Smirnovljeva testa su pokazali da hipoteza H_0 nije prihvaćena za skupinu ispitanika treće studijske godine preddiplomskog studija (**K-S=0.12, p=0.001;** S-W=0.97, p=0.07).

S obzirom na rezultati testova distribucije podataka za varijablu *Dijametar kvazi - pouzdanosti* u odnosu na treću studijsku godinu preddiplomskog studija, na uzorku od N=147 ispitanika, izvršena je analiza simetričnosti i spljoštenosti (Tablica 53) i Q-Q prikaza (Slika 55). Omjeri mjera asimetričnosti i spljoštenosti s pripadnim standardnim pogreškama ukazuju da

distribucije svih promatranih skupina podataka ne odudaraju značajno od normalne distribucije, kao i Q-Q prikaz.

Tablica 54. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Studijsku godinu na uzorku od N=147 ispitanika

STUDIJSKA GODINA	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
		vrijed.	*p*	*vrijed.*	*p*
prva preddiplomskog	38	0.10	0.20	0.98	0.71
treća preddiplomskog	**92**	**0.12**	**0.001**	**0.97**	**0.07**
prva diplomskog	17	0.12	0.20	0.94	0.30

Tablica 55. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Studijsku godinu koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=147 ispitanika

STUDIJSKA GODINA	N	ARITMETIČKA SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
		vrijed.	*st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed./ st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed./st.pogr.*
prva preddiplomskog	38	0.23	0.02	0.66	0.38	1.74	0.50	0.75	0.67
treća preddiplomskog	92	0.24	0.01	0.02	0.25	0.08	-0.32	0.50	-0.64
prva diplomskog	17	0.21	0.04	0.04	0.55	0.07	-0.88	1.06	-0.83

Rezultati Levenova testa su pokazali da ne postoji statistiki značajna razlika u varijancama varijable *Dijametar kvazi - pouzdanosti* u odnosu na *Studijsku godinu* (F=1.237, df=2/144, p=0.293).

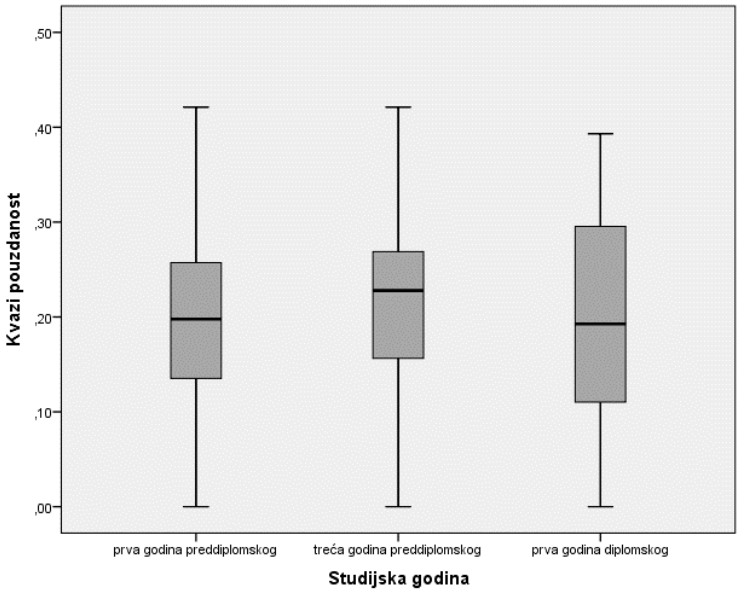

Slika 54. Kutijasti dijagrami varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na studijsku godinu, na uzorku od N=147 ispitanika

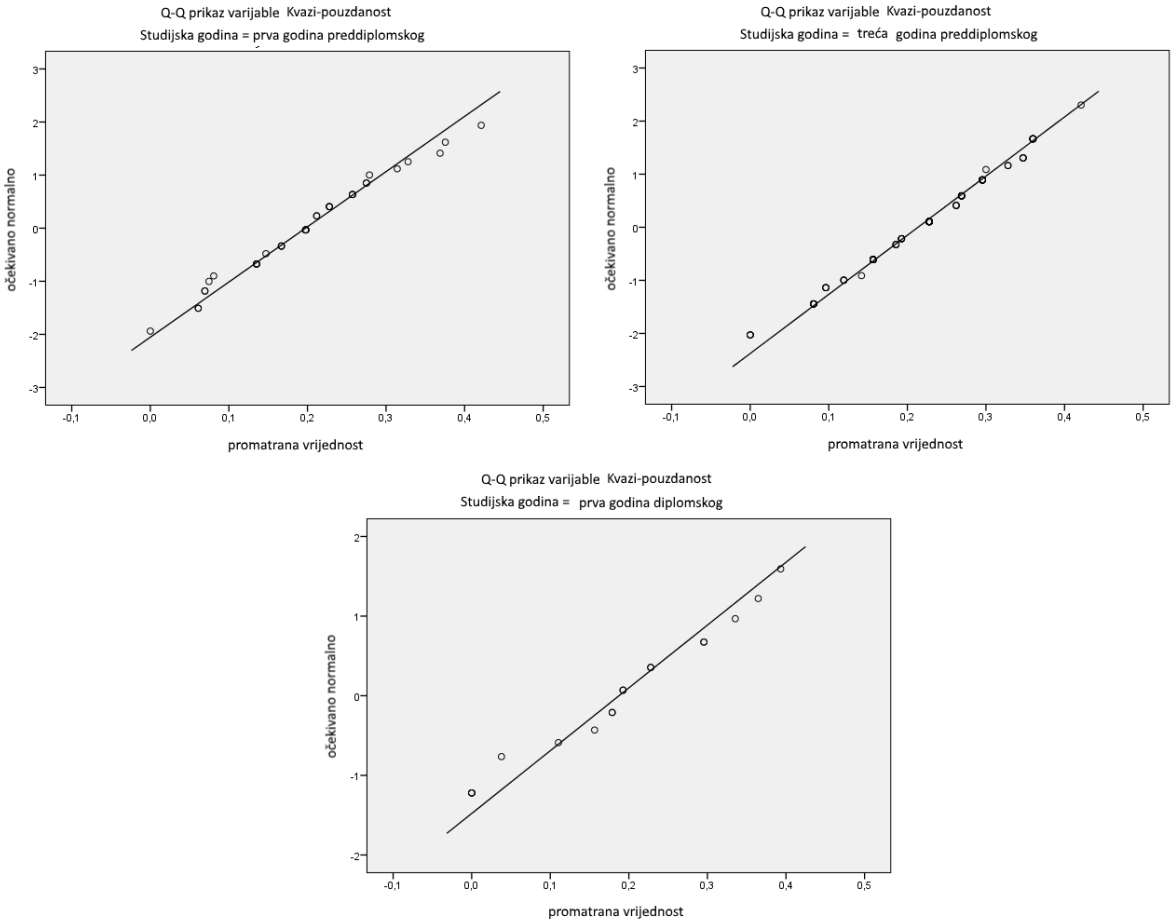

Slika 55. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na studijsku godinu, na uzorku od N=147 ispitanika

Rezultati jednosmjerne analize varijance pokazali su da nema statistički značajne razlike za *Dijametar kvazi - pouzdanosti* u odnosu na *Studijsku godinu* (F=0.379, df=2/144, p=0.685).

5.6.7 Dijametar kvazi - pouzdanosti u odnosu na Razinu studija

Utjecaj nezavisne varijable *Razina studija* na zavisnu varijablu *Dijametar kvazi - pouzdanosti* ispitao se analizom varijance, na razini značajnosti α=0.05.

Rezultati Kolmogorov-Smirnovljeva i Shapiro-Wilkova testa su pokazali da hipoteza H_0 nije prihvaćena za skupinu ispitanika sa preddiplomske razine studija (**K-S=0.09, p=0.001;** S-W=0.98, p=0.13) (Tablica 55).

S obzirom na rezultate testova distribucije podataka za varijablu *Dijametar kvazi - pouzdanosti* u odnosu na preddiplomsku razinu studija, na uzorku od N=150 ispitanika, izvršena je analiza simetričnosti i spljoštenosti (Tablica 56) i Q-Q prikaza (Slika 57). Omjeri mjera asimetričnosti

i spljoštenosti s pripadnim standardnim pogreškama ukazuju da distribucije svih promatranih skupina podataka ne odudaraju značajno od normalne distribucije, kao i Q-Q prikaz (Slika 57).

Tablica 56. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Razinu studija na uzorku od N=150 ispitanika

RAZINA STUDIJA	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
		vrijed.	*p*	*vrijed.*	*p*
preddiplomska	**130**	**0.09**	**0.01**	**0.98**	**0.13**
diplomska	20	0.12	0.20	0.94	0.30

Tablica 57. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Razinu studija koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=150 ispitanika

RAZINA STUDIJA	N	ARITMETIČKA SREDINA		ARITMETIČKA SREDINA			MJERA SPLJOŠTENOSTI		
		vrijed.	*vrijed.*	*vrijed.*	*st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed.*	*st.pogr.*
preddiplomska	130	0.23	0.01	0.25	0.21	1.19	-0.21	0.42	-0.5
diplomska	20	0.19	0.03	0.36	0.51	0.71	-0.86	0.99	-0.87

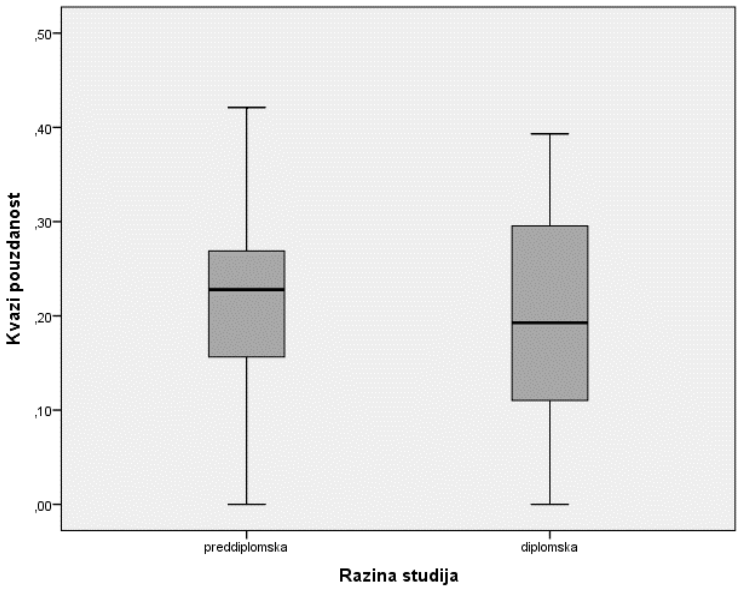

Slika 56. Kutijasti dijagrami varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na razinu studija, na uzorku od N=150 ispitanika

Rezultati Levenova testa su pokazali da ne postoji statistiki značajna razlika u varijancama varijable *Dijametar kvazi - pouzdanosti* u odnosu na *Razinu studija* (F=2.578, df=1/148, p=0.111).

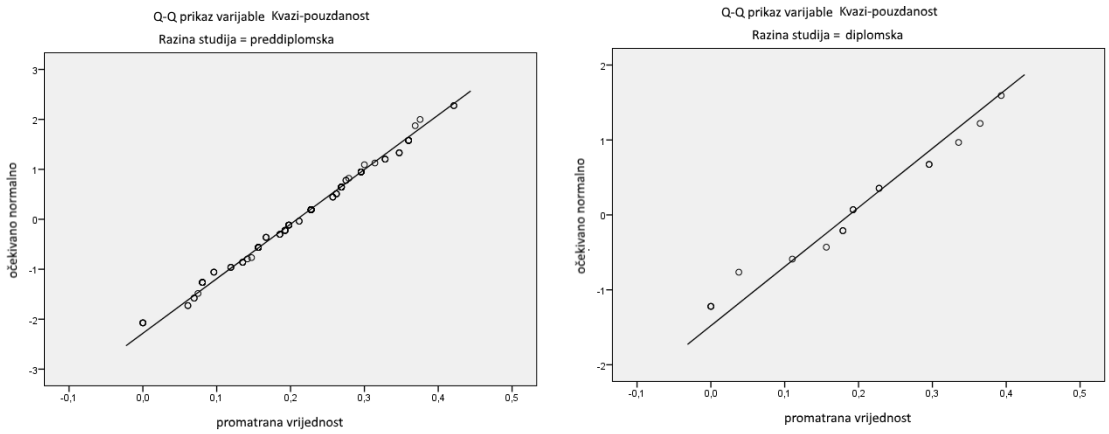

Slika 57. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na razinu studija, na uzorku od N=150 ispitanika

Rezultati jednosmjerne analize varijance pokazali su da nema statistički značajne razlike za *Dijametar kvazi - pouzdanosti* u odnosu na *Razinu studija* (F=2.439, p=0.120).

5.6.8 Dijametar kvazi - pouzdanosti u odnosu na Znanstveno područje kolegija

Utjecaj nezavisne varijable *Razina studija* na zavisnu varijablu *Dijametar kvazi - pouzdanosti* ispitao se Welchovom analizom varijance, na razini značajnosti α=0.05.

Rezultati Kolmogorov-Smirnovljeva i Shapiro-Wilkova testa su pokazali da je hipoteza H_0 prihvaćena za sve skupine ispitanika (Tablica 57).

Tablica 58. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu Dijametar kvazi - pouzdanosti u odnosu na Znanstveno područje kolegija na uzorku od N=149 ispitanika

ZNAN. PODRUČJE KOLEGIJA	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
		vrijed.	*p*	*vrijed.*	*p*
društveno	42	0.13	0.06	0.96	0.18
prirodno	83	0.10	0.06	0.98	0.14
humanističko	8	0.18	0.20	0.90	0.30
tehničko	17	0.12	0.20	0.94	0.30

Deskriptivna statistika za varijablu *Dijametar kvazi - pouzdanosti*, u odnosu *Znanstveno područje kolegija*, prikazana je u Tablici 58.

Tablica 59. Deskriptivna ststistika za varijablu Dijametar kvazi - pouzdanosti u odnosu na Znanstveno područje kolegija koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=149 ispitanika

ZNAN. PODRUČJE KOLEGIJA	N	ARITMETIČKA SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
		vrijed.	*st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed./ st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed./ st.pogr.*
društveno	42	0.22	0.01	-0.40	0.37	1.08	0.06	0.72	0.08
prirodno	83	0.20	0.01	0.06	0.26	0.23	-0.35	0.52	-0.67
humanističko	8	0.24	0.06	-0.19	0.79	0.24	-1.99	1.59	-1.25
tehničko	17	0.19	0.03	0.12	0.55	0.22	-0.92	1.06	-0.87

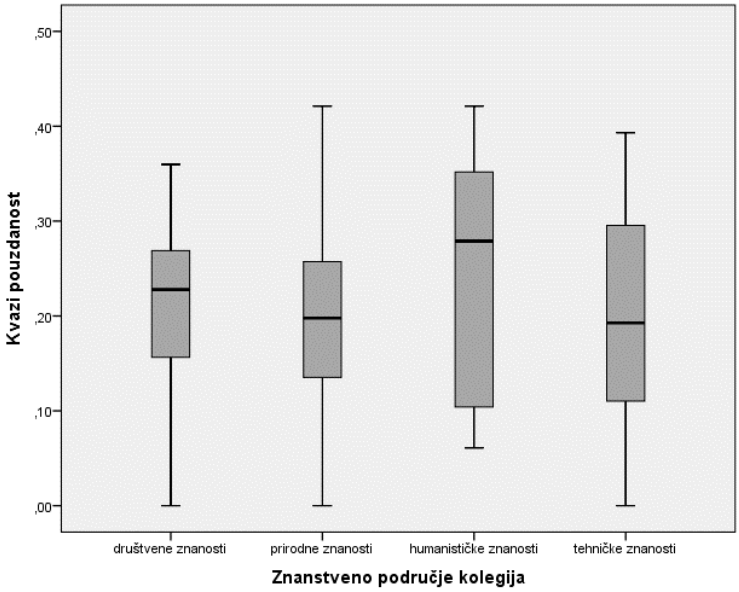

Slika 58. Kutijasti dijagrami varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na znanstveno područje kolegija, na uzorku od N=150 ispitanika

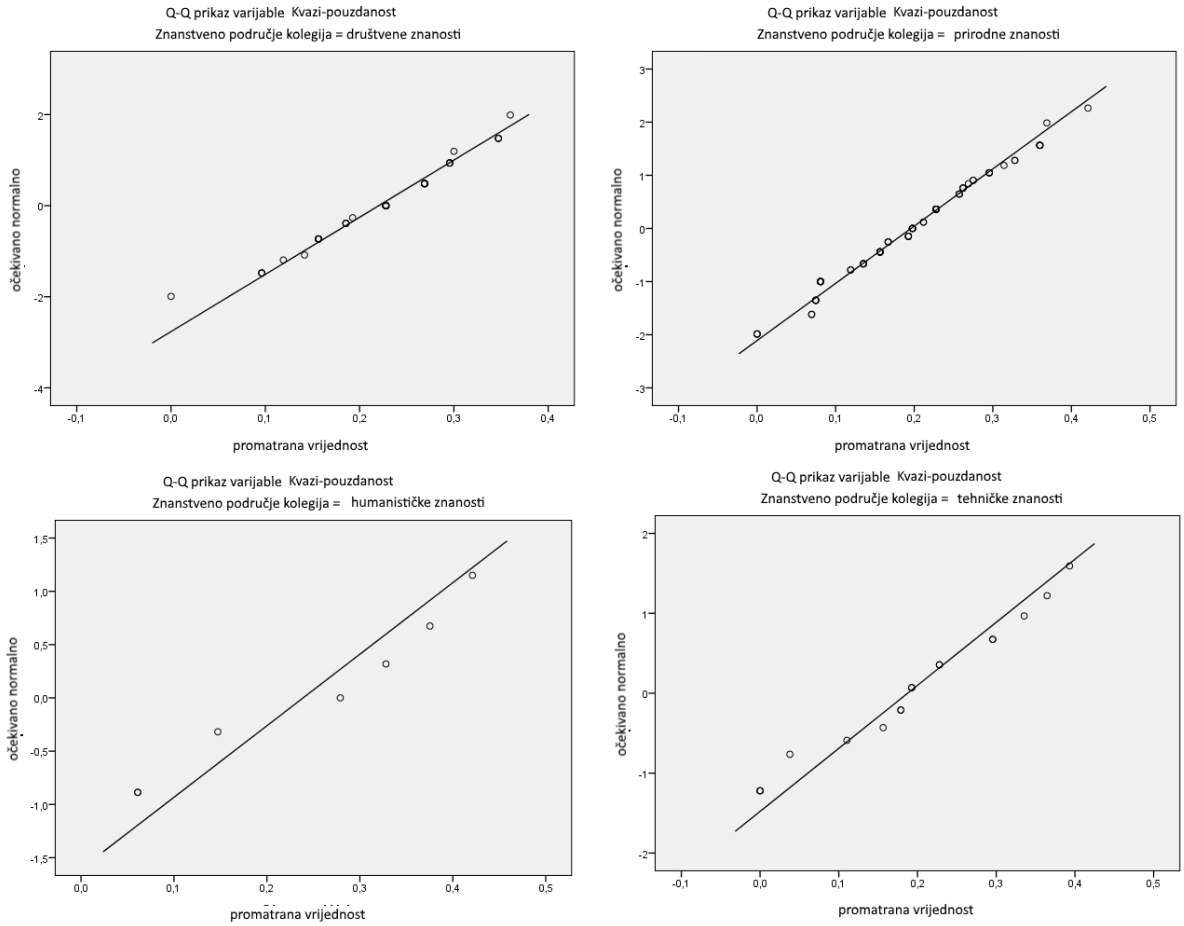

Slika 59. Q-Q prikazi varijable Dijametar kvazi - pouzdanosti za sve skupine ispitanika u odnosu na znantveno područje kolegija, na uzorku od N=150 ispitanika

Rezultati Levenova testa su pokazali da postoji statistički značajna razlika u varijancama varijable *Dijametar kvazi - pouzdanosti* u odnosu na *Znanstveno područje kolegija* (F=4.784, df=3/145, p=0.003).

Rezultati Welchove analize varijance pokazali su da nema statistički značajne razlike za *Dijametar kvazi - pouzdanosti* u odnosu na *Znanstveno područje kolegija* (F=1.278, df=3/24.23, p=0.304).

5.7 Hipoteza H4

H4: Sudjelovanje u procesu vršnjačke procjene i/ili samoprocjene rješenja problemskog zadatka u okviru online suradničkog učenja utječe na percepciju budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi.

Promatrana hipoteza testirana je tro-faktorskom analizom varijance s ponovljenim mjerenjem, na razini značajnosti α=0.05.

Za utvrđivanje normalne distribucije podataka korišteni su Kolmogorov-Smirnovljev i Shapiro-Wilkov test nivoa značajnosti α=0.05 kojim se testirala nulta hipoteza da distribucija varijable *TPACK* u danom uzorku ne odstupa značajno od normalne za promatrani izvor procjene i vrijeme. Rezultati su pokazali da je hipoteza H_0 odbačena za skupinu ispitanika koji su sudjelovali i u vršnjačkoj procjeni i samoprocjeni prije sudjelovanja u postupku procjene (K-S=0.093, p=0.2; **S-W=0.942, p=0.008**). Nakon što je iz skupa podataka za analizu isključen slučaj 157 koji je predstavljao stršilo za promatrani skup podataka, rezultati Kolmogorov-Smirnovljeva i Shapiro-Wilksova testa su pokazali da je hipoteza H_0 prihvaćena za sve promatrane skupine ispitanika u odnosu na izvor procjene i vrijeme (Tablica 59), odnosno da distribucija promatrane skupine ne odstupa značajno od normalne distribucije podataka. Također, rezultati su pokazali da je hipoteza H_0 odbačena za varijablu *TPACK_poslije-TPACK_prije* za skupinu ispitanika koji su sudjelovali u vršnjačkoj procjeni, ali nisu sudjelovali u samoprocjeni (**K-S=0.14, p=0.03**; S-W=0.98, p=0.58). S obzirom da je riječ o skupu podataka manjem od 50, kao relevantni su uzeti rezultati Shapiro-Wilkova testa, odnosno za promatranu distribuciju se smatra da ne odudara značajno od normalne distribucije.

Deskriptivna statistika za varijablu *TPACK,* u odnosu varijable *Samoprocjena, Vršnjačka procjena* i *Vrijeme*, prikazana je u Tablici 60.

Tablica 60. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu TPACK u odnosu na samoprocjenu, vršnjački procjenu i vrijeme, na uzorku od N=195 ispitanika

SAMO PROCJENA	VRŠNJAČKA PROCJENA	VRIJEME	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
				vrijed.	*p*	*vrijed.*	*p*
nije uključena	*nije uključena*	*prije*	34	0.09	0.20	0.98	0.90
		poslije	34	0.10	0.20	0.97	0.51
		TPACK_poslije-TPACK_prije	34	0.11	0.20	0.96	0.21
	uključena	*prije*	46	0.10	0.20	0.97	0.35
		poslije	46	0.09	0.20	0.98	0.58
		TPACK_poslije-TPACK_prije	**46**	**0.14**	**0.03**	**0.98**	**0.58**
uključena	*nije uključena*	*prije*	59	0.06	0.20	0.99	0.91
		poslije	59	0.08	0.20	0.98	0.49
		TPACK_poslije-TPACK_prije	59	0.10	0.20	0.96	0.07
	uključena	*prije*	56	0.08	0.20	0.98	0.46
		poslije	56	0.07	0.20	0.99	0.90
		TPACK_poslije-TPACK_prije	56	0.06	0.20	0.99	0.69

Kutijasti dijagrami za varijablu *TPACK* u odnosu na sudjelovanje u samoprocjeni i vršnjačkoj procjeni, prije sudjelovanja u eksperimentu, prikazani su na Slici 19, poslije sudjelovanja u eksperimentu na Slici 20, dok su kutijasti dijagrami za varijablu *TPACK_poslije-TPACK_prije* prikazani na Slici 21. Q-Q prikazi varijable *TPACK_poslije-TPACK_prije* prikazani su na Slici 22.

Tablica 61. Deskriptivna statistika za varijablu TPACK u odnosu na samoprocjenu, vršnjački procjenu i vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i njihovim omjerom na skupu podataka od N=195

SAMO PR.	VRŠ. PROCJ.	VRIJEME	N	ARITM. SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
				vrij	*st.p*	*vrij*	*st.p*	*vrij/st p..*	*vrij*	*st.p*	*vrij/ st p.*
nije uključena	*nije uključena*	*prije*	34	3.66	0.07	-0.19	0.40	-0.48	-0.19	0.79	-0.24
		poslije	34	3.71	0.08	0.25	0.40	0.63	0.64	0.79	0.81
		TPACK_poslije-TPACK_prije	34	0.05	0.05	0.37	0.40	0.93	1.19	0.79	1.51
	uključena	*prije*	46	3.58	0.06	0.08	0.35	0.23	0.68	0.69	0.99
		poslije	46	3.62	0.07	-0.29	0.35	0.83	-0.02	0.69	-0.03
		TPACK_poslije-TPACK_prije	46	0.06	0.05	-0.25	0.35	-0.71	0.50	0.69	0.72
uključena	*nije uključena*	*prije*	59	3.64	0.06	-0.01	0.31	-0.03	-0.14	0.61	-0.45
		poslije	59	3.72	0.06	0.32	0.31	1.03	0.37	0.61	0.61
		TPACK_poslije-TPACK_prije	**59**	**0.08**	**0.04**	**0.69**	**0.31**	**2.22**	**1.95**	**0.61**	**3.20**
	uključena	*prije*	56	3.61	0.05	0.10	0.32	0.31	-0.67	0.63	-1.06
		poslije	56	3.72	0.05	0.03	0.32	0.09	-0.15	0.63	-0.24
		TPACK_poslije-TPACK_prije	56	0.11	0.34	-0.28	0.32	-0.88	-0.19	0.63	-0.30

Homogenost varijanci provjerena je Levenovim testom homogenosti varijanci. Rezultati su pokazali da ne postoji statistički značajna razlika u varijancama varijable *TPACK* prije

sudjelovanja u samoprocjeni i/ili vršnjačkoj procjeni (F=0.01, df=3/191, p=0.99), odnosno poslije sudjelovanja u samoprocjeni i/ili vršnjačkoj procjeni (F=0.78, df=3/191, p=0.50).

Provedena je trofaktorska ANOVA s ponovljenim mjerenjem, na nivou značajnosti od α=0.05, u svrhu ispitivanja utjecaja nezavisnih varijabli *Samoprocjena* i *Vršnjačka procjena* na primjenu tehnologije u nastavi, prije i poslije sudjelovanja u postupku samoprocjene i vršnjačke procjene.

Prvo su testirani efekti između subjekata i rezultati su pokazali da niti jedan efekt nije statistički značajan. Glavni efekt za varijablu *Samoprocjena* pokazao je da nema statistički značajne razlike po pitanju sudjelovanja u postupku samoprocjene (F(1,191)=0.209, p=0.648). Također, glavni efekt za varijablu *Vršnjačka procjena* je pokazao da nema statistički značajne razlike po pitanju sudjelovanja u postupku vršnjačke procjene (F(1,191)=0.676, p=0.412). Međusobna interakcija spomenutih efekata također nije statistički značajna (F(1,191)=0.422, p=0.517).

Efekti unutar subjekata su pokazali da postoji statistički značajna razlika zavisne varijable *TPACK* u odnosu na nezavisnu varijablu *Vrijeme* (F(1,191)=8.526, p=0.004), odnosno postoji statistički značajna razlika u samoprocjeni vlastitih znanja o primjeni tehologije u nastavi prije i poslije sudjelovanja u procesu procjene. Efekti interakcije varijable *Vrijeme* s varijablama *Samoprocjena* i *Vršnjačka procjena* nisu statistički značajni (Tablica 61).

Tablica 62. Razine vjerojatnosti F vrijednosti u faktorskoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu TPACK u odnosu na nezavisne varijable Samoprocjena, Vršnjačka procjena i Vrijeme

TPACK	**Stupnjevi slobode**	**Wilks' Lambda (pogreška = 191)**		
		vrijednost	F	p
VRIJEME	**1**	**0.957**	**8.526**	**0.004**
VRIJEME * SAMOPROCJENA	1	0.994	1.211	0.273
VRIJEME * VRŠNJAČKA PROCJENA	1	1.000	0.059	0.808
VRIJEME * SAMOPROCJENA * VRŠNJAČKA PROCJENA	1	0.998	0.306	0.581

5.7.1 Percepcija budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi u odnosu na spol

Utjecaj nezavisnih varijabli *Spol* i *Vrijeme* na zavisnu varijablu *TPACK* ispitao se dvo-faktorskom analizom varijance s ponovljenim mjerenjem, na razini značajnosti α=0.05. Faktore u ovoj dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Spol* i *Vrijeme* te zavisna varijabla *TPACK*.

Rezultati Kolmogorov-Smirnovljeva i Shapiro-Wilkova testa su pokazali da je hipoteza H_0 prihvaćena za sve skupine ispitanika osim skupine ispitanika ženskog spola prije sudjelovanja u postupku procjene (K-S=0.037, p=0.2; **S-W=0.981, p=0.011**). Nakon što je iz skupa podataka za analizu isključen slučaj 159 koji je predstavljao stršilo za promatrani skup podataka, rezultati Kolmogorov-Smirnovljeva i Shapiro-Wilkova testa su pokazali da je hipoteza H_0 prihvaćena za sve promatrane skupine ispitanika u odnosu na spol i vrijeme (Tablica 62), odnosno da distribucija promatranih skupina varijabli ne odstupa značajno od normalne distribucije podataka na uzorku od N=195 ispitanika.

Tablica 63. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu TPACK u odnosu na vrijeme i spol na skupu podataka od N=195 ispitanika

VRIJEME	SPOL	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
			vrijed.	*p*	*vrijed.*	*p*
prije	***muški***	11	0.13	0.20	0.93	0.39
	ženski	184	0.04	0.20	0.99	0.57
poslije	***muški***	11	0.12	0.20	0.96	0.76
	ženski	184	0.06	0.09	0.99	0.26
TPACK_poslije-TPACK_prije	***muški***	11	0.15	0.20	0.94	0.54
	ženski	184	0.05	0.20	0.99	0.09

Deskriptivna statistika za varijablu *TPACK*, u odnosu varijable *Spol* i *Vrijeme*, prikazana je u Tablici 63.

Tablica 64. Deskriptivna ststistika za varijablu TPACK u odnosu na Spol i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima na uzorku od N=195 ispitanika

VRIJEME	SPOL	N	ARITMETIČKA SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
			vrijed.	*st.pogr.*	*vrijed.*	*st.pogr.*	*vrijed./st. pogr.*	*vrijed.*	*st.pogr.*	*vrijed./st. pogr.*
prije	***muški***	11	3.71	0.13	0.66	0.66	1.00	-0.41	1.28	-0.32
	ženski	184	3.62	0.03	-0.03	0.18	-0.17	-0.17	0.36	-0.47
poslije	***muški***	11	3.80	0.16	0.08	0.66	0.12	-0.72	1.28	-0.56
	ženski	184	3.69	0.03	0.01	0.18	0.06	0.34	0.36	0.94
TPACK_poslije-TPACK_prije	***muški***	11	0.09	0.08	-0.50	0.66	-0.76	-0.62	1.28	-0.48
	ženski	184	0.08	0.02	0.16	0.18	0.89	1.15	0.36	**3.19**

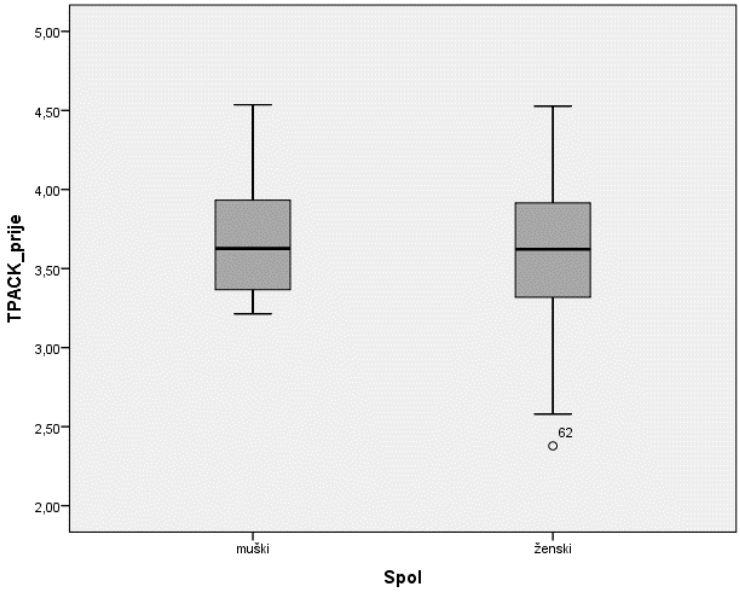

Slika 60. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na spol, na skupu podataka od N=195 ispitanika, prije sudjelovanja u eksperimentu

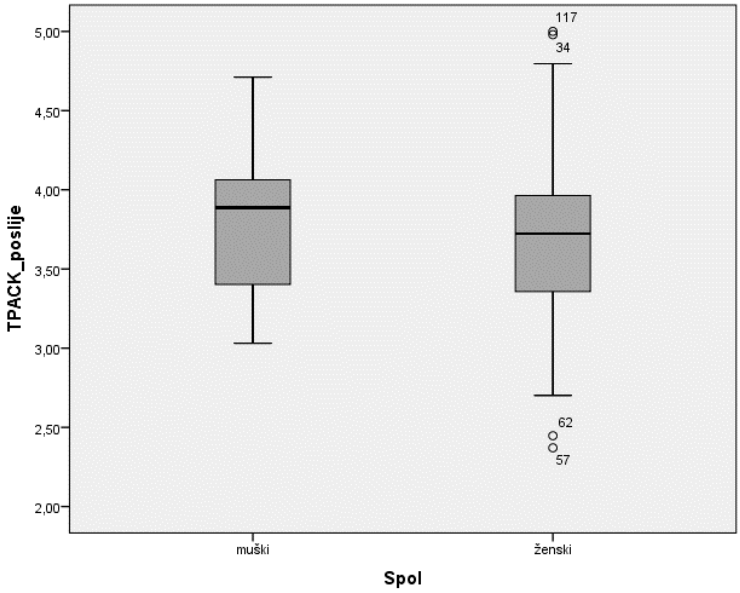

Slika 61. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na spol, na skupu podataka od N=195 ispitanika, poslije sudjelovanja u eksperimentu

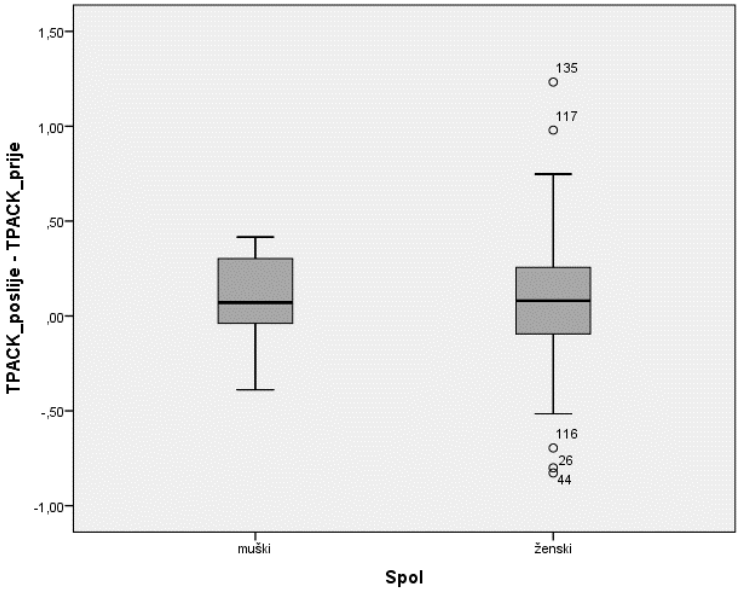

Slika 62. Kutijasti dijagrami varijable TPACKposlije-TPACK_prije za sve skupine ispitanika u odnosu na spol, na skupu podataka od N=195 ispitanika

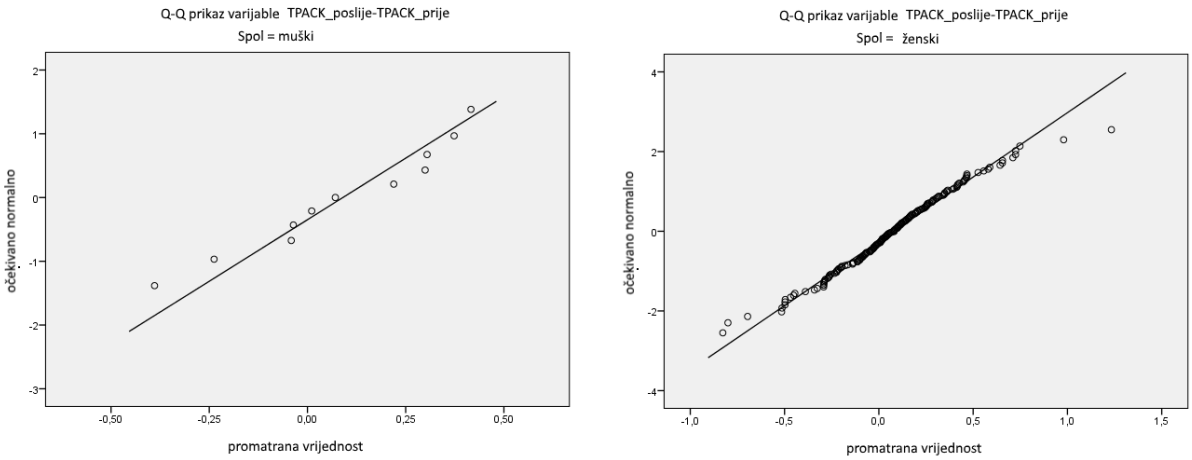

Slika 63. Q-Q prikazi varijable TPACKposlije-TPACK_prije za sve skupine ispitanika u odnosu na spol, na skupu podataka od N=195 ispitanika

Rezultati Levenova testa su pokazali da ne postoji statistiki značajna razlika u varijancama varijable TPACK u odnosu spol i vrijeme prije sudjelovanja u eksperimentu (F=0.049, df=1/193, p=0.825), odnosno poslije sudjelovanja u eksperimentu (F=0.678, df=1/193, p=0.411).

Provedena je dvo-faktorska ANOVA s ponovljenim mjerenjem, na nivou značajnosti od α=0.05, u svrhu ispitivanja utjecaja nezavisne varijable *Spol* na percepciju budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi, prije i poslije sudjelovanja u eksperimentu.

Prvo su testirani efekti između subjekata. Glavni efekt za varijablu *Spol* je pokazao da nema statistički značajne razlike u percepciju budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi prije i nakon sudjelovanja u eksperimentu (F=0.727, df=(1,193), p=0.395).

Efekti unutar subjekata su pokazali da glavni efekt nije statistički značajan, kao niti međusobna interakcija efekata. Glavni efekt za varijablu *Vrijeme* kao i efekt interakcije varijable *Vrijeme* s varijablom *Spol* prikazani su u Tablici 64.

Tablica 65. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu TPACK u odnosu na nezavisne varijable Spol i Vrijeme

Duboki	**Stupnjevi slobode**	**Wilks' Lambda (pogreška = 194)**		
		vrijednost	F	p
VRIJEME	1	0.987	2.600	0.109
VRIJEME * SPOL	1	1.000	0.030	0.863

5.7.2 Percepcija budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi u odnosu na studijsku godinu

Utjecaj nezavisnih varijabli *Studijska godina* i *Vrijeme* na zavisnu varijablu *TPACK* ispitao se dvo-faktorskom analizom varijance s ponovljenim mjerenjem, na razini značajnosti α=0.05. Faktore u ovoj dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Studijska godina* i *Vrijeme* te zavisna varijabla *TPACK*.

Rezultati Kolmogorov-Smirnovljeva i Shapiro-Wilkova testa su pokazali da je hipoteza H_0 prihvaćena za sve skupine ispitanika osim skupine ispitanika treće studijske godine prije sudjelovanja u postupku procjene (K-S=0.046, p=0.2; **S-W=0.967, p=0.006**). Nakon što je iz skupa podataka za analizu isključen slučaj 170 koji je predstavljao stršilo za promatrani skup podataka, rezultati Kolmogorov-Smirnovljeva i Shapiro-Wilkova testa su pokazali da je hipoteza H_0 prihvaćena za sve promatrane skupine ispitanika u odnosu na spol i vrijeme (Tablica 65), odnosno da distribucija promatranih skupina varijabli ne odstupa značajno od normalne distribucije podataka na uzorku od N=195 ispitanika.

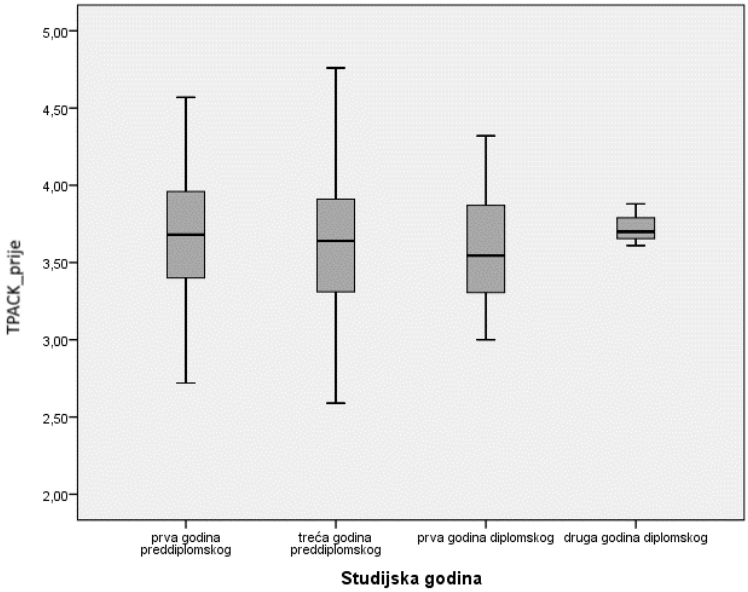

Slika 64. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na Studijsku godinu, na skupu podataka od N=195 ispitanika, prije sudjelovanja u eksperimentu

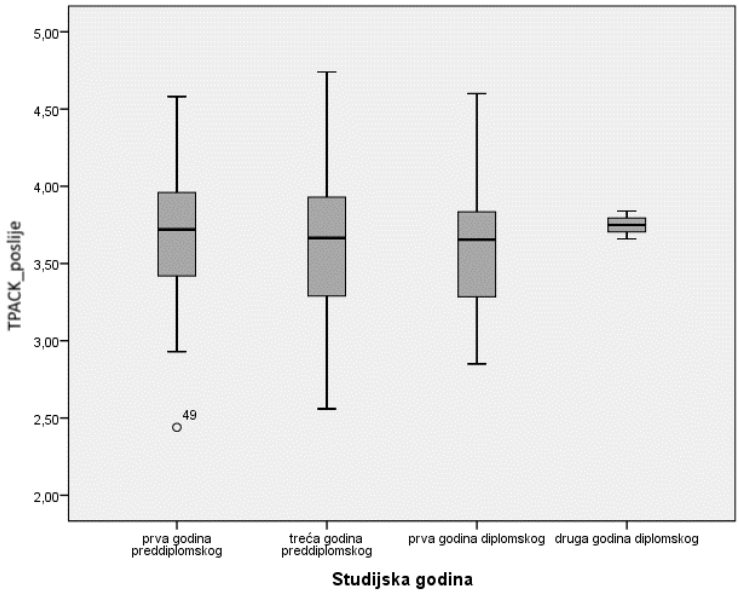

Slika 65. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na Studijsku godinu, na skupu podataka od N=195 ispitanika, poslije sudjelovanja u eksperimentu

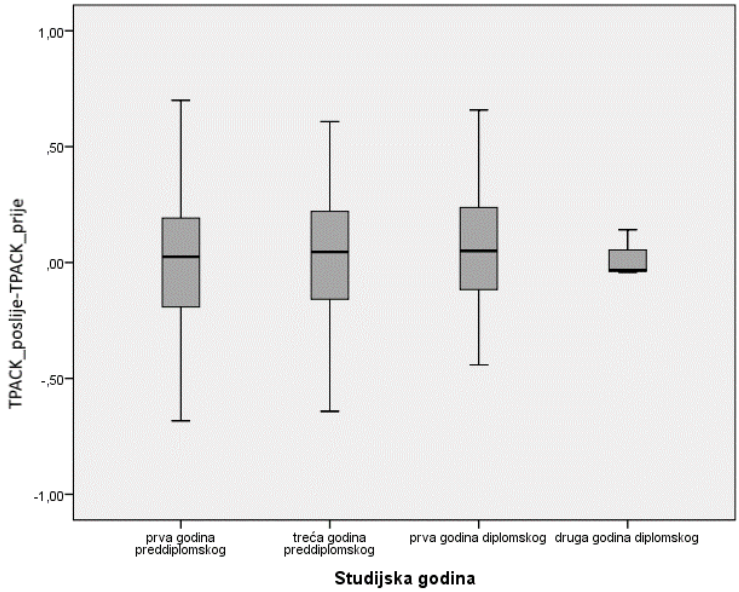

Slika 66. Kutijasti dijagrami varijable TPACK_poslije-TPACK_prije za sve skupine ispitanika u odnosu na Studijsku godinu, na skupu podataka od N=195 ispitanika

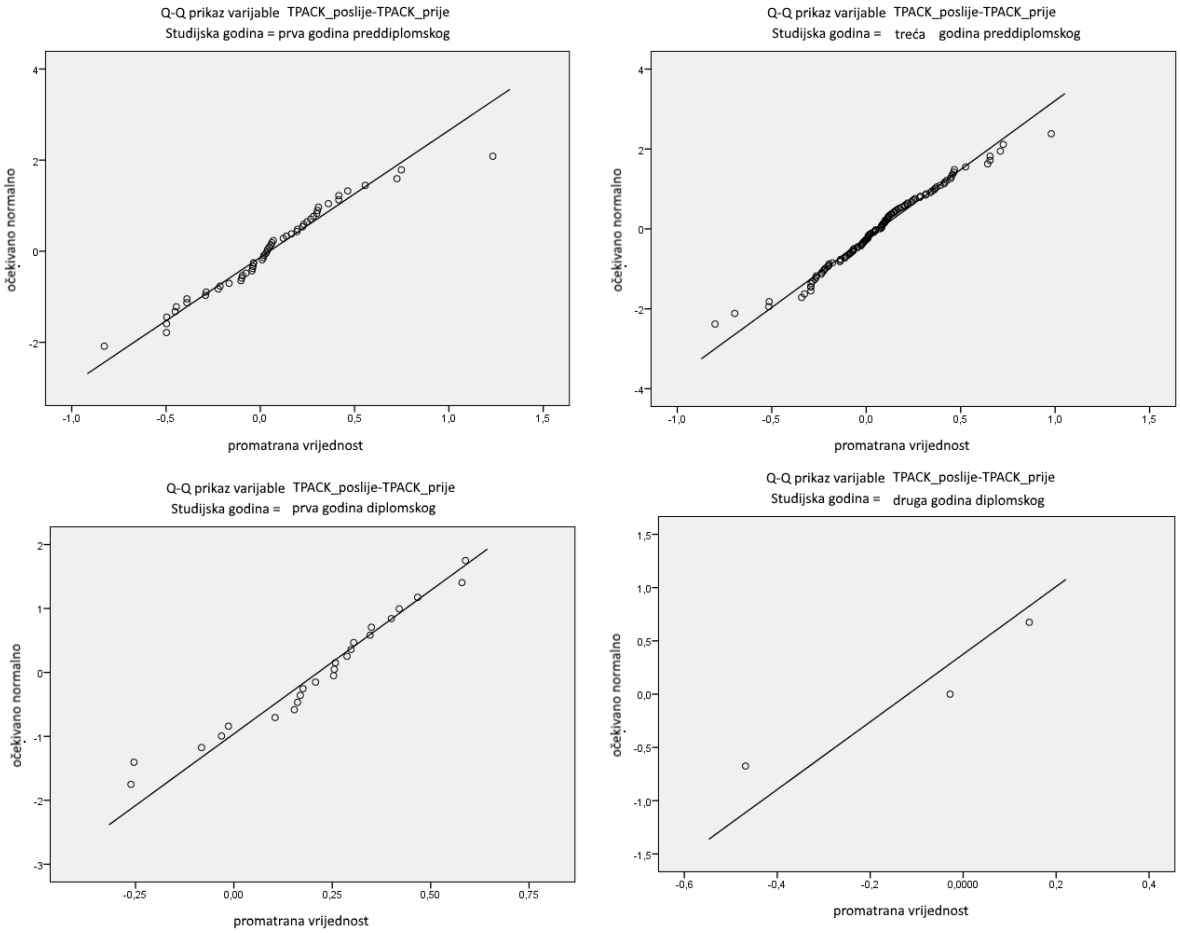

Slika 67. Q-Q prikazi varijable TPACKposlije-TPACK_prije za sve skupine ispitanika u odnosu na studijsku godinu, na skupu podataka od N=195 ispitanika

Tablica 66. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu TPACK u odnosu na vrijeme i studijsku godinu na skupu podataka od N=195 ispitanika

VRIJ.	ST.GOD.	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
			vrijed.	*p*	*vrijed.*	*p*
prije	***prva preddiplomskog***	53	0.09	0.20	0.98	0.48
	druga preddiplomskog	0	-	-	-	-
	treća preddiplomskog	115	0.05	0.20	0.98	0.12
	prva diplomskog	24	0.09	0.20	0.99	0.98
	druga diplomskog	3	0.20	-	0.99	0.86
poslije	***prva preddiplomskog***	53	0.07	0.20	0.98	0.64
	druga preddiplomskog	0	-	-	-	-
	treća preddiplomskog	115	0.07	0.19	0.98	0.11
	prva diplomskog	24	0.18	0.05	0.96	0.46
	druga diplomskog	3	0.23	-	0.98	0.72
TPACK_poslije-TPACK_prije	***prva preddiplomskog***	53	0.09	0.20	0.97	0.20
	druga preddiplomskog	0				
	treća preddiplomskog	115	0.07	0.20	0.99	0.24
	prva diplomskog	24	0.14	0.20	0.96	0.37
	druga diplomskog	3	0.28	-	0.94	0.52

Deskriptivna statistika za varijablu *TPACK*, u odnosu varijable *Studijsku godinu* i *Vrijeme*, na uzorku od N=195 ispitanika, prikazana je u Tablici 66.

Tablica 67. Deskriptivna ststistika za varijablu TPACK u odnosu na Studijsku godinu i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima na uzorku od N=195 ispitanika

VRIJ.	ST.GOD.	N	ARITMETIČKA SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
			vrij	*st.p*	*vrij.*	*st.p*	*vrij./st. p*	*vrij.*	*st.p*	*vrij./ st. p*
prije	***prva preddiplomskog***	53	3.58	0.06	-0.26	0.33	-0.79	0.74	0.64	1.16
	druga preddiplomskog	0	-	-	-	-	-	-	-	-
	treća preddiplomskog	115	3.64	0.04	0.13	0.23	0.57	-0.74	0.45	-1.64
	prva diplomskog	24	3.58	0.08	0.32	0.47	0.68	0.53	0.92	0.58
	druga diplomskog	3	3.80	0.08	0.38	1.23	0.31	-	-	-
poslije	***prva preddiplomskog***	53	3.61	0.07	-0.22	0.33	-0.68	0.15	0.64	0.23
	druga preddiplomskog	0	-	-	-	-	-	-	-	-
	treća preddiplomskog	115	3.71	0.04	0.24	0.23	1.04	0.14	0.45	0.31
	prva diplomskog	24	3.79	0.09	-0.14	0.47	-0.30	0.89	0.92	0.97
	druga diplomskog	3	3.68	0.13	0.74	1.23	0.60	-	-	-
TPACK_poslije-TPACK_prije	***prva preddiplomskog***	53	0.02	0.04	-0.16	0.32	-0,5	-0.08	0.64	-0.125
	druga preddiplomskog	0	-	-	-	-	-	-	-	-
	treća preddiplomskog	115	0.02	0.03	-0.73	0.23	-3.17	0.86	0.45	1.91
	prva diplomskog	24	0.06	0.05	0.39	0.47	0.83	0.63	0.92	0.68
	druga diplomskog	3	0.02	0.06	1.72	1.23	1.40	-	-	-

Rezultati Levenova testa su pokazali da ne postoji statistiki značajna razlika u varijancama varijable *TPACK* u odnosu na *Studijsku godinu* i *Vrijeme* prije sudjelovanja u eksperimentu

(F=1.128, df=3/191, p=0.339), odnosno poslije sudjelovanja u eksperimentu (F=1.026, df=3/191, p=0.382).

Provedena je dvo-faktorska ANOVA s ponovljenim mjerenjem, na nivou značajnosti od α=0.05, u svrhu ispitivanja utjecaja nezavisne varijable *Studijska godina* na percepciju budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi, prije i poslije sudjelovanja u eksperimentu.

Prvo su testirani efekti između subjekata i rezultati su pokazali da promatrani efekt nije statistički značajan. Glavni efekt za varijablu *Studijska godina* je pokazao da nema statistički značajne razlike u percepciji budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi, prije i nakon sudjelovanja u eksperimentu (F=0.549, df=(3,191), p=0.650).

Efekti unutar subjekata su pokazali da niti jedan efekt nije statistički značajan, kao niti međusobne interakcije efekata. Glavni efekt za varijablu *Vrijeme* kao i efekt interakcije varijable *Vrijeme* s varijablom *Studijska godina* prikazani su u Tablici 67.

Tablica 68. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu TPACK u odnosu na nezavisne varijable Studijska godina i Vrijeme

TPACK	**Stupnjevi slobode**	**Wilks' Lambda (pogreška = 191)**		
		vrijednost	F	p
VRIJEME	1	0.995	0.913	0.341
VRIJEME * ST. GOD.	3	0.966	2.233	0.086

5.7.3 Percepcija budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi u odnosu na razinu studija

Utjecaj nezavisnih varijabli *Razina studija* i *Vrijeme* na zavisnu varijablu *TPACK* ispitao se dvo-faktorskom analizom varijance s ponovljenim mjerenjem, na razini značajnosti α=0.05. Faktore u ovoj dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Razina studija* i *Vrijeme* te zavisna varijabla *TPACK*.

Rezultati Kolmogorov-Smirnovljeva i Shapiro-Wilkova testa su pokazali da je hipoteza H_0 prihvaćena za sve skupine ispitanika osim skupine ispitanika preddiplomskog studija prije sudjelovanja u postupku procjene (K-S=0.044, p=0.2; **S-W=0.978, p=0.009**). Nakon što je iz skupa podataka za analizu isključen slučaj 136 koji je predstavljao stršilo za promatrani skup

podataka, rezultati Kolmogorov-Smirnovljeva i Shapiro-Wilkova testa su pokazali da je hipoteza H_0 prihvaćena za promatranu skupinu ispitanika u odnosu na razinu studija i vrijeme (Tablica 68). Shapiro-Wilkov test pokazuje da distribucija varijable *TPACK_poslije-TPACK_prije* za ispitanike na preddiplomskoj razini studija odstupa od normalne distribucije te je provedena analiza simetričnosti i spljoštenosti (Tablica 69) i Q-Q prikaza (Slika 71). Omjer mjere asimetričnosti i spljoštenosti s pripadnim standardnim pogreškama je za varijablu *TPACK_poslije-TPACK_prije* za ispitanike na preddiplomskoj razini studija veći od |1.96|, dok Q-Q prikaz pokazuje da podaci prate liniju normalne distribucije (Slika 71).

Tablica 69. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu TPACK u odnosu na vrijeme i razinu studija, na uzorku od N=195 ispitanika

VRIJEME	RAZINA STUDIJA	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
			vrijed.	*p*	*vrijed.*	*p*
prije	***preddiplomski***	168	0.04	0.20	0.99	0.40
	diplomski	27	0.08	0.20	0.99	0.99
poslije	***preddiplomski***	168	0.05	0.20	0.99	0.39
	diplomski	27	0.14	0.20	0.97	0.54
TPACK_poslije-TPACK_prije	***preddiplomski***	168	0.06	0.20	0.98	**0.04**
	diplomski	27	0.15	0.13	0.96	0.28

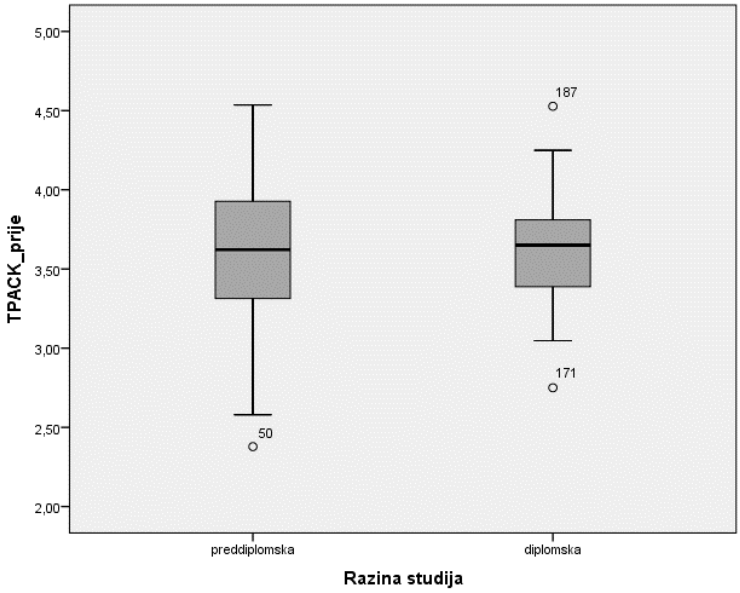

Slika 68. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na Razinu studija, na skupu podataka od N=196 ispitanika, prije sudjelovanja u eksperimentu

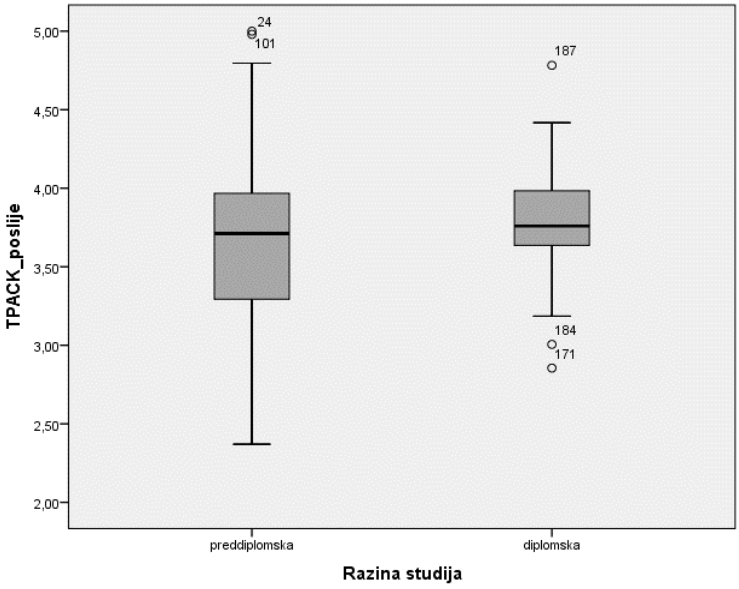

Slika 69. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na Razinu studija, na skupu podataka od N=196 ispitanika, poslije sudjelovanja u eksperimentu

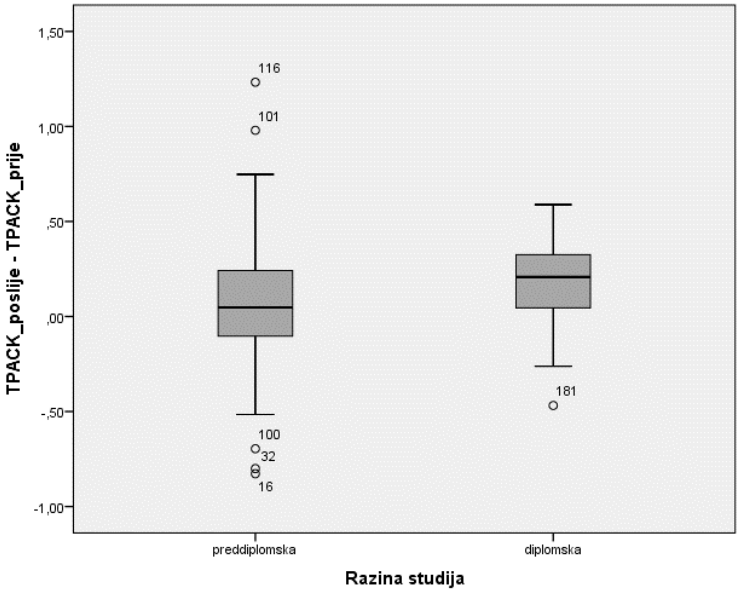

Slika 70. Kutijasti dijagrami varijable TPACK_poslije-TPACK_prije za sve skupine ispitanika u odnosu na Razinu studija, na skupu podataka od N=196 ispitanika

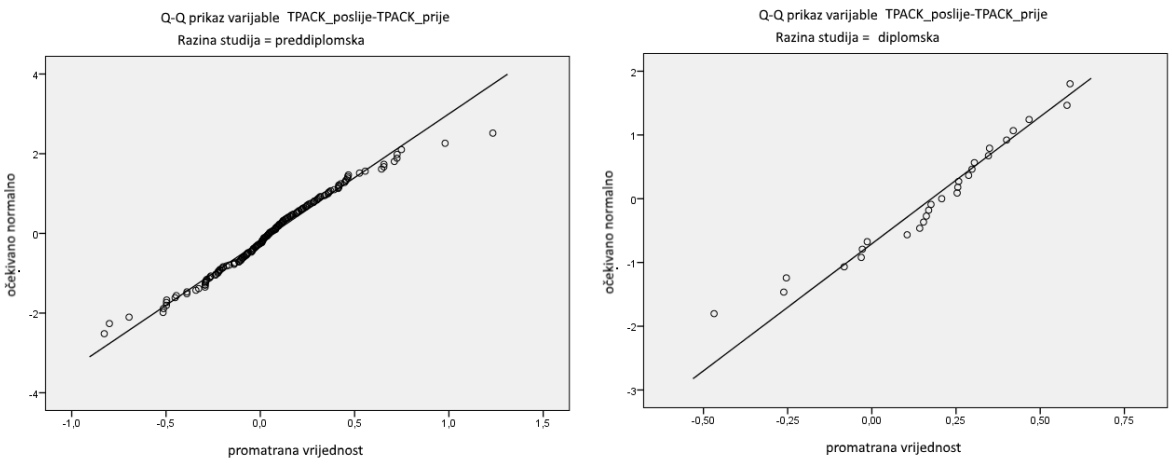

Slika 71. Q-Q prikazi varijable TPACKposlije-TPACK_prije za sve skupine ispitanika u odnosu na razinu studija, na skupu podataka od N=195 ispitanika

Tablica 70. Deskriptivna ststistika za varijablu TPACK u odnosu na Razinu studija i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=195 ispitanika

VRIJEME	RAZINA STUDIJA	N	ARITMETIČKA SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
			vrij	*st.p*	*vrij*	*st.p*	*vrij./st. p*	*vrij.*	*st.p*	*vrij./st. p*
prije	***preddiplomski***	168	3.62	0.03	-0.01	0.19	-0.05	-0.22	0.37	-0.59
	diplomski	27	3.60	0.07	0.15	0.45	0.33	0.56	0.87	0.64
poslije	***preddiplomski***	168	3.68	0.04	0.06	0.19	0.32	0.20	0.37	0.54
	diplomski	27	3.78	0.08	-0.06	0.45	-0.13	1.07	0.87	1.23
TPACK_poslije-TPACK_prije	***muški***	168	0.06	0.02	0.26	0.19	1.37	1.30	0.37	3.51
	ženski	27	0.18	0.05	-0.72	0.45	-1.6	0.60	0.87	0.69

Rezultati Levenova testa su pokazali da ne postoji statistiki značajna razlika u varijancama varijable *TPACK* u odnosu na *Razinu studija* i *Vrijeme* prije sudjelovanja u eksperimentu (F=0.730, df=1/193, p=0.394), odnosno poslije sudjelovanja u eksperimentu (F=2.102, df=1/193, p=0.149).

Provedena je dvo-faktorska ANOVA s ponovljenim mjerenjem, na nivou značajnosti od α=0.05, u svrhu ispitivanja utjecaja nezavisne varijable *Razina studija* na percepciju budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi, prije i poslije sudjelovanja u eksperimentu.

Prvo su testirani efekti između subjekata i rezultati su pokazali da promatrani efekt nije statistički značajan. Glavni efekt za varijablu *Razina studija* je pokazao da nema statistički značajne razlike u percepciji budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi, prije i nakon sudjelovanja u eksperimentu (F=0.209, df=(1,193), p=0.648).

Efekti unutar subjekata su pokazali da postoji statistički značajna razlika zavisne varijable *TPACK* u odnosu na nezavisnu varijablu *Vrijeme* (F(1,193)=12.266, p=0.001), odnosno postoji statistički značajna razlika u samoprocjeni vlastitih znanja o primjeni tehologije u nastavi prije i poslije sudjelovanja u procesu procjene. Efekti interakcije varijable *Vrijeme* s varijablama *Samoprocjena* i *Vršnjačka procjena* nisu statistički značajni (Tablica 70).

Tablica 71. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu TPACK u odnosu na nezavisne varijable Razina studija i Vrijeme

TPACK	**Stupnjevi slobode**	**Wilks' Lambda (pogreška = 193)**		
		vrijednost	F	p
VRIJEME	**1**	**0.940**	**12.266**	**0.001**
VRIJEME * ST. GOD.	1	0.984	3.234	0.074

5.7.4 Percepcija budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi u odnosu na znanstveno područje kolegija

Utjecaj nezavisnih varijabli *Znanstveno područje kolegija* i *Vrijeme* na zavisnu varijablu *TPACK* ispitao se dvo-faktorskom analizom varijance s ponovljenim mjerenjem, na razini značajnosti α=0.05 Faktore u ovoj dvo-faktorskoj analizi varijance predstavljaju nezavisne varijable *Znanstveno područje kolegija* i *Vrijeme* te zavisna varijabla *TPACK*.

Rezultati oba testa su pokazali da distribucija skupine ispitanika na kolegijima iz područja društvenih znanosti u odnosu na vrijeme prije sudjelovanja u eksperimentu značajno odstupa od normalne distribucije (K-S=0.135, p=0.020; S-W=0.95, p=0.02). Za ostale skupine ispitanika promatrane distribucije podataka ne odstupaju značajno od normalne distribucije u odnosu na rezultate oba testa (Tablica 71).

S obzirom da rezultati testova distribucije podataka za skupinu ispitanika na kolegijima iz područja društvenih znanosti u odnosu na vrijeme prije sudjelovanja u eksperimentu, na uzorku od N=196 ispitanika, ne pokazuje konzistentne rezultate, izvršena je analiza simetričnosti i spljoštenosti (Tablica 72) i Q-Q prikaza (Slika 75). Omjeri mjera asimetričnosti i spljoštenosti s pripadnim standardnim pogreškama ukazuju da distribucije svih promatranih skupina podataka ne odudaraju značajno od normalne distribucije.

Tablica 72. Vrijednosti Kolmogorov-Smirnovljevog i Shapiro-Wilkova testa normalne distribucije za varijablu TPACK u odnosu na vrijeme i znanstveno područje kolegija

VRIJEME	ZNAN. POD. KOL.	N	KOLMOGOROV SMIRNOV		SHAPIRO WILK	
			vrijed.	*p*	*vrijed.*	*p*
prije	Društvene znanosti	**52**	**0.14**	**0.02**	**0.93**	**0.003**
	Prirodne znanosti	105	0.05	0.20	0.99	0.57
	Humanističke znanosti	15	0.13	0.20	0.98	0.96
	Tehničke znanosti	24	0.09	0.20	0.99	0.98
poslije	Društvene znanosti	**52**	0.11	0.17	0.98	0.56
	Prirodne znanosti	105	0.06	0.20	0.99	0.38
	Humanističke znanosti	15	0.13	0.20	0.94	0.35
	Tehničke znanosti	24	0.18	0.05	0.96	0.46
TPACK_poslije-TPACK_prije	Društvene znanosti	**52**	0.09	0.2	0.98	0.39
	Prirodne znanosti	105	0.08	0.09	0.98	0.25
	Humanističke znanosti	15	0.18	0.2	0.90	0.09
	Tehničke znanosti	24	0.14	0.2	0.96	0.37

Nakon što je iz skupa podataka za analizu isključen slučaj 51 koji je predstavljao stršilo za promatrani skup podataka, rezultat Shapiro-Wilkova testa i dalje je pokazivao da distribucija značajno odstupa od normalne distribucije (K-S=0.121, p=0.060; **S-W=0.93, p=0.003**), stoga je daljna analiza nastavljena na početnom skupu podataka N=196.

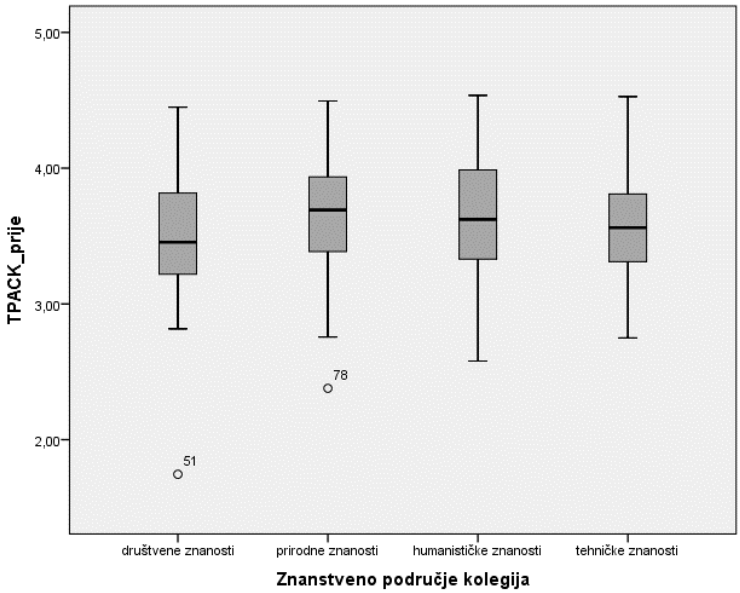

Slika 72. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na znnanstveno područje kolegija, na skupu podataka od N=196 ispitanika, prije sudjelovanjau eksperimentu

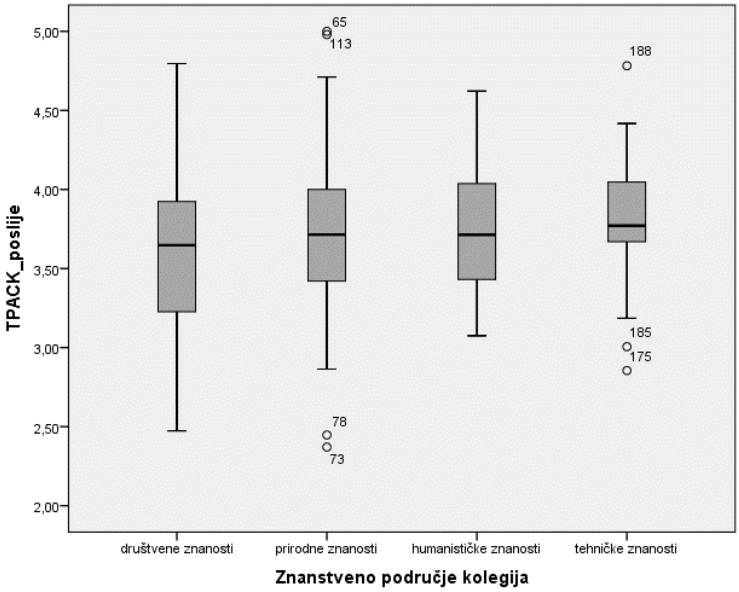

Slika 73. Kutijasti dijagrami varijable TPACK za sve skupine ispitanika u odnosu na znnanstveno područje kolegija, na skupu podataka od N=196 ispitanika, poslije sudjelovanjau eksperimentu

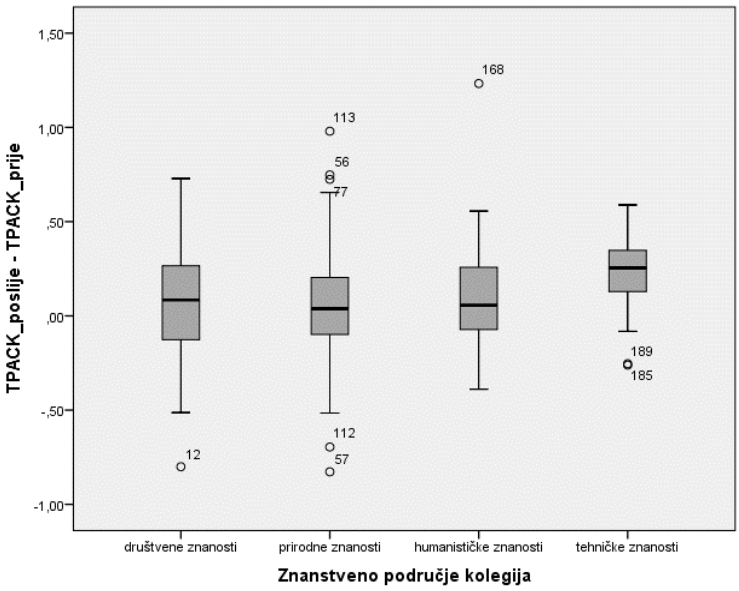

Slika 74. Kutijasti dijagrami varijable TPACK_poslije-TPACK_prije za sve skupine ispitanika u odnosu na Znanstveno područje kolegija, na skupu podataka od N=196 ispitanika

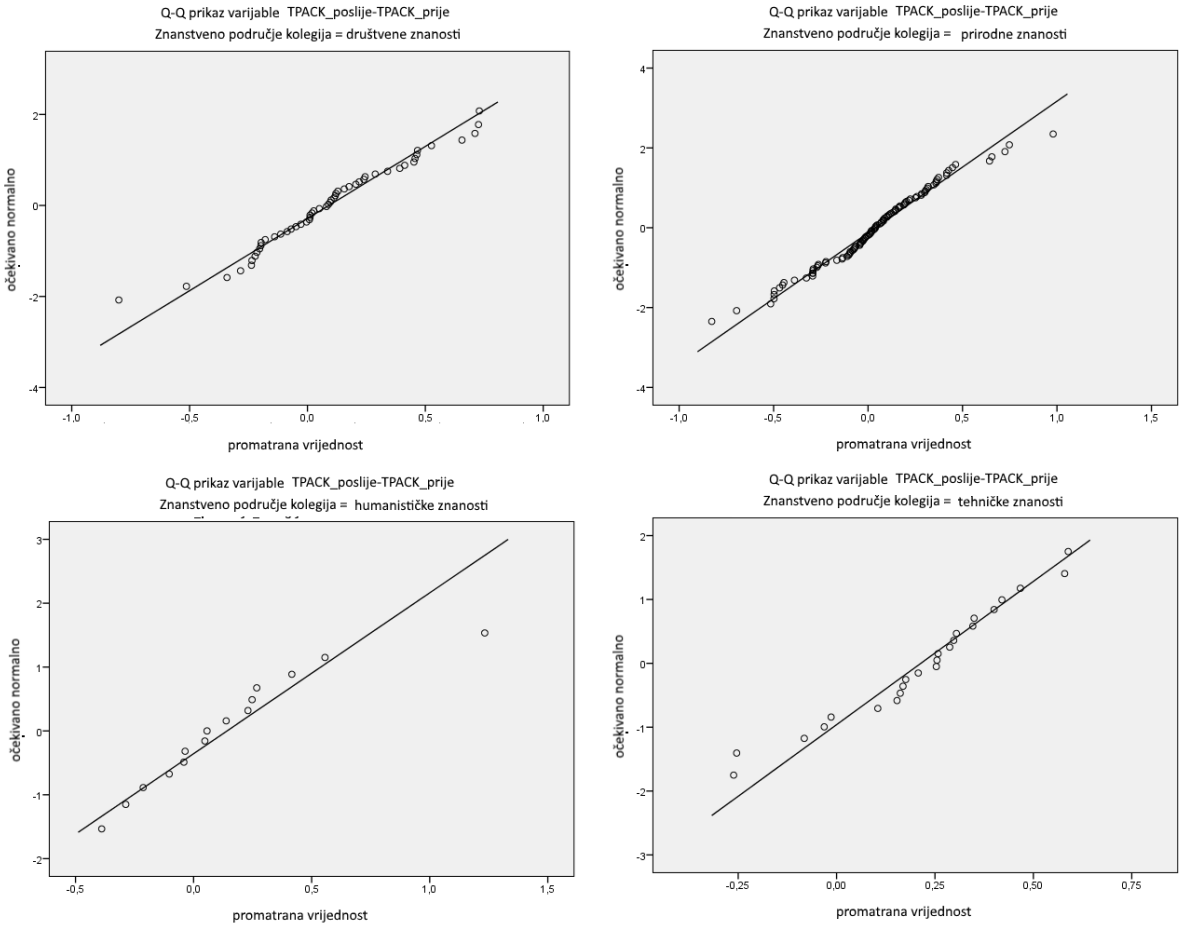

Slika 75. Q-Q prikazi varijable TPACKposlije-TPACK_prije za sve skupine ispitanika u odnosu na znanstveno pdručje kolegij, na skupu podataka od N=196 ispitanika

Q-Q prikaz promatrane skupine ispitanika pokazuje da podaci ne prate liniju koja predstavlja normalnu distribuciju podataka (Slika 77).

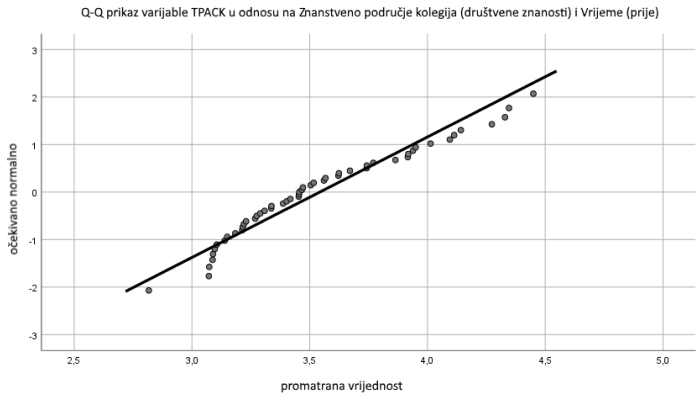

Slika 76. Q-Q prikaz varijable TPACK_prije za skupinu ispitanika koji su pohađali kolegije iz društvenih znanosti, na skupu podataka od N=196 ispitanika

Tablica 73. Deskriptivna ststistika za varijablu TPACK u odnosu na Znanstveno područje kolegija i Vrijeme koja opisuje aritmetičku sredinu, mjere asimetričnosti i spljoštenosti s pripadnim standarnim pogreškama i omjerima, na uzorku od N=196 ispitanika

VRIJEME	ZNAN. POD. KOL.	N	ARITMETIČKA SREDINA		MJERA ASIMETRIČNOSTI			MJERA SPLJOŠTENOSTI		
			vrij	*st.p*	*vrij*	*st.p*	*vrij./ st.p*	*vrij*	*st.p*	*vrij./ st.p*
prije	Društvene znanosti	52	3.51	0.06	0.60	0.33	1.81	-0.47	0.66	-0.71
	Prirodne znanosti	105	3.67	0.04	-0.28	0.24	-1.16	0.26	0.47	0.55
	Humanističke znanosti	15	3.64	0.14	-0.19	0.58	-0.33	-0.09	1.12	-0.08
	Tehničke znanosti	24	3.58	0.08	0.32	0.47	0.68	0.53	0.92	0.58
poslije	Društvene znanosti	52	3.60	0.06	0.15	0.33	0.45	-0.35	0.66	-0.53
	Prirodne znanosti	105	3.70	0.05	-0.06	0.24	-0.25	0.70	0.47	1.49
	Humanističke znanosti	15	3.78	0.13	0.37	0.58	0.64	-0.87	1.12	-0.78
	Tehničke znanosti	24	3.79	0.09	-0.14	0.47	-0.30	0.89	0.92	0.97
TPACK_poslije-TPACK_prije	Društvene znanosti	52	0.09	0.04	-0.01	0.33	-0.03	0.40	0.65	0.62
	Prirodne znanosti	105	0.04	0.03	0.04	0.24	0.17	0.87	0.47	1.85
	Humanističke znanosti	15	0.14	0.10	1.04	0.58	1.79	1.27	1.12	0.60
	Tehničke znanosti	24	0.21	0.05	-0.53	0.47	-1.13	0.19	0.92	0.21

Zbog rezultata Shapiro-Wilkova testa i Q-Q prikaza zaključeno je da podaci za skupinu ispitanika na kolegijima iz područja društvenih znanosti u odnosu na vrijeme

Rezultati Levenova testa su pokazali da ne postoji statistiki značajna razlika u varijancama varijable *TPACK* u odnosu na znanstveno područje kolegija i vrijeme prije sudjelovanja u eksperimentu (F=0.693, df=3/192, p=0.557), odnosno poslije sudjelovanja u eksperimentu (F=0.684, df=3/192, p=0.563).

Provedena je dvo-faktorska ANOVA s ponovljenim mjerenjem, na nivou značajnosti od α=0.05, u svrhu ispitivanja utjecaja nezavisne varijable *Znanstveno područje kolegija* na percepciju budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi, prije i poslije sudjelovanja u eksperimentu.

Prvo su testirani efekti između subjekata i rezultati su pokazali da promatrani efekt nije statistički značajan. Glavni efekt za varijablu *Znanstveno područje kolegija* je pokazao da nema statistički značajne razlike u percepciji budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi, prije i nakon sudjelovanja u eksperimentu (F=1.351, df=(3,192), p=0.259).

Efekti unutar subjekata su pokazali da postoji statistički značajna razlika zavisne varijable *TPACK* u odnosu na nezavisnu varijablu *Vrijeme* (F(1,193)=682.486, p=0.000), odnosno postoji statistički značajna razlika u samoprocjeni vlastitih znanja o primjeni tehologije u nastavi prije i poslije sudjelovanja u procesu procjene. Efekt interakcije varijable *Vrijeme* s varijablom *Znanstveno područje kolegija* nije statistički značajan (Tablica 73).

Tablica 74. Razine vjerojatnosti F vrijednosti u multivarijatnoj analizi varijance ponovljenih mjerenja koje testiraju učinke unutar subjekata za zavisnu varijablu TPACK u odnosu na nezavisne varijable Znanstveno područje kolegija i Vrijeme

TPACK	**Stupnjevi slobode**	**Wilks' Lambda (pogreška = 192)**		
		vrijednost	*F*	*p*
VRIJEME	**1**	**0.780**	**682.486**	**0.000**
VRIJEME * ZNAN.POD.KOL.	3	0.033	2.202	0.089

Rezultati Kruskal Wallisova testa su pokazali da postoji statistička značajnost razlike u percepciji budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi u odnosu na znanstveno područje kolegija (χ^2=9.10, p=0.03) i to prirodne znanosti i tehničke znanosti te društvene znanosti i tehničke znanosti (Tablica 74).

Tablica 75. Usporedba u parovima varijable TPACK_poslije-TPACK_prije u odnosu na znanstveno područje kolegija

Znanstveno područje kolegija	**vrijednost**	**p**
Prirodne znanosti – društvene znanosti	8.90	0.36
Prirodne znanosti – humanističke znanosti	-10.91	0.47
Prirodne znanosti – tehničke znanosti	-38.54	0.003
Društvene znanosti – humanističke znanosti	-2.02	0.90
Društvene znanosti – tehničke znanosti	-29.64	0.03
Humanističke znanosti – Tehničke znanosti	-27.63	0.14

5.8 Mišljenje studenata

Udio pozitivnih i negativnih elemenata u komentarima studenata na zadani zadatak, njegovo rješavanje i procjenjivanje prikazan je na Slici 44.

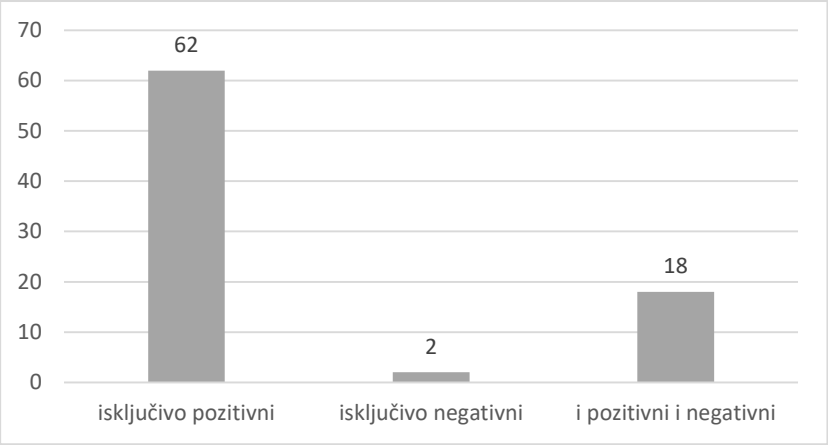

Slika 77. Udio pozitivnih i negativnih elemenata u komentarima studenata na zadani zadatak, njegovo rješavanje i procjenjivanje

5.8.1 Pozitivni elementi procjene i samoprocjene

U komentarima je najčešće spomenuto da im je ovakav način rješavanja zadatka nešto novo i neuobičajeno i da im se jako sviđa. Ističu se i sljedeći pozitivni elementi:

- Zadatak (kreativnost u postavljanju i rješavanju zadatka),
- Grupni rad (ističe se veći broj ideja, međusobno nadopunjavanje znanja, upoznavanje i druženje),
- Procjena (zadovoljstvo zbog sudjelovanja u procjeni, osvještavanje težine objektivnog procjenjivanja, proširivanje vlastitih znanja tijekom vršnjačke procjene),
- Rubrike (olakšavaju proces procjene, ističu elemente procjene kojih se studenti ne bi sjetili),
- Organizacija (samostalnost u odabiru timova, jasnoća i detaljnost danih uputa),
- Upitnik (spomenut samo jednom u pozitivnom kontekstu, potaknuo je studenticu na razmišljanje o stvarima o kojima inače ne bi razmišljala)

Niže su izdvojeni neki komentari s istaknutim pozitivnim elementima:

- *„Meni se ovakav način rješavanja zadatka dojmio. Prvo sam mislila da neću znati riješiti zadatak dok ga nisam vidjela, a onda kad sam vidjela sliku i napravila to u programu bilo je u redu i osjećala sam se bolje. Najviše me zainteresirala procjena. To je prvi puta da se od nas studenata tražio nekakav oblik procjene nečega na Fakultetu. Obično smo mi ti koji napišu, predaju i čekaju da "ih" se procijeni. To mi je stvarno bilo super iako se možda nismo najbolje snašli u tome jer je ipak to prvi puta, ali pozitivna*

je stvar to što se želi čuti i naše mišljenje. Cijelo je istraživanje stvarno pozitivno iskustvo.“

- *„Cijelo ovo istraživanje bilo mi je zanimljivo. Zadatak je bio prikladan gradivu koje smo radili na kolegiju PJL te mi je ujedno pomoglo pri vježbi za kolokvij. Također, svidio mi se i grupni rad. Ponekad je dobro raditi u grupi, razmjenjivati ideje, pomoći jedni drugima i zajednički učiti. Vrednovanje pomoću rubrike pomoglo mi je u vrednovanju ostalih studentica te mi dalo ideju da je možda zanimljivo i korisno dati učenicima da međusobno vrednuju druge učenike.“*
- *„Zadatak je ugodno iznenađenje nakon uobičajenih zadataka koje izvršavamo na Fakultetu. Način na koji je osmišljen ovaj zadatak zanimljiviji je od uobičajenog zadatka. Grupni rad također nosi mnogobrojne prednosti, a procjena tuđih radova daje dobro iskustvo za budući rad.“*
- *„Vezano za procjenjivanje tuđih zadataka, smatram da je i to u redu jer ćemo svakako u budućnosti procjenjivati radove svojih učenika pa je ovo bila dobra praksa.“*
- *„Moja dosadašnja iskustva s procjenama tuđih rješenja nisu baš pozitivna jer sam uglavnom procjenjivala radove svojih kolega pa nisam mogla biti potpuno objektivna pri procjenjivanju budući da su oni imali uvid u te procjene i procjenjivača. No, ovakav način to sprječava jer se ne zna tko je procjenjivač pa nema straha od toga da ćemo nekoga povrijediti svojom procjenom i svojim mišljenjem.“*
- *„Nisam dobila ni jednu zadaću za procjenu, ali prema oglednom primjerku koji smo ocjenjivali sviđa mi se takav način procjene jer pruža kakvu-takvu objektivnost, a ne samo subjektivno davanje bodova prema tome sviđa li nam se netko ili ne. Prema smjernicama gledala sam više kako je rad napravljen i na što trebam obratiti pozornost (a što možda ne bih uočila bez smjernica) te sam prema tome mogla napraviti objektivniju procjenu nečijeg rada, nego što bih to napravila bez smjernica.“*
- *„Smatram da je zadatak drugačiji od onoga na što smo navikli, međutim mislim da je dobar upitnik jer me je potaknuo da razmišljam o nečemu čega se ne bi sjetila. Smatram da smo mi morali znati kako i o čemu se radi da bi mogli procijeniti tuđe radove. Rad je u grupi bio vrlo zanimljiv i koristan.“*
- *„Smatram da je zadatak vršnjačke procjene odlično zadan, tj. slažem se sa time da bi se učenici/studenti trebali međusobno ocjenjivati, no da bi određeni profesor to trebao svakako još jednom provjeriti.“*

- *„Meni se osobno sviđa ovakav način rada jer mi je pomoglo da shvatim neke stvari u koje nisam bila sigurna te mi se sviđa ovaj način procjene tuđih rješenja jer mislim da tako vidimo i učimo na tuđim greškama.“*
- *„Smatram kako je ovaj način rješavanja zadataka za nas studente vrlo dobar i koristan. Sviđa mi se što je to bio grupni rad jer smo tako učili jedni od drugih, razmjenjivali ideje, razmišljali o prijedlozima drugih kolega te se zajednički trudili doći do nekog najboljeg rješenja. Isto tako, smatram da nam je taj grupni rad olakšao ovaj zadatak, a i učinio ga zanimljivijim. Što se tiče procjene tuđih rješenja, rekla bih da je to vrlo korisno za nas jer na taj način učimo. Učimo procjenjivati, odnosno ocjenjivati, a isto tako učimo i iz tuđih radova jer kada smo vidjeli rad drugih kolega i kolegica, uspoređivanjem radova mogli smo uvidjeti neke dobre/loše strane našeg/tuđeg rada. Rubrike su bile od velike pomoći jer smo se tako lakše snalazili i one su nam bile smjernice u tom procjenjivanju.“*
- *„Zanimljivo je kada naučeno primjenimo kako bi uočili pogreške ili točne dijelove nekog zadatka. Mislim da se onda točno vidi jesmo li naučili ili nismo. Voljela bih kada bi bilo više takvih zadaća.“*

5.8.2 Negativni elementi procjene i samoprocjene

Negativni elementi koji su istaknuti dotiču se:

- tehničkih problema (Moodle, problemi s formatom u kojem se trebalo predati rješenje, pretjerana upotreba IKT-a),
- organizacijskih (oduzima puno vremena, nejasne upute zadatka),
- zadatka (nepredvidivost, jednostavnost zadatka, zadatak se ne ocjenjuje),
- grupni rad (ne preferiraju grupni rad, ne ulažu svi studenti jednaki napor pri rješavanju zadatka),
- procjena (nastavnikova je povratna informacija bitnija od vršnjačke, osjećaj nekompetentnosi za obavljanje procjene, objektivnost pri samoprocjeni),
- rubrike (stupnjevanje izvedbe za svaki kriterij procjene trebalo bi biti procjenjivano na skali od 1 do 5 bez detaljnijih opisa),
- upitnik (iako se ne dotiče samog zadavanja i rješavanja zadatka, složenost su upitnika i konstrukcija pitanja u velikom broju slučajeva istaknuti kao negativni elementi).

Niže su izdvojeni neki komentari s istaknutim negativnim elementima:

- „*Ovakav grupni rad je kreativan i zanimljiv, ali oduzima puno vremena.*“
- *„Budući da se zadatak ne ocjenjuje mislim da je uloženi trud u zadatak minimalan. Vjerujem da bi veći trud, što se mene osobno tiče, bio kada bih dobila ocjenu za taj zadatak.“*
- *„Sviđa mi se ovakav način rada, ali ne znači mi previše evaluacija koju provode drugi studenti, ako napravim neki zadatak onda me zanima povratna informacija profesora, povratnu informaciju od kolega mogu dobiti i sama.“*
- *„Meni se ovaj zadatak nije svidio zbog toga što je preko Interneta, a ja nemam vremena da stalno provjeravam je li stigao novi zadatak. Od svega ovoga jedino mi je bilo zabavno raditi u grupi. I smatram da bi bilo sve ovo zanimljivije da smo se sastali i pričali o napravljenom radu uživo, a ne ovako preko Interneta.“*
- *„Smatram da se grupni rad ne bi trebao ocjenjivati i vrednovati. Mislim da bi se trebao koristiti samo u odgojne svrhe jer uvijek postoje članovi grupe koji se zalažu više ili manje od ostalih te se na taj način ne pokazuju prave sposobnosti i vještine.“*
- *„Smatram kako je procjenjivanje teško jer često nije objektivno, pogotovo samoprocjenjivanje.“*
- *„Procjenjivanje je išlo malo teže jer se s takvim načinom rada prvi put susrećem.“*

5.8.3 I pozitivni i negativni elementi procjene i samoprocjene

U slučajevima kada se u komentaru pojavljuju i pozitivni i negativni elementi, oni su kombinacija već ranije nabrojanih pozitivnih elemenata i negativnih elemenata. Niže je naveden jedan primjer komentara u kojem se nalaze i pozitivni i negativni elementi:

„Jako mi se svidio ovaj način rada. Zadatak je jasno zadan, upute su bile jasne i precizne. Rad je u grupi odlično funkcionirao, svi smo imali nekoliko ideja i zatim o svakoj raspravljali, tražeći najbolji način rješavanja zadatka. Jedina je zamjerka procjena radova, odnosno bilo je pomalo nelagodno i neobično ocijeniti vlastiti rad. Bilo bi puno lakše ocijeniti tuđi rad, nego vlastiti jer je uvijek sebe najteže ocijeniti. Također, svidjela mi se rubrika po kojoj smo ocjenjivali jer nam je olakšavala procjenu“.

6 RASPRAVA O REZULTATIMA ISTRAŽIVANJA

Istraživanje u okviru ove doktorske disertacije možemo podijeliti na sljedeće dijelove:

- Proširenje i validacija RASI upitnika,
- Validacija SPTKTT upitnika,
- Ispitivanje trenutnog stanja u znanjima nastavnika i učitelja u Hrvatskoj o primjeni tehnologije u nastavi,
- Kvazi eksperiment koji istražuje utjecaj vršnjačke procjene i/ili samoprocjene na pristup učenju i primjenu tehnologije u nastavi,
- Prikupljanje mišljenja studenata putem otvorenog pitanja.

Svaki od navedenih dijelova bit će uključen u interpretaciju rezultata i donošenje konačnih zaključaka, kao i preporuka za daljnje istraživanje.

6.1 Proširenje i validacija RASI upitnika

Proširenje RASI upitnika rezultiralo je novim mjernim instrumentom koji ispituje pristup učenju studenata u kontekstu rješavanja problemskih i složenih zadataka. Proširena, nevalidirana verzija upitnika sastojala se od 66 čestica. Validacija upitnika provedena je konfirmatornom faktorskom analizom nad postojećim česticama i podskalama upitnika (Byrne, Flood i Willis, 2004), (Diseth, 2001), (Entwistle, 2000a), (Tait, Entwistle i McCune, 1998) kao i česticama i podskalama dodanim u kontekstu problemskih i složenih zadataka.

Uzorak na kojem je provedena validacija sastoji se od 635 studenata, dakle uzorak je, u odnosu na broj čestica dovoljno velik (Kline P., 1994, str. 73), (Pallant, 2001, str. 173), (Lewley i Maxwell, 1971).

Nakon prvotno provedene konfirmatorne faktorske analize faktorska opterećenja za tri čestice su bila manja od 0.32: R32, R38 i R51. Iako je predloženi model odgovarao teorijskom modelu (RMSEA = 0.049, SRMR = 0.074) spomenute čestice su isključene iz upitnika (Tabarnich i Fidel, 2013) te je ponovno provedena konfirmatorna faktorska analiza nad preostalim česticama.

Uočena je visoka korelacije između domena Strateški i Dubinski, što potvrđuju i prethodna istraživanja (Entwistle i Tait, 2013)

Pouzdanost postojećih i dodanih podskala i čestica upitnika RASI upitnika iskazana je Cronbach α koeficijentom. Cronbachov koeficijent α za cjelokupni upitnik je 0.88 što sugerira visoku pouzdanost mjernog instrumenta. Za podskale se Cronbachov koeficijent α kreće između 0.52 i 0.88 što sugerira privatljivu pouzdanost mjernog instrumenta. Cronbachov koeficijent α za tri osnovne podskale, duboki, strateški i površinski, su redom 0.88, 0.81 i 0.77 što predstavlja visoku pouzdanost tih skala. Visoku pouzdanost podskala i mjernog instrumenta pokazala su i ostala istraživanja (Entwistle i Tait, 2013) , ((Long, 2000) prema (Entwistle i Tait, 2013)), (Byrne, Flood i Willis, 2004), (Diseth, 2001), (Valadas, Goncalves i Faisca, 2010).

6.2 Validacija upitnika SPTKTT

Validacija upitnika SPTKTT provedena je na uzorku od 337 studenata što prema (Kline P., 1994, str. 73), (Pallant, 2001, str. 173), (Lewley i Maxwell, 1971) čini uzorak dovoljno velikim za provođenje faktorske analize u odnosu na broj čestica upitnika.

Predložena faktorska struktura za upitnik SPTKTT u kontekstu hrvatskog obrazovnog sustava temelji se na razlikama u obrazovnim sustavima zemalja u kojima je validacija upitnika provedena. Schmidt i suradnici (2009) su istraživanje provodili u SAD-u. Obrazovni sustav SAD razlikuje sljedeće predmete: Matematika (Math), Društvene znanosti (Social Sciences), Znanost (Science) i Pimenost (Literacy), na temelju kojih su i konstruirane podskale za specifična sadržajna znanja u originalnom upitniku. Hrvatski obrazovni sustav u razrednoj nastavi razlikuje sljedeće predmete: Matematika, Priroda i društvo te Hrvatski jezik. Kada se usporede predmeti u tim dvama obrazovnim sustavima uočeno je da je Matematika prisutna u oba, Pismenost u obrazovnom sustavu SAD-a odgovarala bi Hrvatskom jeziku u hrvatskom obrazovnom sustavu, dok Priroda i društvo u hrvatskom obrazovnom sustavu objedinjuje Društvene znanosti i Znanost obrazovnog sustava SAD-a. Kada uzmemo u obzir navedene razlike u obrazovnim sustavima, jasno je da su podskale Sadržajna znanja – društvene znanosti i Sadržajna znanja – znanost teoretski mogu biti objedinjene u jedan faktor Sadržajna znanja – priroda i društvo.

Konfirmatorna faktorska analiza potvrdila je predloženu strukturu. Osim toga, konfirmatornom fakorskom analizom utvrđeno je da se faktori Sadržajna znanja – matematika, Sadržajna znanja – priroda i društvo te Sadržajna znanja – pismenost mogu objediniti pod jednim faktorom Sadržajna znanja. Ovime se potvrđuje faktorska struktura od sedam faktora koju zastupa teorijski okvir Tehnološko pedagoško predmetnih znanja (TPACK). Potvrda faktorske

strukture od sedam faktora utvrđena je i u istraživanjima (Schmidt i sur., 2009) i (Pamuk i sur., 2013).

Pouzdanost podskala i dodanih čestica upitnika SPTKTT iskazana je Cronbach α koeficijentom. Pouzdanost se kreće u rasponu 0.81-0.91 za sve podskale upitnika, dok je za cijeli upitnik 0.92, što je u skladu s rezultatima istraživanja Schmidt i sur. (2009).

6.3 Ispitivanje trenutnog stanja u znanjima nastavnika i učitelja u Hrvatskoj o primjeni tehnologije u nastavi

U svrhu ispitivanja trenutnog stanja u znanjima nastavnika i učitelja u Hrvatskoj o primjeni tehnologije u nastavi postavljena je hipoteza H1:

H1: Učitelji i nastavnici u Hrvatskoj percipiraju slabija vlastita znanja o primjeni IKT-a u nastavi u odnosu na vlastita pedagoška i predmetna znanja.

Rezultati istraživanja potvrdili su hipotezu H1 da učitelji i nastavnici u Hrvatskoj percipiraju slabija vlastita znanja o primjeni IKT-a u nastavi u odnosu na vlastita pedagoška i predmetna znanja. S obzirom da se poučavanje uz pomoć IKT-a pojavljuje u svim teorijskim okvirima poučavanja za 21. stoljeće (Voogt i Roblin, 2012), potvrđivanje hipoteze H1 dovodi u pitanje mogućnost primjene takvih teorijskih okvira u hrvatskom obrazovnom sustavu.

Nekoliko je razloga, iznesenih u pregledu literature ove doktorske disertacije, zbog kojih je potvrđivanje hipoteze H1 važno ozbiljno razmotriti:

- Europska komisija (European Commission, 2015) navodi da fokus procesa obrazovanja treba biti stavljen na učenika te tada govorimo o učenju usmjerenom prema učeniku, a upotreba IKT-a u nastavi pomaže u transformaciji okoline za poučavanje usmjerene prema nastavniku u okolinu za poučavanje usmjerenu prema učeniku (Shan Fu, 2013),
- Strategija obrazovanja, znanosti i tehnologije (Vlada Republike Hrvatske, 2014) naglašava potrebu za uvođenjem suvremenih metoda poučavanja temeljenih na informacijskoj i komunikacijskoj tehnologiji i to na svim razinama i u svim vrstama obrazovanja,
- Strategija se posebno dotiče obrazovanja odraslih te ističe da će se snažnijim i širim uvođenjem novih digitalnih pomagala za učenje na daljinu te otvorenim i slobodnim pristupom postojećim i novim resursima znanja i obrazovnim pomagalima proširiti,

racionalizirati, učiniti kvalitetnijim i ubrzati procesi obrazovanja, osposobljavanja i usavršavanja odraslih,

- usavršavanje učitelja u korištenju i primjeni obrazovnih tehnologija ima pozitivan utjecaj na razvoj pedagoškog i predmetnog tehnološkog znanja (Shin i sur., 2009), a veće pedagoško i predmetno tehnološko znanje rezultira većim znanjem i boljim vještinama nastavnika u kombiniranju tehnologije i pedagogije u praktičnoj nastavi (Altun, 2013).

6.4 Kvazi eksperiment koji istražuje utjecaj vršnjačke procjene i/ili samoprocjene na pristup učenju i primjenu tehnologije u nastavi

Kvazi eksperiment proveden u okviru ove doktorske disertacije proveden je u svrhu istraživanja mogućnosti koje pruža uključivanje studenata u proces procjene znanja uz pomoć IKT-a te o utjecaju uključenosti studenata u proces procjena na pristup učenju i percepciju vlastitih znanja o primjeni tehnologije u nastavi. Tijekom kvazi eksperimenta, studenti su iskusili grupni i suradnički rad, nastavu organiziranu na temelju konstruktivnog poravnanja, rješavanje problemskih i složenih zadataka, procjenjivanje uz pomoć rubrike, poučavanje usmjereno na studenta, a sve to uz pomoć IKT-a. Potrebu za takvom vrstom istraživanja naglašava i Whealan (2008). Panadero i Jonsson (2013) također ističu potrebu za takvim vrstama istraživanja, posebice eksperimentalnim.

Uključivanje studenata u proces procjene znanja je jedan od načina poticanja studenata da primjene duboki pristup učenju (Entwistle, 2009, str. 88). Rezultati ovog istraživanja pokazali su suprotno, odnosno sudjelovanje u bilo kojem obliku procjene ne utječe na usvajanje dubinskog pristupa učenju. Pregled literature navodi da studenti u različitim disciplinama upotrebljavaju različite pristupe učenju učenja (Eley, 1992), (Kember i sur., 2008). Rezultati ovog istraživanja pokazali su da, bez obzira poučava li kolegij teme iz prirodnih, društvenih, tehničkih ili humanističkih znanosti, nema utjecaja znanstvenog područja kolegija na pristup učenju. Pregled literature također sugerira da studenti starije životne dobi češće primjenjuju duboki pristup učenju (Chamorro-Premuzic i Furnham, 2009), (Christie i sur., 2006). Rezultati istraživanja pokazuju da studijska godina, koja nije nužno proporcionalno povezana sa životnom dobi studenta, nema utjecaja na pristup učenju. Empirijska istraživanja u kontekstu visokog obrazovanja o utjecaju poučavanja usmjerenog prema studentu na dubinski pristup učenju ne pokazuju konzistentnost (Baeten i sur., 2010.). Ovo istraživanje pokazalo je da na

pristup učenju ne utječe sudjelovanje u procjeni, spol, studijska godina, razina studija niti znanstveno područje kolegija.

Što se tiče utjecaja spomenutih čimbenika (sudjelovanje u procjeni, spol, studijska godina, razina studija i znanstveno područje kolegija) na percepciju budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi, rezultati su istraživanja pokazali da niti jedan od navedenih čimbenika nema utjecaja na percepciju budućih učitelja o vlastitim znanjima u primjeni IKT-a u nastavi, iako je uočeno da je utjecaj vremena statistički značajan faktor. Dakle, postoji razlika u percepciji vlastitih znanja o primjeni tehnologije u nastavi, prije i nakon sudjelovanja u eksperimentu, ali niti jedan od promatranih čimbenika nije utjecao na tu promjenu.

Pouzdanost procjene je problem koji spominju Dochy i suradnici (1999) te navode kako se pouzdanost vršnjačke procjene može povećati kombinacijom vršnjačke procjene i samoprocjene ili kombinacijom vršnjačke i nastavničke procjene. Rezultati ovog istraživanja su pokazali da ne postoji povezanost između pristupa učenju koji student uobičajeno primjenjuje i dijametra kvazi - pouzdanosti i procjene, kao niti statistički značajna razlika između dijametra kvazi - pouzdanosti i kod samoprocjene i vršnjačke procjene, niti njihove kombinacije. Nije zabilježen utjecaj pristupa učenju, spola, studijske godine, razine studija i znanstvenog područja kolegija na varijabilnost dijametra kvazi - pouzdanosti i studentske procjene.

6.5 Prikupljanje mišljenja studenata o sudjelovanju u procesu procjene i samoprocjene

Na samom su kraju istraživanja studenti imali mogućnost iskazivanja vlastitog mišljenja putem otvorenog pitanja. Mišljenja i stavovi koje su iznijeli pojedini studenti mogu se povezati s činjenicama navedenim u pregledu literature.

Liu i Carless (2010) navode kako je broj studenata koji su imali mogućnost ocijeniti svog vršnjaka ili biti ocjenjeni od strane vršnjaka mali, što je u skladu s mišljenjem studenata jer većina njih navodi da je sudjelovanje u istraživanju nešto novo za njih i da nisu imali priliku sudjelovati u procjeni. Osim toga navode kako im je sudjelovanje u procjeni pozitivno iskustvo koje će im sigurno koristiti u njihovom budućem radu, što je u skladu s činjenicom da

konstruktivno poravnanje ima pozitivan utjecaj na zadovoljstvo studenata (Mulder i sur., 2014), (Azasu i Berggren, 2015), (McCann, 2016).

Procjena se eksperta (nastavnika) bezrezervno uzima točnom, dok se o procjeni vršnjaka kritički promišlja (Foley, 2013) što potvrđuje i jedan komentar kako je povratna informacija od vršnjaka nepotrebna i da je važna samo nastavnikova povratna informacija.

Prilikom vršnjačke procjene i samoprocjene, radi lakšeg i pouzdanijeg provođenja procjene, preporučuje se upotreba rubrika (Panadero i Jonsson, 2013), (Mulder i sur., 2014). Rubrike su od strane studenata u ovom istraživanju prepoznate kao iznimno pozitivno sredstvo za olakšavanje procesa procjene, koje je pojedincima, između ostalog, ukazalo na propuste koje su napravili u vlastitom uratku.

Kada je riječ o korištenju potencijala tehnologije u nastavi, manjak interakcije sa studentima navodi se kao glavni uzrok njegove slabe iskorištenosti ((Iahad i Dafoulas, 2004) prema (Hutinski i Aurer, 2009)). Među 82 komentara studenata bio je i jedan komentar koji upravo manjak interakcije zbog prevelike upotrebe IKT-a navodi kao razlog negativnog doživljaja cijelog procesa.

7 ZAKLJUČAK

Istraživanje u okviru ove doktorske disertacije rezultiralo je upitnikom o pristupu učenju u kontekstu problemskih i složenih zadataka. Validacijom proširenog RASI upitnika opravdana je njegova upotreba u svrhu ispitivanja pristupa učenju u spomenutom kontekstu. Daljnja istraživanja, u području razvoja RASI upitnika, trebala bi obuhvatiti dodatno proširenje upitnika u kontekstu problemskih i složenih zadataka, posebno za Strateški pristup učenju.

Validacija upitnika SPTKTT pokazala je da je upitnik moguće koristiti u svrhu ispitivanja percepcije vlastitih znanja o primjeni IKT-a u nastavi. Daljnja istraživanja trebala bi obuhvatiti prilagođavanje upitnika SPTKTT hrvatskom obrazovnom sustavu, posebno u domeni sadržajnih znanja, prilagoditi pitanja tako da odgovaraju predmetima Matematike, Prirode i društva te Hrvatskog jezika u razrednoj nastavi hrvatskog obrazovnog sustava.

Istraživanje o utjecaju sudjelovanja u procesu vršnjačke procjene i/ili samoprocjena na pristup učenju i percepciju vlastitih znanja o primjeni IKT-a u nastavi pokazalo je da postoji statistički značajan utjecaj sudjelovanja u procjeni na percepciju vlastitih znanja o primjenu tehnologije u nastavi. Svi ostali aspekti obuhvaćeni ovim istraživanjem, utjecaj spola, studijske godine, razine studija, znanstvenog područja kolegija, nemaju utjecaj ni na pristup učenju niti na percepciju budućih učitelja o primjeni IKT-a u nastavi niti na pouzdanost studentske procjene.

Mišljenja studenata o sudjelovanju u ovom istraživanju su većinom pozitivna, a posebno su istaknuti sljedeći pozitivni elementi: grupni rad, sudjelovanje u procjeni, upotreba rubrike tijekom procjene. Negativni se elementi dotiču uglavnom grupnom rada, pretjerane upotrebe IKT-a, procjene, ali su većinom izneseni u obliku vlastitog negativnog stava.

Cjelokupno je istraživanje obuhvaćeno ovom doktorskom disertacijom opsežno i rezultiralo je mnogim i vrijednim znanstvenim spoznajama, a najvrjednija među njima je činjenica da su studenti iskazali pozitivan stav prema ovom načinu poučavanja iako nisu imali prilike ranije učiti na taj način. Njihov je pozitivan stav motivacija za daljnje istraživanje i usavršavanje poučavanja u kojem studenti imaju glavnu ulogu u procjeni znanja.

7.1 Znanstveni doprinosi istraživanja

Znanstveni su doprinosi provedenog istraživanja sljedeći:

(1). Unaprjeđenje spoznaja o primjeni IKT-a u nastavi kod učitelja i nastavnika u praksi u Republici Hrvatskoj,

(2). Doprinos postojećim znanstvenim spoznajama o načinima unaprjeđenja znanja budućih učitelja i nastavnika o primjeni IKT-a u nastavi,

(3). Unaprjeđenje dizajna online okoline za učenje u svrhu razvoja znanja budućih učitelja i nastavnika o primjeni IKT-a u nastavi,

(4). Upotreba IKT-a u svrhu poboljšanja kvalitete nastave i boljeg postizanja ciljeva i zadataka odgojno-obrazovnog procesa, unaprjeđenja procesa procjene viših razina znanja i usvajanja dubinskog pristupa učenju,

(5). Proširenje postojećeg RASI mjernog instrumenta za ispitivanje pristupa učenju studenata.

7.2 Ograničenja istraživanja

Osnovno je ograničenje istraživanja uzorak ispitanika koji nije reprezentativan. S obzirom da se radi o kvazi eksperimentu, odnosno eksperimentu u obrazovanju, jasno je da se radi o prigodnom uzorku. Obrazovna istraživanja, općenito, jako teško zadovoljavaju zahtjevu za reprezentativnim uzorkom.

Učionica i ostale okoline za učenje složene su okoline u kojima istovremeno djeluju mnogobrojni faktori. Reći kako jedna ili dvije varijable imaju utjecaj na ishod mogu preuveličati njihov značaj i iz tog je razloga nužno eksperiment ponoviti i ispitati utjecaj ostalih varijabli kako bi se bolje razumio njihov utjecaj (Schunk D.H., 2012). Iako je u provedenom eksperimentu jedina varijabla po kojoj su se eksperimentalne skupine razlikovale bila Izvor procjene, ne smije se isključiti utjecaj ostalih faktora, poput grupnog rada, inteligencije, kriterijske procjene, konstruktivnog poravnanja ili osobnosti studenta, na konačne rezultate istraživanja. Svakako bi ovakav eksperiment trebalo ponoviti u nekom daljnjem istraživanju.

U eksperimentima u obrazovanju nemoguće je imati strogo kontrolirane uvjete i okolinu te pratiti sve moguće događaje i utjecaje (Cresswel, 2012). Kada kontrolna i eksperimentalna grupa u istraživanju mogu komunicirati, kontrolna grupa može dobiti informacije o tretmanu od eksperimentalne grupe (Cresswel, 2012). S obzirom da eksperimentalne skupine nisu bile

razdvojene po studijskim godinama, dakle na istoj studijskoj godini bile su uključene sve eksperimentalne skupine, njihov međusobni utjecaj treba istaknuti kao ograničenje istraživanja.

Odustajanje sudionika tijekom istraživanja zbog raznih razloga također može biti problem u ovom istraživanju (Cresswel, 2012). Jedan od načina da se izbjegne ovaj problem je izabiranje velikog uzorka. Prilikom odabira uzorka i svrstavanja u skupine postoji mogućnost da neki od sudionika budu otvoreniji prema eksperimentalnom tretmanu koji njihova skupina prima ili da ima takav način rada, kao osobama, više odgovara. Ovaj se problem može ublažiti slučajnim odabirom sudionika (Cresswel, 2012) kao što je i učinjeno u ovom istraživanju.

Zadaci koji su studentima zadani u okviru eksperimenta, kao i način njihove procjene, temelje se na konstruktivnom poravnanju. Konstruktivno poravnanje izvedeno je za potrebe ovog istraživanja, sami kolegiji i njihovo poučavanje ne temelje se na konstruktivnom poravnanju. Za neke kolegije bilo je lako posložiti ishode učenja, zadatak i procjenu, dok je za neke to bilo ipak teže ili nemoguće izvesti.

Sudjelovanje u eksperimentu bilo je dobrovoljno što može značiti da su u njemu sudjelovali motiviraniji i uspješniji studenti. Mišljenje je studenata u postupku procjene također bilo dobrovoljno što je moglo rezultirati manjim brojem negativnih komentara pa samim time se mogao steći lažan dobar dojam koji je sudjelovanje u procjeni ostavilo na studente.

LITERATURA

[1.] Abbitt. J. (2011). Measuring Technological Pedagogical Content Knowledge. *Journal of Research on Technology in Education Preservice Teacher Education: A Review of Current Methods and Instruments. 43*(4). 281-300.

[2.] Adam. S. (2008). *Learning outcomes current development in europe: Update on the issues and applications of learning outcomes associated with the Bologna process.* Edinburgh: Heriot-Watt University.

[3.] Adamson B. i Berry. R. (2011). *Assessment Reform in Education.* Dordrecht: Springer.

[4.] Altun. T. (2013). Examination of classroom teachers' technological pedagogical and content knowledge on the basis of their demographic profiles. *Croatian Journal of Education. 15*(2). 365-397.

[5.] American Library Association. (2000). *Information literacy competency standards for higher education.* Preuzeto 17.11.2017 iz https://arizona.openrepository.com/arizona/bitstream/10150/105645/1/standards.pdf

[6.] Anderson. L.. Krathwohl. D. R. i Bloom. B. S. (2001). *A taxonomy for learning. teaching. and assessing: a revision of Bloom's taxonomy of educational objectives.* London: Longman.

[7.] Anić. V. (2003). *Hrvatski enciklopedijski rječnik.* Zagreb: Novi Liber.

[8.] Archambault. L. i Barnett. J. (2010). Revisiting technological pedagogical content knowledge: exploring the TPACK framework. *Computers & Education. 55*(4). 1656–1662.

[9.] Azasu. S. i Berggren. B. (2015). Using constructive alignment to improve student research and writing skills: a case study of a master's program in real estate management. *International Journal of Learning and Change. 8*(1). 83-100.

[10.] Baeten. M.. Dochy. F.. Struyven. K.. Parmentier. E. i Vanderbruggen. A. (2016). Student-centred learning environments: an investigation into student teachers' instructional preferences and approaches to learning. *Learning Environments Research. 19*(1). 43-62.

[11.] Baeten. M.. Kyndt. E.. Struyven. K. i Dochy. F. (2010). Using student-centered learning environments to stimulate deep approaches to learning: Factors encouraging or discouraging their effectiveness. *Educational Research Review*. *5*(3). 243-260.

[12.] Ballantine. J.. Duff. A. i Larres. P. (2008). Accounting and business students' approaches to learning: a longitudinal study". *Journal of Accounting Education. 26*. 188-201.

[13.] Baser. D.. Kopcha. T. i Ozden. M. (2015). Developing a technological pedagogical content knowledge (TPACK) assessment for preservice teachers learning to teach English as a foreign language. *Computer Assisted Language Learning. 29*(4). 749-764.

[14.] Beaten. M.. Dochy. F. i Struyven. K. (2008). Students' approaches to learng and assessment preferenes in a prtofolio-based learning environment. *Instructional Science. 36*. 359-374.

[15.] Bell. B. i Cowie. B. (2001). The characteristics of formative assessment in science education. *Science Education. 85*(5). 536-553.

[16.] Berlin Communiqué. (2003). Realising the European higher education area. Communiqué of the conference of ministers responsible for higher education in Berlin on 19 September 2003. Berlin. Preuzeto 11. 7. 2015 iz http://www.enqa.eu/wp-content/uploads/2013/03/BerlinCommunique1.pdf

[17.] Biggs. J. (1996). Enhancing teaching through constructive alignment. *Higher Education. 32*(3). 347-364.

[18.] Biggs. J. (2001). Enhancing learning: A matter of style or approach? U R. Sternberg i L. Zhang (Ur.). *Perspectives on thinking. learning. and cognitive styles*. Mahwah. NJ: Erlbaum.

[19.] Biggs. J. i Tang. C. (2007). *Teaching for quality learning at university: what the student does.* New York: McGraw-Hill.

[20.] Bloom. B.. Engelhart. M. D.. Furst. E. J.. Hill. W. i Krathwohl. D. R. (1956). *Taxonomy of educational objectives: the classification of educational objectives. handbook1: cognitive domain.* New York: David McKay.

[21.] Bologna Declaration. (1999). *Joint declaration of the European ministers of education convened in Bologna on the 19th of June 1999.* Preuzeto 4. 11 2015 iz https://www.eurashe.eu/library/modernising-phe/Bologna_1999_Bologna-Declaration.pdf

[22.] Booth. P.. Luckett. P. i Maldenovic. R. (1999). The quality of larning in accaunting education: The impact of approaches to learning on academic performance. *Accounting Education: An International Journal. 8*(4). 277-300.

[23.] Boud. D. (2000). Sustainable assessment: rethinking assessment for the learning society. *Studies in Continuing Education. 22*(2). 151-167.

[24.] Boud. D. i Falchikov. N. (1989). Quantitative studies of self-assessment in higher education: a critical analysis of findings. *Higher Education. 18*(5). 529-549.

[25.] Brown. G. (1997). *Assessing student learning in higher education.* London: Routledge.

[26.] Byrne. M.. Flood. B. i Willis. P. (1999). Approaches to learning: Irish students of accounting. *Irish Accounting Review. 6*(2). 1-29.

[27.] Byrne. M.. Flood. B. i Willis. P. (2004). Validation of the approaches and study skills inventory for students (assist) using accouting students in the USA and Ireland: a research note. *Accounting Education: An International Journal. 13*(4). 449-459.

[28.] Cain. A. i Babar. M. (2016). Reflections on applying constructive alignment with formative feedback for teaching introductory programming and software architecture. *IEEE International Conference on Software Engineering Companion* (str. 336-345). Austin. Texas: ACM Press.

[29.] Campbell. K. S.. Mothersbaugh. D. L.. Brammer. C. i Taylor. T. (2001). Peer versus self assessment of oral business presentation performance. *Business Communication Quarterly. 64*(3). 23-42.

[30.] Carless. D. (2003). Learning-oriendted asessment. Adelaide: Evaluation and Assessment conference.

[31.] Chai . C.. Koh. J.. Tsai. C.-C. i Tan. L. (2011). Modeling primary school pre-service teachers' technological pedagogical content knowledge (TPACK) for meaningful learning with information and knowledge (TPACK) for meaningful learning with

information and communication technology (ICT). *Computers & Education*. *57*. 1184–1193.

[32.] Chai. C.. Koh. J. i Tsai. C. (2010). Facilitating preservice teachers' development of technological. pedagogical. and content knowledge (TPACK). *Educational Technology and Society. 13*(4). 63-73.

[33.] Chamorro-Premuzic. T. i Furnham. A. (2009). Mainly openness: the relationship between the Big Five personality traits and learning appoaches. *Learnig and Individual differences. 19*. 524-529.

[34.] Christie. H.. Cree. V.. Hounsell. J.. McCune. V. i Tett. L. (2006). From college to university: looking backwards. lookin forwards. *Research in Post-Compulsory Education. 11*(3). 351-365.

[35.] Cohen. L.. Manion. L. i Morrison. K. (2007). *Research methods in education.* London: Routledge.

[36.] Cox. W. (2003). A MATH-KIT for engineers. *Teaching mathematics and its applications. 22*(4). 193-198.

[37.] Cramp. A. (2011). Developing first-year engagement with written feedback. *Active Learning in Higher Education. 12*(2). 113-124.

[38.] Cresswel. J. (2012). *Eduactional Research: Planning. Conducting. and Evaluating Quantitative and Qualitative Research* (4 izd.). New York: Pearson.

[39.] Davies. A. (1999). *Dictionary of Language Testing.* Cambridge: Cambridge University Press.

[40.] De Grez. L.. Valcke. M. i Roozen I. (2012). How effective are self- and peer assessment of oral presentation skills compared with teychers' assessment? *Active Learning in Higher Education. 13*(2). 129-142.

[41.] De-la-Fuente-Valentín. L.. Carrasco. A.. Konya. K. i Burgos. D. (2013). Emerging technologies landscape on education. A review. *International Journal of Interactive Multimedia & Artificial Intelligence*. 2(3). 55-70.

[42.] Diseth. A. (2001). Validation of a Norwegian version of the approaches and study skills inventory for students (ASSIST): application of structural equation modelling. *Scandinavian Journal of Educationla Research. 45*(4). 381-394.

[43.] Divjak. B. (2011). Implementation of learning outcomes in mathematics for non-mathematics major by using e-learning. U Juan. H. Angel A.. T. Maria A.. S. Sven. & Cristina (Ur.). *Teaching Mathematics Online: Emergent Technologies and Methodologies* (str. 119-140). Hershey: IGI Global Snippet.

[44.] Divjak. B. i Maretić. M. (2015). Geometry for learning analytics. *18th Scientific-Professional Colloquium on Geometry and Graphics*. 15-15. (T. Došlić. & E. Jurkin. Ur.) Zagreb: Croatian Society for Geometry and Graphics.

[45.] Divjak. B. i Maretić. M. (2017). Learning analytics for peer-assessment: (dis)advantages. reliability and implementation. *Journal of Information and Organizational Sciences. 41*(1). 21-34.

[46.] Divjak. B. i Spahić. A. (2008). Linking higher education and employers: Bologna reforms and the Croatian private sector. U F. Ferrier. & M. Heagney (Ur.). *Higher Education in Diverse Communities. Global Perspectives - Local Initiatives* (str. 105-110). London: Higher Education Authority.

[47.] Divjak. B.. Grabar . D. i Maretić. M. (2016). Assessment analytics for peer-assessment: a model and implementation. U J. Greer. M. Molinaro. X. Ochoa. & T. McKay (Ur.). *Learning Analytics Curriculum and Program Quality Improvement* (str. 27-31). Aachen: CEUR Workshop Proceedings (CEUR-WS.org).

[48.] Divjak. B.. Strahonja. V.. Kermek. D. i Mornar. V. (2008). *Ishodi učenja* (II izd.). Varaždin: Fakultet organizacije i informatike.

[49.] Dochy. F.. Segers. M. i Sluijsmans. D. (1999). The use of self-. peer. and co-assessment in higher education: a review. *Studies in Higher Education. 24*(3). 331-350.

[50.] Dragulanescu. N.-G. (2002). Website quality evaluations: criteria and tools. *International Information And Library Review. 34*. 247-254.

[51.] Draper. S. (2009). Catalytic assessment: understanding how MCQs and EVS can foster deep learning. *Britih Journal of Educational Technology*. *40*(2). 285-293.

[52.] Draper. S. (2009). What are learners actually regulating when given feedback? *British Journal of Educational Technology*. *40*(2). 306-315.

[53.] Duff. A. (2004). Understanding academic performance and progression of first year accounting and business economics undergraduates: The role of approaches to learning and prior academic achievement. *Accounting Education: An International Journal*. *13*(4). 409-430.

[54.] Education Councile. (2006). Recommendation of the European parliament and of the council of 18 December 2006 on key competences for lifelong learning. *Brussels: Official Journal of the European Union*.

[55.] Eley. M. (1992). Differeential adoption of study approaches within individual studens. *Higher Education* . *23*(3). 231-254.

[56.] Elton. L. (1987). *Teaching in Higher Education: Appraisal and Training.* London: Kogan Page.

[57.] Entwistle. N. (2000a). Promoting deep learning through teaching and assessment: conceptual frameworks and educational contexts. Leicester: TLRP conference.

[58.] Entwistle. N. (2000b). Approache sto studying and levels of understanding : The influences of teaching and assessment. U J. C. Smart. *Higher Education: Handbook of theory and research* (str. 156-218). New York: Agathon Press.

[59.] Entwistle. N. (2009). *Teaching for Undrestanding at University: Deep Approaches and Distinctive Ways of Thinking.* New York: Palgrave Macmillan.

[60.] Entwistle. N. i Peterson. E. (2004). Conceptions of learning and knowledge in higher education: Relationships with study behaviour and influences of learning environments. *International Journal of Educational Research. 41*. 407-428.

[61.] Entwistle. N. i Ramsden. P. (1983). *Understanding student learning.* London: Croom Helm.

[62.] Entwistle. N. i Tait. H. (2013). *Approaches and Study Skills Inventory for Students (ASSIST) - Report of the development and use of the inventories.* Preuzeto 2015 iz http:/ www.etl.tla.ed.ac.uk/ publications.html

[63.] Entwistle. N. i Waterstone. S. (1988). Approaches to studying and levels of processing in university students. *British Journal of Educational Psychology. 58*(3). 258-265.

[64.] Entwistle. N.. Tait. H. i McCune. V. (2000). Patterns of response to an approaches to studying inventory across contrasting groups and context. *European Journal of Psychology of Education. 15*(1). 33-48.

[65.] Europea Commission. (2010). *Europe 2020: A strategy for smart. sustainable and inclusive growth.* Preuzeto 17.11.2017. iz http://ec.europa.eu/eu2020/pdf/COMPLET%20EN%20BARROSO%20%20%20007%20-%20Europe%202020%20-%20EN%20version.pdf

[66.] European Association for Quality Assurance in Higher Education. (2009). *Standards and Guidelines for Quality Assurance in the European Higher Education Area.* Helsinki: European Association for Quality Assurance in Higher Education.

[67.] European Commission. (2015). *ECTS Users' Guide 2015.* Preuzeto 20. 3 2017 iz http://europass.cedefop.europa.eu/sites/default/files/ects-users-guide_en.pdf

[68.] Falchikov. N. (1995). Peer feedback marking: developing peer assessment. *Innovations in Education and Training International. 32*(5). 175-187.

[69.] Fallows. S. i Bhanot. R. (2002.). Educational development of ICT: an introduction. U S. Fallows i R. Bhanot (Ur.). *Educational Development Through Information and Communications Technology* (str. 1-7). London: Kogan Page Limited.

[70.] Foley. S. (2013). Student views of peer assessment at the International School of Lausanne. *Journal of Research in International Education. 12*(3). 201-213.

[71.] Galand. B.. Bourgeois. E. i Frenay. M. (2003). The effect of PBL curriculum on students' motivation and self-regulation. Padova. Italy: *Biennial Conference of the European Association for Research on Learning and Instruction.*

[72.] Ghasemi A. i Zahedias S. (2012). Normality Tests for Statistical Analysis: A Guide for Non-Statisticians. *International Journal of Endocrinology & Metabolism.* 10(2). 486-489.

[73.] Giannakos. M.. Doukakis. S.. Pappas. I.. Adamopoulos. N. i Giannopoulou. P. (2015). Investigating teachers' confidence on technological pedagogical and content knowledge

- an initial validation of TPACK scales in K-12 computing education context. *Journal of Computers in Education. 2*(1). 43-59.

[74.] Gijbels. D. i Dochy. F. (2006). Students' asessment preferences and approaches to learning: Can formative assessment make a difference? *Educational Studies. 32*(4). 399-409.

[75.] Gijbels. D.. Segers. M. i Struyf. E. (2008). Constructivist learning environments and the (im)possibility to change students' perceptions of assessment demands and approaches to learning. *Instructional Science. 36*(5-6). 431–443.

[76.] Gilbert. L.. Whitelock. D. i Gale. V. (2011). *Synthesis report on assessment and feedback with technology enhancement.* Southampton: UK:Electronics and Computer Science EPrints.

[77.] Graesser. A. C.. Chipmann. P. i King. B. G. (2008). Computer-mediated technologies. U J. M. Spector. M. D. Merrill. J. Van MerrienBoer i M. P. Driscoll (Ur.). *Handbook of research on educational communication and technologies* (str. 211-224). New York: Rutledge.

[78.] Graham. C.. Burgoyne. N. i Borup. J. (2010). Te decision-making processes of preservice teachers as they integrate technology. U C. Crawford. D. Willis. R. Carlsen. I. Gibson. K. McFerrin. J. Price i R. Weber (Ur.). *Proceedings of the society for information technology & teacher education international conference 2010* (str. 3826–3832). Chesapeake: VA:.

[79.] Gulikers. J.. Kester. L.. Kirschner. P. i Bastiaens. T. (2008). The effecct of practical exprience onn perceptions of assessment authenticity. study approach and learnig outcomes. *Learning and Instruction. 18*(2). 172-186.

[80.] Hair. J. F.. Black. W. C.. Babin. B. J. i Anderson. R. E. (2010). *Multivariate data analysis: a global perspective*. New Jersey: Pearsib.

[81.] Handley. K.. Price. M. i Millar. J. (2008). *Engaging students with assessment feedback.* Oxford: Oxford Brooks University.

[82.] Harasim. L. (2012). *Learning theory and online technologies* (I izd.). New York and London: Routledge Taylor & Francis Group.

[83.] Harris. J.. Grandgenett. N. i Hofer. M. (2010). Testing a TPACK-based technology integration assessment rubric. U C. Crawford. D. Willis. R. Carlsen. I. Gibson. K. McFerrin. J. Price i R. Weber (Ur.). *Proceedings of the society for information technology & teacher education international conference 2010* (str. 3833–3840). Chesapeake: VA: AACE.

[84.] Hattie. J. i Timperley. H. (2007). The power of feedback. *Review of Educational Research. 77*(1). 81-112.

[85.] Hennink. M. (2007). *International focus group research: a handbook for the health and social sciences.* Cambridge: Cambridge University Press.

[86.] Hinkle. D.E.. Wiersma. W.. Jurs. S.G. (2003). *Applied Statistics for the Behavioral Sciences*. 5th ed. Boston: Houghton Mifflin.

[87.] Hooper. D.. Coughlan . J. i Mullen . M. (2008).Structural equation modelling: guidelines for determinig model fit. *Electronic Journal of Business Research Methods*. *6*(1). 53-60.

[88.] Hornsby. D. i Osman. R. (2014). Massification in higher education: large classes and student learning. *Higher Education. 67*(6). 711-719.

[89.] Hovardas. T.. Tsivitanidou. O. i Zacharia. Z. (2014). Peer versus expert feedback: An investigation of the quality of peer feedback among secondary school students. *Computers & Education. 71*. 133-152.

[90.] Hu. L. i Bentler . P. (1999). Cutoff criteria for fit indexes in covariance structure analysis: conventional criiteria versus new aternatives. *Structural Equation Modeling. 6*(1). 1-55.

[91.] Hutinski. Ž. i Aurer. B. (2009). Informacijskai komunikacijska tehnolopgijau obrazovanju: stanje i perspektive. *Informatologija. 42*(4). 265-272.

[92.] Iahad. N. i Dafoulas. G. A. (2004). The role of feedback in interactive learning systems: a comparative analysis of computer-aided assessment for theoretical and practical courses. (str. 535-539). Machester: IEEE International Conference.

[93.] Ibabe. I. i Jauregizar. J. (2009). Online self-assessment with feedback and metacognitive knowledge. *Higher Education. 59*. 243-258.

[94.] Jelaska. Z. i Cvikić. L. (2008). Procjenjivane i vrjednovanje u hrvatskom jeziku. *LAHOR*. 115-125.

[95.] Jimoyiannis. A. (2012). *Research on e-learning and ICT in education.* New York Dordrecht Heidelberg London: Springer.

[96.] Johnson-Wilder. S. i Primm. D. (2004). Samo technological tools of the mathematics teacher's trade. U S. Johnson-Wilder i D. Primm (Ur.). *Teaching secondary mathematics with ICT* (str. 18-39). McGraw-Hill International.

[97.] Jonassen. D. (2011). *Learning to solve problems.* New York: Routledge.

[98.] Jönsson. A.. Mattheos. N.. Svingby. G. i Attström. R. (2007). Dynamic assessment and the "interactive examination". *Educational Technology & Society. 10*(4). 17-27.

[99.] Kaiser. H. F. (1960). The application of electronic computers to factor analysis. *Educational and Pshychological Measurement. 20*. 141-151.

[100.] Karasavvidis. I. i Theodosiou. S. (2012). The design and development of a wiki task in undergraduate education: retrospects and prospects. U A. Jimoyiannis (Ur.). *Research on e-Learning and ICT in Education* (str. 157-168). London: Springer.

[101.] Keating. T. i Evans. E. (2001). Three computers in the back of the classroom: pre-service teachers' conceptions of technology integration. U J. Price. D. A. Willis. N. Davis. & J. Willis (Ur.). *Proceedings of the Society for Information Technology & Teacher Education International Conference 2001* (str. 1671-1676). Chesapeake: AACE.

[102.] Kember. D.. Leung. D. i McNaught. C. (2008). A workshop activity to demonastate that approaches to learning are influenced by teaching and learning environmet. *Active learning in higher education. 9*. 43-56.

[103.] Kennedy J. J. (1970). The eta coefficient in complex ANOVA designs. *Educational and Psychological measurement*. 30. 885-889.

[104.] Kim. M. (2009). The imapact of an elaborated assesse's role in peer assessment. *Assessment and Evaluation in Higher Education. 34*. 105-114.

[105.] Kline. P. (1994). A*n -easy guide to factor analysis*. New York: Routledge.

[106.] Kline. R. (2005). *Principles and Practice of Structural Equation Modeling* (2. izd.). New York: The Guilford Press.

[107.] Koehler. M. i Mishra. P. (2009). What is technological pedagogical content knowledge? *Contemporary Issues in Technology and Teacher Education. 9*(1). 60-70.

[108.] Koehler. M.. Mishra . P. i Yahya. K. (2007). Tracing the development of teacher knowledge in a design seminar: Integrating content. pedagogy and technology. *Computers & Education. 49*(3). 740-762.

[109.] Koehler. M.. Mishra. P.. Kerel. K.. Shin. T. i Graham. C. (2014). The technological pedagogical content knowledge framework. U J. Spector. J. Elen. M. Bishop i M. Merrill. *Handbook of Research on Educational Communications and Technology* (str. 101-111). New York: Springer.

[110.] Koehler. M.. Shin. T. i Mishra. P. (2012). How do we measure tpack? let me count the ways. U R. Ronau. C. Rakes i M. Niess. *Educational technology. teacher knowledge. and classroom impact: a research handbook on frameworks and approaches* (str. 16-31). Harshey: IGI Global.

[111.] Koh. J.. Chai. C. i Tsai. C. (2010). Examining the technological pedagogical content knowledge of Singapore preservice teachers with a large-scale survey. *Journal of Computer Assisted Learning. 26*. 563-573.

[112.] Kreber. C. (2003). The relationship between students' course perception and their approaches to studying in undergraduate science coursees: a Canadian experience. *Higher Education Research & Development. 22*(1). 57-75.

[113.] Krueger. R. i Casey. M. (2000). *Focus groups:a practical guide for applied research*. (3rd. Ur.) Thousand Oaks. CA: SAGE.

[114.] Larkin. H. i Richardson. B. (2012). Creating high challenge/high support academic environments through constructive alignment: student outcomes. *Teaching in Higher Education. 18*(2). 192-204.

[115.] Lawless. C. i Richardson . J. (2002). Approaches to studying and perceptions of academic quality in distance education. *Higher Education. 44*. 527-282.

[116.] Lee. M. i Tsai. C. (2010). Exploring teachers' perceived self efficacy and technological pedagogical content knowledge with respect to educational use of the world wide web. *Instructional Science. 38*. 1-21.

[117.] Lew. M.. Alwis . W. i Schmidt. H. (2010). Accuracy of students' self-assessment abd their belifs about it's utility. *Assessment & Evaluation in Higher Education. 35*(2). 135-156.

[118.] Lewley. D. N. i Maxwell. A. E. (1971). *Factor analysis as a statistical method.* London: Butterworth and Co.

[119.] Liu. N.-F. i Carless . D. (2010). Peer feedback: the learning element of peer assessment. *Teaching in Higher Education. 41*(3). 525-536.

[120.] Long. W. (2003). Dissonance detected by cluster analysis of responses to the Approaches and Study Skills Inventory for students. *Studies in Higher Education. 28*. 21-36.

[121.] Long. W. F. (2000). Detecting study approach dissonance in higher educational settings. An examination and use of the Approaches and Study Skills Inventory for Students. x: University of Aberdeen.

[122.] Lorent-Catalan . E. i Kirk. D. (2014). Making the case for democratic assessment practices within a critical pedagogy of physical education teacher education. *European Physical Review. 20*(1). 104-119.

[123.] Marton. F. i Säljö. R. (1984). Approaches to learning. U F. Marton. D. Hounsell i N. Entwistle (Ur.). *The experience of learning* (str. 39-58). Edinburgh: Scottish Academic Press.

[124.] McCann. M. (2016). Constructive alignment in economics teaching: a reflection on effective implementation. *Teaching in Higher Education. 22*(3). 336--348.

[125.] McDonald. R. i Ho. M.-R. (2002). Principles and practice in reporting statistical equation analyses. *Psychological Methods. 7*(1). 64-82.

[126.] Messina. L. i Tabone. S. (2013). Technology proficiency. TPACK and beliefs about technology: A survey with primary school student teachers. *Research on education and media*. *5*(1). 11-29.

[127.] Meyers, L.S., Gamst, G. i Guarino, A. (2006). *Applied multivariate research: Design and interpretation. Thousand Oaks*, CA: Sage Publishers.

[128.] Meyer. J. i Muller. M. (1990). Evaluating the quality of student learning. An unfolding analysis of the association between perceptions of learning context and approaches to studying at an individual level. *Studies in Higher Education*. *15*(2). 137-154.

[129.] Miles. J. i Shevlin. M. (1998). Effects of sample size. model specifications and factor loadings on the GFI in confirmatory factor analysis. *Personality and Individual Differences*. *25*. 85-90.

[130.] Ministarstvo znanosti. obrazovanja i sporta RH. (2013). *Zakon o Hrvatskom kavlifikacijskom okviru.* Zagreb: Ministrastvo znanosti. obrazovanja i sporta RH. Preuzeto 12.1.2016 iz Hrvatski kvalifikacijski okvir: http://www.kvalifikacije.hr/sites/default/files/documents-publications/2017-08/Zakon%20o%20Hrvatskom%20kvalifikacijskom%20okviru.pdf

[131.] Ministratstvo znanosti. obrazovanja i športa. (2010). *Nacionalani okvirni kurikulum za predškolski odgoj i obrazovanje te opće obvezno i srednjoškolsko obrazovanje.* Preuzeto 15. 11 2017 iz Agencija za odgoj i obrazovanje: http://www.azoo.hr/images/stories/dokumenti/Nacionalni_okvirni_kurikulum.pdf

[132.] Ministarstvo znanosti. obrazovanja i sporta RH. (2016). Okvir nacionalnog kurikuluma. Zagreb: Ministrastvo znanosti. obrazovanja i sporta RH. Preuzeto 25.3.2018. iz Cjelovita kurikulana reforma: http://www.kurikulum.hr/wp-content/uploads/2016/02/ONK-18.2-POPODNE-2.pdf

[133.] Mishra . K. i Koehler. M. (2005). Educational technology by design: Results from a survey assessing its effectiveness. U C. Crawford. C. Roger. I. Gibson. K. McFerrin. R. Weber. i D. Willis (Ur.). *Proceedings of the Society for Information Technology & Teacher Education International Conference 2005* (str. 1-7). Chesapeake: AACE.

[134.] Mishra. P. i Koehler. M. (2006). Technological pedagogical content. *Teachers Collage Record*. *108*(6). 1017-1054.

[135.] Moder, K. (2010). Alternatives to F-Test in One Way ANOVA in case of heterogeneity of variances. *Psychological Test and Assessment Modeling,* Volume 52(4), 343-353.

[136.] Morgan. D. (1988). *Focus groups as qualitative research* . Beverly Hills. CA: Sage.

[137.] Mulder. R.. Pearce. J. i Bail. C. (2014). Peer review in higher education: student perceptions before and after participation. *Active Learning in Higher Education. 15*(2). 157-171.

[138.] Nacionalnao Vijeće za Znanost. (2009). *Narodne Novine.* Dohvaćeno iz Pravilnik o znanstvenim i umjetničkim područjima. poljima i granama: http://narodne-novine.nn.hr/clanci/sluzbeni/2009_09_118_2929.html

[139.] National Research Council. (1999). *Being fluent with information technology literacy. Computer science and telecommunications board commission on physical sciences. mathematics. and applications.* Washington. DC: National Academy Press.

[140.] Nicol. D. J. i Macfarlane-Dick. D. (2006). Formative assessment and self-regulated learning: a model and seven priniples of good feedback practice. *Studies in Higher Education. 31*(2). 199-218.

[141.] Nightingale. S.. Carew. A. i Fung. J. (2007). Application of constructive alignment principles to engineering education: have we really changed? *AAEE - Annual Conference of Australasian Association for Engineering Education* (str. 1-9). Melbourne. Australia: Department of Computer Science and Software Engineering. University of Melbourne.

[142.] Norman. G. (2010). Likert scales. levels of measurement and the ‘‘laws’’ of statistics. *Advances in Health Sciences Education. 15*(5). 625-632.

[143.] Nuthall. G. (2002). Social constructivist teaching and the shaping of students' knowledge and thinking. *Advances in Research on Teaching. 9*. 43-79.

[144.] OECD (2013). *OECD Programme for International Student Assessment.* Preuzeto 5.. 3. 2015. iz http://www.oecd.org/pisa/pisaproducts/Draft%20PISA%202015%20Collaborative%20Problem%20Solving%20Framework%20.pdf

[145.] Pallant. J. (2001). *Spss survival manual. a step-by-step guide to data analysis using spss for windows.* Philadelphia. PA: Open University Press.

[146.] Pamuk. S.. Ergun. M.. Cakir. R.. Yilmaz. H. i Ayas. C. (2013). Exploring relationships among TPACK components and development of the TPACK instrument. *Education and Information Technologies. 2022*. 241–263.

[147.] Panadero. E. i Jonsson. A. (2013). The Use of Scoring Rubrics for Formative Assessment Purposes Revisited: A Review. *Educational Research Review. 9*. 129-144.

[148.] Pérez-Sanagustín. M.. Nussbaum . M.. Hilliger . I.. Alario-Hoyos . C.. Heller. R.. Twining . P. i Tsai. C.-C. (2017). Research on ICT in K-12 schools - a review of experimental and survey-based studies in Computers & Education 2011 to 2015. *Computers & Education. 105*. 1-15.

[149.] Potkonjak. V.. Gardner. M.. Callagha. V.. Mattila. P.. Guetl. C.. Petrović. V. i Jovanović. K. (2016). Virtual laboratories for education in science. technology. and engineering: a review. *Computers & Education. 95*. 309-327.

[150.] Prosser. M. i Trigwell. K. (2014). Qualitative variation in approaches to university teaching and learning in large first-year classes. *Higher Education. 67*(6). 783-795.

[151.] Ramsden. P. (1991). A performance indicator of teaching quality in higher education: the Course Experience Questionnaire. *Studies in Higher Education. 16*. 129-150.

[152.] Ramsden. P. (1992). *Learning to teach in higher education.* London: Routledge.

[153.] Ratner. H.. Foley . M. i Gimpert. N. (2002). The role of collaborative planning in children's source-monitoring errors and learning. *Journal of Experimental Child Psychology. 81*. 44-73.

[154.] Richardson. J. (1990). Reliability and replicability of the Approaches to Studying Questionnaire. *Studies in Higher Education. 15*(2). 155-168.

[155.] Richardson. J. T. (2005). Student's perceptions of academic quality and approaches to studying in distance education. *Studies in Higher Education. 31*(1). 7-27.

[156.] Rodrigues. F. i Oliveira. P. (2014). A system for formative assessment and monitoring of students' progress. *Computers & Education. 76*. 30-41.

[157.] Rosenberg. J. i Koehler. M. (2015). Context and technological pedagogical content knowledge (tpack): a systematic review. *Journal of Research on Technology in Education. 47*(3). 186-210.

[158.] Sadler. R. (1989). Formative assessment and the design of instructional systems. *Instructional Science. 18*(2). 119-144.

[159.] Saunders. L. (2012). Faculty perspectives on information literacy as a student learning outcome. *The Journal of Academic Librarianship. 38*(4). 226–236.

[160.] Scardamalia. M. i Bereiter. C. (2006). Knowledge building: theory. pedagogy. and technology. U K. Sawyer (Ur.). *Cambridge handbookof the learning sciences* (str. 97-118). New York: Cambridge University Press.

[161.] Schmidt. D.. Baran. E.. Thompson. A.. Punya. M.. Koehler. M. i Shin. T. (2009). Technological pedagogical content knowledge: the development and validation of an assessment instrument for preservice teachers. *Journal of Research on Technology in Education. 42*(2). 123-149.

[162.] Schunk D.H. (2012). *Learning theories: an educational perspective* (6. izd.). Boston: Pearson.

[163.] Sendziuk. P. (2010). Sink or swim? improving student learning through feedback and self-assessment. *International Journal of Teaching and Learning in Higher Education*. *22*(3). 320-330.

[164.] Shan Fu. J. (2013). ICT in education: a critical literature review and its implications. *International Journal of Education and Development using Information and Communication Technology*. *9*(1). 112-125.

[165.] Sharma. S.. Mukherjee. S.. Kumar . A. i Dillon. W. (2005). A simulation study to investigate the use of cutoff values for assessing model fit in covariance structure models. *Journal of Business Research. 58*(1). 935-943.

[166.] Sheskin. D. (2004). *Handbook of parametric and nonparametric statistical precedures*. Boca Raton: Chapman & Hall/CRC.

[167.] Shin. T.. Koehler. M.. Mishra. P.. Schmidt. D.. Baran. E. i Thompson. A. (2009). Changing technological pedagogical content knowledge (TPACK) through course

experiences. U *Society for Information Technology & Teacher Education International Conference* (str. 4152-4159). Association for the Advancement of Computing in Education (AACE).

[168.] Shinas. V.. Yilmaz-Ozden. S.. Mouza. C.. Karchmer-Klein. R. i Glutting. J. (2013). Examining domains of technological pedagogical content knowledge using factor analysis. *Journal of Research on Technology in Education* . *45*(4). 339–360.

[169.] Shulman . L. (1986). Those who understand: knowledge growth in teaching. *Education Researcher. 15*(2). 4-14.

[170.] Somerwell. H. (1993). Issues in assessment. enterprise and higher education: the case for self-. peer and collaborative assessment. *Assessment and evaluation in higher education. 18*(3). 221-233.

[171.] Struyven. K.. Dochy. F.. Janssens. S. i Gielen. S. (2006). On the dynamics of students' approaches to learning: The effects of the teaching/learning environment. *Learning and instruction. 16*. 279-294.

[172.] Tabachnick. B. G. i Fidell. L. S. (2013). *Using multivariate statistics.* Boston: Pearson.

[173.] Tait. H.. Entwistle. N. i McCune. V. (1998). ASSIST: A reconceptualisation of the approaches to studying inventory. U C. Rust. *Improving student learning: Improving students as learners.* Oxford: Oxford Brooks University. Oxford Centre for Staff and Learning Development.

[174.] Teixeira. C.. Gomes. D. i Borges. J. (2013). The Approaches to studying of portuguese students of Introductory Accounting. *Accounting Education. 22*. 193-210.

[175.] Topping. K. J. (2009). Peer assessment. *Theory into Practice. 48*(1). 20-27.

[176.] Trigwell. K. i Prosser. M. (1991). Relating approaches to study and quality of learning outcomesat the course level. *British Journal of Educational Psychology. 37*. 57-70.

[177.] Tseng. S.-C. i Tsai. C.-C. (2010). Taiwan college students' self-efficacy and motivation of learning in online peer assessment enviroments. *Internet and Higher Education. 13*. 164-169.

[178.] Učiteljski fakultet u Osijeku. (2014). *Samoanaliza Učiteljskog fakulteta u Osijeku.* Preuzeto 17. 3 2017 iz http://wt.foozos.hr/download/samoanaliza-2014.pdf

[179.] Valadas. S.. Goncalves. F. i Faisca. L. (2010). Approaches to studying in higher education Portuguese students: a Portuguese version of the approaches and study skills inventory for students. *Higher Education. 59*. 259-275.

[180.] Valtonen. T.. Sointu. E.. Mäkitalo-Siegl. K. i Kukkonen. J. (2015). Developing a TPACK measurement instrument for 21st century pre-service teachers. *Seminar.net - International journal of media. technology and lifelong learning. 11*(2). 87-100.

[181.] Vanfretti. L. i Milano. F. (8 2012). Facilitating constructive alignment in power systems engineering education using free and open-source software. *IEEE transactions on education. 55*(3). str. 309-318.

[182.] Vijeće Europe (2005). *Zajednički referentni okvir za jezike: učenje. poučavanje. vrednovanje.* Zagreb: Školska knjiga.

[183.] Vlada Republike Hrvatske. (2. 7 2014). *Strategija obrazovanja. znanosti i tehnologije.* Preuzeto 10. 1 2015 iz https://vlada.gov.hr/UserDocsImages//Materijali%20za%20istaknuto/2014/Strategija%20obrazovanja%20znanosti%20i%20tehnologije//Strategija%20OZT-Radni%20materijal%20rujan%202013%20%281%29.pdf

[184.] Vonderwell. S.. Liang. X. i Alderman. K. (2007). Asynchronous discussions and assessment in online learning. *Journal of Research on Technology in Education. 39*(3). 309-328.

[185.] Voogt. J. i Roblin. N. (2012). A comparative analysis of international frameworks for 21st century competences: Implications for national curriculum policies. *Journal of Curriculum Studies. 44*(3). 299–321.

[186.] Vos. N.. van der Meijden. H. i Denessen. E. (2011). Effects of constructing versus playing an educational game on student motivation and deep learning strategy use. *Computers & Education. 56*(1). 127-137.

[187.] Wang. X.. Su. Y.. Cheung. S.. Wong. E. i Kwong. T. (2013). An exploration of Biggs' constructive alignment in course design and its impact on students' learning approaches. *Assessment & Evaluation in Higher Education. 38*(4). 477-491.

[188.] Watkins. D. i Hattie. J. (1981). The learning proccesses of Australian university students: Investigations of contextual and personalogical factors. *British Journal of Educational Psychology. 51*(3). 384-393.

[189.] Whealan. R. (2008). Use of ICT in education in the South Pacific: findings of the Pacific eLearning Observatory. *Distance Education. 29*. 53-70.

[190.] William. D. i Black. P. (1996). Meanings and consequences: a basis for distinguishing formative and summative functions of assessment. *British Educational Research Journal. 22*(5). 537-548.

[191.] Willson. K.. Lizzio. A. i Ramsden . P. (1997). The development. validation and appreciation of the Course Experience Quesstionaire. *Studies in Higher Education. 22*. 33-53.

[192.] Žiljak. O. (2013). Ishodi učenja i inkluzivna edukacija učenika s intelektualnim poteškoćama. *Revija za socijalnu politiku. 20*(3). 275-291.

PRILOZI

PRILOG I

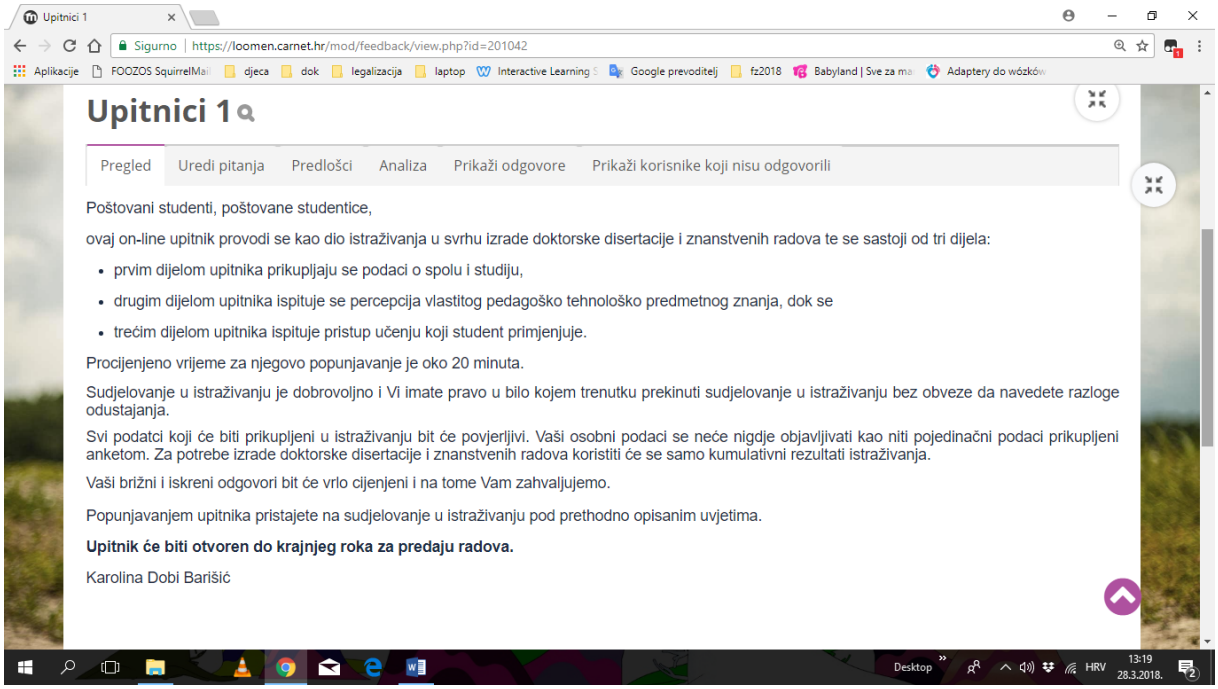

Slika 78. Suglasnost za sudjelovanja u istraživanju u sklopu aktivnosti Survey unutar sustava za upravljanje učenjem Moodle

PRILOG II

U ovom prilogu opisani su zadaci koji su rješavani u okviru istraživanja. za vrijeme provedbe eksperimenta. Za svaki kolegij i svaki zadatak je prikazano konstruktivno poravnanje te kriteriji na temelju kojih su vršene procjene.

Programski jezik Logo

Studenti su se samostalno podijelili u grupe od po četiri studenta. Rješavali su sljedeći zadatak:

> Zadatak: *Svakoj skupini studenata bit će dodijeljen crtež na kojem se nalazi lik. Treba napisati program koji crta zadani lik i obojiti ga kako je zadano na slici. Duljine stranica su proizvoljne. a kutove trebate odrediti sami tako da nacrtani lik odgovara zadanom liku. Tijekom rješavanja zadatka treba primijeniti sva do sada stečena znanja.*
>
> *Datoteku prilikom spremanja nazovite proizvoljnim imenom. ali izbjegavajte imena članova skupine koja su rješavala zadatak. Prilikom predavanja rješenja trebate predati i sliku koja je dodijeljena u okviru zadatka.*

Tablica 75 prikazuje konstruktivno poravnanje za kolegij Programski jezik Logo.

Tablica 76 prikazuje popis kriterija i raspon bodova za svaki promatrani kriterij pomoću kojih se vršila procjenu rješenja zadataka u okviru Programskog jezika LOGO.

Tablica 76. Konstruktivno poravnanje za kolegij Programski jezik Logo

Ishodi učenja na nivou studijskog programa	***Ishodi učenja kolegija***	***Sadržaj/način učenja***	***Procjena***	***ECTS***
Cilj je upoznati studente s principima programiranja i korištenja programskog jezika LOGO	U Logu primijeniti koncepte: programska petlja. grananje. potprogram. ulazne i izlazne vrijednosti. Programirati crtanje geometrijskih likova i mreža u Logu primjenom grafike kornjače. Samostalno se snalaziti u okolini Loga s ciljem daljnjeg napredovanja.	U skupinama od po četiri studenta izraditi program koji crta zadani lik	Samoprocjena i/ili vršnjačka procjena rješenja zadatka uz pomoć unaprijed definiranih kriterija i rubrike	15 sati 0.5 ECTS

Potpuna rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjenu rješenja zadataka u okviru Programskog jezika Logo nalazi se u Tablici 77.

Tablica 77. Popis kriterija i raspona bodova za svaki pojedini kriterij za Programski jezik LOGO

Kriterij	***Izgled nacrtane slike***	***Duljine stranica i kutovi***	***Procedure***	***Petlje***	***Inovativni elementi u programskom kodu***
Raspon bodova	0-2	0-2	0-3	0-3	0-3

Tablica 78. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Programski jezik LOGO

Kriteriji ↓		***Stupnjevi izvedbe za svaki pojedini kriterij →***			
1.	***Izgled nacrtane slike***	*Nacrtana slika ne odgovara zadanoj slici.*	*Nacrtana slika ne odgovara u potpunosti zadanoj slici. neki dijelovi i elementi nisu nacrtani prema zadanoj slici.*	*Nacrtana slika u potpunosti odgovara zadanoj slici.*	
		0 bodova	**1 bod**	**2 boda**	
2.	***Duljine stranica i kutovi***	*Odabrane duljine stranica i određeni kutovi nisu točni i iz tog razloga krajnji crtež ne odgovara zadanom crtežu.*	*Nekim stranicama nisu dobro odabrane duljine ili nekim kutovima nisu dobro određene mjere pa predloženi crtež ne odgovara u potpunosti zadanom crtežu.*	*Odabrane duljine stranica i određeni kutovi su točni.*	
		0 bodova	**1 bod**	**2 boda**	
3.	***Procedure***	*U programskom kodu uopće nisu korištene procedure.*	*U programskom kodu su korištene procedure. ali dio programskog koda koji se odnosi na procedure je netočan.*	*U programskom kodu su korištene procedure. dio programskog koda koji se odnosi na procedure djelomično je točan.*	*U programskom kodu su procedure korištene na točan i ispravan način.*
		0 bodova	**1 bod**	**2 boda**	**3 boda**
4.	***Petlje***	*U programskom kodu uopće nisu korištene petlje.*	*U programskom kodu su korištene petlje. ali dio programskog koda koji se odnosi na petlje je netočan.*	*U programskom kodu su korištene petlje. dio programskog koda koji se odnosi na petlje djelomično je točan.*	*U programskom kodu su petlje korištene na točan i ispravan način.*
		0 bodova	**1 bod**	**2 boda**	**3 boda**
5.	***Inovativni elementi u programskom kodu***	*Predloženi programski kod je netočan i u tom kontekstu ne može se govoriti o inovativnim elementima.*	*Predloženi programski kod je korektan. ali bez inovativnih elemenata.*	*Predloženi programski kod je korektan s ponekim inovativnim elementom.*	*Predloženi programski kod je u potpunosti inovativan i kreativan.*
		0 bodova	**1 bod**	**2 boda**	**3 boda**

Statistika

Studenti su se samostalno podijelili u grupe od po četiri studenta. Rješavali su sljedeći zadatak:

Zadatak: *Svakoj skupini studenata dodijeljena je jedna baza podataka. Analizirajte dodijeljenu bazu podataka u odnosu na sljedeće smjernice:*

- *navesti sve varijable u bazi i opisati ih (klasificirati).*
- *tablica frekvencija i relativnih frekvencija svih varijabli.*
- *osnovne numeričke karakteristike podataka (aritmetička sredina. medijan. donji i gornji kvartil. mod. raspon i standardnu devijaciju) sadržane u danim varijablama.*

Opišite (interpretirajte) moguću primjenu osnovnih numeričkih karakterističnih podataka u kontekstu dane baze podataka.

Analizu baze te interpretaciju moguće primjene zapišite u tekstualnom dokumentu (npr. Microsoft Office Word). Osim tekstualnog dokumenta. prilikom predavanja rješenja zadaće trebate predati i dodijeljenu bazu.

Tablica 78 prikazuje konstruktivno poravnanje za kolegij Statistika.

Tablica 79. Konstruktivno poravnanje za kolegij Statistika

Kompetencija na nivou studijskog programa	***Ishodi učenja kolegija***	***Sadržaj/način učenja***	***Procjena***	***ECTS***
Osposobiti studente za izvođenje zaključaka i donošenje odluka korištenjem statističkih metoda.	Odrediti mjere deskriptivne statistike. Interpretirati mjere deskriptivne statistike.	U skupinama od po četiri studenta analizirati dodijeljenu bazu podataka u kontekstu deskriptivne statistike.	Samoprocjena i/ili vršnjačka procjena rješenja zadatka uz pomoć unaprijed definiranih kriterija i rubrike	15 sati 0.5 ECTS

Tablica 79 prikazuje rubriku s kriterijima i stupnjevima izvedbe za svaki promatrani kriterij pomoću koje se vršila procjena rješenja zadataka u okviru Statistike.

Tablica 80. Popis kriterija i raspona bodova za svaki pojedini kriterij za Statistiku

Kriterij	***Varijable***	***Klasifikacija varijabli***	***Tablica frekvencija i relativnih frekvencija***	***Osnovne numeričke karakteristike podataka***	***Interpretacija***
Raspon bodova	0-2	0-2	0-3	0-3	0-3

Potpuna rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjenu rješenja zadataka u okviru Statistike prikazani su u Tablici 80.

Tablica 81. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Statistika

Kriteriji ↓		***Stupnjevi izvedbe za svaki pojedini kriterij →***			
1.	***Varijable***	*Varijable uopće nisu navedene.*	*Nisu navedene sve varijable koje se pojavljuju u dodijeljenoj bazi.*	*Sve varijable koje se pojavljuju u bazi su navedene.*	
		0 bodova	**1 bod**	**2 boda**	
2.	***Klasifikacija varijabli***	*Varijable nisu klasificirane.*	*Klasifikacija nekih od navedenih varijabli nije točna.*	*Sve navedene varijable su točno klasificirane.*	
		0 bodova	**1 bod**	**2 boda**	
3.	***Tablica frekvencija i relativnih frekvencija***	*U analizi baze nisu uopće prikazane tablice frekvencija i relativnih frekvencija.*	*Analiza baze ne obuhvaća tablice frekvencija i relativnih frekvencija svih varijabli i neke od njih nisu točne.*	*Analiza baze <u>ne obuhvaća</u> tablice frekvencija i relativnih frekvencija svih varijabli. ali su sve navedene tablice frekvencija i relativnih frekvencija u potpunosti su točne*	*Analiza baze <u>obuhvaća</u> tablice frekvencija i relativnih frekvencija svih varijabli i sve navedene tablice frekvencija i relativnih frekvencija u potpunosti su točne*
		0 bodova	**1 bod**	**2 boda**	**3 boda**
4.	***Osnovne numeričke karakteristike podataka***	*U analizi dodijeljene baze uopće nisu obrađene osnovne numeričke karakteristike podataka.*	*U analizi dodijeljene baze podataka obrađene su samo neke od osnovnih numeričkih karakteristika podataka od kojih su neke netočno izračunate.*	*U analizi dodijeljene baze podataka obrađene su samo neke od osnovnih numeričkih karakteristika podataka. Sve navedene karakteristike točno su izračunate.* *ILI* *U analizi dodijeljene baze podataka obrađene su sve osnovne numeričke karakteristike*	*U analizi dodijeljene baze podataka obrađene su sve osnovne numeričke karakteristike podataka i sve su točno izračunate.*

				podataka. ali su neke od njih netočno izračunate.	
		0 bodova	**1 bod**	**2 boda**	**3 boda**
5.	***Interpretacija***	*U analizi dodijeljene baze podataka nije navedena interpretacija moguće primjene osnovnih numeričkih karakteristika podataka.*	*U analizi dodijeljene baze podataka navedena je interpretacija moguće primjene osnovnih numeričkih karakteristika podataka.. ali je ona nejasna i netočna.*	*U analizi dodijeljene baze podataka navedena je korektna interpretacija moguće primjene osnovnih numeričkih karakteristika podataka.*	*U analizi dodijeljene baze podataka navedena je inovativna i kreativna interpretacija moguće primjene osnovnih numeričkih karakteristika podataka.*
		0 bodova	**1 bod**	**2 boda**	**3 boda**

Prirodno geografska obilježja Hrvatske

Studenti su se samostalno podijelili u grupe od po sedam studenata. Rješavali su sljedeći zadatak:

Zadatak: *Zadatak se rješava u skupinama od po 7 studenata. Svaka skupina treba nacrtati kartu većeg zamišljenog grada na jezeru. u podnožju brda. Karta treba uključivati sve matematičke i reljefne elemente (međusobno raspodijelite koje elemente će izraditi koji član skupine).*

Kada nacrtate kartu. uslikajte ju (.jpg. .gif. .png. ...) i predajte na Loomen. Datoteku (fotografiju) nazovite imenom koji ste odabrali za svoj zamišljeni grad.

Tablica 81 prikazuje konstruktivno poravnanje za kolegij Prirodno geografska obilježja Hrvatske.

Tablica 82. Konstruktivno poravnanje za kolegij Prirodno geografska obilježja Hrvatske

Kompetencija na nivou studijskog programa	***Ishodi učenja kolegija***	***Sadržaj/način učenja***	***Procjena***	***ECTS***
Produbljivanje i proširivanje stečenih geografskih znanja radi potpunijeg općeg i stručnog obrazovanja budućih učitelja razredne nastave.	Ishodima učenja studenti će se osposobiti za razumijevanje zemljopisnih osobitosti Republike Hrvatske. za poznavanje osobitosti krajobraza svijeta.	U skupinama od po sedam studenata izraditi zemljopisnu kartu zamišljenog grada.	Samoprocjena i/ili vršnjačka procjena rješenja zadatka uz pomoć unaprijed definiranih kriterija i rubrike	20 sati 0.66 ECTS

Tablica 82 prikazuje rubriku s kriterijima i stupnjevima izvedbe za svaki promatrani kriterij pomoću koje se vršila procjenu rješenja zadataka u okviru kolegija Prirodno geografskih obilježja Hrvatske.

Tablica 83. Popis kriterija i raspona bodova za svaki pojedini kriterij za Prirodno geografska obilježja Hrvatske

Kriterij	***Raznovrsnost topoloških simbola***	***Točnost upotrijebljenih topoloških simbola***	***Pravilna upotreba boja***	***Matematički elementi***	***Geografski elementi***	***Urednost***	***Vizualni dojam***
Raspon bodova	0-2	0-2	0-2	0-2	0-2	0-2	0-2

Potpuna rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjenu rješenja zadataka u okviru Prirodno geografskih obilježja Hrvatske prikazani su Tablici 83.

Tablica 84. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Prirodno geografska obilježja Hrvatske

Kriteriji ↓		***Stupnjevi izvedbe za svaki pojedini kriterij →***		
1.	***Raznovrsnost topoloških simbola***	Na nacrtanoj karti korišteno je izrazito malen broj različitih topoloških simbola	Na nacrtanoj karti su korišteni raznovrsni topološki simboli. u korektnoj količini	Raznovrsnost topoloških simbola na nacrtanoj karti je vrlo bogata
		0 bodova	*1 bod*	*2 boda*
2.	***Točnost upotrijebljenih topoloških simbola***	Na nacrtanoj karti su mnogi topološki simboli netočni ili su korišteni na pogrešan način.	Na nacrtanoj karti postoji do tri topološka simbola koja su netočna ili su korištena na pogrešan način.	Na nacrtanoj karti su svi topološki simboli točni i pravilno su korišteni.
		0 bodova	*1 bod*	*2 boda*
3.	***Pravilna upotreba boja***	Svi sadržaji na karti su nepravilno obojani	Neki (do dva) sadržaji na karti su nepravilno obojeni	Svi sadržaji na karti su nepravilno obojani
		0 bodova	*1 bod*	*2 boda*
4.	***Matematički elementi***	Matematički elementi uopće nisu zastupljeni na karti	Neki od matematičkih elemenata nisu zastupljeni na karti	Na karti su zastupljeni svi matematički elementi
		0 bodova	*1 bod*	*2 boda*
5.	***Geografski elementi***	Na nacrtanoj karti nisu zastupljeni svi geografski elementi	Geografski elementi na karti su korektni	Na nacrtanoj karti zastupljeni su svi geografski elementi na zanimljiv i kreativan način
		0 bodova	*1 bod*	*2 boda*

6.	***Urednost***	Nacrtana karta je neuredna	Urednost nacrtane karte je korektna	Nacrtana karta je izuzetno uredna. što povećava vizualni dojam
		0 bodova	*1 bod*	*2 boda*
7.	***Vizualni dojam***	Vizualni dojam nacrtane karte je jako loš	Vizualni dojam nacrtane karte je korektan	Nacrtana karta je vizualno izuzetno dopadljiva
		0 bodova	*1 bod*	*2 boda*

Metodika matematike I

Studenti su se samostalno podijelili u grupe od po četiri studenta. Rješavali su sljedeći zadatak:

> Zadatak: *Svaka skupina studenata ima zadatak osmisliti zadatak otvorenog tipa. Osim teksta zadatka. studenti trebaju predati i predloženo rješenje zadatka. Zadatak i njegovo rješenje mogu se predati kao tekstualni dokument (.docx. .pdf. .odt. ...) ili kao slike (.png. .jpg. ...)*

Tablica 84 prikazuje konstruktivno poravnanje za kolegij Metodika matematike I.

Tablica 85. Konstruktivno poravnanje za kolegij Metodika matematike I

Kompetencija na nivou studijskog programa	***Ishodi učenja kolegija***	***Sadržaj/način učenja***	***Procjena***	***ECTS***
Osposobiti studente u planiranju. organiziranju i ostvarivanju zadataka nastave matematike u prva četiri razreda osnovne škole. primjenom uobičajenih i suvremenih didaktičkih postupaka. načina djelovanja i metoda učenja i poučavanja	Razumjeti i koristiti metode mišljenja i zaključivanja (analogija. analiza i sinteza. indukcija i dedukcija. generalizacija i specijalizacija. apstrakcija i konkretizacija) Korektno koristiti matematički aparat i matematičku terminologiju. Primijeniti suvremene koncepcije nastave	U skupinama od po četiri studenta osmisliti i riješiti zadatak otvorenog tipa	Samoprocjena i/ili vršnjačka procjena rješenja zadatka uz pomoć unaprijed definiranih kriterija i rubrike	20 sati 0.66 ECTS

Tablica 85 prikazuje rubriku s kriterijima i stupnjevima izvedbe za svaki promatrani kriterij pomoću koje se vršila procjenu rješenja zadataka u okviru Metodike matematike I

Tablica 86. Popis kriterija i raspona bodova za svaki pojedini kriterij za Metodiku matematika I

Kriterij	***Matematičke oznake i terminologija***	***Razumljivost***	***Kreativnost osmišljenog zadatka***	***Rješenja zadatka***	***Sadržajna valjanost***	***Zanimljivost***
Raspon bodova	0-2	0-2	0-2	0-2	0-2	0-2

Potpuna rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadataka u okviru Metodika Matematike I prikazani su Tablici 86.

Tablica 87. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Metodika matematike I

Kriteriji ↓		***Stupnjevi izvedbe za svaki pojedini kriterij →***		
1.	***Matematičke oznake i terminologija***	*U postavljenom zadatku matematički pojmovi i terminologija korišteni su na krivi način.*	*U postavljenom zadatku pojmovi i terminologija korišteni su na ispravan način.*	*U postavljenom zadatku korišteni su matematički pojmovi i terminologija za koje je potrebno učenikovo dublje razumijevanje.*
		0 bodova	**1 bod**	**2 boda**
2.	***Razumljivost***	*Iz postavljenog zadatka nije razumljivo što se u zadatku traži.*	*U postavljenom su zadatku neki dijelovi nejasni i nerazumljivi.*	*Zadatak je postavljen na razumljiv i jasan način.*
		0 bodova	**1 bod**	**2 boda**
3.	***Kreativnost osmišljenog zadatka***	*U postavljenom zadatku matematički pojmovi i terminologija korišteni su na krivi način pa se iz tog razloga ne može prosuđivati njegova kreativnost.*	*Kreativnost je osmišljenog zadatka korektna.*	*Osmišljeni je zadatak zadan na kreativan način i sadržava zanimljive i inovativne elemente.*
		0 bodova	**1 bod**	**2 boda**
4.	***Rješenja zadatka***	*Zadatak ima jedinstveno rješenje do kojeg je moguće doći na samo jedan način.*	*Zadatak ima jedinstveno rješenje do kojeg je moguće doći na više različitih načina.* *ILI* *Zadatak ima nekoliko različitih rješenja.*	*Zadatak ima više rješenja i više načina da se dođe do tih rješenja.*
		0 bodova	**1 bod**	**2 boda**
5.	***Sadržajna***	*Rješavanje zadatka od*	*Zadatak je postavljen u*	*Dijelovi zadatka izazovni su*

	valjanost	*učenika zahtjeva znanja koja oni ne posjeduju.*	*skladu s učeničkim postojećim znanjima.*	*za učenike u odnosu na njihova postojeća znanja.*
		0 bodova	**1 bod**	**2 boda**
6.	***Zanimljivost***	*Osmišljeni zadatak postavljen je korektno. ali je nezanimljiv te na taj način ne predstavlja dodatni poticaj njegovom rješavanju.*	*Zanimljivost osmišljenog zadatka nije nadahnjujuća. ali je korektna.*	*Osmišljeni je zadatak vrlo zanimljiv što daje dodatni poticaj njegovom rješavanju.*
		0 bodova	**1 bod**	**2 boda**

Metodologija pedagoškog istraživanja

Studenti su se samostalno podijelili u grupe od po četiri studenta. Rješavali su sljedeći zadatak:

> Zadatak: *Podijeljeni u grupe od po četiri osobe provedite intervju s djecom za potrebe izrade sociograma. Svaka skupina dobit će vrtić koji će obići. Intervju se provodi snimajući diktafonom i zapisujući odgovore djece. Dobivene podatke unijet ćete u program Walsh's Sociometrics i napraviti izvješće o socijalnom statusu djece u skupini.*

Tablica 87 prikazuje konstruktivno poravnanje za kolegij Metodologija pedagoškog istraživanja.

Tablica 88. Konstruktivno poravnanje za kolegij Metodologija pedagoškog istraživanja.

Kompetencija na nivou studijskog programa	***Ishodi učenja kolegija***	***Sadržaj/način učenja***	***Procjena***	***ECTS***
Razviti istraživačke vještine na razini izrade stručnog rada. Razviti sklonost prema timskom radu. interakcijom i suradnjom utemeljenima na partnerskim odnosima. Pokazati sposobnost za stalno procjenjivanje i samoprocjenu vlastitoga rada.	Posjedovati kapacitet za učenje kao pretpostavku za generiranje novih ideja i za prilagodljivost na nove situacije. Demonstrirati sposobnost prilagođavanja novim i neočekivanim situacijama na način aktivne primjene stečenih znanja. vještina i sposobnosti;	U skupini od po četiri studenta izraditi sociogram i izvješće o socijalnom statusu djece za dodijeljenu vrtićku skupinu.	Samoprocjena i/ili vršnjačka procjena rješenja zadatka uz pomoć unaprijed definiranih kriterija i rubrike	30 sati 1 ECTS

Tablica 88 prikazuje rubriku s kriterijima i stupnjevima izvedbe za svaki promatrani kriterij pomoću koje se vršila procjena rješenja zadataka u okviru Metodologije pedagoškog istraživanja.

Tablica 89. Popis kriterija i raspona bodova za svaki pojedini kriterij za Metodologiju pedagoškog istraživanja

Kriterij	***Opis vrtićke skupine u kojoj se provodi sociometrijsko istraživanje***	***Istaknuti sociometrijski status pojedinaca u grupi***	***Odnosi unutar grupe***	***Kohezivnost grupe***	***Posebne sociometrijske kategorije***
Raspon bodova	0-2	0-2	0-3	0-2	0-3

Potpuna rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjenu rješenja zadataka u okviru Metodologija pedagoškog istraživanja prikazani su Tablici 89.

Tablica 90. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Metodologija pedagoškog istraživanja

Kriteriji ↓		***Stupnjevi izvedbe za svaki pojedini kriterij →***			
1.	**Opis vrtićke skupine u kojoj se provodi sociometrijsko istraživanje**	*Vrtićka skupina uopće nije opisana*	*Opis je vrtićke skupine korektan*	*Opis je vrtićke skupine informativan i detaljan*	
		0 bodova	**1 bod**	**2 boda**	
2.	**Istaknuti sociometrijski status (***pozitivan. negativan ili indiferetan***) pojedinaca u grupi**	*Nisu uopće prepoznate ILI Nisu uopće spomenute u izvješću*	*Nisu prepoznati svi istaknuti pojedinci. ILI Neki istaknuti pojedinci nisu pravilno prepoznati.*	*Uočeni su i pojašnjeni svi istaknuti sociometrijski statusi pojedinaca unutar skupine.*	
		0 bodova	**1 bod**	**2 boda**	
3.	**Odnosi unutar grupe**	*Nisu uopće prepoznati. ILI Nisu uopće spomenuti u izvješću.*	*Neki su odnosi unutar grupe prepoznati. ali postoje odnosi koji nisu uočeni i objašnjeni*	*Odnosi su unutar grupe pravilno prepoznati i objašnjeni*	*Odnosi su unutar grupe lijepo i detaljno pojašnjeni. uočeni su neki odnosi koje je teže zapaziti (ja osobno ih nisam zapazio/zapazila)*
		0 bodova	**1 bod**	**2 boda**	3 boda
4.	**Kohezivnost grupe**	*Nije uopće prepoznata ILI Nije uopće spomenuta u izvješću*	*Kohezivnost je grupe korektno opisana i pojašnjena*	*Kohezivnost je grupe vrlo detaljno opisana i vrlo je informativna.*	

		0 bodova	1 bod	2 boda	
5.	**Posebne sociometrijske kategorije**	*Nisu uopće prepoznate ILI Nisu uopće spomenute u izvješću*	*Neke posebne sociometrijske kategorije uočene su. ali su krivo protumačene.*	*Posebne su sociometrijske kategorije koje su uočene pravilno i korektno protumačene.*	*Posebne su sociometrijske kategorije vrlo detaljno i precizno pojašnjenje. istaknute su neke kategorije koje je teže zapaziti (ja osobno ih nisam zapazio/zapazila)*
		0 bodova	**1 bod**	**2 boda**	**3 boda**

Programiranje

Studenti su se samostalno podijelili u grupe od po četiri studenta. Rješavali su sljedeći zadatak:

Zadatak: *Svakoj skupini studenata daje se zadatak izrade edukativnog programa u Scratchu:*

Potrebno je pripremiti dijagram toka. pseudokod i program za vježbanje zbrajanja do 20 uz pomoć programskog alata Scratch. Program treba omogućiti generiranje dva nasumična broja u rasponu od 1 do 10. ispisati ih na ekranu i omogućiti korisniku unos rezultata njihovog zbrajanja. Korisnik (učenik) unosi rezultat zbrajanja. Program uspoređuje uneseni broj sa zbrojem dvaju prije generiranih nasumičnih brojeva. Ukoliko je zbroj jednak unesenom broju tada izvještava da je rezultat točan. a inače da nije točan te u svakom slučaju ispisuje točan rezultat zbrajanja. Program treba omogućiti korisniku vježbanje zbrajanja tako dugo dok na upit o tome želi li još zbrajati odgovara 'Da'.

Uz pomoć ugrađenih simbola dijagrama toka u OpenOffice Writeru ili Microsoft Wordu potrebno je pripremiti dijagram toka. napisati pseudokod te u Scratchu napisati program. Predaju se ukupno tri pojedinačne datoteke (dijagram toka (.doc. .docx ili .odt. pseudokod (.doc. .docx ili .odt) i program u Scratchu (.sb)) ili sve tri sažete u jednu saženu datoteku (.zip. .rar ili slično).

Tablica 90 prikazuje konstruktivno poravnanje za kolegij Programiranje.

Tablica 91. Konstruktivno poravnanje za kolegij Programiranje

Kompetencija na nivou studijskog programa	***Ishodi učenja kolegija***	***Sadržaj/način učenja***	***Procjena***	***ECTS***
Osposobljenost za cjeloživotno učenje novih informacijsko-komunikacijskih tehnologija. medija. programa i aplikacija. novih koncepcija učenja i poučavanja potpomognutih informacijsko-komunikacijskom tehnologijom te poznavanje programiranja;	Razumijevanje i primjena osnovnih tipova podataka. struktura podataka i algoritama. Razumijevanje i primjena osnovnih programskih struktura u strukturnom programiranju. Sposobnost samostalne izrada jednostavnijih programskih zadataka primjenjivih u odgoju i obrazovanju. Znanja i vještine u primjeni suvremenih razvojnih programskih okolina i programskih jezika za rano učenje programiranja.	U timovima od po tri studenta riješiti zadatak izrade edukativnog programa uz pomoć IKT-a	Samoprocjena i/ili vršnjačka procjena rješenja zadatka uz pomoć unaprijed definiranih kriterija i rubrike	20 sati 0.66 ECTS

Tablica 91 prikazuje rubriku s kriterijima i stupnjevima izvedbe za svaki promatrani kriterij pomoću koje se vršila procjena rješenja zadataka u okviru Programiranja.

Potpuna rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadataka u okviru Programiranja prikazana je u Tablici 92.

Tablica 92. Popis kriterija i raspona bodova za svaki pojedini kriterij za Programiranje

Kriterij	***Dijagram toka***	***Pseudokod***	***Program u Scratchu – definirani potrebni tipovi podataka***	***Program u Scratchu – jasnoća. razumljivost. jednostavnost. stil izvornog koda***	***Program u Scratchu – ispravnost rezultata***	***Program u Scratchu – ljubaznost prema korisniku***
Raspon bodova	0-2	0-2	0-2	0-2	0-2	0-2

Tablica 93. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Programiranje

Kriteriji ↓		***Stupnjevi izvedbe za svaki pojedini kriterij →***		
1.	***Dijagram toka***	*Nije napravljen ili ne odgovara zadatku*	*Djelomično odgovara zadatku ili su korišteni neodgovarajući simboli*	*U potpunosti odgovara zadatku*
		0 bodova	**1 bod**	**2 boda**
2.	***Pseudokod***	*Nije napravljen ili ne odgovara zadatku*	*Djelomično odgovara zadatku ili su nedosljedno korištene ključne riječi/naredbe*	*U potpunosti odgovara zadatku*
		0 bodova	**1 bod**	**2 boda**
3.	***Program u Scratchu – definirani potrebni tipovi podataka***	*Potrebne varijable uopće nisu odgovarajuće definirane*	*Potrebne varijable djelomično su odgovarajuće definirane*	*Potrebne varijable u potpunosti su odgovarajuće definirane.*
		0 bodova	**1 bod**	**2 boda**
4.	***Program u Scratchu – jasnoća. razumljivost. jednostavnost. stil izvornog koda***	*Izvorni kod programa je nejasan i/ili nerazumljiv*	*Izvorni kod programa djelomično je jasan i razumljiv*	*Izvorni kod programa u potpunosti je jasan i razumljiv*
		0 bodova	**1 bod**	**2 boda**
5.	***Program u Scratchu – ispravnost rezultata***	*Program ne radi ispravno ili uopće ne radi ono što je zadano*	*Program samo djelomično radi ispravno i ono što je zadano.*	*Program je u potpunosti ispravan i radi ono što je zadano.*
		0 bodova	**1 bod**	**2 boda**
6.	***Program u Scratchu – ljubaznost prema korisniku***	*Program uopće ne izvještava niti upućuje korisnika o potrebnim akcijama i rezultatima*	*Program djelomično izvještava i upućuje korisnika o potrebnim akcijama i rezultatima*	*Program u potpunosti izvještava i upućuje korisnika o potrebnim i akcijama i rezultatima*
		0 bodova	**1 bod**	**2 boda**

Uvod u baze podataka

Studenti su se samostalno podijelili u grupe od po četiri studenta. Rješavali su sljedeći zadatak:

> Zadatak: *Svakoj skupini studenata daje se zadatak izrade baze podataka na zadanu temu uz pomoć alata Microsoft Access do razine identificiranja entiteta. njihovog opisivanja potrebnim atributima. određivanja primarnih ključeva te definiranja odnosa između entiteta (tzv. Relationships).*
>
> *Potrebno je na zadanu temu (primjerice Dječji vrtić. Osnovna škola. Fakultet) identificirati entitete. opisati ih odgovarajućim atributima i odgovarajućim tipovima*

podataka. Entiteti trebaju imati određene primarne ključeve. Između entiteta potrebno je ostvariti odgovarajuće tipove odnosa.

Tablica 93 prikazuje konstruktivno poravnanje za kolegij Uvod u baze podataka.

Tablica 94. Konstruktivno poravnanje za kolegij Uvod u baze podataka

Kompetencija na nivou studijskog programa	***Ishodi učenja kolegija***	***Sadržaj/način učenja***	***Procjena***	***ECTS***
Stjecanje znanja i vještina za oblikovanje baza podataka i aplikacija primjenjivih u osnovnom obrazovanju.	Usvojena znanja i vještina u strukturiranju i organiziranju podataka. Usvojena znanja i vještine u projektiranju. oblikovanju i primjeni baza podataka i pripadajućih aplikacija u osnovnom obrazovanju.	U timovima od po tri studenta riješiti zadatak izrade baze podataka na zadanu temu.	Samoprocjena i/ili vršnjačka procjena rješenja zadatka uz pomoć unaprijed definiranih kriterija i rubrike	30 sati 1 ECTS

Tablica 94 prikazuje rubriku s kriterijima i stupnjevima izvedbe za svaki promatrani kriterij pomoću koje se vršila procjena rješenja zadataka u okviru Uvoda u baze podataka.

Potpuna rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadataka u okviru Uvoda u baze podataka prikazaan je u Tablici 95.

Tablica 95. Popis kriterija i raspona bodova za svaki pojedini kriterij za Uvod u baze podataka

Kriterij	***Identifikacija entiteta***	***Entiteti su opisani potrebnim atributima***	***Atributi imaju odgovarajući tip podataka i duljinu***	***Entiteti imaju definirane primarne ključeve***	***Između entiteta uspostavljeni su odnosi***
Raspon bodova	0-2	0-2	0-2	0-2	0-2

Tablica 96. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Uvod u baze podataka

Kriteriji ↓		***Stupnjevi izvedbe za svaki pojedini kriterij →***		
1.	***Identifikacija entiteta***	*Entiteti nisu odgovarajuće identificirani*	*Entiteti su većim dijelom odgovarajuće identificirani*	*Svi su entiteti u potpunosti identificirani*
		0 bodova	**1 bod**	**2 boda**
2.	***Entiteti su opisani potrebnim atributima***	*Entiteti uopće ili većim dijelom nisu opisani potrebnim atributima*	*Entiteti su većim dijelom opisani potrebnim atributima*	*Entiteti su u potpunosti opisani potrebnim atributima*
		0 bodova	**1 bod**	**2 boda**
3.	***Atributi imaju odgovarajući tip podataka i duljinu***	*Atributi uopće ili većim dijelom nemaju odgovarajući tip ni duljinu podataka*	*Atributi većim dijelom imaju odgovarajući tip i duljinu podataka*	*Atributi u potpunosti imaju odgovarajući tip i duljinu podataka*
		0 bodova	**1 bod**	**2 boda**
4.	***Entiteti imaju definirane primarne ključeve***	*Entiteti uopće ili većim dijelom nemaju označene odgovarajuće primarne ključeve*	*Entiteti većim dijelom imaju označene odgovarajuće primarne ključeve*	*Entiteti u potpunosti imaju označene odgovarajuće primarne ključeve*
		0 bodova	**1 bod**	**2 boda**
5.	***Između entiteta uspostavljeni su odnosi***	*Između entiteta uopće ili većim dijelom nisu uspostavljeni odgovarajući odnosi*	*Između entiteta većim su dijelom uspostavljeni odgovarajući odnosi*	*Između entiteta u potpunosti su uspostavljeni odgovarajući odnosi*
		0 bodova	**1 bod**	**2 boda**

Engleski jezik I

Studenti su se samostalno podijelili u grupe od po četiri studenta. Rješavali su sljedeći zadatak:

Zadatak: *Usporediti program preddiplomskog studija na kojem Vi studirate i program odgovarajućeg preddiplomskog studija Oxfordskog sveučilišta (službena stranica http://www.ox.ac.uk/).*

- *koje kolegije studenti mogu slušati/slušaju na prvoj godini.*
- *na koji način ih se ocjenjuje.*
- *kakvi su jezični zahtjevi za strane studente.*
- *koje su obrazovne kvalifikacije (službeni dokumenti) potrebni za upis studenata iz Hrvatske na Sveučilište u Oxfordu?*

Usporedbu promatranih studijskih programa ukratko opišite u jednom tekstualnom dokumentu (npr. Microsoft Office Word) u duljini od oko 600 riječi.

Tablica 96 prikazuje konstruktivno poravnanje za kolegij Engleski jezik I.

Tablica 97. Konstruktivno poravnanje za kolegij Engleski jezik I

Kompetencija na nivou studijskog programa	***Ishodi učenja kolegija***	***Sadržaj/način učenja***	***Procjena***	***ECTS***
Dvopredmetni preddiplomskog studij Hrvatskog jezika i književnosti Prosuditi važnost jezične norme *Dvopredmetni preddiplomski studij Povijesti* Pratiti stručnu literaturu na hrvatskom i stranom jeziku *Dvopredmetni preddiplomski studij Filozofije* Praćenje stručne i filozofijske literature na hrvatskom i stranom jeziku. *Dvopredmetni preddiplmoski studij Mađarskog jezika i književnosti* Jezična i književno-znanstvena kompetencija *Dvopredmetni preddiplomski studij Pedagogije* Pratiti stručnu literaturu na hrvatskom i stranom jeziku	Razlikovati opći leksik od akademskog. Prepoznati karakteristične leksičke i gramatičke strukture te rečenična vezna sredstva u akademskom diskursu. Upotrijebiti glagolska vremena obrađena nastavnim gradivom.	U skupinama od po četiri studenta analizirati odgovarajući preddiplomski studija Oxfordskog sveučilišta te istaknuti sličnosti i razlike sa njihovim studijskim programom	Samoprocjena i/ili vršnjačka procjena rješenja zadatka uz pomoć unaprijed definiranih kriterija i rubrike	15 sati 0.5 ECTS

Tablica 97 prikazuje rubriku s kriterijima i stupnjevima izvedbe za svaki promatrani kriterij pomoću koje se vršila procjena rješenja zadataka u okviru Engleskog jezika I.

Tablica 98. Popis kriterija i raspona bodova za svaki pojedini kriterij za Engleski jezik I

Kriterij	***Programi preddiplomskih studija***	***Kolegiji na prvoj studijskoj godini***	***Metode ocjenjivanja***	***Studiranje stranih studenata***	***Obrazovne Kvalifika-cije***	***Upotreba odgovarajućih izraza (collocations)***	***Gramatika***
Raspon bodova	0-2	0-3	0-3	0-2	0-2	0-2	0-2

Potpuna rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadataka u okviru Engleskog jezika I prikazana je u Tablici 98.

Tablica 99. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Engleski jezik I

Kriteriji ↓		***Stupnjevi izvedbe za svaki pojedini kriterij →***			
1.	***Programi preddiplomskih studija***	*U opisu nije naveden ni preddiplomski studijski program studenata na kojem studiraju niti odgovarajući preddiplomski studijski program na Oxfordu.*	*U opisu je naveden preddiplomski studijski program na kojem studenti trenutno studiraju. ali odabrani preddiplomski studijski program na Oxfordu nije odgovarajući.*	*U opisu je naveden preddiplomski studijski program na kojem studenti trenutno studiraju i odabrani preddiplomski studijski program na Oxfordu je odgovarajući*	
		0 bodova	**1 bod**	**2 boda**	
2.	***Kolegiji na prvoj studijskoj godini***	*U opisu uopće nisu navedeni kolegiji koje studenti mogu slušati/slušaju na prvoj godini*	*U opisu su nabrojani <u>samo neki</u> kolegiji koje studenti mogu slušati/slušaju na prvoj godini*	*U opisu su nabrojani <u>svi</u> kolegiji koje studenti mogu slušati/slušaju na prvoj godini*	*Nabrojani su svi kolegiji koje studenti mogu slušati/slušaju na prvoj godini te su također međusobno i uspoređeni.*
		0 bodova	**1 bod**	**2 boda**	**3 boda**
3.	***Metode ocjenjivanja***	*Metode ocjenjivanja uopće nisu opisane*	*Nisu nabrojane sve metode ocjenjivanja već samo neke.* *ILI* *Nabrojane su samo metode ocjenjivanja za jedan preddiplomski studijski program dok za drugi nisu.*	*Metode su ocjenjivanja za oba studijska programa samo nabrojane.*	*Metode su ocjenjivanja za oba studijska programa nabrojane i uspoređene u odnosu na kolegije i studijske programe.*
		0 bodova	**1 bod**	**2 boda**	**3 boda**
4.	***Studiranje stranih studenata***	*U opisu nisu navedene mogućnosti studiranja i jezični zahtjevi za strane studente.*	*Nepotpuno su opisane mogućnosti studiranja i jezični zahtjevi za strane studente.*	*Mogućnosti su studiranja i jezični zahtjevi za strane studente detaljno i točno opisani.*	
		0 bodova	**1 bod**	**2 boda**	
5.	***Obrazovne kvalifikacije***	*U opisu nisu navedene i pojašnjene potrebne obrazovne kvalifikacije hrvatskih studenata za upis na Oxford*	*Potrebne su obrazovne kvalifikacije hrvatskih studenata za upis na Oxford nepotpuno navedene i nedovoljno objašnjene*	*Potrebne su obrazovne kvalifikacije hrvatskih studenata za upis na Oxford detaljno i točno opisane.*	
		0 bodova	**1 bod**	**2 boda**	
6.	***Upotreba odgovarajućih izraza (collocations)***	*Jezični su izrazi u velikoj mjeri krivo upotrijebljeni (više od tri izraza).*	*Poneki su jezični izrazi krivo upotrijebljeni (do tri izraza)*	*Jezični su izrazi u opisu pravilno upotrijebljeni*	
		0 bodova	**1 bod**	**2 boda**	
7.	***Gramatika***	*U opisu postoje mnoge gramatičke pogreške.*	*U opisu postoji nekoliko gramatičkih pogrešaka.*	*Opisani je tekst gramatički točan.*	
		0 bodova	**1 bod**	**2 boda**	

PRILOG III

Ukratko o istraživanju i njegovoj provedbi

Područje je istraživanja samoprocjena studenata o napretku njihovog tehnološko pedagoško predmetnog znanja (primjena tehnologije u nastavi) nakon sudjelovanja u procesima vršnjačke kriterijske procjene i samoprocjene rješenja problemskog zadatka u okviru online suradničkog učenja. kao i utjecaj spomenutih procesa na razvoj pristupa učenju u promatranom kontekstu (pristup učenju promatramo kroz površinski. dubinski i strategijski pristup). Kriterijska procjena provodi se pomoću unaprijed definirane rubrike sa stupnjevima izvedbe za svaki pojedini kriterij. Studentima je rubrika s kriterijima dostupna tijekom cijelog postupka rješavanja zadatka.

Na početku istraživanju studenti popunjavaju upitnike te se dijele u skupine. U skupinama rješavaju zadatak nakon čega pristupaju vršnjačkoj procjeni rješenja drugih studenata i/ili samoprocjeni vlastitog rješenja danog problema.

Nakon procjene ponovno se popunjavaju upitnici te se daje mišljenje o samom procesu rješavanja zadaće i sudjelovanju u postupku ocjenjivanja. Cijeli opisani postupak provodi se putem sustava za upravljanje učenjem u vidu različitih aktivnosti.

Najznačajnija je aktivnost radionica (s nazivom *Zadatak*) koja se sastoji od nekoliko faza (uvod. predaja. procjena. evaluacija). Tijekom uvodne faze radionice objašnjen je zadatak koji će se rješavati nakon čega slijedi faza predaje rješenja zadatka. Nakon faze predaje rješenja započinje faza procjene nakon čega slijedi faza evaluacije. Svakom je studentu bilo dodijeljeno jedno rješenje neke druge skupine i/ili rješenje vlastite skupine da ga procjeni. Postupak je procjene u potpunosti bio anoniman. studenti nisu znali čiju zadaću procjenjuju. ni tko je procjenjivao njihovu zadaću. Aktivnost je radionica predstavljena jednom poveznicom unutar kolegija. dok se njezin sadržaj mijenja ovisno o fazi u kojoj se trenutno nalazi. Promjenu faza (početnih i krajnjih datuma) mogli su pratiti pomoću tablice koja se prikazala kada su otvorili radionicu. Trenutna faza u kojoj se radionica nalazila bila je označena zelenom bojom. Svaka faza uključivala je i detaljno pojašnjenje što se tijekom te faze trebalo napraviti.

U okviru istraživanja postavljen je i forum putem kojeg su studenti biti obaviješteni o tijeku istraživanja te datumima kada započinju ili završavaju pojedine aktivnosti. Također. forum je

služio i za informiranje o samom istraživanju. eventualnim nejasnoćama ili problemima s aktivnostima na Moodlu.

Ukoliko su imali pitanja u vezi istraživanja. slobodno su se mogli javiti putem foruma ili na elektroničku poštu kdobi@foozos.hr.

U tablici na sljedećoj stranici su navedeni koraci istraživanja i aktivnosti na Moodlu pomoću kojih su se navedeni koraci realizirali.

Tablica 100. Koraci istraživanja i odgovarajuće aktivnosti na Moodlu

	Korak u istraživanju	Moodle aktivnost
1.	Studenti popunjavaju upitnike o pristupu učenju i primjeni tehnologije u nastavi.	Upitnik
2.	• Formiranje skupina studenata (ovisno o broju studenata u studijskoj grupi) • Zadavanje zadatka i prikaz kriterija procjene (dovoljno je da mogu vidjeti samo kriterije. bez stupnjeva).	Zadaća s online tekstom Radionica (Uvodna faza)
3.	Predaja rješenja zadatka. Svaki student iz skupine treba predati rješenje. Predana rješenja unutar skupine trebaju biti jednaka.	Radionica (Faza predaje)
4.	Procjenjivanje zadaća.	Radionica (Faza procjene – svaki student kada uđe u radionicu u ovoj fazi vidi zadaće koje su mu dodijeljene za procjenu)
5.	• Davanje mišljenja o ovoj zadaći i ovakvom načinu procjene. • Studenti ponovno popunjavaju upitnike o pristupu učenju i primjeni tehnologije u nastavi.	Zadaća s online tekstom Upitnik

PRILOG IV

Primjer

Na primjeru rješavanja zadatka u grupama od po četiri studenta rješenja zadatka procjenjivat će se vršnjačkom procjenom tako da svaki student procijeni jedan rad svog vršnjaka. Na taj će način svaki rad biti procijenjen od strane četiriju studenata. Procjena se vrši uz pomoć rubrike s pet kriterija. rang svakog kriterija prikazan je u Tablici 99.

Tablica 100 prikazuje dodijeljene bodove za promatrani rad od strane četiri procjenitelja (studenta).

Tablica 101. Primjer računanja pouzdanosti - rang kriterija

Kriterij	**Rang**
C_1	[0.2]
C_2	[0.3]
C_3	[0.3]
C_4	[0.2]
C_5	[0.2]

Tablica 102. Primjer za računanje pouzdanosti - procjene po svakom pojedinom kriteriju

	C_1	C_2	C_3	C_4	C_5	$\sum$
S_1	1	2	3	2	2	10
S_2	2	2	2	2	2	10
S_3	2	2	2	2	2	10
S_4	2	2	1	2	2	9

Ako promotrimo procjenu S_1 i S_4. vidimo da se one. po ukupnom broju bodova. razlikuju za 1 bod (Δ=1). Ukoliko razliku u procjenama gledamo po svakom pojedinom kriteriju (taxicab

udaljenost). tada je razlika u procjenama jednaka 3 ($d_1(S_1.S_2) = 3$). Ukoliko tako dobivenu udaljenost normiramo. dobijemo vrijednost u rasponu [0.1].

$$r = (2.3.3.2.2) \rightarrow |r| = 12$$

$$|d_1(S_1.S_4)| = \frac{d_1(S_1.S_4)}{|r|} = \frac{3}{12} = 0.25$$

Ukoliko procjenu vrše četiri studenta. tada postoji šest različitih parova procjena koji su navedeni ispod:

$$d_1(S_1.S_2) = |2-1| + |2-2| + |2-3| + |2-2| + |2-2| = 1+0+1+0+0 = 2$$

$$|d_1(S_1.S_2)| = \frac{d_1(S_1.S_2)}{|r|} = \frac{2}{12} = 0.17$$

$$d_1(S_1.S_3) = |2-1| + |2-2| + |2-3| + |2-2| + |2-2| = 1+0+1+0+0 = 2$$

$$|d_1(S_1.S_3)| = \frac{d_1(S_1.S_3)}{|r|} = \frac{2}{12} = 0.17$$

$$d_1(S_1.S_4) = |2-1| + |2-2| + |1-3| + |2-2| + |2-2| = 1+0+2+0+0 = 3$$

$$|d_1(S_1.S_4)| = \frac{d_1(S_1.S_4)}{|r|} = \frac{3}{12} = 0.25$$

$$d_1(S_2.S_3) = |2-2| + |2-2| + |2-2| + |2-2| + |2-2| = 0+0+0+0+0 = 0$$

$$|d_1(S_2.S_3)| = \frac{d_1(S_2.S_3)}{|r|} = \frac{0}{12} = 0$$

$$d_1(S_2.S_4) = |2-2| + |2-2| + |1-2| + |2-2| + |2-2| = 0+0+1+0+0 = 1$$

$$|d_1(S_2.S_4)| = \frac{d_1(S_2.S_4)}{|r|} = \frac{1}{12} = 0.08$$

$$d_1(S_3.S_4) = |2-2| + |2-2| + |1-2| + |2-2| + |2-2| = 0+0+1+0+0 = 1$$

$$|d_1(S_3.S_4)| = \frac{d_1(S_3.S_4)}{|r|} = \frac{1}{12} = 0.08$$

Skup je procjena promatrane zadaće sljedeći: $\{0.25.\ 0.17.\ 0.17.\ 0.08.\ 0.25.\ 0.17\}$. Dijametar skupa procjena promatrane zadaće je

$$diam\ S = \max\{0.17.\,0.17.\,0.25.\,0.\,0.08.\,0.08\} = 0.25$$

što sugerira nepouzdanu procjenu. Međutim. postupak procesa procjenjivanja obuhvaća i korak eliminacije outliera među procjenama. Za ovaj konkretan slučaj kritični N će biti 3 što znači da trebamo pronaći barem tri procjene čiji dijametar će biti manji od $2e$. odnosno 0.2.

$$S' = \{S_1.S_2.S_3\}$$

$$diam\ S' = \max\{0.17, 0.17, 0\} = 0.17$$

To znači da se procjene S_1. S_2 i S_3 smatraju pouzdanima i na temelju njih se računa konačna ocjena.

PRILOG V

Zadaci zadani u okviru Pilot istraživanja:

ZADATAK 1

Ovaj problem rješavaju timovi čija oznaka završava brojem 1 (T-1-1. T-2-1. T-3-1. T-4-1. T-5-1. T-6-1. T-7-1. T-8-1. T-9-1. T-10-1. T-11-1. T-12-1. T-13-1. T-14-1. T-15-1)

U dječjem vrtiću Bubamara djeca iz skupine Ježići imala su zadatak zajedno osmisliti dobro čudovište iz bajke te su zajedno s odgajateljicom osmislili igrokaz na istu temu. Kako su u dani zadatak uložili puno truda odlučili su organizirati predstavu za roditelje na kojoj će odglumiti igrokaz. Predstava se treba održati 9. lipnja 2015. g. s početkom u 17 sati u dvorani vrtića i djecu je posebno veselilo što će upravo oni biti glumci u predstavi. Odgajateljica je odlučila obavijestiti roditelje o predstavi kako bi bila sigurna da su svi roditelji dobili potrebne informacije o samoj predstavi. vremenu i mjestu njezinog održavanja kao i glumcima koji u predstavi glume. Odlučila je da je plakat najbolji način obavijesti. Možeš li joj pomoći da osmisli zanimljiv i originalan način na koji obavijestiti roditelje. ali tako da budu zastupljene sve prethodno navedene informacije?

ZADATAK 2

Ovaj problem rješavaju timovi čija oznaka završava brojem 2 (T-1-2. T-2-2. T-3-2. T-4-2. T-5-2. T-6-2. T-7-2. T-8-2. T-9-2. T-10-2. T-11-2. T-12-2. T-13-2. T-14-2. T-15-2)

Udruga Stvarajmo zajedno. koja okuplja simpatizere i znatiželjnike likovne umjetnosti. organizirala je likovnu radionicu na temu "Čine li brkovi čovjeka? " na kojoj su polaznici uljem na platnu slikali auto-portrete ukrašene brkovima različitih veličina i boja. Radionica je rezultirala lijepim i kreativnim uradcima pa su se polaznici dogovorili kako će održati izložbu na kojoj će pokazati svoje radove. Izložba se treba održati 9. lipnja 2015. g. s početkom u 17 sati u prostorijama Udruge. Kako bi bili sigurni da će sve potrebne informacije o samoj izložbi. vremenu i mjestu njezinog postava. kao i autorima izloženih slika biti valjano prenesene široj javnosti. odlučili su promovirati izložbu izradom brošure. Možeš li im pomoći da osmisle zanimljiv i originalan način na koji će

obavijestiti javnost. ali takav da njemu budu zastupljene sve prethodno navedene informacije?

ZADATAK 3

Ovaj problem rješavaju timovi čija oznaka završava brojem 3 (T-1-3. T-2-3. T-3-3. T-4-3. T-5-3. T-6-3. T-7-3. T-8-3. T-9-3. T-10-3. T-11-3. T-12-3. T-13-3. T-14-3. T-15-3)

Tvrtka specijalizirana za razvoj hardvera osmislila je novi dizajn tipkovnice za slijepe i slabovidne osobe. Nakon provedenog testiranja istaknute su sljedeće prednosti proizvoda:

- *mehanički prekidači ispod tipki (pruža puno bolji osjećaj tijekom tipkanja).*
- *duboki hod tipki (produžava trajnost tipkovnice).*
- *laserski gravirani znakovi na tipkama (dugotrajnost i bolja opipljivost).*
- *ugrađeni produžni za slušalice (za okruženja u kojima je nezgodno slušati upute putem zvučnika).*
- *dodatne tipke za pokretanje aplikacija (za lakše snalaženje).*

Tvrtka želi ponuditi proizvod ustanovama i udrugama koje okupljaju slijepe i slabovidne osobe te su odlučili da je najbolji način za promociju web stranica. Možeš li im pomoći da osmisle zanimljiv i originalan način na koji će obavijestiti skupine od interesa. ali takav da na njemu budu zastupljene sve prethodno navedene informacije?

ZADATAK 4

Ovaj problem rješavaju timovi čija oznaka završava brojem 4 (T-1-4. T-2-4. T-3-4. T-4-4. T-5-4. T-6-4. T-7-4. T-8-4. T-9-4. T-10-4. T-11-4. T-12-4. T-13-4. T-14-4. T-15-4)

Otvoreno učilište poznato po kvalitetnim pripremama za Državnu maturu osmislilo je novi program priprema. Njihovim programom obuhvaćena su tri osnovna predmeta iz kojih se polaže državna matura. Prednost njihovog programa je u trajanju priprema. vrhunskim predavačima i fleksibilnosti vremena održavanja priprema. Žele izraditi letak kojim bi privukli nove polaznike. Možeš li im pomoći da osmisle zanimljiv i originalan

način na koji će obavijestiti javnost. ali takav da budu zastupljene sve prethodno navedene informacije?

ZADATAK 5

Ovaj problem rješavaju timovi čija oznaka završava brojem 5 (T-1-5. T-2-5. T-3-5. T-4-5. T-5-5. T-6-5. T-7-5. T-8-5. T-9-5. T-10-5. T-11-5. T-12-5. T-13-5. T-14-5. T-15-5)

Visoko učilište Stjepana Radića odlučilo je promovirati vlastiti online diplomski studij Informacijska medicina. Vrijednost studija prema ECTS bodovima je 120 ECTS-a. a samo učilište posjeduje međunarodni ESG certifikat sustava osiguranja kvalitete u obrazovanju. Najveće prednosti novog studija koje ističu su: međunarodno priznanje studija. izvođenje kolegija u turnusima. povratna informacija nastavnika unutar 24h te fleksibilno vrijeme održavanja ispita. Žele izraditi brošuru kojom bi privukli nove polaznike. Možeš li im pomoći da osmisle zanimljiv i originalan način na koji će obavijestiti javnost. ali takav da budu zastupljene sve prethodno navedene informacije?

PRILOG VI

Tablica 103. Rubrika s kriterijima procjene i stupnjevima izvedbe za svaki pojedini kriterij pomoću koje se vršila procjena rješenja zadatka na kolegiju Oblikovanje teksta i slike tijekom Pilot istraživanja

<table>
<tr><th colspan="2">Kriterij ↓</th><th colspan="4">Stupnjevi izvedbe za svaki kriterij →</th></tr>
<tr><td rowspan="2">1.</td><td rowspan="2">Svrha i prilagođenost ciljanim korisnicima</td><td colspan="2">Iz rješenja se ne može razaznati koja je tema/svrha i koje informacije trebaju biti pružene ciljanim korisnicima</td><td colspan="2">Tema/svrha je jasna. ali informacije koje rješenje treba pružiti nejasne su i teže uočljive ciljanim korisnicima</td><td colspan="2">Tema/svrha je jasna i logično prikazana. rješenje sadrži sve potrebne informacije koje ciljani korisnici mogu jasno uočiti</td></tr>
<tr><td colspan="2">0 bodova</td><td colspan="2">1 bod</td><td colspan="2">2 boda</td></tr>
<tr><td rowspan="2">2.</td><td rowspan="2">Kompozicija. dizajn. raspored elemenata</td><td colspan="2">Kompozicija je konfuzna i nema logičnosti u korištenju i rasporedu elemenata; principi dizajna (kontrast. ponavljanje. poravnanje. blizina) nisu nimalo poštovani</td><td colspan="2">Kompozicija je konfuzna i nema logičnosti u rasporedu elemenata. ali svi potrebni elementi nalaze se na rješenju; principi dizajna (kontrast. ponavljanje. poravnanje. blizina) su sporadično poštovani</td><td colspan="2">Kompozicija je logična i uočljiva. ali nedostaju pojedini elementi; principi dizajna (kontrast. ponavljanje. poravnanje. blizina) su velikim dijelom poštovani</td><td colspan="2">Kompozicija je jasna i svi elementi su navedeni na rješenju; principi dizajna (kontrast. ponavljanje. poravnanje. blizina) su u potpunosti poštovani</td></tr>
<tr><td colspan="2">0 bodova</td><td colspan="2">1 bod</td><td colspan="2">2 boda</td><td colspan="2">3 boda</td></tr>
<tr><td rowspan="2">3.</td><td rowspan="2">Odabir boja</td><td colspan="2">Kombinacija je odabranih boja naporna i čini elemente sredstva promocije nečitljivima</td><td colspan="2">Kombinacija je odabranih boja ugodna. ali kontrast je nedovoljan i elementi sredstva promocije su nečitljivi</td><td colspan="2">Kombinacija je odabranih boja ugodna i svi elementi sredstva promocije su jasno uočljivi i čitljivi</td></tr>
<tr><td colspan="2">0 bodova</td><td colspan="2">1 bod</td><td colspan="2">2 boda</td></tr>
<tr><td>4.</td><td>Tehnička realizacija</td><td>Elementi su rješenja (tekst. slike. ilustracije. korištene boje....) tehnički loše riješeni</td><td>Elementi su rješenja (tekst. slike. ilustracije. korištene boje....) tehnički dobro riješeni. ali nisu prilagođeni svrsi/mediju</td><td>Elementi su rješenja (tekst. slike. ilustracije. korištene boje....) tehnički vrlo dobro riješeni i prilagođeni svrsi/mediju</td><td>Elementi su rješenja (tekst. slike. ilustracije. korištene boje....) tehnički vrlo dobro riješeni. u potpunosti prilagođeni svrsi/mediju i kreativno upotrijebljeni</td></tr>
</table>

		0 bodova	1 bod	2 boda	3 boda
5.	***Struktura prezentacije***	*Tijekom prezentacije nije bilo jasno što je uvod u temu. glavni dio prezentacije i koji je konačan zaključak*	*Tijekom prezentacije bilo je moguće razabrati strukturu prezentacije. ali pojedinačni dijelovi nisu bili dovoljno istaknuti*	*Tijekom prezentacije bilo je potpuno jasno što je uvod u temu prezentacije. središnji dio prezentacije i konačni zaključak*	
		0 bodova	**1 bod**	**2 boda**	
6.	***Pridržavanje vremenskog ograničenja***	*Prezentacija je trajala puno dulje/puno kraće od određenog vremena*	*Prezentacija je trajala malo dulje/ malo kraće od preporučenog vremena. ali u prihvatljivim okvirima*	*Tema je prezentirana unutar preporučenog vremenskog okvira*	
		0 bodova	**1 bod**	**2 boda**	
7.	***Interakcija s publikom***	*Nije ostvarena interakcija sa publikom*	*Pokušala se ostvariti interakcija sa publikom. ali neuspješno*	*Interakcija sa publikom je uspješno ostvarena*	
		0 bodova	**1 bod**	**2 boda**	

PRILOG VII

UPITNIK STUDENTIMA - O PRISTUPIMA UČENJU

Hvala Vam što ste odvojili vrijeme za ispunjavanje ovog Upitnika. Molim Vas da na svako pitanje odgovorite najbolje što znate. Vaši brižni i iskreni odgovori bit će vrlo cijenjeni. Vaše ime ili identifikacijski broj niti u jednom trenutku neće bit povezani s Vašim odgovorima. Vaši odgovori bit će strogo povjerljivi i neće utjecati na konačnu ocjenu iz kolegija.

Upitnik se sastoji od 66 izjava. Za svaku izjavu odaberite tvrdnju koja odgovara Vašem mišljenju o pojedinoj izjavi. Moguće tvrdnje su: *„Uopće se ne slažem“*. *“Ne slažem se“*. *„Niti se slažem niti se ne slažem“*. *„Slažem se“*. *„U potpunosti se slažem“* . Molim Vas da pokušate što manje koristiti tvrdnju *„Niti se slažem niti se ne slažem*“. osim ukoliko baš nije nužno. ili ako izjavu ne možete primijeniti na trenutni nastavni zadatak.

	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem
Uspijevam ostvariti uvjete za učenje koji mi olakšavaju nastavak rada.	○	○	○	○	○
Tijekom rada na zadatku. cijelo vrijeme razmišljam kako najbolje impresionirati ocjenjivača.	○	○	○	○	○
Često se pitam je li ovo što radim vrijedno truda.	○	○	○	○	○
Obično želim razumjeti ono što trebam naučiti.	○	○	○	○	○
Pažljivo organiziram vrijeme za učenje kako bih ga najbolje iskoristio.	○	○	○	○	○
Smatram da se moram koncentrirati na čisto memoriranje velikog dijela gradiva.	○	○	○	○	○
Pažljivo provjeravam rad na kojem sam radio kako bih provjerio njegovu razumljivost i smislenost.	○	○	○	○	○
Često imam osjećaj da se *utapam* u količini gradiva koje trebam savladati.	○	○	○	○	○

	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem
Pažljivo promatram dokaze i pokušavam stvoriti zaključak o onome o čemu učim.	○	○	○	○	○
Važan mi je osjećaj da dajem sve od sebe tijekom kolegija.	○	○	○	○	○
Ideje na koje naiđem pokušavam povezati s idejama iz drugih kolegija ili predmeta.	○	○	○	○	○
Nemam običaj čitati puno više od onoga što je potrebno za prolaz.	○	○	○	○	○
Često primijetim da razmišljam o idejama s nastave dok radim neke druge stvari.	○	○	○	○	○
Mislim da sam prilično sistematičan/sistematična i organiziran/organizirana tijekom ponavljanja za ispit.	○	○	○	○	○
Pažljivo proučavam komentare nastavnika kako bih idući put dobio bolju ocjenu.	○	○	○	○	○
Nema mnogo toga što smatram zanimljivim ili važnim.	○	○	○	○	○
Tijekom čitanja članka ili knjige. pokušavam shvatiti što je autor mislio.	○	○	○	○	○
Spreman sam za svaki rad.	○	○	○	○	○
Malo onoga što učim ima smisla. sve mi djeluje nepovezano.	○	○	○	○	○
Razmišljam o tome što želim ostvariti na kolegiju kako bih ostao/ostala usmjeren/usmjerena tijekom učenja.	○	○	○	○	○
Kada radim na novoj temi. pokušavam zamisliti koje se sve ideje uklapaju zajedno.	○	○	○	○	○
Često se brinem hoću li se uopće moći u pravoj mjeri nositi s radom.	○	○	○	○	○
Često preispitujem stvari koje čujem na predavanjima ili koje pročitam u knjigama.	○	○	○	○	○
Osjećaj dobroga napretka pomaže mi da uložim više napora u posao.	○	○	○	○	○

	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem
Koncentriram se na učenje samo onoliko koliko mi je potrebno da prođem ispit.	○	○	○	○	○
Smatram da učenje akademskih tema ponekad može biti prilično uzbudljivo.	○	○	○	○	○
Dobar sam u izvršavanju dodatnih zadatka koji se temelje na literaturi koju je predložio nastavnik.	○	○	○	○	○
Razmišljam o tome tko će ocjenjivati zadatak i na što će najvjerojatnije obraćati pozornost.	○	○	○	○	○
Gledajući unatrag. često se pitam zašto sam odlučio/odlučila doći ovamo.	○	○	○	○	○
Tijekom učenja. s vremena na vrijeme napravim pauzu kako bih razmislio/razmislila što iz toga pokušavam naučiti.	○	○	○	○	○
Redovito radim tijekom polugodišta ili semestra. radije nego da ostavim posao za zadnju minutu.	○	○	○	○	○
Nisam baš siguran/sigurna što je važno na predavanjima pa pokušavam zapisati sve što mogu.	○	○	○	○	○
Ideje u knjigama. člancima ili e-materijalima često me potaknu na dugotrajna razmišljanja.	○	○	○	○	○
Prije nego počnem raditi na zadatku ili ispitnom pitanju razmislim kako ga riješiti.	○	○	○	○	○
Često paničarim ukoliko zaostanem s poslom.	○	○	○	○	○
Tijekom čitanja pažljivo pregledavam detalje kako bih uvidio po čemu se uklapaju u temu.	○	○	○	○	○
Kada odlučim dobro naučiti gradivo ulažem puno napora u učenje.	○	○	○	○	○
Pažljivo usmjeravam učenje na ono što se čini obveznim i važnim za zadatak ili ispit.	○	○	○	○	○
Neke od ideja do kojih sam došao slušajući nastavu zaista su privukle moju pozornost.	○	○	○	○	○
Obično unaprijed planiram rad vikendom. na papiru ili u mislima.	○	○	○	○	○

	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem
Pozorno pratim što nastavnik smatra važnim i koncentriram se na to.	○	○	○	○	○
Nisam zainteresiran za ovaj predmet. ali imam druge razloge zašto ga pohađam.	○	○	○	○	○
Prije rješavanja problema ili zadatka. prvo pokušam shvatiti što je u njegovoj pozadini.	○	○	○	○	○
Uglavnom dobro iskoristim svoje vrijeme tijekom dana.	○	○	○	○	○
Često imam problema pronaći smisao u onome što trebam zapamtiti. .	○	○	○	○	○
Volim se poigravati vlastitim idejama. čak i kada to nikamo ne vodi.	○	○	○	○	○
Kada završim dio posla. provjeravam kako bih bio siguran da odgovara zahtjevima.	○	○	○	○	○
Često ležim budan brinući se o poslu za koji mislim da neću moći napraviti.	○	○	○	○	○
Važno mi je moći pratiti argumente ili vidjeti razlog koji je u pozadini.	○	○	○	○	○
Uopće mi nije teško motivirati se.	○	○	○	○	○
Volim da mi se točno kaže što da učinim u zadatku.	○	○	○	○	○
Ponekad se „*navučem*“ na akademske teme i osjećam da bih volio nastaviti proučavati ih.	○	○	○	○	○
Pažljivo razmatram zadani problem i pokušam pronaći vlastitu strategiju njegovog rješavanja.	○	○	○	○	○
Tijekom rješavanja problema i zadataka pokušavam upotrijebiti ideje i teoriju naučenu u ovom i ostalim kolegijima.	○	○	○	○	○
Ponekad se uhvatim da oko sebe tražim probleme koje bih riješio uz pomoć teorije i vještina koje sam stekao tijekom učenja.	○	○	○	○	○
Rad na problemima i zadacima inspirira me za istraživanje novih ideja i izvora.	○	○	○	○	○

	Uopće ne se slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem
Rješavanje problema ne nagrađuje se dovoljnim brojem bodova.	○	○	○	○	○
Frustrira me kada me traže da riješim problem ili složeni zadatak jer ne mogu isplanirati vrijeme koje ću utrošiti na njegovo rješavanje.	○	○	○	○	○
Smatram da je rad na problemima i zadacima koristan za moje učenje i profesionalni razvoj.	○	○	○	○	○
Teško mi je objasniti vlastitu strategiju rješavanja problema i njegove rezultate.	○	○	○	○	○
Volim raspraviti problem s kolegama/nastavnicima prije nego odredim vlastitu strategiju.	○	○	○	○	○
Uspoređujem vlastitu strategiju rješavanja problema sa strategijama drugih.	○	○	○	○	○
Važno mi je da je rješenje danog problema ili složenog zadatka kreativno.	○	○	○	○	○
Rješavanje problema i ostalih složenih zadataka mi je vrlo stresno.	○	○	○	○	○
Rješavanje problema često me vodi do nekoliko različitih rješenja.	○	○	○	○	○
Teško mi je fokusirati se na zadani zadatak ako ne vidim osobni interes u njemu	○	○	○	○	○

PRILOG VIII

UPITNIK SAMOPROCJENE ZNANJA O PRIMJENI TEHNOLOGIJE U NASTAVI

Termin *tehnologija* ima široko značenje. Za potrebe ovog Upitnika. tehnologija se odnosi na digitalnu tehnologiju/tehnologije i predstavlja digitalna sredstva koja upotrebljavamo u nastavi (računala. prijenosna računala. mobitele. tablete. interaktivne pametne ploče. različite programe itd.).

	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem
Uporaba tehnologije					
Znam riješiti tehničke probleme s kojima se suočavam.	◯	◯	◯	◯	◯
Lako svladavam tehnologiju.	◯	◯	◯	◯	◯
Držim korak s važnim novim tehnologijama.	◯	◯	◯	◯	◯
Često se poigravam tehnologijom.	◯	◯	◯	◯	◯
Znam mnogo o različitim tehnologijama.	◯	◯	◯	◯	◯
Posjedujem tehničke vještine potrebne za upotrebu tehnologije.	◯	◯	◯	◯	◯
Imao/imala sam dovoljno prilika za rad s različitim tehnologijama.	◯	◯	◯	◯	◯
Poznavanje sadržaja					
Matematika					
Posjedujem dovoljno znanja iz matematike.	◯	◯	◯	◯	◯
Mogu upotrebljavati matematički način razmišljanja.	◯	◯	◯	◯	◯
Vlastito razumijevanje matematike razvijam različitim strategijama i na različite načine.	◯	◯	◯	◯	◯
Društvene znanosti					
Posjedujem dovoljno znanja iz društvenih znanosti.	◯	◯	◯	◯	◯
Mogu koristiti povijesni način razmišljanja.	◯	◯	◯	◯	◯
Vlastito razumijevanje društvenih znanosti razvijam različitim strategijama i na različite načine.	◯	◯	◯	◯	◯
Znanost					
Posjedujem dovoljno znanja iz znanosti.	◯	◯	◯	◯	◯
Mogu koristiti znanstveni način razmišljanja.	◯	◯	◯	◯	◯
Vlastito razumijevanje znanosti razvijam različitim strategijama i na različite načine.	◯	◯	◯	◯	◯
Pismenost					
Posjedujem dovoljno znanja iz pismenosti.	◯	◯	◯	◯	◯
Mogu koristiti književni način razmišljanja.	◯	◯	◯	◯	◯

	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem
Vlastito razumijevanje pismenosti razvijam različitim strategijama i na različite načine.	◯	◯	◯	◯	◯
Pedagoško znanje					
Znam kako vrjednovati postignuća učenika u razredu.	◯	◯	◯	◯	◯
Prilagođavam poučavanje onome što učenici trenutno razumiju ili ne razumiju.	◯	◯	◯	◯	◯
Prilagođavam stil poučavanja različitim učenicima.	◯	◯	◯	◯	◯
Znam vrjednovati znanje učenika na različite načine.	◯	◯	◯	◯	◯
Koristim široki raspon pristupa poučavanju ovisno o razrednim uvjetima.	◯	◯	◯	◯	◯
Upoznat/upoznata sam s uobičajenim učeničkim razumijevanjem i zabludama.	◯	◯	◯	◯	◯
Znam kako organizirati i upravljati razredom.	◯	◯	◯	◯	◯
Sadržajno znanje u pedagoškom kontekstu					
Odabirem efektivne načine poučavanja u svrhu usmjeravanja razmišljanja i učenja učenika u matematici.	◯	◯	◯	◯	◯
Odabirem efektivne načine poučavanja u svrhu usmjeravanja razmišljanja i učenja učenika u društvenim znanostima.	◯	◯	◯	◯	◯
Odabirem efektivne načine poučavanja u svrhu usmjeravanja razmišljanja i učenja učenika u znanosti.	◯	◯	◯	◯	◯
Odabirem efektivne načine poučavanja u svrhu usmjeravanja razmišljanja i učenja učenika u pismenosti.	◯	◯	◯	◯	◯
Tehnološka znanja u kontekstu sadržaja					
Znam koje tehnologije mogu upotrebljavati kako bih osigurao razumijevanje i primjenu matematike.	◯	◯	◯	◯	◯
Znam koje tehnologije mogu upotrebljavati kako bih osigurao razumijevanje i primjenu društvenih znanosti.	◯	◯	◯	◯	◯
Znam koje tehnologije mogu upotrebljavati kako bih osigurao razumijevanje i primjenu znanosti.	◯	◯	◯	◯	◯
Znam koje tehnologije mogu upotrebljavati kako bih osigurao razumijevanje i primjenu pismenosti.	◯	◯	◯	◯	◯
Tehnološka znanja u pedagoškom kontekstu					
Mogu izabrati tehnologiju koja će unaprijediti poučavanje tijekom nastavnog sata.	◯	◯	◯	◯	◯
Mogu izabrati tehnologiju koja će unaprijediti učenikovo učenje tijekom nastavnog sata.	◯	◯	◯	◯	◯
Moj program učiteljskog obrazovanja potaknuo me na dublje razmišljanje o utjecaju tehnologije na pristup poučavanju koji koristim u razredu.	◯	◯	◯	◯	◯
Kritički razmišljam o načinima upotrebe tehnologije u razredu.	◯	◯	◯	◯	◯
Mogu prilagoditi svoje znanje o tehnologiji različitim aktivnostima tijekom poučavanja.	◯	◯	◯	◯	◯
Mogu izabrati tehnologiju za rad u razredu koja unaprjeđuje sadržaj i način poučavanja kao i ono što učenici nauče.	◯	◯	◯	◯	◯
Mogu upotrebljavati strategije kombiniranja sadržaja. tehnologije i pristupa poučavanju u razredu. o kojima sam učio/učila tijekom obrazovanja.	◯	◯	◯	◯	◯
Mogu pružiti podršku drugima u koordinaciji upotrebe sadržaja. tehnologija i pristupa poučavanju u mojoj školi i/ili području .	◯	◯	◯	◯	◯
Mogu izabrati tehnologije koje unaprjeđuju sadržaj nastavnog sata.	◯	◯	◯	◯	◯
Tehnološko pedagoško sadržajno znanje (TPACK)					

	Uopće se ne slažem	Ne slažem se	Niti se slažem niti se ne slažem	Slažem se	U potpunosti se slažem
Mogu poučavati nastavne sadržaje koji na odgovarajući način kombiniraju matematiku. tehnologiju i pristupe poučavanju.	◯	◯	◯	◯	◯
Mogu poučavati nastavne sadržaje koji na odgovarajući način kombiniraju pismenost. tehnologiju i pristupe poučavanju.	◯	◯	◯	◯	◯
Mogu poučavati nastavne sadržaje koji na odgovarajući način kombiniraju društvene znanosti. tehnologiju i pristupe poučavanju.	◯	◯	◯	◯	◯
Mogu poučavati nastavne sadržaje koji na odgovarajući način kombiniraju znanost. tehnologiju i pristupe poučavanju.	◯	◯	◯	◯	◯

ŽIVOTOPIS

Karolina Dobi Barišić rođena je u Osijeku 22. prosinca 1984. g. kao drugo dijete Dobi Ištvana i Verice. Nakon završene III. gimnazije u Osijeku (prirodoslovno-matematičkog usmjerenja) upisuje Odjel za matematiku. Diplomirala je 2008. godine s temom diplomskog rada "Kružnice u geometriji trokuta" te stekla zvanje diplomirane profesorice matematike i informatike. 2008. upisuje poslijediplomski doktorski studij Informacijskih znanosti na Fakultetu informatike i organizacije u Varaždinu.

Nakon završenog fakulteta zaposlena je u OŠ Darda kao nastavnik matematike te nestručno fizike te u OŠ Jagodnjak kao nastavnik matematike i informatike. Od listopada 2008. zaposlena je na Učiteljskom fakultetu u Osijeku (danas Fakultet za odgojne i obrazovne znanosti. Osijek) kao asistentica na kolegijima: Oblikovanje teksta (učiteljski studij). Web programiranje (učiteljski studij). Informatika u obrazovanju (učiteljski studij). Uvod u računarstvo (učiteljski studij). Informatička pismenost (studij ranog i predškolskog odgoja i obrazovanja).

Objavila je više znanstvenih i stručnih radova te aktivno sudjelovala na nekoliko međunarodnih i domaćih skupova.

Popis objavljenih radova:

[1] Dobi Barišić K.. Divjak B.. Kirinić V. (2017). Validation of Survey of Preservice Teachers' Knowledge of Teaching and Technology in the Context of Croatian Educational System. *Proceedings of the 28th International Conference Central European Conference on Information and Intelligent Systems*. V. Strahonja. V. Kirinić (Ur.) Varaždin: Faculty of Organization and Informatics. University of Zagreb. str. 37-45.

[2] Dobi Barišić. K. (2015). Future teachers' perception on the application of ICT in the process of assessment and feedback. *Higher Goals in Mathematics Education*. Z. Kolar-Begović. R. Kolar-Šuper. I. Đurđević Babić (Ur.) Zagreb: Element. str. 142-150.

[3] Dobi Barišić. K. (2013). Matematičke formule u OpenOfficeu. *Matematika i škola*. 72. str. 76-79. (stručni)

[4] Đeri. I.. Dobi Barišić. K. i Jukić Matić. LJ. (2013). The influence of formal education and personal initiatives on the willingness to use ICT in teaching mathematics. *Mathematics*

Teaching for the Future. M. Pavleković. Z. Kolar-Begović. R. Kolar-Šuper (Ur.) Zagreb: Element. str. 261-270.

[5] Dobi Barišić. K.. Đeri. I. i Jukić. L. (2011). What Is the Future of the Integration of ICT in Teaching Mathematics. *The Third International Scientific Colloquium Mathematics and Children (The Math Teacher)* M. Pavleković (Ur.). Zagreb: Element. str. 128-140.

[6] Dobi. K. Đurđević I. i. Đeri. I. (2011). Usage of Learning Management System in the Teaching Process – Users' Perspective. *Digital Technologies and New Forms of Learning* J. Milat (Ur.). Split: Faculty of Philosophy. University of Split. Croatia. str. 103-112.

[7] Dobi. K.. Đeri. I. i Đurđević. I. (2010). Analytical Hierarchical Multicriteria Model For Selecting The Type Of Teaching. *Pre-Conference proceedings of the Special Focus Symposium on 2nd IKS: Information and Knowledge Systems*. V. Šimović. L. Burita. P. Hruza (Ur.). Zagreb: Faculty of Teacher Education. str. 47-57.

[8] Dobi. K.. Đeri. I. i Đurđević. I. (2010). Students Perception of a Learning Support System on Faculty of Teacher Education in Osijek. Ohrid. Faculty of Pedagogy "St. Kliment Ohridski". University "Sts. Cyril and Methodius". Skopje. Macedonia. str. 79-80.

[9] Dobi. K.. Gugić. J. i Kancijan. D. (2010). AHP as a Decision Support Tool in the Multicriteria Evaluation of Bids in Public Procurement. *Proceedings of the ITI 2010 - 32nd International Conference on Information Technology Interfaces* V.Luzar-Stiffler. I. Jarec. Z. Bekić (Ur.). Zagreb: IEEE Region 8. Catalog Number CFP10498-PRT. str. 447-453.