METROPOLITAN UNIVERZITET BEOGRAD
FAKULTET INFORMACIONIH TEHNOLOGIJA

Razvoj studentskih modela za inteligentne sisteme e-učenja baziranih na primeni algoritama mašinskog učenja

Doktorska disertacija

Mentor:
Prof. dr Dragan Domazet

Kandidat:
Jovana Jović
Broj indeksa: 2885

Beograd, 2026. godine

BELGRADE METROPOLITAN UNIVERSITY
FACULTY OF INFORMATION TECHNOLOGY

Development of Student Models for Intelligent e-Learning Systems Based on the Application of Machine Learning Algorithms

Doctoral dissertation

Mentor:
Prof. dr Dragan Domazet

Candidate:
Jovana Jović
Student ID: 2885

Belgrade, 2026. godine

Mentor:

prof. dr Dragan S. Domazet, profesor emeritus

Članovi komisije:

prof. dr Nemanja Zdravković

prof. dr Dijana Oreški

doc. dr Emilija Kisić

doc. dr Dušan Simjanović

Datum odbrane:

_____

Razvoj studentskih modela za inteligentne sisteme e-učenja baziranih na primeni algoritama mašinskog učenja

Sažetak

Savremeni sistemi za e-učenje raspolažu velikom količinom podataka o aktivnostima, rezultatima i napredovanju studenata, ali njihova upotreba često ostaje ograničena na agregirane pokazatelje uspeha. Takvi podaci sami po sebi ne daju dovoljno precizan odgovor na pitanja koje je nastavne sadržaje pojedinačni student savladao, gde mu je potrebna dodatna podrška i koji sadržaj bi trebalo da koristi u daljem učenju. Polazeći od ovog problema, predmet disertacije je razvoj i evaluacija fleksibilnog i interpretabilnog modela studenta koji podatke o učenju povezuje sa formalno organizovanim nastavnim sadržajem, sa ciljem podrške personalizovanom i adaptivnom e-učenju.

Istraživanje je sprovedeno u skladu sa metodologijom nauke o projektovanju, kroz iterativni razvoj i evaluaciju međusobno povezanih modela i softverskih artefakata. Razvijen je ontološki model nastavnog sadržaja zasnovan na objektima učenja, koji omogućava strukturiranje, povezivanje, pretragu i vizualizaciju nastavnih materijala. Model je proširen kompetencijskim okvirom, čime je omogućeno povezivanje objekata učenja sa ishodima učenja, kompetencijama, nivoima dubine i dokazima koji nastaju tokom aktivnosti studenata. Na taj način uspostavljena je semantička osnova za tumačenje podataka o učenju u odnosu na konkretan nastavni sadržaj.

Razvoj modela studenta sproveden je kroz više faza primenom metoda analitike učenja i algoritama mašinskog učenja. Istraživane su mogućnosti predikcije akademskog uspeha i identifikovanja obrazaca studentskog angažovanja, a nalazi i ograničenja ovih pristupa korišćeni su za razvoj konačnog višeslojnog modela studenta. U njemu se stanje studenta predstavlja kroz međusobno povezane, ali konceptualno odvojene dimenzije: procenu ovladanosti kompetencijama, ostvarenost nastavnih aktivnosti i ponašajni kontekst. Takav

pristup omogućava da se napredovanje studenta ne svodi na jednu ukupnu ocenu ili pripadnost određenoj grupi, već da se potreba za podrškom lokalizuje u odnosu na konkretne nastavne sadržaje. Povezivanjem modela studenta sa ontološkim modelom nastavnog sadržaja razvijen je adaptivni mehanizam kojim se identifikovane potrebe pojedinačnog studenta prevode u uređenu putanju za dalje učenje. Pri formiranju preporuke uzimaju se u obzir stanje studenta, raspoloživi dokazi o učenju i semantičke veze između nastavnih sadržaja, uključujući njihove preduslove i odnose između osnovnih i naprednijih sadržaja. Poseban zahtev pri razvoju pristupa bila je objašnjivost, pa je preporuku moguće pratiti od predloženog nastavnog sadržaja do podataka, procene stanja i pravila na kojima je odluka zasnovana.

Razvijeni modeli evaluirani su korišćenjem stvarnih nastavnih sadržaja i obrazovnih podataka. Ontološki model i njegova vizualizacija provereni su kroz dve iteracije u realnom nastavnom okruženju, dok je konačni model studenta primenjen na dva predmeta različita prema domenu i strukturi aktivnosti. Rezultati su pokazali da je razvijeni pristup moguće operacionalizovati nad realnim obrazovnim podacima i da omogućava formiranje interpretabilnih individualnih profila i sledljivih preporuka za dalje učenje. Dodatne analize podržale su unutrašnju stabilnost ključnih projektnih odluka u analiziranim kohortama, dok su povratne informacije 86 studenata pokazale da su personalizovane preporuke i njihova objašnjenja uglavnom percipirani kao razumljivi, relevantni i korisni.

Centralni doprinos disertacije predstavlja integrisani pristup koji povezuje formalno strukturiran nastavni sadržaj, podatke i dokaze nastale tokom učenja, dinamički model studenta i objašnjivi adaptivni mehanizam. Njegova vrednost ogleda se u mogućnosti da se stanje pojedinačnog studenta tumači u odnosu na ono što se uči i da se identifikovana potreba za podrškom prevede u konkretnu i obrazloženu preporuku za dalje učenje. Rezultati podržavaju izvodljivost, interpretabilnost i sledljivost razvijenog pristupa u analiziranim obrazovnim kontekstima, dok njegova spoljašnja generalizacija, obrazovna efikasnost, interoperabilnost i skalabilnost zahtevaju dalju empirijsku validaciju.

Ključne reči: personalizovano učenje, adaptivno e-učenje, model studenta, analitika učenja, mašinsko učenje, Bajesovo praćenje znanja, ontološki model, kompetencijski zasnovano učenje, objašnjiva veštačka inteligencija

Naučna oblast: Tehničko-tehnološke nauke

Uža naučna oblast: Softversko inženjerstvo

Development of Student Models for Intelligent e-Learning Systems Based on the Application of Machine Learning Algorithms

Abstract

Contemporary e-learning systems contain large amounts of data on student activities, performance, and progress, yet their use often remains limited to aggregated indicators of achievement. Such data alone do not provide sufficiently precise answers to questions concerning which learning content an individual student has mastered, where additional support is needed, and which content should be used in further learning. Starting from this problem, the subject of this dissertation is the development and evaluation of a flexible and interpretable student model that connects learning data with formally organized learning content in order to support personalized and adaptive e-learning.

The research was conducted in accordance with the design science methodology through the iterative development and evaluation of interconnected models and software artifacts. An ontology-based learning content model was developed to support the structuring, linking, retrieval, and visualization of learning materials. The model was extended with a competence-based framework, enabling learning objects to be connected with learning outcomes, competences, depth levels, and evidence generated through student activities. In this way, a semantic basis was established for interpreting learning data in relation to specific learning content.

The student model was developed through several phases using learning analytics methods and machine learning algorithms. The possibilities of predicting academic performance and identifying patterns of student engagement were investigated, and the findings and limitations of these approaches were used to develop the final multilayer student model. In this model, the student's state is represented through interconnected but conceptually separate dimensions: estimated competence mastery, attainment of learning activities, and behavioral context. Such

an approach makes it possible to avoid reducing student progress to a single overall score or group membership and instead enables the need for support to be localized in relation to specific learning content. By connecting the student model with the ontology-based learning content model, an adaptive mechanism was developed through which the identified needs of an individual student are translated into an ordered path for further learning. The recommendation process takes into account the student's state, available evidence of learning, and semantic relationships between learning content, including prerequisites and relationships between basic and more advanced content. Explainability was a particular requirement in the development of the approach, making it possible to trace a recommendation from the proposed learning content back to the data, estimated state, and rules on which the decision was based.

The developed models were evaluated using real learning content and educational data. The ontology-based model and its visualization were examined through two iterations in a real teaching environment, while the final student model was applied to two courses differing in domain and activity structure. The results showed that the developed approach can be operationalized using real educational data and can support the formation of interpretable individual profiles and traceable recommendations for further learning. Additional analyses supported the internal stability of key design decisions within the examined cohorts, while feedback from 86 students showed that personalized recommendations and their explanations were generally perceived as understandable, relevant, and useful.

The central contribution of the dissertation is an integrated approach that connects formally structured learning content, data and evidence generated during learning, a dynamic student model, and an explainable adaptive mechanism. Its value lies in the ability to interpret the state of an individual student in relation to what is being learned and to translate an identified need for support into a concrete and justified recommendation for further learning. The results support the feasibility, interpretability, and traceability of the developed approach in the examined educational contexts, while its external generalization, educational effectiveness, interoperability, and scalability require further empirical validation.

Keywords: personalized learning, adaptive e-learning, student model, learning analytics, machine learning, Bayesian Knowledge Tracing, ontological model, competence-based learning, explainable artificial intelligence

Scientific field: Technical and technological sciences

Scientific subfield: Software engineering

Sadržaj

Sažetak **4**

Abstract **6**

SADRŽAJ **8**

Spisak akronima **12**

Lista Slika **14**

Lista tabela **16**

POGLAVLJE 1 ..... **17**

1. Uvod **17**

1.1. Predmet i ciljevi istraživanja 21

1.2. Istraživačka pitanja i hipoteze 22

1.3. Doprinosi disertacije 24

1.3.1. Teorijski doprinosi 25

1.3.2. Metodološki doprinosi 26

1.3.3. Softversko-arhitekturni i praktični doprinosi 27

1.3.4. Empirijski doprinosi 28

1.4. Zadaci istraživanja 29

1.5. Pregled sadržaja rada 31

POGLAVLJE 2 ..... **34**

2. Pregled relevantne literature **34**

2.1. Personalizovano i adaptivno učenje 34

2.2. Modeli sadržaja za učenje 40

2.2.1. Kreiranje nastavnih materijala 40

2.2.2. Objekti učenja 41

2.2.3. Strukturiranje nastavnih sadržaja 42

2.2.4. Preporuka nastavnih materijala 45

2.2.4.1. Preporuke korišćenjem ontologije domena 47
2.3. Modelovanje studenata 50
2.3.1. Pojam modela studenta 50
2.3.1.1. Znanje/kompetencije studenata 52
2.3.2. Tehnike modelovanja studenta 55
2.3.2.1. Modelovanje studenta zasnovano na algoritmima mašinskog učenja 56
2.4. Istraživački jaz i pozicioniranje originalnosti disertacije 59

POGLAVLJE 3 67

3. Metodologija 67
3.1. Istraživanja u softverskom inženjerstvu 67
3.2. Metodologija nauke o projektovanju 68
3.3. Primenjene metode istraživanja 70
3.3.1. Mapiranje postavljene metodologije i doktorske disertacije 72
3.3.2. Metode prikupljanja i analize podataka 78
3.4. Vremensko i prostorno određenje predmeta istraživanja 81
3.5. Podaci korišćeni u istraživanju 82

POGLAVLJE 4 84

4. Teorijski okvir za postavljanje problema 84
4.1. Primena ontologije za razvoj modela nastavnih materijala 84
4.1.1. Ontološki model prema Noy & McGuinness-u 85
4.2. Vizualizacija 87
4.2.1. Multidimenzionalne konceptualne mape 87
4.3. Metode za modelovanje znanja i ponašanja studenta 89
4.3.1. Kompetencijski okvir razvoja nastavnih sadržaja 90
4.3.2. Bajesovo praćenje znanja (BKT) 92
4.3.2.1. Ocenjivanje i ograničavanje parametara 94
4.3.2.2. Kontinuirane opservacije 95
4.3.2.3. Jedinica modelovanja i sastav sekvence 96
4.3.3. Klasterovanje obrazaca ponašanja studenata 97
4.3.4. Objašnjiva veštačka inteligencija 99

POGLAVLJE 5 102

5. Model sadržaja za učenje 102
5.1. Ontološki model za organizaciju nastavnog sadržaja koji je u formi objekata učenja 103
5.1.1. Fleksibilnost ontološkog modela nastavnih sadržaja 108

5.2. Adaptivna preporuka sadržaja i dinamička isporuka i vizualizacija nastavnih sadržaja 117
5.2.1. Vizualizacija ontološkog modela korišćenjem multidimenzionalnih konceptualnih mapa 117
5.2.1.1. Softverska arhitektura sistema za podršku učenju korišćenjem ontologija i MCM-a 119
5.2.1.2. Primer vizualizacije ontologije za oblast *Upravljanje informacijama*, primenjenim na predmetu Baze podataka 126
5.3. Proširenje ontološkog modela kompetencijskim okvirom 131

POGLAVLJE 6 139

6. Model studenta 139
6.1. Definicija i značaj modela studenta 139
6.2. Tehnike modelovanja studenata 140
6.3. Faza 1: Predikcija studentskog uspeha pomoću mašinskog učenja 141
6.4. Faza 2: Klasterovanje i analiza obrazaca učenja 145
6.5. Faza 3: Model kontinuiranog praćenja ovladanosti nastavnim sadržajem 151
6.5.1. Podaci i jedinica modelovanja 151
6.5.2. Slojevi modela studenta 156
6.5.2.1. Sloj ovladanosti kompetencijama 157
6.5.2.2. Sloj ostvarenosti nivoa 159
6.5.2.3. Sloj analitike učenja i ponašajni tipovi studenata 161
6.5.2.4. Tok obrade i izlazi modela studenta 163
6.5.3. Arhitektura modela razvijenog u trećoj fazi 164

POGLAVLJE 7 169

7. Rezultati i diskusija 169
7.1. Evaluacija modela nastavnih materijala 170
7.1.1. Prva iteracija evaluacije modela nastavnih sadržaja 173
7.1.1.1. Uporedna analiza korišćenja OBSLO i LAMS sistema 175
7.1.1.2. Analiza zadovoljstva studenata korišćenjem OBSLO-a 178
7.1.2. Druga iteracija evaluacije modela nastavnih sadržaja 180
7.1.2.1. Analiza puteva učenja studenata 185
7.1.2.2. Modifikacija ontologije 191
7.1.2.3. Analiza zadovoljstva studenata korišćenjem unapređene verzije OBSLO-a 193
7.2. Evaluacija modela studenata 195
7.2.1. Faza 1: Predikcija studentskog uspeha pomoću mašinskog učenja 196
7.2.2. Faza 2: Klasterovanje i analiza obrazaca učenja 201
7.2.3. Faza 3: Model kontinuiranog praćenja ovladanosti nastavnim sadržajem 205
7.2.3.1. Ovladanost kompetencijama i ostvarenost nivoa na nivou kohorte 206
7.2.3.2. Individualni profili ovladanosti po kompetencijama 210

7.2.3.3. Ponašajni tipovi studenata 213
7.2.3.4. Identifikovani sadržaji za podršku kao osnova objašnjivih preporuka 221
7.2.3.5. Povratne informacije studenata o kontrolnoj tabli i objašnjivim preporukama 223
7.3. Adaptivni model 228
7.3.1. Adaptivna preporuka na osnovu modela studenta i ontologije 228
7.3.2. Primena i mogućnosti integracije adaptivne preporuke u postojeće sisteme e-učenja 238
7.3.3. Zaključne napomene o adaptivnom modelu 241

POGLAVLJE 8 245

8. Zaključci i budući rad 245
8.1. Zaključci istraživanja 245
8.2. Prednosti razvijenog pristupa 252
8.3. Nedostaci i ograničenja istraživanja 256
8.4. Budući rad 263
8.5. Ispunjenost ciljeva istraživanja 269
8.6. Ispunjenost hipoteza 273
8.7. Zaključna razmatranja 279

Prilog A. Prompt za generisanje objašnjivih preporuka 281

9. Literatura 283

Spisak akronima

Akronim	Puni naziv	Prevod / objašnjenje
AI	Artificial Intelligence	Veštačka inteligencija
ARI	Adjusted Rand Index	Prilagođeni Randov indeks; mera saglasnosti između rezultata klasterovanja
BA	Basic/Advanced	Relacija „osnovni/napredni“ između semantički povezanih koncepata
BKT	Bayesian Knowledge Tracing	Bajesovo praćenje znanja
BMU	Belgrade Metropolitan University	Univerzitet Metropolitan u Beogradu
COMP	Competency	Kompetencija
DBSCAN	Density-Based Spatial Clustering of Applications with Noise	Algoritam klasterovanja zasnovan na gustini
DDL	Data Definition Language	Jezik za definisanje podataka
DITA	Darwin Information Typing Architecture	OASIS standard za strukturiranje sadržaja
DML	Data Manipulation Language	Jezik za manipulaciju podacima
DQL	Data Query Language	Upitni jezik nad podacima; u radu se koristi i kao jedinica znanja
DS	Design Science	Nauka o projektovanju
DSR	Design Science Research	Istraživanje zasnovano na nauci o projektovanju
DSP	Design Science Paradigm	Paradigma nauke o projektovanju
DT	Decision Tree(s)	Stablo / stabla odlučivanja
EMS	Educational Management System	Sistem za upravljanje obrazovanjem
HC	Has Content	Relacija „ima sadržaj“ između koncepta i pripadajućih objekata učenja
HDBSCAN	Hierarchical Density-Based Spatial Clustering of Applications with Noise	Hijerarhijski algoritam klasterovanja zasnovan na gustini
HR	Has Resource	Relacija „ima resurs“ između objekta učenja i njegovih resursa
ILS	Institutional Learning System	Institucionalni sistem za e-učenje
ITS	Intelligent Tutoring System(s)	Inteligentni tutorski sistem(i)
JSON	JavaScript Object Notation	Format za predstavljanje i razmenu strukturiranih podataka
KNN	K-Nearest Neighbors	K najbližih suseda
KNOW	Knowledge	Znanje
LAMS	Learning Activity Management System	Sistem za upravljanje aktivnostima učenja

LDA	Linear Discriminant Analysis	Linearna diskriminantna analiza
LLM	Large Language Model	Veliki jezički model
LMS	Learning Management System(s)	Sistem(i) za upravljanje učenjem
LO	Learning Object	Objekat učenja; engleska oznaka istog pojma kao OU
LOR	Learning Object Repository	Repozitorijum objekata učenja
LOUT	Learning Outcome	Ishod učenja
LR	Logistic Regression	Logistička regresija
MCM	Multidimensional Concept Maps	Multidimenzionalne konceptualne mape
MCMLEC	OBSLO MCM Learning Environment Creator	Kreator MCM okruženja za učenje
ML	Machine Learning	Mašinsko učenje
NB	Naïve Bayes	Naivni Bajesov klasifikator
NCM	Novak Concept Map	Novakova konceptualna mapa
OAT	OBSLO Ontology Authoring Tool	Alat za kreiranje i uređivanje ontologije u OBSLO-u
OBSLO	Ontology-Based System for Learning Object Retrieval	Sistem zasnovan na ontologiji za objekte učenja
OR	Order relation	Relacija redosleda između objekata učenja; može predstavljati obavezni ili opcioni odnos
OU	Objekat učenja	Srpska oznaka za objekat učenja; koristi se naizmenično sa LO
PCA	Principal Component Analysis	Analiza glavnih komponenti
PO	Part Of relation	Relacija „biti deo“ između elemenata hijerarhije ontologije
RDBMS	Relational Database Management System	Sistem za upravljanje relacionim bazama podataka
SERS	Semantic Educational Recommender System	Semantički obrazovni sistem za preporučivanje
SKILL	Skill	Veština
SQL	Structured Query Language	Strukturirani upitni jezik za rad sa relacionim bazama podataka
SVM	Support Vector Machine(s)	Metoda / mašine potpornih vektora
VERIFY	Verification	Element verifikacije; u integrisanom modelu predstavlja semantičku vezu objekta učenja sa dokazom iz odgovarajuće aktivnosti provere
XAI	Explainable Artificial Intelligence	Objašnjiva veštačka inteligencija

Lista Slika

Slika 1. Konceptualni prikaz komponenti adaptivnog sistema za e-učenje: model nastavnog sadržaja, model studenta i adaptivni model. ... 18

Slika 2. Centralni doprinos disertacije: operativni lanac od verifikovanog dokaza do sledljivog obrazloženja preporuke. ... 65

Slika 3. Vizualizacija tipova istraživačkih aktivnosti u metodologiji nauke o projektovanju. Preuzeto iz [223]. ... 69

Slika 4. Model doprinosa nauke o projektovanju u softverskom inženjerstvu. Preuzeto iz [223] i [228]. ... 71

Slika 5. Tokovi podataka između modela studenta, modela nastavnog sadržaja i adaptivnog modela u predloženom sistemu. ... 73

Slika 6. Konceptualni model ontologije. ... 106

Slika 7. HR relacija između objekata učenja i njihovih resursa. ... 107

Slika 8. Konceptualni model ontologije sa pridodatim nivoima znanja dodatnim atributom *level*. ... 109

Slika 9. Konceptualni model ontologije sa pridodatim kompetencijama i ishodima učenja. ... 111

Slika 10. Konceptualni model ontologije sa strukturom lekcija. ... 113

Slika 11. Konceptualni model ontologije obogaćen formativnim proverama znanja radi lakšeg prilagođavanja putanja učenja. ... 116

Slika 12. Softverska arhitektura OBSLO sistema. ... 122

Slika 13. Ključni koncepti za oblast znanja *Upravljanje informacijama*. ... 127

Slika 14. Ontologija za jedinicu znanja Upitni jezik baza podataka (DQL). ... 128

Slika 15. OBSLO MCM vizualizacija osnovnog nivoa znanja. ... 129

Slika 16. OBSLO MCM vizualizacija naprednog nivoa znanja. ... 129

Slika 17. Prikaz OU „*Group By*“ *klauzula*. ... 131

Slika 18. Mapiranje ciljeva, ishoda učenja i kompetencija od referentnog korpusa znanja do kurikuluma, predmeta i lekcije. Prilagođeno iz [15]. ... 133

Slika 19. Struktura metapodataka objekta učenja u usvojenom kompetencijskom okviru: ishod učenja (LOUT), kompetencija (COMP), znanje (KNOW) i veština (SKILL), organizovani prema nivoima dubine N1, N2 i N3. Preuzeto iz [15]. ... 134

Slika 20. Primer profila kompetencija dva studenta: nivo N1 predstavlja zajedničko obavezno jezgro, dok se kompetencijski profili na nivoima N2 i N3 mogu razlikovati prema obimu i dubini. Prilagođeno iz [15]. ... 135

Slika 21. Ontološki model iz [14], proširen kompetencijama i ishodima učenja prema okviru iz [15]. ... 136

Slika 22. Struktura objekta učenja u spojenom modelu: nivo dubine (N1/N2/N3) i pet elemenata - LOUT, COMP, KNOW, SKILL, VERIFY. ... 137

Slika 23. Metodologija istraživanja predikcije studentskog uspeha pomoću algoritama mašinskog učenja. 143
Slika 24. Poređenje ključnih komponenti strukture lekcija za BMU i FOI. 146
Slika 25. Primer BMU-ovog strukturiranja lekcije sa objektima učenja i aktivnostima učenja lekcije. 147
Slika 26. Primer BMU-ove organizacije stepenovanih testova u različite sekcije. 147
Slika 27. Primer strukture lekcije FOI. 148
Slika 28. Aktivnosti provere i njihovo mapiranje na objekte učenja pri različitim nivoima granularnosti. Pojedinačna pitanja pružaju fino granularne dokaze, dok testovi, ocenjeni zadaci, projekti i eseji pružaju šire dokaze mapirane na objekte učenja i nivoe dubine..... 155
Slika 29. Tok obrade podataka u modelu studenta: od mapiranja dokaza iz aktivnosti provere do procene ovladanosti, ostvarenosti nivoa i identifikovanja ponašajnog tipa studenta..... 164
Slika 30. Komponentna arhitektura integrisanog modela u trećoj fazi: institucionalni sistem za učenje, sistem za upravljanje obrazovanjem i OBSLO sa modelom studenta, adaptivnim mehanizmom i komponentom za objašnjive preporuke..... 165
Slika 31. Prikaz MCM-a osnovnog nivoa za Jezik za upite nad podacima u OBSLO-u..... 182
Slika 32. Prikaz MCM-a naprednog nivoa za Jezik za upite nad podacima u OBSLO-u. 183
Slika 33. Primer sadržaja za učenje u DQL-GROUP BY, HAVING, ORDER BY OU-u..... 183
Slika 34. Radna stranica koja prikazuje dodeljeni problem, izabrani OU od strane studenta i prostor za pružanje rešenja. 184
Slika 35. Toplotna mapa korelacije. 197
Slika 36. Boxplot dijagram sa tačnošću nakon 10 iteracija unakrsne validacije za šest različitih klasifikatora. 199
Slika 37. Matrica konfuzije SVM predloženog modela..... 199
Slika 38. K-means klasterovanje rezultata BMU studenata po objektima učenja nakon redukcije dimenzionalnosti. Preuzeto iz [19]. 203
Slika 39. Raspodela rezultata studenata po klasterima na BMU i FOI..... 204
Slika 40. Profili ovladanosti kompetencijama na nivoima dubine N1 i N2 za četiri odabrana studenta, po dva iz predmeta SE201 i CS202..... 211
Slika 41. Ponašajni tipovi studenata dobijeni k-means klasterovanjem i prikazani u dvodimenzionalnom prostoru glavnih komponenti: tri tipa za predmet SE201 i dva tipa za predmet CS202. 215
Slika 42. Uticaj dodavanja pokazatelja ostvarenosti i ovladanosti na dodelu studenata k-means klasterima, prikazan u zajedničkom PCA prostoru standardizovanih ponašajnih atributa. 218
Slika 43. Primer kontrolne table sa objašnjivom preporukom za studenta predmeta SE201: ponašajni tip, procene ovladanosti, ostvarenost nivoa, identifikovani sadržaji za podršku, uređena putanja učenja, profil kompetencija i ontološki prostor nastavnog sadržaja. 237

Lista tabela

TABELA 1. POREĐENJE PREDLOŽENOG MODELA SA PRISTUPIMA RAZMATRANIM U POGLAVLJU 2. 61
TABELA 2. MAPIRANJE AKTIVNOSTI METODOLOGIJE NAUKE O PROJEKTOVANJU NA POGLAVLJA DISERTACIJE..... 77
TABELA 3. MAPIRANJE HIPOTEZA ISTRAŽIVANJA NA NAČIN PROVERE I ODGOVARAJUĆA POGLAVLJA. 81
TABELA 4. KARAKTERISTIKE PREDMETA KORIŠĆENIH U TREĆOJ FAZI RAZVOJA MODELA STUDENTA. 152
TABELA 5. DEKOMPOZICIJA KOMPETENCIJA IZ REFERENTNOG KURIKULUMA NA KOMPETENCIJE PREDMETA. 153
TABELA 6. PRIMERI ZADATAKA DODELJENIH OBSLO (SA1-SA3) I LAMS (HQ1-HQ3) GRUPAMA STUDENATA. 174
TABELA 7. BROJ STUDENATA KOJI SU KORISTILI OBSLO, ZAVRŠILI ZADATKE I TAČNO IH REŠILI. 176
TABELA 8. BROJ STUDENATA KOJI SU KORISTILI LAMS, ZAVRŠILI DOMAĆE ZADATKE I TAČNO IH REŠILI. 176
TABELA 9. REGISTROVANO VREME RADA SA INTERAKTIVNIM SADRŽAJEM OBJEKATA UČENJA (U SEKUNDAMA PO STUDENTU). 177
TABELA 10. REZULTATI STUDENTSKOG UPITNIKA O OBSLO-U. 179
TABELA 11. PROBLEMI DODELJENI STUDENTIMA TOKOM DRUGE EVALUACIONE FAZE. 181
TABELA 12. BROJ STUDENATA KOJI SU POKUŠALI DA REŠE ZADATE PROBLEME I ONIH KOJI SU DOBILI TAČAN ODGOVOR 186
TABELA 13. FREKVENCIJA PUTANJA UČENJA PO PITANJU. 186
TABELA 14. VREME PROVEDENO NA SADRŽAJU OU-A PO STUDENTU U SEKUNDAMA ZA SVAKO PITANJE [SEK]. 190
TABELA 15. KORIŠĆENI OBJEKTI UČENJA KOD Q2. 192
TABELA 16. KORIŠĆENI OBJEKTI UČENJA KOD Q4. 192
TABELA 17. REZULTATI IZ UPITNIKA STUDENATA. 194
TABELA 18. PERFORMANSE PREDIKTIVNOG MODELA. 200
TABELA 19. PROSEČNA OVLADANOST KOMPETENCIJAMA I OSTVARENOST NIVOA PREMA PREDMETU I NIVOU DUBINE. 206
TABELA 20. STABILNOST PROCENA OVLADANOSTI I POREĐENJE PREDIKTIVNE SPOSOBNOSTI KONTINUIRANE I BINARNE BKT FORMULACIJE. 209
TABELA 21. KOEFICIJENT SILUETE ZA RAZLIČIT BROJ KLASTERA. 214
TABELA 22. PONAŠAJNI TIPOVI STUDENATA PREMA PREDMETU: ATRIBUTI KORIŠĆENI ZA KLASTEROVANJE I NAKNADNO PRIDRUŽENA OSTVARENOST NIVOA. 214
TABELA 23. SAŽETAK PROVERA ROBUSNOSTI PONAŠAJNOG KLASTEROVANJA. 218
TABELA 24. IDENTIFIKOVANI SADRŽAJI ZA PODRŠKU PREMA PREDMETU I VRSTI IDENTIFIKOVANE POTREBE. 222
TABELA 25. POVRATNA INFORMACIJA STUDENATA O KONTROLNOJ TABLI I OBJAŠNJIVIM PREPORUKAMA (N = 86). 224
TABELA 26. TEME IDENTIFIKOVANE U OTVORENIM KOMENTARIMA STUDENATA. 226
TABELA 27. OSETLJIVOST IDENTIFIKOVANJA POKUŠAVANIH SLABIH TAČAKA I PRIORITETA INDIVIDUALNE PREPORUKE U ODNOSU NA OSNOVNE PRAGOVE N1 = 0,80 I N2 = 0,50. 232

Poglavlje 1

1. Uvod

Digitalne tehnologije predstavljaju jedan od ključnih oslonaca savremenog visokog obrazovanja, jer omogućavaju razvoj novih oblika nastave, učenja, provere znanja, komunikacije i praćenja studentskog napretka. Sistemi za e-učenje, sistemi za upravljanje učenjem (engl. Learning Management Systems (LMS)), repozitorijumi nastavnih materijala, sistemi za elektronsku proveru znanja i alati za analitiku učenja generišu značajnu količinu podataka o aktivnostima studenata, njihovom radu, tempu učenja, rezultatima i interakcijama sa nastavnim sadržajem. Međutim, sama digitalizacija nastavnih materijala i dostupnost podataka ne znače automatski da je obrazovni proces personalizovan. Veliki broj sistema za e-učenje i dalje organizuje nastavne materijale linearno i jednako za sve studente, bez dovoljno preciznog uvida u to šta je pojedinačni student savladao, gde nailazi na teškoće i koji sadržaj ili aktivnost mu mogu pomoći u daljem učenju [1,2]. Personalizovano e-učenje nastaje kao odgovor na ograničenja pristupa „jedan sadržaj za sve“, sa ciljem da se nastavne aktivnosti, materijali, tempo učenja, redosled sadržaja ili preporuke prilagode potrebama pojedinačnog studenta [3]. Ipak, personalizacija se ne može svesti samo na tehničku mogućnost izbora materijala ili na preporuku dodatnog sadržaja. Da bi sistem e-učenja mogao da pruži smislenu podršku učenju, potrebno je povezati najmanje tri ključne komponente koje se u literaturi prepoznaju kao osnova adaptivnih sistema e-učenja: model nastavnog sadržaja, model studenta i adaptivni model, odnosno mehanizam preporuke koji rezultate modela studenta dovodi u vezu sa strukturom nastavnog sadržaja [4] (Slika 1). Bez modela nastavnog sadržaja sistem nema semantičku osnovu za razumevanje toga šta se uči, a bez modela studenta nema osnovu za razumevanje toga kako pojedinačni student napreduje.

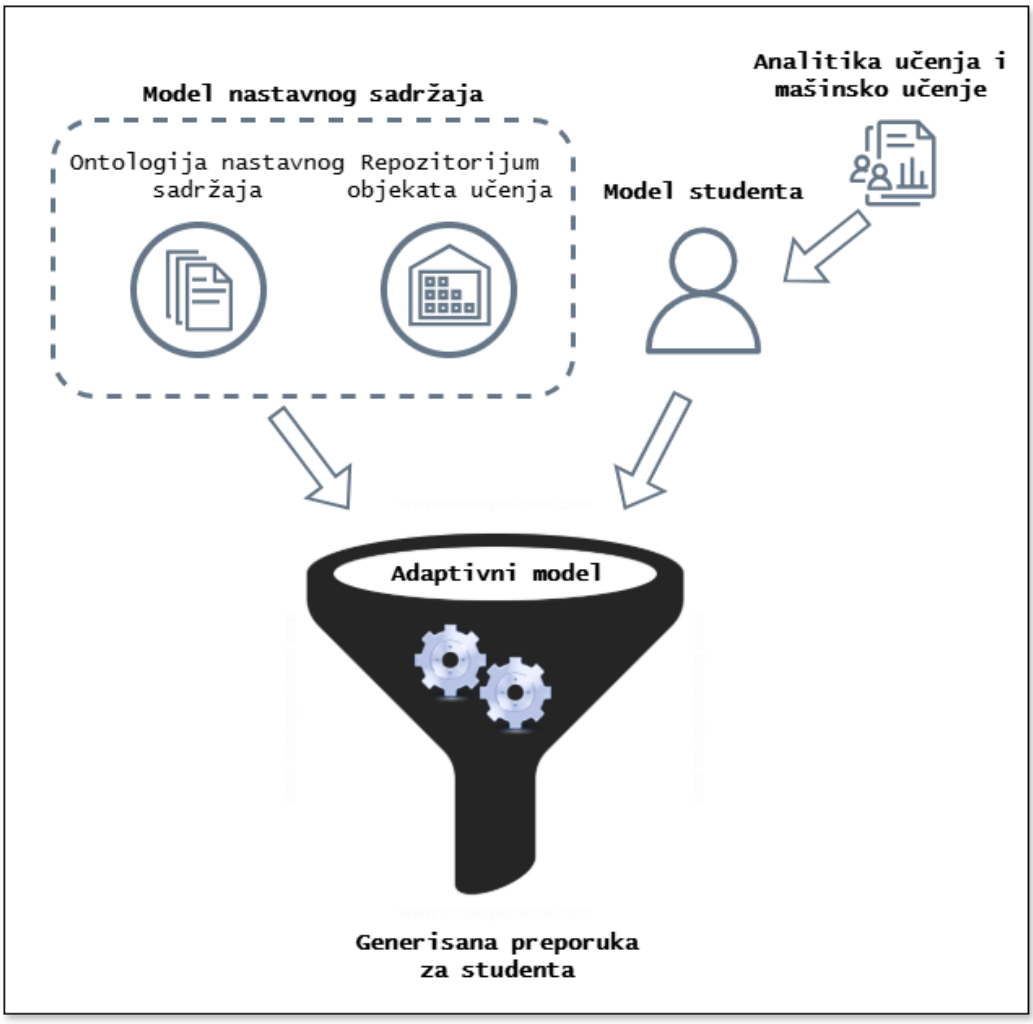

Slika 1. Konceptualni prikaz komponenti adaptivnog sistema za e-učenje: model nastavnog sadržaja, model studenta i adaptivni model.

Centralni fokus ove disertacije jeste razvoj modela studenta za inteligentne sisteme e-učenja. Pod inteligentnim sistemima e-učenja u ovom radu podrazumevaju se sistemi koji, pored isporuke nastavnih sadržaja, koriste podatke o aktivnostima i rezultatima studenata, metode analitike učenja i algoritme mašinskog učenja kako bi kontinuirano pratili napredak, procenjivali nivo ovladanosti nastavnim sadržajem i prilagođavali podršku pojedinačnom studentu. Ovakvi sistemi se u literaturi često razmatraju u širem okviru inteligentnih tehnika u e-učenju i adaptivnih platformi za učenje, pri čemu inteligentni sistemi e-učenja predstavljaju jedan od specifičnih oblika njihove primene [5,6]. Model studenta predstavlja osnovu za praćenje i tumačenje procesa učenja na nivou pojedinačnog studenta, jer omogućava prikupljanje i obradu podataka o aktivnostima, rezultatima, obrascima rada, napretku, nivou ovladanosti nastavnim sadržajem i delovima sadržaja u kojima se javlja potreba za dodatnim radom. Studentski model se može koristiti za različite oblike podrške obrazovnom procesu: (1) za pravovremeno uočavanje problema kao što su neuspeh, slabije napredovanje ili rizik od

odustajanja, (2) za pružanje orijentacije i preporuka studentima, ili (3) prilagođavanje resursa za učenje u skladu sa uočenim potrebama. Izgradnja modela studenta na osnovu aktivnosti u sistemu za e-učenje nije statičan proces, već zahteva kontinuirano praćenje i ažuriranje na osnovu novih podataka o aktivnostima, rezultatima i napretku studenta, kako bi se promene u načinu rada, nivou ovladanosti sadržajem i postignućima mogle uzeti u obzir tokom procesa učenja [4,5]. Značaj modela studenta ne ogleda se samo u mogućnosti predviđanja ukupnog uspeha, već pre svega u tome što omogućava bolje razumevanje odnosa između studentskih aktivnosti, postignutih rezultata i konkretnih nastavnih sadržaja na koje se ti rezultati odnose. Ako se model oslanja samo na agregirane pokazatelje, kao što su ukupna ocena, broj pristupa platformi ili zbirni broj poena, tada ostaje nejasno koji deo sadržaja je student savladao, gde se javlja problem i koju vrstu podrške treba ponuditi. Zbog toga savremeni pristupi modelovanju studenata i obrazovnim sistemima preporuka sve više naglašavaju potrebu da se analitika učenja poveže sa ishodima učenja, proverama znanja i procenom ovladanosti, a ne samo sa pokazateljima aktivnosti ili opšte uspešnosti [7,8].

Polazeći od navedenog, model studenta treba povezati sa strukturom nastavnog sadržaja, a ne samo sa opštim evidencijama aktivnosti u sistemu za e-učenje. Takav model ne može se razvijati potpuno odvojeno od nastavnog konteksta predmeta u kome nastaju podaci o učenju. Isti tip aktivnosti u sistemu za e-učenje može imati različito značenje u različitim predmetima, u zavisnosti od nastavnog dizajna, načina korišćenja LMS-a, vrste aktivnosti, uloge zadataka, strukture provera znanja i očekivanih ishoda učenja [9,10]. Istraživanja pokazuju da modeli predikcije akademskog uspeha nisu jednako prenosivi između različitih predmeta i da se značajni prediktori mogu razlikovati između modela specifičnih za predmet i generalizovanih modela. Stoga analitika učenja mora uzeti u obzir specifične nastavne uslove i način na koji se tehnologija koristi u konkretnom predmetu, jer zanemarivanje nastavnog konteksta može dovesti do pogrešnog tumačenja podataka iz LMS-a [9]. Ovaj nalaz je posebno važan za razvoj modela studenta koji se ne oslanja samo na generičke logove aktivnosti, već podatke tumači u odnosu na strukturu konkretnog predmeta i nastavne sadržaje koji se u njemu obrađuju.

U ovoj disertaciji model studenta se ne posmatra kao statičan opis ličnosti, sposobnosti ili trajnih karakteristika studenta. Takav pristup bio bi ograničen u kontekstu e-učenja, jer se studenti tokom procesa učenja menjaju, razvijaju strategije rada i različito reaguju na nastavne aktivnosti. Umesto toga, model studenta se razvija kao dinamička reprezentacija napretka i nivoa ovladanosti konkretnim elementima nastavnog sadržaja i izbora koje student ima u učenju. Time se model vezuje za ono što se u nastavnom procesu može pratiti: aktivnosti

studenta, rezultate provera znanja, izvršenost zadataka, obrasce učenja i nivo ovladanosti određenim delovima sadržaja [7,11]. Da bi takav model bio moguć, nastavni sadržaj mora biti strukturiran tako da se njegovi elementi mogu jasno identifikovati, povezati i koristiti u procesu preporuke. Zbog toga se u radu koristi ontološki model objekata učenja, koji omogućava formalno predstavljanje nastavnih elemenata i relacija između njih, kao što su oblasti znanja, jedinice znanja, teme, podteme, objekti učenja, resursi, ishodi učenja, nivoi znanja i, po potrebi, kompetencije. Ovako definisan model nije samo način organizacije sadržaja, već predstavlja semantičku osnovu za povezivanje studentskih aktivnosti sa nastavnim elementima na koje se te aktivnosti odnose [12,13]. U okviru ove disertacije, razvijen je ontološki model objekata učenja čija je evaluacija pokazala da se takav model može koristiti za organizaciju, pretragu i vizualizaciju nastavnog sadržaja, kao i za dinamičko kreiranje personalizovanog prostora za učenje kroz multidimenzionalne konceptualne mape (engl. Multidimensional Concept Maps (MCM)) [14].

Važno svojstvo predloženog pristupa jeste fleksibilnost. Napredak studenta ne mora se pratiti samo na nivou cele lekcije, ukupne ocene ili zbirnog broja poena. Predloženi ontološki model omogućava predstavljanje nastavnog sadržaja kroz više međusobno povezanih dimenzija, uključujući lekcije, teme, objekte učenja (OU), ishode učenja, nivoe znanja i kompetencije. Takva struktura omogućava da se model studenta primeni nad različitim nastavnim elementima i da se rezultati praćenja napretka povežu sa odgovarajućim nastavnim sadržajem i preporukama za dalje učenje [8,13,14]. Predloženi modeli kompatibilni su i sa savremenim pristupima organizaciji i pripremi nastavnih materijala, uključujući konceptualne okvire koji razmatraju primenu generativne veštačke inteligencije [15]. Preporuka nastavnih sadržaja u ovom radu ne posmatra se kao zamena za nastavnika, niti kao mehanizam koji studentu nameće jedinu moguću putanju učenja. Njena uloga je da obezbedi objašnjivu podršku studentu i nastavniku, koja je zasnovana na podacima, dok student odlučuje o daljim koracima učenja. Kada model studenta ukaže na teškoću u određenom delu nastavnog sadržaja, ontološki model omogućava identifikovanje povezanih OU, dok mehanizam preporuke može predložiti odgovarajući sadržaj ili aktivnost za dodatni rad. Na taj način se rezultati modela studenta povezuju sa konkretnim nastavnim materijalima i koriste kao osnova za personalizovanu podršku učenju [16,17].

Poseban značaj ima interpretabilnost modela studenta. U obrazovnom kontekstu nije dovoljno da model samo predvidi uspeh, neuspeh ili rizik. Studentu i nastavniku je potrebno da razumeju zašto je određeni zaključak izveden, koji podaci su doveli do tog zaključka i koje

aktivnosti mogu doprineti unapređenju učenja. Zbog toga se savremena istraživanja sve više usmeravaju ka analitici učenja koja ne ostaje na nivou predikcije, već omogućava praćenje napretka, procenu nivoa ovladanosti, prepoznavanje obrazaca učenja i formulisanje objašnjivih preporuka [8,16,17]. U tom smislu, model studenta ne predstavlja samo prediktivni artefakt, već osnovu za tumačenje, praćenje i podršku procesu učenja.

Motivacija za ovo istraživanje proizilazi iz potrebe da se razvije model studenta koji može da funkcioniše u realnim obrazovnim okruženjima, sa realnim podacima, postojećim nastavnim materijalima i sistemima za e-učenje koji nisu nužno projektovani kao personalizovani. Takav model treba da bude fleksibilan, robusan, interpretabilan i povezan sa nastavnim sadržajem. Zato se istražuje razvoj modela studenta koji podatke o aktivnostima i rezultatima tumači u odnosu na strukturu nastavnog sadržaja i nastavne uslove konkretnog predmeta. Time se model studenta, model nastavnog sadržaja i mehanizam preporuke povezuju u jedinstven okvir za podršku personalizovanom e-učenju.

1.1. Predmet i ciljevi istraživanja

Predmet istraživanja ove disertacije je razvoj i evaluacija fleksibilnog modela studenta za inteligentne sisteme e-učenja, zasnovanog na podacima o aktivnostima, rezultatima i proverama znanja studenata u okruženjima za e-učenje. Model studenta se razvija kao deo šireg okvira koji povezuje podatke o učenju, ontološki model nastavnog sadržaja i mehanizam preporuke nastavnih materijala. Istraživanje je usmereno na to da se aktivnosti i rezultati studenata ne analiziraju samo na nivou ukupnog uspeha, već u odnosu na konkretne nastavne elemente predstavljene u ontološkom modelu, kao što su lekcije, teme, podteme, objekti učenja (OU), ishodi učenja, kompetencije i nivoi znanja. Na taj način model studenta treba da omogući procenu nivoa ovladanosti nastavnim sadržajem (engl. mastery) i identifikaciju delova sadržaja u kojima je studentu potrebna dodatna podrška, dok ontološki model nastavnog sadržaja obezbeđuje osnovu za povezivanje uočenog stanja studenta sa odgovarajućim nastavnim materijalima i preporukama. U okviru istraživanja razvija se ontološki model nastavnog sadržaja zasnovan na OU, koji omogućava strukturiranje, pretragu, povezivanje i vizualizaciju nastavnih materijala. Poseban deo istraživanja odnosi se na primenu MCM za prikaz ontološkog modela i dinamičko kreiranje personalizovanog prostora za učenje. Time se omogućava da složena struktura nastavnog sadržaja bude predstavljena studentu na pregledan način, uz mogućnost prilagođavanja prikaza njegovom napretku i potrebama.

Glavni ciljevi ove disertacije su:

CILJ 1: Razviti i evaluirati model nastavnog sadržaja zasnovan na ontologiji, koji omogućava strukturiranje, povezivanje, pretragu i vizualizaciju nastavnih materijala, kao osnovu za njihovo preporučivanje u sistemu za e-učenje.

CILJ 2: Istražiti, razviti i evaluirati model studenta zasnovan na aktivnostima i rezultatima studenata u digitalnim okruženjima za učenje, koji može da podrži kontinuirano praćenje napretka i procenu nivoa ovladanosti nastavnim sadržajem povezanim sa određenim ciljem učenja, ishodom učenja i/ili kompetencijom.

CILJ 3: Osmisliti, projektovati, implementirati i evaluirati model studenta i model nastavnog sadržaja koji zajedno mogu da podrže personalizovano učenje u sistemu za e-učenje kroz sledeće funkcionalnosti:

- organizovanje objekata učenja korišćenjem predloženog modela ontologije,
- praćenje napretka studenta tokom učenja,
- davanje objašnjivih preporuka nastavnog sadržaja na osnovu procenjenog stanja učenja, napretka i postignutih ciljeva, ishoda učenja i/ili kompetencija,
- vizualizaciju ontološkog modela i dinamičko kreiranje personalizovanog prostora za učenje za svakog studenta.

CILJ 4: Osmisliti i razviti model studenta i model nastavnog sadržaja kao modularne komponente, razdvojene od konkretnog sistema za e-učenje, kako bi se omogućila njihova jednostavnija integracija u različite adaptivne i personalizovane kontekste e-učenja.

Jednostavnija integracija pri tome se ne meri kao smanjenje vremena, troškova ili tehničke složenosti integracije, niti podrazumeva potvrđenu interoperabilnost sa proizvoljnim LMS platformama.

1.2. Istraživačka pitanja i hipoteze

Na osnovu ciljeva disertacije, definisana su sledeća istraživačka pitanja (IP):

IP1: Na koji način metode analitike učenja i algoritmi mašinskog učenja mogu podržati razvoj modela studenta koji omogućava praćenje napretka i procenu nivoa ovladanosti nastavnim sadržajem u odnosu na određene ciljeve učenja, ishode učenja ili kompetencije?

IP2: Na koji način se podaci o aktivnostima, rezultatima i proverama znanja studenata mogu povezati sa strukturom nastavnog sadržaja radi formiranja personalizovanih preporuka za dalje učenje?

IP3: Na koji način se ontološki model nastavnog sadržaja može automatski vizualizovati i koristiti za dinamičko kreiranje personalizovanog prostora za učenje u sistemu za e-učenje?

IP4: Na koji način modularna arhitektura razvijenog modela studenta i modela nastavnog sadržaja smanjuje njihovu zavisnost od konkretnog sistema za e-učenje i omogućava jednostavniju integraciju u različite adaptivne i personalizovane obrazovne sisteme i kontekste, i koje prednosti ta integracija donosi?

Opšta polazna hipoteza istraživanja glasi: OH - Odgovarajućim modelom studenta, zasnovanim na metodama analitike učenja i algoritmima mašinskog učenja, kao i modelom nastavnog sadržaja zasnovanim na ontologiji, moguće je podržati personalizovano i adaptivno (prilagodljivo) e-učenje kroz praćenje napretka studenta, organizaciju nastavnih sadržaja i formiranje preporuka za dalje učenje.

Posebne hipoteze (PH) ovog istraživanja su:

PH1: Softverski sistem koji povezuje model studenta, razvijen primenom metoda analitike učenja i algoritama mašinskog učenja nad podacima o aktivnostima i rezultatima studenata u sistemu za e-učenje, i model nastavnog sadržaja, zasnovan na objektima učenja i strukturiran korišćenjem ontologije, može da podrži praćenje napretka studenta tokom učenja, kao i dinamičko određivanje i vizualizaciju nastavnog sadržaja koji se studentu preporučuje za dalji rad.

PH2: Analiza podataka o aktivnostima i rezultatima studenata u onlajn aktivnostima učenja, primenom metoda analitike učenja i algoritama mašinskog učenja, može podržati procenu nivoa ovladanosti određenim nastavnim sadržajem i identifikaciju delova sadržaja u kojima je studentu potrebna dodatna podrška, čime se omogućava bolje usklađivanje preporučenih sadržaja sa njegovim trenutnim stanjem učenja.

PH3: Primena ontološkog modela za organizaciju objekata učenja može podržati proces personalizacije nastave i olakšati pronalaženje, povezivanje i vizualizaciju obrazovnih materijala.

PH4: Razvijeni model studenta i model nastavnog sadržaja, realizovani kao modularne komponente razdvojene od konkretnog sistema za e-učenje, mogu obezbediti jednostavniju integraciju u različite adaptivne i personalizovane kontekste e-učenja.

1.3. Doprinosi disertacije

Centralni naučni doprinos ove disertacije predstavlja razvoj i empirijska evaluacija integrisanog, sledljivog i kompetencijski zasnovanog modela personalizovanog i adaptivnog e-učenja. U ovom modelu pojedinačni dokaz iz aktivnosti provere povezuje se sa objektom učenja, ishodom učenja, kompetencijom i nivoom dubine, koristi za procenu stanja studenta i zatim, preko ontoloških relacija, za formiranje objašnjive preporuke za dalje učenje. Naučna novina nije u pojedinačnom algoritmu procene, klasterovanja ili preporuke, već u povezivanju ovih komponenti u jedinstven lanac u kome dokaz zadržava svoje semantičko značenje od nastanka do konačne preporuke. Pristupi praćenju znanja procenjuju ovladanost, ali ne određuju koji konkretan objekat učenja treba preporučiti, dok ontološki i kompetencijski modeli formalizuju strukturu nastavnog sadržaja, ali je ne povezuju sa dinamičkom procenom stanja pojedinačnog studenta (odeljak 2.4).

Pristup je razvijen iterativno. Predikcija akademskog uspeha zadržavala je rezultat na nivou završnog ishoda, klasterovanje je izdvajalo obrasce angažovanja bez dovoljno fine slike pojedinačnog studenta, a ontološki model i multidimenzionalne konceptualne mape [14] organizovali su nastavni sadržaj bez dinamičkog modela studenta. Konačni model povezuje rezultate ova tri pravca. Iz tog razloga empirijska evaluacija proverava izvodljivost, interpretabilnost, unutrašnju stabilnost i sledljivost individualnih adaptivnih odluka, a ne uzročni efekat preporuka na postignuće studenata, za koji bi bila potrebna zasebna kontrolisana studija.

Doprinosi disertacije mogu se objediniti u četiri centralna doprinosa:

I. semantički i kompetencijski model nastavnog sadržaja, koji objekte učenja povezuje sa ishodima učenja, kompetencijama, nivoima dubine i dokazima iz aktivnosti provere,
II. višeslojni interpretabilni model studenta, koji odvojeno predstavlja ovladanost kompetencijama, ostvarenost nivoa, stanje na nivou pojedinačnog objekta učenja i ponašajni kontekst,
III. sledljivi adaptivni postupak, koji identifikovane potrebe studenta povezuje sa ontološkim relacijama radi izbora i uređivanja konkretnih objekata učenja,
IV. modularna integrisana arhitektura i njena empirijska provera koncepta na stvarnim obrazovnim podacima.

Ovi doprinosi dalje se razlažu na teorijske, metodološke, softversko-arhitekturne i praktične, kao i empirijske doprinose.

1.3.1. Teorijski doprinosi

Razvoj proširivog ontološkog modela nastavnog sadržaja zasnovanog na objektima učenja.

Razvijen je i u [14] objavljen ontološki model koji nastavni sadržaj predstavlja kroz hijerarhiju oblasti znanja, jedinica znanja, tema i podtema. Objekti učenja nose konkretan sadržaj, a semantičke relacije određuju obavezni i preporučeni redosled učenja i vezu između osnovnog i naprednog sadržaja. Razdvajanjem koncepata od resursa model se može menjati i proširivati bez narušavanja strukture domena, a alat za kreiranje ontologije (engl. Ontology Authoring Tool (OAT)) [18] omogućava nastavniku da ga kreira i iterativno unapređuje. U disertaciji ovaj model predstavlja polaznu strukturu koja se proširuje kompetencijama, dokazima iz aktivnosti i modelom studenta.

Proširenje, integracija i semantička operacionalizacija kompetencijski vođenog okvira u ontološkom modelu nastavnog sadržaja.

Kompetencijski vođeni okvir [15] usvojen je kao osnova za predstavljanje kompetencija i nivoa dubine i integrisan sa ontološkim modelom [14]. Objekti učenja tako se povezuju sa ishodima učenja, kompetencijama, komponentama znanja i veština, nivoima dubine N1, N2 i N3 i dokazima iz aktivnosti provere. Element VERIFY pri tome dobija operativno značenje semantičke veze između objekta učenja i dokaza: aktivnost i njeni rezultati vode se u sistemu za upravljanje obrazovanjem, a ontologija određuje na koji objekat učenja, kompetenciju i nivo dubine se dokaz odnosi. Time ontologija nije samo model organizacije nastavnog sadržaja, već i semantička osnova za tumačenje podataka o učenju pojedinačnog studenta.

Razvoj i softverska operacionalizacija multidimenzionalne vizuelizacije ontologije i dinamičkog personalizovanog prostora za učenje.

Razvijen je pristup automatskom generisanju multidimenzionalnih konceptualnih mapa (MCM) iz ontološkog modela, čije se dimenzije formiraju na osnovu ontoloških atributa i relacija [14]. U sistemu zasnovanom na ontologiji za pronalaženje objekata učenja (engl. Ontology-Based System for Learning Object Retrieval (OBSLO)) iz ove strukture se dinamički generiše prostor za učenje. U konačnom modelu taj prostor predstavlja prezentacioni i navigacioni sloj za individualno određenu putanju učenja.

Razvoj višeslojnog, kompetencijski i ontološki utemeljenog modela studenta.

Razvijen je model studenta sa tri sloja: ovladanost kompetencijama, ostvarenost nivoa i analitika učenja. Iz njih nastaju četiri vrste izlaza: sekvencijalna procena ovladanosti, lokalni dijagnostički indikator na nivou objekta učenja, ostvarenost nivoa i ponašajni tip. Svaki izlaz zadržava vezu sa objektom učenja, kompetencijom i nivoom dubine na koje se odnosi, pa se rezultat modelovanja može tumačiti u odnosu na konkretan nastavni sadržaj (odeljak 6.5).

Razdvajanje procene ovladanosti kompetencijama od ostvarenosti nivoa.

Procena ovladanosti opisuje koliko uspešno student savladava kompetencije sa kojima je radio. Ostvarenost nivoa opisuje u kojoj meri je realizovao aktivnosti predviđene za dati nivo dubine i kakve je rezultate na njima ostvario. Njihovim razdvajanjem razlikuju se situacije koje bi u jednoj zbirnoj oceni izgledale slično, što je potvrđeno na podacima dva predmeta (odeljci 6.5.2.2 i 7.2.3).

Razdvajanje ponašajnog tipa od procene ovladanosti kompetencijama i ostvarenosti nivoa.

Ponašajni tip formira se isključivo iz atributa angažovanja i opisuje kako student radi, a ne koliko je savladao. Za razliku od ranije faze [19], u kojoj su u klasterovanje uključivani i pokazatelji rezultata, pripadnost klasteru se u konačnom modelu ne tumači kao mera znanja (odeljci 6.5.2.3 i 7.2.3).

1.3.2. Metodološki doprinosi

Definisanje semantičkog postupka transformacije aktivnosti provere znanja u strukturirane dokaze za model studenta.

Definisan je postupak kojim se rezultat aktivnosti provere, od pojedinačnog pitanja do projekta, prevodi u strukturiran dokaz. Dokaz nosi informaciju o objektu učenja, ishodu učenja, kompetenciji, nivou dubine, značaju veze i hronološkom redosledu pokušaja. Kada aktivnost obuhvata više objekata učenja, nastavnik određuje relativni značaj svake veze. Ovako strukturirani dokazi predstavljaju zajednički ulaz za sve slojeve modela studenta.

Prilagođavanje i integracija interpretabilnih postupaka za sekvencijalnu procenu ovladanosti, lokalnu dijagnostiku, ostvarenost nivoa i ponašajnu analitiku u modelu studenta.

Interpretabilni postupci prilagođeni su granularnosti i ulozi dokaza. Bajesovo praćenje znanja (engl. Bayesian Knowledge Tracing (BKT)) primenjuje se na nivou kompetencije predmeta i nivoa dubine, u kontinuiranoj formulaciji koja čuva informaciju o delimičnom uspehu. Lokalni indikator primenjuje se na nivou objekta učenja, a klasterovanje samo na ponašajne atribute. Doprinos nije novi algoritam, već povezivanje postojećih interpretabilnih postupaka nad semantički strukturiranim dokazima.

Razvoj postupka za formiranje individualnih, ontološki utemeljenih putanja za dalje učenje.

Razvijen je adaptivni postupak koji razlikuje pokušavani sadržaj sa nedovoljnom ovladanošću od nepokušavanog obaveznog sadržaja nivoa N1. Na osnovu relacija preduslova i odnosa osnovnog i naprednog sadržaja zatim formira uređenu individualnu putanju. Ponašajni tip služi kao kontekst za predstavljanje podrške, ali ne utiče na izbor ni redosled sadržaja. Postupak predstavlja dalji razvoj istraživanja personalizovanih preporuka [17], jer je izbor sadržaja u neposrednoj vezi sa dokazima pojedinačnog studenta.

Obezbeđivanje sledljivosti adaptivne odluke i razdvajanje odlučivanja od jezičkog oblikovanja objašnjenja.

Za svaki preporučeni objekat učenja može se slediti lanac od izvornog dokaza i izlaza modela studenta do pravila i ontološke relacije na osnovu kojih je uključen u putanju, pa je objašnjivost ugrađena u sam postupak odlučivanja. Veliki jezički model (engl. Large Language Model (LLM)), kada se koristi, samo jezički oblikuje već doneto obrazloženje i ne može da menja izbor ni redosled preporučenih sadržaja.

1.3.3. Softversko-arhitekturni i praktični doprinosi

Razvoj modularne softverske arhitekture za integraciju modela nastavnog sadržaja, modela studenta i adaptivnog mehanizma.

Razvijena je modularna arhitektura koja postojeći sistem za učenje i sistem za upravljanje obrazovanjem povezuje sa OBSLO-om preko servisnih interfejsa [20]. Analitičke i adaptivne funkcionalnosti tako se uvode kao dodatni sloj, bez zamene postojećeg LMS-a. Arhitektura demonstrira povezivanje sa postojećom institucionalnom infrastrukturom, ali se ne tumači kao empirijski potvrđena interoperabilnost sa proizvoljnim LMS platformama.

Softverska implementacija ontološki zasnovanog prostora za rad sa objektima učenja.

Ontološki model i MCM implementirani su u OBSLO-u i njegovoj komponenti za kreiranje MCM okruženja za učenje (engl. MCM Learning Environment Creator (MCMLEC)) [14], koja omogućava automatsko generisanje prikaza, navigaciju i dinamičku isporuku objekata učenja. U konačnoj arhitekturi ovaj prostor zadržan je kao prezentacioni i navigacioni sloj, povezan sa modelom studenta i adaptivnim mehanizmom.

Softverska operacionalizacija modela studenta i adaptivnog mehanizma za formiranje i prikaz individualnih preporuka.

Model studenta i adaptivni postupak implementirani su kao softverske komponente čiji su rezultati objedinjeni u kontrolnoj tabli. Ona prikazuje ponašajni tip, procene ovladanosti, ostvarenost nivoa, sadržaje za podršku, individualnu putanju, profil kompetencija i položaj preporučenih objekata u ontološkom prostoru.

1.3.4. Empirijski doprinosi

Empirijska evaluacija i iterativno unapređenje ontološkog modela i multidimenzionalnih konceptualnih mapa u stvarnom nastavnom okruženju.

Ontološki model i MCM [14] evaluirani su kroz dve iteracije: poređenjem sa linearnim LAMS okruženjem i analizom putanja studenata kroz objekte učenja. Podaci o korišćenju iskorišćeni su za unapređenje same ontologije. Razlike u odnosu na LAMS tumače se kao deskriptivne, a ne uzročne, jer potiču iz različitih realizacija predmeta.

Empirijska evaluacija višeslojnog modela studenta i ontološki utemeljenog adaptivnog postupka na stvarnim obrazovnim podacima.

Model je primenjen na podatke dva predmeta različite prirode. Pokazano je da ovladanost, ostvarenost nivoa i ponašajni obrazac pružaju različite i komplementarne informacije, i da su ključne projektne odluke stabilne pri proverama osetljivosti, unakrsnoj validaciji i promenama uzorka. Pokazano je i da ontološki utemeljen redosled čuva semantičke zavisnosti koje rangiranje samo prema procenjenoj ovladanosti zanemaruje. Rezultati se ne tumače kao potvrda spoljašnje generalizacije.

Empirijska evaluacija percipirane razumljivosti, relevantnosti i korisnosti individualnih objašnjivih preporuka.

Kontrolnu tablu i preporuke ocenilo je 86 studenata sa dva predmeta. Percepcija razumljivosti, relevantnosti i korisnosti obrazloženja bila je pretežno pozitivna, uz visoku

unutrašnju konzistentnost upitnika. Ovi rezultati pokazuju percipiranu prihvatljivost pristupa, a ne njegovu nastavnu efikasnost.

1.4. Zadaci istraživanja

Radi ostvarivanja postavljenih ciljeva i ispitivanja hipoteza bilo je potrebno razviti i evaluirati pristup koji povezuje podatke o aktivnostima i rezultatima studenata sa formalno organizovanim nastavnim sadržajem. Istraživanje je polazilo od pretpostavke da podaci dostupni u sistemima za e-učenje mogu da pruže detaljniji uvid u stanje pojedinačnog studenta, ali da njihova primena u personalizovanom učenju zahteva povezivanje sa konkretnim objektima učenja, kompetencijama, ishodima učenja i odnosima između nastavnih sadržaja.

Prvi zadatak istraživanja odnosio se na analizu relevantne literature i postojećih rešenja u oblastima personalizovanog i adaptivnog e-učenja, modelovanja nastavnog sadržaja, ontologija, objekata učenja, modelovanja studenata, analitike učenja, obrazovnog rudarenja podataka i sistema preporučivanja. Cilj ove analize bio je da se utvrde mogućnosti postojećih pristupa, ali i njihova ograničenja u povezivanju procenjenog stanja studenta sa konkretnim sadržajem koji mu treba preporučiti.

Drugi zadatak obuhvatio je definisanje i razvoj ontološkog modela nastavnog sadržaja. Bilo je potrebno odrediti nivoe granularnosti nastavnog domena, strukturu objekata učenja i relacije kojima se predstavljaju hijerarhija sadržaja, veze između koncepata i objekata učenja, redosled izučavanja, odnosi između osnovnih i naprednih sadržaja i veze sa pojedinačnim nastavnim resursima. Model je projektovan tako da omogućava proširivanje i ponovno korišćenje sadržaja bez narušavanja osnovne strukture domena.

Treći zadatak odnosio se na razvoj načina vizuelizacije ontološkog modela i njegovo uključivanje u personalizovani prostor za učenje. U tu svrhu razvijen je pristup zasnovan na multidimenzionalnim konceptualnim mapama, kojim se složena struktura nastavnog domena prikazuje postepeno, u skladu sa izabranom oblašću, temom, nivoom znanja i trenutnim potrebama studenta. Razvijeno rešenje implementirano je u softverskom sistemu i evaluirano kroz rad studenata sa ontološki organizovanim nastavnim sadržajem.

Četvrti zadatak bio je proširenje osnovnog ontološkog modela kompetencijama, ishodima učenja, znanjem, praktičnim veštinama, nivoima dubine i dokazima iz aktivnosti provere znanja. Time je bilo potrebno uspostaviti vezu između strukture nastavnog sadržaja i podataka koji nastaju tokom provere znanja i veština. Posebna pažnja posvećena je mapiranju pitanja,

testova, ocenjenih zadataka, projekata i eseja na odgovarajuće objekte učenja, kompetencije i nivoe dubine.

Peti zadatak obuhvatio je istraživanje mogućnosti primene analitike učenja i algoritama mašinskog učenja za razvoj modela studenta. U početnim fazama analizirani su pristupi zasnovani na predikciji studentskog uspeha i klasterovanju studenata. Njihova primena omogućila je identifikovanje faktora povezanih sa uspehom i obrazaca studentskog angažovanja, ali je istovremeno ukazala na ograničenja modela koji stanje studenta predstavljaju samo završnim ishodom, oznakom rizika ili pripadnošću određenoj grupi.

Šesti zadatak bio je razvoj konačnog višeslojnog modela studenta, kojim se rezultati aktivnosti pretvaraju u interpretabilan prikaz trenutnog stanja učenja. Model je trebalo da omogući sekvencijalnu procenu ovladanosti kompetencijama, prikaz ostvarenosti aktivnosti prema nivoima dubine, lokalne procene na nivou pojedinačnih objekata učenja, evidentiranje statusa pokušaja i identifikovanje ponašajnih obrazaca studenata. Time se obezbeđuju podaci potrebni da adaptivni sloj razlikuje pokušani sadržaj kod kojeg procena ukazuje na nedovoljnu ovladanost od nepokušavanog obaveznog sadržaja za koji procena ovladanosti ne postoji. Pri tome je bilo važno jasno razlikovati demonstrirano ovladavanje sadržajem, ostvarenost predviđenih aktivnosti i način na koji student pristupa radu.

Sedmi zadatak odnosio se na razvoj adaptivnog modela kojim se izlazi modela studenta povezuju sa relacijama ontološkog modela. Bilo je potrebno definisati postupak kojim se kao početni kandidati za podršku razlikuju pokušani objekti sa procenom ovladanosti nižom od odgovarajućeg praga i nepokušani obavezni objekti učenja. Tako formiran skup trebalo je povezati sa relacijama preduslova i redosleda i relacijama između osnovnog i naprednog sadržaja radi formiranja uređene putanje učenja. Dodatni zahtev bio je da izbor i redosled preporučenih objekata ostanu sledljivi do podataka, pravila i ontoloških relacija na kojima su zasnovani i da se studentu i nastavniku mogu prikazati u razumljivom obliku. Jezičko formulisanje objašnjenja pri tome je trebalo razdvojiti od same adaptivne odluke.

Osmi zadatak obuhvatio je implementaciju i evaluaciju razvijenih modela. Ontološki model i multidimenzionalne konceptualne mape evaluirani su kroz poređenje sa linearnim nastavnim okruženjem, analizu studentskih putanja i povratne informacije korisnika. Konačni model studenta i adaptivni sloj instancirani su na podacima dva predmeta različita prema domenu i strukturi aktivnosti. Ispitane su mogućnosti formiranja interpretabilnih procena ovladanosti, razlikovanja ovladanosti od ostvarenosti nivoa, identifikovanja individualnih profila i

ponašajnih obrazaca, lokalizovanja sadržaja kojima je potrebna podrška i generisanja ontološki utemeljenih objašnjivih preporuka. Stabilnost ključnih odluka modelovanja proverena je analizama osetljivosti pragova na nivou procena ovladanosti i individualnih prioriteta preporuke, analizom alternativnog ponderisanja dokaza, petostrukom unakrsnom validacijom procena ovladanosti, poređenjem kontinuirane i binarne BKT formulacije, strukturnim poređenjem ontološki uređene putanje sa referentnim redosledom zasnovanim samo na proceni ovladanosti, kao i analizama robustnosti ponašajnog klasterovanja pri promeni uzorka, metode i skupa ulaznih atributa. Evaluacija je dopunjena povratnim informacijama studenata o razumljivosti, relevantnosti i percipiranoj korisnosti kontrolne table, preporuka i objašnjenja. Ova evaluacija predstavlja proveru koncepta i ne koristi se kao dokaz uzročnog uticaja preporuka na znanje, akademski uspeh ili angažovanje studenata.

Realizacijom navedenih zadataka postepeno su razvijene i povezane tri osnovne komponente istraživanja: model nastavnog sadržaja, model studenta i adaptivni model. Njihova integracija omogućila je da se podaci prikupljeni tokom učenja prevedu u interpretabilne procene stanja studenta i zatim povežu sa konkretnim nastavnim sadržajima koji mogu da podrže njegov dalji rad.

1.5. Pregled sadržaja rada

Disertacija je organizovana u osam sadržajnih poglavlja, nakon kojih sledi literatura.

Poglavlje 1 uvodi u istraživanje: definiše predmet istraživanja i predstavlja ciljeve, istraživačka pitanja, hipoteze, doprinose i zadatke istraživanja. U ovom poglavlju obrazložena je potreba za razvojem modela studenta koji podatke o aktivnostima, rezultatima i proverama znanja tumači u odnosu na strukturu nastavnog sadržaja, a ne samo na nivou agregiranih pokazatelja uspeha. Takođe je prikazana veza između modela studenta, modela nastavnog sadržaja i formiranja preporuka za dalje učenje.

Pregled relevantne literature dat je u Poglavlju 2 i obuhvata oblasti personalizovanog i adaptivnog e-učenja, modelovanja nastavnog sadržaja, ontološkog modelovanja, modelovanja studenta, analitike učenja, algoritama mašinskog učenja i obrazovnih sistema preporuka. Posebna pažnja posvećena je pristupima koji povezuju podatke o učenju, ishode učenja, provere znanja, procenu ovladanosti nastavnim sadržajem i preporuke za dalje učenje. Razmatraju se i savremeni pristupi objašnjivoj veštačkoj inteligenciji u obrazovanju, kao osnova za interpretabilnije tumačenje rezultata modela studenta i preporuka.

Metodologija istraživanja predstavljena je u Poglavlju 3. Objašnjen je izbor metodologije nauke o projektovanju kao istraživačkog okvira za razvoj i evaluaciju predloženih modela. Prikazano je mapiranje faza metodologije na poglavlja disertacije, kao i vremensko i prostorno određenje istraživanja i podaci korišćeni u radu. Predstavljene su i metode korišćene u razvoju modela studenta, uključujući analitiku učenja, metode praćenja znanja (engl. knowledge tracing) za procenu ovladanosti nastavnim sadržajem, agregaciju pokazatelja provera znanja i klasterovanje obrazaca učenja.

Poglavlje 4 daje teorijski okvir za postavljanje problema. Razmatraju se osnovni koncepti ontološkog modelovanja nastavnog sadržaja, vizualizacije korišćenjem MCM, modelovanja studenta i metoda za procenu trenutnog stanja učenja u sistemima za e-učenje. Posebno su obrađeni pristupi koji omogućavaju procenu nivoa ovladanosti nastavnim sadržajem, uključujući BKT, kao i metode analitike učenja i klasterovanja koje se koriste za tumačenje aktivnosti i rezultata studenata.

Model nastavnog sadržaja zasnovan na ontologiji objekata učenja predstavljen je u Poglavlju 5. Opisana je struktura ontološkog modela, ključni nastavni elementi, relacije između njih i mogućnosti proširenja modela različitim dimenzijama, kao što su nivoi znanja, ishodi učenja, provere znanja i, po potrebi, kompetencije. Posebno je prikazan pristup vizualizaciji ontološkog modela korišćenjem MCM, kao i mogućnost dinamičkog kreiranja personalizovanog prostora za učenje.

Poglavlje 6 posvećeno je modelu studenta i njegovom iterativnom razvoju kroz tri faze istraživanja. Prve dve faze obuhvataju predikciju akademskog uspeha i analizu obrazaca studentskog angažovanja, dok je u trećoj fazi razvijen konačni višeslojni model kontinuiranog praćenja. Model objedinjuje sekvencijalnu procenu ovladanosti kompetencijama primenom BKT-a na nivou kombinacije *predmet-kompetencija predmeta-nivo dubine*, odvojenu procenu ostvarenosti aktivnosti prema nivoima dubine, lokalne procene i status pokušaja na nivou objekata učenja i ponašajno klasterovanje. Posebno je prikazana arhitektura koja povezuje model studenta sa kompetencijski proširenim ontološkim modelom nastavnog sadržaja i adaptivnim mehanizmom.

Rezultati istraživanja i njihova diskusija izloženi su u Poglavlju 7. Predstavljena je evaluacija ontološkog modela nastavnog sadržaja, multidimenzionalnih konceptualnih mapa i personalizovanog prostora za učenje, kao i rezultati sve tri faze razvoja modela studenta. Za konačni model prikazane su procene ovladanosti i ostvarenosti nivoa, individualni profili,

ponašajni tipovi i fino granularno identifikovanje sadržaja kojima je potrebna dodatna podrška. Stabilnost rezultata analizirana je proverama osetljivosti i unakrsnom validacijom BKT procena, kao i analizama robustnosti ponašajnog klasterovanja. U završnom delu poglavlja prikazano je kako adaptivni mehanizam povezuje stanje studenta sa ontološkim relacijama radi formiranja uređene i objašnjive preporuke, kao i rezultati evaluacije kontrolne table od strane studenata.

Poglavlje 8 donosi zaključke istraživanja, pregled ispunjenosti ciljeva i hipoteza, prednosti razvijenog pristupa, ograničenja istraživanja i smernice za budući rad. Završno poglavlje sumira doprinos disertacije u razvoju i povezivanju modela studenta i ontološkog modela nastavnog sadržaja za potrebe personalizovanog e-učenja.

Poglavlje 2

2. Pregled relevantne literature

2.1. Personalizovano i adaptivno učenje

Jedinstven pristup obrazovanju nije dovoljan da zadovolji potrebe studenata i društva u celini, pa mnoge institucije sve više usvajaju personalizovano učenje kako bi bolje odgovorile na raznolike potrebe studenata [21]. Savremeno visoko obrazovanje u velikoj meri se oslanja na digitalna okruženja za učenje, ali povećana dostupnost digitalnih nastavnih materijala i podataka o studentskim aktivnostima sama po sebi ne obezbeđuje personalizaciju obrazovnog procesa. U tradicionalnim sistemima za upravljanje učenjem nastavni sadržaji se i dalje često isporučuju u unapred definisanom i pretežno linearnom redosledu, uz ograničeno prilagođavanje prethodnom znanju, tempu rada, performansama i napredovanju pojedinačnog studenta. Personalizovano adaptivno učenje nastoji da prevaziđe ovo ograničenje korišćenjem podataka o studentu, njegovim aktivnostima i rezultatima, kao i informacija o nastavnom sadržaju, radi prilagođavanja daljeg procesa učenja [22,23]. E-učenje, ili elektronsko učenje, odnosi se na upotrebu digitalnih tehnologija za podršku učenju na daljinu ili u kombinaciji sa tradicionalnim metodama nastave. U kontekstu ove disertacije, e-učenje podrazumeva upotrebu digitalnih alata i platformi za isporuku personalizovanih i adaptivnih obrazovnih sadržaja koji su prilagođeni individualnim potrebama svakog studenta.

Personalizacija u učenju je obrazovni pristup koji prilagođava iskustva učenja individualnim potrebama, veštinama, predznanju i interesovanjima svakog studenta. Ovaj koncept nije nov i vuče korene iz prošlosti, sa idejama poput onih koje je predložio Ruso u 18. veku, koji je zagovarao obrazovanje usmereno na studenta [24]. Dewey [25], početkom 20. veka, naglašavao je važnost korišćenja prethodnog znanja studenta za planiranje nastave, dok su Montesori i Blum isticali značaj prilagođenog i kolaborativnog učenja [26,27]. Danas se personalizacija razvija kao šira inicijativa koja obuhvata celoživotno učenje, sa ciljem preoblikovanja društvenih i ekonomskih okvira. UNESCO je prepoznao važnost personalizovanog učenja u rešavanju obrazovnih nejednakosti [28].

Dolaskom digitalnog doba, personalizacija u učenju se proširuje kroz razvoj personalizovanih digitalnih sistema. Personalizovani sistemi e-učenja su digitalne platforme ili aplikacije koje koriste podatke i tehnologije, poput veštačke inteligencije i analitike učenja, kako bi kreirale i prilagodile obrazovne sadržaje i aktivnosti specifičnim potrebama svakog studenta. Ovi sistemi kombinuju tehnologiju, podatke i algoritme kako bi pružili iskustvo učenja prilagođeno svakom studentu. Koristeći podatke o prethodnim znanjima, obrascima učenja, interesima i performansama studenta, personalizovani sistemi prilagođavaju sadržaj, aktivnosti i tempo učenja [29,30]. Personalizovani sistemi e-učenja omogućavaju studentima da napreduju u svom ritmu, fokusirajući se na svoje specifične potrebe i interesovanja. Oni često koriste metode analitike učenja i mašinskog učenja kako bi analizirali podatke i predložili personalizovane resurse, zadatke i aktivnosti, uključujući adaptivno preporučivanje sadržaja, individualizaciju rasporeda učenja, pružanje podrške u realnom vremenu i prilagođavanje formativnih provera znanja poput testova, kvizova i slično [31,32].

Pojmovi personalizovano i adaptivno učenje u literaturi se delimično preklapaju, a granice između njih nisu uvek jednoznačno određene. U okviru ove disertacije, personalizovano učenje posmatra se kao širi obrazovni pristup u kome se sadržaji, aktivnosti, putanje i podrška prilagođavaju karakteristikama i potrebama pojedinačnog studenta, dok se adaptivno učenje odnosi na dinamički mehanizam kojim sistem menja određene elemente procesa učenja na osnovu procenjenog stanja i napredovanja studenta. Adaptivni sistemi mogu pri tome kombinovati podatke poznate pre početka učenja, kao što su prethodno znanje i karakteristike studenta, sa podacima koji nastaju tokom procesa učenja, uključujući rezultate provera, aktivnosti, ponašanje i interakcije sa nastavnim sadržajem [32–35]. Na osnovu takvih podataka mogu se prilagođavati izbor i redosled sadržaja, tempo rada, nivo složenosti, aktivnosti i povratne informacije. Istraživanja pokazuju da adaptivni pristupi mogu pozitivno uticati na angažovanost i akademski učinak studenata [36–38], ali efekat adaptacije zavisi i od načina projektovanja nastavnog procesa, povezanosti sa ciljevima učenja i aktivnosti provere, kvaliteta povratne informacije i institucionalnog konteksta u kome se sistem primenjuje [39–41]. Zbog toga se u ovoj disertaciji adaptivni sistem ne posmatra samo kao tehnološki mehanizam za dinamičku isporuku sadržaja, već kao sistem u kome se odluka o prilagođavanju zasniva na eksplicitnoj vezi između strukturiranog nastavnog sadržaja i procenjenog stanja studenta.

U širem kontekstu inteligentnih obrazovnih sistema, personalizovani i adaptivni mehanizmi predstavljaju i važne komponente inteligentnih tutorskih sistema (engl. Intelligent Tutoring

System (ITS)). ITS su računarski sistemi koji pružaju personalizovanu nastavu i povratne informacije studentima, imitujući ponašanje ljudskog tutora i kao takvi predstavljaju naprednu primenu personalizovanih i adaptivnih pristupa [42,43]. Oni su projektovani da prepoznaju obrasce u učenju studenata i prilagode nastavne strategije kako bi optimizovali proces učenja.

Personalizovani sistemi, adaptivni sistemi i ITS nisu međusobno isključive kategorije, već se razlikuju prvenstveno prema dominantnoj funkcionalnosti. Kod personalizovanih sistema u prvom planu je prilagođavanje iskustva učenja individualnim osobinama, potrebama i preferencijama studenata, kod adaptivnih sistema dinamička promena sadržaja i aktivnosti na osnovu učinka i napredovanja studenta, a kod ITS-a imitiranje ljudskog tutora kroz povratne informacije i smernice u realnom vremenu. U praksi se ove karakteristike često preklapaju, pa isti sistem može istovremeno biti personalizovan, adaptivan i imati tutorske funkcije. ITS po pravilu koriste i adaptivne i personalizovane mehanizme, ali ih stavljaju u službu tutorskog vođenja studenta kroz rešavanje zadataka. Zbog toga se ove kategorije u disertaciji ne koriste kao stroga klasifikacija sistema, već kao opis dominantne funkcije pojedinih sistema i njihovih komponenti.

U ovoj disertaciji termin inteligentni sistemi e-učenja koristi se u širem smislu definisanom u Poglavlju 1 i obuhvata personalizovane sisteme i ITS, sisteme koji na osnovu podataka o učenju kontinuirano prate napredak i prilagođavaju podršku pojedinačnom studentu. Razvoj ITS-a kao celine nije predmet ove disertacije, ali su razvijeni modeli projektovani tako da mogu biti integrisani u takve sisteme kao njihovi adaptivni i personalizovani moduli.

Postoje različiti tipovi personalizacije koji se primenjuju u adaptivnim sistemima e-učenja kako bi se prilagodio proces učenja svakom pojedinačnom studentu na osnovu njegovih osobina i preferencija. Različiti naučni radovi i istraživanja ističu različite vidove personalizacije u adaptivnim sistemima e-učenja, koje generalno možemo podeliti na sledeće kategorije [3,44–46]:

- **Personalizacija sadržaja (engl. content personalization)**: Ovaj tip personalizacije se odnosi na prilagođavanje sadržaja učenju na osnovu individualnih potreba i preferencija studenta. To može uključivati pružanje prilagođenih resursa, materijala ili literature koji su relevantni interesovanjima i nivou znanja svakog studenta [47,48]. Personalizacija sadržaja omogućava studentima da se fokusiraju na specifične oblasti koje ih zanimaju ili da tokom učenja prate sopstveni tempo, ali i koriste različite formate medija za sam proces učenja (tekst, audio, video). Preporuka

sadržaja kao vid personalizacije nekada može značiti i preporuku čitavog predmeta kao skupa obrazovnih objekata prilagođenih potrebama studenta putem sistema preporuka, koja pruža relevantan i personalizovan obrazovni sadržaj [49,50].

- **Personalizovana/adaptivna isporuka sadržaja (engl. content delivery)**: Ova vrsta personalizacije se odnosi na prilagođavanje tempa, redosleda i nivoa isporuke sadržaja za učenje. Isporuka uključuje primenu različitih strategija kako bi se studentima pomoglo da bolje razumeju koncept, kao što su predavanja, učenje kroz igru, tutorijali i slično [51]. Pored toga, adaptacija u obrazovnim sistemima može se postići i kroz korisnički interfejs (UI), koji omogućava studentima intuitivnu i personalizovanu interakciju sa obrazovnim sadržajem. Različite vrste korisničkih interfejsa, kao što su grafički, senzorni ili glasovni interfejsi, mogu se koristiti za prilagođavanje iskustva učenja individualnim potrebama studenta, čime se dodatno poboljšava proces personalizacije i adaptacije učenja [47,52]. Adaptivna isporuka može se ostvariti i putem personalizovane putanje učenja [53–56], gde se organizuju aktivnosti u skladu sa individualnim potrebama studenta, i kroz strategiju učenja [57–60], koja prilagođava ne samo redosled, već i tip obrazovnih objekata koji se koriste u nastavi.
- **Individualizacija zadatka i provera znanja (engl. assessment personalization):** Ova vrsta personalizacije se odnosi na prilagođavanje zadatka ili aktivnosti učenju svakog pojedinačnog studenta. To može uključivati prilagođavanje nivoa težine, vrste zadatka ili pristupa koji se koristi u zavisnosti od sposobnosti i preferencija studenta. Personalizacija zadatka omogućava studentima da se suoče sa izazovima koji su adekvatni za njihov nivo znanja i sposobnosti [61–63]. Provere znanja se pri tome posmatraju kao sastavni deo procesa učenja i izvor podataka za kontinuirano praćenje napretka, a ne samo kao završno ocenjivanje. U adaptivnom sistemu rezultati takvih aktivnosti imaju dodatnu funkciju, jer predstavljaju dokaz na osnovu koga se može ažurirati procena stanja studenta. Da bi rezultat provere mogao da se koristi za donošenje odluke o daljem učenju, potrebno je eksplicitno povezati aktivnost provere sa odgovarajućim ishodom učenja, kompetencijom i delom nastavnog sadržaja na koji se ona odnosi. Na taj način pojedinačni rezultat ne ostaje samo izolovana ocena, već postaje strukturirani dokaz o tome kojim znanjem ili veštinom student ovladava i gde mu je potrebna dodatna podrška. Savremeni pristupi projektovanju adaptivnog učenja upravo naglašavaju povezanost nastavnih jedinica, ishoda, aktivnosti provere, povratne informacije i podataka o učenju [40,64].

- **Prilagođeno praćenje i povratne informacije (engl. feedback personalization):** Ovaj tip personalizacije omogućava praćenje individualnog napredovanja studenta i pruža relevantne povratne informacije u vidu preporuka za poboljšanje ili pohvala za postignuća, pružajući podršku i smernice za dalje učenje [65,66]. U tom procesu značajnu ulogu ima analitika učenja, koja omogućava da se podaci nastali kroz studentske aktivnosti i provere transformišu u informacije o napredovanju, obrascima angažovanja i potencijalnim poteškoćama [67]. Za potrebe adaptacije mogu se kombinovati podaci dostupni pre procesa učenja, kao što su prethodno znanje i profil studenta, sa podacima nastalim tokom učenja, kao što su rezultati aktivnosti, tempo rada i interakcije sa nastavnim sadržajem. Takvo kontinuirano praćenje omogućava da povratna informacija ne bude samo retrospektivna, već da predstavlja osnovu za preporuku naredne aktivnosti ili nastavnog sadržaja [64].

Da bi digitalni sistemi e-učenja podržali gore navedene elemente personalizacije, personalizovani sistemi e-učenja integrišu nekoliko ključnih komponenti kako bi pružili prilagođeno iskustvo učenja [4,68]:

- Model studenta (engl. Student/Learner model): Ova komponenta predstavlja digitalni profil studenata, koji prikuplja i analizira podatke kao što su rezultati testova, ocene, prethodna znanja, obrasci učenja i interesi. Analitički alati, koristeći algoritme i metode analitike učenja i mašinskog učenja, obrađuju ove podatke kako bi identifikovali obrazovne potrebe, snage i slabosti studenata, te prilagodili učenje individualnim potrebama. Pri tome, pristupi zasnovani na grupisanju studenata prema zajedničkim karakteristikama imaju ograničenu preciznost na nivou pojedinca, zbog čega savremena istraživanja naglašavaju modelovanje znanja i napretka pojedinačnog studenta [69].
- Struktura nastavnih materijala (engl. Instructional design), odnosno model nastavnog sadržaja: Ova komponenta se odnosi na nastavne materijale koji su dinamički prilagodljivi potrebama svakog studenata. Sadržaj može biti u različitim formatima, poput teksta, videa, simulacija, i mora biti strukturiran tako da odgovara individualnom napretku i obrascima učenja studenata.
- Personalizovani sistemi preporuka (engl. Personalized Recommendation Systems): Na osnovu analize podataka, ovi sistemi preporučuju resurse, zadatke i aktivnosti prilagođene interesima i nivou znanja svakog pojedinačnog studenta [70]. Oni omogućavaju dinamičko prilagođavanje sadržaja i aktivnosti, uključujući stilove

predstavljanja materijala, kako bi se studenti motivisali i aktivno učestvovali u procesu učenja. Ovi sistemi često koriste alate za analizu učenja (engl. Learning Analytics Tools) kako bi pratili napredak studenata i pružili povratne informacije u realnom vremenu, omogućavajući dodatnu podršku tamo gde je potrebna. U arhitekturi adaptivnih sistema, ova komponenta odgovara adaptivnom modelu, prikazanom na Slici 1. Personalizacija se, međutim, može posmatrati i iz perspektive kompetencija koje student treba da stekne, a ne samo njegovih karakteristika, interesovanja ili prethodnih rezultata. Kompetencijski zasnovan pristup omogućava da se nastavnim sadržajima pridruže eksplicitno definisani ishodi učenja, znanja i praktične veštine, čime se stvara osnova za povezivanje sadržaja koji student koristi, aktivnosti kojima se proverava njegovo znanje i stanja koje se o studentu procenjuje. U kompetencijski vođenom modelu personalizovanog učenja nastavni sadržaj se može organizovati kroz obavezne i opcione kompetencije, dok se kompetencijski prostor može posmatrati kroz dve povezane dimenzije: širinu kompetencija, koja se odnosi na obuhvat tema i kompetencija, i dubinu kompetencija, koja predstavlja nivo do kojeg se znanje i veštine razvijaju. Na taj način personalizacija ne podrazumeva samo izbor različitog sadržaja za različite studente, već omogućava i formiranje različitih kompetencijskih profila prema obimu i dubini savladanog sadržaja [15].

U okviru ovog istraživanja pregled literature usmeren je na komponente potrebne za povezivanje personalizovanog i adaptivnog učenja u jedinstven model. Poseban značaj imaju strukturiranje nastavnog sadržaja i njegova povezanost sa ishodima učenja i kompetencijama, prikupljanje dokaza iz studentskih aktivnosti i provera znanja i veština, modelovanje trenutnog stanja i napredovanja studenta, kao i korišćenje tako dobijenih informacija za izbor i preporuku narednih nastavnih sadržaja. Ovakva perspektiva polazi od toga da adaptacija ne predstavlja izolovanu funkcionalnost sistema preporuka, već proces u kome su odluke o daljem učenju zasnovane na vezi između modela nastavnog sadržaja i dinamičkog modela studenta. Stoga je nastavak pregleda literature organizovan u skladu sa ključnim elementima tog procesa: u odeljku 2.2 razmatraju se modeli sadržaja za učenje, njihovo strukturiranje i preporuka nastavnih materijala, dok se u odeljku 2.3 razmatraju modeli studenta i tehnike koje omogućavaju procenu znanja, napredovanja i ponašanja studenata.

2.2. Modeli sadržaja za učenje

2.2.1. Kreiranje nastavnih materijala

Personalizovano i adaptivno učenje zahteva fleksibilno organizovane nastavne materijale koji mogu biti odabrani, kombinovani i isporučeni u skladu sa individualnim potrebama i trenutnim stanjem studenta [71]. Adaptivni i personalizovani sistemi e-učenja zahtevaju pažljivo planiranje i organizaciju nastavnih materijala kako bi se postigao maksimalan efekat učenja. Loše je rešenje samo kopirati obrazovne materijale koji su se pokazali efikasnim za jednu grupu studenata i primeniti ih na drugu grupu u drugačijem kontekstu. Ograničenu prenosivost obrazaca učenja između različitih obrazovnih konteksta potvrdila su i istraživanja autora sprovedena nad podacima dve visokoškolske institucije iz različitih zemalja [19].

Dva modela koja se pominju u literaturi i omogućavaju organizaciju nastavnih materijala su model sadržaja (engl. content model) i model domena (engl. domain model). Model sadržaja je fokusiran na stvarni obrazovni materijal koji se pruža studentima i može da uključuje objekte učenja, multimedijalne resurse i nastavni sadržaj struktuiran da zadovolji specifične ciljeve učenja [72]. Model domena predstavlja strukturu znanja koja obuhvata koncepte, teme i veštine koje studenti treba da savladaju. Ovaj model može da koristi ontologije, taksonomije ili kognitivne mape kako bi definisao koncepte i njihove međusobne odnose unutar određene oblasti znanja. U kontekstu adaptivnog e-učenja, model domena pomaže u prilagođavanju sadržaja na osnovu trenutnog stanja znanja i kompetencija studenata [69,73]. Ova podela nije striktna, jer autori model sadržaja i model domena smatraju i sinonimom s obzirom na to da ova dva modela rade zajedno kako bi obezbedili fleksibilnost i prilagodljivost obrazovnih materijala prema individualnim potrebama studenata u adaptivnim i personalizovanim sistemima [74]. U tom smislu, zajednička definicija model sadržaja i domena identifikuje kao osnovu znanja ili sadržaj predmeta [75], koji može sadržati i međusobno povezane koncepte i uključivati mapu učenja koja prikazuje odnose između različitih ideja i način na koji se predmet isporučuje studentima [76]. Za potrebe adaptivnog učenja, međutim, nije dovoljno da model sadržaja opisuje samo koje nastavne jedinice i resursi postoje. Potrebno je predstaviti i njihove pedagoške i semantičke veze: koje ishode učenja podržavaju, koje kompetencije razvijaju, kakav je njihov međusobni odnos i kojim aktivnostima se može proveriti da li je student odgovarajućim sadržajem ovladao. Na taj način model sadržaja postaje strukturna osnova za povezivanje nastavnih materijala sa dinamičkim modelom studenta i adaptivnom odlukom. U pristupu razvijenom u ovoj disertaciji ta veza ostvaruje se povezivanjem objekata učenja sa

ishodima učenja, kompetencijama, komponentama znanja i veštine, nivoima dubine i dokazima iz aktivnosti provera znanja [14,15].

2.2.2. Objekti učenja

Visokokvalitetan obrazovni sadržaj, prilagođen specifičnim potrebama studenata i isporučen na personalizovan način, predstavlja jedan od izazova za izgradnju održivog i efikasnog sistema za e-učenje [77]. Većina obrazovnih materijala koji se nalaze u veb okruženju ili na portalima za učenje su u vidu digitalnih objekata [72]. Pod digitalnim obrazovnim resursima podrazumevamo sve digitalne obrazovne sadržaje, bilo sirove ili obrađene, osnovne ili agregirane, koji pružaju informacije studentu o domenu znanja koji se uči. Iako ne postoji standardna definicija šta je obrazovni resurs, digitalni obrazovni resursi mogu uključivati tekst, zvuk, grafičke slike, fotografije, video zapise, simulacije, animacije, objekte učenja, programirane module za učenje, formativne provere znanja, itd. Digitalni objekti, kao što su tekst, zvuk, grafike, video zapisi, simulacije i animacije, a koriste se u obrazovnim okruženjima, organizuju se u objekte učenja koji predstavljaju male, ponovno upotrebljive delove nastavnog materijala [78–82]. U [83], autori su razlikovali ponovno upotrebljivi objekat učenja (engl. Reusable Learning Object (RLO)) od deljivog objekta učenja (engl. Sharable Learning Object (SLO)). Definisali su RLO kao objekat koji ima osnovna svojstva obrazovno ispravnog sadržaja, sa jasnim ciljem i koji se može koristiti na platformi za učenje. Sa druge strane, SLO je RLO, sa dovoljno metapodataka koji mogu da pomognu u interakcijama sa drugim platformama za učenje u pretragama i boljem strukturiranju sadržaja. Kako bi se omogućila ponovna upotreba, pristupačnost, interoperabilnost i upravljanje, važno je strukturirati obrazovni materijal na način da se njegov sadržaj može podeliti na manje modularne jedinice koje se nazivaju objektima učenja (engl. Learning Objects) [84].

Objekti učenja koji čine osnovu mnogih personalizovanih sistema za e-učenje mogu sadržati jedan ili više tipova datoteka, jednu ili više aktivnosti, ali je sve to uključeno u sam objekat učenja kako bi se postiglo bolje razumevanje jednog ili više obrazovnih ciljeva [85]. Važna svojstva idealnih objekata učenja su ponovna upotrebljivost, modularnost, interoperabilnost, prenosivost i obrazovni cilj. Ponovno upotrebljivi objekti učenja, za razliku od deljivih, imaju jasne obrazovne ciljeve i mogu se koristiti na različitim platformama [83]. Da bi se lako koristili na različitim platformama, objekti učenja se obično pridržavaju određenog standarda poput SCORM-a (engl. Sharable Content Object Reference Model) [86] ili DITA (engl. Darwin Information Typing Architecture) [87] standarda radi ponovne upotrebljivosti i prenosivosti

između različitih platformi za učenje, čime se olakšava razmena i ponovna upotreba sadržaja. DITA pruža dva strukturna elementa: (i) teme, koje se koriste za opisivanje pregleda, sažetka ili određenih delova lekcije, vežbi, zadataka, studija slučaja, i (ii) mape, koje se koriste za određivanje izabranog modela učenja [88]. U kontekstu ove disertacije važno je razlikovati tehničko strukturiranje nastavnog sadržaja od njegovog semantičkog modelovanja. DITA obezbeđuje modularnu strukturu potrebnu za kreiranje, ponovno korišćenje i skladištenje objekata učenja, dok ontološki model definiše njihovo značenje i odnose prema drugim nastavnim elementima. Objekat učenja zato se ne posmatra samo kao tehnički izdvojen digitalni resurs, već kao nastavni element koji može biti povezan sa konceptom domena, ishodom učenja, kompetencijom, nivoom dubine i odgovarajućim dokazom ovladanosti [14,15]. Ovakvo razdvajanje tehničke strukture i semantičke organizacije omogućava da se isti modularni sadržaj koristi u različitim putanjama učenja, dok ontološke relacije određuju njegovu ulogu u konkretnom adaptivnom scenariju.

Kada se nastavni materijali pripremaju u obliku objekata učenja, obično se skladište u repozitorijumu objekata učenja (engl. Learning Object Repository (LOR)) koje povećava prilagodljivost i pretraživost. Ideja organizovanja i skladištenja objekata učenja u LOR-u je omogućiti organizaciji i pojedincima da lako dele i ponovo koriste objekte učenja [89–91]. LOR sam po sebi ne može povećati pretraživost objekata učenja, pa se za te svrhe koriste druge komponente. Sistemi za upravljanje učenjem (engl. Learning Management Systems (LMS)) često se koriste za upravljanje, kombinovanje, objavljivanje, administriranje i isporuku objekata učenja [92]. LMS predstavlja interaktivan interfejs za korisnika koji olakšava pristup objektima učenja, a takođe upravlja: (i) administriranjem pristupa studenata određenom predmetu, (ii) isporukom objekata učenja ili resursa, i (iii) praćenjem i izveštavanjem o procesu učenja. Kombinovanjem objekta učenja kroz LMS, može se kreirati individualizovani put učenja za svakog studenta ili grupu studenata i isporučiti na personalizovan način [93]. Putevi učenja mogu biti predstavljeni na različite načine, u linearnoj ili nelinearnoj sekvenci, što omogućava veću fleksibilnost nastavnicima prilikom rada sa različitim tipovima studenata [93,94].

2.2.3. Strukturiranje nastavnih sadržaja

Strukturiranje nastavnih materijala predstavlja izazov, posebno kada je u pitanju pretraživanje i pronalaženje relevantnog sadržaja. Da bi se omogućilo efikasno pronalaženje objekata učenja, oni se obogaćuju dodeljivanjem skupa metapodataka. Dok su metapodaci

pogodni za opis multimedije, oni nisu u potpunosti od pomoći u opisivanju semantičkog značenja tekstualnih informacija [77]. Iako preporučeni standardima e-učenja, metapodaci takođe nisu dovoljni da reše probleme ponovne upotrebe objekata učenja, fleksibilnog pronalaženja i pristupačnosti [95]. Iz tog razloga, objekti učenja moraju biti obogaćeni reprezentacijom komplementarnih atributa koji mogu biti od pomoći kako za kreiranje novog sadržaja tako i za pretraživanje postojećeg sadržaja [96]. Takvo komplementarno znanje može biti predstavljeno u obliku ontologija. Ontologija može biti odgovarajuća semantička struktura koja s jedne strane omogućava definisanje određenog obrazovnog domena, a s druge strane pruža različite strategije učenja [97]. Ona predstavlja eksplicitan način za konceptualizaciju i predstavljanje domena znanja, dok pokriva sve koncepte znanja, opisuje kako su koncepti povezani i pruža set informacija o svojstvima odnosa između koncepata. Ontologija se može organizovati u klase ili kategorije na osnovu nivoa zadatka: (i) ontologije najvišeg nivoa (engl. top-level ontologies) se odnose na opšte koncepte nezavisne od određenog domena (vreme, prostor itd.), (ii) domen ontologije/zadatak ontologije predstavljaju opšte koncepte uvedene u ontologiji najvišeg nivoa i pružaju osnovni zajednički vokabular vezan za generički domen za konceptualno modeliranje i ontološku analizu; ili opisuju generički zadatak ili aktivnost i (iii) aplikacione ontologije koje opisuju koncepte koji zavise kako od određenog domena tako i od zadatka, i često kombinuju specijalizacije i domena i zadatka ontologija [93].

Kreiranje ontologije obično je vođeno taksonomijom u kojoj su koncepti od interesa klasifikovani u hijerarhijskoj strukturi stabla, pri čemu su najopštiji koncepti čvorovi na korenu ove hijerarhije. Svaki čvor, uključujući čvor na korenu, predstavlja koncept domena i svaka veza između dva čvora u taksonomiji predstavlja odnos „podklasifikacija“ ili „superklasifikacija“ [98]. Objekti učenja su predstavljeni kao čvorovi na najnižem nivou hijerarhije, koji su povezani korišćenjem odgovarajućih odnosa sa pripadajućim konceptima. Ovaj pristup ontologiji omogućava da se veliko znanje o domenu koji se uči podeli na manja podstabla, što omogućava dinamičko kreiranje puteva učenja za svakog studenta [99]. Put učenja se sastoji od: (a) izabranog koncepta visokog nivoa koji treba da se nauči (ciljni koncept); (b) različitih koncepata/podkoncepata ponuđenih studentu za učenje određenog ciljnog koncepta; (c) redosleda objekata učenja koje student koristi kako bi stekao koncepte uključene u putanju učenja [99]. Poseban pravac razvoja ontoloških modela u obrazovanju odnosi se na eksplicitno predstavljanje kompetencija. Takvi modeli proširuju klasičnu organizaciju nastavnog domena tako što, pored koncepata i resursa, formalizuju kompetencije koje se kroz njih razvijaju. COMP2 ontologija predstavlja kompetencije, kompetencijske

profile i referentne okvire u obliku koji je istovremeno razumljiv korisniku i pogodan za mašinsku obradu [100]. EduCOR ontologija proširuje ovu perspektivu povezivanjem obrazovnih resursa, ciljeva učenja, karakteristika korisnika i veština relevantnih za obrazovanje i razvoj karijere [101].

Ontološki pristupi koriste se i za mapiranje kurikuluma i kompetencijski zasnovanu analizu nastavnih programa. Ontološko mapiranje omogućava da odnosi između predmeta, ishoda učenja i kompetencija postanu eksplicitni i računarski obradivi [102]. Noviji pristupi dodatno pokazuju mogućnost korišćenja ontologija za dinamički razvoj kurikuluma u visokom obrazovanju [103], kao i za analizu kompetencijski zasnovanih nastavnih programa i njihovih elemenata [104]. Navedeni kompetencijski ontološki modeli pokazuju da je moguće formalno predstaviti kompetencije i njihove veze sa obrazovnim resursima, ciljevima i kurikulumom [100–102]. Međutim, takva relativno stabilna struktura sama po sebi ne predstavlja trenutno stanje pojedinačnog studenta. Za potrebe adaptivnog učenja potrebno je kompetencijski model povezati sa dinamičkim podacima koji nastaju tokom procesa učenja. U ovoj disertaciji zato se ontološki model objekata učenja [14] proširuje kompetencijskom dimenzijom iz okvira [15], dok se stanje pojedinačnog studenta naknadno određuje na osnovu njegovih aktivnosti i rezultata provera znanja. Na taj način kompetencija nije samo klasifikaciona oznaka nastavnog resursa, već postaje element koji povezuje model nastavnog sadržaja, dokaz o učenju i model studenta.

Problematika efikasnog predstavljanja ontologije povezana je sa složenom strukturom teme domena. Uprkos vrlo važnoj ulozi ontologije u pružanju personalizovanog e-učenja okruženja, korišćenje ove strukture u velikom domenu učenja može rezultirati sistemom koji nije skalabilan. Kako bi se pojednostavila složena struktura znanja predstavljena ontologijom dok se omogućava studentima da uče progresivno i efikasno savladavajući male i nezavisne koncepte, uvedena je struktura multidimenzionalnih mapa koncepata (engl. Multidimensional Concept Maps (MCM)). Mapiranje koncepata se koristi kao alat za učenje kako u akademiji, tako i u industriji u oblastima kao što su: biologija, istorija, matematika, inženjering, računarstvo i komunikacije [105]. U [106] je pokazano da je metakognitivna strategija mapiranja koncepata pomogla u prevazilaženju varijacija u postignućima studenata, što je dovelo do značajnog postignuća u učenju biologije. U [107] je koncept mapa prvi put primenjen za predstavljanje međusobnih odnosa među skupom značenja koncepata kao dvodimenzionalni, hijerarhijski, aciklički graf poznat i kao Novakova konceptualna mapa (engl. Novak Concept Map (NCM)). NCM se sastoji od čvorova i ivica, pri čemu najviši čvor obično sadrži opis svrhe NCM grafa,

dok se ivice koriste za povezivanje čvorova relevantnih koncepata. Takva organizacija i struktura pruža dobru navigacionu strategiju za studente jer smanjuje njihovu dezorijentaciju, koja često nastaje kada se kreću kroz nelinearnu strukturu ili složenu ontologiju [108]. Međutim, zbog mogućnosti proširenja i dodavanja novih koncepata u nastavni materijal, takvi grafovi mogu se postepeno dublje ili šire razvijati tokom vremena. Rasteći NCM graf može zauzeti nekoliko veb stranica u horizontalnom i vertikalnom pravcu, što uzrokuje poteškoće studentima da proučavaju koncepte bez korišćenja traka za pomeranje veb stranica [109]. Takođe, NCM-ovi se ne mogu koristiti za lako objašnjenje složenih koncepata koji se sastoje od mnogih drugih podkoncepata, što može dovesti do kognitivnog preopterećenja studenata [109,110]. Jedno od mogućih rešenja je korišćenje „fisheye“ pregleda koji posebno olakšava problem vizualizacije. Koncept fokusa i njegovi povezani koncepti u fisheye pregledu su maksimizirani na ekranu, dok su ostali koncepti minimizirani u pozadini [111]. Za ontologije velikih domena, čak i korišćenje fisheye pregleda može biti zbunjujuće i pojavljuje se potreba da se domen ontologija razbije na poddomene. Učenje istog koncepta u različitim vremenima u različitim kontekstima, za različite svrhe i iz različitih konceptualnih perspektiva veoma je važno za sticanje naprednog znanja [109]. Pristup zasnovan na MCM predstavlja osnovu modela vizualizacije razvijenog u ovoj disertaciji, prikazanog u ranijem istraživanju autora [14] i detaljno u Poglavlju 5.

2.2.4. Preporuka nastavnih materijala

U domenu e-učenja, personalizovani sistem preporuka nudi sadržaj prilagođen specifičnim potrebama svakog studenta. Personalizacija se ostvaruje određivanjem sadržaja koji će najverovatnije biti efikasan na osnovu informacija iz modela studenta [112]. Ova personalizacija se postiže analizom faktora kao što su nivo znanja, prethodno iskustvo i preferirani način učenja studenata. Tokom proteklih godina razvijene su različite tehnike i algoritmi za formiranje preporuka, uključujući kolaborativno filtriranje, filtriranje zasnovano na sadržaju, hibridne pristupe, preporuke zasnovane na znanju, ontologijama, pravilima, fazi logici, tagovima, poverenju, društvenim mrežama i grupnom učenju. U oblasti e-učenja, posebnu ulogu imaju sistemi koji preporučuju objekte učenja, resurse ili putanje učenja na osnovu modela studenta, karakteristika nastavnog sadržaja i semantičkih veza između nastavnih elemenata [13,113]. U obrazovnom kontekstu relevantnost preporuke ne može se određivati samo na osnovu sličnosti resursa, preferencija korisnika ili obrazaca ponašanja drugih korisnika. Preporučeni sadržaj treba povezati i sa ciljevima i ishodima učenja,

prethodnim znanjem, rezultatima aktivnosti provere i trenutnim stanjem studenta. Sistematski pregled obrazovnih sistema preporuka pokazuje da povezivanje preporuka sa ishodima učenja, proverama znanja i evaluacijom nije podjednako zastupljeno kao pristupi zasnovani na drugim kriterijumima relevantnosti [8]. Ontološki i na znanju zasnovani pristupi omogućavaju eksplicitno predstavljanje odnosa između studenata, nastavnih resursa i koncepata domena [12,13], zbog čega predstavljaju pogodnu osnovu za preporuke koje treba da budu povezane sa obrazovnim ciljevima.

Kolaborativno filtriranje (engl. Collaborative Filtering (CF)) preporučuje sadržaj na osnovu sličnosti sa drugim studentima, ali se suočava sa izazovima hladnog starta i nedostatka podataka [114]. Ova tehnika pretpostavlja da će slični studenti preferirati slične stavke. Preporuke zasnovane na sadržaju (engl. Content-based (CB)) identifikuju sličnosti među stavkama poredeći njihov sadržaj. CB gradi profil interesovanja studenta na osnovu već ocenjenih stavki i primenjuje tehnike uparivanja karakteristika stavki sa profilom studenta kako bi odredio relevantnost [115]. Preporuke zasnovane na znanju pružaju sadržaj studentima na temelju specifičnog znanja iz određenog područja. Sistemi zasnovani na znanju kombinuju informacije o studentima i resursima za učenje kako bi preporučili odgovarajući sadržaj [13]. Takođe, preporuke koristeći veštačku inteligenciju mogu se primeniti za adaptivne sisteme preporuka. Tradicionalni sistemi preporuka koriste se za procenu stanja znanja pojedinaca i preporučivanje sadržaja [116].

Posebnu grupu predstavljaju kompetencijski zasnovani sistemi preporuka, kod kojih se izbor resursa ili aktivnosti zasniva i na kompetencijama koje student poseduje ili treba dalje da razvija. Sistematski pregled ove oblasti pokazuje da se kompetencijski modeli koriste za preporučivanje nastavnih resursa, iskustava učenja i drugih oblika obrazovne podrške [117]. Ontološki i kompetencijski pristup mogu se povezati u adaptivnom sistemu preporuka u kome se kompetencije, stanje studenta i obrazovni resursi povezuju preko ontološke strukture i pravila preporučivanja [118]. Ovi pristupi potvrđuju značaj kompetencije kao moguće veze između modela studenta i nastavnog sadržaja. U pristupu razvijenom u ovoj disertaciji ta veza se dodatno konkretizuje kroz procenu ovladanosti kompetencijom na određenom nivou dubine na osnovu rezultata studentskih aktivnosti.

Za ovaj rad ključan je način povezivanja ontološki organizovanog sadržaja i modela studenta. Ontološki pristup obezbeđuje eksplicitne relacije između obrazovnih objekata i koncepata, dok model studenta daje informacije o trenutnom stanju pojedinca. Njihovo povezivanje omogućava da se preporuka zasniva istovremeno na strukturi sadržaja i na

podacima o učenju. Ovakva arhitekturna povezanost predstavlja osnovu razvijenog pristupa, dok se skalabilnost i interoperabilnost konačne arhitekture ne pretpostavljaju na osnovu same integracije, već se razmatraju kao zasebna pitanja evaluacije i budućeg rada. Pregled sistema zasnovanih na ontologiji dat je u nastavku, a model razvijen u ovoj disertaciji predstavljen je u Poglavlju 5.

2.2.4.1. Preporuke korišćenjem ontologije domena

Upravo zbog otežane pretrage i vizualizacije velikih domena, razvijeni su različiti sistemi za pretragu objekata na osnovu domena ontologije sa ciljem pružanja personalizovanog učenja. Sistemi sa preporukama su takođe primenjeni na sisteme za e-učenje. Njihov glavni cilj je da pruže preporuke nastavnog materijala za svakog studenta kako bi student mogao da napreduje efikasnije ka svojim ciljevima i ishodima učenja. Na primer, Intelligent Web Teacher (IWT) koristi ontologiju za C-programiranje u obrazovnom domenu kako bi definisao i sproveo personalizovana e-učenja iskustva [119]. Autori IWT-a zaključuju da je uvođenje personalizacije dovelo do relevantnog povećanja procenta studenata koji su uspešno položili ispit. Alati za planiranje kurseva kao što je PASER korišćeni su za izgradnju personalizovanih planova predmeta na osnovu ciljeva studenata i njihovog nivoa znanja koristeći ontologiju domena [120]. ERSDO predlaže dinamički sistem preporuka zasnovan na ontologiji koji ažurira profile studenata u realnom vremenu. Sistem koristi dinamičku ontologiju koja se ažurira sa promenama profila studenta, uključujući stil učenja i nivo znanja, i na osnovu nje preporučuje kurseve [121], što je pristup srodan kontinuiranom praćenju koje se primenjuje u ovoj disertaciji, iako se u njemu ne procenjuje ovladanost na osnovu rezultata provera. Srodan pravac predstavlja ON-SMMILE, modularni model studenta zasnovan na mreži ontologija, koji povezuje informacije o studentu, stanje i trag aktivnosti studenta, objekte znanja, ciljeve učenja, rubrike i pokazatelje performansi [122]. Ovaj ontološki model studenta kasnije je iskorišćen kao osnova adaptivnog kompetencijski zasnovanog sistema preporuka [118]. Za ovu disertaciju takvi pristupi su relevantni jer pokazuju da se ontološki organizovan sadržaj i model studenta mogu integrisati u proces preporučivanja. Predloženi pristup se od njih razlikuje po tome što se dinamičko stanje studenta dodatno izražava kroz procenu ovladanosti kompetencijama na različitim nivoima dubine i povezuje sa konkretnim dokazima iz aktivnosti provere. Semantički obrazovni sistem za preporučivanje (SERS) [123] i Semantički afektivni obrazovni sistem za preporučivanje nastavnih sadržaja (SAERS) [124] obogaćuju preporuke e-učenja sa adaptivnom navigacijom u cilju poboljšanja performansi učenja korišćenjem smanjenog broja obrazovnih resursa bez smanjenja efikasnosti učenja. SERS preporuke su

ponuđene kao lista linkova kako bi se prevazišle trenutne ograničenja sistema za upravljanje učenjem u pružanju personalizacije i pristupačnosti [123]. SAERS uključuje model usmeren na korisnika u procesu preporuka s ciljem pružanja liste najpogodnijih resursa na osnovu trenutnog afektivnog stanja studenata (tok, frustracija itd.) i ciljeva studenata [124]. Sistem preporuka personalizovanih objekata za učenje (PLORS) kreira personalizovanu listu preporuka OU-ova na osnovu stilova učenja studenata, nivoa ekspertize, prethodnog znanja i performansi kako bi pružio naprednu personalizaciju nastavnog sadržaja koji će biti predstavljen studentima [125]. Personalizovani e-učenje preporučivački sistem (PERS) predstavlja softverski sistem zasnovan na komponentama koji uzima u obzir ličnost studenta i koristi metode kolaborativnog filtriranja kako bi generisao adaptivni kurikulum za personalizovane potrebe studenata. PERS predlaže personalizovani scenarije učenja kreiran izborom odgovarajućih OU-ova generisanih deljenjem nastavnog materijala [126]. Veoma često, ovi sistemi preporuka se implementiraju kao sistemi za e-učenje. Međutim, većina ovih sistema za e-učenje koristi se samo za istraživačke svrhe i nije u potpunosti implementirana i korišćena do svog punog potencijala, delom i zbog visokih troškova pripreme i održavanja velikog broja objekata učenja. Noviji konceptualni pristupi ovaj problem razmatraju kroz dinamičko kreiranje nedostajućih objekata učenja primenom generativne veštačke inteligencije [15], što je komplementarno pristupu ove disertacije, koji polazi od postojećeg repozitorijuma objekata učenja**.**

Postoji nekoliko drugih pristupa u modelovanju onlajn predmeta sa ontologijama i neki plug-inovi za mapiranje koncepata spremni za upotrebu u popularnim LMS-ovima. Na primer, Moodle, popularni open-source sistem za učenje, nudi različite plug-inove. Jedan od Moodle plug-inova, MindMap Course Software, omogućava modelovanje onlajn predmeta koristeći mentalne mape umesto redovne stranice predmeta. Block MindMap Course i slični plug-inovi pružaju pristup nastavnom sadržaju putem interaktivnih mapa koje se mogu složiti i omogućavaju korisniku lak pristup ne samo nastavnom sadržaju, već i procenama, chat-ovima i internet resursima. Dok Moodle mentalne mape predstavljaju poboljšanje u tradicionalnom prikazu lekcija u Moodle-u, isporuka nastavnog sadržaja nije pogodna za veliki predmet. Velika količina čvorova može uzrokovati konfuziju kod studenata i povećati vreme za pretragu odgovarajućeg nastavnog sadržaja, što može dovesti do kognitivnog preopterećenja studenata. Courseware WatchDog je modul većeg projekta PADLR (engl. Personalized Access to Distributed Learning Repositories) [127,128], koji se bavi različitim potrebama nastavnika i studenata za organizaciju nastavnog materijala. Courseware WatchDog integriše princip

Semantičkog Weba koristeći ontologije i peer-to-peer mrežu semantički označenih materijala za učenje i rešava važna pitanja pronalaženja i organizovanja materijala koristeći semantičke informacije. Izazov u takvom sistemu je u kreiranju ontologije, budući da struktura i kreiranje ontologije za veliki broj objekata učenja može biti složen, vremenski zahtevan i skup [129]. U CoMPASS projektu, korišćeni su alternativni prikazi koncepata, tako da se svaki od koncepata mogao koristiti u drugom kontekstu. Svaki alternativni prikaz je predstavljen kao mapa iz koje su studenti mogli izabrati svoj koncept koji je fokusiran i za koji bi bio prikazan određeni fisheye prikaz. Rezultati CoMPASS projekta su pokazali da takva fokusirana navigacija može pomoći studentima da posete više koncepata koji su konceptualno povezani jedan s drugim i 'relevantni' za njihov trenutni cilj [111]. Nedostatak stila učenja koji pruža CoMPASS je u složenosti hiperteksta i velikoj granulaciji koncepata s obzirom na to da student ne bi trebalo da bude preopterećen sa previše informacija odjednom. Različiti modeli ontologije su korišćeni u struktuiranju predmeta. U ontologiji za predmet C-programiranja, autori su koristili pristup struktuiranju koji je zasnovan na razvoju vokabulara relevantnih koncepata, definisanju hijerarhija među konceptima i deljenju većih koncepata na set manjih i grupisanju sličnih koncepata u meta-koncepte [119]. Lee je razvio model ontologije objekata učenja za predmet Java programiranja, čineći ih deljivim i ponovo upotrebljivim, čime je pružio različite strategije učenja u okruženju za e-učenje [130]. Adaptive Educational eLearning System (AEeLS) ima mogućnost prikupljanja i analize podataka iz repozitorijuma OU na osnovu čega preporučuje relevantne obrazovne sadržaje zasnovane na tehnikama semantičkih ontologija [131].

Pored relevantnosti preporučenog sadržaja, značajan aspekt sistema preporuka predstavlja mogućnost objašnjenja razloga zbog kojih je određeni resurs preporučen. U opštoj literaturi o objašnjivim sistemima preporuka razlikuju se sam proces formiranja preporuke i mehanizam kojim se korisniku obrazlažu razlozi te odluke [132]. U obrazovnom kontekstu objašnjivost ima dodatni značaj, jer student i nastavnik treba da mogu da razumeju zašto je određeni sadržaj preporučen i na koje informacije o učenju se preporuka oslanja. Pregled objašnjivih obrazovnih sistema preporuka pokazuje da način generisanja i predstavljanja objašnjenja treba posmatrati kao poseban element projektovanja i evaluacije takvih sistema [133]. U pristupu razvijenom u ovoj disertaciji razlog preporuke može se slediti od procene ovladanosti, preko pripadajuće kompetencije i nivoa dubine, do ontološke relacije na osnovu koje je objekat uključen u preporučenu putanju. Takva sledljivost je u skladu sa potrebom da sistemi zasnovani na analitici učenja i XAI (engl. Explainable AI (XAI)) daju razumljive informacije studentima i nastavnicima [16,17].

Uporedni pregled ontoloških i kompetencijski zasnovanih pristupa, prema tome u kojoj meri povezuju objekte učenja, kompetencije, rezultate provera znanja, model studenta i preporučivanje, dat je u Tabeli 1 u odeljku 2.4.

2.3. Modelovanje studenata

2.3.1. Pojam modela studenta

Model studenta, koji je osnova personalizovanih sistema e-učenja, predstavlja ključni faktor za unapređenje znanja i kompetencija studenta, kao i njegovih postignuća u učenju. Iako su prednosti i mogućnosti koje nudi razumevanje individualnih karakteristika svakog studenta brojne, postoji i mnogo problema koje treba prevazići u modelovanju studenata. Korišćenjem sistema za e-učenje čuva se velika količina informacija o aktivnostima i rezultatima studenata, pa je pravilna analiza i razumevanje tih informacija ključno za bilo koji adaptivan sistem i može poslužiti za kreiranje modela studenta. Ovi modeli predstavljaju podtip korisničkih modela koji se u velikoj meri koriste, a specifično su vezani za domen korišćenja tj. edukativne sisteme. Literatura navodi i terminološku razliku između profila i modela koja je značajna za razumevanje same teme [134]. Navodi se da profil studenta sadrži statične informacije o studentu bez ikakvog dodatnog opisa ili tumačenja. Statičke karakteristike kao što su godište, maternji jezik, i slične karakteristike su poznate i pre nego što se započne proces učenja i ostaju nepromenjene tokom samog učenja, dok dinamičke karakteristike potiču direktno iz interakcije studenta sa sistemom i to su one koje sistem stalno ažurira tokom sesija učenja na osnovu prikupljenih podataka [135]. Proces kreiranja, modifikacije i održavanja modela studenta naziva se modelovanje studenta. Za razliku od profila, model studenta je apstraktni prikaz studenta koji sadrži sve informacije koje sistem ima o dinamičkom ponašanju studenta i nekim predviđenim stanjima. Pojednostavljeno, profil studenta čuva statične informacije o studentu, ali model studenta čuva i statične i dinamičke. U skladu sa karakteristikama studenta ili obrascima ponašanja preuzetih iz okruženja za učenje, model studenta se može kreirati i kao takav ključan je za obezbeđivanje efikasnog učenja u personalizovanim sistemima [136–138]. Da bi se konstruisao validan i upotrebljiv model studenta, moraju se razmotriti karakteristike studenta koje će se modelovati, načini ažuriranja modela i način uparivanja modela i personalizovanih nastavnih sadržaja za učenje [139]. Savremeno modelovanje studenta zato se sve manje svodi na formiranje jedinstvenog profila, a sve više na dinamičko predstavljanje više povezanih dimenzija stanja studenta. Pored relativno stabilnih karakteristika, model može

obuhvatati procenjeno znanje i ovladanost pojedinačnim elementima sadržaja, rezultate aktivnosti provere, obrasce angažovanja, tempo napredovanja i druge podatke koji se menjaju tokom procesa učenja [4]. Izbor dimenzija koje će biti uključene u model zavisi od njegove namene: model namenjen predikciji akademskog uspeha ne mora imati istu strukturu kao model čiji je cilj izbor konkretnog nastavnog sadržaja za dalje učenje. U poslednjem slučaju posebno je značajno da se procenjeno stanje studenta može neposredno povezati sa elementima nastavnog sadržaja na koje se procena odnosi [7,8]. Relevantna literatura razmatra različite karakteristike koje mogu biti uključene u model studenta:

- **Stilovi učenja**: Stilovi učenja odražavaju preferencije u načinu obrade informacija (vizuelni, auditivni, tekstualni). Najpoznatiji model je Felder-Silvermanov, koji razlikuje četiri stila: aktivan/reflektivan, senzorni/intuitivan, vizuelan/verbalan, sekvencijalan/globalan [140]. Kritike uključuju nedostatak čvrstih dokaza o njihovom uticaju na efikasnost učenja i veliki broj definicija, a dovodi se u pitanje i tvrdnja da ono što studenti preferiraju možda nije ono što je najbolje za njih [141,142].
- **Znanje/kompetencije studenata:** Znanje se procenjuje kroz provere znanja, dok kompetencije obuhvataju znanje, veštine njegove primene i stavove pojedinca. Modelovanje znanja uključuje analizu prethodnih odgovora, digitalnih tragova i formativne procene znanja. Značaj formativnih provera leži u prilagođavanju nastave i poboljšanju učenja [136,143–145]. Znanje studenata je od posebnog značaja za ovaj rad, pa je detaljnije razmotreno u odeljku 2.3.1.1.
- **Osobine ličnosti:** Osobine koje dovode do ponašanja pojedinca i predviđanja reakcije u datoj situaciji čine neku vrstu definicije ličnosti [146]. Ključni modeli su BIG 5 (otvorenost, savest, ekstraverzija, prijatnost, neuroticizam) i Myers-Briggs. Ovi modeli mogu pomoći u predviđanju akademskih rezultata, ali postoje sumnje u njihovu povezanost sa uspehom i pouzdanost automatskog merenja [147–151].
- **Društvene karakteristike:** Društvene interakcije i kulturne pozadine utiču na akademski uspeh i angažovanje. Dok društveni alati mogu poboljšati uspeh, izazovi uključuju privatnost i kulturne razlike koje treba uzeti u obzir za efikasnu primenu [152–155].
- **Motivacija:** Motivacija je važna za angažovanje i akademski uspeh, ali se tumači na različite načine i izazov je prepoznati i otkriti najbitnije od njih [156–159]. Različiti modeli motivacije, kao što je ARCS motivacioni model (engl. Attention,

Relevance, Confidence, Satisfaction), nude teoretske osnove za poboljšanje angažovanja, ali postoje ograničeni empirijski dokazi koji podržavaju ove modele [136].

Poseban pravac razvoja predstavljaju otvoreni modeli studenta (engl. *Open Learner Models* (OLM)), kod kojih se deo ili celokupna reprezentacija znanja, napretka ili drugih karakteristika studenta čini vidljivom samom studentu. Za razliku od modela koji funkcionišu isključivo kao interna komponenta adaptivnog sistema, OLM pristupi omogućavaju studentu da dobije uvid u način na koji sistem predstavlja njegovo trenutno stanje. Novija meta-sinteza istraživanja u visokom obrazovanju pokazuje da ovakvi modeli mogu podržati svest o sopstvenom napretku, refleksiju, postavljanje ciljeva, kalibraciju povratne informacije i samoregulisano učenje, pri čemu efekti zavise od nivoa transparentnosti modela i stepena kontrole koji je omogućen studentu [160]. Ovakav pristup je relevantan i za objašnjive adaptivne sisteme, jer se procena stanja studenta ne koristi samo interno za donošenje odluke, već se njeni ključni elementi mogu prikazati studentu kao osnova za razumevanje sopstvenog napretka i preporučenih narednih koraka. U tom smislu, model razvijen u ovoj disertaciji ima funkciju uvida u model studenta: studentu se prikazuju procene ovladanosti, pokazatelji napretka i obrazloženja preporučenih narednih koraka. Međutim, student ne menja niti pregovara vrednosti i strukturu modela na osnovu kojih se te procene i preporuke formiraju, pa razvijeni pristup ne predstavlja potpuno otvoren model studenta u kojem korisnik neposredno učestvuje u njegovom uređivanju.

2.3.1.1. Znanje/kompetencije studenata

Znanje se definiše kao skup činjenica, informacija i koncepata koje pojedinac stiče kroz iskustvo ili obrazovanje. Kompetencija se, u skladu sa evropskim okvirima za celoživotno učenje, definiše kao kombinacija znanja, veština primene tog znanja i stavova pojedinca u efikasnom obavljanju zadataka i rešavanju problema [15,161]. U fokusu ove disertacije, u skladu sa okvirom kompetencijski vođenog personalizovanog učenja primenjenim u ovom radu [15], razmatraju se komponente znanja i veštine, koje je moguće pratiti kroz aktivnosti i provere znanja u sistemu za e-učenje, dok razvoj stavova prevazilazi obim ovog istraživanja. Da bi se precizno merilo znanje studenta, obično se koriste upitnici i testovi koji omogućavaju procenu stečenih informacija i veština. Preporučuje se upotreba kraćih testova koji fokusiraju na najreprezentativnije aspekte domena koji je student proučavao [162]. Ovi testovi omogućavaju bržu i precizniju procenu ključnih komponenti znanja i veština.

Znanje i kompetencije su dinamični i stalno se menjaju kako se povećava iskustvo i obrazovanje studenta. Modelovanje znanja uključuje različite pristupe kako bi se obuhvatili ovi

dinamični aspekti. Posebnu klasu pristupa čine metode praćenja znanja (engl. knowledge tracing), koje na osnovu odgovora studenta na zadatke i aktivnosti tokom vremena procenjuju verovatnoću ovladanosti pojedinačnim elementima znanja. Najpoznatiji predstavnik je Bajesovo praćenje znanja (engl. Bayesian Knowledge Tracing (BKT)) [11], probabilistički model koji ovladanost tretira kao skriveno stanje koje se ažurira nakon svakog odgovora studenta, korišćenjem parametara početnog znanja, brzine učenja, pogađanja i omaške. Pelánek [163] daje sistematičan pregled ovih tehnika, od BKT-a i njegovih varijanti do logističkih modela. Razvijena su i brojna proširenja osnovnog modela: Hawkins i Heffernan [164] pokazuju da sličnost između prethodnih i tekućih zadataka može poboljšati preciznost praćenja, Hernández et al. [165] koriste Bajesove mreže koje uzimaju u obzir zaboravljanje i greške studenata, a Nedungadi i Remya [166] uključuju faktor zaboravljanja direktno u BKT. Novije varijante zasnovane na dubokim neuronskim mrežama (engl. Deep Knowledge Tracing) [167] postižu visoku prediktivnu tačnost, ali po cenu interpretabilnosti procena i uz zahteve za velikim skupovima podataka, pri čemu proširene varijante BKT-a postižu uporedive rezultate uz zadržavanje interpretabilnosti [168]. Oblast praćenja znanja poslednjih godina značajno se proširila i obuhvata probabilističke, logističke, neuronske i hibridne modele. Savremeni pregled KT pristupa pokazuje razvoj od klasičnih BKT i logističkih modela ka dubokim sekvencijalnim arhitekturama, modelima pažnje i Transformer pristupima, uz istovremeno razmatranje pitanja granularnosti jedinice znanja, karakteristika interakcija i interpretabilnosti procene [169]. Pregledi dubokog praćenja znanja dodatno pokazuju veliki broj arhitektura razvijenih radi povećanja prediktivne tačnosti i modelovanja složenijih obrazaca studentskih interakcija [170].

Posebno intenzivan razvoj poslednjih godina beleže Transformer modeli za praćenje znanja. Principijelno projektovane Transformer arhitekture istražuju fleksibilnije predstavljanje studentskih interakcija i poboljšanje prediktivnih performansi [171]. Paralelno se razvijaju pristupi koji pokušavaju da ublaže problem netransparentnosti dubokih modela, kao što su teorijski utemeljeni Grounded Transformers namenjeni povećanju interpretabilnosti u dubokom praćenju znanja [172]. Drugi pristupi koriste automatsko pretraživanje arhitekture radi izbora pogodnije Transformer strukture za konkretan problem praćenja znanja [173]. Ovi modeli pokazuju rastuću sposobnost reprezentovanja složenih i dugoročnih obrazaca u sekvencama studentskih interakcija. Međutim, izbor metode praćenja znanja zavisi i od cilja primene, raspoloživog obima podataka i zahteva za interpretabilnošću, a ne samo od prediktivne tačnosti. U sistemima u kojima procena ovladanosti predstavlja neposrednu osnovu

za preporuku konkretnog nastavnog sadržaja, posebno je značajno da rezultat modela bude moguće jasno povezati sa jedinicom znanja i obrazložiti studentu ili nastavniku.

Pored samih odgovora, istraživanja pokazuju da preciznost modelovanja znanja mogu poboljšati i dopunski signali: vreme odgovora i intervencije nastavnika [174], podaci prikupljeni u realnom vremenu tokom samoprocenjivanja [144], digitalni tragovi i ponašanje studenata u sistemu [175], samopouzdanje studenta pri odgovaranju [176], kao i analiza interakcija sa sadržajem primenom neuronskih mreža [143]. Za inicijalizaciju modela studenta mogu se koristiti kraći testovi fokusirani na najreprezentativnije aspekte domena [162], dok analiza korišćenja digitalnih resursa može ukazati na koncepte kod kojih studenti najčešće imaju poteškoće [177].

Važno je razlikovati rezultat pojedinačne aktivnosti provere od procenjenog stanja znanja studenta. Rezultat testa, zadatka ili druge aktivnosti predstavlja neposrednu opservaciju, dok model praćenja znanja iz sekvence takvih opservacija izvodi procenu skrivenog stanja ovladanosti. Upravo zato KT pristupi ne posmatraju pojedinačni rezultat kao konačnu meru znanja, već koriste istoriju interakcija kako bi procenili kako se stanje studenta menja tokom vremena [169]. Ova distinkcija je posebno značajna za kompetencijski zasnovano modelovanje, jer procena ovladanosti kompetencijom ne mora biti jednaka procentu izvršenih aktivnosti kojima se ta kompetencija proverava.

Formativne provere znanja imaju poseban značaj u modelovanju jer omogućavaju kontinuirano prilagođavanje i poboljšanje nastavnih strategija i procesa učenja na osnovu trenutnih povratnih informacija. Formativno ocenjivanje pruža nastavnicima dragoceno sredstvo za identifikaciju praznina u razumevanju studenata i omogućava im da odrede šta student još treba naučiti [178,179]. Ova metoda omogućava nastavnicima da prilagode svoju nastavu na temelju povratnih informacija i omogućava studentima da unaprede svoje projekte i metode učenja [180].

Heacox [178] istražuje kako diferencijacija nastave može pomoći u zadovoljenju različitih potreba studenata kroz formativne procene, što omogućava nastavnicima da prilagode svoje metode poučavanja na temelju specifičnih potreba studenata. Furtak et al. [179] pokazuje da sposobnosti nastavnika u oblasti formativnog ocenjivanja direktno utiču na studentovo učenje, pružajući empirijske podatke o efektivnosti različitih pristupa formativnoj proceni. Khursheed i Shahid [180] analiziraju uticaj formativnog ocenjivanja na razvoj kompetencija studenata, pokazujući kako povratne informacije mogu poboljšati sposobnosti studenata u različitim

oblastima. Whitelock i Bektik [181] istražuju napredak i izazove u automatizovanom ocenjivanju i sistemima za povratne informacije, naglašavajući važnost ovih sistema u velikim procenama i obrazovnim okruženjima. Van Der Kleij [182] upoređuje percepcije nastavnika i studenata o praksama formativnog ocenjivanja i njihovim uticajima na karakteristike pojedinačnih studenata.

2.3.2. Tehnike modelovanja studenta

Kada se u procesu modelovanja studenata identifikuju parametri modela koji će se koristiti, neophodno je identifikovati metode i tehnike za njihovo modelovanje. Kreiranje modela studenta mora se izvršiti kako bi se modelovale karakteristike kao što su nivo znanja, stil učenja, nedostaci i putanja napretka, a u nekim slučajevima i da se predvide [183,184]. Autori rada [134] klasifikuju tehnike koje se u te svrhe koriste u 5 grupa:

- **Metode klasterovanja i klasifikacije:** koriste se za grupisanje studenata prema karakteristikama kao što su nivo znanja i stilovi učenja, čime se omogućava personalizacija obrazovnog iskustva [19,185–189].
- **Prediktivne metode**: koriste algoritme za predviđanje karakteristika studenata i identifikaciju rizika od odustajanja [190–196]. Kombinacija algoritama poboljšava tačnost predikcija [184,197].
- **Metode preklapanja:** analiziraju znanje studenata kao podskup domenskog znanja, ali imaju ograničenja u preciznom procenjivanju nivoa znanja [198,199].
- **Metode modelovanja nesigurnosti:** kao što su Bajesove mreže i fazi logika, koriste se za procenu karakteristika studenata podložnih nesigurnostima [190,200–204]. U ovu grupu spada i BKT, razmotren u odeljku 2.3.1.1
- **Ontologije:** omogućavaju definisanje zajedničkog vokabulara za modelovanje znanja, pogrešnih shvatanja i stilova učenja [205–208].

Navedena klasifikacija predstavlja koristan pregled tradicionalnih pristupa modelovanju studenta, ali granice između pojedinih grupa nisu striktne. Ovo je posebno vidljivo kod metoda praćenja znanja. BKT pripada probabilističkim metodama modelovanja nesigurnosti, dok noviji KT modeli koriste logističku regresiju, rekurentne neuronske mreže, mehanizme pažnje i Transformer arhitekture [169]. Zbog toga se praćenje znanja danas može posmatrati kao poseban problem sekvencijalnog modelovanja stanja studenta koji može biti realizovan različitim algoritamskim paradigmama.

2.3.2.1. Modelovanje studenta zasnovano na algoritmima mašinskog učenja

Mašinsko učenje je popularan pristup koji koristi algoritme za predikciju učinka studenta i identifikaciju njegovih karakteristika, smanjujući probleme hladnog starta [209]. Međutim, ova tehnika uveliko zavisi od kvaliteta korišćenih algoritama i podataka korišćenih za obuku ovih algoritama. Mašinsko učenje traži algoritme koji su sposobni da zaključe iz podataka kako bi proizveli opšte hipoteze, koje zatim prave predikcije o budućim stanjima. Indukcija pravila (engl. Rule Induction) je efikasan metod za pravljenje predikcija, koji je postigao tačnost od 94% pri predviđanju odustajanja novih studenata sa medicinskih predmeta [193]. Primena više algoritama i upoređivanje njihovih rezultata često je korisno, kao što je slučaj u [194], gde su četiri klasifikaciona algoritma: Logistička regresija (engl. Logistic regression (LR)), Stabla odlučivanja (engl. Decision tree (DT)), Veštačke neuronske mreže (engl. Artificial neural networks (ANN)) i Metoda potpornih vektora (engl. Support Vector Machine (SVM)) upoređena sa tri tehnike balansiranja podataka: (engl. Over-Sampling, Under-Sampling i Synthetic Minority Over-Sampling (SMOTE)). SVM sa SMOTE-om je kod upoređivanja dao najbolju tačnost (90,24%) pri predviđanju studenata koji odustaju od predmeta. Kombinacija tehnika k-najbližih suseda (engl. K-Nearest Neighbor (KNN)), Ograničena Bolcmanova mašina (engl. Restricted Boltzmann machine (RBM)) i SVM pokazuje visoke rezultate u predikciji rizika od odustajanja [195]. Veštačke neuronske mreže (ANN) su korišćene za predikciju akademskog uspeha i stilova učenja [196]. Obrada prirodnog jezika (engl. Natural language processing (NLP)) je korišćena u svrhu analiziranja poruka studenta na forumima i četovima kako bi se identifikovale karakteristike njihove ličnosti, kognitivne sposobnosti i znanje [151,210]. Različite studije pokazuju da kombinacija više algoritama i upotreba dodatnih informacija o studentima poboljšava tačnost predikcija. Ranija istraživanja autora potvrdila su primenljivost ovih pristupa za predikciju akademskog uspeha studenata [184] i uporednu analizu učinka studenata kroz različite generacije [211], uz nalaz da su prediktivni modeli osetljivi na kontekst iz koga podaci potiču. Algoritmi kao što su metoda slučajne šume (engl. Random Forest (RF)), Naivni Bajesov klasifikator (engl. Naïve Bayes (NB)), SVM i metoda dubokog učenja (engl. Deep Learning (DL)) pokazuju odlične performanse u različitim metrikama za binarnu klasifikaciju i predikciju akademskog uspeha [184,197]. Za razliku od klasifikacionih i prediktivnih metoda, klasterovanje ne zahteva unapred definisane oznake grupa i može se koristiti za identifikovanje obrazaca u načinu na koji studenti pristupaju učenju. Analizom konzistentnosti rada, tempa, uloženog napora, prethodnog znanja i ponašanja tokom

provera moguće je formirati različite profile studenata [212]. Klasterovanje je korišćeno i za analizu samoregulisanog ponašanja studenata u okruženjima zasnovanim na ovladavanju, pri čemu se obrasci aktivnosti analiziraju kroz više nivoa i vremenskih tragova [213]. Takvi ponašajni profili mogu dopuniti procenu znanja, ali ih ne treba poistovećivati sa njom. Dva studenta mogu imati različite obrasce angažovanja, a ipak postići sličan nivo ovladanosti, kao što i studenti sličnog ponašanja mogu imati različite potrebe u pogledu nastavnog sadržaja. Zbog toga je u modelu studenta korisno odvojeno posmatrati ponašajne karakteristike i procenjeno stanje znanja. Navedene vrednosti tačnosti treba ipak tumačiti oprezno. One potiču iz različitih skupova podataka, sa različitim ciljnim promenljivima (odustajanje, položen ispit, konačna ocena), različitim odnosom klasa i različitim metrikama, pa nisu neposredno uporedive i ne pokazuju koji je algoritam generalno najbolji. Za personalizovano učenje važnije ograničenje odnosi se na granularnost procene. Ciljna promenljiva u ovim istraživanjima najčešće je ishod na nivou celog predmeta ili studija, pa model može da ukaže koji je student u riziku, ali ne i koji deo gradiva nije savladao. Ulazni atributi su takođe najčešće zbirni pokazatelji, kao što su ukupni poeni na testovima, prisustvo ili broj prijava na platformu, pa veza sa konkretnim objektom učenja, ishodom učenja ili kompetencijom ne postoji ni na ulazu ni na izlazu modela. Takav rezultat koristan je za rano upozoravanje nastavnika, ali se ne može neposredno prevesti u preporuku određenog nastavnog sadržaja. Isto ograničenje uočeno je i u prvoj fazi ovog istraživanja (odeljak 6.3): predikcija uspeha postigla je visoku tačnost, ali je rezultat ostao na nivou završnog ishoda predmeta, što je motivisalo razvoj modela studenta zasnovanog na dokazima vezanim za konkretne objekte učenja.

Drugo zajedničko ograničenje navedenih pristupa jeste to što modeli visoke prediktivne tačnosti često funkcionišu kao „crne kutije“, bez objašnjenja na osnovu čega je procena doneta, što otežava njihovu primenu u obrazovnom kontekstu [16]. Zbog toga se u novijim istraživanjima primenjuju metode objašnjive veštačke inteligencije (engl. Explainable Artificial Intelligence (XAI)), koje procene modela prevode u razumljiva objašnjenja i preporuke, čime se povećava poverenje studenata i nastavnika u sistem [214]. U istraživanju autora [17] pokazano je da kombinacija klasterovanja, klasifikacije i XAI tehnika omogućava generisanje transparentnih, personalizovanih i akciono upotrebljivih preporuka za unapređenje napretka studenata.

Izbor metode modelovanja mora uzeti u obzir i obim i kontekst raspoloživih obrazovnih podataka. Istraživanja pokazuju da nastavni uslovi konkretnog predmeta utiču i na prediktivnu moć modela i na značaj pojedinačnih atributa [9], zbog čega se rezultati dobijeni u jednom

predmetu ne mogu automatski preneti na drugi. Istovremeno, korisni modeli mogu se razvijati i nad manjim obrazovnim skupovima podataka kada je cilj interpretabilna analiza i kada se koriste pažljivo odabrani indikatori i odgovarajuće metode vizualizacije i grupisanja [215]. Ovo je posebno relevantno za modele na nivou pojedinačnog predmeta, gde cilj nije razvoj univerzalnog modela na masivnim skupovima podataka, već interpretabilno predstavljanje stanja i ponašanja studenata u konkretnom nastavnom kontekstu.

Pregled literature pokazuje da savremeno modelovanje studenta obuhvata više komplementarnih istraživačkih pravaca. Prediktivni modeli i analitika učenja omogućavaju identifikovanje akademskog uspeha, rizika i obrazaca aktivnosti, ali se često zasnivaju na agregiranim pokazateljima performansi i aktivnosti, bez eksplicitnog predstavljanja konkretnog nastavnog sadržaja na koji se procena odnosi [9,184]. Metode praćenja znanja omogućavaju dinamičku procenu ovladanosti pojedinačnim veštinama ili komponentama znanja na osnovu sekvence studentskih interakcija [169], ali sama procena ovladanosti ne određuje automatski koji konkretan nastavni objekat treba preporučiti studentu. Ponašajno profilisanje i klasterovanje omogućavaju dodatno razumevanje načina na koji studenti rade i identifikovanje grupa sa sličnim obrascima angažovanja [19], ali pripadnost grupi ne predstavlja nužno individualno stanje znanja pojedinačnog studenta. Sa druge strane, ontološki sistemi preporuka omogućavaju formalno predstavljanje odnosa između nastavnih resursa, koncepata domena i karakteristika studenta [12,13]. Kompetencijski zasnovani sistemi dodatno koriste kompetencije kao osnovu za izbor obrazovnih resursa [117], dok postoje i pristupi koji povezuju kompetencijski model i ontološku strukturu u adaptivnom sistemu preporuka [118]. Ipak, sistematski pregled obrazovnih sistema preporuka ukazuje da preporuke nisu dosledno povezane sa ishodima učenja, aktivnostima provere i procenom ovladanosti [8].

Istraživački prostor ove disertacije zato nije u razvoju još jednog izolovanog algoritma za predikciju, klasterovanje ili praćenje znanja, već u njihovom funkcionalnom povezivanju sa formalno strukturiranim nastavnim sadržajem. Potrebno je omogućiti da se rezultat studentske aktivnosti interpretira kao dokaz vezan za konkretan objekat učenja, kompetenciju i nivo dubine, da se iz takvih dokaza formira dinamička i interpretabilna procena stanja pojedinačnog studenta i da se potom identifikovano stanje poveže sa ontološkim relacijama radi izbora i objašnjenja narednog nastavnog sadržaja. Upravo integracija strukturiranog modela sadržaja, verifikovanih dokaza o učenju, dinamičkog modela studenta i objašnjive preporuke predstavlja istraživački problem koji se dalje razmatra u ovoj disertaciji.

2.4. Istraživački jaz i pozicioniranje originalnosti disertacije

Pregled relevantne literature pokazuje da su ključne komponente potrebne za razvoj personalizovanih i adaptivnih sistema e-učenja predmet više razvijenih, ali delimično odvojenih istraživačkih pravaca. Modeli studenta, analitika učenja i prediktivne metode omogućavaju izdvajanje obrazaca aktivnosti, procenu akademskog uspeha i identifikovanje karakteristika studenata, ali se njihovi rezultati često zadržavaju na nivou agregiranih pokazatelja ili predikcije ishoda, bez neposredne veze sa konkretnim nastavnim sadržajem na koji se procena odnosi [9], [184]. Metode praćenja znanja omogućavaju dinamičku procenu ovladanosti pojedinačnim komponentama znanja na osnovu sekvence studentskih interakcija [169], ali sama procena stanja ne određuje automatski koji konkretan objekat učenja treba preporučiti studentu niti na koji način takav sadržaj treba urediti u odnosu na njegove pedagoške preduslove. Ponašajno profilisanje i klasterovanje pružaju dodatne informacije o načinu angažovanja studenata [19], ali pripadnost grupi ne predstavlja individualnu procenu znanja niti sama po sebi određuje sadržaj potreban pojedinačnom studentu.

Sa druge strane, ontološki pristupi omogućavaju formalno predstavljanje nastavnog domena, koncepata, obrazovnih resursa i njihovih semantičkih odnosa, dok ontološki sistemi preporuka koriste takvu strukturu za izbor i povezivanje nastavnih sadržaja [12,13]. Kompetencijski zasnovani sistemi dodatno uvode kompetencije kao osnovu za određivanje obrazovnih potreba i preporučivanje resursa [117], a postoje i pristupi u kojima se kompetencijski model, stanje studenta i obrazovni resursi povezuju preko ontološke strukture i pravila preporučivanja [118]. Ovi pristupi potvrđuju mogućnost povezivanja modela studenta i modela sadržaja, ali se način na koji se konkretan rezultat aktivnosti provere transformiše u dokaz vezan za određeni objekat učenja, kompetenciju i nivo njenog razvoja, zatim koristi za dinamičku procenu individualnog stanja i na kraju prevodi u sledljivu adaptivnu odluku, ne razmatra dosledno u svim navedenim komponentama. Sistematski pregledi obrazovnih sistema preporuka takođe ukazuju da ishodi učenja, aktivnosti provere i procene ovladanosti nisu uvek neposredno uključeni u proces formiranja preporuke [8]. Razlika predloženog pristupa u odnosu na ontološke i kompetencijski zasnovane sisteme preporuka detaljnije je obrazložena posle Tabele 1.

Za pozicioniranje doprinosa ove disertacije posebno je značajno razgraničiti rezultate istraživanja autora i konceptualne osnove na kojima je završni pristup izgrađen. Razvijen ontološki model objekata učenja i njegova vizualizacija korišćenjem multidimenzionalnih konceptualnih mapa omogućili su formalnu organizaciju objekata učenja, predstavljanje

odnosa između njih, njihovo pronalaženje i dinamičko formiranje personalizovanog prostora za učenje [14]. U okviru sistema OBSLO definisane su, između ostalog, relacije redosleda između objekata učenja i relacije između osnovnih i naprednih koncepata, čime je obezbeđena semantička struktura pogodna za nelinearno kretanje kroz nastavni sadržaj. Inicijalni pristup je, međutim, bio prvenstveno usmeren na organizaciju, pronalaženje, vizuelizaciju i navigaciju kroz ontološki strukturiran sadržaj i nije obuhvatao dinamički višeslojni model pojedinačnog studenta zasnovan na sekvencijalnim dokazima o učenju.

Drugu važnu osnovu predstavlja kompetencijski vođen koncept personalizovanog učenja [15], u kojem se nastavni sadržaj organizuje prema kompetencijama, pri čemu se kompetencijski prostor posmatra kroz dimenzije širine i dubine, a razlikuju se obavezne i opcione kompetencije. U okviru te koncepcije objekti učenja predstavljaju nosioce znanja i veština, dok različiti nivoi omogućavaju da se sadržaj organizuje prema različitoj dubini kompetencije [15]. Ovaj okvir pruža konceptualnu osnovu za kompetencijsku organizaciju nastavnog procesa, ali nije sam po sebi dinamički model studenta kojim se iz sekvence individualnih rezultata procenjuje trenutno stanje ovladanosti i ono neposredno povezuje sa ontološki strukturiranom adaptivnom preporukom.

Posmatrani zajedno, radovi [14] i [15] daju dve komplementarne osnove, ali i jasno ukazuju na ono što u njima nedostaje u odnosu na ciljeve ove disertacije. Rad [14] obezbeđuje ontološku strukturu objekata učenja i relacije redosleda i osnovnih i naprednih koncepata, ali se personalizacija u njemu zasniva na strukturi domena i izboru studenta pri navigaciji, a ne na proceni njegovog stanja znanja. Ontološki model u tom radu ne sadrži kompetencije, ishode učenja ni nivoe dubine, a OR i BA relacije koriste se za prikaz i kretanje kroz sadržaj, a ne za automatsko uređivanje individualne putanje. Okvir [15], sa druge strane, uvodi kompetencijski prostor sa dimenzijama širine i dubine, ali ostaje na konceptualnom nivou: element VERIFY određuje da se sticanje kompetencije proverava, ali ne definiše kako se pojedinačni rezultati provera kvantifikuju i objedinjuju u procenu ovladanosti, niti kako se iz takve procene izvodi izbor i redosled objekata učenja. Uloga generativne veštačke inteligencije u kreiranju nedostajućih objekata učenja dodatno otvara pitanje sledljivosti odluke o tome šta se studentu preporučuje. Nijedan od ova dva pristupa stoga ne povezuje rezultat konkretne aktivnosti provere sa objektom učenja, kompetencijom i nivoom dubine na koje se odnosi, niti iz takvih dokaza formira dinamičku procenu stanja pojedinačnog studenta. Upravo to povezivanje predstavlja pravac razvoja ove disertacije: ontološka struktura iz rada [14] proširena je kompetencijskim okvirom iz rada [15], element VERIFY operacionalizovan je kao semantička

veza između objekta učenja i dokaza, a na toj osnovi razvijeni su sekvencijalna procena ovladanosti i sledljiv adaptivni postupak. Tabela 1 sažima odnos predloženog modela prema pristupima razmatranim u ovom poglavlju, na koje se disertacija nadovezuje ili sa kojima deli pojedina svojstva: ontološkom prostoru za učenje [14], kompetencijskom konceptu personalizovanog učenja [15], adaptivnom sistemu preporuka zasnovanom na kompetencijama i ontologijama [118], Bajesovom praćenju znanja [11], ontološkom generisanju kursa [99], sistemu za planiranje personalizovanog kursa PASER [120], sistemu preporuka zasnovanom na dinamičkoj ontologiji ERSDO [121] i modelu studenta ON-SMMILE [122]. Svako od pet prikazanih svojstava postoji u nekom od ovih pristupa, ali nijedan ne objedinjuje sva svojstva. Originalnost predloženog modela zato nije u pojedinačnoj komponenti, već u njihovom povezivanju: rezultat konkretne aktivnosti provere vezuje se za objekat učenja, kompetenciju i nivo dubine, na osnovu toga se sekvencijalno procenjuje ovladanost, a preporuka se formira kao uređen skup objekata učenja prema ontološkim relacijama.

Tabela 1. Poređenje predloženog modela sa pristupima razmatranim u Poglavlju 2.

Pristup	**Ontologija?**	**Kompetencije i nivoi?**	**Rezultat provere vezan za objekat učenja?**	**Praćenje promene znanja kroz vreme?**	**Preporuka objekata učenja određenim redom?**
OBSLO i MCM [14]	Da	Ne	Ne	Ne	Delimično (student sam bira put kroz mapu)
Kompetencijski koncept [15]	Delimično	Da	Delimično (samo konceptualno, kroz VERIFY)	Ne	Ne
Kompetencije i ontologije u sistemu preporuka [118]	Da	Da	Delimično (vezan za aktivnost i kompetenciju)	Delimično (pravila posle svake akcije)	Delimično (preporučuje kompetencije i aktivnosti)
Bajesovo praćenje znanja [11]	Ne	Ne	Ne	Da	Ne
Ontološko generisanje kursa [99]	Da	Ne	Ne	Ne	Da
PASER [120]	Da	Delimično (ontologija kompetencija, bez nivoa dubine)	Ne	Ne	Da
ERSDO [121]	Da	Ne	Ne	Delimično (profil se dinamički ažurira)	Ne (preporučuje kurseve, top-N)
ON-SMMILE [122]	Da	Da	Delimično (rubrike vezane za ciljeve i aktivnosti)	Delimično (dijagnostička pravila)	Ne (model studenta, bez preporuka)
Predloženi model	Da	Da	Da	Da	Da

Pristupi [118] i [122] jedini u Tabeli 1, pored predloženog modela, istovremeno koriste ontologiju i kompetencije, pa razlika u odnosu na njih zahteva detaljnije obrazloženje. U radu [118] predložen je adaptivni sistem preporuka u kome mreža ontologija beleži nastavni dizajn i podatke o studentu, a stanje studenta zaključuje se nemonotonim dijagnostičkim pravilima nad njegovim akcijama tokom izvođenja aktivnosti. Preporuke se zatim formiraju pravilima, na primer kao preporuka nesavladane kompetencije kada je rezultat po kriterijumu rubrike ispod standarda ili kao preporuka jednostavnije aktivnosti za studenta na početnom nivou ovladanosti. ON-SMMILE [122] je model studenta predstavljen mrežom ontologija koja povezuje stanje znanja studenta, procene zasnovane na rubrikama i ciljevima, jedinice učenja i informacione resurse. On sam ne formira preporuke, već je zamišljen kao osnova budućeg kompetencijski zasnovanog sistema preporuka. Predloženi model ove disertacije razlikuje se od ova dva pristupa u tri pogleda. Prvo, rezultat aktivnosti provere u njima je vezan za aktivnost, cilj ili kriterijum rubrike i kompetenciju, dok se u predloženom modelu vezuje za konkretan objekat učenja, kompetenciju i nivo dubine, uz relativni značaj te veze, pa se potreba za podrškom može lokalizovati na nivou konkretnog nastavnog sadržaja. Drugo, stanje studenta se u [118] i [122] izvodi dijagnostičkim pravilima zaključivanja, u [118] uz diskretne nivoe ovladanosti, dok predloženi model iz hronološkog niza dokaza formira kontinuiranu sekvencijalnu procenu ovladanosti i odvojeno prati ostvarenost nivoa i ponašajni kontekst. Treće, preporuka u [118] predstavlja izbor kompetencije ili aktivnosti, a [122] preporuku ne formira, dok predloženi model formira uređenu putanju konkretnih objekata učenja na osnovu ontoloških relacija preduslova i odnosa osnovnog i naprednog sadržaja, uz sledljivo obrazloženje za svaki uključeni objekat. Originalnost predložene integracije stoga nije u korišćenju ontologije i kompetencija kao takvih, što deli sa ovim pristupima, već u tome što se isti dokaz prati od objekta učenja, preko procene stanja studenta, do položaja preporučenog objekta u putanji.

Istraživanja autora u oblasti analitike učenja i mašinskog učenja takođe su pokazala mogućnost predikcije akademskog uspeha, identifikovanja obrazaca angažovanja i primene objašnjive veštačke inteligencije radi prevođenja rezultata klasifikacije i klasterovanja u razumljive preporuke [17,19,184]. Takvi rezultati predstavljaju važnu osnovu za razvoj modela studenta, ali imaju drugačiju granularnost i namenu od konačnog pristupa disertacije: predikcija završnog ishoda ne određuje koji konkretan deo sadržaja zahteva podršku, pripadnost ponašajnom klasteru ne predstavlja individualno stanje znanja, a preporuka izvedena iz obrazaca grupe nije isto što i preporuka koja se može slediti do individualnog

dokaza, kompetencije i konkretnog objekta učenja. Upravo su ova ograničenja prethodnih faza korišćena kao zahtevi za razvoj narednih iteracija modela. Takva iterativna razvojna logika prati definisanu metodologiju disertacije.

Istraživački jaz kojim se ova disertacija bavi zato ne predstavlja odsustvo pojedinačne metode za modelovanje studenta, ontološkog modela nastavnog sadržaja ili algoritma za preporučivanje. Reč je o nedostatku pristupa koji ove komponente operativno povezuje u jedinstven i interpretabilan proces, u kome se dokaz nastao kroz aktivnost studenta zadržava i koristi u svim koracima, od modelovanja stanja studenta do adaptivne odluke. Takav proces treba da obezbedi da se:

- rezultat studentske aktivnosti interpretira u odnosu na konkretan objekat učenja, ishod učenja, kompetenciju i odgovarajući nivo dubine, umesto da ostane samo izolovan pokazatelj postignuća;
- iz sekvence tako strukturiranih dokaza formira dinamička i interpretabilna procena ovladanosti pojedinačnog studenta, uz razdvajanje procenjene ovladanosti od ostvarenosti propisanih aktivnosti i od ponašajnih karakteristika studenta;
- identifikovana individualna potreba za podrškom lokalizuje na nivou konkretnog nastavnog sadržaja;
- stanje studenta poveže sa ontološkim relacijama nastavnog sadržaja kako preporuka ne bi predstavljala samo rangiranu listu slabih oblasti, već strukturno uređenu individualnu putanju koja poštuje odnose preduslova i odnose osnovnog i naprednog sadržaja;
- razlog uključivanja određenog objekta u preporuku može slediti unazad do podataka o studentu, procene modela, pripadajuće kompetencije i ontološke relacije na osnovu koje je adaptivna odluka doneta.

U odnosu na navedeni istraživački jaz, originalnost pristupa razvijenog u ovoj disertaciji prvenstveno se nalazi u načinu integracije i operacionalizacije navedenih komponenti, a ne u predlaganju novog osnovnog algoritma mašinskog učenja. Ontološki model objekata učenja [14] proširen je kompetencijskom dimenzijom zasnovanom na okviru [15], tako da objekti učenja mogu biti povezani sa ishodima, kompetencijama, komponentama znanja i veštine i nivoima dubine. Aktivnosti provere semantički se povezuju sa elementima ove strukture, čime njihovi rezultati postaju ulazni dokazi za model studenta. Nad tako formiranim dokazima model studenta kombinuje sekvencijalnu procenu ovladanosti, ostvarenost aktivnosti prema

nivoima dubine, lokalne dijagnostičke pokazatelje i ponašajni kontekst, pri čemu se njihove funkcije namerno razdvajaju. Takvo razdvajanje predstavlja važan deo predloženog pristupa. Procena ovladanosti opisuje modelom procenjeno stanje na nivou kompetencije i dubine. Ostvarenost nivoa pokazuje koliki je deo poena predviđenih za aktivnosti određenog nivoa student ostvario, lokalni indikator na nivou objekta učenja omogućava identifikovanje konkretnog sadržaja kojem je potrebna podrška, dok ponašajni tip opisuje način rada i angažovanja studenta, ali se ne koristi kao zamena za procenu njegovog znanja. Time se izbegava svođenje modela studenta na jednu agregiranu ocenu ili jednu kategoriju i omogućava da različiti slojevi modela imaju jasno određene funkcije u procesu adaptacije.

Dodatna razlika u odnosu na pristupe u kojima se preporuka završava izborom relevantnih resursa jeste razvoj i korišćenje formalne strukture ontologije pri određivanju konačne individualne putanje. Identifikovana slaba tačka ili obavezni sadržaj za koji student još nema dokaz ne posmatraju se izolovano. Ontološke relacije redosleda koriste se radi uključivanja potrebnih preduslova, dok relacije osnovnog i naprednog sadržaja omogućavaju odgovarajuće uređivanje putanje u skladu sa strukturom domena. Na taj način analitički rezultat modela studenta dobija neposrednu nastavnu funkciju: prevodi se u izbor i redosled konkretnih objekata učenja.

Poseban aspekt originalnosti odnosi se na sledljivost adaptivne odluke. U predloženom pristupu preporuka nije rezultat netransparentnog generativnog postupka, već se može obrazložiti povezivanjem preporučenog objekta učenja sa identifikovanom potrebom, procenom modela studenta i ontološkim odnosima koji određuju njegov položaj u putanji. Jezičko formulisanje objašnjenja odvojeno je od procesa donošenja adaptivne odluke: generativni model, kada se koristi, dobija već strukturirane činjenice i nema ulogu u određivanju slabih tačaka, izboru sadržaja ili njegovom redosledu. Time se objašnjivost prvenstveno zasniva na sledljivosti strukturiranog procesa odlučivanja, a ne samo na naknadno generisanom tekstualnom obrazloženju. Ova separacija je jasno definisana i u završnoj implementaciji disertacije.

Na osnovu navedenog, razvojni kontinuitet istraživanja može se sagledati kao prelazak od ontološki organizovanog i vizuelizovanog prostora objekata učenja [14], preko kompetencijskog strukturiranja sadržaja prema širini i dubini [15] i analitičkog modelovanja studentskih obrazaca [17,19], ka integrisanom pristupu u kojem se individualni dokaz povezuje sa kompetencijom i objektom učenja, transformiše u višeslojnu procenu stanja studenta i zatim

koristi za formiranje ontološki uređene i objašnjive preporuke. Centralni doprinos disertacije stoga predstavlja uspostavljanje operativne veze prikazane na Slici 2.

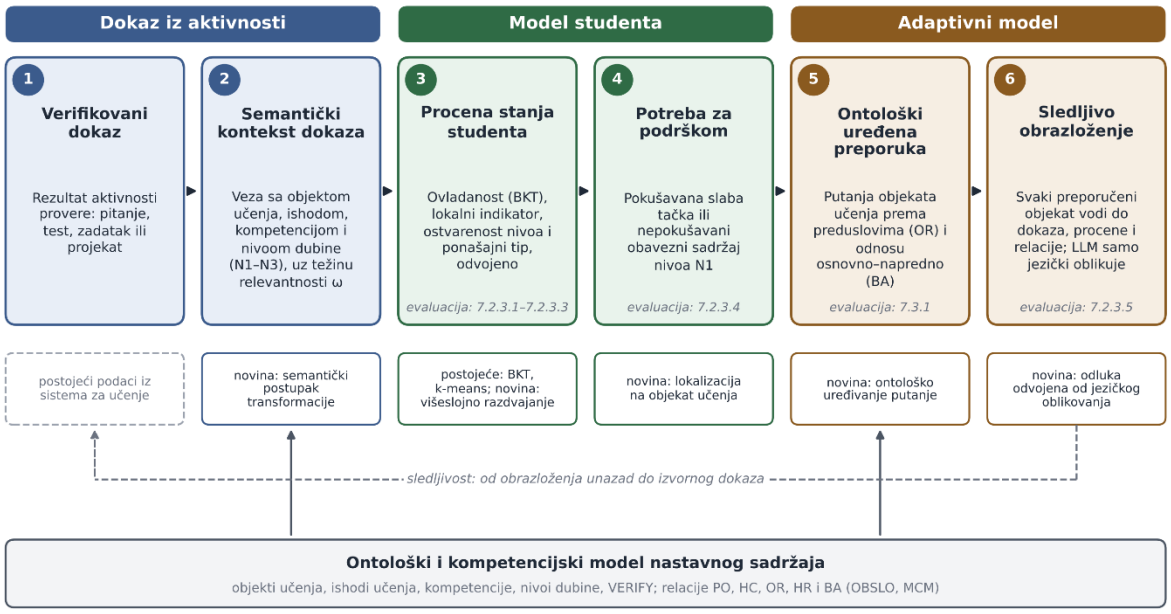

Slika 2. Centralni doprinos disertacije: operativni lanac od verifikovanog dokaza do sledljivog obrazloženja preporuke.

Slika 2 prikazuje šest koraka kroz koje prolazi pojedinačni dokaz o učenju. Rezultat aktivnosti provere (1) najpre dobija semantički kontekst preko ontološkog i kompetencijskog modela nastavnog sadržaja (2). Nad tako strukturiranim dokazima formira se višeslojna procena stanja studenta (3), na osnovu koje se identifikuju potrebe za podrškom na nivou konkretnih objekata učenja (4). Adaptivni model te potrebe povezuje sa ontološkim relacijama i formira uređenu putanju objekata učenja (5), uz obrazloženje koje se može slediti unazad do izvornog dokaza (6). Ispod svakog koraka naznačeno je da li se oslanja na postojeće metode ili predstavlja metodološku novinu disertacije, kao i odeljak u kome je evaluiran.

Ovakvo pozicioniranje određuje i granice tvrdnje o originalnosti. Disertacija ne uvodi ontologije, kompetencijske modele, BKT, klasterovanje, XAI ni sisteme preporuka kao nove metode; njihova primena predstavlja rezultat povezivanja i implementacije postojećih rešenja. Metodološku novinu čine postupci kojima se te komponente povezuju. Prvi je semantički postupak kojim se rezultat aktivnosti provere prevodi u strukturiran dokaz vezan za objekat učenja, kompetenciju i nivo dubine, uz relativni značaj te veze, čime element VERIFY dobija operativno značenje. Drugi je višeslojni model studenta u kome se nad istim dokazima odvojeno određuju sekvencijalna procena ovladanosti, lokalni indikator na nivou objekta učenja, ostvarenost nivoa i ponašajni tip. Treći je adaptivni postupak koji identifikovane potrebe prevodi u uređenu putanju objekata učenja preko ontoloških relacija preduslova i

odnosa osnovnog i naprednog sadržaja, uz sledljivo obrazloženje odvojeno od njegovog jezičkog oblikovanja.

Rezultati evaluacije potvrđuju ove novine u granicama provere izvodljivosti, interpretabilnosti i unutrašnje stabilnosti. Primena na podacima dva predmeta pokazala je da ovladanost kompetencijama i ostvarenost nivoa daju različite informacije o istim studentima (odeljak 7.2.3.1) i da lokalni indikator, zajedno sa statusom pokušaja, razlikuje pokušavane slabe tačke od nepokušavanog obaveznog sadržaja (odeljak 7.2.3.4). Ponašajni tipovi formirani samo iz atributa angažovanja pokazali su se stabilnim pri proverama robusnosti, dok nijedna varijanta u koju su uključeni pokazatelji postignuća nije dala bolje razdvojene klastere, što podržava razdvajanje ponašanja od procene znanja (odeljak 7.2.3.3). Ontološki uređena putanja čuva zavisnosti preduslova i odnose osnovnog i naprednog sadržaja koje rangiranje samo prema procenjenoj ovladanosti zanemaruje (odeljak 7.3.1), a 86 studenata ocenilo je preporuke i njihova obrazloženja kao pretežno razumljive, relevantne i korisne (odeljak 7.2.3.5). Uzročni uticaj preporuka na ishode učenja, univerzalna prenosivost i interoperabilnost sa proizvoljnim LMS platformama ne izvode se kao zaključci iz sprovedene evaluacije.

Poglavlje 3

3. Metodologija

U ovom poglavlju su predstavljeni metodološki pristupi i istraživačke strategije korišćene za postizanje ciljeva disertacije. Poglavlje razmatra izazov u istraživanjima softverskog inženjerstva, uključujući dva osnovna pristupa: istraživanje usmereno ka sticanju znanja i istraživanje usmereno ka pronalaženju rešenja. Metodologija nauke o projektovanju (engl. Design Science (DS)) je prikazana kao ključna paradigma koja integriše ove pristupe kroz iterativni ciklus konceptualizacije problema, projektovanja rešenja i empirijske validacije, a koji je korišćen kao osnovni metodološki pristup u ovoj disertaciji. Samim tim, u poglavlju se fokus stavlja na metodološki prikaz kako su ovi principi primenjeni u razvoju modela za adaptivno i personalizovano učenje, uključujući evaluaciju i testiranje predloženih modela u obrazovnom kontekstu. Na kraju, detaljno su opisani izvori podataka i vremenski okvir istraživanja koji obuhvata različite obrazovne sisteme i periode.

3.1. Istraživanja u softverskom inženjerstvu

Istraživanja u oblasti softverskog inženjerstva suočavaju se sa brojnim izazovima, posebno u vezi sa metodologijama koje se koriste. Jedan od ključnih problema je jak fokus na ograničen skup specifičnih metoda, kao što su eksperimentisanje, studije slučaja i ankete koje su, prema Stolu i Ficdžeraldu [216], tri najčešće korišćene empirijske metode. Iako su ove metode najčešće korišćene, postoje i mnoge druge metode koje nisu dovoljno istražene ili primenjene. Dodatni problem predstavlja nedostatak saglasnosti oko taksonomije metoda, što otežava sistematsko poređenje i analizu različitih pristupa [217]. U okviru istraživanja softverskog inženjerstva mogu se identifikovati dva osnovna pristupa [217]:

- **Istraživanje usmereno ka sticanju znanja (engl. *knowledge-seeking research)*:** fokusira se na razumevanje fenomena, tehnologija, organizacija i ljudi u različitim okruženjima. Ova vrsta istraživanja obuhvata prikupljanje podataka i analizu s ciljem doprinosa bazi znanja u oblasti softverskog inženjerstva. Primeri uključuju

studije slučaja i eksperimentalna istraživanja koja istražuju kako određene prakse funkcionišu u specifičnim kontekstima.

- **Istraživanje usmereno ka pronalaženju rešenja (engl. *solution-seeking research)***: ovo istraživanje je fokusirano na projektovanje, kreiranje ili razvoj rešenja za određene izazove u softverskom inženjerstvu. Rezultati ovakvih studija mogu uključivati algoritme, modele ili alate. Ove studije često koriste postojeća znanja iz baze znanja softverskog inženjerstva i doprinose toj bazi kroz novo znanje koje pokazuje kako se određeni inženjerski problem može rešiti.

Istraživanje usmereno ka pronalaženju rešenja se često poistovećuje sa metodologijom Nauke o projektovanju (DS) [218]. Međutim, preciznija definicija DS-a, data u [219] pokazuje da DS obuhvata evalucione studije koje spadaju u istraživanja usmerena ka sticanju znanja, ali i istraživanje usmereno ka pronalaženju rešenja. Zato su, istraživanje usmereno ka sticanju znanja, kao i istraživanje usmereno ka pronalaženju rešenja, međusobno komplementarni i često se koriste zajedno u istraživanjima [220]. U tom kontekstu, istraživanje usmereno ka sticanju znanja pruža osnovu za razumevanje problema i identifikaciju potreba, dok istraživanje usmereno ka pronalaženju rešenja omogućava razvoj praktičnih odgovora na te potrebe. Korišćenje oba pristupa osigurava da istraživanja budu i teorijski utemeljena i praktično relevantna, pa istraživači mogu prvo koristiti znanje stečeno kroz teorijska istraživanja kako bi kreirali nova rešenja, a zatim ta rešenja testirati u stvarnom svetu kako bi se potvrdila njihova efikasnost [217].

3.2. Metodologija nauke o projektovanju

DS se često koristi u softverskom inženjerstvu jer omogućava istraživačima da razvijaju i testiraju nove alate i metode u realnim okruženjima, dok istovremeno obogaćuju teorijsku osnovu discipline [221]. Ovaj metodološki pristup naglašava važnost iterativnog ciklusa između istraživanja usmerenog ka sticanju znanja i istraživanja usmerenog ka pronalaženju rešenja, čime se osigurava da istraživanje ne samo da rešava konkretne probleme, već i doprinosi razvoju opšteg znanja i teorija u oblasti [222]. DS je predstavljen kao jedna od tri glavne istraživačke paradigme [221], zajedno sa formalnim naukama i naukama koje opisuju postojeće fenomene. Dok se fundamentalne nauke (npr. matematika) fokusiraju na kreiranje konzistentnih sistema znanja bez potrebe za empirijskom validacijom, a druge nauke opisuju i objašnjavaju fenomene, DS ima za cilj unapređenje strukturiranja artefakata i sistema u kontekstu prakse. Ovo čini DS pogodnim za softversko inženjerstvo, a primer ove paradigme

u softverskom inženjerstvu je definisana [223] i prikazana na Slici 3. Definiciju nauke o projektovanju koju je razradio Hevner i saradnici za informacione sisteme [219], a Wieringa [224] proširio na softverski inženjering, Runeson i saradnici [223] su integrisali sa perspektivama Van Akena iz teorije menadžmenta [222]. Ključne predložene aktivnosti su (Slika 3):

1. **Konceptualizacija problema:** razumevanje i opis problema kroz prizmu potencijalnog rešenja, uključujući tehničke i društvene aspekte.
2. **Projektovanje rešenja:** kreativno mapiranje problema u opšte rešenje, uz korišćenje postojećih istraživanja i alata.
3. **Empirijska validacija:** provera učinkovitosti rešenja u realnim ili simuliranim uslovima, uzimajući u obzir specifičnosti problema i okruženja.

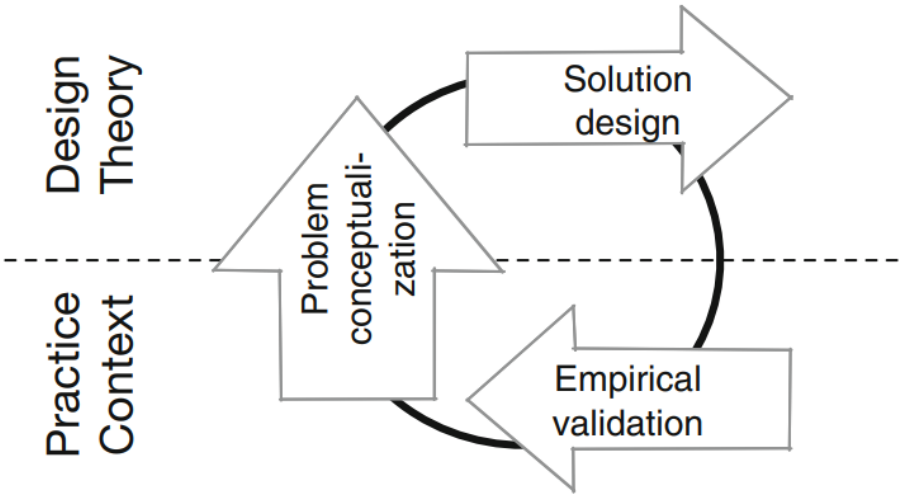

Slika 3. Vizualizacija tipova istraživačkih aktivnosti u metodologiji nauke o projektovanju. Preuzeto iz [223].

Ciklus istraživačkih aktivnosti u okviru DS paradigme, koji obuhvata problem konceptualizacije, projektovanje rešenja i empirijsku validaciju je iterativan, što znači da istraživači mogu da se vraćaju na prethodne korake kako bi unapredili rešenja na osnovu dobijenih povratnih informacija. Iterativna priroda DS procesa omogućava neprekidno poboljšanje rešenja na osnovu povratnih informacija dobijenih kroz empirijsku validaciju. Ovo osigurava da se rešenja neprestano prilagođavaju stvarnim potrebama i novim izazovima iz prakse.

Paradigma DS-a se koristi u mnogim poljima istraživanja koja imaju za cilj razumevanje i poboljšanje neke oblasti prakse, a odatle proizilaze i različiti termini koji se koriste kao sinonimi. Jedan od njih je *Istraživanja zasnovana na projektovanju* (engl. Design-Based Research (DBR)) koji se često primenjuje u obrazovnim istraživanjima za razvoj i evaluaciju obrazovnih praksi i tehnologija, pri čemu se naglasak stavlja na razvoj teorija i intervencija koje su testirane u stvarnim situacijama [225]. Slično tome, pojam Design Science Research (DSR) koristi se u poljima kao što su informacioni sistemi i softversko inženjerstvo. Ovaj pristup uključuje identifikaciju i konceptualizaciju problema, projektovanje rešenja, i validaciju predloženih rešenja, s ciljem poboljšanja praktičnih rešenja u softverskom inženjerstvu i razvoju alata i metoda [222]. Tehničko akciono istraživanje (engl. Technical Action Research (TAR)) je još jedan srodni pojam koji kombinuje inženjerski ciklus i empirijski istraživački ciklus kako bi se integrisala istraživanja sa realnim projektima, a koristi se za validaciju tehnologije u informacionim sistemima i softverskom inženjerstvu [224,226,227].

3.3. Primenjene metode istraživanja

U ovoj doktorskoj disertaciji primenjena je *metodologija paradigme nauke o projektovanju* (engl. Design Science Paradigm (DSP)), kako je predložena u [223]. Osnova primenjene metodologije, *nauka o projektovanju* (DS) predstavlja istraživački pristup usmeren na stvaranje i evaluaciju artefakata, metoda i sistema koji mogu unaprediti praksu u određenoj oblasti. Za razliku od nauka koje se bave isključivo opisivanjem i objašnjavanjem postojećih fenomena, DS se fokusira na kreiranje novih rešenja kroz iterativni proces projektovanja, implementacije i evaluacije. Specifičan metodološki okvir DS-a je *paradigma nauke o projektovanju* (DSP), koji proširuje opšte istraživačke aktivnosti nauke o projektovanju (Slika 3), sa posebnim fokusom na empirijska istraživanja u softverskom inženjerstvu i na način na koji se principi DSP-a mogu koristiti za unapređenje metodologija i praksi u ovoj oblasti [228] (Slika 4). DSP se fokusira na sistematski razvoj, implementaciju i evaluaciju novih tehnologija i rešenja u stvarnim okruženjima, što je posebno značajno u softverskom inženjerstvu, gde je važno ne samo razvijati teorijske modele već ih i testirati u praksi. Zbog toga DSP predstavlja metodološki okvir koji je disertacija primenila u svim fazama istraživanja.

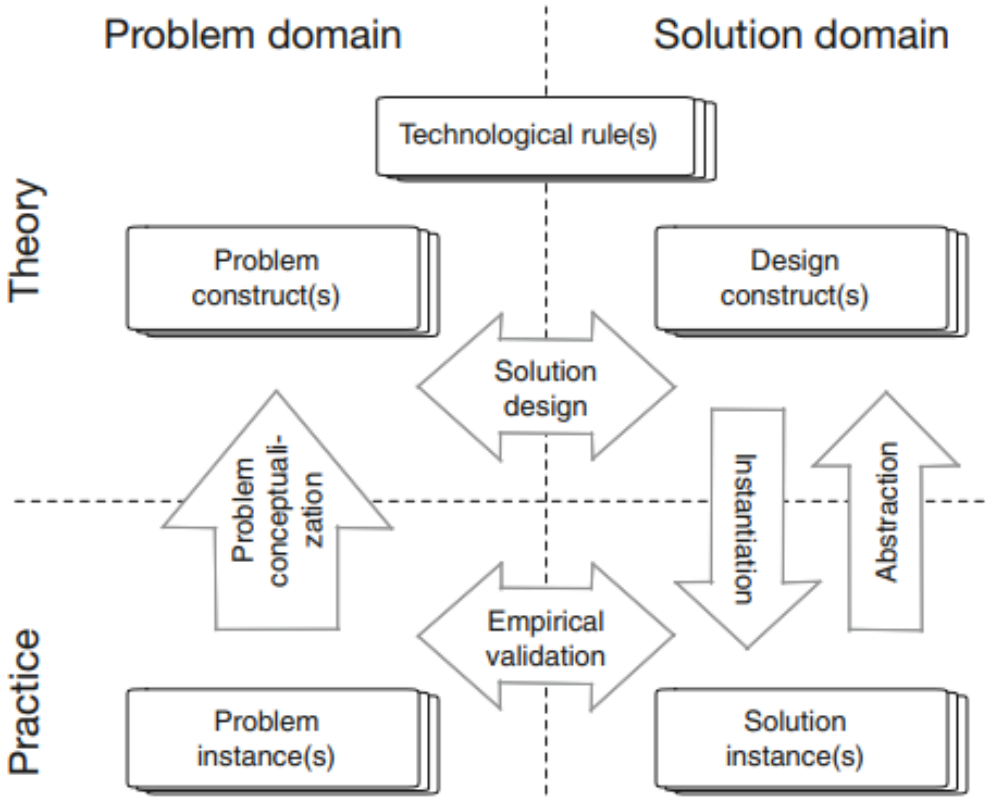

Slika 4. Model doprinosa nauke o projektovanju u softverskom inženjerstvu. Preuzeto iz [223] i [228].

Slika 4 ilustruje dvodimenzionalni model nauke o projektovanju koji se sastoji od dve glavne dimenzije: *problem-rešenje* i *teorija-praksa*. Ovaj model prikazuje kako se različite istraživačke aktivnosti u okviru DS-a odvijaju kroz prelaze između ova dva aspekta. *Problem-rešenje* dimenzija (donji kvadranti slike) bave se instanciranjem problema i rešenja, koji predstavljaju praktični doprinos istraživanja. *Teorija-praksa* dimenzija (gornji kvadranti) predstavljeni su teorijski doprinosi, uključujući generalizaciju i definisanje opsega kroz tehnološka pravila i odgovarajuće konstrukte (koncepti ili pojmovi koji se koriste za opisivanje i razumevanje problema ili rešenja u određenom istraživačkom kontekstu). Ovi kvadranti se bave stvaranjem opšteg znanja i teorijskih okvira koji se mogu primeniti na širok spektar problema. Strelice na Slici, koje povezuju ove kvadrante, prikazuju različite aktivnosti stvaranja znanja, koje mogu obavljati i istraživači i praktičari. Ove aktivnosti uključuju:

- **Konceptualizacija problema**: Razumevanje i definisanje problema.
- **Projektovanje rešenja**: Razvijanje rešenja za identifikovani problem.
- **Apstrakcija**: Generalizacija znanja iz specifičnih instanci kako bi se razvila opšta pravila ili teorije.
- **Instanciranje**: Implementacija rešenja u specifičnim kontekstima.

- **Empirijska validacija**: Provera efikasnosti rešenja u praksi.

Ovako postavljena metodologija istražuje kako se teorijski i praktični doprinosi DS-a međusobno povezuju kroz kontinuirani ciklus istraživačkih aktivnosti, omogućavajući stalno unapređenje znanja i praksi u ovoj oblasti.

3.3.1. Mapiranje postavljene metodologije i doktorske disertacije

Metodološki okvir disertacije organizovan je oko tri funkcionalno razdvojena, ali međusobno povezana modela: (i) modela nastavnog sadržaja, (ii) modela studenta i (iii) adaptivnog modela. Model nastavnog sadržaja obezbeđuje formalnu i semantičku strukturu nastavnih elemenata i njihovih međusobnih relacija. Model studenta na osnovu aktivnosti i dokaza iz provera formira dinamičku procenu trenutnog stanja pojedinačnog studenta. Adaptivni model povezuje procenjeno stanje sa strukturom nastavnog sadržaja radi izbora, uređivanja i objašnjavanja preporučenih objekata učenja. Tokovi podataka između ova tri modela prikazani su na Slici 5.

U konačnoj fazi istraživanja adaptivni model je operacionalizovan kao sastavni deo integrisane arhitekture. Njegova uloga je da izlaze modela studenta, uključujući procene ovladanosti, ostvarenost nivoa, status pokušaja i ponašajni kontekst, poveže sa ontološkim relacijama nastavnog sadržaja i prevede ih u uređenu i sledljivu preporuku. Evaluacija ovog sloja u okviru disertacije odnosi se na izvodljivost integrisanog postupka i na percepciju razumljivosti, relevantnosti i korisnosti preporuka od strane studenata, a ne na dokazivanje uzročnog efekta preporuke na ishode učenja.

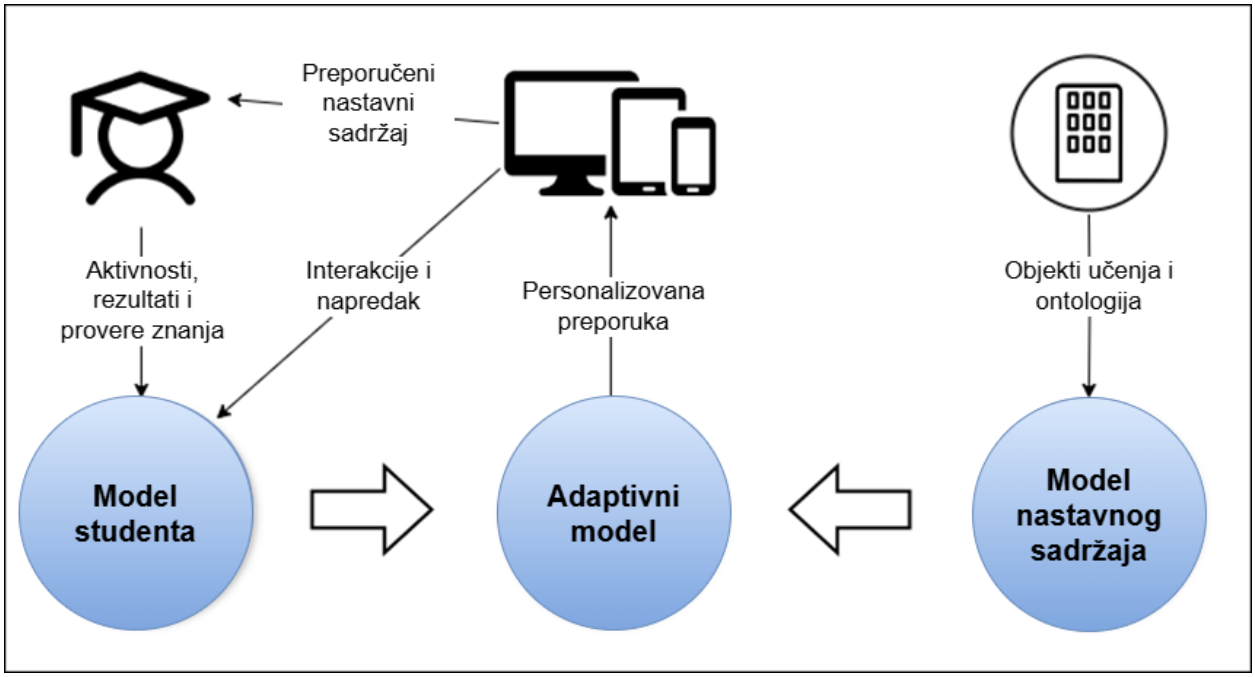

Slika 5. Tokovi podataka između modela studenta, modela nastavnog sadržaja i adaptivnog modela u predloženom sistemu.

DSP metodologija omogućila je da se razvoj ova tri modela posmatra kao iterativni razvoj međusobno povezanih istraživačkih artefakata. Modeli su konceptualno razdvojeni kako bi njihove odgovornosti i izlazi bili jasno definisani, ali nisu razvijani kao nezavisna rešenja. Nalazi dobijeni projektovanjem i evaluacijom jednog artefakta korišćeni su za definisanje zahteva naredne iteracije. Ontološki model nastavnog sadržaja obezbedio je semantičku osnovu za kasnije povezivanje aktivnosti sa konkretnim nastavnim elementima, prve dve faze modelovanja studenta ukazale su na ograničenja agregiranog i grupnog predstavljanja studenata, dok je konačna iteracija povezala kompetencijski strukturiran sadržaj, dinamički model studenta i adaptivni mehanizam u jedinstven proces.

U prvoj fazi DSP metodologije, *konceptualizaciji problema*, fokus je bio na razumevanju i definisanju problema koji treba rešiti. Kroz pregled i analizu relevantne literature o personalizovanom i adaptivnom učenju identifikovani su ključni izazovi i potrebe u oblasti obrazovanja. Na osnovu ovog pregleda literature, utvrđeno je da je potrebno razviti modele koji će omogućiti prilagodljivost nastavnog sadržaja prema potrebama studenata. Ova faza konceptualizacije problema bila je presudna za definisanje osnovnih elemenata modela koji su razvijani u daljim fazama.

Nakon konceptualizacije problema, projektovanje rešenja sprovedeno je kroz više povezanih artefakata i iteracija. Najpre je razvijen ontološki model nastavnog sadržaja kojim su formalizovani koncepti domena, objekti učenja i relacije potrebne za njihovu organizaciju,

pretragu i vizuelizaciju. Model je zatim proširen kompetencijama, ishodima učenja, komponentama znanja i veštine, nivoima dubine i semantičkom vezom prema dokazima iz aktivnosti provere. Paralelno sa razvojem modela sadržaja, model studenta razvijan je kroz tri iteracije: predikciju akademskog uspeha, klasterovanje obrazaca učenja i konačni višeslojni model kontinuiranog praćenja.

Izbor algoritamskih metoda u tim fazama nije zasnovan na pretpostavci da postoji jedan opšte „najefikasniji“ algoritam za modelovanje studenta. Metode su birane u odnosu na istraživačku svrhu pojedinačne iteracije, strukturu raspoloživih podataka i zahtev za interpretabilnošću rezultata. U konačnoj iteraciji sekvencijalna procena ovladanosti realizovana je primenom BKT-a, ostvarenost nivoa određena je odvojeno agregacijom odgovarajućih aktivnosti, a ponašajni obrasci formirani su klasterovanjem atributa angažovanja. Izlazi ovih slojeva zatim su povezani sa ontološkim modelom kroz adaptivni mehanizam.

Razvoj modela studenta sproveden je kroz tri iteracije DSP ciklusa, pri čemu je svaka iteracija obuhvatila projektovanje odgovarajućeg rešenja, njegovo instanciranje nad stvarnim obrazovnim podacima i evaluaciju dobijenih rezultata. U prvoj iteraciji ispitan je pristup predikciji akademskog uspeha primenom algoritama mašinskog učenja nad agregiranim podacima [184]. Dobijeni rezultati pokazali su da se akademski uspeh može predviđati na osnovu raspoloživih atributa, ali je izlaz takvog modela ostao na agregiranom nivou i nije omogućavao lokalizovanje potrebe za podrškom na konkretnom nastavnom sadržaju.

U drugoj iteraciji analizirani su obrasci studentskog angažovanja klasterovanjem podataka iz dva različita institucionalna i nastavna konteksta [19]. Ova analiza pokazala je da grupni obrasci mogu pružiti korisne informacije o načinu rada studenata, ali i da zavise od strukture nastavnog procesa, granularnosti sadržaja i načina beleženja aktivnosti. Pripadnost klasteru takođe nije pružala dovoljno fino predstavljanje stanja pojedinačnog studenta.

Nalazi prve dve iteracije neposredno su oblikovali zahteve treće iteracije. Iz prve iteracije proistekla su dva zahteva. Pošto je model predviđao ishod celog predmeta na osnovu zbirnih pokazatelja, njegov rezultat mogao je da ukaže koji je student u riziku, ali ne i koji deo gradiva nije savladao. Zato je u trećoj iteraciji osnovna jedinica ulaza postao rezultat pojedinačne aktivnosti provere, mapiran na objekat učenja, kompetenciju i nivo dubine (odeljak 6.5.1). Pored toga, predikcija je formirana jednom, nad podacima prikupljenim do određenog trenutka,

pa nije pratila promenu stanja studenta tokom semestra. Za procenu ovladanosti zato je izabrano sekvencijalno praćenje znanja (BKT), koje se ažurira posle svakog novog dokaza.

Iz druge iteracije proistekla su tri zahteva. Prvo, na podacima BMU broj bodova na testovima imao je najveći doprinos razlikovanju klastera, pa su klasteri u velikoj meri odražavali uspeh, a ne način rada studenata. Zato se u konačnom modelu ponašajni tip formira isključivo iz atributa angažovanja, dok se znanje procenjuje odvojeno. Drugo, razlike između BMU i FOI pokazale su da rezultati zavise od granularnosti nastavnog sadržaja i načina mapiranja aktivnosti, pa je u trećoj iteraciji mapiranje aktivnosti na objekte učenja definisano eksplicitno i jednoobrazno, uz težinu relevantnosti za aktivnosti koje obuhvataju više objekata učenja. Treće, pripadnost klasteru opisuje grupu, a ne pojedinačnog studenta, pa ponašajni tip u konačnom modelu služi samo kao kontekst za predstavljanje i obrazloženje podrške, dok se izbor i redosled sadržaja zasnivaju na individualnoj proceni ovladanosti, statusu pokušaja i lokalnom indikatoru na nivou objekta učenja. Evaluacija ontološki organizovanog prostora za učenje (odeljak 7.1.2) dala je još jedan zahtev. Studenti koji nisu tačno rešili pojedine zadatke, na primer zadatak Q2, nisu prepoznali koji im je objekat učenja potreban, iako im je bio dostupan u MCM prikazu. Zbog toga se u konačnom modelu izbor i redosled objekata učenja ne prepuštaju samo navigaciji studenta, već ih predlaže adaptivni mehanizam na osnovu identifikovane potrebe i ontoloških relacija. Iz svih prethodnih faza proistekao je i zahtev za interpretabilnošću: svaki izlaz modela mora se moći objasniti studentu i nastavniku. Zato su u trećoj iteraciji korišćeni interpretabilni postupci, a izlazi različitih slojeva namerno su razdvojeni. Dodatne analize osetljivosti, unakrsne validacije i robustnosti korišćene su za proveru stabilnosti ključnih odluka modelovanja. Ovakav razvoj ilustruje iterativnu prirodu nauke o projektovanju, u kojoj ograničenja prethodnog artefakta postaju projektni zahtevi sledeće iteracije.

Faza apstrakcije odnosila se na izdvajanje projektnih principa i metodoloških rešenja iz konkretnih instanci razvijenih tokom istraživanja. Cilj apstrakcije nije bio da se na osnovu ograničenog broja analiziranih predmeta empirijski dokaže univerzalna prenosivost modela, već da se utvrdi koji delovi rešenja nisu vezani za jedan konkretan predmet ili softversku platformu. Takvi elementi obuhvataju razdvajanje semantičkog modela nastavnog sadržaja od dinamičkog modela studenta, mapiranje dokaza na objekte učenja i kompetencije, korišćenje kombinacije *predmet-kompetencija predmeta-nivo dubine* kao jedinice sekvencijalne procene, razdvajanje ovladanosti, ostvarenosti i ponašajnog obrasca, kao i odvajanje adaptivne odluke od njenog završnog jezičkog objašnjenja. Na nivou softverske arhitekture apstrakcija je

ostvarena razdvajanjem funkcionalnih komponenti i definisanjem strukturirane razmene podataka između njih. Ovakva rešenja predstavljaju osnovu za moguću primenu u drugim predmetima i sistemima, ali njihovu stvarnu prenosivost na druge discipline, institucije i tehnološka okruženja potrebno je dodatno empirijski proveriti. Zaključci o opsegu generalizacije i ograničenjima prenosivosti razmatraju se u Poglavlju 8.

U ovoj disertaciji instanciranje označava konkretizaciju projektovanih modela u određenom obrazovnom i softverskom kontekstu. Različiti artefakti instancirani su na različite načine. Ontološki model i multidimenzionalne konceptualne mape implementirani su u OBSLO okruženju i korišćeni u stvarnim nastavnim zadacima. Prve dve iteracije modela studenta instancirane su nad stvarnim skupovima podataka radi ispitivanja predikcije i ponašajnih obrazaca. Konačni višeslojni model instanciran je nad evidencijama aktivnosti i provera studenata predmeta Uvod u softversko inženjerstvo (SE201) i Objektno orijentisano programiranje 2 (CS202), dok je adaptivni sloj na osnovu njegovih izlaza formirao konkretne uređene preporuke. Kontrolna tabla sa prikazom stanja, preporuka i objašnjenja predstavljena je studentima i evaluirana putem anonimnog upitnika.

Pojam empirijske validacije u okviru DSP ciklusa se u ovoj disertaciji odnosi na evaluaciju artefakata u skladu sa njihovom namenom, a ne na jednu zajedničku meru uspešnosti. Model nastavnog sadržaja evaluiran je kroz zadatke, analizu putanja, vreme korišćenja i povratne informacije studenata. Prva faza modela studenta evaluirana je standardnim metrikama prediktivnog modelovanja, dok je druga faza analizirala mogućnost izdvajanja i interpretiranja obrazaca angažovanja. U trećoj fazi procena ovladanosti proverena je analizama osetljivosti i unakrsnom validacijom, a ponašajni klasteri analizama stabilnosti, alternativnim metodama klasterovanja i izostavljanjem pojedinačnih atributa. Integrisana arhitektura zatim je ocenjena u pogledu mogućnosti da stvarne podatke prevede u interpretabilno stanje studenta i ontološki utemeljenu preporuku, dok je upitnikom studenata procenjena percipirana razumljivost, relevantnost i korisnost prikazanih preporuka.

Konačna faza predstavlja proveru koncepta na stvarnim obrazovnim podacima, a ne kontrolisani eksperiment kojim bi se dokazao uzročni uticaj preporuke na učenje. Razvijeno rešenje nije tokom ove evaluacije uvedeno kao produkcioni sistem koji u realnom vremenu automatski menja putanju svakog studenta, već pilot implementacija koja je primenjena u nekoliko nedelja nastave. Zbog toga empirijski rezultati podržavaju izvodljivost, stabilnost pojedinih komponenti i interpretabilnost integrisanog postupka u analiziranom kontekstu, dok

efekat adaptivnih preporuka na znanje, angažovanje i ostvarivanje aktivnosti zahteva zasebnu kontrolisanu ili kvazieksperimentalnu evaluaciju.

Kroz navedene faze DSP metodologija omogućila je da se razvoj artefakata poveže sa empirijskim nalazima iz prethodnih iteracija i da se konačna arhitektura izgradi kao rezultat kumulativnog procesa projektovanja, instanciranja, evaluacije i apstrakcije. Dobijeni rezultati podržavaju izvodljivost i interpretabilnost razvijenih modelskih i metodoloških rešenja u analiziranim obrazovnim kontekstima, dok njihova primena u drugim institucijama, disciplinama i tehnološkim okruženjima predstavlja predmet dalje validacije. Na taj način se u disertaciji jasno razdvajaju demonstrirana svojstva konkretnih instanci od projektnih principa za koje se pretpostavlja šira prenosivost.

Mapiranje između poglavlja disertacije i odgovarajućih faza DSP metodologije dato je u Tabeli 2.

Tabela 2. Mapiranje aktivnosti metodologije nauke o projektovanju na poglavlja disertacije.

Aktivnost DSP	Poglavlje
Konceptualizacija problema	Poglavlje 1: Uvod; Poglavlje 2: Pregled relevantne literature
Projektovanje rešenja	Poglavlje 4: Teorijski okvir za postavljanje problema; Poglavlje 5.1: Ontološki model sadržaja za učenje; Poglavlje 6.1-6.2: Definicija i projektni zahtevi modela studenta
Instanciranje	Poglavlje 5.2: Vizualizacija i softverska arhitektura (primer Baze podataka, 5.2.1.2); Poglavlje 6.3-6.5: tri iterativne implementacije modela studenta; Poglavlje 6.5.3: arhitektura finalnog modela
Empirijska validacija	Validacija pojedinačnih iteracija u Poglavlju 6 (6.3-6.5); Poglavlje 7.1: Evaluacija modela nastavnih materijala; Poglavlje 7.2: Primena modela studenta na dva predmeta, uključujući anketu studenata
Apstrakcija	Poglavlje 5.1.1: Fleksibilnost ontološkog modela nastavnih sadržaja; Poglavlje 8: Zaključci, prednosti pristupa, prenosivost i budući rad

U okviru dvodimenzionalnog modela sa Slike 4, doprinosi disertacije mogu se pozicionirati prema aktivnostima nauke o projektovanju. Doprinosi 1-4, koji obuhvataju razvoj proširivog ontološkog modela, njegovo kompetencijsko proširenje, multidimenzionalnu vizuelizaciju i višeslojni model studenta, predstavljaju konstrukciju artefakata i pripadaju aktivnosti projektovanja rešenja. Doprinosi 5 i 6, kojima se pojmovno razdvajaju ovladanost kompetencijama od ostvarenosti nivoa, odnosno ponašajni obrazac od procene znanja,

predstavljaju generalizaciju znanja u opšte distinkcije primenljive izvan konkretnih predmeta i pripadaju aktivnosti apstrakcije, zajedno sa zaključcima o prenosivosti modela izloženim u Poglavlju 8. Metodološki doprinosi (7-10), koji definišu postupke povezivanja aktivnosti provere sa objektima učenja, integrisane procene ovladanosti i formiranja objašnjivih preporuka, takođe pripadaju projektovanju rešenja na nivou postupaka. Softversko-arhitekturni doprinosi (11-13), koji obuhvataju softverski okvir, ontološki prostor za pronalaženje i korišćenje sadržaja i prikaz individualnog stanja studenta, pripadaju instanciranju, odnosno konkretnoj implementaciji razvijenih rešenja. Empirijski doprinosi (14-16) pripadaju empirijskoj validaciji.

3.3.2. Metode prikupljanja i analize podataka

U okviru navedenih aktivnosti nauke o projektovanju korišćena je kombinacija kvalitativnih, kvantitativnih, algoritamskih i korisnički usmerenih metoda. Za konceptualizaciju problema sprovedeni su pregled i analiza relevantne literature i analiza prethodno razvijenih artefakata. Za projektovanje modela nastavnog sadržaja korišćene su smernice za razvoj ontologije prema Noy i McGuinness [229], strukturiranje nastavnih sadržaja u objekte učenja prema DITA standardu i multidimenzionalne konceptualne mape za vizualizaciju semantičke strukture. Objekat učenja predstavlja osnovni gradivni element nastavnih materijala u ovoj disertaciji. To je najmanja samostalna celina nastavnog sadržaja, poput teksta, primera ili video zapisa sa pridruženim zadacima, koja obrađuje jedan određeni pojam ili temu i može se nezavisno koristiti u različitim lekcijama i predmetima. Strukturiranje prema DITA standardu obezbeđuje modularnost i ponovnu upotrebljivost objekata učenja, dok ih ontološki model povezuje sa konceptima domena, ishodima učenja, kompetencijama i nivoima dubine, kao i međusobno, kroz relacije redosleda i relacije osnovnih i naprednih koncepata. Ovakva granularnost ključna je za ceo pristup. Kada su aktivnosti provere povezane sa pojedinačnim objektima učenja, rezultat studenta ne ostaje samo ukupna ocena, već se može pripisati konkretnom sadržaju na koji se odnosi. Na taj način moguće je utvrditi koje delove gradiva je student savladao, gde mu je potrebna dodatna podrška i koje obavezne sadržaje još nije pokušao. Takođe, adaptivna preporuka ne upućuje studenta na celu lekciju ili predmet, već na konkretne objekte učenja, uređene prema ontološkim relacijama, pa je preporuka razumljiva i proverljiva. Objekat učenja je zato mesto na kojem se povezuju model nastavnog sadržaja, model studenta i adaptivni mehanizam.

Razvoj modela studenta obuhvatio je tri različita analitička pristupa. U prvoj iteraciji primenjene su nadgledane metode mašinskog učenja za predikciju akademskog uspeha. U drugoj iteraciji primenjeno je k-means klasterovanje radi analize obrazaca studentskog angažovanja u različitim nastavnim kontekstima. U konačnoj iteraciji sekvencijalna procena ovladanosti zasnovana je na BKT modelu, čiji se parametri procenjuju metodom očekivanja i maksimizacije na nivou kombinacije *predmet-kompetencija predmeta-nivo dubine*.

Kontinuirane opservacije korišćene su radi očuvanja informacije o delimičnom uspehu (formalna definicija data je u odeljku 4.3.2.2, jednačine 5-6), dok je kompletna hronologija ranijih pokušaja zadržana pri proceni ovladanosti. Ostvarenost nivoa izračunavana je odvojeno, samo iz trenutno važećih aktivnosti. Ponašajni tipovi u konačnom modelu formirani su isključivo na osnovu tri standardizovana atributa: obima aktivnosti, broja aktivnih dana i udela ranijih pokušaja. Broj klastera određivan je zasebno za svaki predmet poređenjem rešenja sa dva do pet klastera pomoću koeficijenta siluete. Stabilnost klasterovanja proverena je ponovljenim poduzorkovanjem, poređenjem sa metodama zasnovanim na gustini i analizom izostavljanja pojedinačnih ponašajnih atributa. Stabilnost sloja procene ovladanosti dodatno je proverena analizom osetljivosti na pragove ovladanosti i ponderisanje dokaza, kao i petostrukom unakrsnom validacijom. Kontinuirana BKT formulacija poređena je sa binarnom formulacijom i jednostavnom referentnom procenom na osnovu predviđanja narednog zapažanja. Ove provere korišćene su za procenu stabilnosti projektnih odluka unutar analiziranih kohorti, a ne za tvrdnju o spoljašnjoj generalizaciji na nove populacije.

Stabilnost je dodatno proverena i na nivou individualnog adaptivnog izlaza, odnosno ispitivanjem u kojoj meri promena pragova ovladanosti utiče na identifikovanje slabih tačaka i njihov prioritet u preporučenoj putanji. Analiza je ponovljena za osam alternativnih kombinacija pragova u odnosu na osnovne pragove N1 = 0,80 i N2 = 0,50. Pošto se nepokušani obavezni objekti nivoa N1 identifikuju nezavisno od procenjene ovladanosti i odgovarajućeg praga, analiza osetljivosti sprovedena je samo nad pokušavanim objektima identifikovanim kao slabe tačke. Za svakog studenta posmatrani su promena broja pokušavanih slabih tačaka, Spearmanova korelacija njihovog redosleda u odnosu na osnovno rešenje i Jaccardova sličnost skupa do pet najviše rangiranih pokušavanih slabih tačaka. Na taj način ispitana je ne samo stabilnost numeričkih procena ovladanosti na nivou kohorte već i stabilnost onog dela izlaza modela koji neposredno određuje prioritete individualne preporuke.

Adaptivni postupak evaluiran je povezivanjem izlaza modela studenta sa eksplicitnim ontološkim relacijama radi formiranja konkretnih uređenih putanja učenja. Da bi se procenila

strukturna uloga ontoloških relacija u formiranju putanje, ontološki uređen redosled poređen je sa jednostavnim referentnim postupkom koji koristi isti skup identifikovanih slabih tačaka, ali ih rangira samo prema procenjenoj ovladanosti, bez primene OR i BA relacija. Poređenje je sprovedeno na istim podacima i za iste studente, pri čemu su posmatrani broj prekršenih ontoloških ograničenja između preporučenih objekata i broj slučajeva u kojima uključivanje ontološke strukture menja njihov redosled. Ova analiza nije korišćena za procenu nastavne efikasnosti preporuke, već za utvrđivanje strukturne informacije koju jednostavno rangiranje prema ovladanosti ne uzima u obzir. Izbor objekata i njihov redosled određuju model studenta, pravila adaptivnog mehanizma i ontološka struktura. Veliki jezički model, kada se koristi, ne učestvuje u donošenju adaptivne odluke, već samo u završnom jezičkom formulisanju prethodno strukturiranog objašnjenja.

Empirijska evaluacija obuhvatila je uporednu analizu razvijenog ontološkog okruženja i postojećeg sistema za e-učenje, analizu stvarnih studentskih putanja, primenu modela studenta na stvarne obrazovne podatke, analize robustnosti i korisničke upitnike sa petostepenom Likertovom skalom. Povratne informacije 86 studenata o konačnoj kontrolnoj tabli korišćene su za procenu percipirane razumljivosti, relevantnosti i korisnosti preporuka i objašnjenja. Ova anketa nije korišćena za izvođenje zaključaka o uzročnom uticaju sistema na obrazovna postignuća.

Veza između postavljenih hipoteza, vrste prikupljenih dokaza i poglavlja u kojima su odgovarajući rezultati razmatrani prikazana je u Tabeli 3. Pri tome sve hipoteze nisu proveravane istom vrstom empirijskog dokaza. PH1 i PH2 razmatrane su kroz instanciranje modela nad stvarnim obrazovnim podacima i analizu dobijenih procena i preporuka, dok je PH3 dodatno podržana kroz dve iteracije evaluacije ontološki organizovanog prostora za učenje. PH4 prvenstveno se odnosi na arhitekturnu modularnost i demonstrirane načine povezivanja komponenti; zato se njena podrška ne tumači kao dokaz univerzalne interoperabilnosti sa proizvoljnim sistemom za e-učenje. Evaluacija kontrolne table dodatno pruža podatke o percepciji studenata, ali ne predstavlja kontrolisanu proveru efekta adaptacije na ishode učenja.

Tabela 3. Mapiranje hipoteza istraživanja na način provere i odgovarajuća poglavlja.

Hipoteza	Način provere	Poglavlje
PH1	Demonstracija povezanog rada modela studenta i modela nastavnog sadržaja nad realnim podacima: praćenje napretka i dinamičko određivanje i vizualizacija preporučenog sadržaja	7.2 Evaluacija modela studenata; 7.3 Adaptivni model
PH2	Procena ovladanosti kompetencijama i ostvarenosti nivoa na dva predmeta različitih karakteristika; identifikovanje pokušavanih slabih tačaka i razlikovanje nepokušavanog obaveznog N1 sadržaja od niske procene ovladanosti; provere stabilnosti procena kroz analizu osetljivosti pragova i ponderisanja dokaza, petostruku unakrsnu validaciju i poređenje kontinuirane i binarne BKT formulacije; provera uticaja promena pragova na individualni skup, redosled i najviše prioritete preporuke.	7.2 Evaluacija modela studenata; 7.3.1 Adaptivna preporuka na osnovu modela studenta i ontologije
PH3	Evaluacija ontološki organizovanog prostora za učenje kroz dve iteracije: uporedna analiza OBSLO i LAMS okruženja na osnovu uspešnosti rešavanja zadataka i registrovanog vremena rada sa interaktivnim sadržajem, kao i analiza studentskih putanja u unapređenoj verziji OBSLO-a radi identifikovanja potreba za modifikacijom ontologije; dodatna provera strukturne uloge ontologije u adaptivnom sloju poređenjem ontološki uređene putanje, koja koristi OR i BA relacije, sa referentnim redosledom koji isti skup identifikovanih slabih tačaka rangira samo prema procenjenoj ovladanosti, odnosno bez korišćenja OR i BA relacija pri određivanju redosleda.	7.1 Evaluacija modela nastavnih materijala; 7.3.1 Adaptivna preporuka na osnovu modela studenta i ontologije
PH4	Demonstracija integracije razvijenih modela sa različitim tipovima obrazovnih sistema - sistemom za upravljanje učenjem (LMS), alatom za izradu nastavnog sadržaja, repozitorijumom objekata učenja (engl. Learning Object Repository (LOR)) i sistemom za upravljanje obrazovanjem (engl. Educational Management System (EMS)) - zasnovane na labavoj sprezi i servisno orijentisanoj arhitekturi	5 Model sadržaja za učenje; 7.3 Adaptivni model

3.4. Vremensko i prostorno određenje predmeta istraživanja

Istraživanje obuhvata period od 2015. do 2026. godine i više uzastopnih razvojnih i evaluacionih faza. Najveći deo projektovanja, implementacije i evaluacije artefakata sproveden je u nastavnom okruženju Univerziteta Metropolitan u Beogradu, dok je druga faza razvoja modela studenta obuhvatila i komparativnu analizu podataka Fakulteta organizacije i informatike (FOI). Konačna faza razvoja i evaluacije višeslojnog modela studenta sprovedena je na dva predmeta Univerziteta Metropolitan, u okviru istog institucionalnog i kompetencijskog okvira.

Predmet istraživanja ove doktorske disertacije je deo mnogo šireg istraživanja koje UM primenjuje. Onlajn učenje se primenjuje još od 2005. godine, a personalizacija učenja je strateški cilj više od 10 godina sa ciljevima da se:

- iskoristi potencijal učenja svakog studenta pojedinačno,
- poboljša kvalitet i efikasnost studiranja, kao i celokupnog nastavnog procesa,
- smanji procenat studenata koji odustaju od studiranja.

3.5. Podaci korišćeni u istraživanju

Podaci korišćeni u disertaciji potiču iz više razvojnih i evaluacionih faza i zato ne predstavljaju jedan jedinstven skup podataka. Zajednička osnova istraživanja na Univerzitetu Metropolitan jeste postojeća infrastruktura za e-učenje i veliki repozitorijum nastavnih materijala strukturiranih u obliku objekata učenja prema DITA standardu. Univerzitet raspolaže sa više od 50000 takvih objekata učenja, što je omogućilo razvoj i evaluaciju ontološkog modela nad stvarnim nastavnim sadržajima [230].

Za istraživanja sprovedena u okviru Univerziteta Metropolitan korišćeni su podaci iz postojećih obrazovnih sistema. LAMS obezbeđuje podatke o realizaciji nastavnih aktivnosti i interakcijama studenata sa nastavnim procesom, dok sistem za upravljanje obrazovanjem (EMS), kao deo institucionalnog informacionog sistema, obezbeđuje podatke o predmetima, studentima, aktivnostima provere, pokušajima, ostvarenim rezultatima i kontinuiranom radu tokom semestra [231]. U različitim fazama istraživanja korišćeni su različiti podskupovi ovih podataka, u skladu sa ciljem konkretnog artefakta.

Druga faza razvoja modela studenta imala je komparativni karakter i uključila je podatke iz dva različita institucionalna konteksta, BMU i FOI. Analitički skup obuhvatao je ukupno 409 studenata, od čega 97 iz BMU i 312 iz FOI. Ovi podaci korišćeni su za ispitivanje obrazaca aktivnosti, postignuća i uticaja različite strukture nastavnog sadržaja na rezultate grupnog modelovanja. Upravo je poređenje heterogenih nastavnih konteksta ukazalo na ograničenu prenosivost grupnih obrazaca i predstavljalo jedan od projektnih podsticaja za prelazak na individualno i sadržajno utemeljeno modelovanje u trećoj fazi.

Konačni model studenta razvijen je i evaluiran na podacima dva dodiplomska predmeta Univerziteta Metropolitan iz jedne školske godine. Predmet SE201 - Uvod u softversko inženjerstvo obuhvatao je 37 studenata i 227 objekata učenja, dok je CS202 - Objektno orijentisano programiranje 2 obuhvatao 74 studenta i 126 objekata učenja. Skup podataka činile

su evidencije aktivnosti i provera nastale tokom redovne realizacije predmeta, uključujući rezultate testova i drugih aktivnosti, informacije o pokušajima i mapiranje aktivnosti na jedan ili više objekata učenja. U analitičku kohortu uključen je svaki student za koga je postojalo najmanje jedno zapažanje relevantno za procenu ovladanosti.

Podaci konačne faze anonimizovani su pre analize, a studenti su u analitičkom skupu predstavljeni neidentifikujućim numeričkim oznakama. Evaluacija kontrolne table dopunjena je anonimnim i dobrovoljnim upitnikom u kojem je učestvovalo 86 studenata. Podaci iz upitnika korišćeni su isključivo za analizu percepcije razumljivosti, relevantnosti i korisnosti prikazanih preporuka i objašnjenja.

Zbog različite namene pojedinačnih faza, skupovi podataka ne koriste se kao jedna objedinjena populacija. Ranije faze služe za sticanje projektnih uvida i identifikovanje ograničenja prethodnih pristupa, dok konačni skup SE201/CS202 predstavlja osnovu za proveru koncepta integrisanog kompetencijskog, studentskog i adaptivnog modela. Konačna evaluacija zato nije zamišljena kao osnova za statističku generalizaciju na druge institucije i discipline, već kao provera da se predložena arhitektura može instancirati na stvarnim obrazovnim podacima i proizvesti interpretabilne procene i sledljive preporuke.

Podaci o studentskim aktivnostima i rezultatima korišćeni u istraživanju prikupljeni su u okviru redovnog nastavnog procesa i anonimizovani pre analize. Povratne informacije o kontrolnoj tabli i personalizovanim preporukama prikupljene su putem dobrovoljnog i anonimnog upitnika. U skladu sa institucionalnom praksom, za analizu anonimizovanih nastavnih evidencija i anonimnu dobrovoljnu anketu nije bila potrebna posebna etička saglasnost. Rezultati su analizirani i prikazani u agregiranom obliku, bez obrade i izveštavanja podataka koji omogućavaju identifikaciju pojedinačnih studenata.

Poglavlje 4

4. Teorijski okvir za postavljanje problema

Istraživanja u oblasti personalizovanih i adaptivnih sistema e-učenja i modelovanja studenata pokazuju značaj ontoloških modela i algoritama mašinskog učenja u personalizaciji obrazovnog sadržaja. Ovo poglavlje uspostavlja teorijski okvir za integrisani pristup razvijen u disertaciji, u kojem se ontološki model nastavnog sadržaja, model studenta i adaptivni mehanizam povezuju radi formiranja objašnjivih preporuka za dalje učenje. Poglavlje najpre izlaže teorijske osnove ontološkog modelovanja nastavnih sadržaja (odeljak 4.1) i njihove vizualizacije (odeljak 4.2), a zatim kompetencijski okvir i metode za modelovanje znanja i ponašanja studenta: BKT, klasterovanje i XAI (odeljak 4.3).

4.1. Primena ontologije za razvoj modela nastavnih materijala

Ontološki model predstavlja jedan od ključnih pristupa za rešavanje problema organizovanja i povezivanja objekata učenja, jer omogućava sistematično povezivanje različitih koncepata i znanja, čineći ih dostupnim za algoritme preporuke. U ovom radu ontologija je korišćena kao formalna struktura za organizovanje i semantičko povezivanje nastavnog sadržaja, koja pruža osnovu adaptivnom mehanizmu da, u kombinaciji sa modelom studenta, identifikuje relevantne sadržaje i uređuje ih prema potrebama pojedinačnog studenta.

Koncept ontologije potiče iz filozofije, gde se koristi za sistematsko objašnjenje postojanja. Međutim, poslednjih godina, ovaj koncept je pronašao primenu u različitim disciplinama, posebno u inženjeringu znanja i veštačkoj inteligenciji, gde igra ključnu ulogu u predstavljanju i organizovanju znanja [232]. U kontekstu računarskih nauka, ontologija predstavlja okvir za predstavljanje koncepata i odnosa među tim konceptima [233]. Definiše osnovne termine i odnose koji čine rečnik određenog domena, kao i pravila za kombinovanje termina i odnosa, olakšavajući proširivanje [234]. Ontologije se mogu smatrati "šemama metapodataka koje pružaju kontrolisani rečnik koncepata" [235], što omogućava jasnije definisanje i organizovanje znanja u određenom domenu.

Važno je napomenuti da ontologije ne samo da definišu vrste entiteta u aplikativnom domenu, već i precizno određuju tipove odnosa između tih entiteta, što omogućava sofisticirano modeliranje znanja i njegovih implikacija [236]. U obrazovanju, ontologije omogućavaju stvaranje fleksibilnih sistema koji mogu poboljšati prikupljanje i interpretaciju informacija, čineći ih korisnijim za potrebe učenika ili studenata [237]. Ontologije omogućavaju strukturiranje domena znanja kao skup koncepata povezanih definisanim odnosima, što olakšava generisanje sadržaja iz znanja predstavljenog u ontologijama predmeta. Ovaj pristup čini implicitno znanje eksplicitnim i omogućava prilagođavanje sadržaja na osnovu nivoa znanja studenata [238].

Ontologije su takođe ključne za eksplicitno razdvajanje znanja i sadržaja u obrazovnim materijalima, što omogućava fleksibilnost i prilagođavanje obrazovnog iskustva prema individualnim potrebama studenata. Pod razdvajanjem znanja i sadržaja podrazumeva se to da ontologija opisuje pojmove domena i odnose među njima nezavisno od konkretnih objekata učenja koji taj sadržaj isporučuju. Time je moguće menjati ili dopunjavati nastavni materijal bez narušavanja konceptualne strukture domena, i obrnuto [14]. Ovo je posebno korisno u kontekstu adaptivnog učenja, gde se obrazovni resursi i strategije prilagođavaju na osnovu kontinuiranog praćenja i analize napretka studenata. Iako ontologije postoje za mnoge domene, njihov kvalitet i pogodnost za obrazovni kontekst može biti nejasna [239]. Razvoj ontologija se obično sprovodi timski, uz učešće stručnjaka iz domena, inženjera ontologije i pedagoga, čime se osigurava da ontologije adekvatno reflektuju kompleksnost i dinamiku obrazovnih potreba. Pored toga, korišćenje ontologija u sistemima preporuke može značajno poboljšati tačnost i relevantnost preporuka, jer omogućava da se uzme u obzir ne samo sadržaj, već i kontekst i ciljevi korisnika. Na primer, korišćenjem ontologije koja mapira odnose između različitih koncepata i veština, moguće je preciznije preporučiti resurse koji će pomoći studentima da popune praznine u znanju ili unaprede svoje veštine na specifičan način.

4.1.1. Ontološki model prema Noy & McGuinness-u

Razvoj ontološkog modela koji je urađen u ovoj doktorskoj disertaciji se oslanja na smernice koje su razvili Noy i McGuinness u njihovom radu [98]. Noy i McGuinness identifikuju ključne razloge za razvoj ontologija i faze kroz koje prolazi proces njihovog pojektovanja i razvoja. Prema njihovim smernicama, glavni razlozi za izradu ontologije uključuju:

1. **Deljenje zajedničkog razumevanja strukture informacija:** Ontologije omogućavaju ljudima i softverskim agentima da dele zajedničko razumevanje strukture informacija u

određenom domenu, što je posebno važno u sistemima koji zahtevaju koherentnu razmenu informacija među više agenata.

2. **Ponovna upotreba znanja iz domena**: Ontologije olakšavaju ponovnu upotrebu znanja koje već postoji u određenom domenu, čime se smanjuje potreba za rekonstrukcijom znanja i štede vreme i resursi.
3. **Eksplicitno izražavanje pretpostavki o domenu**: Kroz ontologije je moguće eksplicitno izraziti pretpostavke o domenu koje bi inače ostale implicitne. Ako su pretpostavke jasno izražene u ontologiji, lakše je prilagoditi ontologiju promenama u znanju o domenu.

Ontologije su konceptualizacije domena koje mogu imati različite stepene formalnosti, kao što su taksonomije, metapodaci ili logičke teorije. Taksonomija je hijerarhijska struktura koja se koristi za klasifikaciju skupa pojmova, dok ontologija definiše termine koji se koriste za opisivanje i predstavljanje oblasti znanja. Takođe uključuje računarom upotrebljive definicije osnovnih koncepata u domenu i odnosa između tih koncepata.

Noy i McGuinness [98] predlažu sledeće faze u projektovanju i razvoju ontologije:

1. **Određivanje domena i izvora, svrhe i opsega ontologije:** Ključni koraci uključuju definisanje domena koji će ontologija pokrivati, svrhe ontologije i vrsta pitanja na koja bi informacije iz ontologije trebale da odgovaraju.
2. **Provera postojanja prethodno razvijenih ontologija u istom predmetnom području**: Ako postoje slične ontologije, može biti efikasnije modifikovati postojeće nego kreirati nove od početka.
3. **Navođenje važnih termina u ontologiji**: Identifikacija ključnih termina relevantnih za domen je osnovna za dalji razvoj ontologije.
4. **Definisanje klasa (koncepta) i hijerarhije klasa:** Ova faza uključuje definisanje glavnih klasa ili koncepata i njihove hijerarhijske strukture.
5. **Definisanje svojstava klasa:** Definišu se svojstva (atributi) klasa koja opisuju unutrašnje strukture koncepata.
6. **Povezivanje aspekata (engl. facets) sa svojstvima**: Ova faza obuhvata opisivanje tipova vrednosti, dozvoljenih vrednosti, broja dozvoljenih vrednosti (kardinalnosti) i drugih značajki svojstava klasa.

Dodatno, Noy i McGuinness naglašavaju nekoliko važnih aspekata koji su posebno relevantni za personalizovano učenje. Prvi od njih je iterativni pristup razvoju ontologija, koji

podrazumeva kontinuiranu reviziju i unapređenje ontologija. Ovaj pristup omogućava da se ontologije prilagode promenama u obrazovnim sadržajima i kurikulumima, čime se osigurava njihova aktuelnost i relevantnost. Evaluacija i validacija ontologije (provera tačnosti i doslednosti u odnosu na ciljeve i domen) predstavljaju ključne korake u procesu njihovog razvoja, uključujući proveru tačnosti, doslednosti i kompletnosti ontologije u odnosu na ciljeve aplikacije. Ovi procesi su od suštinskog značaja kako bi se osiguralo da ontologija pravilno reprezentuje domenske sadržaje i da je korisna za generisanje prilagođenih preporuka i učenja. Razmatranje semantičke interoperabilnosti je još jedan važan aspekt. Dobro struktuirane i projektovane ontologije omogućavaju semantičku interoperabilnost između različitih obrazovnih sistema i platformi, što omogućava koherentnu razmenu i interpretaciju podataka između sistema. Povezivanje ontologija sa obrazovnim standardima može dodatno unaprediti razvoj ontologija, omogućavajući lakšu integraciju u postojeće obrazovne platforme. Ovo omogućava bolje usklađivanje sa standardima i lakšu interoperabilnost sa drugim obrazovnim alatima i resursima.

U ovom radu, metodološke smernice Noy i McGuinness-a koriste se za izgradnju ontološkog modela koji je fleksibilan i prilagodljiv za personalizovano učenje, omogućavajući koherentno organizovanje znanja i prilagođavanje sadržaja u skladu sa potrebama i napretkom studenata.

4.2. Vizualizacija

4.2.1. Multidimenzionalne konceptualne mape

Konceptualne mape (CM) su grafički alati za organizaciju i reprezentaciju znanja. Autori rada [240] definišu ih kao hijerarhijske strukture u kojima se koncepti prikazuju u čvorovima, a veze između njih označavaju relacije. Svaka veza sadrži povezane reči ili fraze koje objašnjavaju odnos među konceptima. CM su prvobitno razvijene na osnovu kognitivne psihologije Davida Ausubela, koji je postavio teoriju da se učenje odvija kroz asimilaciju novih informacija u postojeće kognitivne strukture učenika [241]. Za razliku od mapa uma, koje organizuju pojmove radijalno oko jednog centralnog pojma i povezuju ih neoznačenim asocijativnim vezama, konceptualne mape eksplicitno imenuju relacije između koncepata, zbog čega su pogodne za vizualizaciju ontologije sa tipiziranim relacijama.

Prema [240] konceptualne mape imaju sledeće ključne karakteristike:

- Hijerarhijska organizacija - najopštiji koncepti nalaze se na vrhu, dok su specifičniji pojmovi niže.
- Propozicije - značenje se izražava kroz kombinaciju dva ili više koncepata povezanih linijama i ključnim frazama.
- Unakrsne veze - povezuju pojmove iz različitih oblasti unutar mape, olakšavajući identifikaciju složenih odnosa.
- Kontekstualni okvir - svaka mapa se kreira s određenim fokus pitanjem kako bi se osigurala jasna organizacija znanja.

Međutim, dvodimenzionalne mape imaju ograničenja u predstavljanju složenih struktura znanja, što može dovesti do kognitivnog preopterećenja [109]. Kako bi se prevazišli ovi problemi, Huang et al. (2012) razvili su MCM pristup koji omogućava višedimenzionalnu organizaciju znanja, smanjujući vizualnu složenost i omogućavajući učenicima postepeno usvajanje gradiva [109]. Ovaj pristup koristi teoriju radne memorije Millera [242], koja sugeriše da ljudi mogu istovremeno obraditi 7 ± 2 jedinice informacija, te omogućava klasifikaciju i reorganizaciju čvorova kako bi se smanjilo kognitivno opterećenje učenika [109]. Empirijska istraživanja potvrđuju da MCM može poboljšati rezultate učenja u različitim predmetima, uključujući prirodne nauke [243], računovodstvo [244] i informatiku [109]. U poređenju s tradicionalnim konceptualnim mapama, MCM omogućava bolju personalizaciju učenja i prilagođavanje individualnim potrebama učenika [244].

U ovom radu predložen je model organizacije objekata učenja koji koristi ontološki zasnovane MCM-ove objavljen u radu [14]. Ovaj pristup omogućava dinamičko generisanje mapa na osnovu semantičkih pravila i hijerarhijskih relacija. Na taj način, studenti mogu dinamički pretraživati, organizovati i učiti gradivo kroz vizualne reprezentacije koje odgovaraju njihovom nivou znanja i potrebama. Ontološki modeli omogućavaju povezivanje podataka iz različitih izvora i optimizuju organizaciju znanja kroz mašinsku obradu. Ontološki bazirana MCM je korišćena za:

- Podrška smanjenju vizuelne složenosti i kognitivnog opterećenja - postepenim prikazivanjem informacija kroz segmentirane vizualizacije.
- Podrška interaktivnosti i angažovanju studenata - kroz fleksibilnu navigaciju i personalizovano predstavljanje sadržaja.

- Poređenje sa tradicionalnim sistemima za upravljanje učenjem (LMS) - evaluacijom efikasnosti primene MCM-ova u odnosu na linearne metode učenja.

Multidimenzionalne konceptualne mape (MCM) su izuzetno prilagodljive i lako proširive. Pored osnovnih dimenzija koje organizuju tematske celine i nivoe znanja, mogu se dodavati dodatni atributi i odnosi koji omogućavaju precizniju klasifikaciju i efikasnije filtriranje sadržaja. Osim tradicionalnih hijerarhijskih i sekvencijalnih veza, MCM mogu uključivati i semantičke veze. Ove veze omogućavaju dublju analizu koncepata i generisanje personalizovanih preporuka na osnovu srodnih tema i interesovanja studenata. Prethodna istraživanja MCM pristupa ukazuju na potencijalne koristi ovog načina vizualizacije za rezultate učenja i organizovanje složenijih struktura znanja [109,243,244]. U okviru ove disertacije MCM se prvenstveno posmatra kao mehanizam za višedimenzionalnu organizaciju, navigaciju i personalizovanu vizualizaciju nastavnog sadržaja. Sprovedena evaluacija pokazuje njegovu praktičnu primenljivost u analiziranom nastavnom okruženju, ali ne omogućava izdvajanje samostalnog uzročnog efekta MCM-a na usvajanje znanja ili angažovanje studenata.

4.3. Metode za modelovanje znanja i ponašanja studenta

Model studenta razvijen u ovom radu postavljen je sa ciljem da ispuni tri metodološka zahteva. Prvo, procena znanja mora biti *sekvencijalna*: znanje studenta nije statična veličina, već se menja kroz vreme, pa procena treba da uvaži redosled i istoriju odgovora, uključujući ranije, ponovljene pokušaje. Drugo, model mora biti primenljiv na *podacima realnog obima*: reč je o podacima jednog predmeta i jedne generacije studenata, dakle o desetinama studenata, a ne o desetinama hiljada interakcija koje zahtevaju duboke neuronske arhitekture. Treće, i najvažnije, procene modela moraju biti *interpretabilne i objašnjive*, jer se na osnovu njih formiraju preporuke koje se saopštavaju studentima i nastavnicima, a procena koja se ne može obrazložiti nije upotrebljiva u pedagoškom kontekstu [16].

Pre izlaganja samih metoda, u odeljku 4.3.1 prikazan je kompetencijski okvir razvoja nastavnih sadržaja koji definiše *šta* model studenta prati: kompetencije, njihove nivoe i način na koji se one razvijaju i verifikuju kroz nastavu. Na osnovu navedenih zahteva, u radu su zatim primenjene tri komplementarne klase metoda. Bajesovo praćenje znanja, BKT (odeljak 4.3.2) daje sekvencijalnu, probabilističku procenu ovladanosti elementima znanja, sa parametrima koji imaju jasno pedagoško značenje. Klasterovanje (odeljak 4.3.3) otkriva tipove studenata prema obrascima ponašanja u učenju, nezavisno od samog znanja. Metode objašnjive veštačke inteligencije (odeljak 4.3.4) povezuju prethodne komponente sa studentom: procene i tipove

prevode u čitljiva pravila i obrazložene preporuke. Za svaku metodu najpre se izlaže opšta teorijska osnova, a zatim način na koji je metoda konkretizovana u pristupu ovog rada. Detalji implementacije i rezultati dati su u poglavljima 6 i 7.

4.3.1. Kompetencijski okvir razvoja nastavnih sadržaja

Model studenta ne procenjuje znanje u apstraktnom prostoru, već nad jedinicama koje definiše kompetencijski okvir nastave. U ovom radu preuzet je i konkretizovan okvir kompetencijski vođenog personalizovanog učenja razvijen na Univerzitetu Metropolitan [15], koji određuje kako kompetencije nastaju, kako se strukturiraju po dubini i širini, i kako se njihovo sticanje verifikuje, čime neposredno definiše jedinice i nivoe koje model studenta prati.

Polazna tačka okvira je *vertikalno mapiranje* ciljeva, ishoda učenja i kompetencija: od referentnog korpusa znanja discipline (engl. Body of Knowledge (BOK), npr. preporuke ACM/IEEE za računarske nauke), preko kurikuluma studijskog programa, do pojedinačnih predmeta i, unutar njih, lekcija i njihovih tema [15]. Na nivou kurikuluma studijskog programa definišu se šire kompetencije izvedene iz referentnog BOK-a, nakon čega se na nivou predmeta razlažu na kompetencije predmeta, a zatim povezuju sa kompetencijama lekcija i tema, čime se obezbeđuje doslednost vertikalnog mapiranja od referentnog okvira do konkretnog nastavnog sadržaja. Za potrebe analize kompetencija se posmatra kroz dve komponente: znanje i veštinu primene tog znanja, dok se komponenta stavova zanemaruje [15]. Nosilac kompetencija na najnižem nivou je OU (odeljak 4.1 i poglavlje 5), čije sekcije (koncept, primer, zadatak, provera) sadrže znanje i veštine, pa se kompetencije koriste kao glavni klasifikator objekta učenja. Okvir dalje razlikuje *dubinu* i *širinu* (engl. depth and breadth) kompetencija [15]. Širinu kompetencije određuje obuhvat tema i objekata učenja kroz koje se kompetencija razvija, dok dubina označava nivo složenosti znanja i veština koji se razvija unutar određene teme [15]. U ovoj disertaciji dubina se dodatno operacionalizuje u odnosu na revidiranu Bloomovu taksonomiju, tako da prelazak od N1 ka N3 označava porast dominantnog kognitivnog zahteva, a ne samo povećanje količine nastavnog sadržaja [245]. Po dubini se kompetencije organizuju u tri nivoa:

- N1 - osnovni nivo kompetencije, koji predstavlja obavezno jezgro znanja i veština i povezan je sa nižim kognitivnim zahtevima;
- N2 - srednji nivo kompetencije, koji nadograđuje osnovno jezgro i podrazumeva dodatno i produbljeno razvijanje znanja i veština uz više kognitivne zahteve;

- N3 - napredni nivo kompetencije, koji predstavlja najveću dubinu razvoja kompetencije i podrazumeva složenije oblike samostalnog rezonovanja, kritičkog mišljenja i vrednovanja.

Nivoi N1, N2 i N3 usklađeni su sa progresijom kognitivne složenosti u revidiranoj Bloomovoj taksonomiji, pri čemu N1 predstavlja niži kognitivni zahtev, a N2 i N3 progresivno više kognitivne zahteve. Ovi nivoi predstavljaju šire opsege dubine kompetencije i ne treba ih tumačiti kao strogo preSlikavanje pojedinačnih kategorija Bloomove taksonomije na nivoe N1, N2 i N3 [245]. U ontološkom modelu nastavnih sadržaja ovog rada ova tri nivoa operacionalizuju se kao nivoi dubine N1, N2 i N3, pa se ta terminologija koristi u nastavku. Različiti nivoi nose i različita pedagoška očekivanja: N1 predstavlja obavezno zajedničko jezgro sa strožim kriterijumom ovladanosti, N2 dodatni i produbljeni srednji nivo, dok N3 predstavlja opcioni napredni nivo najveće dubine. U modelu studenta ova razlika operacionalizuje se primenom pragova ovladanosti zavisnih od nivoa: stroži prag za N1 odražava njegovu ulogu obaveznog jezgra, dok su za N2 i N3 primenjeni niži pragovi, primereni dodatnom i dubljem sadržaju. Pri tome se nastavni status sadržaja i njegova kognitivna složenost tretiraju kao povezane, ali različite karakteristike modela. Takvo korišćenje pragova ovladanosti povezano je sa principima mastery learning pristupa, prema kojima preporuka narednog ili zahtevnijeg sadržaja treba da se zasniva na demonstriranom stepenu ovladanosti, a ne samo na vremenu provedenom u učenju ili formalnom završavanju aktivnosti [26].

Okvir je *dinamičan*: skup opcionih tema i kompetencija nije fiksiran, već se proširuje prema potrebama studenata i poslodavaca, pri čemu nove teme i njihove materijale mogu, uz nadzor i verifikaciju nastavnika, pripremati i sami studenti [15]. Takvo horizontalno proširivanje novim opcionim kompetencijama moguće je na svakom nivou dubine, uključujući i N1, a ne samo na nivoima N2 i N3. Nivo dubine i nastavni status sadržaja (obavezan ili opcioni) zato su različite karakteristike; u predmetima analiziranim u ovom radu sadržaji nivoa N1 tretirani su kao obavezni, pa se N1 u nastavku posmatra kao obavezno jezgro. Svaki student time formira sopstveni portfolio kompetencija kao skup obaveznih i izabranih opcionih kompetencija sa dubinom do koje ih je savladao. Konačno, okvir propisuje da se sticanje kompetencija kontinuirano *verifikuje* oblicima provere vezanim za teme i nivoe (testovi znanja, zadaci za proveru veština, projekti, eseji, itd.). Povezivanje ishoda učenja i kompetencija sa nastavnim aktivnostima i dokazima provere u ovom radu dodatno se oslanja na princip konstruktivnog usklađivanja (engl. *constructive alignment*), prema kojem ishodi učenja,

aktivnosti učenja i načini procene treba da budu eksplicitno međusobno povezani [246]. Upravo ti verifikacioni podaci, odnosno hronološki nizovi rezultata provera, mapiranih na OU, kompetencije i nivoe čine ulaz modela studenta, a kompetencija predmeta u kombinaciji sa nivoom dubine čini jedinicu nad kojom se ovladanost prati metodama iz narednih odeljaka.

4.3.2. Bajesovo praćenje znanja (BKT)

Bajesovo praćenje znanja (engl. Bayesian Knowledge Tracing (BKT)) uveli su Corbett i Anderson [11] kao metod za praćenje ovladanosti pojedinačnim veštinama u ITS. BKT je specijalan slučaj skrivenog Markovljevog modela (engl. hidden Markov model (HMM)) sa dva skrivena stanja: student je datu jedinicu znanja ili *savladao* (L) ili *nije savladao* ($\neg L$). Stanje znanja nije direktno vidljivo, a opservacije su tačnost odgovora studenta na provere znanja u vezi sa tom jedinicom, a model iz niza opservacija zaključuje verovatnoću da se student nalazi u stanju savladanosti.

Klasičan BKT model definisan je sa četiri parametra:

- $P(L_0)$ - verovatnoća da student poseduje znanje pre prve opservacije (*početno znanje*)
- $P(T)$ - verovatnoća prelaska iz stanja $\neg L$ u stanje L posle jedne prilike za učenje (*brzina učenja*)
- $P(S)$ - verovatnoća da student koji je savladao gradivo odgovori netačno (*omaška*, engl. *slip*);
- $P(G)$ - verovatnoća da student koji nije savladao gradivo odgovori tačno (*pogađanje*, engl. *guess*).

U osnovnoj formulaciji model ne predviđa zaboravljanje, prelazak iz L u $\neg L$ nije moguć, mada postoje proširenja koja faktor zaboravljanja uključuju [166].

Verovatnoća tačnog odgovora u trenutku t sledi iz ukupne verovatnoće:

$$P(tačno_t) = P(L_t) \cdot \big(1 - P(S)\big) + \big(1 - P(L_t)\big) \cdot P(G) \tag{1}$$

Nakon svake opservacije procena znanja ažurira se Bajesovim pravilom. Ako je odgovor bio tačan:

$$P(L_t \mid tačno) = \frac{P(L_t) \cdot \big(1 - P(S)\big)}{P(L_t) \cdot \big(1 - P(S)\big) + \big(1 - P(L_t)\big) \cdot P(G)} \tag{2}$$

a ako je bio netačan:

$$P(L_t \mid netačno) = \frac{P(L_t) \cdot P(S)}{P(L_t) \cdot P(S) + \big(1 - P(L_t)\big) \cdot \big(1 - P(G)\big)} \tag{3}$$

Konačno, procena se propagira u sledeći trenutak uračunavanjem mogućnosti da je student u međuvremenu naučio gradivo:

$$P(L_{t+1}) = P(L_t \mid o_t) + \big(1 - P(L_t \mid o_t)\big) \cdot P(T) \tag{4}$$

gde je o_t opservacija u trenutku t. Rekurzivnom primenom jednačina (2) - (4) preko cele hronološke sekvence odgovora dobija se $P(L_T)$ verovatnoća da student *u ovom trenutku* vlada jedinicom znanja, posle svih dosadašnjih pokušaja. Upravo ta veličina koristi se u ovom radu kao mera savladanosti: ona je akciona (odgovara na pitanje „da li je student sada ispod praga“), a sekvencijalnost se ogleda u tome što njena vrednost zavisi od celokupnog redosleda ranijih odgovora, a ne od njihovog proseka.

U savremenoj literaturi razvijen je veliki broj modela praćenja znanja, uključujući pristupe zasnovane na dubokim neuronskim mrežama, kao što je Deep Knowledge Tracing [167], kao i novije sekvencijalne i Transformer arhitekture [169,170]. Ovi modeli omogućavaju predstavljanje složenih obrazaca u sekvencama studentskih interakcija, ali izbor metode ne zavisi samo od prediktivne tačnosti, već i od cilja modelovanja, količine raspoloživih podataka, nivoa granularnosti i zahteva za interpretabilnošću [169]. U ovom istraživanju BKT je izabran zato što predstavlja probabilistički sekvencijalni model sa parametrima početnog znanja, učenja, omaške i pogađanja [11], dok se dobijena posteriorna verovatnoća može neposredno interpretirati kao procena trenutne ovladanosti modelovanom jedinicom. Takva interpretabilnost je posebno značajna kada procena modela predstavlja osnovu za identifikovanje slabih tačaka i formiranje objašnjive preporuke. Pored toga, istraživanja pokazuju da pažljivo postavljene varijante BKT-a mogu ostvariti performanse uporedive sa DKT pristupima [168]. Izbor BKT-a može se dodatno obrazložiti u odnosu na druge klasične pristupe modelovanju znanja. Modeli teorije odgovora na stavke (engl. *Item Response Theory* (IRT)) eksplicitno predstavljaju sposobnost studenta i karakteristike, odnosno težinu stavki, ali nisu prvenstveno namenjeni modelovanju sekvencijalnog usvajanja znanja kroz niz uzastopnih pokušaja. Model aditivnih faktora (engl. *Additive Factors Model* (AFM)) i analiza faktora uspešnosti (engl. *Performance Factors Analysis* (PFA)) modeluju efekat vežbanja i informacije iz prethodnih pokušaja, ali ne održavaju eksplicitnu posteriornu verovatnoću ovladanosti za svaku modelovanu jedinicu na način na koji to čini BKT. U kontekstu ove disertacije upravo

je takva verovatnoća važna, jer se ažurira sekvencijalno na osnovu studentskih pokušaja, neposredno se tumači kao trenutno stanje ovladanosti i može se povezati sa kompetencijom, nivoom dubine, pragom ovladanosti i odlukom adaptivnog sloja o potrebi za dodatnom podrškom. Izbor BKT-a zato ne predstavlja tvrdnju o njegovoj opštoj superiornosti u odnosu na savremenije KT modele, već projektnu odluku usklađenu sa zahtevima konkretnog modela studenta i raspoloživim podacima. Pregled BKT-a, logističkih i drugih pristupa modelovanju znanja daje Pelánek [163], dok savremeniji pregled šireg spektra KT modela daju Shen et al. [169].

4.3.2.1. Ocenjivanje i ograničavanje parametara

Parametri BKT modela procenjuju se iz raspoloživih sekvenci studentskih opservacija primenom algoritma maksimizacije očekivanja (engl. Expectation-Maximization (EM)), kojim se iterativno procenjuju parametri radi maksimizacije verodostojnosti posmatranih podataka [247]. U konkretnoj implementaciji parametri se procenjuju odvojeno za svaku kombinaciju *predmet-kompetencija predmeta-nivo dubine*, korišćenjem svih raspoloživih sekvenci studenata za tu jedinicu. Dobijeni parametri zatim se koriste za izračunavanje individualne posteriorne verovatnoće ovladanosti svakog studenta. Za konačne procene prikazane u empirijskom delu parametri su procenjeni na kompletnoj kohorti, dok je stabilnost postupka dodatno proverena petostrukom unakrsnom validacijom unutar kohorte, opisanom u odeljku 7.2.3.1. Ta provera ocenjuje unutrašnju stabilnost i ne predstavlja nezavisnu validaciju na novoj kohorti.

Pri ocenjivanju parametara BKT modela mogu se dobiti granične vrednosti koje otežavaju njihovo pedagoško tumačenje [248,249]. Jedan od takvih slučajeva jeste procena $P(L_0) \approx 1$:: bliska vrednosti 1, kada model veliki deo uspešnih odgovora pripisuje početnom znanju, a manje učenju tokom posmatrane sekvence. Ovakve procene mogu se češće javiti u skupovima podataka sa visokim udelom uspešnih odgovora. Zbog toga je u ovom radu za verovatnoću početnog znanja uvedeno ograničenje $P(L_0) \leq 0.5$. Ova vrednost predstavlja regularizacionu pretpostavku kojom se sprečava da model pretpostavi visok nivo početne ovladanosti pre nego što za njega postoji dovoljno dokaza u posmatranoj sekvenci. Potreba za kontrolom graničnih i pedagoški teško interpretabilnih procena BKT parametara razmatrana je i u prethodnim istraživanjima [248,249]. Konkretna vrednost 0,5 predstavlja projektnu odluku ove implementacije, a stabilnost dobijenih procena u odnosu na modelske odluke dodatno se proverava analizama predstavljenim u empirijskom delu disertacije.

U primenjenoj implementaciji verovatnoće omaške P(S) i pogađanja P(G) pri ocenjivanju parametara ograničene su na interval od 0,01 do 0,5, čime se izbegavaju granične vrednosti ovih parametara i zadržava njihovo pedagoški smisleno tumačenje.

4.3.2.2. Kontinuirane opservacije

Klasičan BKT pretpostavlja binarne opservacije (tačno/netačno). Rezultati provera znanja u ovom istraživanju su, međutim, *procenti* ostvarenosti, tj. vrednosti $o \in [0,1]$. Njihova binarizacija pragom odbacila bi informaciju o delimičnoj tačnosti i veštački polarizovala podatke. Motiv za zadržavanje kontinuirane vrednosti zato nije pretpostavka da kontinuirani BKT nužno daje veću prediktivnu tačnost od binarne varijante, već očuvanje pedagoški relevantne informacije o stepenu uspešnosti na aktivnostima učenja. Na primer, rezultati od 0%, 40% i 70% predstavljaju različitu količinu dokaza o trenutnom stanju znanja, iako bi pri određenom binarnom pragu neki od njih mogli biti svedeni na istu kategoriju. Isti procenat ostvaren na različitim aktivnostima pri tome se tretira kao uporediv dokaz samo unutar iste kompetencije i istog nivoa dubine. Težina aktivnosti u modelu nije posebno svojstvo lekcije, već je određena nivoom dubine na koji je aktivnost mapirana: zahtevnija aktivnost mapira se na nivo N2 ili N3 i ulazi u zasebnu sekvencu (odeljak 4.3.2.3), pa se rezultati sa različitih nivoa ne objedinjuju u istoj proceni. Ispravnost ovakvog tretmana zavisi od toga da li je nastavnik pri mapiranju dosledno odredio nivo dubine. Pristupi koji proširuju praćenje znanja delimičnim priznavanjem tačnosti upravo omogućavaju očuvanje takve informacije [250,251]. Zbog toga je u radu primenjeno proširenje BKT-a na kontinuirane opservacije, srodno modelima praćenja znanja sa delimičnim priznavanjem tačnosti (engl. partial credit) [250,251]. Verodostojnost opservacije o pri datoj verovatnoći tačnog odgovora p_c definiše se kao linearna interpolacija:

$$b(o \mid z) = o \cdot p_c(z) + (1 - o) \cdot \big(1 - p_c(z)\big) \qquad (5)$$

gde je $p_c(L) = 1 - P(S)$ za stanje savladanosti i $p_c(\neg L) = P(G)$ za stanje nesavladanosti. Za binarne vrednosti $o \in \{0,1\}$ izraz (5) svodi se tačno na standardni BKT, dok za delimično tačne odgovore daje srazmerno „meku“ verodostojnost. Pri navedenim ograničenjima parametara, verodostojnost opservacije u stanju ovladanosti neopadajuća je, dok je u stanju neovladanosti nerastuća funkcija ostvarenog rezultata. Posledično, posteriorna verovatnoća ovladanosti neopada sa porastom rezultata kada važi P(S)+P(G)≤1. Ovaj uslov bio je ispunjen za sve ocenjene modele na nivou kombinacije predmet-kompetencija predmeta-nivo dubine, pri čemu se vrednost P(S)+P(G) kretala od 0,307 do 0,686. Time se potvrđuje da kontinuirana

formulacija zadržava monotonost procene i svođenje na standardni BKT u graničnim slučajevima i pri korišćenju delimično tačnih odgovora. Bajesovo ažuriranje tada dobija oblik:

$$P(L_t \mid o_t) = \frac{P(L_t) \cdot b(o_t \mid L)}{P(L_t) \cdot b(o_t \mid L) + \big(1 - P(L_t)\big) \cdot b(o_t \mid \neg L)} \tag{6}$$

a propagacija u naredni trenutak ostaje kao u jednačini (4). Ista formulacija verodostojnosti kontinuiranih opservacija koristi se i pri ocenjivanju parametara modela, tako da se BKT parametri procenjuju neposredno iz sekvenci koje zadržavaju informaciju o delimičnoj uspešnosti studenta.

4.3.2.3. Jedinica modelovanja i sastav sekvence

Izbor *jedinice* nad kojom se BKT sekvenca gradi, ključan je za primenljivost modela. Ako je jedinica suviše sitna (pojedinačni objekat učenja), sekvence su prekratke jer se neko znanje/veština u regularnoj nastavi najčešće proverava jednom ili dvaput. Tada sekvencijalni model nema šta da prati. Ako je jedinica suviše krupna (ceo predmet), procena gubi dijagnostičku vrednost. U pristupu ovog rada jedinica modelovanja predstavlja parametar modela i može se prilagoditi granularnosti dostupnih podataka. U konkretnoj implementaciji ove disertacije jedinica modelovanja definisana je kao kombinacija *predmet-kompetencija predmeta-nivo dubine*. Šire kompetencije definisane referentnim kurikulumom predstavljaju suviše krupnu jedinicu za dijagnostičku sekvencijalnu procenu, dok pojedinačni OU u regularnoj nastavi često raspolažu sa premalim brojem ponovljenih opservacija po studentu da bi formirali dovoljno informativnu sekvencu. Kompetencija predmeta zato predstavlja srednji nivo granularnosti: dovoljno je specifična da zadrži dijagnostičku vrednost, a istovremeno može objediniti više hronološki raspoređenih dokaza iz različitih aktivnosti. Dodavanjem nivoa dubine omogućava se da se ovladanost istom kompetencijom procenjuje odvojeno na nivoima N1, N2 i N3, u skladu sa kompetencijskim okvirom iz odeljka 4.3.1. Za pojedinačne OU, gde sekvencijalno praćenje podacima nije podržano, kao mera uspeha koristi se prosečan ostvareni procenat važećih pokušaja (poglavlje 6).

U BKT sekvenci namerno se zadržavaju i raniji pokušaji iste aktivnosti. Kada student izvrši novi pokušaj, prethodni pokušaj više nije trenutno važeći, ali ostaje stvarna istorijska opservacija koja hronološki prethodi novijem rezultatu. Njegovim zadržavanjem čuva se sekvencijalni signal o promeni stanja studenta, na primer prelazak od neuspešnijeg ka uspešnijem pokušaju, koji bi bio izgubljen kada bi se koristio samo poslednji rezultat. Zbog toga BKT koristi punu hronološku sekvencu pokušaja, dok se za pokazatelje ostvarenosti

nivoa, koji imaju drugu svrhu, koriste samo trenutno važeći pokušaji. Na taj način konačna BKT procena predstavlja verovatnoću ovladanosti nakon poslednje raspoložive opservacije, ali njena vrednost zavisi od celokupne hronološke putanje koja joj prethodi. Ona se zato u ovoj disertaciji tumači kao procena demonstrirane ovladanosti kompetencijom na određenom nivou dubine, a ne kao mera količine realizovanih nastavnih aktivnosti. Druga dimenzija, ostvarenost nivoa, izračunava se odvojeno i detaljno je definisana u Poglavlju 6.

4.3.3. Klasterovanje obrazaca ponašanja studenata

Dok BKT daje procenu demonstrirane ovladanosti kompetencijom na određenom nivou dubine, komplementarni aspekt modela studenta odnosi se na način na koji student radi tokom predmeta: obim njegovih aktivnosti, raspodelu aktivnosti tokom vremena i sklonost ponavljanju pokušaja. Ove dimenzije ne predstavljaju neposrednu meru znanja, već ponašajni obrazac angažovanja studenta. Za otkrivanje tipova studenata prema takvim obrascima ponašanja koristi se klasterovanje, nenadgledana tehnika mašinskog učenja koja grupiše objekte tako da su objekti unutar grupe međusobno što sličniji, a grupe što različitije.

U radu je primenjen algoritam k-sredina (engl. *k-means*) [252,253], koji particioniše skup od n opservacija $x_1, \dots, x_n$ u k klastera $C_1, \dots, C_k$ minimizacijom sume kvadrata unutarklasterskih rastojanja:

$$J = \sum_{j=1}^{k} \sum_{x_i \in C_j} \|x_i - \mu_j\|^2 \tag{7}$$

gde je μ_j centroid klastera C_j. Algoritam iterativno smenjuje dodelu opservacija najbližem centroidu i ponovno računanje centroida, do stabilizacije. Pošto je kriterijum zasnovan na euklidskom rastojanju, atributi različitih razmera prethodno se standardizuju (svode na sredinu 0 i standardnu devijaciju 1), kako atribut najvećeg brojnog opsega ne bi dominirao grupisanjem.

Broj klastera nije unapred poznat, pa se može određivati poređenjem kvaliteta rešenja dobijenih za različite vrednosti k. U ovom radu za tu svrhu koristi se koeficijent siluete (engl. *silhouette coefficient*) [254], koji istovremeno uzima u obzir koheziju objekata unutar sopstvenog klastera i njihovu razdvojenost od najbližeg susednog klastera. Silueta opservacije definisana je kao:

$$s(i) = \frac{b(i) - a(i)}{\max\big(a(i),\, b(i)\big)} \tag{8}$$

Vrednosti bliže 1 ukazuju na bolje razdvojene i kompaktnije klastere, vrednosti oko 0 na preklapanje između grupa, dok negativne vrednosti mogu ukazivati na neodgovarajuću dodelu pojedinih opservacija klasteru. U empirijskoj primeni broj klastera određuje se zasebno za svaki predmet poređenjem vrednosti koeficijenta siluete za više kandidatskih rešenja.

U empirijskoj implementaciji klasterovanje je realizovano korišćenjem biblioteke scikit-learn. K-means algoritam primenjen je sa k-means++ inicijalizacijom, uz 20 ponovljenih inicijalizacija (n_init = 20) i fiksirano seme generatora slučajnih brojeva (random_state = 0), dok je broj klastera razmatran u opsegu od dva do pet. Ista standardizacija atributa i ista konfiguracija k-means algoritma zadržane su i pri analizama osetljivosti na promenu skupa ulaznih atributa, kako bi razlike u dobijenim dodelama studenata odražavale promenu reprezentacije podataka, a ne promenu algoritamskih podešavanja.

U konačnom modelu studenta klasterovanje se primenjuje isključivo nad ponašajnim atributima koji opisuju način angažovanja studenta tokom predmeta. Koriste se tri atributa: obim aktivnosti, izražen brojem opservacija formiranih u modelu studenta, broj aktivnih dana i udeo ranijih pokušaja u ukupnom broju pokušaja. Obim aktivnosti pri tome ne predstavlja broj jedinstvenih aktivnosti provere. Kada je jedna aktivnost mapirana na više objekata učenja, ona generiše više opservacionih jedinica u modelu studenta, pa odgovarajuće jedinice ulaze i u ovaj pokazatelj obima aktivnosti. Procene ovladanosti kompetencijama i pokazatelji ostvarenosti nivoa ne koriste se kao ulazni atributi klasterovanja. Oni se pridružuju formiranim grupama tek nakon klasterovanja, radi naknadne interpretacije odnosa između načina angažovanja i postignutih rezultata. Ovakvim razdvajanjem izbegava se tautološka, odnosno cirkularna definicija ponašajnog tipa u kojoj bi se student najpre grupisao prema svom postignuću, a zatim bi se isto postignuće koristilo za objašnjenje dobijene grupe. Ponašajni tip zato u ovom modelu opisuje kako student radi, dok procena ovladanosti opisuje koliko uspešno demonstrira pripadajuću kompetenciju, a ostvarenost nivoa koliki je deo poena predviđenih za aktivnosti odgovarajuće dubine ostvario.

Pošto rezultat k-means klasterovanja zavisi od izbora broja klastera, početne konfiguracije i skupa ulaznih atributa, pouzdanost ponašajnih tipova ne treba procenjivati samo na osnovu jedne vrednosti koeficijenta siluete. Zbog toga se u empirijskom delu disertacije dodatno ispituju stabilnost rešenja pri ponovljenom uzorkovanju, osetljivost na broj klastera i skup

atributa, kao i ponašanje alternativnih metoda klasterovanja. Time se ponašajni tipovi tretiraju kao empirijski izvedeni i proveravani obrasci angažovanja, a ne kao unapred zadate ili prirodno odvojene kategorije studenata.

4.3.4. Objašnjiva veštačka inteligencija

Modeli mašinskog učenja visoke prediktivne tačnosti često funkcionišu kao „crne kutije“: daju procenu, ali ne i uvid u to na osnovu čega je doneta. U obrazovanju je to posebno problematično, jer procena modela studenta neposredno utiče na to šta će sistem preporučiti i kako će nastavnik intervenisati, a procena bez obrazloženja ostavlja obe strane bez mogućnosti da je provere, ospore ili pretvore u akciju [16]. Objašnjiva veštačka inteligencija (XAI) obuhvata metode i principe čiji je cilj da odluke i procene sistema veštačke inteligencije učine razumljivim ljudima [255,256].

U literaturi se razlikuju interpretabilnost, kao svojstvo modela čiju vezu između ulaza i izlaza čovek može neposredno da razume, i objašnjivost, koja može obuhvatiti i naknadno formirana objašnjenja rezultata složenijih modela [255,256]. Među najpoznatijim post-hoc pristupima nalaze se LIME [257] i SHAP [258]. Takva objašnjenja mogu povećati transparentnost modela, ali predstavljaju dodatni sloj između izvornog modela i korisnika, zbog čega je potrebno voditi računa o vernosti objašnjenja stvarnom ponašanju modela [259]. Rudin [260] zato ukazuje da, kada interpretabilni modeli mogu da ostvare odgovarajuće performanse i kada odluke imaju značajne posledice po korisnike, treba razmotriti njihovu upotrebu umesto oslanjanja isključivo na naknadno objašnjavanje netransparentnih modela. Ovaj princip je posebno relevantan za obrazovne primene u kojima analitički izlaz služi kao osnova za intervenciju ili preporuku studentu. Raniji rad autora [17] pokazao je mogućnost povezivanja klasterovanja, klasifikacije i XAI tehnika radi formiranja razumljivih preporuka. U konačnom modelu razvijenom u ovoj disertaciji taj princip se dalje razvija kroz kombinovanje interpretabilnih procena modela studenta, čitljivih pravila ponašajnih tipova i ontološki utemeljenih razloga za preporuku.

Kao interpretabilan model za objašnjavanje pripadnosti studenata tipovima koristi se stablo odlučivanja [261,262], koje rekurzivno deli prostor atributa pitanjima oblika „da li je x_j veće od praga θ“, birajući u svakom čvoru podelu koja najviše smanjuje Ginijev indeks nečistoće:

$$G(t) = 1 - \sum_{c} p_c(t)^2 \tag{9}$$

gde je $p_c(t)$ udeo primeraka klase c u čvoru t. Svaki put od korena do lista je konjunkcija jednostavnih uslova, čitljivo pravilo „ako uslov_1 i uslov_2 … onda klasa c“; ograničavanjem dubine i minimalne veličine lista složenost pravila se svesno drži u zoni razumljivosti, po ceni eventualnog gubitka tačnosti. Stablo se trenira nad istim ponašajnim atributima nad kojima je izvršeno klasterovanje, sa klasterima kao ciljnim klasama, čime se dobija i globalno objašnjenje tipologije, i za svakog studenta lokalno objašnjenje njegove pripadnosti tipu, dosledno atributima koji su tip zaista definisali. Stablo odlučivanja pri tome ne učestvuje u formiranju ponašajnih tipova. Tipovi se prethodno određuju k-means klasterovanjem nad ponašajnim atributima, dok se stablo naknadno trenira nad istim atributima, sa oznakama dobijenih klastera kao ciljnim klasama, kako bi se karakteristike već formiranih tipova izrazile kroz čitljiva pravila oblika „ako-onda“ (engl. if-then). Time se odvajaju postupak otkrivanja obrazaca ponašanja i postupak njihovog objašnjavanja.

U skladu sa principom favorizovanja interpretabilnih postupaka kada oni mogu adekvatno da podrže posmatrani zadatak [260], objašnjivost u ovom radu nije ograničena na naknadno tumačenje konačnog izlaza, već je ugrađena u više faza analitičkog i adaptivnog postupka. Na nivou procene ovladanosti, BKT daje eksplicitnu verovatnoću ovladanosti kompetencijom na određenom nivou dubine, pri čemu parametri modela imaju neposredno interpretabilno značenje. Na nivou ponašajnog profila, pravila izvedena stablom odlučivanja opisuju pripadnost ponašajnom tipu kroz mali broj uslova nad istim atributima koji su korišćeni za klasterovanje. Na nivou adaptivne preporuke, razlog za uključivanje određenog objekta učenja može se povezati sa identifikovanom slabom tačkom, procenom ovladanosti i odgovarajućim pragom, pripadajućom kompetencijom i nivoom dubine, kao i ontološkim relacijama koje određuju preduslove i redosled sadržaja. Objašnjivost se zato u konačnom modelu zasniva na sledljivosti od podataka i analitičke procene do konkretnog preporučenog sadržaja, a ne samo na tekstualnom obrazloženju prikazanom korisniku.

Da bi strukturirano obrazloženje bilo predstavljeno studentu u razumljivom obliku, u konačnom modelu razdvojene su dve povezane, ali različite funkcije: formiranje preporuke i jezičko formulisanje njenog objašnjenja. Adaptivni mehanizam određuje koje objekte učenja treba preporučiti i kojim redosledom na osnovu lokalnih procena ovladanosti, statusa pokušaja, pragova prema nivoima dubine i ontoloških relacija. Ponašajni tip koristi se kao dodatni opisni kontekst za predstavljanje podrške, ali ne utiče na izbor, broj, prioritet ni redosled preporučenih objekata učenja. Tek nakon što je takva strukturirana odluka formirana, veliki jezički model može da je pretvori u prirodno formulisano objašnjenje namenjeno studentu. Jezički model

zato ne određuje slabe tačke, ne bira niti menja redosled objekata učenja, ne određuje pragove i ne uvodi nove činjenice na kojima bi preporuka bila zasnovana. Njegova uloga ograničena je na jezičku realizaciju prethodno izračunatog i strukturiranog obrazloženja.

Povratna informacija studentu organizuje se oko tri pitanja koja Hattie i Timperley izdvajaju kao osnovne komponente efektivne povratne informacije: (i) *Kuda idem? (ii) Kako mi ide? (iii) Šta dalje*? [263]. Takva organizacija omogućava da se studentu istovremeno predstave cilj učenja, trenutno procenjeno stanje i sledeći preporučeni koraci, dok analitička osnova preporuke ostaje odvojena od načina na koji je ona jezički predstavljena.

U obrazovnom kontekstu, međutim, sama tehnička sledljivost odluke nije dovoljna da bi objašnjenje bilo korisno nastavniku ili studentu. Objašnjenje treba da bude predstavljeno terminima koji imaju jasno značenje u konkretnom nastavnom domenu i koji se mogu povezati sa poznatim elementima kurikuluma. Istraživanje Feldman-Maggor et al. pokazuje da domenski specifična objašnjenja, izražena kroz kurikularnu terminologiju, mogu biti razumljivija nastavnicima od objašnjenja zasnovanih samo na tehničkim pokazateljima modela, pri čemu su razumljivost objašnjenja, poverenje u sistem i prihvatanje AI preporuka međusobno povezani [264]. Savremeni pristupi usmereni na čoveka dodatno naglašavaju da objašnjivost obrazovnih AI sistema treba posmatrati zajedno sa pedagoškom personalizacijom, jasnoćom i angažujućim karakterom objašnjenja, odgovornošću i sledljivošću odluka, pravičnošću, refleksijom i očuvanjem smislenog učešća učenika i nastavnika u procesu učenja [265]. Ovi zahtevi neposredno podržavaju pristup razvijen u ovoj disertaciji, u kojem se razlog preporuke izražava kroz konkretne kompetencije, nivoe dubine, procene ovladanosti, imenovane objekte učenja i eksplicitne ontološke relacije, umesto kroz latentne ili tehničke pokazatelje koje korisnik ne može neposredno da poveže sa nastavnim sadržajem.

Pri tome je važno razlikovati objašnjivost preporučivačkog postupka od kvaliteta generisanog teksta. Tvrdnja o objašnjivosti u ovom radu odnosi se na sledljivost preporuke do modela studenta, definisanih pragova, pravila i ontoloških relacija, kao i na strukturirano obrazloženje izvedeno iz tih elemenata. Ona sama po sebi ne predstavlja tvrdnju da su tačnost, potpunost, konzistentnost, ton ili moguća jezička pristrasnost svakog LLM-generisanog objašnjenja empirijski potvrđeni. U konkretnoj implementaciji generisani tekst se zato podvrgava dodatnim kontrolama, a determinističko, pravilima zasnovano formulisanje istog strukturiranog sadržaja ostaje dostupno kao rezervni mehanizam. Detalji implementacije, validacionih uslova i empirijske primene prikazani su u poglavljima 6 i 7.

Poglavlje 5

5. Model sadržaja za učenje

Model nastavnog sadržaja predstavljen u ovom poglavlju razvijan je u dve faze koje odgovaraju dvema fazama samog istraživanja, pa poglavlje prati taj isti redosled.

Prva faza - odeljci 5.1 i 5.2 - jeste ontološki model objekata učenja (OU), sa MCM vizualizacijom i softverskom arhitekturom OBSLO, ranije objavljen u [14] i demonstriran na predmetu Baze podataka. Ovaj model odgovara na pitanje *kako* nastavni sadržaj organizovati, povezati, pretraživati i vizualizovati (Cilj 1), ali sam po sebi ne sadrži eksplicitnu vezu sa kompetencijama koje taj sadržaj razvija ni sa dubinom na kojoj se razvijaju.

Druga faza - odeljak 5.3 - jeste proširenje tog modela kompetencijskim okvirom [15]: formalni nivoi dubine N1/N2/N3, ishodi učenja i kompetencije postaju sastavni deo ontologije. Ovo proširenje je bilo neophodno jer model studenta (Poglavlje 6) procenjuje ovladanost nastavnim sadržajem u odnosu na konkretne ciljeve učenja i kompetencije (Cilj 2), a osnovni ontološki model iz 5.1-5.2 takvu vezu ne obezbeđuje. Kompetencijski proširen model iz 5.3 je, stoga, oblik modela nastavnog sadržaja na kome se u disertaciji dalje razvija model studenta: primenjen je na predmetima SE201 (Uvod u softversko inženjerstvo) i CS202 (Objektno-orijentisano programiranje 2), gde nivoi N1/N2/N3 čine osnovu za procenu ovladanosti u modelu studenta (Poglavlje 6) i njegovoj evaluaciji (odeljak 7.2). Uspešnost ovog proširenja - dodavanje nove dimenzije (kompetencije, nivoi N1/N2/N3) bez izmene osnovne hijerarhije koncepata i relacija iz odeljka 5.1 - istovremeno predstavlja potvrdu fleksibilnosti i proširivosti ontološkog modela, svojstva koje je deo Cilja 1 i Doprinosa 1 ove disertacije, a detaljnije je razmotreno u odeljku 5.1.1.

Predmet Baze podataka u odeljcima 5.1-5.2 nije treći, nezavisan slučaj primene, već prikazuje osnovni model u obliku u kojem je prvi put publikovan [14], pre kompetencijskog proširenja - odabran je jer je na njemu ontologija i MCM vizualizacija prvi put demonstrirana, i ostaje najjednostavniji način da se osnovni mehanizam objasni bez dodatne složenosti koju

uvodi kompetencijski okvir, a njegova upotrebljivost samostalno se evaluira u odeljku 7.1. SE201 i CS202 se, nasuprot tome, javljaju tek u 5.3 i dalje kroz poglavlja 6 i 7, jer su to predmeti na kojima je kompetencijski proširen model i model studenta zajedno empirijski provereni.

5.1. Ontološki model za organizaciju nastavnog sadržaja koji je u formi objekata učenja

Ontološki model za organizaciju OU omogućava efikasnu klasifikaciju, pretragu i personalizaciju nastavnog materijala. Korišćenjem ontologije, nastavne jedinice mogu biti struktuirane na više nivoa, pri čemu se uspostavljaju odnosi između koncepata, podkoncepata i odgovarajućih objekata učenja. Ova struktura olakšava integraciju sadržaja u postojeće sisteme za e-učenje i poboljšava proces personalizovanog učenja. Ontološki model u ovom radu zasniva se na hijerarhijskoj strukturi znanja, gde se definisani koncepti i odnosi među njima koriste za organizaciju objekata učenja. Struktura ontološkog modela uključuje sledeće elemente:

- **Znanje domena (engl. Knowledge domain)** - Najviši nivo hijerarhije predstavlja akademsku oblast ili specifičan domen znanja (npr. „Računarske nauke“).
- **Oblasti znanja (engl. Knowledge Area)** - Svaki domen znanja deli se na više oblasti znanja (npr. „Baze podataka“, „Veštačka inteligencija“).
- **Jedinice znanja (engl. Knowledge Unit)** - Unutar oblasti znanja nalaze se jedinice znanja koje definišu određene tematske celine (npr. „SQL upiti“, „Neuronske mreže“).
- **Teme i podteme (engl. Topics/Subtopics)** - Svaka jedinica znanja sadrži teme i podteme koje razlažu sadržaj na još finije nivoe (npr. „Spajanje tabela – JOIN“)
- **Objekti učenja (engl. Learning Objects)** - Objekti učenja su povezani sa odgovarajućim temama i podtemama i predstavljaju konkretne nastavne materijale kao što su tekstovi, video zapisi sa pridodatim resursima kao što su kvizovi, zadaci i slično (npr. „LEFT JOIN“, „RIGHT JOIN“).

U ovom radu, početna struktura ontologije objekata učenja postavljena je korišćenjem Noy & McGuinness-ovih smernica koje preciziraju faze razvoja i modifikacije ontologije [98]. Ove faze prvenstveno podrazumevaju definisanje koncepata i njihovih unutrašnjih struktura (osobina), dodavanje faseta osobinama (tip vrednosti, dozvoljene vrednosti, broj dozvoljenih

vrednosti itd.) i definisanje hijerarhije koncepata. Pravila su preuzeta sa ciljem strukturiranja ontologije objekata učenja, a na osnovu njih je razvijena specifična hijerarhija koncepata u ovom radu. Ontologija je razvijena za jedan kurikulum koji u specifičnom slučaju predstavlja najviši koncept Znanje domena (engl. knowledge domain). U toj hijerarhiji, na nivou ispod se nalazi oblast znanja (engl. knowledge area), koja sadrži jedinice znanja (engl. knowledge units), dok se unutar njih nalaze teme (engl. topics) i podteme (engl. subtopics). Na ovaj način, kurikulum se definiše kao najopštiji koncept na vrhu ontologije, zajedno sa oblastima i jedinicama znanja, dok su teme i podteme određene kao specijalizovaniji koncepti na nižim nivoima ontologije. Kako bi se obezbedila preciznija organizacija i bolje prilagođavanje studentima sa različitim nivoima predznanja, ontologija je dodatno proširena mehanizmima koji omogućavaju razlikovanje osnovnih i naprednih koncepata unutar iste oblasti znanja. Na ovaj način, studentima se omogućava da postepeno prelaze sa jednostavnijih na složenije pojmove, u skladu sa svojim nivoom znanja. Takođe, proširenje je omogućilo i definisanje preporučenog redosleda usvajanja koncepata i povezanih objekata učenja, čime se postiže jasnija struktura koja podržava personalizovano učenje. Ovo unapređenje omogućava eksplicitno predstavljanje prethodnih jedinica znanja neophodnih za usvajanje novih koncepata i pruža osnovu za usmerenu navigaciju kroz nastavni materijal. Postepenim prikazivanjem relevantnih delova strukture nastoji se ograničiti količina informacija prikazana studentu u jednom trenutku, pri čemu kognitivno opterećenje nije neposredno mereno u sprovedenoj evaluaciji. Uopšteni primer jedne ovakve hijerarhije, proširen da podrži i dodatne aspekte, prikazan je na Slici 6. Kao što se može videti, ontologija je predstavljena kao graf koji sadrži tri tipa elemenata: (i) koncepte (oblast znanja, jedinica znanja, tema i podtema), (ii) relacije između koncepata i (iii) objekte učenja. Između koncepata se koristi pet vrsta relacija:

- **Relacija „biti deo“ (engl. „part of“ (PO))** - Relacija koja povezuje niže nivoe hijerarhije sa višim nivoima (npr. podtema je deo teme, tema je deo jedinice znanja).
- **Relacija „ima sadržaj“ (engl. „has content“ (HC))** - Definiše odnos između koncepata i OU-ova, označavajući da povezani OU nudi nastavni sadržaj za objašnjenje određene teme ili podteme.
- **Relacija redosleda (engl. „order“ (OR))** - Ova relacija se može definisati kao:
    - Obavezna relacija (engl. mandatory) koja predstavlja da su jedan ili više OU preduslov za OU koji sledi, odnosno da postoji nastavni sadržaj koji prethodno treba savladati.

    - Opciona relacija (engl. optional) koja predstavlja preporuke objekata učenja koji se mogu naučiti kako bi stekli dublje znanje o nekoj temi.
- **Relacija „ima resurs“ (engl. „has resource“ (HR))** - Koristi se između OU i njegovih resursa. Ova relacija obezbeđuje fleksibilnost u traženju određenog dela OU-a, bez potrebe da se pretražuje celo ontološko stablo. Zahvaljujući ovoj relaciji student može da traži resurs, bez potrebe da pretražuje koncepte i sadržaje objekata učenja. Detaljni prikaz ove relacije je prikazan na Slici 7.
- **Relacija „osnovni/napredni“ (engl. „basic/advanced“ (BA))** - Ovo je dvosmerni odnos koji ukazuje da je jedan koncept na nižem nivou znanja od drugog. Dva koncepta povezana BA relacijom mogu biti na različitim nivoima u hijerarhiji ontologije.

Navedene relacije ne nastaju na isti način tokom projektovanja ontološkog modela. Konceptualna hijerarhija i pripadajući objekti učenja proizlaze iz strukture kurikuluma i silabusa predmeta, na osnovu kojih se formiraju koncepti i njihove PO i HC relacije. Nasuprot tome, OR i BA relacije izražavaju semantičke zavisnosti koje se ne mogu pouzdano izvesti samo iz položaja sadržaja u kurikulumu ili redosleda kojim se sadržaji pojavljuju u silabusu. Njih nastavnik eksplicitno definiše korišćenjem alata za kreiranje ontologije (OAT), na osnovu značenja povezanih koncepata i objekata učenja i njihove pedagoške uloge [18]. Pri definisanju OR relacije najpre se utvrđuje da li između dva objekta učenja postoji stvarna zavisnost u znanju ili veštini. Obavezna OR relacija A → B definiše se samo kada je znanje ili veština obuhvaćena objektom učenja A neophodna da bi se sadržaj objekta B mogao smisleno razumeti ili da bi se aktivnost povezana sa objektom B mogla uspešno izvesti. Ako objekat B može da se uči bez prethodnog savladavanja objekta A, ali A pruža koristan dodatni kontekst, obogaćivanje ili omogućava dublje razumevanje sadržaja B, veza se označava kao opciona OR relacija, a ne kao obavezni preduslov. Sam hronološki položaj dva objekta učenja u predmetu nije dovoljan osnov za definisanje obavezne OR relacije.

BA relacija definiše se odvojeno, na nivou koncepata, kada dva semantički povezana koncepta predstavljaju fundamentalniji i napredniji nivo znanja. Zbog toga je važno razlikovati nivo na kojem se relacije definišu: OR povezuje objekte učenja i određuje zavisnost u njihovom usvajanju, dok BA povezuje koncepte i označava odnos između osnovnijeg i naprednijeg znanja. BA relacija se, takođe, ne poistovećuje sa nivoima dubine N1, N2 i N3 uvedenim kompetencijskim proširenjem modela. N1-N3 predstavljaju šire nivoe dubine razvoja kompetencije, dok BA opisuje semantički odnos između dva konkretna koncepta.

Pri odlučivanju o OR i BA relacijama nastavnik zato razmatra semantički sadržaj povezanih koncepata i objekata učenja i, kada je primenljivo, pripadajuće ishode učenja, kompetencije, elemente znanja i veština i zahteve aktivnosti provere. Na taj način OR i BA relacije nisu proizvoljne veze, već eksplicitno dokumentovane pedagoške i semantičke zavisnosti koje kasnije adaptivni sloj koristi pri formiranju uređene putanje učenja.

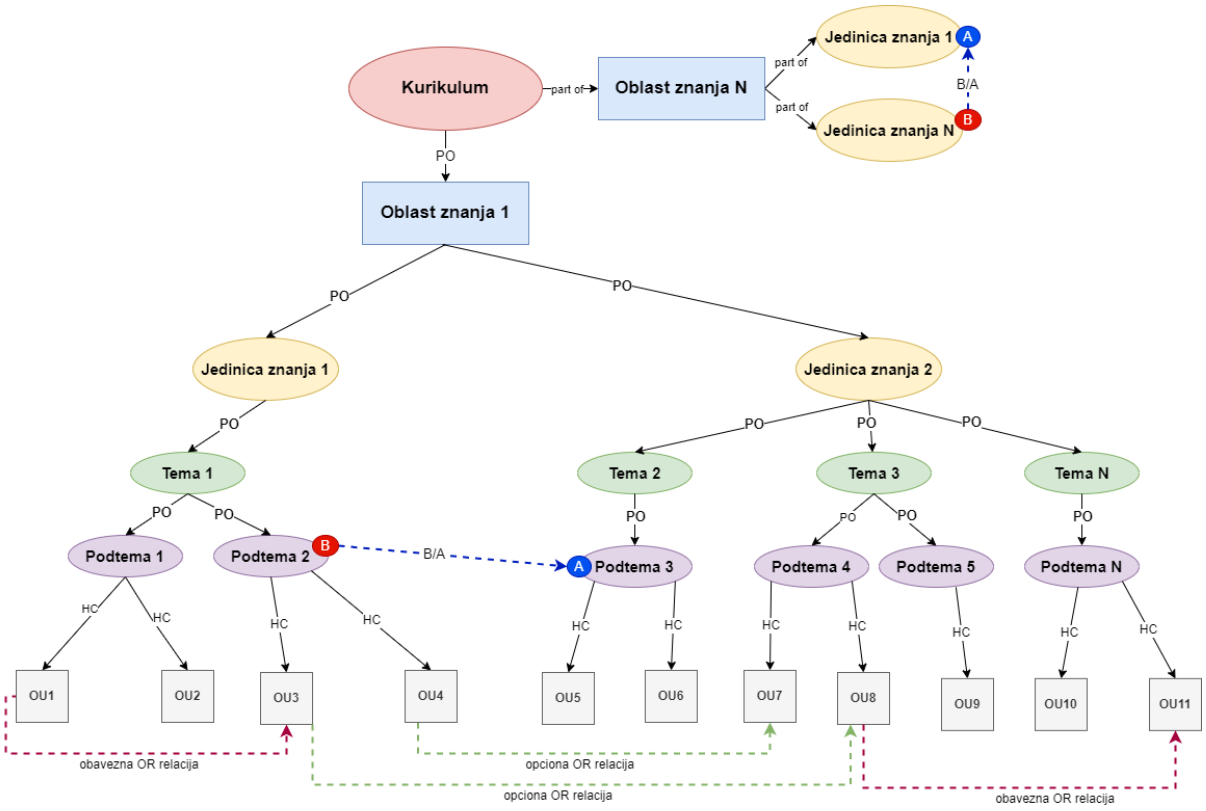

Slika 6. Konceptualni model ontologije.

Na ontološkom modelu, koncepti i sadržaj su razdvojeni. OU predstavljaju jedine čvorove koji zapravo sadrže nastavni sadržaj, dok sama struktura ontologije definiše organizaciju znanja i odnose između koncepata. Ovo odvajanje strukture od sadržaja omogućava fleksibilnost da se sadržaj može menjati, dopunjavati ili prilagođavati bez uticaja na celokupnu strukturu ontologije, a istovremeno se može redefinisati ili proširiti hijerarhija koncepata bez potrebe za promenom postojećeg nastavnog materijala. Ovakav pristup posebno je značajan u akademskom obrazovanju, gde se kurikulum jednog studijskog programa pažljivo planira kako bi obuhvatio progresivno učenje i sistematski razvoj znanja studenata. Struktura ontologije omogućava jasno definisanje nastavnih jedinica i njihovih međusobnih odnosa, čime se osigurava logičan tok učenja kroz kurikulum. Istovremeno, fleksibilnost u ažuriranju nastavnog sadržaja omogućava da se programi brzo prilagode novim naučnim dostignućima, tehnološkim

inovacijama i promenama u industriji, bez potrebe za rekonstrukcijom osnovne strukture programa. Ovo je posebno važno u oblastima koje se brzo razvijaju, gde je neophodno kontinuirano ažuriranje nastavnog materijala kako bi studenti stekli relevantna i aktuelna znanja.

Ontološki model koji je postavljen na opisan način, ne samo da pruža stabilan okvir za organizaciju akademskog sadržaja, već ima i cilj da omogući njegovu dugoročnu održivost i prilagodljivost. Koncepti se mogu okarakterisati svojim svojstvima (atributima), a njihovo korišćenje omogućava definisanje različitih dimenzija koje se koriste za vizuelizaciju ontologije i mnoštvo dodatnih mogućnosti pretraga i organizovanja nastavnih sadržaja. Svaki koncept može imati atribut sa više vrednosti (npr. koncept može biti i osnovni i napredni). Pored toga, svaki OU unutar ontologije povezan je sa različitim resursima koji predstavljaju nastavne materijale. Kao što je prikazano na Slici 7, svaki OU poseduje veze ka dodatnim resursima, uključujući video snimke, slike, programski kod i druge multimedijalne sadržaje. Ove veze omogućavaju studentima da brzo pristupe odgovarajućim resursima koji dopunjuju osnovni nastavni materijal, čime se dodatno unapređuje efikasnost adaptivne dodele resursa ili pretrage relevantnih informacija unutar sistema.

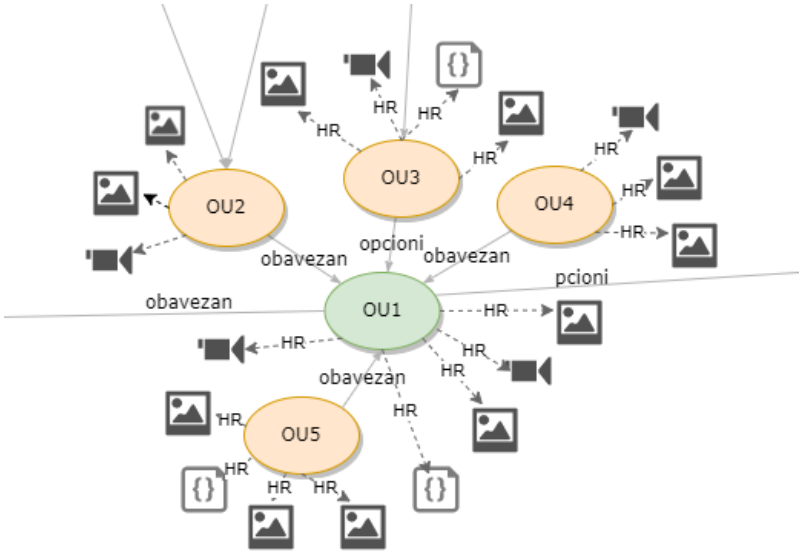

Slika 7. HR relacija između objekata učenja i njihovih resursa.

5.1.1. Fleksibilnost ontološkog modela nastavnih sadržaja

Definisana ontologija omogućava lako integrisanje dodatnih atributa i veza, čime se struktura znanja fleksibilno organizuje i prilagođava različitim scenarijima učenja. Njena modularnost omogućava kontinuirano proširenje i prilagođavanje, bez potrebe za rekonstruisanjem celokupnog modela. Ove relacije omogućavaju formiranje različitih grupa znanja u skladu sa potrebama nastavnog procesa, uključujući lekcije, nivoe znanja, ishode učenja, kompetencije, predmete, tutorijale i druge obrazovne komponente čime ontologija pokazuje proširivost u razmatranim scenarijima. U okviru ontološkog modela, svaki koncept može imati više atributa, koji se mogu dodati bez narušavanja postojeće strukture. Ova fleksibilnost omogućava nekoliko ključnih aspekata prilagođavanja i proširenja.

Pri opisu ovih mogućnosti treba razlikovati funkcionalnosti koje su implementirane i evaluirane u okviru ovog istraživanja od onih koje ontološki model podržava na konceptualnom nivou. Implementirani i evaluirani su hijerarhijska organizacija koncepata i objekata učenja sa relacijama PO, HC, OR, HR i BA, grupisanje tema i objekata učenja u lekcije, vizualizacija pomoću MCM i nelinearna navigacija u OBSLO okruženju (odeljak 7.1), zatim nivoi dubine i povezivanje objekata učenja sa ishodima učenja, kompetencijama i aktivnostima provere (odeljci 6.5 i 7.2.3), kao i adaptivna preporuka narednih koraka zasnovana na modelu studenta (odeljak 7.3.1). Ponovna upotreba istih objekata učenja u više predmeta, metapodaci o resursima i višejezičnost, tutorijali, kao i prethodna dijagnostika, kriterijumi prelaska na sledeći nivo, preporučene i adaptivne provere predstavljaju mogućnosti koje struktura ontologije podržava, ali nisu bile predmet implementacije ni evaluacije u ovom istraživanju. Za njih opisi u nastavku pokazuju šta model omogućava, a ne šta je realizovano u razvijenom sistemu.

Dodavanje atributa vezanih za nivo znanja. Svaki objekat učenja može biti označen kao osnovni, srednji ili napredni, čime se omogućava diferencirano učenje. Ova kategorizacija omogućava studentima da samostalno biraju odgovarajući nivo težine sadržaja ili da im sistem automatski dodeljuje materijal na osnovu prethodnih postignuća i procene znanja. Nivo dubine ne treba mešati sa relacijom osnovni/napredni (BA). BA relacija povezuje dva semantički povezana koncepta od kojih jedan predstavlja fundamentalniji, a drugi napredniji nivo znanja. Na primer, koncept Arhitektura može predstavljati fundamentalniji koncept u odnosu na koncept Mikroservisi, koji predstavlja napredniji koncept u okviru iste oblasti znanja. Sama BA relacija, međutim, ne označava da je jedan koncept obavezni preduslov za drugi; obavezna zavisnost u redosledu usvajanja predstavlja se OR relacijom između odgovarajućih objekata

učenja. Nasuprot tome, nivo dubine predstavlja svojstvo nastavnog sadržaja kojim se razvoj kompetencije operacionalizuje kroz nivoe N1, N2 i N3. Drugim rečima, isti koncept može biti podržan različitim objektima učenja koji odgovaraju različitim nivoima dubine razvoja kompetencije, čime je moguće organizovati postepeni prelazak od obaveznog jezgra ka dodatnom i naprednom sadržaju. Na Slici 8 prikazano je kako se atribut nivoa može primeniti na objekte učenja, omogućavajući da se sadržaji povezani sa istim konceptom organizuju na različitim nivoima dubine i da se podrži postepeni razvoj kompetencije. Formalna oznaka ovih nivoa (N1/N2/N3) i njihova veza sa kompetencijama uvode se u odeljku 5.3, u okviru proširenja modela kompetencijskim okvirom.

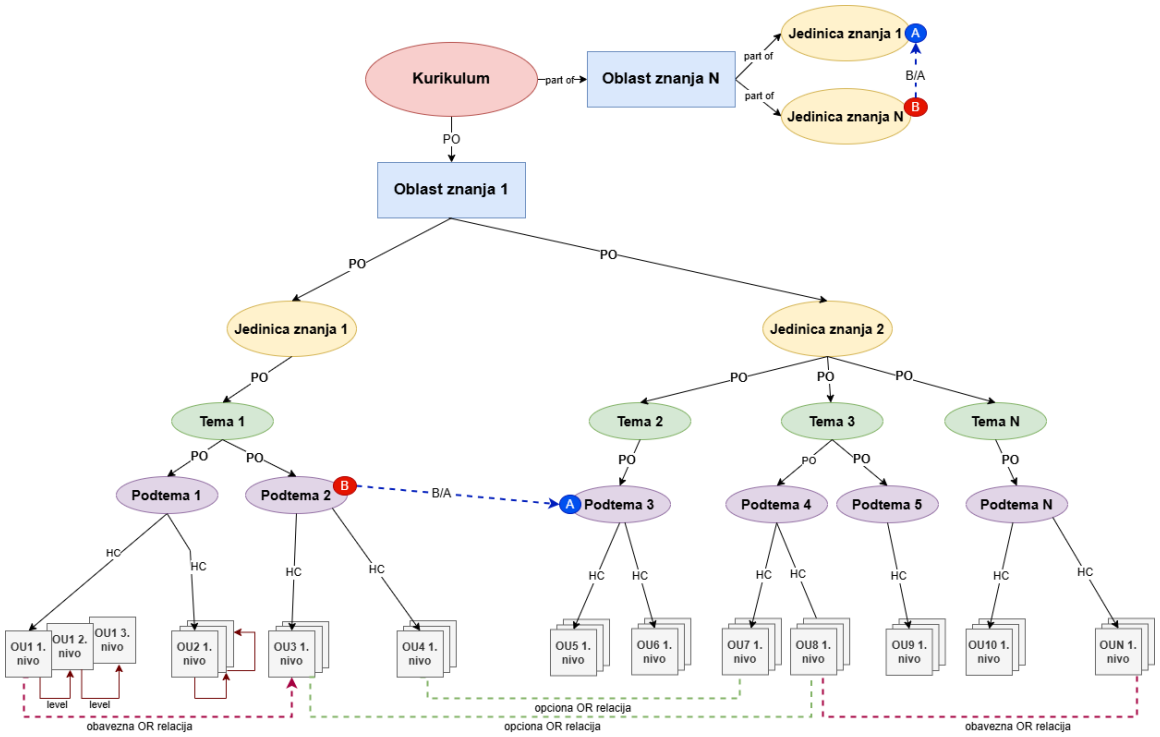

Slika 8. Konceptualni model ontologije sa pridodatim nivoima znanja dodatnim atributom *level*.

Povezivanje sa kompetencijama i/ili ishodima učenja. Svaki objekat učenja može biti eksplicitno povezan sa jasno definisanim ishodima učenja i kompetencijama koje student treba da stekne. Ishodi učenja određuju konkretna znanja, veštine i sposobnosti koje student treba da usvoji nakon obrade određenog sadržaja, dok kompetencije predstavljaju širi skup veština koji uključuje sposobnost primene znanja u različitim kontekstima. Ove veze omogućavaju precizno praćenje putanja učenja studenata i olakšavaju prilagođavanje nastavnog procesa njihovim potrebama i sposobnostima. Slika 9 ilustruje kako određeni ishod učenja može obuhvatiti jedan ili više koncepata unutar ontologije, ali i kako kompetencije, koje predstavljaju opsežnije sposobnosti studenta, mogu biti povezane sa više koncepata istovremeno. Na taj

način, prikazano je da su i ishodi i kompetencije direktno vezani za delove ontologije, omogućavajući jasan pregled koji delovi nastavnog sadržaja doprinose razvoju određenih akademskih i profesionalnih veština. Na Slici je jasno prikazano da isti koncept može biti deo više ishoda i kompetencija, čime se dodatno naglašava međuzavisnost znanja i veština. Svaki ishod može obuhvatiti određene koncepte i jasno ukazati na to koji delovi nastavnog sadržaja doprinose ostvarenju tog ishoda. Ovim pristupom omogućava se precizno usklađivanje kurikuluma sa ciljevima obrazovanja, kao i efikasnije praćenje napretka studenata u skladu sa očekivanim kompetencijama. Dodatno, ovakva organizacija omogućava nastavnicima da precizno planiraju kurikulum i raspodelu sadržaja, jer mogu videti kako se određeni koncepti uklapaju u ostvarenje različitih ciljeva učenja i profesionalnih standarda. Takođe, studentima se pruža jasniji put kroz obrazovni program, jer mogu identifikovati koje kompetencije i ishode stiču kroz pojedinačne koncepte. Način na koji je ova veza dalje formalizovana i usklađena sa širim kompetencijskim okvirom opisan je u odeljku 5.3. Ontološka hijerarhija pri tome opisuje strukturu znanja domena, a ne način na koji se nastava izvodi. Nastava se i dalje organizuje kroz predmete i lekcije, koje u modelu predstavljaju posebne elemente povezane sa konceptima i objektima učenja, kao što je opisano u nastavku ovog odeljka (Slika 10). Način na koji je veza sa ishodima učenja i kompetencijama dalje formalizovana i usklađena sa širim kompetencijskim okvirom, od referentnog korpusa znanja preko kurikuluma i predmeta do lekcije, opisan je u odeljku 5.3.

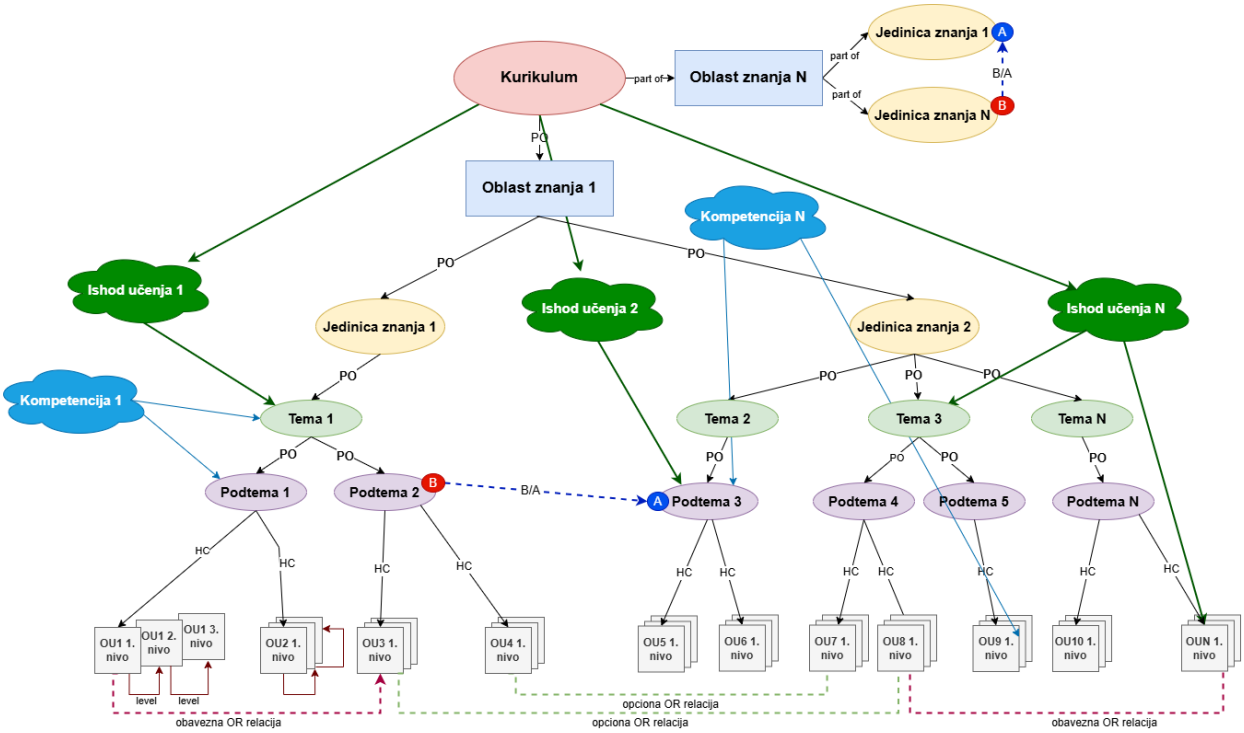

Slika 9. Konceptualni model ontologije sa pridodatim kompetencijama i ishodima učenja.

Dodavanje metapodataka o resursima. Objekti učenja mogu sadržati dodatne informacije o korišćenim izvorima, autorima materijala, jezicima sadržaja, preporučenim nastavnim metodama i vrstama medija (tekst, video, slike, interaktivni sadržaji itd.). Ovi podaci omogućavaju bolje pretraživanje i filtriranje sadržaja, olakšavajući studentima pristup relevantnim materijalima i prilagođavanje načina učenja prema njihovim preferencijama. Čak i ako sistem podržava višejezičnost, ontologija ostaje nepromenjena, dok se sam objekat učenja dopunjuje dodatnim metapodacima koji omogućavaju isporuku sadržaja na traženom jeziku prema istim pravilima.

Dodatna fleksibilnost u organizaciji nastavnog sadržaja je moguća i kroz dinamičko grupisanje koncepata i/ili objekta učenja u različite strukture koje odgovaraju specifičnim nastavnim potrebama, bez rigidnog vezivanja koncepata za jednu tačno određenu organizaciju. Ova fleksibilnost omogućava višestruku upotrebu istih objekata učenja u različitim obrazovnim kontekstima, bez nepotrebnog dupliranja podataka ili gubljenja logičke povezanosti nastavnih celina. Koristeći definisane ontološke relacije, moguće je organizovati objekte učenja u različite grupe koje odgovaraju specifičnim nastavnim potrebama - lekcije, predmete, i tutorijale sa dodatnim resursima.

Lekcije. Teme i podteme mogu se dinamički grupisati u lekcije, pri čemu se svaki objekat učenja povezuje sa odgovarajućim konceptima kroz relacije „ima sadržaj“ (HC) i „redosled“

(OR). Ovim modelom nastavnicima se omogućava da precizno definišu sekvence učenja koje studenti treba da prate, osiguravajući da svaki koncept dolazi u logičnom redosledu. Slika 10 prikazuje kako se lekcije organizuju unutar ontološkog modela. Lekcija se sastoji od skupa tema i podtema koje su povezane sa objektima učenja (OU) relacijom HC, čime se omogućava modularna struktura bez dupliranja sadržaja. OU su dalje povezani relacijom OR, koja definiše preporučeni tok učenja, ali ne nameće strogo linearan pristup, već omogućava fleksibilne putanje učenja. Lekcije ne moraju obuhvatiti celu oblast znanja, već mogu sadržati samo relevantne koncepte, što omogućava kreiranje specifičnih nastavnih celina prilagođenih određenim ishodima učenja. Isti koncepti i OU mogu se koristiti u više lekcija, a lekcije se mogu povezivati u predmete, čime se postiže skalabilnost i prilagodljivost obrazovnog sadržaja. Ovakva organizacija omogućava nastavnicima jednostavno prilagođavanje nastavnog plana. Slika 10 ilustruje moguće nivoe granularnosti povezivanja, a ne preporučenu veličinu lekcije: lekcija se može povezati sa celom temom, pojedinačnom podtemom ili izabranim objektima učenja. U uobičajenoj organizaciji nastave lekcija obuhvata više tema sa njihovim podtemama, kao što je slučaj sa lekcijama na Univerzitetu Metropolitan (odeljak 6.4, Slika 25). Model ne zahteva promenu takve organizacije niti akreditovanog plana i programa predmeta, već postojeće lekcije povezuje sa konceptima i objektima učenja koje obuhvataju. Fleksibilnost grupisanja koristi se pre svega za ponovnu upotrebu istih objekata učenja u više lekcija i predmeta i kao osnova za preporuku sadržaja studentu.

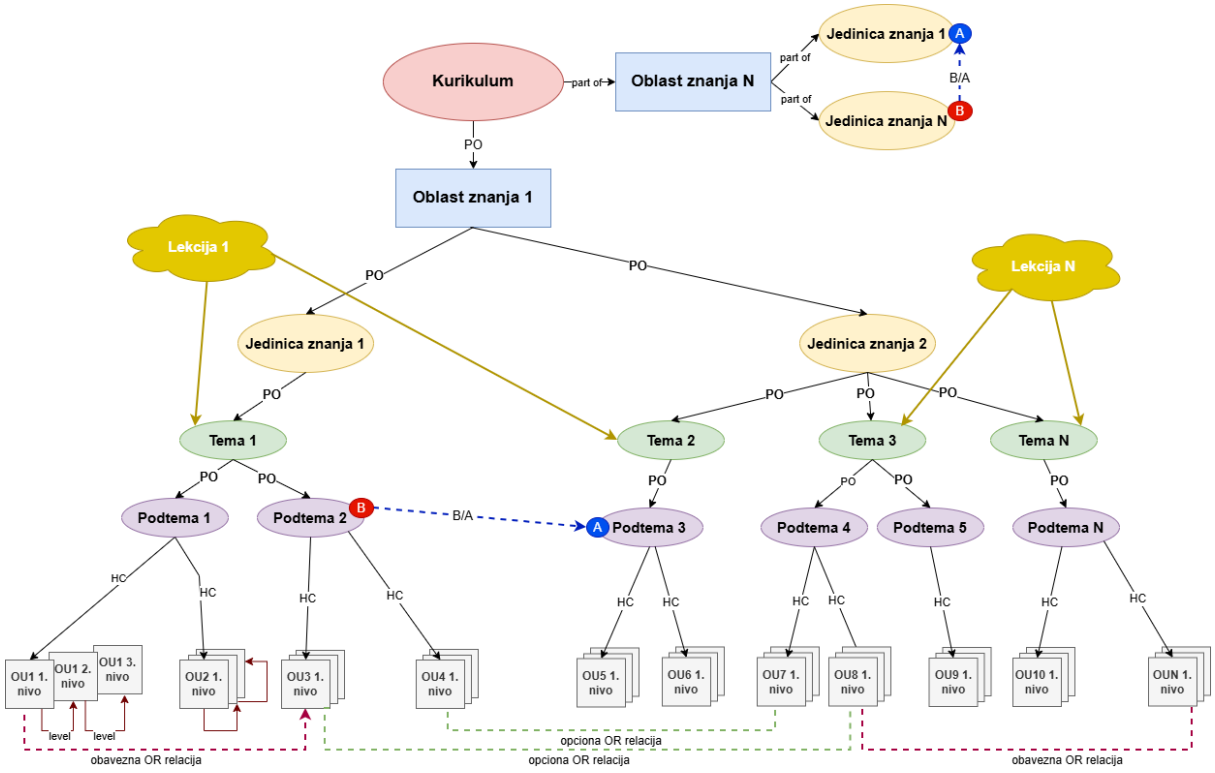

Slika 10. Konceptualni model ontologije sa strukturom lekcija.

Predmet. Skup povezanih lekcija može formirati predmet, pri čemu se lekcije grupišu na osnovu tematske povezanosti i ciljeva učenja. Predmeti mogu sadržati lekcije koje pokrivaju širok spektar koncepata, ali i specijalizovane lekcije fokusirane na praktične primene određene oblasti znanja. Posebna prednost ovog modela jeste to što struktura omogućava korišćenje istih OU u više predmeta, čime se omogućava ponovna upotreba obrazovnih resursa bez potrebe za kreiranjem novih kopija istog materijala. Na primer, isti objekat učenja može biti deo osnovnog predmeta kao uvodni materijal, ali i deo naprednog predmeta gde se koristi kao osnova za složenije analize i primene.

Tutorijali i dodatni resursi. Pod tutorijalom se u ovom radu podrazumeva ciljana nastavna celina, sastavljena od izabranih koncepata, objekata učenja i dodatnih resursa, koja je usmerena na savladavanje određene veštine ili rešavanje određene vrste problema. U kontekstu studija tutorijal po nameni odgovara vežbama i praktičnom delu nastave i može se planirati i za samostalni rad studenta, na primer kao priprema za aktivnu nastavu na časovima. Isti mehanizam omogućava i formiranje kratkih programa obuke i kurseva koji nisu vezani za studijski program, čime se pokazuje da se isti objekti učenja mogu ponovo koristiti i izvan strukture predmeta. Pomoću relacije „ima resurs“ (HR), lekcijama i predmetima mogu se dodavati dodatni nastavni materijali, poput vodiča, primera iz prakse, video snimaka, interaktivnih zadataka ili simulacija. Tutorijali ne moraju nužno biti deo osnovne strukture

predmeta, već mogu biti dodatni resursi koje studenti koriste prema potrebi, u skladu sa individualnim preferencijama i prethodnim znanjem. Pored toga, od specifičnih koncepata i/ili objekata učenja mogu se formirati specifični tutorijali, koji studentima mogu služiti kao ciljane obrazovne celine za rešavanje određenih problema ili savladavanje konkretnih veština. Ovi tutorijali mogu biti strukturirani tako da prate logiku problemskog učenja (engl. problem-based learning), gde studenti dobijaju priliku da primene svoje znanje u realnim ili simuliranim scenarijima.

Fleksibilnost ontološkog modela se ne ogleda samo u njegovoj strukturi, već i u podršci za različite modele učenja, prilagođavajući se potrebama studenata i pedagoškim pristupima. Korišćenje relacija „ima sadržaj“ (HC) i „redosled“ (OR) omogućava personalizovane putanje učenja, podržavajući nekoliko modela:

- Sekvencijalno učenje omogućava studentima da prate preporučene puteve učenja, gde se koncepti predstavljaju logičnim redosledom uz jasno definisane prethodne uslove. Ovaj pristup obezbeđuje sistematično usvajanje znanja, posebno korisno za studente koji prvi put savladavaju gradivo.
- Nelinearni putevi učenja omogućavaju studentima sa odgovarajućim predznanjem da preskoče određene sadržaje i usmere se na složenije koncepte. Na taj način nastavni sadržaj može biti prilagođen individualnom predznanju studenta i organizovan tako da se izbegne nepotrebno ponavljanje već poznatog gradiva.
- Adaptivno učenje podrazumeva da sistem prilagođava sadržaj, redosled ili tempo učenja pojedinačnom studentu na osnovu informacija o njemu. Te informacije mogu poticati iz rezultata aktivnosti provere (testova, zadataka i projekata) i praćenja aktivnosti studenta, ali i iz iskazanih interesovanja i ciljeva studenta, na primer kada student želi da produbi užu oblast kompetencija. U ovoj disertaciji adaptacija je zasnovana na rezultatima aktivnosti provere i podacima o aktivnostima studenta (odeljak 7.3.1). Prilagođavanje prema interesovanjima studenta model podržava kroz izbor dodatnih sadržaja nivoa N2 i N3 (odeljak 4.3.1), ali ono nije bilo predmet implementacije. Na osnovu uspeha u prethodnim lekcijama, studentima se mogu ponuditi dodatni resursi, vežbe ili alternativni pristupi učenju, što omogućava personalizaciju nastavnog procesa.

Fleksibilnost ontološkog modela kroz gore navedene primene pokazuje njegovu proširivost i sposobnost da podrži različite pristupe učenju. Međutim, istraživanja modela studenta, kao i analiza i evaluacija modela nastavnih materijala koji su predstavljeni u Poglavlju 7, ukazuju na

to da je za uspešno ostvarivanje adaptivnog modela ključno imati jasan uvid u nivo znanja studenta. Da bi personalizovane putanje učenja bile efikasne, potrebno je u model integrisati formativne provere znanja, koje omogućavaju kontinuiranu procenu studentskog razumevanja i prilagođavanje nastavnog sadržaja prema individualnim potrebama. Ove provere ne samo da omogućavaju dinamičko prilagođavanje kurikuluma, već i pružaju povratne informacije kako nastavnicima, tako i studentima, čime se poboljšava proces usvajanja znanja. Dodavanjem formativnih provera u ontološki model, obezbeđuje se bolje praćenje rada studenata tokom učenja Ove provere imaju različite funkcije:

- Prethodna dijagnostika - Identifikacija početnog nivoa znanja studenta omogućava preciznije usmeravanje ka odgovarajućim nastavnim resursima, sprečavajući suvišno ponavljanje poznatog gradiva ili preuranjeni prelazak na složenije teme.
- Praćenje napretka - Kontinuirana evaluacija razumevanja koncepta pomaže u prilagođavanju nastavnog procesa i pružanju individualnih preporuka za dalje učenje. Preduslov za to je da student redovno izvršava predispitne obaveze i druge aktivnosti tokom semestra, jer se njegovo stanje procenjuje iz dokaza koje te aktivnosti proizvode. Kod kampanjskog načina studiranja, u kojem se rad koncentriše neposredno pred rokove ili ispit, dokaza tokom semestra ima malo, pa praćenje napretka i preporuke ne mogu pravovremeno da deluju. U analiziranim predmetima ovaj obrazac delimično se ogleda u minimalističkom ponašajnom tipu (odeljak 7.2.3.3).
- Samoevaluacija studenata - Omogućava studentima da prate svoj napredak i samostalno identifikuju oblasti koje zahtevaju dodatno vežbanje, podstičući ih na aktivno učenje.
- Prelazak na sledeći nivo - Model može definisati određene kriterijume koje student mora da ispuni pre nego što pređe na sledeći segment gradiva, čime se osigurava da studenti savladaju osnovne koncepte pre nego što se suoče sa složenijim temama.

Uvođenjem formativnih provera znanja ontološki model dobija dodatnu ulogu u podršci personalizovanom i adaptivnom učenju, jer omogućava da se nastavni sadržaji i aktivnosti provere povežu sa informacijama potrebnim za praćenje napretka i formiranje individualizovane podrške. Od navedenih funkcija provera, u ovom istraživanju realizovano je povezivanje aktivnosti provere sa objektima učenja radi praćenja napretka i identifikovanja potreba za podrškom (odeljak 6.5), dok prethodna dijagnostika, kriterijumi prelaska na sledeći nivo, preporučene i adaptivne provere predstavljaju konceptualne mogućnosti modela. Time se

dodatno pokazuje proširivost modela, dok se konkretna adaptivna odluka formira tek povezivanjem ontološke strukture sa modelom studenta i adaptivnim mehanizmom. U ontološkom modelu, provere znanja se mogu organizovati na različitim nivoima i na sledeće načine (Slika 11):

- Kao deo individualnih objekata učenja (OU) - Svaka tema ili podtema može sadržati pripadajuće formativne provere (npr. kvizove, mini testove, interaktivne zadatke), čak i po različitim nivoima znanja.
- Kao poseban entitet u ontologiji - Formativne provere mogu biti zasebni čvorovi u ontološkoj strukturi, povezani sa odgovarajućim temama i podtemama.
- Preporučene provere - Na osnovu performansi studenata, sistem može automatski preporučiti dodatne testove ili vežbe za usvajanje znanja.
- Adaptivne provere - Provere znanja i/ili veština mogu se prilagođavati u realnom vremenu na osnovu odgovora studenata, nudeći lakše ili teže zadatke u zavisnosti od tačnosti njihovih odgovora. Ovakvo prilagođavanje pojedinačnom studentu izvodljivo je pre svega u onlajn okruženju, odnosno u onlajn delovima kombinovane nastave, kao što su testovi u sistemu za učenje i samostalni rad, dok ga je u nastavi uživo teško sprovesti za svakog studenta posebno.

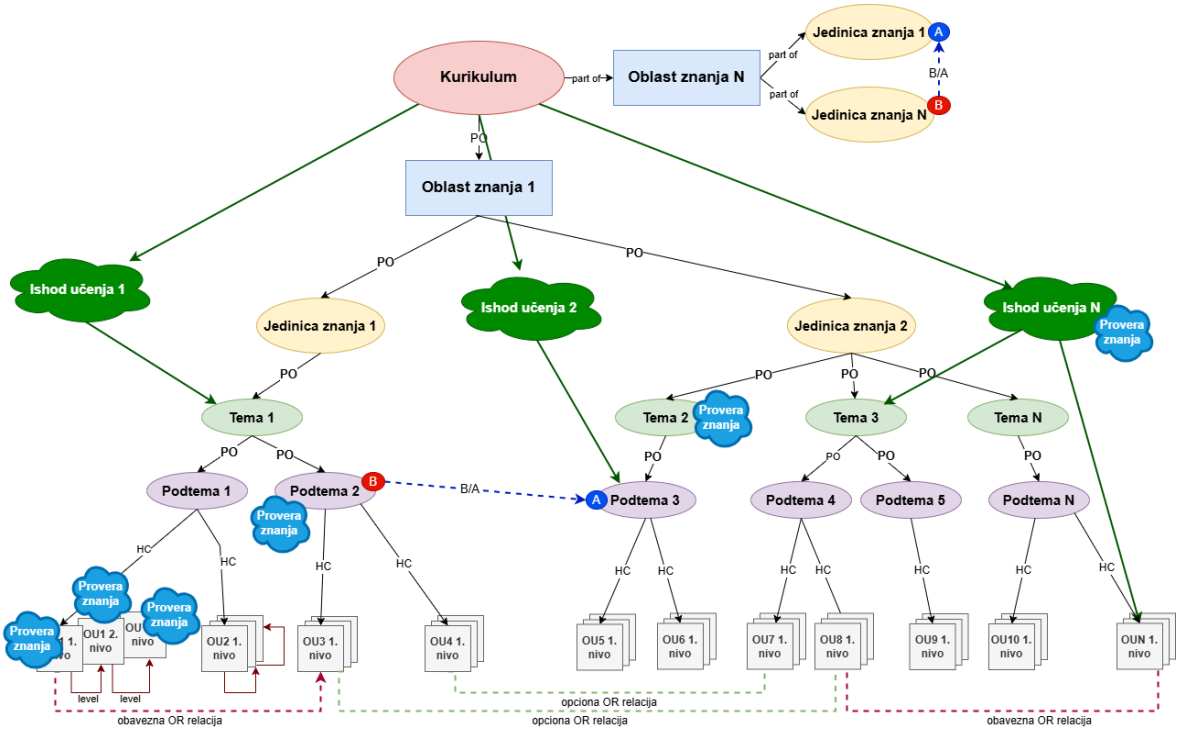

Slika 11. Konceptualni model ontologije obogaćen formativnim proverama znanja radi lakšeg prilagođavanja putanja učenja.

Zahvaljujući relacijama „biti deo“ (PO) i „osnovni/napredni“ (BA), objekti učenja mogu se koristiti u više predmeta, što omogućava njihovu ponovnu upotrebu i jednostavnu integraciju u različite nastavne kontekste. Dodatna prednost ovakve ontološke strukture leži u njenoj proširivosti. Zahvaljujući multidimenzionalnoj organizaciji, moguće je ne samo koristiti postojeće relacije, već i lako uvoditi nove vrste veza i atributa koji omogućavaju preciznije mapiranje obrazovnih resursa. Ova fleksibilnost osigurava da sistem ostane prilagodljiv promenama u nastavnim programima i novim pristupima učenju, čime se olakšavaju održavanje i buduće proširenje modela.

5.2. Adaptivna preporuka sadržaja i dinamička isporuka i vizualizacija nastavnih sadržaja

Ontološki model sadržaja opisan u odeljku 5.1, model studenta (Poglavlje 6) i mehanizam preporuke nastavnog sadržaja (Poglavlje 7) odgovaraju klasičnim komponentama koje literatura prepoznaje u adaptivnim i personalizovanim obrazovnim sistemima - modelu sadržaja, modelu studenta i adaptivnom modelu [266]. Centralni fokus disertacije jeste razvoj modela studenta i njegovo semantičko povezivanje sa ontološki strukturiranim nastavnim sadržajem, dok adaptivni model predstavlja završni sloj kojim se izlazi modela studenta operacionalizuju kroz izbor, uređivanje i obrazlaganje individualno preporučenih objekata učenja. Predmet disertacije nije razvoj novog inteligentnog tutorskog ili LMS sistema kao celine, već razvoj i integracija ovih modela i mehanizama u sledljiv postupak personalizovanog i adaptivnog e-učenja. U ovom odeljku opisuje se kako se model sadržaja isporučuje i vizualizuje studentu, kao i softverska arhitektura koja to podržava.

5.2.1. Vizualizacija ontološkog modela korišćenjem multidimenzionalnih konceptualnih mapa

Prilikom vizualizacije ontološkog modela primenjuju se principi vizuelnog grupisanja kako bi se omogućila intuitivna i pregledna organizacija koncepata u hijerarhijsku strukturu. Ovi principi omogućavaju efikasno navigiranje kroz obimne skupove podataka, personalizovano prilagođavanje sadržaja korisniku i dinamičko prikazivanje relevantnih informacija u skladu sa individualnim potrebama studenta. Vizualizacija ontološkog modela u ovom radu zasnovana je na multidimenzionalnim konceptualnim mapama (MCM), koje omogućavaju strukturalnu organizaciju pojmova kroz sledeće dimenzije:

1. **Hijerarhijska organizacija tematskih celina**

   Koncepti su predstavljeni kroz „roditelj/dete“ odnose, pri čemu se nadređeni čvorovi granaju u podteme, sve do pojedinačnih objekata učenja (OU). Ova hijerarhijska struktura omogućava progresivno učenje i sistematsko prelaženje kroz sadržaj. Relacije koje omogućavaju ovu organizaciju su:

   - Relacija „biti deo“ (engl. „part of“ (PO)) - definiše da je određeni koncept sastavni deo drugog, nadređenog koncepta.
   - Relacija „ima sadržaj“ (engl. „has content“ (HC)) - povezuje koncepte sa pripadajućim objektima učenja koji objašnjavaju sadržaj datog koncepta.

2. **Horizontalna povezanost objekata učenja**

   Objekti učenja koji imaju sličan sadržaj ili koji su deo iste tematske celine povezani su međusobno horizontalnim vezama. Ovo omogućava korisnicima da istraže alternativne ili dopunske materijale bez narušavanja logičke strukture ontologije. Ova povezanost ostvaruje se putem:

   - Relacija redosleda (engl. „order“ (OR)) - odnosi se na sekvencijalni redosled između objekata učenja, određujući preporučeni tok učenja i progresiju od osnovnih ka naprednim sadržajima.

3. **Klasifikacija po atributima i diferencijacija nivoa znanja**

   Kako bi se omogućila preciznija personalizacija i filtriranje sadržaja, objekti učenja se grupišu prema zajedničkim atributima. Na primer, jedan od ključnih kriterijuma za klasifikaciju je nivo znanja, gde se OU mogu kategorizovati kao osnovni ili napredni. Ova dimenzija uvodi dodatnu složenost u prikaz konceptualnih mapa i omogućava dinamičko prilagođavanje sadržaja u skladu sa potrebama korisnika. Relacija „osnovni/napredni“ (engl. „basic/advanced“ (BA)) se odnosi na povezivanje osnovnih i naprednih koncepata, omogućavajući studentima da biraju nivo složenosti gradiva.

Nakon definisanja ontološkog modela, MCM se generiše dinamički, pri čemu korisnik u svakom trenutku vidi samo relevantne delove konceptualne mape. Prikaz se dinamički generiše na osnovu aktuelne strukture ontološkog modela, dok student izborom koncepata i nivoa prikaza pristupa odgovarajućim delovima konceptualne mape i povezanim nastavnim sadržajima. Ovakav pristup omogućava postepeno prikazivanje strukture domena i ograničavanje količine informacija prikazane u jednom trenutku, pri čemu se personalizacija u ovoj fazi sistema prvenstveno ostvaruje kroz izbor i navigaciju studenta kroz MCM. MCM prikaz ne zamenjuje sekvencijalnu nastavu po lekcijama, već služi kao dopunski način pristupa

sadržaju. Pošto je lekcija u ontologiji povezana sa temama, podtemama i objektima učenja koje obuhvata (Slika 10), prikaz se može implementirati i tako da polazi od lekcije, u redosledu lekcija – tema – podtema – objekat učenja.

Principi vizuelnog grupisanja prilikom prikaza konceptualne mape su sledeći:

- **Prikaz podređenih čvorova**
  Za svaki koncept najvišeg nivoa prikazuju se samo njegovi direktni podređeni čvorovi. Na primer, ako je oblast znanja definisana kao najviši nivo, korisniku će biti prikazane samo njene jedinice znanja.
- **Prikaz podstabala pri izboru nižeg nivoa**
  Kada student odabere određenu tematsku jedinicu, prikazuje se njeno celo podstablo, uključujući teme, podteme i pripadajuće objekte učenja.
- **Navigacija kroz osnovne i napredne koncepte**
  Relacije osnovni/napredni omogućavaju studentima da biraju između osnovnih i naprednih verzija istog koncepta, što omogućava fleksibilan pristup učenju u skladu sa prethodnim znanjem.
- **Prikaz obaveznih i opcionalnih OU**
  Za teme na najnižem nivou hijerarhije prikazuju se svi obavezni objekti učenja, dok se opcioni OU označavaju indikatorima koji omogućavaju studentima da ih istraže ako žele dodatno proširiti svoje znanje. Model pri tome ne ograničava opcione OU na najniži nivo hijerarhije, već se oni mogu pridružiti konceptima na bilo kom nivou.
- **Prikaz sadržaja OU pri izboru**
  Kada student odabere određeni objekat učenja, njegov sadržaj se prikazuje u posebnom segmentu, omogućavajući detaljno proučavanje materijala bez ometanja pregleda šire konceptualne mape.

5.2.1.1. Softverska arhitektura sistema za podršku učenju korišćenjem ontologija i MCM-a

OBSLO (engl. Ontology-Based System for Learning Object Retrieval) je novoprojektovan sistem razvijen sa ciljem da podrži razvoj modela ontologije objekata učenja (OU) za određeni domen i da vizualizuje razvijenu ontologiju koristeći multidimenzionalne konceptualne mape (MCM) [14]. Ovaj sistem pruža mogućnost prilagođenog i dinamičkog učenja kroz povezivanje ontološkog modela, personalizovanih puteva učenja i napredne vizualizacije

znanja, omogućavajući studentima da na intuitivan način istražuju i savladavaju nastavne sadržaje.

U savremenim obrazovnim sistemima postoji potreba za efikasnijim načinima organizacije i prezentacije nastavnih materijala. Tradicionalni sistemi za e-učenje često ne pružaju adekvatnu podršku za individualizaciju pristupa učenju, što može otežati prilagođavanje sadržaja različitim nivoima znanja i interesovanjima studenata. OBSLO je projektovan upravo da odgovori na ove izazove kroz implementaciju ontološkog modela koji omogućava preciznu kategorizaciju i personalizovanu isporuku nastavnog materijala. Sistem se sastoji od tri osnovne komponente koje zajedno omogućavaju sve ključne funkcionalnosti OBSLO okruženja (Slika 12):

1. Alat za izradu ontologije (engl. Ontology Authoring Tool (OAT))
2. Kreator MCM okruženja za učenje (engl. MCM Learning Environment Creator (MCMLEC))
3. Sistem za upravljanje relacionim bazama podataka (engl. Relational Database Management System (RDBMS)).

OBSLO je razvijen kao modularni sistem projektovan za povezivanje sa postojećim institucionalnim sistemima za e-učenje (engl. Institutional Learning System (ILS)). U prikazanoj arhitekturi razmena podataka ostvaruje se preko definisanih interfejsa, čime se smanjuje potreba za promenama u osnovnim sistemima. Ova projektovana modularnost ne predstavlja empirijski potvrđenu interoperabilnost sa proizvoljnim spoljnim platformama.

Posebna pažnja posvećena je integraciji OBSLO-a sa *Repozitorijumom objekata učenja* (engl. Learning Object Repository (LOR)), koji služi kao centralno skladište nastavnih materijala u formi objekata učenja. Integracija sa LOR-om omogućava automatsko preuzimanje i prikaz nastavnih materijala unutar MCMLEC-a, čime se studentima pruža intuitivan i pregledan način navigacije kroz nastavne sadržaje. Ova integracija realizovana je kroz LOR content provider, koji omogućava MCMLEC-u da u realnom vremenu preuzima sadržaj iz ILS-a i prikazuje ga nastavnicima i studentima.

U cilju dodatnog poboljšanja interaktivnosti i efikasnosti u učenju, OBSLO je projektovan tako da se može povezati sa eksternim alatima za automatsku proveru rešenja zadataka čija se ispravnost može utvrditi izvršavanjem, kao što su SQL upiti. Jedan od primera je integracija sa CodeBox-om, platformom koja omogućava izvršavanje SQL naredbi. Ova integracija omogućava studentima da rešavaju zadatke direktno unutar sistema i odmah dobiju povratne

informacije o ispravnosti svojih rešenja. Tokom rada sa CodeBox-om, studentska rešenja se putem CB provajdera šalju na proveru, gde se SQL izrazi izvršavaju i analiziraju. Nakon toga, rezultati se vraćaju u sistem i postaju deo studentskog profila, omogućavajući nastavnicima uvid u njihov napredak. Samu proveru obavlja eksterni alat, a automatsko ocenjivanje nije bilo predmet razvoja ni evaluacije u ovoj disertaciji. Ovakva provera mogla bi se proširiti na programske zadatke u jezicima kao što su Java, Python ili C++, kod kojih se ispravnost rešenja takođe može utvrditi izvršavanjem koda. Automatsko ocenjivanje pisanih i usmenih odgovora u slobodnoj formi, projekata, seminarskih radova i studija slučaja, koji preovlađuju na predmetima kao što su predmeti softverskog inženjerstva, predstavlja znatno složeniji problem, čak i uz primenu alata zasnovanih na veštačkoj inteligenciji, i ostaje otvoreno pitanje za buduća istraživanja.

Predložena arhitektura OBSLO sistema donosi brojne prednosti za različite korisnike. Za institucije, sistem je projektovan tako da se sa postojećim sistemom za e-učenje povezuje kao dodatni sloj, bez zamene tog sistema. U ovom istraživanju takvo povezivanje realizovano je sa postojećim komponentama institucionalnog sistema, dok povezivanje sa drugim LMS platformama nije proveravano. Modularna struktura predstavlja osnovu za prilagođavanje sistema specifičnim potrebama obrazovnih institucija. Nastavnicima OBSLO pruža mogućnost dinamičkog kreiranja ontoloških modela i povezivanja nastavnih sadržaja sa problemima i zadacima koje studenti rešavaju. Sistem omogućava praćenje učinka studenata i generisanje podataka o njihovim interakcijama sa nastavnim sadržajima, koje nastavnik može koristiti pri razmatranju prilagođavanja nastavnih materijala. Za studente, OBSLO donosi personalizovane puteve učenja koji omogućavaju postepeno savladavanje znanja u skladu sa individualnim potrebama. Sistem omogućava vizuelnu navigaciju kroz nastavne sadržaje korišćenjem MCM-a, čime se omogućava preglednije sagledavanje strukture gradiva i odnosa između povezanih nastavnih sadržaja. Povratna informacija o tačnosti rešenja, kada je sistem povezan sa alatom za proveru, dodatno podržava aktivan rad studenta, dok nelinearna navigacija kroz MCM omogućava neposredniji pristup relevantnim objektima učenja bez potrebe za prolaskom kroz celokupnu linearnu sekvencu nastavnog sadržaja. Ovakav način rada posebno je pogodan za samostalni rad studenta kao pripremu za nastavu uživo, po modelu obrnute učionice (engl. flipped classroom), u kojem se sadržaj savladava pre časa, a časovi se koriste za diskusiju, rešavanje zadataka i proveru naučenog.

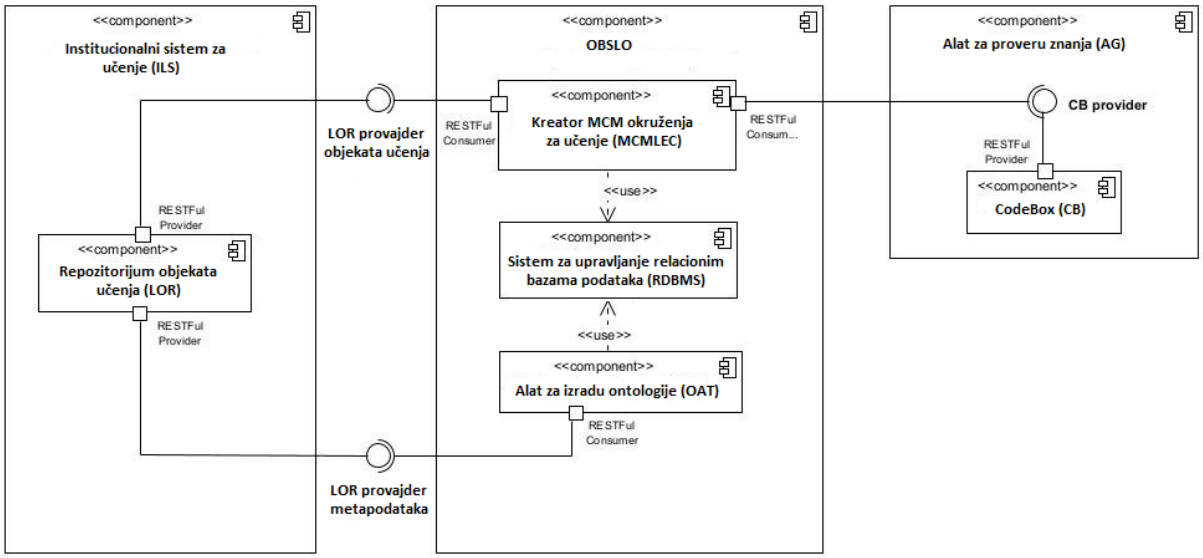

Slika 12. Softverska arhitektura OBSLO sistema.

OBSLO predstavlja rešenje koje objedinjuje ontologije, multidimenzionalne konceptualne mape i automatizovane alate za proveru znanja u cilju poboljšanja procesa učenja i evaluacije. Njegova primena omogućava efikasno organizovanje, pretragu i vizuelizaciju nastavnog sadržaja, dok istovremeno pruža fleksibilno i personalizovano okruženje za studente. U nastavku rada, detaljnije će biti obrađene ključne komponente sistema - OAT i MCMLEC - kao i praktičan primer njegove primene u domenu baza podataka.

5.2.1.1.1. OBSLO Ontology Authoring Tool (OAT)

OBSLO Ontology Authoring Tool (OAT) predstavlja komponentu sistema koja omogućava nastavnicima da definišu, upravljaju i unapređuju ontologije domena znanja [18]. OAT omogućava intuitivno kreiranje i modifikaciju ontoloških modela, skladištenje podataka u sistemu za upravljanje relacionim bazama podataka (RDBMS) i generisanje izveštaja o korišćenju nastavnih materijala.

Ova komponenta omogućava da se svi elementi ontologije domena čuvaju u RDBMS sistemu, čime se obezbeđuje sigurno i efikasno skladištenje svih podataka relevantnih za nastavne procese. Elementi ontologije domena uključuju:

1. Koncepte i njihove povezane atribute (kao što je nivo znanja, složenost sadržaja, vrsta resursa)
2. Relacije između koncepata (hijerarhijske i semantičke veze)
3. Relacije između objekata učenja (OU) (veze između različitih nastavnih materijala)
4. Relacije između koncepata i OU (povezivanje teorijskih znanja sa specifičnim resursima)

Kreiranje ontoloških modela unutar OAT-a omogućava precizno definisanje strukture nastavnog sadržaja i olakšava pronalaženje relevantnih nastavnih materijala. OAT omogućava nastavniku da koristi izveštaje o studentskim putanjama, generisane u okviru analitičke komponente OBSLO sistema, kao osnovu za razmatranje izmena ontološkog modela.

Iako OAT prvenstveno funkcioniše kao alat za nastavnike koji kreiraju ontologije domena, on takođe obezbeđuje okruženje za analizu i evaluaciju obrazovnih procesa. Kroz ovu komponentu moguće je generisati različite izveštaje bazirane na personalizovanim putanjama učenja, koje studenti sami kreiraju tokom interakcije sa sistemom. Analizom putanja učenja svih korisnika, moguće je dobiti preporuke za modifikaciju postojeće verzije ontologije domena. Na primer, ako većina studenata preskače određeni objekat učenja ili ga koristi na drugačiji način nego što je predviđeno, nastavnik može ažurirati ontologiju kako bi se poboljšala relevantnost i dostupnost nastavnog materijala. OAT komponenta je razvijena sa grafičkim korisničkim interfejsom (GUI) koji omogućava vizuelnu manipulaciju ontološkim modelima. Nastavnici mogu vizuelno organizovati koncepte, dodeljivati im atribute i definisati međusobne veze.

Jedan od glavnih ciljeva OAT arhitekture jeste unapređenje upravljanja objektima učenja i njihovog pronalaženja unutar sistema. Ovo se postiže povezivanjem ontoloških modela sa LOR-om, što omogućava semantički bogatiju klasifikaciju i organizaciju nastavnih materijala. Tradicionalni metapodaci dodeljeni OU ne opisuju uvek dovoljno njihove semantičke odnose sa drugim nastavnim materijalima, pa OAT omogućava obogaćivanje OU komplementarnim znanjem predstavljenim u obliku ontologija. Svaki OU može biti povezan sa odgovarajućim konceptualnim strukturama, dok OAT obezbeđuje i ontološki model domenske oblasti, čime se podržavaju povezivanje i ponovna upotreba nastavnih resursa. Obogaćena svojstva OU čuvaju se u RDBMS-u, a sadržaj se preuzima iz LOR-a. U prikazanoj implementaciji realizovane su konkretne integracije sa postojećim komponentama sistema; univerzalna interoperabilnost sa različitim spoljnim platformama nije empirijski potvrđena.

Proces kreiranja ontologije u OAT-u prolazi kroz sledeće faze:

1. Definisanje osnovnih koncepata i hijerarhije
   i) Nastavnici unose ključne pojmove iz domena i organizuju ih u hijerarhijski model.
   ii) Definišu se osnovni odnosi između koncepata, uključujući nadređeni/podređeni odnosi (roditelj/dete).
2. Dodavanje atributa i semantičkih veza

i) Konceptima se dodeljuju atributi poput nivoa znanja, složenosti, relevantnosti itd.
ii) Povezuju se sa srodnim pojmovima kroz semantičke relacije (npr. ekvivalencija, povezani pojmovi, zavisnosti).

3. Integracija sa objektima učenja (OU)
   i) Svaki koncept se povezuje sa odgovarajućim nastavnim resursima iz LOR-a.
   ii) OAT omogućava kreiranje veza između OU, što omogućava bolje navigiranje i organizaciju nastavnih materijala.
4. Vizualizacija ontologije i evaluacija interakcija studenata
   i) Kreirana ontologija se prikazuje putem MCMLEC komponente, omogućavajući studentima personalizovan prikaz sadržaja.
   ii) Sistem prikuplja podatke o korišćenju OU i generiše izveštaje o interakcijama studenata, koji se koriste za unapređenje modela.
5. Iterativno unapređenje ontologije
   i) Na osnovu generisanih izveštaja i analize studentskog napretka, nastavnici mogu prilagoditi ontologiju i poboljšati kvalitet nastavnog materijala.
   ii) OAT omogućava kontinuirano ažuriranje ontoloških modela, čime se osigurava njihova relevantnost i preciznost.

OAT komponenta je deo OBSLO sistema i direktno je povezana sa MCMLEC-om i RDBMS-om. Kreirane ontologije se dinamički prikazuju kroz MCMLEC, dok se podaci o interakcijama studenata sa nastavnim materijalima skladište u RDBMS-u radi naknadne analize. Analizu studentskih putanja u izvornoj OBSLO arhitekturi obavlja analitička komponenta, a dobijene izveštaje nastavnik može koristiti u OAT-u kao osnovu za razmatranje izmena ontološkog modela.

5.2.1.1.2. OBSLO MCM Learning Environment Creator (MCMLEC)

MCMLEC predstavlja komponentu OBSLO sistema za prezentaciju ontologije domena i povezanih objekata učenja korišćenjem multidimenzionalnih konceptualnih mapa (MCM). Funkcionalnost MCMLEC-a oslanja se na dinamičko generisanje konceptualnih mapa iz aktuelne verzije ontologije i omogućava studentima nelinearnu navigaciju kroz nastavne sadržaje, izbor osnovnih ili naprednih koncepata, pristup zadacima i rešavanje problema. Sistem beleži putanje studenata, korišćene objekte učenja, redosled njihovog korišćenja, vreme provedeno na sadržajima i rezultate aktivnosti radi naknadne analize. Nastavnici kroz MCMLEC mogu postavljati zadatke, probleme i resurse za učenje zasnovano na rešavanju problema, kao i pregledati studentska rešenja dobijena putem integrisanih alata za proveru

znanja. U ovoj verziji OBSLO-a personalizovani prostor nastaje kroz izbor i navigaciju studenta kroz MCM, dok automatski izbor sadržaja na osnovu dinamičke procene ovladanosti studenta pripada konačnom modelu studenta i adaptivnom mehanizmu razvijenom u kasnijoj fazi disertacije.

Jedna od važnijih uloga MCMLEC-a jeste povezivanje sistema za e-učenje sa alatima za proveru znanja, kao što je CodeBox. Kada student reši zadatak čija se ispravnost može automatski utvrditi, kao što je SQL upit, programski kod, njegovo rešenje se šalje na proveru putem RESTful servisa, a povratna informacija o tačnosti i eventualnim greškama vraća se u sistem. Za testove sa otvorenim tekstualnim odgovorima i druge aktivnosti tekstualnog karaktera ovakva automatska provera nije primenljiva, što je navedeno kao otvoreno pitanje za buduća istraživanja (odeljak 8.4). Tako se omogućava studentima da odmah dobiju povratne informacije i prilagode svoje dalje učenje na osnovu dobijenih rezultata. Podaci o interakciji studenata sa sistemom skladište se u bazi podataka i omogućavaju analizu napretka, identifikaciju potencijalnih teškoća u učenju i generisanje preporuka za poboljšanje nastavnih sadržaja. U MCMLEC okruženju, nastavnici mogu pregledati studentske putanje učenja, analizirati koje objekte učenja studenti najčešće koriste i prilagođavati nastavne materijale kako bi unapredili obrazovni proces. Kreiranje novih zadataka i problemskih situacija može se bazirati na analizi studentskih odgovora i njihovog razumevanja određenih koncepata. Sistem pruža fleksibilnost u vezi sa integracijom različitih eksternih alata za proveru znanja, omogućavajući nastavnicima da koriste različite tehnologije u skladu sa specifičnostima predmeta. MCMLEC obezbeđuje podršku za više modela učenja, uključujući samostalno istraživanje nastavnih materijala, učenje kroz rešavanje problema i personalizovano usmeravanje studenata kroz obrazovni sadržaj. U institucionalnom okruženju Univerziteta Metropolitan ove funkcionalnosti mogle bi se rasporediti po postojećim podsistemima. Funkcionalnosti namenjene studentu, kao što su navigacija kroz MCM, pristup objektima učenja i rešavanje zadataka, pripadale bi sistemu za učenje iLearn. Izrada nastavnih materijala i objekata učenja i njihovo povezivanje sa ontologijom pripadali bi alatu za pisanje nastavnih materijala iCreate. Evidencija aktivnosti provere, pokušaja i ostvarenih rezultata pripadala bi informacionom sistemu iMet. Ovakva podela olakšala bi definisanje prototipskih rešenja u daljem razvoju sistema. Zbog mogućnosti fleksibilne integracije sa različitim alatima i platformama, ovaj sistem je pogodan za širok spektar obrazovnih scenarija, omogućavajući institucijama da obogate i unaprede svoje nastavne programe.

MCMLEC predstavlja korisničku komponentu OBSLO sistema kroz koju se ontološka struktura i multidimenzionalne konceptualne mape operacionalizuju u okruženju za rad studenta. Komponenta omogućava dinamički prikaz nastavnog sadržaja, navigaciju kroz objekte učenja, pristup zadacima i povezivanje sa eksternim alatima za automatsku proveru rešenja. Aktivnosti studenata i rezultati rada evidentiraju se radi naknadne analize studentskih putanja i korišćenja nastavnih materijala, čime se nastavniku obezbeđuju podaci koji mogu poslužiti kao osnova za razmatranje izmena sadržaja i ontološke strukture. Na taj način MCMLEC pruža tehničku i funkcionalnu podršku fleksibilnijem pristupu nastavnim materijalima i analizi interakcija studenata, dok se efekti OBSLO okruženja na uspešnost i percepciju korisnika razmatraju zasebno u empirijskoj evaluaciji prikazanoj u Poglavlju 7.

5.2.1.2. Primer vizualizacije ontologije za oblast *Upravljanje informacijama*, primenjenim na predmetu Baze podataka

Za potrebe prikaza načina rada OBSLO sistema korišćena je ontologija za predmet Baze podataka, zasnovana na *IEEE Computer Society's Information Technology 2008 Curriculum Guidelines for Undergraduate Degree Programs* [267,268]. Ovaj kurikulum je odabran zbog svoje stabilne i hijerarhijske strukture, koja odgovara načinu organizacije znanja u OBSLO sistemu. Njegova modularnost i jasno definisani domeni omogućavaju precizno modeliranje obrazovnih sadržaja i njihovu lakoću integracije u ontološki okvir sistema. Njegova organizacija ostaje relevantna jer pokriva fundamentalne koncepte na način koji je kompatibilan sa savremenim obrazovnim i tehnološkim pristupima. Predmet Baze podataka pripada oblasti znanja Upravljanje informacijama (Information Management - IM), koja se bavi organizacijom, skladištenjem, pretraživanjem i manipulacijom podacima u informacionim sistemima. Ova oblast obuhvata različite jedinice znanja koje se odnose na upravljanje podacima, modeliranje baza podataka, upitne jezike i druge ključne koncepte iz oblasti informacionih sistema. U okviru ove oblasti, jedinice znanja su definisane na osnovu njihovih međusobnih odnosa, pri čemu su povezani osnovni i napredni koncepti. Na Slici 13 prikazana je struktura jedinica znanja iz oblasti Upravljanje informacijama, prilagođena predmetu Baze podataka.

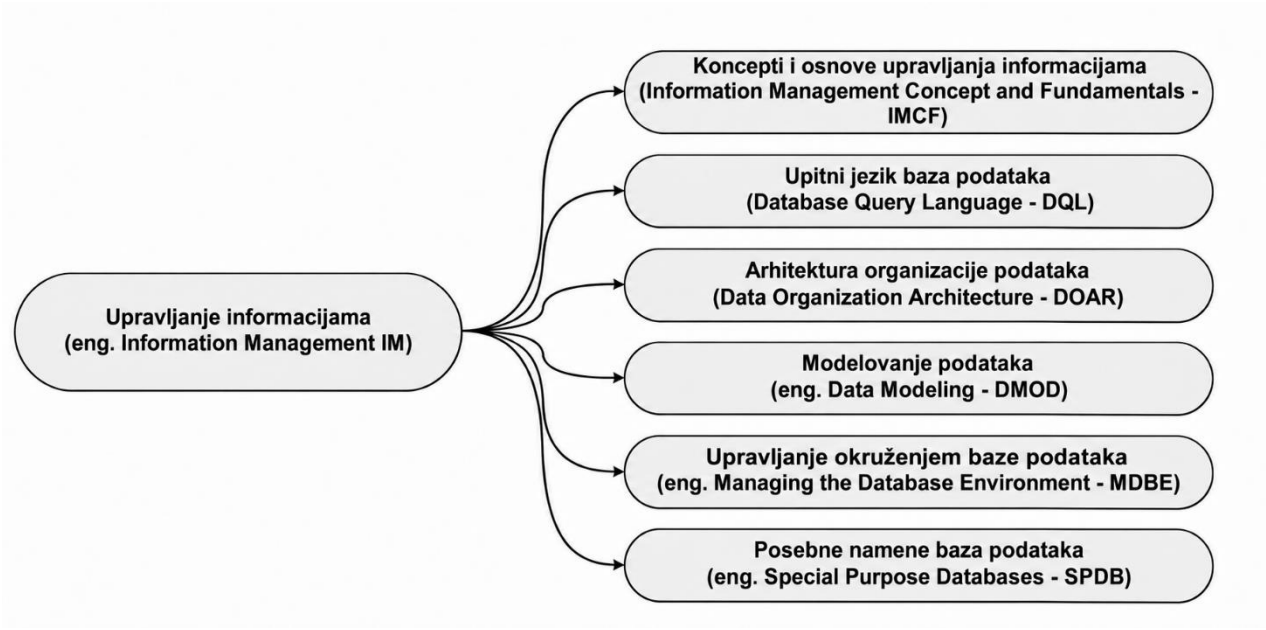

Slika 13. Ključni koncepti za oblast znanja *Upravljanje informacijama*.

Jedan od ključnih koncepata u predmetu Baze podataka je upitni jezik baza podataka (engl. Database Query Language (DQL)), koji omogućava korisnicima da efikasno pretražuju i manipulišu podacima u relacionim bazama. Ova jedinica znanja je podeljena na osnovne i napredne koncepte, pri čemu osnovni koncepti pokrivaju jednostavne *SELECT* naredbe i *WHERE* klauzule, dok napredni koncepti uključuju složenije tehnike pretrage, poput ugnežđenih upita, agregatnih funkcija i naprednih filtera podataka. Slika 14 prikazuje kako se atributi „nivoa znanja na nivou koncepata“ koriste za kreiranje različitih dimenzija, koje će kasnije koristiti multidimenzionalne konceptualne mape (MCM). Ovaj model omogućava studentima da odaberu način na koji žele da istražuju sadržaj, bilo tako što će početi od osnovnih koncepata ili odmah preći na napredne teme.

Na primer, student koji je stekao osnovno znanje o korišćenju klauzule *WHERE* u *SELECT* naredbi, može da istraži kako se složeniji uslovi mogu definisati u jeziku *Query by Example* (QBE). Ovaj pristup omogućava postepeno usvajanje znanja kroz strukturirani model, gde studenti mogu prvo savladati osnovne tehnike pretrage podataka, a zatim ih nadograditi naprednim konceptima.

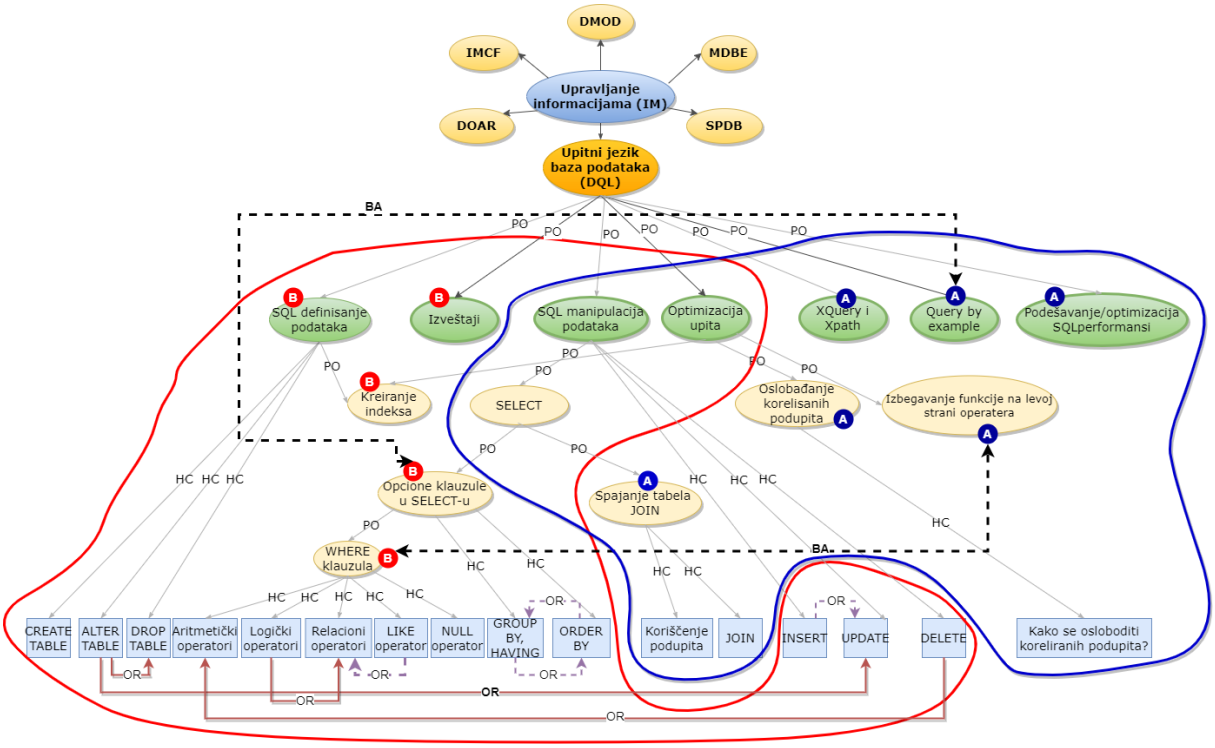

Slika 14. Ontologija za jedinicu znanja Upitni jezik baza podataka (DQL).

OBSLO omogućava dinamičko kreiranje personalizovanog okruženja za učenje, prilagođavajući sadržaj potrebama i prethodnim znanjima studenata. Ključne prednosti ovakvog pristupa uključuju:

1. Fleksibilnost u učenju - studenti mogu da istražuju gradivo sopstvenim tempom i prilagođavaju dinamiku učenja svojim potrebama.
2. Vizualizacija nastavnih sadržaja kroz MCM - studenti imaju mogućnost da vide strukturu i povezane teme kroz multidimenzionalne konceptualne mape.
3. Modularizacija nastavnih materijala - svi nastavni sadržaji su organizovani u manje jedinice, što omogućava lakšu pretragu i selektivno usvajanje znanja.

Koristeći ontološki model prikazan na Slici 14, OBSLO može automatski generisati multidimenzionalne konceptualne mape (MCM), omogućavajući studentima intuitivnu navigaciju kroz gradivo.

Na Slici 15 prikazan je ontološki model za jedinicu znanja *Upitni jezik baza podataka* (DQL), gde su koncepti sa sličnim nivoima znanja grupisani zajedno. U ovom prikazu, osnovni koncepti su obeleženi unutar crvenog pravougaonika, dok napredni koncepti pripadaju plavom pravougaoniku (prikazano na Slici 16).

Dodatno, koncepti koji se nalaze na granici između osnovnih i naprednih tema predstavljeni su u oba podstabla nivoa znanja, omogućavajući studentima fleksibilnost u istraživanju i prelasku sa jednog nivoa na drugi u skladu sa njihovim potrebama i interesovanjima.

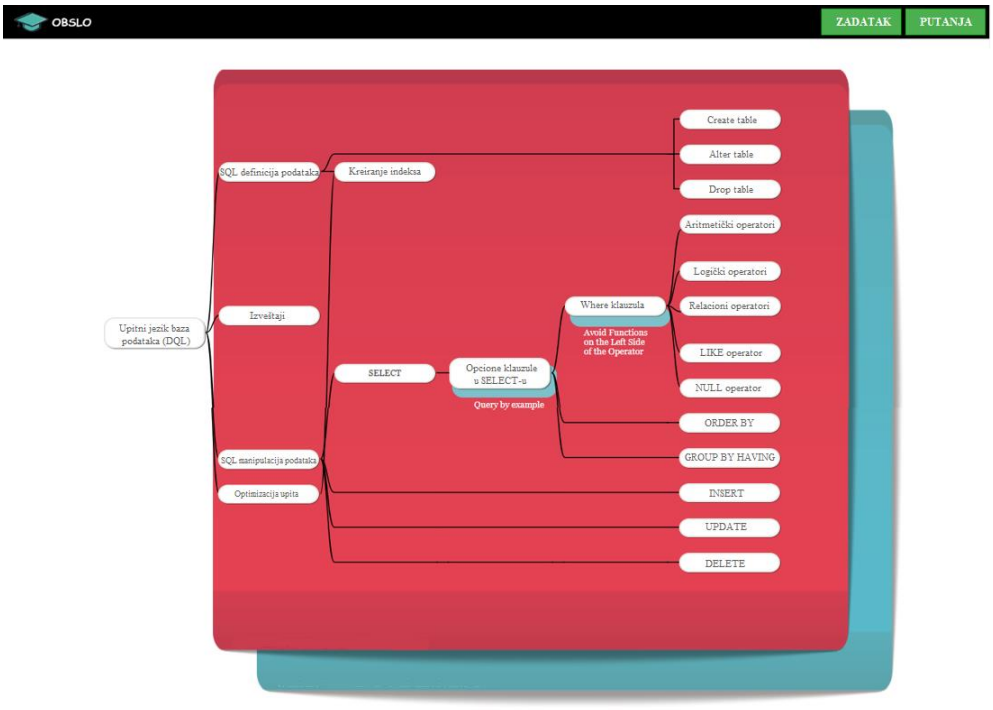

Slika 15. OBSLO MCM vizualizacija osnovnog nivoa znanja.

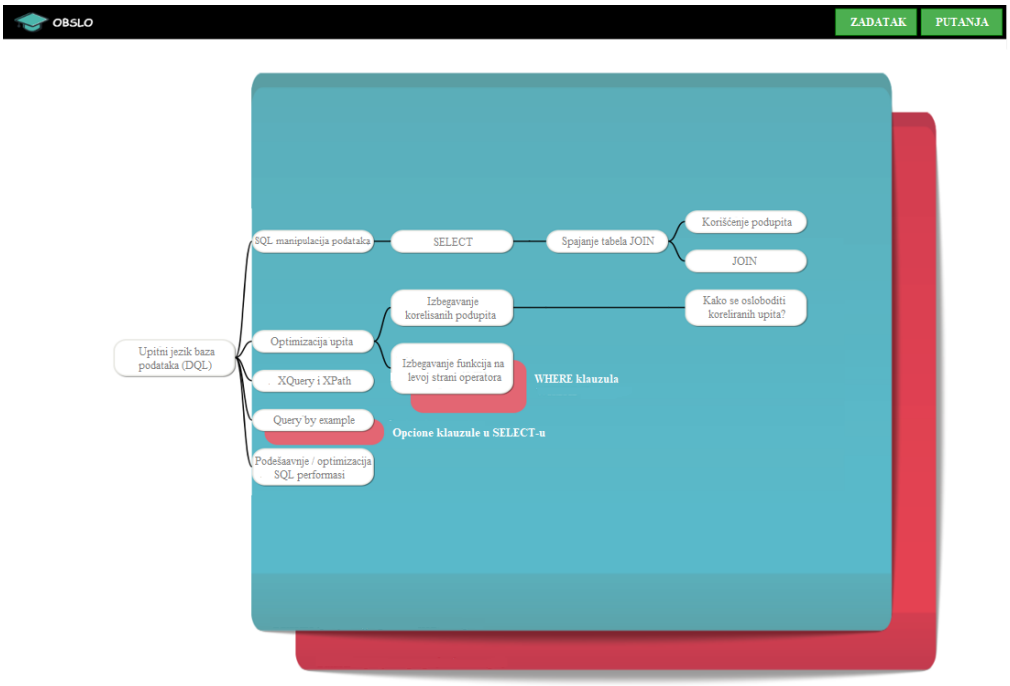

Slika 16. OBSLO MCM vizualizacija naprednog nivoa znanja.

Jedna od glavnih prednosti OBSLO sistema je njegova sposobnost dinamičke vizualizacije nastavnih materijala, omogućavajući studentima intuitivno istraživanje sadržaja putem konceptualnih mapa.

Studenti mogu da navigiraju kroz MCM sve dok ne pronađu sve potrebne objekte učenja (OU) koji im omogućavaju savladavanje gradiva. Nakon što student odabere određeni koncept, sistem automatski generiše relevantne nastavne materijale i povezuje ih sa odabranom temom. Na Slici 17 prikazan je primer prikaza sadržaja OU-a u OBSLO sistemu. Ovaj prikaz omogućava studentima da:

1. Vide teorijski deo gradiva sa osnovnim objašnjenjima i definicijama.
2. Pregledaju primer koda ili upita koji ilustruje praktičnu primenu koncepta.
3. Pristupe interaktivnim zadacima koji im omogućavaju da odmah testiraju naučeno kroz praktične primere.

Ovakav model omogućava studentima progresivnu navigaciju kroz osnovne i napredne sadržaje i pristup povezanim objektima učenja. Ovakav način rada pretpostavlja da je student motivisan da samostalno istražuje nastavni sadržaj. Za studente koji to ne čine osnovni tok predmeta i dalje ostaje dostupan kroz redosled lekcija, dok OBSLO predstavlja dopunski način pristupa sadržaju, prvenstveno za samostalnu pripremu pre nastave uživo. U kojoj meri su studenti spremni na takvu samostalnu pripremu, kao preduslov za primenu aktivne i interaktivne nastave na časovima, predstavlja pitanje za dalja istraživanja.

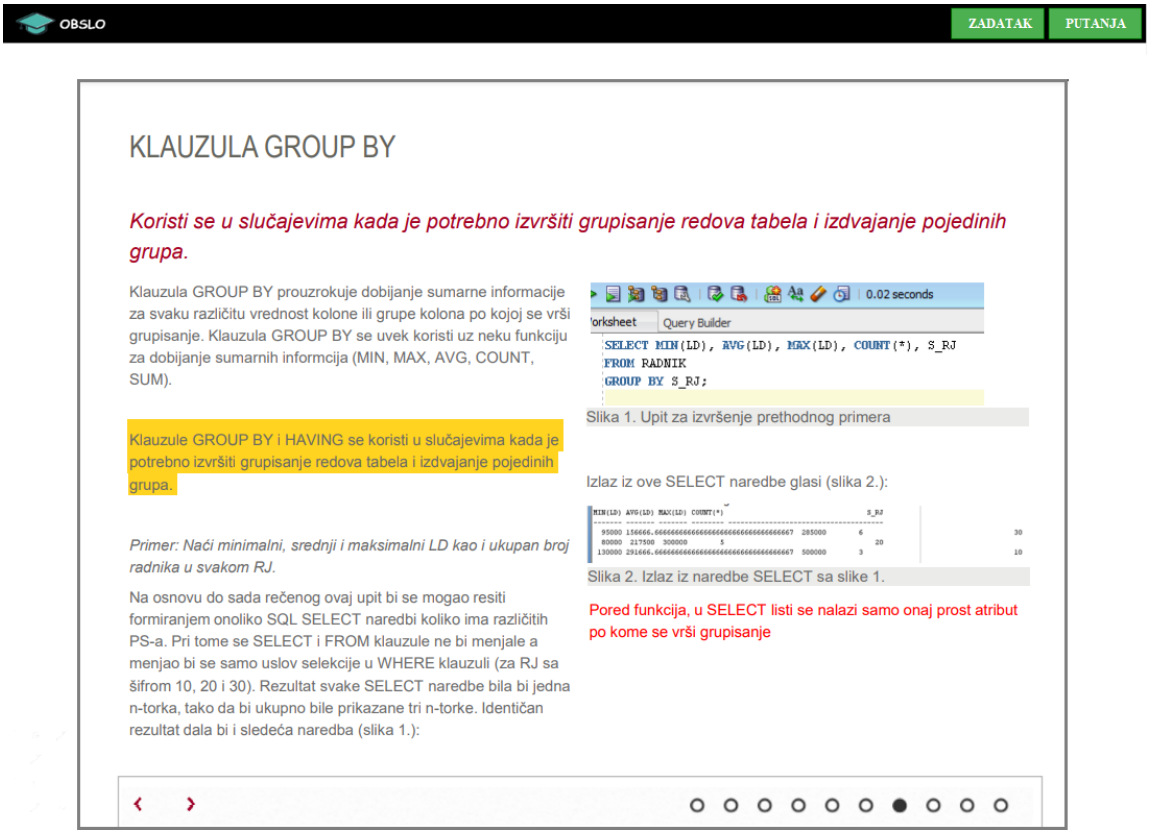

Slika 17. Prikaz OU „*Group By" klauzula.*

5.3. Proširenje ontološkog modela kompetencijskim okvirom

Ranije uvedeni atribut nivoa sadržaja, predstavljen kategorijama osnovni, srednji i napredni, u ovom odeljku usklađuje se sa formalnim nivoima dubine N1, N2 i N3 preuzetim iz usvojenog kompetencijskog okvira [15]. Ovako formalizovan model predstavlja osnovu za njegovu kasniju primenu i empirijsku proveru u okviru modela studenta prikazanog u poglavljima 6 i 7. Isti okvir [15] kompetencijski prostor ne opisuje samo kroz dubinu (N1/N2/N3), već i kroz širinu, odnosno obuhvat tema kroz koje se određena kompetencija razvija. U ontološkom modelu predloženom u ovoj disertaciji širina nije uvedena kao poseban numerički atribut, već proizlazi iz skupa tema, koncepata i objekata učenja povezanih sa datom kompetencijom. Dubina je, nasuprot tome, eksplicitno predstavljena oznakom nivoa N1, N2 ili N3. U skladu sa teorijskim okvirom iz odeljka 4.3.1, ovi nivoi ne predstavljaju samo različitu količinu sadržaja, već rastući dominantni kognitivni zahtev u smislu revidirane Bloomove taksonomije [245]: N1 predstavlja osnovno i obavezno jezgro, N2 produbljenu primenu i analizu, dok N3 predstavlja napredno ovladavanje sa naglašenim višim kognitivnim zahtevima. Na taj način ontološka struktura istovremeno omogućava predstavljanje obuhvata kompetencije kroz širinu povezanog sadržaja i nivoa njenog razvoja kroz dubinu.

Ontološki model prikazan u odeljku 5.1, hijerarhija Znanje domena / Oblast znanja / Jedinica znanja / Tema / Podtema, sa relacijama PO, HC, OR, HR i BA (Slika 6), objavljen je u [14] kao samostalan model za organizaciju i vizualizaciju objekata učenja putem multidimenzionalnih konceptualnih mapa (MCM). U tom, objavljenom obliku, model odgovara na pitanje *šta* je nastavni sadržaj i *kako* je strukturiran, ali ne sadrži eksplicitnu vezu sa kompetencijama koje taj sadržaj razvija, ni sa dubinom na kojoj se razvijaju.

Ovaj model, međutim, prirodno može biti proširen dimenzijom kompetencija. Za tu dimenziju u ovom radu je usvojen kompetencijski okvir razvijen na Univerzitetu Metropolitan [15] (detaljno izložen u odeljku 4.3.1), koji definiše kaskadno mapiranje ciljeva, ishoda učenja i kompetencija, od referentnog korpusa znanja discipline (BOK), preko kurikuluma i predmeta, do lekcije (Slika 18) i tri nivoa dubine kompetencija po jedinici nastavnog sadržaja: N1 (osnovni nivo), N2 (srednji nivo) i N3 (napredni nivo) [15,245]. Nivoi predstavljaju progresiju dubine razvoja kompetencije i rastuće kognitivne zahteve, ali se ne tumače kao strogo preSlikavanje pojedinačnih kategorija revidirane Bloomove taksonomije. Nastavni status povezanog sadržaja definiše se odvojeno: N1 predstavlja obavezno zajedničko jezgro, N2 dodatni sadržaj koji nadograđuje jezgro i omogućava dublji razvoj znanja i veština, dok N3 predstavlja opcioni napredni sadržaj najveće dubine. Na taj način oznaka nivoa dubine i status sadržaja predstavljaju povezane, ali konceptualno različite karakteristike: nivo N1-N3 opisuje dubinu razvoja kompetencije, dok obavezni, dodatni ili opcioni status opisuje ulogu konkretnog sadržaja u nastavnom dizajnu. Iz istog okvira usvojena je i ideja da svaki OU nosi eksplicitne pokazatelje ishoda i kompetencija: ishod učenja (LOUT), kompetenciju (COMP), znanje (KNOW) i veštinu (SKILL), organizovane po nivou dubine (Slika 19). Razdvajanje elemenata KNOW i SKILL omogućava da ista kompetencija ne bude predstavljena samo posedovanjem teorijskog znanja, već i sposobnošću njegove praktične primene [15]. Ovo je posebno važno za predmete koji kombinuju konceptualne i praktične aktivnosti, jer se dokaz o poznavanju određenog pojma i dokaz o sposobnosti njegove primene ne moraju dobijati istom vrstom provere. Zbog toga se u nastavku modela različite aktivnosti provere mogu povezivati sa komponentom znanja, komponentom veštine ili sa obe komponente, u zavisnosti od toga šta konkretna aktivnost proverava.

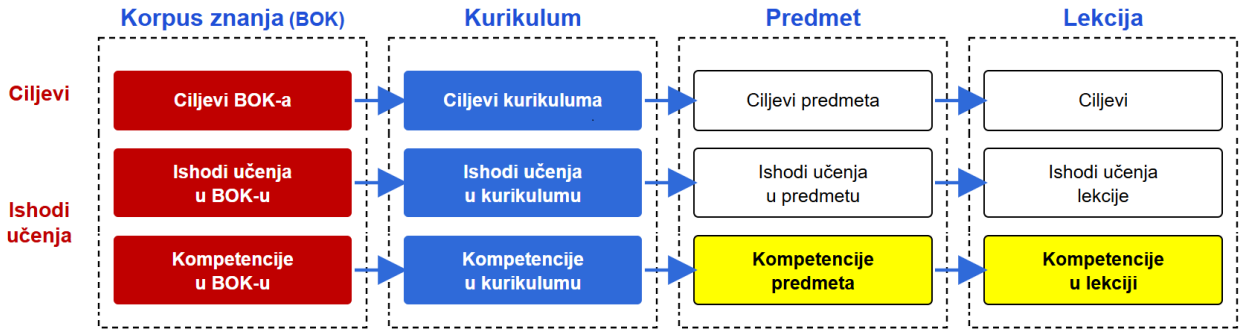

Slika 18. Mapiranje ciljeva, ishoda učenja i kompetencija od referentnog korpusa znanja do kurikuluma, predmeta i lekcije. Prilagođeno iz [15].

U ontološkom modelu ovog rada ova kaskada nije samo teorijska šema. Referentni korpus znanja i odgovarajući referentni kurikulum obezbeđuju šire kompetencije i ishode koje obrazovni program treba da razvija, dok se na nivou konkretnog predmeta one operacionalizuju kroz finije definisane kompetencije predmeta. Ovu razliku je potrebno eksplicitno napraviti, jer šira kompetencija definisana referentnim kurikulumom može obuhvatati više tema i nastavnih jedinica i zato je suviše gruba za fino praćenje napretka pojedinačnog studenta. Kompetencije predmeta predstavljaju njenu konkretniju dekompoziciju u odnosu na sadržaj, ishode i aktivnosti određenog predmeta [15]. Na nivou predmeta objekti učenja povezuju se sa odgovarajućim ishodima i kompetencijama predmeta, čime BOK-kurikulum-predmet-teme kaskada postaje operativni deo strukture podataka koju kasnije koristi model studenta.

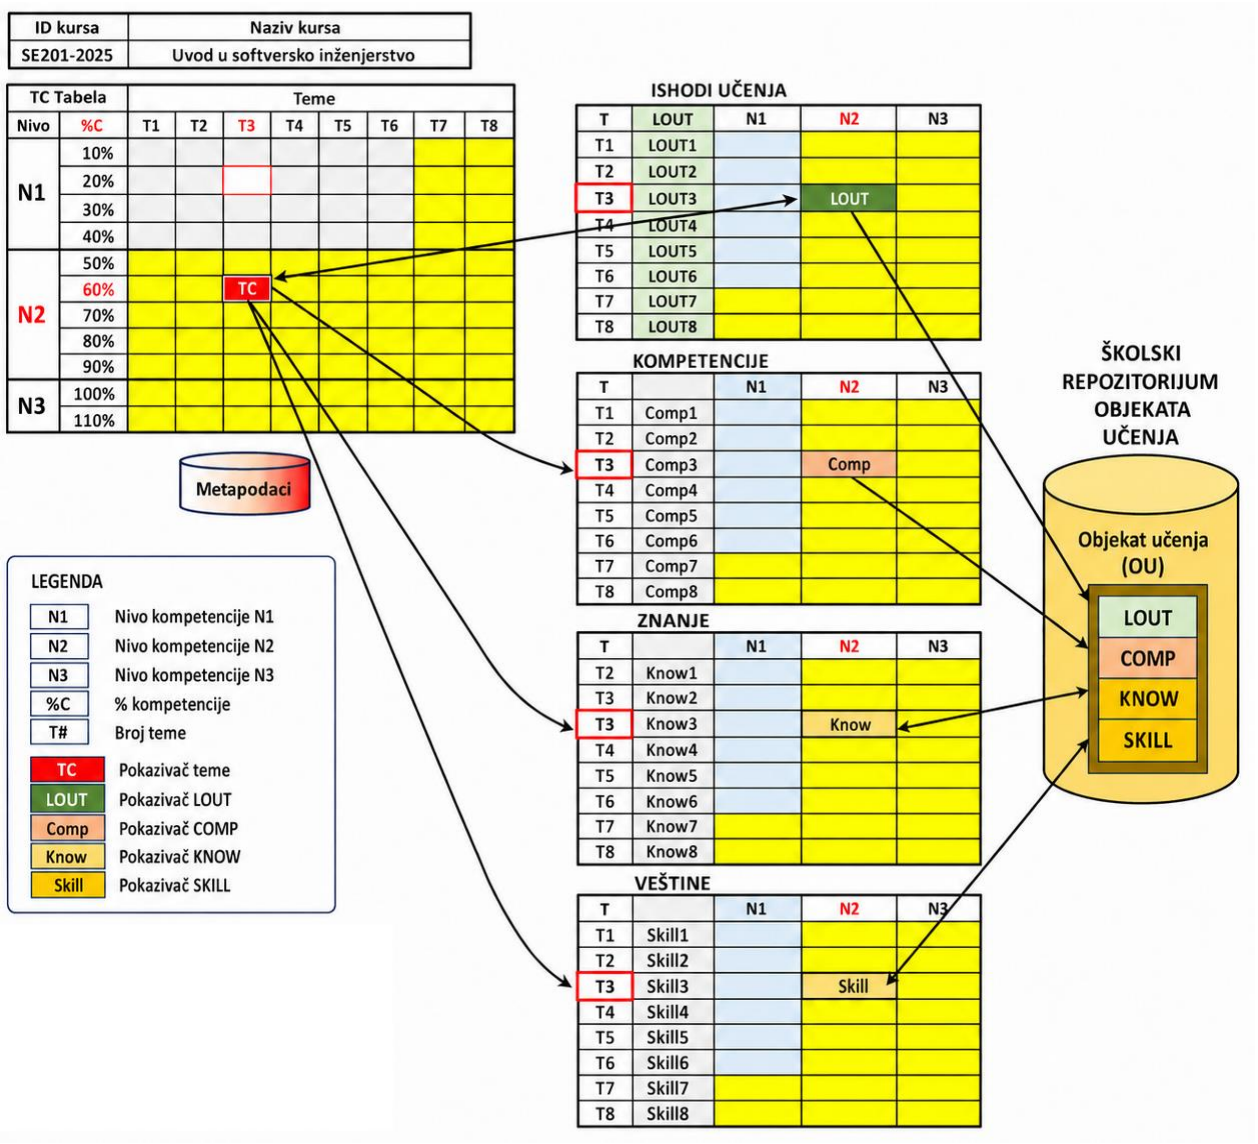

Slika 19. Struktura metapodataka objekta učenja u usvojenom kompetencijskom okviru: ishod učenja (LOUT), kompetencija (COMP), znanje (KNOW) i veština (SKILL), organizovani prema nivoima dubine N1, N2 i N3. Preuzeto iz [15].

Nivo N1 predstavlja zajedničko obavezno jezgro koje svi studenti treba da savladaju, dok se sadržaji i kompetencije zastupljeni na nivoima N2 i N3 mogu razlikovati između studenata u skladu sa njihovim izborima, postignućima i individualnim potrebama za daljim razvojem kompetencija (odeljak 4.3.1). Slika 20 ilustruje ovu razliku na primeru dva hipotetička studenta koji ostvaruju zajedničko obavezno jezgro N1, ali se razlikuju prema tome koje su kompetencije i sadržaji viših nivoa zastupljeni u njihovim profilima i u kojoj meri su njima ovladali.

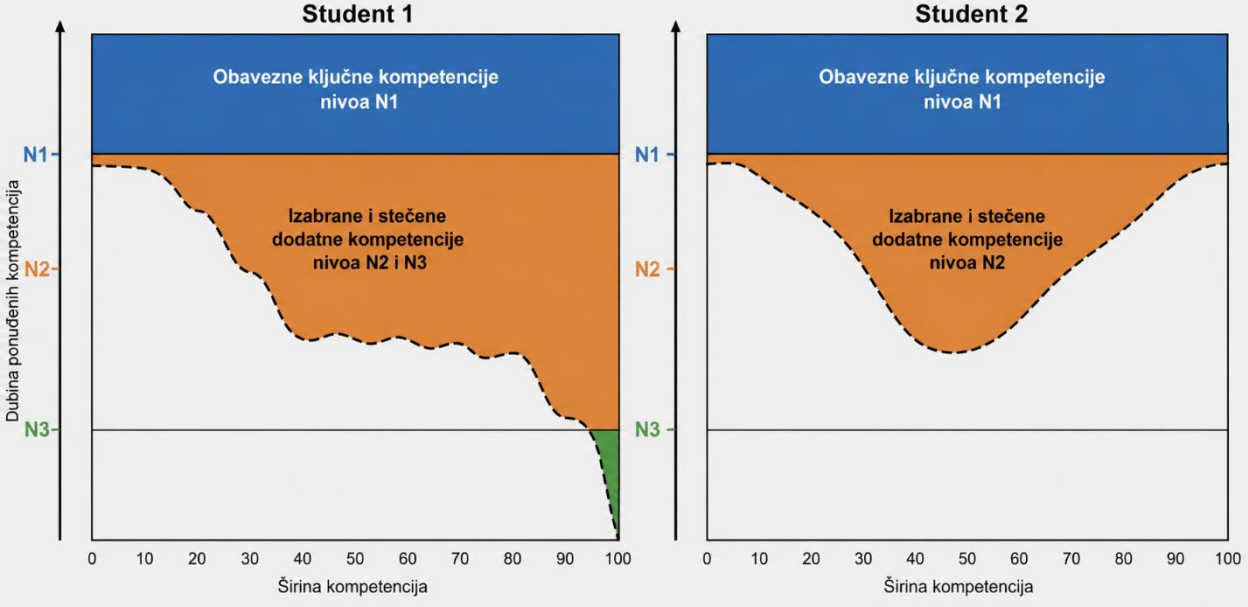

Slika 20. Primer profila kompetencija dva studenta: nivo N1 predstavlja zajedničko obavezno jezgro, dok se kompetencijski profili na nivoima N2 i N3 mogu razlikovati prema obimu i dubini. Prilagođeno iz [15].

Integracija ontologije objekata učenja iz [14] i kompetencijskog okvira iz [15] predstavlja osnovu proširenog modela nastavnog sadržaja razvijenog u ovoj disertaciji. Kao što je prikazano na Slici 21, postojeća hijerarhija koncepata, kurikulum, oblast znanja, jedinica znanja, tema i podtema, proširena je vezama prema kompetencijama i ishodima učenja. Pri tome su očuvane postojeće ontološke relacije između koncepata i objekata učenja, uključujući relaciju osnovni/napredni (B/A), dok je svakom objektu učenja pridružen nivo dubine N1, N2 ili N3. Relaciju B/A i nivo dubine potrebno je pojmovno razlikovati: relacija B/A povezuje dva različita koncepta, od kojih jedan predstavlja osnovu za drugi, dok nivo N1, N2 ili N3 označava dubinu na kojoj se isti koncept izučava.

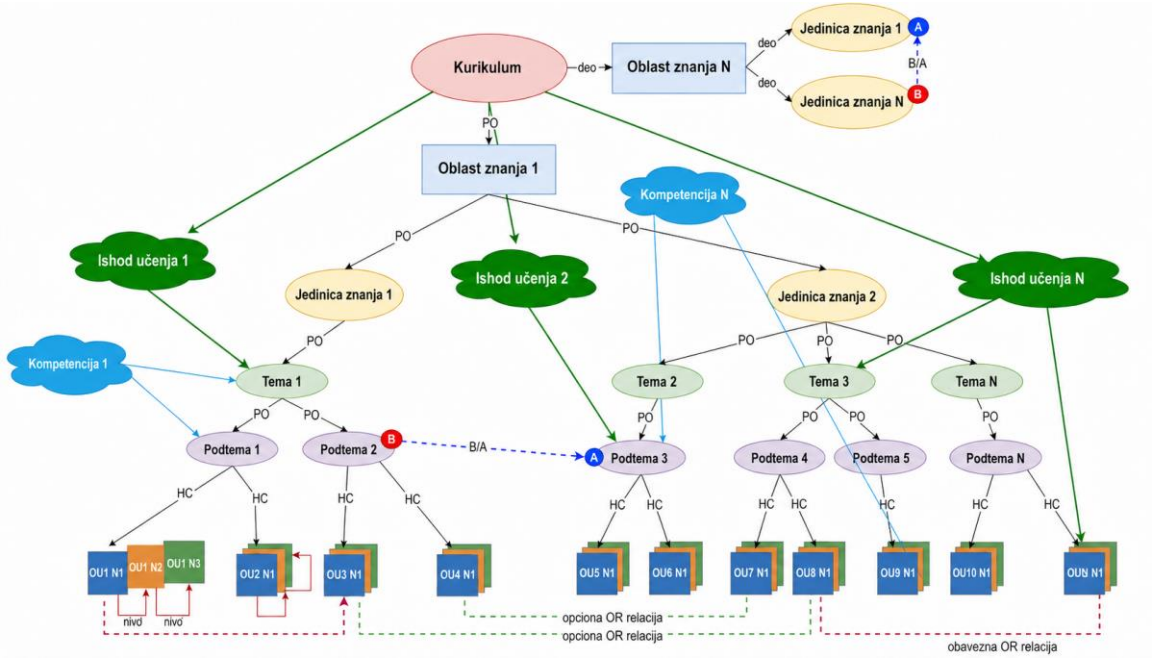

Slika 21. Ontološki model iz [14], proširen kompetencijama i ishodima učenja prema okviru iz [15].

U integrisanom modelu svaki objekat učenja povezan je sa pet elemenata: ishodom učenja (LOUT), kompetencijom (COMP), znanjem (KNOW), veštinom (SKILL) i elementom verifikacije (VERIFY), kao što je prikazano na Slici 22. Element VERIFY preuzet je iz kompetencijski vođenog okvira iz [15], u kojem predstavlja način verifikacije onoga što je student naučio. U integrisanom modelu razvijenom u ovoj disertaciji njegova uloga je dodatno semantički precizirana: VERIFY ne predstavlja posebnu komponentu sistema za proveru znanja niti sam dokaz ovladanosti, već semantičku vezu između objekta učenja i dokaza o učenju koji nastaje u odgovarajućoj aktivnosti provere. Sama aktivnost provere, pokušaji studenta i ostvareni rezultati vode se u sistemu za upravljanje obrazovanjem (EMS), dok VERIFY u ontološkom modelu određuje na koji objekat učenja, ishod, kompetenciju i nivo dubine se odgovarajući dokaz odnosi. Na taj način rezultat testa, pojedinačnog pitanja, ocenjenog zadatka, projekta ili druge aktivnosti može biti interpretiran kao strukturirani dokaz o učenju, umesto samo kao izolovana brojčana vrednost. Konkretni postupak mapiranja aktivnosti provere na objekte učenja i njihova upotreba u modelu studenta detaljno su prikazani u odeljku 6.5.1. Ovakva veza omogućava da dokaz o učenju postoji na različitim nivoima granularnosti. Pojedinačno pitanje može pružiti fino granularan dokaz vezan za jedan objekat učenja, dok test, ocenjeni zadatak ili projekat može obuhvatiti više objekata učenja i time pružiti širi dokaz o pripadajućem ishodu ili kompetenciji. Zato granica između modela nastavnog sadržaja i modela studenta nije određena vrstom aktivnosti, već njenim eksplicitnim mapiranjem na semantičke elemente sadržaja. Model nastavnog sadržaja određuje na šta se

dokaz odnosi, dok model studenta određuje kako se niz takvih dokaza koristi za procenu trenutnog stanja pojedinačnog studenta.

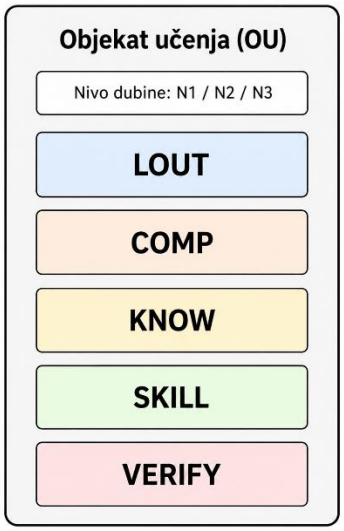

Slika 22. Struktura objekta učenja u spojenom modelu: nivo dubine (N1/N2/N3) i pet elemenata - LOUT, COMP, KNOW, SKILL, VERIFY.

Snaga ovako spojenog modela je u tome što se struktura sadržaja (odakle potiče koncept, čime je pokriven, koji su mu preduslovi) i struktura kompetencija (šta se njime razvija, na kojoj dubini, kako se to verifikuje) čuvaju u istoj ontologiji, umesto u dva paralelna sistema koje bi tek naknadno trebalo usklađivati. Ovim se izbegava čest problem adaptivnih sistema za učenje da model sadržaja i model kompetencija „žive“ odvojeno, a model studenta (Poglavlje 6) i mehanizam preporuke (Poglavlje 7) mogu se osloniti na jedinstvenu, dosledno povezanu strukturu podataka, umesto na naknadno mapiranje između dva nezavisno vođena modela.

Ontologija OU proširena kompetencijskim okvirom, nivoima dubine N1, N2 i N3 i strukturom OU-a od pet elemenata: LOUT, COMP, KNOW, SKILL i VERIFY, predstavlja konačni oblik modela nastavnog sadržaja usvojenog u ovoj disertaciji za povezivanje sa modelom studenta. Osnovna ontološka struktura iz odeljaka 5.1 i 5.2, koja obuhvata hijerarhiju koncepata, relacije PO, HC, OR, HR i BA i vizuelizaciju pomoću multidimenzionalnih konceptualnih mapa, ostaje očuvana. Njena upotrebljivost i mogućnost podrške navigaciji kroz nastavne sadržaje evaluirane su na predmetu Baze podataka, kao što je prikazano u Poglavlju 7.1.

Kompetencijsko proširenje modela nije evaluirano samo kroz preglednost i upotrebljivost korisničkog interfejsa, jer njegova primarna svrha nije vizuelna navigacija kroz sadržaj, već

povezivanje nastavnog sadržaja sa dokazima iz aktivnosti provere znanja studenata. Ono se zato evaluira kroz mogućnost modela studenta da, na osnovu stvarnih podataka sa predmeta SE201 i CS202, proceni ovladanost pojedinačnim kompetencijama, razlikuje nivoe dubine N1, N2 i N3, ali i poveže identifikovane potrebe za podrškom sa odgovarajućim objektima učenja. Rezultati ove evaluacije predstavljeni su u odeljku 7.2.3. Na taj način osnovni i kompetencijski prošireni oblik modela nastavnog sadržaja evaluirani su komplementarnim metodama, u skladu sa različitim istraživačkim tvrdnjama koje treba da potvrde.

Kompetencijski proširen ontološki model na taj način obezbeđuje semantički lanac potreban za razvoj modela studenta:

objekat učenja → ishod učenja → kompetencija predmeta → KNOW/SKILL → nivo dubine → VERIFY → dokaz iz aktivnosti studenta.

Ovaj lanac omogućava da se procena stanja studenta ne formira nezavisno od nastavnog sadržaja. Svaka opservacija koja ulazi u model studenta može se povezati sa sadržajem čije je ovladavanje proveravano, kompetencijom koju taj sadržaj razvija i nivoom dubine na kojem je aktivnost realizovana. Zato kombinacija predmet-kompetencija predmeta-nivo dubine, koja se u Poglavlju 6 koristi kao osnovna jedinica sekvencijalne procene ovladanosti, neposredno proizlazi iz ovde definisane strukture modela nastavnog sadržaja. Istovremeno, zadržavanje veze prema pojedinačnom objektu učenja omogućava da se šira procena ovladanosti kompetencijom kasnije dopuni fino granularnom identifikacijom konkretnih slabih tačaka.

Poglavlje 6

6. Model studenta

6.1. Definicija i značaj modela studenta

Model studenta predstavlja formalizovanu reprezentaciju podataka i procena o pojedinačnom studentu koje su relevantne za praćenje, razumevanje i podršku procesu učenja. Formira se na osnovu podataka o studentskim aktivnostima, rezultatima provera znanja, interakcijama sa nastavnim sadržajem i drugim pokazateljima koji nastaju u sistemima za e-učenje. Njegova osnovna uloga jeste da raspoložive podatke transformiše u informacije koje omogućavaju sagledavanje trenutnog stanja i napretka studenta. U tradicionalnim obrazovnim sistemima procena studentskog napretka često se zasniva na agregiranim pokazateljima, kao što su ukupan broj osvojenih poena, prosečna ocena ili broj izvršenih aktivnosti. Iako takvi pokazatelji pružaju opštu informaciju o uspehu, oni ne omogućavaju dovoljno precizno utvrđivanje toga u kojoj meri raspoloživi podaci ukazuju na ovladanost pojedinim nastavnim sadržajima, u kojim delovima gradiva postoje teškoće i koja vrsta podrške mu je potrebna. Studenti sa sličnim ukupnim rezultatom mogu imati različite nivoe ovladanosti pojedinim delovima nastavnog sadržaja, različit obim izvršenih aktivnosti i različite načine angažovanja tokom učenja. Zbog toga se model studenta u ovoj disertaciji ne posmatra kao statičan profil zasnovan na trajnim karakteristikama studenta, već kao dinamička reprezentacija njegovog stanja tokom procesa učenja. Model se menja sa pojavom novih podataka o aktivnostima i rezultatima, čime se omogućava praćenje napretka i uočavanje promena koje ne bi bile vidljive na osnovu samo jednog završnog pokazatelja uspeha.

Važno svojstvo modela studenta jeste interpretabilnost. U obrazovnom kontekstu nije dovoljno dobiti samo procenu uspeha ili klasifikaciju studenta. Potrebno je omogućiti razumevanje podataka i pokazatelja na osnovu kojih je određena procena formirana. Interpretabilan model omogućava nastavniku da sagleda razloge za uočene teškoće, dok studentu pruža jasniju informaciju o sopstvenom napretku i oblastima u kojima je potreban dodatni rad. Model studenta predstavlja jednu od osnovnih komponenti personalizovanih i

adaptivnih sistema za e-učenje. Njegova funkcija nije neposredno određivanje nastavnih materijala koje student mora da koristi, već obezbeđivanje procene stanja studenta koja može biti upotrebljena kao osnova za dalju adaptaciju. Izbor, uređivanje i objašnjavanje preporučenih nastavnih sadržaja pripadaju adaptivnom modelu, koji izlaze modela studenta povezuje sa strukturom nastavnog sadržaja. Da bi takvo povezivanje bilo moguće, podaci o studentu ne mogu se posmatrati nezavisno od sadržaja na koji se odnose. Rezultat na određenoj aktivnosti ima puno značenje tek kada je poznato koje znanje, veštinu, ishod učenja, kompetenciju ili objekat učenja ta aktivnost proverava. Zbog toga je model studenta u predloženom pristupu povezan sa ontološkim modelom nastavnog sadržaja opisanim u prethodnom poglavlju.

Značaj modela studenta ogleda se u tome što omogućava prelazak sa opšteg prikaza studentskog uspeha na detaljnije, dinamičko i objašnjivo sagledavanje procesa učenja. Takav model pruža osnovu za identifikovanje potreba pojedinačnog studenta, povezivanje dokaza o učenju sa konkretnim nastavnim sadržajem i formiranje personalizovane podrške za dalje učenje.

6.2. Tehnike modelovanja studenata

Modelovanje studenata u okviru ovog istraživanja razvijano je kroz više uzastopnih faza, od inicijalne analize obrazovnih podataka i predikcije akademskog uspeha, preko identifikacije obrazaca studentskog angažovanja, do razvoja konačnog višeslojnog modela studenta. Svaka faza imala je poseban istraživački cilj i omogućila je da se identifikuju mogućnosti, ali i ograničenja prethodnog pristupa. Konačna faza zato ne predstavlja samo složeniji prediktivni model, već integriše sekvencijalnu procenu ovladanosti kompetencijama, odvojenu procenu ostvarenosti aktivnosti po nivoima dubine i ponašajno profilisanje studenata, čime se stanje studenta sagledava kroz više međusobno povezanih, ali konceptualno različitih dimenzija.

U prvoj fazi ispitana je mogućnost predikcije akademskog uspeha na osnovu istorijskih podataka o studentskim aktivnostima i postignućima, sa ciljem identifikovanja obrazaca povezanih sa konačnim ishodom studenta na predmetu i ispitivanja mogućnosti klasifikacije studenata prema uspešnosti. U drugoj fazi fokus je pomeren sa predikcije ishoda na analizu načina angažovanja, pri čemu je klasterovanje korišćeno za identifikovanje grupa studenata sa sličnim obrascima aktivnosti i za ispitivanje značaja granularnosti podataka o učenju. Nalazi i ograničenja ove dve faze predstavljali su osnovu za završnu fazu istraživanja, u kojoj je razvijen višeslojni model studenta. U njemu se hronološki uređeni dokazi iz aktivnosti provere koriste za sekvencijalnu procenu ovladanosti pomoću BKT-a, ostvarivanje propisanih

aktivnosti posmatra se kao posebna dimenzija ostvarenosti nivoa, dok se obrazac angažovanja modeluje odvojeno kroz ponašajne tipove studenata. Izlazi ovih slojeva zatim se povezuju sa ontološki organizovanim nastavnim sadržajem radi identifikovanja potreba za podrškom i formiranja personalizovanih preporuka.

Ovo poglavlje objašnjava razvoj modela studenta kroz sledeće faze:

- **Faza 1: Predikcija studentskog uspeha pomoću mašinskog učenja prema uspešnosti na ispitu** (kategorije *pass* i *fail*), sa ciljem ispitivanja mogućnosti klasifikacije konačnog ishoda na osnovu istorijskih podataka o aktivnostima i postignućima studenata.
- **Faza 2: Analiza obrazaca studentskog angažovanja primenom klasterovanja** na podacima iz dve visokoškolske institucije, sa posebnim osvrtom na granularnost praćenja aktivnosti i razlikovanje obrazaca načina rada studenata.
- **Faza 3: Razvoj konačnog višeslojnog modela studenta** koji integriše sekvencijalnu procenu ovladanosti kompetencijama pomoću BKT-a, odvojenu procenu ostvarenosti aktivnosti po nivoima dubine i identifikovanje ponašajnih tipova, a čiji se izlazi koriste za formiranje objašnjivih adaptivnih preporuka u vezi sa konkretnim objektima učenja.

U narednim potpoglavljima detaljno su opisane navedene faze i ključni nalazi svake od njih.

6.3. Faza 1: Predikcija studentskog uspeha pomoću mašinskog učenja

U početnoj fazi istraživanja modela studenata ispitana je mogućnost klasifikacije konačnog ishoda studenta na predmetu primenom metoda mašinskog učenja. Ova faza bila je usmerena na analizu obrazaca u istorijskim studentskim podacima, ispitivanje povezanosti raspoloživih atributa aktivnosti i postignuća sa konačnim ishodom i razvoj prvog prediktivnog modela [184]. Fokus istraživanja bio je na prikupljanju i obradi istorijskih podataka studenata, primeni različitih algoritama mašinskog učenja i evaluaciji njihove sposobnosti da klasifikuju studente prema konačnom ishodu na predmetu. Ovaj deo istraživanja temeljio se na analitici obrazovnih podataka (engl. Educational Data Mining (EDM)). Cilj je bio da se:

- ispita mogućnost klasifikacije studenata prema konačnom ishodu na predmetu;
- identifikuju atributi koji su povezani sa konačnim ishodom i mogu doprineti njegovoj klasifikaciji.

Da bi se ovi ciljevi postigli, istraživanje je prošlo kroz tri ključne faze metodološkog okvira prikazanog na Slici 23

- Prikupljanje i integracija podataka - obuhvatalo je sakupljanje studentskih podataka iz više akademskih godina i različitih predmeta.
- Predobrada podataka - uključivala je čišćenje, selekciju i normalizaciju podataka radi poboljšanja tačnosti modela.
- Izgradnja i evaluacija modela - primenjeni su različiti algoritmi mašinskog učenja radi pronalaženja optimalnog modela za klasifikaciju studentskog uspeha.

Podaci korišćeni u ovoj fazi istraživanja prikupljeni su sa Univerziteta Metropolitan u Beogradu iz sistema za upravljanje učenjem (engl. Learning Management System (LMS)) i obrazovnog menadžment sistema (engl. Educational Management System (EMS)). Skup podataka obuhvatao je studente koji su pohađali sledeće predmete u periodu od 2017/18. do 2021/22. školske godine:

- Uvod u objektno orijentisano programiranje
- Objekti i apstrakcija podataka
- Uvod u informacione tehnologije
- Sistemi informacionih tehnologija

Ukupno je analizirano 1696 studentskih zapisa, koji su sadržali sledeće informacije:

- Prosečna ocena iz srednje škole
- Ocene sa testova, domaćih zadataka i projekata
- Ocena zalaganja studenata tokom semestra
- Prisustvo na časovima
- Angažovanost na platformi za e-učenje
- Broj neuspešnih pokušaja polaganja ispita
- Konačna ocena (položio/nije položio)

Da bi se osigurao kvalitet podataka, sprovedeni su sledeći koraci predobrade:

- Čišćenje podataka - uklonjeni su zapisi sa nepotpunim podacima, nelogične vrednosti (npr. negativne ocene) i duplikati.
- Podela skupa podataka - podaci su podeljeni na skup za treniranje, koji je obuhvatao 80% zapisa, i izdvojeni testni skup, koji je obuhvatao preostalih 20% zapisa.

Izdvojeni testni skup nije korišćen tokom treniranja, izbora karakteristika niti podešavanja modela, već isključivo za završnu evaluaciju.

- Normalizacija podataka - parametri min-max skaliranja određeni su na skupu za treniranje, a zatim su iste transformacije primenjene na izdvojeni testni skup.
- Selekcija relevantnih karakteristika - izbor karakteristika sproveden je u okviru postupka izgradnje modela bez korišćenja informacija iz izdvojenog testnog skupa za optimizaciju modela.

Kroz ovu fazu osigurano je da podaci budu konzistentni i relevantni za izgradnju prediktivnog modela.

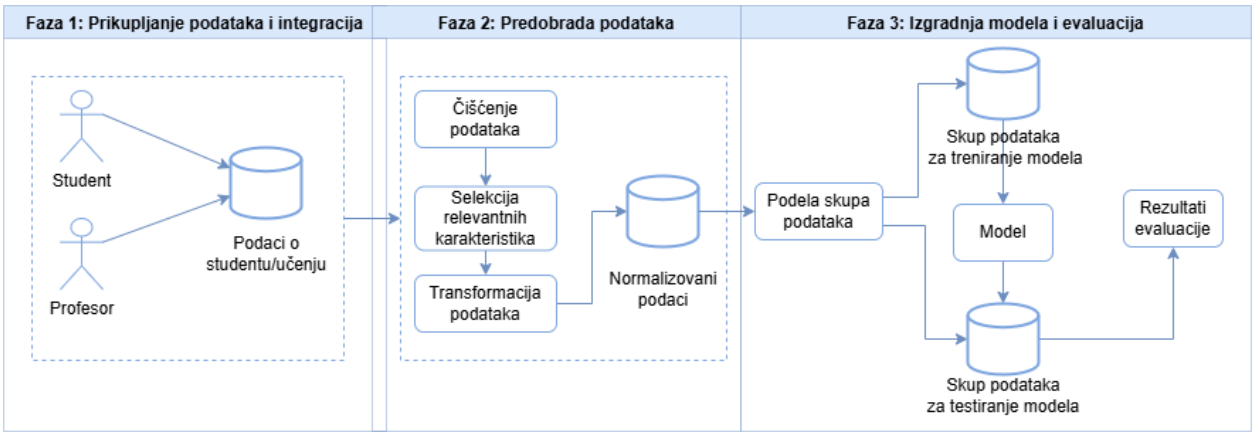

Slika 23. Metodologija istraživanja predikcije studentskog uspeha pomoću algoritama mašinskog učenja.

Nakon predobrade podataka, primenjeni su različiti algoritmi klasifikacije kako bi se pronašao model sa najboljim performansama za predikciju studentskog uspeha. Testirani su sledeći algoritmi:

- Logistička regresija (engl. Logistic Regression (LR)) - koristi se za binarnu klasifikaciju (položio/nije položio) i omogućava interpretabilne rezultate, ali ima ograničenja kod složenijih obrazaca u učenju.
- Linearna diskriminantna analiza (engl. Linear Discriminant Analysis (LDA)) - omogućava razdvajanje uspešnih i neuspešnih studenata na osnovu matematičkih relacija između podataka.
- K-najbliži susedi (engl. K-Nearest Neighbors (KNN)) - klasifikuje studente prema njihovoj sličnosti sa prethodnim primerima iz skupa podataka.
- Stabla odlučivanja (engl. Decision Trees (DT)) - identifikuju ključne faktore uspeha formiranjem hijerarhijske strukture odluka.

- Naivni Bajes (engl. Naïve Bayes (NB)) - koristi verovatnoće za predikciju uspeha na osnovu pojedinačnih faktora.
- Mašine potpornih vektora (engl. Support Vector Machines (SVM)) - koriste hiper-ravnine za razdvajanje uspešnih i neuspešnih studenata, pri čemu su posebno korisne kod nelinearnih odnosa u podacima.

Svi modeli su evaluirani korišćenjem tačnosti (engl. accuracy) klasifikacije i matrice konfuzije, kako bi se procenila njihova preciznost i pouzdanost, a detaljni rezultati su prikazani u poglavlju 7. Rezultati ove faze omogućili su analizu povezanosti raspoloživih atributa aktivnosti i postignuća sa konačnim ishodom na predmetu, ali su istovremeno ukazali na ograničenja statičkog modelovanja, što je predstavljalo osnovu za razvoj naprednijeg sekvencijalnog pristupa u narednim fazama istraživanja. Poređenje klasifikatora pokazalo je da je SVM ostvario najvišu prosečnu tačnost u desetostrukoj unakrsnoj validaciji od 88,5%. Prosečne tačnosti ostalih analiziranih algoritama iznosile su 87,6% za logističku regresiju, 86,5% za KNN, 85,7% za Naivni Bajes, 84,6% za LDA i 84,4% za stablo odlučivanja. Na osnovu ovog poređenja SVM je izabran za završnu evaluaciju na izdvojenom testnom skupu. Dobijeni rezultati omogućavaju poređenje prediktivnih performansi analiziranih klasifikatora u posmatranom skupu podataka, ali sami po sebi ne predstavljaju osnovu za zaključivanje o uzrocima razlika u njihovim performansama.

U ovoj fazi SVM je među analiziranim klasifikatorima ostvario najvišu prosečnu tačnost od 88,5% u desetostrukoj unakrsnoj validaciji na trening skupu, dok je nakon izbora modela na izdvojenom testnom skupu ostvarena tačnost od 90,3%. Ovi rezultati pokazali su da statički atributi aktivnosti i postignuća sadrže značajan signal za klasifikaciju konačnog ishoda na predmetu, ali su istovremeno ukazali na ograničenja takvog pristupa za dinamičko modelovanje pojedinačnog studenta. Iako su modeli pokazali dobre rezultate u identifikaciji kategorije studenata koji će ispit uspešno položiti (engl. pass) i nepoložiti (engl. fail), analiza je otkrila nekoliko ključnih ograničenja koja su zahtevala dalje unapređenje pristupa. Glavni problem bio je nedostatak vremenske dimenzije, jer algoritmi nisu uzimali u obzir način na koji se angažovanje studenata menja kroz vreme. Modeli su se oslanjali na statičke podatke, što je značilo da nisu mogli dinamički pratiti obrasce učenja i prilagođavati predikcije u realnom vremenu. Pored toga, interpretabilnost rezultata bila je ograničena, jer iako su pojedini modeli pokazali visoku tačnost, oni nisu omogućavali dubinsku analizu razloga zbog kojih studenti postižu određene rezultate.

U nastavku će biti detaljno analizirana faza 2 istraživanja koja je imala za cilj da obezbedi dublje razumevanje obrazaca učenja kroz klasterovanje i analizu angažovanja uporedivši podatke iz 2 institucije.

6.4. Faza 2: Klasterovanje i analiza obrazaca učenja

Klasterovanje predstavlja tehniku analize obrazovnih podataka koja omogućava grupisanje studenata na osnovu sličnosti u raspoloživim karakteristikama i obrascima aktivnosti. U ovoj fazi klasterovanje je korišćeno radi identifikovanja grupa studenata sa sličnim obrascima angažovanja i poređenja karakteristika tih grupa u dva različita nastavna konteksta. Posebna pažnja posvećena je atributima koji najviše doprinose razlikovanju dobijenih klastera i načinu na koji struktura predmeta i način beleženja aktivnosti utiču na interpretaciju rezultata. Ova faza predstavljala je korak ka razvoju bogatijeg modela studenta, ali pripadnost klasteru nije tumačena kao neposredna mera znanja niti kao samostalna osnova za određivanje individualne preporuke.

U ovoj fazi analizirani su podaci studenata sa dva različita univerziteta [19] radi poređenja obrazaca angažovanja u različitim nastavnim kontekstima. Cilj je bio da se klasterovanjem identifikuju grupe studenata sa sličnim obrascima aktivnosti, izdvoje atributi koji najviše doprinose razlikovanju tih grupa i razmotre implikacije dobijenih nalaza za buduće projektovanje nastavnih jedinica i razvoj modela studenta.

Istraživanje je imalo sledeće ciljeve:

- Poređenje i analiza studentskih podataka i strukture nastavnih jedinica u dva različita predmeta, kako bi se identifikovale karakteristike sličnih klastera studenata na osnovu nivoa aktivnosti.
- Korišćenje rezultata istraživanja za unapređenje organizacije nastavnih sadržaja, sa ciljem razvoja sistema za preporuku nastavnog sadržaja zasnovanog na modelovanju studenata.

U ovoj fazi istraživanja analizirana su dva predmeta sa dve visokoškolske institucije: Fakulteta informacionih tehnologija, Univerziteta Metropolitan u Beogradu (FIT, BMU), Srbija i Fakulteta organizacije i informatike, Univerziteta u Zagrebu (FOI, UNIZG), Hrvatska. Za potrebe komparativne analize odabrana su dva predmeta, sa organizacijom nastavnih resursa prikazanim na Slici 24. Sa BMU-a je odabran predmet *Diskretne strukture*, dok je sa FOI izabran predmet *Informatika*.

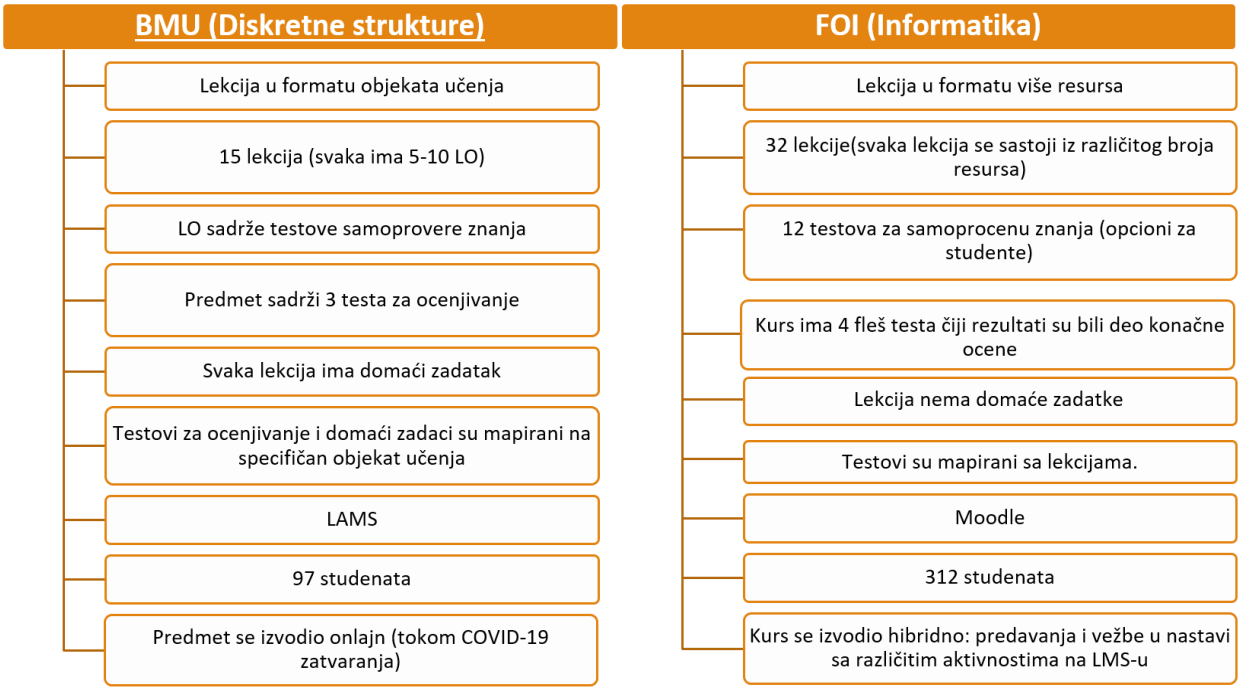

Slika 24. Poređenje ključnih komponenti strukture lekcija za BMU i FOI.

Podaci studenata su prikupljani tokom jednog semestra kroz sisteme za upravljanje učenjem (LMS) institucija. Glavni cilj ove analize bio je da se prati angažovanje studenata tokom predmeta, a zatim se studenti grupišu u klastere na osnovu sličnosti u ponašanju. Na taj način identifikovano je koje karakteristike imaju najveću važnost za adekvatno grupisanje studenata.

Identifikovanje atributa koji najviše doprinose razlikovanju obrazaca angažovanja može biti korisno pri planiranju budućeg prikupljanja podataka i projektovanju modela studenta. U ovoj fazi takvi atributi nisu korišćeni za neposredno određivanje nivoa znanja niti za generisanje individualnih preporuka; njihova potencijalna upotreba za preporučivanje razmatrana je kao pravac daljeg razvoja. Predmet *Diskretne strukture* pohađalo je 97 studenata. Ovaj predmet su pohađali studenti prve i druge godine osnovnih akademskih programa - Informacione tehnologije, Softversko inženjerstvo i Razvoj video igara. Konkretna instanca predmeta, koja je deo ove analize, odnosi se na predmet koji je predavan tokom pandemije COVID-19 i zatvaranja fakulteta. Nastavni materijali su bili postavljeni na sistem za upravljanje nastavnim aktivnostima (engl. Learning Activity Management System (LAMS)), dok su studenti imali nedeljna predavanja sa profesorom putem Zoom platforme. Nastavni materijali postavljeni na LAMS bili su strukturisani kao kombinacija niza OU-ova i nastavnih aktivnosti. Svaka lekcija se sastojala od skupa OU (5-10 OU-ova). Pored nastavnih materijala, lekcije su sadržale aktivnosti kao što su testovi za samoproveru nakon svakog OU-a, forume, deljene resurse i

mape uma. Primer BMU-ovog strukturiranja lekcija sa OU i nastavnim aktivnostima prikazan je na Slici 25.

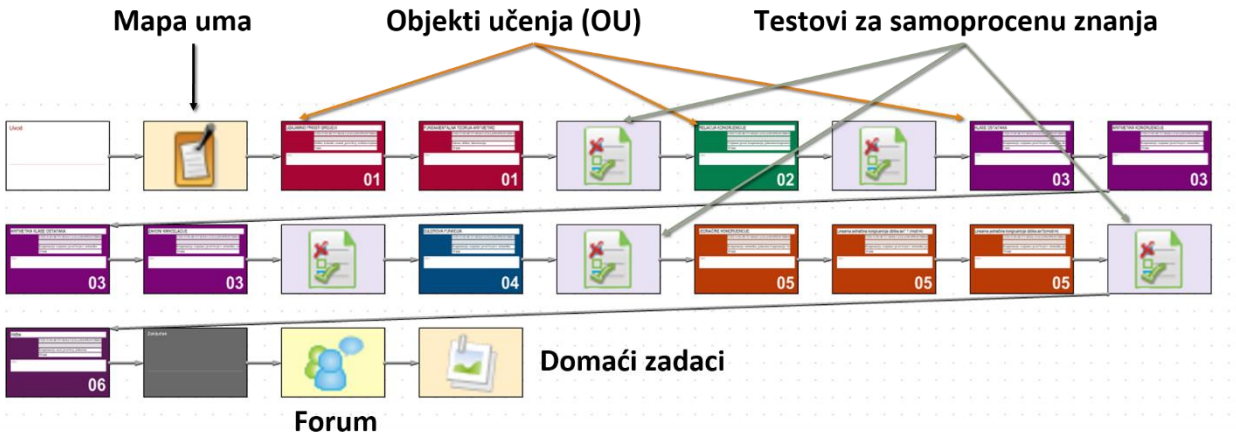

Slika 25. Primer BMU-ovog strukturiranja lekcije sa objektima učenja i aktivnostima učenja lekcije.

Pored testova za samoproveru znanja, studentima su takođe dodeljivani zadaci za ocenjivanje, odnosno domaći zadaci svake nedelje, dok su na svakih približno 3-4 nedelja polagali testove. I testovi i domaći zadaci su bili povezani sa određenim OU-om. Drugim rečima, svaki domaći zadatak i test su ocenjivali specifično znanje iz jednog ili više OU-ova. Štaviše, testovi su bili projektovani sa pet sekcija, pri čemu je svaka sekcija takođe bila povezana sa određenom OU-om ili skupom OU-ova. Ovo je urađeno sa namerom da se studentima lakše ukaže na preporučeni materijal u slučaju da ne polože domaći zadatak ili test sa minimalnom ocenom. Primer organizacije testa sa sekcijama prikazan je na Slici 26. Struktura lekcija, koja je uključivala mapiranje nastavnih materijala i formativnih ocenjivanja za određene sekcije, omogućila je lakše praćenje napretka studenata i identifikaciju oblasti u kojima studenti mogu imati poteškoća u okviru predmeta.

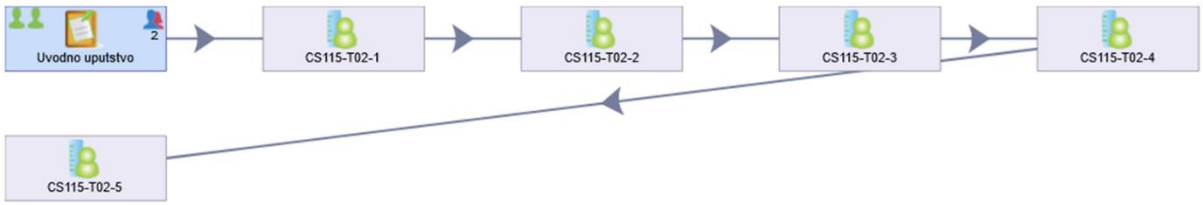

Slika 26. Primer BMU-ove organizacije stepenovanih testova u različite sekcije.

Predmet *Informatika* na FOI-u bio je obavezan u prvom semestru osnovnog studijskog programa Informacioni i poslovni sistemi na Fakultetu organizacije i informatike Univerziteta u Zagrebu, a pohađalo ga je 312 studenata. Predmet se izvodio u hibridnom formatu, koji je uključivao predavanja i laboratorijske vežbe na fakultetu, uz nastavne materijale i zadatke

dostupne putem LMS Moodle sistema. Teme predavanja su studentima predstavljene kroz aktivnosti lekcija na LMS-u, gde je ukupno kreirano 32 lekcije. Lekcije su bile u formatu većeg broja resursa, koji je uključivao tekst, slike, video zapise i dodatne linkove. Evaluacija znanja studenata vršena je, između ostalog, putem testova za samoprocenu znanja i blic testova. Tokom semestra organizovano je 12 testova za samoprocenu znanja, koji su bili neobavezni, što znači da njihovi rezultati nisu ulazili u konačnu ocenu. Studenti su ih mogli koristiti za proveru svog znanja i pripremu za kolokvijume. S druge strane, blic testovi su bili obavezni, a njihovi rezultati su činili deo završne ocene. Pitanja u testovima za samoprocenu i blic testovima bila su mapirana na sadržaj lekcija. Primer organizacije lekcija prikazan je na Slici 27. Tipično, jedna tema predmeta pokrivana je kroz tri različite sekcije lekcija. Na primer, predavanje pod nazivom *Treće predavanje* sastojalo se od lekcija: *Lekcija 2.1, Lekcija 2.2, Lekcija 2.*3. Test za samoprocenu znanja pod nazivom *Samoprocena znanja 3* odgovarao je predavanju *Treće predavanje*. Sa druge strane, blic test pod nazivom *Blic test 2* procenjivao je znanje stečeno iz dva predavanja: *Treće predavanje, Četvrto predavanje*. Ovaj test je obuhvatao ukupno šest lekcija: *Lekcija 2.1* - *Lekcija 2.6*.

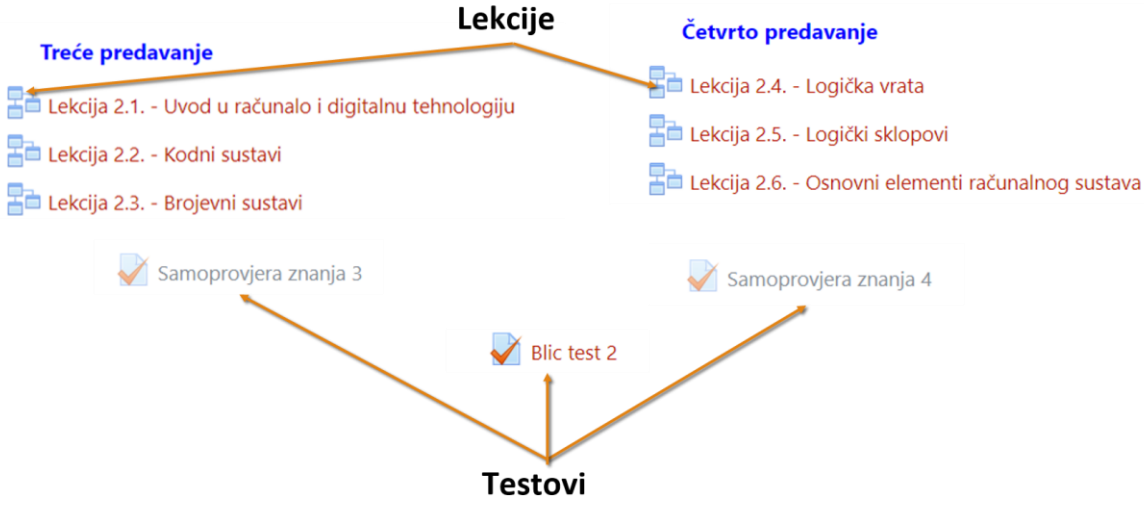

Slika 27. Primer strukture lekcije FOI.

Poređenje ključnih komponenti struktura lekcija za BMU i FOI prikazano je na Slici 24. Kao što se može videti sa Slike 24, postoji nekoliko razlika između odabranih predmeta u strukturi lekcija. Pored različitih LMS sistema i organizacije predmeta, jedna od ključnih razlika je granularnost lekcija i način mapiranja studentskih aktivnosti na određene delove lekcije ili na lekciju u celini. Na BMU-u lekcije su predstavljene kroz objekte učenja, a studentske aktivnosti su mapirane na određene objekte učenja. Na FOI-ju nema mapiranja na određeni deo lekcije; mapiranje se vrši na lekciju u celini.

Dataset na predmetu sa BMU-a zasnovan je na studentskim aktivnostima tokom semestra. Ovaj skup podataka sadrži četiri karakteristike:

- *Broj bodova na testu* - Ova promenljiva predstavlja broj bodova dobijenih na ocenjenom testu.
- *Broj bodova na domaćem zadatku* - Ova promenljiva predstavlja broj bodova dobijenih na domaćem zadatku.
- *Broj bodova na testovima za samoprocenu znanja* - Ova promenljiva predstavlja broj bodova dobijenih na neocenjenim testovima za samoprocenu znanja.
- *Vreme provedeno na svakom OU-u* - Ova promenljiva je predstavljena u obliku kolone sa *true* ili *false* vrednostima, gde *true* znači da je student proveo neko vreme na određenom OU-u, dok *false* znači da student nije proveo vreme na tom OU-u.

FOI skup podataka sadrži podatke o aktivnostima studenata na LMS Moodle platformi, sa fokusom na lekcije. Ovaj skup podataka uključuje sledeće promenljive:

- *Lekcija je pokrenuta* - Ova promenljiva predstavlja broj logova za lekciju, odnosno koliko puta je student pokrenuo lekciju.
- *Lekcija je završena* - Ova promenljiva predstavlja broj logova za svako potpuno pregledano predavanje.
- *Lekcija je nastavljena* - Ova promenljiva predstavlja broj logova za svako ponovno vraćanje na već započetu lekciju.
- *Lekcija je ponovo pokrenuta* - Ova promenljiva predstavlja broj logova kada je student ponovo pokrenuo lekciju od početka.
- *Lekcija je ponovo pregledana* - Ova promenljiva predstavlja broj logova u kojima su studenti ponovo otvorili i pregledali lekciju.
- *Broj bodova na testovima za samoprocenu znanja* - Ova promenljiva prikazuje broj bodova koje su studenti ostvarili na testovima za samoprocenu.
- *Broj bodova na blic testovima* - Ova promenljiva prikazuje broj bodova koje su studenti ostvarili na blic testovima.

Prvih pet promenljivih odnosi se na učestalost pregledanja lekcija od strane studenata, dok poslednje dve promenljive (broj bodova na testovima za samoprocenu i broj bodova na blic testovima) pružaju uvid u njihovu uspešnost.

Nakon što su formirani skupovi podataka, sprovedeno je klasterovanje studenata korišćenjem k-means algoritma. Razmatrano je više različitih brojeva klastera, ali je za analizu

odabrana podela na tri grupe, kako bi se omogućilo jednostavnije poređenje između dve institucije. Rezultati su detaljno prikazani u poglavlju 7. Poređenjem rezultata između BMU i FOI skupova podataka primećene su značajne razlike u distribuciji studenata po klasterima. U BMU skupu podataka najveći broj rezultata pripada grupi veoma aktivnih, dok je u FOI skupu podataka više od polovine rezultata svrstano u grupu pasivnih. Ove razlike mogu se delimično objasniti razlikama u strukturi lekcija. Na BMU predmetima, nastavni materijali su detaljno podeljeni na manje OU-a, dok su na FOI predmetima lekcije tretirane kao celina. Razlika u granularnosti nastavnog sadržaja neposredno je uticala na granularnost podataka koji su bili dostupni za modelovanje: na BMU su aktivnosti mogle biti povezane sa pojedinačnim objektima učenja, dok su na FOI bile povezane sa lekcijom kao celinom. Razlike u raspodeli studenata po klasterima ne mogu se, međutim, pripisati samo granularnosti, jer su se analizirani predmeti razlikovali i prema instituciji, LMS platformi, načinu izvođenja nastave i skupu raspoloživih atributa. Konačni zaključci ove faze su:

- Granularnije mapiranje aktivnosti omogućava detaljnije podatke za modelovanje i preciznije lokalizovanje dela nastavnog sadržaja na koji se aktivnost odnosi, ali ovom analizom nije izolovano utvrđen njegov samostalan efekat na nivo angažovanja studenata. Na BMU je slabiji rezultat na sekciji testa mogao biti povezan sa konkretnim objektom učenja, dok bi na FOI preporuka mogla da uputi studenta samo na celu lekciju. Granularnost nastavnog sadržaja i provera zato određuje najveću preciznost koju preporuka može da dostigne.
- U obe institucije atribut koji je najviše razdvajao klastere potiče iz rezultata provera znanja: na BMU broj bodova na testovima, a na FOI broj bodova na testovima za samoprocenu, uz broj pokretanja lekcija. Rezultati provera tako su se pokazali kao najinformativniji signal nezavisno od institucije i platforme, pri čemu su i neobavezne formativne provere, koje na FOI nisu ulazile u ocenu, nosile korisnu informaciju. Zbog toga su u trećoj fazi dokazi iz aktivnosti provere, uključujući i formativne, osnovni ulaz za procenu ovladanosti.
- Vremenski obrasci zabeleženih aktivnosti pokazali su promene intenziteta studentskog angažovanja tokom semestra, dok uzroci uočenih promena nisu neposredno ispitivani u ovoj fazi. Zbirni atributi korišćeni pri klasterovanju ne čuvaju redosled aktivnosti, pa ovaj obrazac nije mogao biti obuhvaćen samim modelom. To je jedan od razloga zašto je u trećoj fazi procena ovladanosti formirana iz hronološke sekvence dokaza.

- Poređenje između institucija ograničeno je brojnim razlikama u kontekstu, pa se zaključci ove faze odnose na projektne smernice, a ne na uzročne efekte. Zato je u trećoj fazi poređenje sprovedeno između dva predmeta unutar iste institucije i istog kompetencijski proširenog modela nastavnog sadržaja (odeljak 6.5.1).

6.5. Faza 3: Model kontinuiranog praćenja ovladanosti nastavnim sadržajem

Ograničenja prethodne dve iteracije - odsustvo vremenske dimenzije u fazi 1 i nemogućnost klasterovanja da opiše pojedinačnog studenta u fazi 2 - usmerila su finalnu iteraciju istraživanja modela studenta ka pristupu koji: (i) prati pojedinačnog studenta kontinuirano tokom semestra, umesto da ga klasifikuje na osnovu statične slike ili grupne pripadnosti, i (ii) procenu ovladanosti eksplicitno vezuje za kompetencijski okvir nastavnog sadržaja opisan u odeljku 5.3, umesto da se oslanja na agregirane pokazatelje uspeha bez veze sa konkretnim nastavnim sadržajem. Teorijski aparat na kome se ovaj model zasniva - Bajesovo praćenje znanja (BKT), klasterovanje ponašajnih obrazaca i objašnjiva veštačka inteligencija - detaljno je izložen u odeljku 4.3. Ovaj odeljak opisuje kako je taj okvir konkretizovan i primenjen na stvarne podatke dva predmeta, kao i rezultujuću arhitekturu modela studenta.

6.5.1. Podaci i jedinica modelovanja

Model je razvijen i evaluiran na dva predmeta koja su kompetencijski strukturirana prema okviru iz odeljka 5.3: SE201 - Uvod u softversko inženjerstvo (37 studenata, 227 OU, usklađen sa SE2014 okvirom [269], konceptualno orijentisan predmet) i CS202 - Objektno orijentisano programiranje 2 (74 studenta, 126 OU, usklađen sa IT2017 okvirom [270], programski orijentisan predmet). Predmeti su odabrani tako da se razlikuju po prirodi gradiva, jedan sa naglaskom na konceptualno razumevanje, a drugi na praktične programske veštine, kako bi se ispitala primenljivost istog modela kontinuiranog praćenja u dva različita nastavna konteksta. Ovim se, za razliku od faze 2, poređenje ne vrši između institucija ili nastavnih sistema, već između dva predmeta unutar istog, kompetencijski proširenog modela nastavnog sadržaja, čime je izbegnuto metodološko ograničenje na koje je ukazala prethodna iteracija.

Osnovne karakteristike predmeta i konkretizacije kompetencijskog modela prikazane su u Tabeli 4. Pored različitog domena i usmerenja predmeta, razlikuju se i distribucija objekata učenja prema nivoima dubine i stepen granularnosti kompetencijske strukture.

Tabela 4. Karakteristike predmeta korišćenih u trećoj fazi razvoja modela studenta.

Karakteristika	SE201	CS202
Naziv predmeta	Uvod u softversko inženjerstvo	Objektno orijentisano programiranje 2
Referentni kurikulum	SE2014	IT2017
Usmerenje predmeta	konceptualno	programsko
Broj studenata	37	74
Ukupan broj objekata učenja	227	126
Objekti učenja nivoa N1	78	51
Objekti učenja nivoa N2	81	63
Objekti učenja nivoa N3	68	12
Broj kompetencija referentnog kurikuluma	7	3
Broj kompetencija predmeta	10	11

Kao što je najavljeno u odeljku 4.3.2.3, jedinica modelovanja konkretizovana je kao kombinacija kompetencije predmeta i nivoa dubine (N1, N2 ili N3, odeljak 5.3). Kompetencije definisane referentnim kurikulumima predstavljaju šire sposobnosti, pa su tokom projektovanja silabusa dekomponovane na finije kompetencije predmeta koje predstavljaju konkretne sposobnosti razvijane i proveravane u okviru datog predmeta. Pri tome kompetencija predmeta nije isto što i nastavna tema. Tema predstavlja čvor u hijerarhijskoj organizaciji sadržaja, dok kompetencija izražava ono što student treba da bude sposoban da uradi i može biti razvijana kroz više tema i više objekata učenja. Ovakva dekompozicija omogućava da se ovladanost procenjuje na nivou specifičnih sposobnosti, umesto samo na nivou širokih kompetencija kurikuluma. Na predmetu SE201 sedam kompetencija kurikuluma razloženo je na deset kompetencija predmeta, dok su na predmetu CS202 tri šire kompetencije razložene na jedanaest kompetencija predmeta. Kombinacija kompetencije predmeta i nivoa dubine istovremeno predstavlja jedinicu koju ontološki model nastavnog sadržaja koristi za organizovanje povezanih objekata učenja i jedinicu za koju model studenta formira sekvencijalnu procenu ovladanosti. Time su model sadržaja i model studenta strukturno usklađeni, umesto da se procena ovladanosti naknadno vezuje za već formiranu strukturu sadržaja.

Konkretna dekompozicija kompetencija korišćena pri instanciranju modela prikazana je u Tabeli 5. „Različit odnos broja kompetencija iz referentnog kurikuluma i kompetencija predmeta odražava različitu početnu granularnost referentnih okvira. Kod SE201 kompetencije iz referentnog kurikuluma već su relativno specifične i uglavnom se razlažu na jednu ili dve

kompetencije predmeta. Kod CS202 tri šire kompetencije iz referentnog kurikuluma zahtevaju finiju dekompoziciju kako bi se odvojeno mogle pratiti različite programske sposobnosti studenta.

Tabela 5. Dekompozicija kompetencija iz referentnog kurikuluma na kompetencije predmeta.

Predmet	Kompetencija kurikuluma	Kompetencije predmeta
SE201	Tehnike modelovanja	Primena modela softverskog procesa; Modelovanje sistema pomoću UML-a
	Specifikacija zahteva	Inženjerstvo softverskih zahteva; Primena agilnih metoda
	Metodologije projektovanja	Projektovanje softvera zasnovano na proizvodu
	Arhitektonsko projektovanje	Projektovanje softverske arhitekture; Projektovanje mikroservisnih arhitektura
	Pouzdanost softvera	Obezbeđivanje pouzdanosti softvera
	Tehnike testiranja	Primena tehnika testiranja
	Upravljanje konfiguracijom	Upravljanje konfiguracijom i DevOps praksama
CS202	Ovladavanje jednim ili više programskih jezika	Izrada grafičkih korisničkih interfejsa; Obrada događaja korisničkog interfejsa; Razvoj naprednih komponenti korisničkog interfejsa; Strukturiranje i vizualizacija podataka u korisničkom interfejsu; Programiranje konkurentnih aplikacija; Razvoj mrežnih aplikacija
	Projektovanje i implementacija algoritama	Primena rekurzivnog rešavanja problema; Primena generičkog programiranja; Rad sa strukturama podataka i kolekcijama
	Kreiranje SQL naredbi	Pristup relacionim bazama podataka; Objektno-relaciono mapiranje podataka

Ontološka struktura dva predmeta dodatno je konkretizovana relacijama koje određuju preduslove i veze između osnovnih i naprednih sadržaja. Za predmet SE201 definisane su 73 relacije redosleda (OR) i 11 relacija osnovni/napredni (BA), dok su za predmet CS202 definisane 47 relacija OR i 12 relacija BA. Ove relacije koriste se u adaptivnom sloju za uređivanje preporučenih objekata učenja prema preduslovima i odnosima između osnovnih i naprednih sadržaja.

Skup podataka obuhvata rezultate provera znanja i praktičnih veština prikupljene tokom redovne realizacije predmeta SE201 i CS202 u toku jedne školske godine. Na predmetu SE201 korišćeno je 13 testova, 3 ocenjena zadatka i 1 projekat, dok su za napredni nivo bila predviđena 2 esejska zadatka. Pošto nijedan student nije završio esejske zadatke, za predmet SE201 nisu postojali dokazi iz aktivnosti provere na nivou N3. Na predmetu CS202 korišćeno je 12 testova, 4 ocenjena zadatka, 1 projekat i 1 esej, pri čemu je esej predstavljao opcioni dokaz iz aktivnosti provere za sadržaj nivoa N3. Testovi, ocenjeni zadaci i projekti obezbeđivali su dokaze na osnovnom i srednjem nivou, N1 i N2. Ovakva zajednička struktura provere omogućila je primenu istog postupka modelovanja studenta na dva predmeta različita po domenu i prirodi gradiva. Svaka aktivnost provere ima definisan maksimalan broj poena u skladu sa strukturom konkretnog predmeta. Ove vrednosti koriste se pri agregiranju ostvarenosti aktivnosti na nivou N1, N2 i N3, kao što je opisano u odeljku 6.5.2.2. Njih je potrebno razlikovati od težina relevantnosti mapiranja aktivnosti na objekte učenja, koje nastavnik definiše na skali od 1 do 3 i koje se koriste u sloju procene ovladanosti opisanom u odeljku 6.5.2.1. Prva vrsta pondera određuje relativni doprinos aktivnosti ukupnoj ostvarenosti nivoa, dok druga određuje koliko snažno rezultat određene aktivnosti predstavlja dokaz za konkretan objekat učenja i pripadajuću kompetenciju.

U integrisanom modelu element VERIFY ne predstavlja zasebnu komponentu sistema za ocenjivanje niti samostalni tip aktivnosti. On predstavlja semantičku vezu između objekta učenja i dokaza o znanju ili veštini koji se prikupljaju u sistemu za upravljanje obrazovanjem. Aktivnosti provere definišu se i povezuju sa nastavnim planom, dok se njihovi rezultati, ostvareni poeni, ocene, vreme realizacije i podaci o pokušajima, prosleđuju modelu studenta. Rezultat provere tako se ne posmatra samo kao deo konačne ocene, već kao strukturirani dokaz povezan sa konkretnim objektima učenja, ishodima učenja, kompetencijama i nivoima dubine.

Aktivnosti provere razlikuju se prema obimu nastavnog sadržaja koji obuhvataju i prema granularnosti dokaza koji pružaju:

1. pojedinačno pitanje mapira se na jedan objekat učenja i predstavlja najfiniji nivo dokaza;
2. test nivoa N1 ili N2 obuhvata više pitanja mapiranih na objekte učenja odgovarajućeg nivoa;
3. ocenjeni zadatak nivoa N1 ili N2 može biti povezan sa više objekata učenja unutar jedne ili više tema;

4. projekat pruža objedinjeni dokaz za veći deo objekata učenja i više kompetencija predmeta;
5. esej se povezuje isključivo sa objektima učenja naprednog nivoa N3 i predstavlja dokaz samostalnog i produbljenog rada studenta.

Granularnost ovih aktivnosti i njihovo mapiranje na objekte učenja prikazani su na Slici 28.

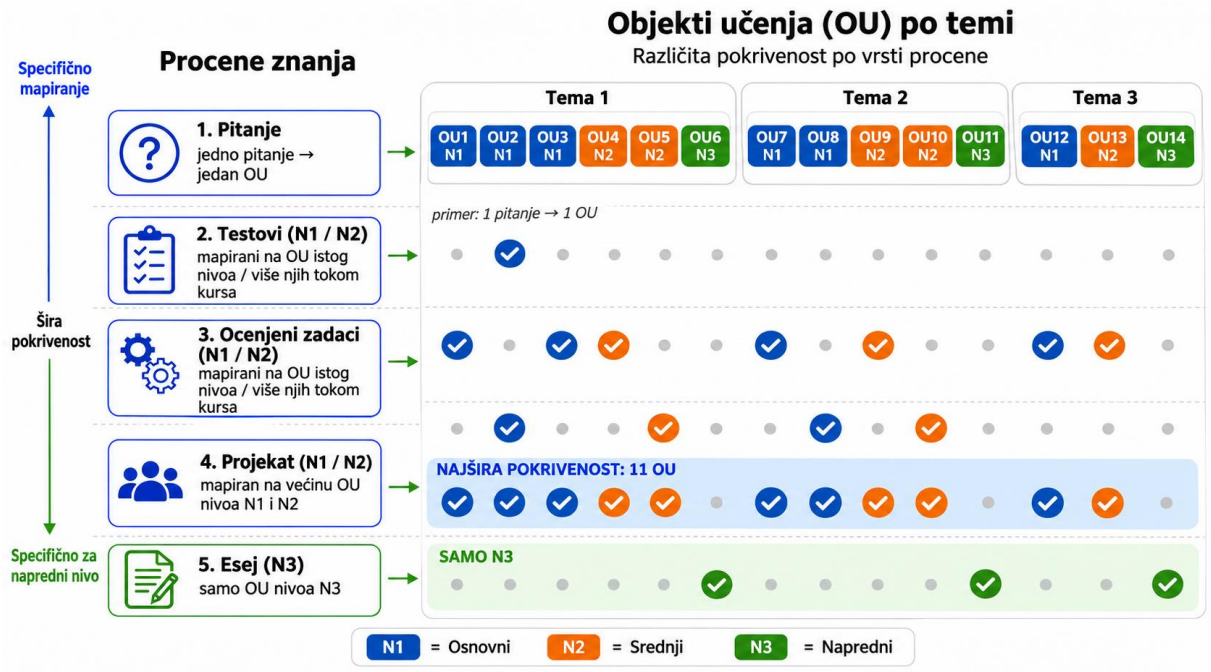

Slika 28. Aktivnosti provere i njihovo mapiranje na objekte učenja pri različitim nivoima granularnosti. Pojedinačna pitanja pružaju fino granularne dokaze, dok testovi, ocenjeni zadaci, projekti i eseji pružaju šire dokaze mapirane na objekte učenja i nivoe dubine.

Mapiranje prikazano na Slici 28 omogućava da se rezultati različitih aktivnosti prevedu iz izolovanih brojčanih vrednosti u strukturirane dokaze o učenju. Jedna aktivnost može biti povezana sa jednim ili sa više objekata učenja, ali je svaka veza dodatno određena pripadajućom kompetencijom i nivoom dubine. Na taj način isti rezultat može doprineti proceni ovladanosti šire kompetencije, dok se istovremeno zadržava podatak o konkretnim objektima učenja koje je aktivnost obuhvatila. Mapiranje predstavlja vezu između elementa VERIFY iz modela nastavnog sadržaja i ulaznih podataka modela studenta.

Nivo N1 predstavlja obavezno jezgro sadržaja i kompetencija, dok N2 predstavlja dodatni nivo produbljenog ovladavanja, a N3 napredni nivo koji podrazumeva izraženiji samostalni i složeniji rad. Nivoi se zato razlikuju prema ulozi u strukturi predmeta i očekivanoj dubini ovladavanja, ali način na koji se neizvršena aktivnost numerički tretira zavisi od sloja modela studenta. U sloju ostvarenosti nivoa aktivnost koja je bila predviđena i dostupna studentu, ali nije završena, doprinosi vrednošću nula, dok se aktivnost koja u datoj realizaciji predmeta nije

sprovela isključuje iz obračuna. Napredni nivo N3 dodatno se interpretira uzimajući u obzir njegov opcioni karakter. Precizna pravila agregiranja prikazana su u odeljku 6.5.2.2.

Analitičku kohortu čine svi studenti za koje postoji najmanje jedno zapažanje relevantno za procenu ovladanosti, odnosno rezultat testa ili druge aktivnosti provere mapiran na jedan ili više objekata učenja. Svi podaci korišćeni u analizi anonimizovani su, a studenti su u skupu podataka predstavljeni isključivo neidentifikujućim numeričkim oznakama. Studija je koncipirana kao provera koncepta (engl. proof of concept), a ne kao osnova za statističko uopštavanje na druge institucije, studijske programe ili nastavne domene. Podaci potiču sa jedne institucije i iz jedne školske godine. Cilj ove faze evaluacije jeste da se proveri da li se ista arhitektura i postupak modelovanja mogu operacionalizovati na stvarnim podacima dva predmeta različite prirode i da li se na osnovu tih podataka mogu formirati interpretabilne procene ovladanosti koje se kasnije koriste za generisanje objašnjivih preporuka.

6.5.2. Slojevi modela studenta

Model studenta ima ulogu da verifikovane podatke o aktivnostima studenata pretvori u interpretabilan prikaz njihovog trenutnog stanja učenja, napretka i načina rada. Model je organizovan kroz tri međusobno povezana, ali konceptualno odvojena sloja: sloj ovladanosti kompetencijama, sloj ostvarenosti nivoa i sloj analitike učenja. Prva dva sloja čine dvoslojni model procene napretka: sloj ovladanosti pokazuje koliko uspešno student savladava sadržaj sa kojim je radio, dok sloj ostvarenosti pokazuje koliki je deo poena predviđenih za aktivnosti određenog nivoa dubine ostvario. Treći sloj opisuje način na koji student pristupa učenju i ne predstavlja dodatnu meru njegovog znanja.

U okviru modela potrebno je razlikovati četiri vrste izlaza koje imaju različitu ulogu. Sekvencijalna procena ovladanosti formira se primenom BKT modela na nivou kombinacije predmet-kompetencija predmeta-nivo dubine. Za pojedinačne objekte učenja, za koje najčešće ne postoji dovoljno duga sekvenca zapažanja za pouzdanu BKT procenu, koristi se lokalni dijagnostički indikator zasnovan na prosečnom rezultatu trenutno važećih relevantnih pokušaja. Ostvarenost nivoa predstavlja odvojenu meru, udeo osvojenih poena u ukupnom broju poena predviđenih za aktivnosti nivoa N1, N2 i N3, i ne tumači se kao procena ovladanosti. Ponašajni tip, dobijen klasterovanjem atributa angažovanja, predstavlja dodatni kontekst načina rada studenta i takođe se ne tumači kao mera znanja. Na taj način model razdvaja procenu ovladanosti, lokalni dokaz na nivou sadržaja, ostvarenost predviđenih aktivnosti i ponašajni obrazac, iako se svi ovi izlazi kasnije zajedno koriste u adaptivnom sloju.

Predložena arhitektura ne zavisi od jednog konkretnog algoritma procene ili profilisanja. U implementaciji prikazanoj u ovoj disertaciji Bajesovo praćenje znanja primenjeno je za sekvencijalnu procenu ovladanosti, dok je k-means klasterovanje primenjeno za identifikovanje ponašajnih tipova studenata. Ove metode odabrane su zbog interpretabilnosti, relativno male računarske složenosti i mogućnosti primene na skupovima podataka na nivou pojedinačnog predmeta. Naučni doprinos zato nije razvoj novog algoritma mašinskog učenja, već prilagođavanje i integracija interpretabilnih metoda u kompetencijski zasnovan model studenta, povezan sa ontološkim modelom nastavnog sadržaja.

6.5.2.1. Sloj ovladanosti kompetencijama

Sloj ovladanosti kompetencijama primenjuje Bajesovo praćenje znanja, opisano u odeljku 4.3.2, na hronološke nizove zapažanja grupisane prema kombinaciji student-predmet-kompetencija predmeta-nivo dubine. Jedinicu sekvencijalnog modelovanja zato ne predstavlja pojedinačni objekat učenja, već kompetencija predmeta na nivou N1, N2 ili N3. Kompetencije iz referentnog kurikuluma bile bi previše široke za neposrednu procenu, dok pojedinačni objekti učenja najčešće nemaju dovoljan broj zapažanja po studentu za formiranje pouzdanog sekvencijalnog niza. Kompetencija predmeta u kombinaciji sa nivoom dubine predstavlja odgovarajući srednji nivo granularnosti.

Parametri BKT modela procenjuju se zasebno za svaku kombinaciju *predmet-kompetencija predmeta -nivo dubine*, na osnovu svih raspoloživih sekvenci studenata koje pripadaju toj kombinaciji. Za procenu parametara primenjuje se postupak maksimizacije očekivanja (engl. expectation-maximization), nakon čega se dobijeni parametri koriste za izračunavanje posteriorne verovatnoće ovladanosti svakog pojedinačnog studenta. Za konačne procene prikazane u ovoj disertaciji koriste se parametri procenjeni na kompletnoj kohorti. Stabilnost ovog postupka dodatno je proverena petostrukom unakrsnom validacijom unutar kohorte, pri čemu su parametri procenjivani na 80% studenata i primenjivani na preostalih 20%; rezultati te provere prikazani su u odeljku 7.2.3.1. Ova validacija proverava unutrašnju stabilnost procene, a ne generalizaciju na nezavisnu kohortu. Za svaku jedinicu modelovanja formira se hronološki niz svih relevantnih pokušaja. Kada student preda novi pokušaj iste aktivnosti, prethodni pokušaj dobija status ranijeg pokušaja, dok se samo poslednji tretira kao trenutni. Raniji pokušaji ne odbacuju se iz BKT niza, jer mogu da pokažu proces napredovanja studenta i predstavljaju stvarni sekvencijalni signal učenja. Zapažanja se ne pretvaraju u binarne vrednosti tačno-netačno, već se u model unosi ostvareni procenat u intervalu od 0 do 1. Time

se zadržava više informacija o kvalitetu rezultata i smanjuje rizik od preuranjenog zasićenja procene.

Pragovi ovladanosti određuju se prema pedagoškoj ulozi nivoa dubine. Za obavezni nivo N1 koristi se prag 0,8, dok se za dodatne i produbljene nivoe N2 i N3 koristi prag 0,5. Početna verovatnoća ovladanosti ograničena je na najviše 0,5, kako model ne bi pretpostavljao visok početni nivo ovladanosti kompetencijom pre nego što za to postoji odgovarajući dokaz. Konačna procena predstavlja posteriornu verovatnoću ovladanosti nakon poslednjeg zapažanja i opisuje trenutno stanje studenta u trenutku analize. Kada aktivnost provere obuhvata više objekata učenja, njen rezultat se najpre povezuje sa svim obuhvaćenim objektima prema mapiranju definisanom u odeljku 6.5.1, a zatim se uključuje u odgovarajuće nizove predmet-kompetencija predmeta-nivo dubine. Pošto aktivnost ne mora biti podjednako relevantna za svaki objekat učenja koji obuhvata, nastavnik vezi između aktivnosti i objekta učenja dodeljuje težinu relevantnosti $\omega \in \{1, 2, 3\}$, gde vrednost 3 označava centralnu, a vrednost 1 marginalnu povezanost. Ako je ostvareni rezultat aktivnosti izražen vrednošću o∈[0,1], u sekvencijalni niz unosi se skalirana vrednost:

$$o' = 0.5 + (o - 0.5) \cdot \frac{\omega}{3}. \tag{10}$$

Prema jednačini (10), centralni objekti učenja (ω = 3) zadržavaju puni signal, dok se oni koji su samo marginalno povezani (ω = 1) pomeraju ka neutralnoj vrednosti 0.5. Time se praktična procena, koja je u tradicionalnim sistemima često odvojena od procene na nivou teme, objedinjuje sa procenom znanja. Za dijagnostiku i preporučivanje na nivou pojedinačnog objekta učenja, gde je niz podataka najčešće prekratak za pouzdanu sekvencijalnu procenu, izračunava se prosečan procenat koji je student ostvario na tom objektu učenja, uzimajući u obzir samo trenutno važeće pokušaje. Dobijena vrednost poredi se sa pragom ovladanosti definisanim za odgovarajući nivo dubine: 0,80 za nivo N1 i 0,50 za nivoe N2 i N3. Za objekte nivoa N1 koji pripadaju obaveznom jezgru, a koje student nije pokušao, odsustvo procene ne tumači se kao ovladanost jednaka nuli. Takvi objekti se u adaptivnom sloju posebno evidentiraju kao nepokušani obavezni sadržaji visokog prioriteta. Time se razlikuju dva pedagoški različita slučaja: pokušani sadržaj sa procenom ovladanosti ispod praga i obavezni sadržaj koji student još nije pokušao.

Obradu aktivnosti koja obuhvata više objekata učenja ilustruje sledeći hipotetički primer. Test od 20 poena mapiran je na tri objekta učenja koji pripadaju istoj kompetenciji predmeta na nivou N1, sa težinama relevantnosti ω = 3, ω = 2 i ω = 1. Student je na testu osvojio 8 poena,

odnosno $o = 0{,}4$. Prema jednačini (10), u niz te kompetencije unose se tri zapažanja: 0,40 za centralno povezani objekat, 0,433 za objekat sa težinom 2 i 0,467 za marginalno povezani objekat. Isti rezultat se, dakle, u sekvencijalnoj proceni koristi onoliko puta koliko objekata učenja aktivnost obuhvata. Ovakvo formiranje sekvencijalnog niza predstavlja projektnu odluku opisanu u objavljenom radu [20]: rezultat jedne aktivnosti uključuje se kao zasebno zapažanje za svaki obuhvaćeni objekat učenja, pri čemu se uticaj manje relevantnih veza ublažava ponderisanjem prema jednačini (10). Budući da zapažanja izvedena iz iste aktivnosti nisu nezavisni pokušaji, broj objekata učenja na koje je aktivnost mapirana može uticati na njen relativni doprinos BKT proceni, što je razmotreno među ograničenjima istraživanja u odeljku 8.3. U ostalim izlazima modela isti rezultat ne računa se višestruko. Lokalni dijagnostički indikator svakog od tri objekta učenja dobija po jedan rezultat od 0,40, a u ostvarenosti nivoa test učestvuje samo jednom, sa 8 od 20 poena, bez obzira na broj objekata učenja na koje je mapiran.

Model, dakle, kombinuje sekvencijalnu procenu ovladanosti kompetencijama na nivou predmeta sa dijagnostičkim procenama na nivou pojedinačnih objekata učenja. Informacije o procenjenoj ovladanosti i o tome da li je obavezni sadržaj pokušavan predstavljaju ulaz za adaptivni sloj, koji ih koristi pri formiranju ciljanih preporuka.

6.5.2.2. Sloj ostvarenosti nivoa

Sloj ostvarenosti nivoa agregira izabrane aktivnosti provere znanja i praktičnih veština prema nivoima dubine N1, N2 i N3. Za razliku od sloja ovladanosti kompetencijama, koji procenjuje koliko uspešno student savladava sadržaj sa kojim je radio, ovaj sloj pokazuje koliki je deo ukupnog broja poena predviđenih za aktivnosti odgovarajućeg nivoa student ostvario. Na vrednost ostvarenosti zato utiču i broj realizovanih aktivnosti i rezultati postignuti na njima. Ovladanost se odnosi samo na sadržaj sa kojim je student radio, dok ostvarenost obuhvata ceo skup aktivnosti predviđenih za nivo, uključujući i one koje student nije realizovao.

Pri formiranju vrednosti ostvarenosti nivoa primenjuju se sledeća pravila:

- aktivnosti se grupišu prema nivou dubine nastavnog sadržaja koji proveravaju;
- za nivoe N1 i N2 uključuju se rezultati testova, ocenjenih zadataka i projekata;
- za opcioni nivo N3 uključuju se rezultati esejskih aktivnosti;
- aktivnosti se ponderišu maksimalnim brojem poena koji im je dodeljen u strukturi predmeta, tako da aktivnosti različitog obima i značaja ne doprinose podjednako ukupnoj vrednosti;

- u obračun se uključuju samo trenutno važeći pokušaji;
- raniji pokušaji ne računaju se kao dodatno realizovane aktivnosti;
- aktivnost koja nije sprovedena u posmatranom ciklusu predmeta izostavlja se iz analize;
- aktivnosti koja je bila dostupna, ali je student nije realizovao, dodeljuje se vrednost nula.

Na osnovu navedenih pravila, ostvarenost nivoa izračunava se kao udeo osvojenih poena u ukupnom broju poena predviđenih za aktivnosti tog nivoa:

$$O_N = \frac{\sum_a p_a}{\sum_a P_a} \tag{11}$$

gde se sabiranje vrši po svim aktivnostima a datog nivoa koje su sprovedene u posmatranoj realizaciji predmeta, P_a je maksimalan broj poena aktivnosti a, a p_a broj poena koji je student osvojio u trenutno važećem pokušaju te aktivnosti. Ako student aktivnost nije realizovao, $p_a = 0$, ali se njen maksimalan broj poena P_a i dalje uračunava u imenilac. Ostvarenost nivoa stoga nije mera samo obima realizovanih aktivnosti, već objedinjuje dva činioca: koliki deo predviđenih aktivnosti je student realizovao i kakve je rezultate na njima postigao.

Razliku ilustruje sledeći hipotetički primer. Pretpostavimo da su za nivo N1 predviđena četiri testa od po 10 poena, jedan ocenjeni zadatak od 20 poena i projekat od 40 poena, ukupno 100 poena. Student A realizovao je sve aktivnosti i na svakoj ostvario 60% poena, odnosno ukupno 60 poena. Student B uradio je sva četiri testa i ocenjeni zadatak sa maksimalnim brojem poena, ali projekat nije realizovao, pa je takođe osvojio 60 poena. Oba studenta imaju istu ostvarenost nivoa N1 od 0,60, iako je njihova situacija pedagoški različita. Razliku otkrivaju ostali izlazi modela studenta. Kod studenta A lokalni dijagnostički indikatori pokušanih objekata učenja iznose 0,60 i nalaze se ispod praga 0,80 za nivo N1, što ukazuje na nedovoljno ovladavanje sadržajem sa kojim je radio. Kod studenta B pokušani objekti učenja nalaze se iznad praga, dok se objekti učenja koje proverava samo projekat evidentiraju kao nepokušavani obavezni sadržaj. Ostvarenost nivoa se zato ne tumači samostalno, već zajedno sa procenom ovladanosti i statusom pokušaja.

Razlikovanje tekućih i ranijih pokušaja posebno je važno zbog različite namene dva sloja modela. Raniji pokušaji zadržavaju se u sloju ovladanosti kompetencijama, jer njihov hronološki redosled može da pokaže napredovanje studenta. U sloju ostvarenosti nivoa koristi

se samo važeći rezultat aktivnosti, kako višestruki pokušaji iste aktivnosti ne bi veštački povećali ostvarenost nivoa.

Sloj ostvarenosti nivoa omogućava razlikovanje sledećih slučajeva:

- visoka ovladanost i visoka ostvarenost nivoa - student je realizovao veći deo predviđenih aktivnosti, na njima ostvario dobre rezultate i pokazao visok stepen savladanosti;
- visoka ovladanost i niska ostvarenost nivoa - student je bio uspešan na sadržajima sa kojima je radio, pa niska ostvarenost prvenstveno ukazuje na to da nije realizovao dovoljan deo aktivnosti predviđenih za taj nivo;
- niska ovladanost i visoka ostvarenost nivoa - student je realizovao veliki deo aktivnosti i osvojio veći deo predviđenih poena, ali dokazi za pojedine kompetencije, uključujući hronološki niz ranijih pokušaja, ne pokazuju dovoljno uspešno savladavanje;
- niska ovladanost i niska ostvarenost nivoa - na nisku ostvarenost utiču i nerealizovane aktivnosti i slabiji rezultati, a raspoloživi dokazi ukazuju na nedovoljnu ovladanost sadržajem.

Ovladanost kompetencijama i ostvarenost nivoa zato predstavljaju dve komplementarne, ali različite informacije. Prva opisuje demonstrirani nivo znanja i veština, dok druga opisuje koliki je deo poena predviđenih za aktivnosti određenog nivoa dubine student ostvario, bez obzira na to da li neostvareni poeni potiču od nerealizovanih aktivnosti ili od slabijih rezultata. Njihovim paralelnim prikazivanjem moguće je preciznije utvrditi da li je nepovoljan rezultat posledica teškoća u savladavanju sadržaja, nepotpuno realizovanih obaveza ili kombinacije oba faktora. Rezultati predstavljeni u odeljku 7.2.3 pokazuju da se ove dve vrednosti mogu značajno razlikovati, naročito na nivou N2, što opravdava njihovo odvojeno modelovanje.

6.5.2.3. Sloj analitike učenja i ponašajni tipovi studenata

Sloj analitike učenja opisuje način na koji student pristupa radu. U primenjenoj implementaciji ponašajni tipovi studenata identifikuju se k-means klasterovanjem na osnovu tri atributa: obima aktivnosti, broja aktivnih dana i udela ranijih pokušaja. Obim aktivnosti operacionalizovan je kao broj zapažanja formiranih u modelu studenta, a ne samo kao broj različitih testova, zadataka ili projekata. Zbog toga obim aktivnosti zavisi i od granularnosti mapiranja: ista aktivnost mapirana na tri objekta učenja doprinosi sa tri jedinice zapažanja, dok bi pri grubljem mapiranju na jedan objekat doprinosila sa jednom. Unutar jednog predmeta

mapiranje je isto za sve studente, a atributi se standardizuju i klasteruju zasebno za svaki predmet, pa su studenti istog predmeta upoređeni pod istim uslovima. Apsolutne vrednosti obima aktivnosti zato nisu neposredno uporedive između predmeta sa različitom granularnošću mapiranja. Broj aktivnih dana pokazuje vremensku raspoređenost angažovanja, dok udeo ranijih pokušaja pokazuje u kojoj meri student ponavlja i unapređuje već započete aktivnosti.

Pokazatelji ovladanosti kompetencijama i ostvarenosti nivoa namerno se ne koriste kao ulazni atributi klasterovanja. Njihovo uključivanje dovelo bi do cirkularnosti, jer bi tipovi studenata unapred bili definisani prema postignuću, a zatim bi se tim istim postignućem objašnjavali. Ovladanost i ostvarenost koriste se tek nakon klasterovanja, radi interpretacije i poređenja dobijenih grupa. Pre klasterovanja sva tri ponašajna atributa standardizuju se tako da imaju nultu srednju vrednost i jediničnu standardnu devijaciju. U primenjenoj implementaciji k-means algoritam koristi k-means++ inicijalizaciju, 20 ponovljenih inicijalizacija (n_init = 20) i fiksirano seme generatora slučajnih brojeva (random_state = 0), čime se obezbeđuje ponovljivost postupka. Broj klastera određuje se zasebno za svaki predmet na osnovu najviše vrednosti koeficijenta siluete u razmatranom opsegu od dva do pet klastera. Ovakav opseg omogućava poređenje više kandidatskih struktura, uz zadržavanje broja grupa koji ostaje pedagoški interpretabilan.

Robustnost izabranih rešenja dodatno se proverava ponovljenim poduzorkovanjem, poređenjem sa alternativnim metodama klasterovanja zasnovanim na gustini i analizom uticaja pojedinačnih ponašajnih atributa. Rezultati ovih provera prikazani su u odeljku 7.2.3.3.

Dodatno je proverena projektna odluka da se ponašajni tipovi formiraju nezavisno od pokazatelja postignuća. U tu svrhu osnovno klasterovanje, zasnovano samo na tri ponašajna atributa, poređeno je sa alternativnim varijantama u kojima su tim atributima dodavani pokazatelji ostvarenosti i ovladanosti. Zasebno su ispitane varijante sa dodatom ostvarenosti nivoa N1, ostvarenosti nivoa N2, istovremeno dodatim ostvarenostima nivoa N1 i N2 i prosečnom procenom ovladanosti kompetencijama. U svim varijantama zadržani su isti broj klastera izabran u osnovnoj ponašajnoj analizi, isti postupak standardizacije i ista konfiguracija k-means algoritma. Dodela studenata u alternativnim rešenjima poređena je sa osnovnim ponašajnim rešenjem pomoću prilagođenog Randovog indeksa (engl. *Adjusted Rand Index* (ARI)), dok je koeficijent siluete korišćen za procenu razdvojenosti dobijenih klastera. Na ovaj način provereno je da li uključivanje pokazatelja postignuća menja strukturu i semantiku ponašajnih tipova i da li donosi bolje razdvajanje klastera. Rezultati ove analize prikazani su u odeljku 7.2.3.3.

Nakon klasterovanja grupama se dodeljuju opisne oznake, kao što su istrajni, efikasni i minimalistički tip, prema njihovom položaju na kontinuumu angažovanja i karakteristikama načina rada. Ove oznake ne predstavljaju rangiranje studenata prema znanju niti kategorije uspešnih i neuspešnih studenata. Tip studenta opisuje kako student radi, dok slojevi ovladanosti i ostvarenosti opisuju rezultate njegovog rada. Dva studenta istog ponašajnog tipa mogu imati različite profile ovladanosti, kao što različiti načini rada mogu dovesti do uporedivih rezultata. Zbog toga se ponašajni tip koristi kao kontekst za predstavljanje i obrazloženje preporuke, ali ne određuje procenu znanja niti izbor i redosled preporučenog sadržaja.

6.5.2.4. Tok obrade i izlazi modela studenta

Operativni tok obrade podataka u modelu studenta sastoji se od četiri koraka:

- verifikovani rezultati aktivnosti mapiraju se na odgovarajuće objekte učenja, kompetencije, ishode učenja i nivoe dubine pomoću ontološkog modela nastavnog sadržaja;
- za svakog studenta i svaku kombinaciju predmet-kompetencija predmeta-nivo dubine formiraju se hronološki nizovi zapažanja, na osnovu kojih se BKT metodom procenjuje ovladanost;
- trenutno važeći pokušaji agregiraju se prema nivoima dubine radi izračunavanja ostvarenosti nivoa;
- ponašajni atributi koriste se za identifikovanje tipova studenata, dok se vrednosti ovladanosti i ostvarenosti naknadno koriste za tumačenje dobijenih tipova.

Izlazi ovog procesa su:

- procena ovladanosti za svaku kombinaciju student-predmet-kompetencija predmeta-nivo dubine;
- procene na nivou pojedinačnih objekata učenja, zajedno sa informacijom o tome da li je odgovarajući objekat pokušavan;
- vrednosti ostvarenosti nivoa N1, N2 i, kada postoje podaci, N3;
- oznaka ponašajnog tipa studenta.

Ovi izlazi prosleđuju se adaptivnom sloju, koji na osnovu procena ovladanosti, statusa pokušaja, nivoa dubine i relacija ontološkog modela identifikuje sadržaje kojima je potrebna dodatna pažnja i formira preporuke za dalje učenje. Pokušani objekti čija je procena niža od odgovarajućeg praga predstavljaju slabe tačke u ovladanosti, dok se nepokušani obavezni objekti nivoa N1 posebno označavaju kao nedostajući sadržaji visokog prioriteta. Postupak izbora, uređivanja i objašnjavanja preporučenih objekata učenja nije deo modela studenta i detaljno je opisan u odeljku 7.3.

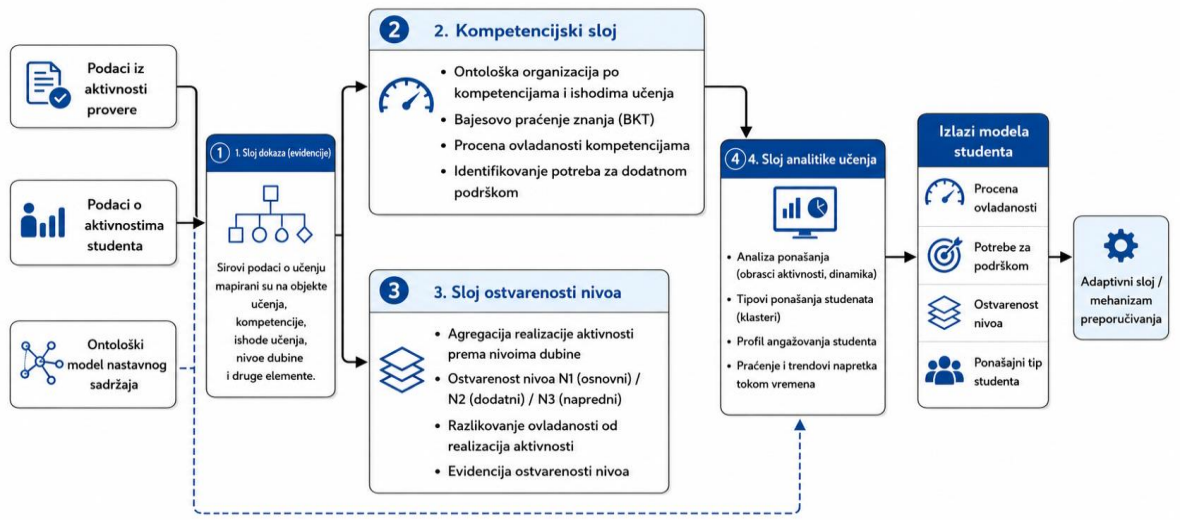

Slika 29. Tok obrade podataka u modelu studenta: od mapiranja dokaza iz aktivnosti provere do procene ovladanosti, ostvarenosti nivoa i identifikovanja ponašajnog tipa studenta.

Tok prikazan na Slici 29 pokazuje da tri sloja modela pružaju komplementarne informacije i da nijedan od njih samostalno ne daje potpunu sliku studenta. Sloj ovladanosti prati promene u procenjenom znanju i kompetencijama, sloj ostvarenosti pokazuje koliki je deo predviđenih poena student ostvario, dok sloj analitike učenja opisuje ponašajni obrazac kojim je student došao do datog stanja.

Njihovim povezivanjem formira se interpretabilan model studenta koji može da podrži identifikovanje slabih tačaka i generisanje personalizovanih preporuka, uz očuvanje jasne razlike između stanja znanja, izvršenosti aktivnosti i načina angažovanja.

6.5.3. Arhitektura modela razvijenog u trećoj fazi

Model razvijen u trećoj fazi istraživanja ne predstavlja izolovan algoritamski postupak, već deo integrisane arhitekture u kojoj se strukturirani nastavni sadržaj, podaci o aktivnostima i proverama znanja i veština, model studenta i adaptivni mehanizam povezuju u jedinstven tok podataka [20]. U konkretnoj realizaciji arhitektura je organizovana kroz tri međusobno

povezana sistema: institucionalni sistem za učenje (ILS), sistem za upravljanje obrazovanjem (EMS) i OBSLO, kao ontološki zasnovan sloj za organizaciju sadržaja, modelovanje studenta i adaptivnu podršku. Komunikacija između sistema ostvaruje se preko servisnih, RESTful interfejsa, čime se zadržava labava povezanost komponenti i mogućnost njihove nezavisne izmene ili zamene. Njihov međusobni odnos prikazan je na Slici 30.

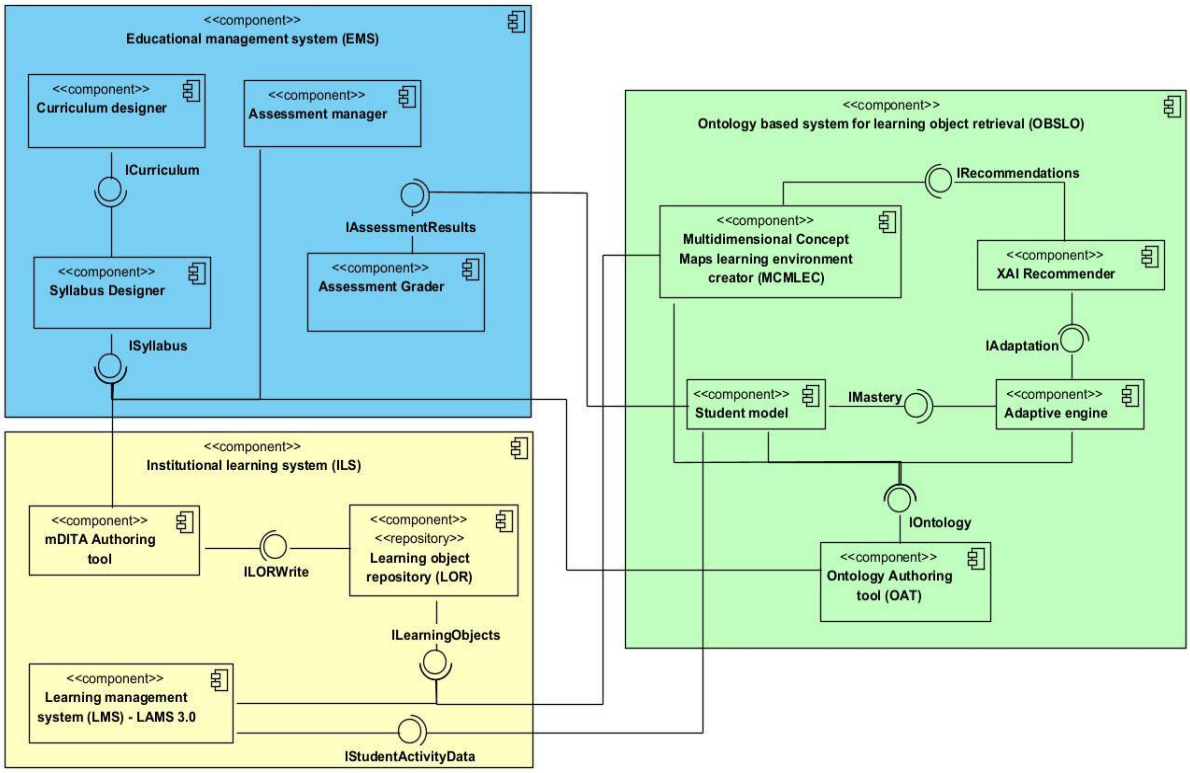

Slika 30. Komponentna arhitektura integrisanog modela u trećoj fazi: institucionalni sistem za učenje, sistem za upravljanje obrazovanjem i OBSLO sa modelom studenta, adaptivnim mehanizmom i komponentom za objašnjive preporuke.

Institucionalni sistem za učenje (ILS) obezbeđuje regularno okruženje u kojem student pristupa nastavnim materijalima i realizuje aktivnosti učenja. Nastavni sadržaji kreiraju se pomoću mDITA alata, strukturiraju kao objekti učenja i čuvaju u repozitorijumu objekata učenja (LOR), dok sistem za upravljanje učenjem omogućava njihovu isporuku studentima i prikupljanje podataka o studentskim aktivnostima. DITA pri tome obezbeđuje tehničku modularnost i ponovnu upotrebljivost objekata učenja, dok ontološki model definiše njihove semantičke odnose prema konceptima, ishodima učenja, kompetencijama i drugim objektima.

Sistem za upravljanje obrazovanjem (EMS) obezbeđuje podatke o kurikulumu, silabusu i proverama znanja i veština. Na nivou kurikuluma definišu se širi ciljevi, ishodi i kompetencije, dok se pri projektovanju konkretnog predmeta oni operacionalizuju kroz kompetencije predmeta, teme, ishode i pripadajuće objekte učenja. Komponente za upravljanje i ocenjivanje

provera obezbeđuju informacije o aktivnostima provere, pokušajima studenata i ostvarenim rezultatima. Veza VERIFY ne predstavlja zasebnu komponentu za proveru, već semantički povezuje ove dokaze sa odgovarajućim elementima modela nastavnog sadržaja.

OBSLO predstavlja prošireni ontološki i adaptivni sloj arhitekture. Alat za izradu ontologije (OAT) definiše dodatne semantičke relacije između nastavnih elemenata, uključujući relacije preduslova, redosleda i veze između osnovnih i naprednih sadržaja, dok MCMLEC omogućava njihov prikaz kroz personalizovani ontološki prostor za učenje. Model studenta koristi verifikovane rezultate provera i podatke o studentskim aktivnostima da bi formirao sekvencijalne procene ovladanosti kompetencijama, pokazatelje ostvarenosti nivoa, procene na nivou pojedinačnih objekata učenja i ponašajne tipove studenata. Ove dimenzije ostaju konceptualno razdvojene: procena ovladanosti opisuje demonstrirano stanje kompetencije, ostvarenost nivoa udeo ostvarenih poena u aktivnostima odgovarajuće dubine, dok ponašajni tip opisuje način angažovanja studenta.

Izlazi modela studenta prosleđuju se adaptivnom mehanizmu, koji ih povezuje sa ontološkim relacijama radi određivanja i uređivanja sadržaja preporučenih za dalje učenje. Adaptacija se pri tome ostvaruje na dva komplementarna nivoa. Na nivou pojedinačnog objekta učenja izbor sadržaja prvenstveno zavisi od procenjene ovladanosti, statusa pokušaja, nivoa dubine i ontoloških odnosa. Na nivou strategije podrške ponašajni tip služi kao kontekst za predstavljanje i obrazloženje preporuke, ali ne određuje koji će objekat učenja biti preporučen niti njihov redosled (odeljak 7.3.1).

Formiranje preporuke i formiranje njenog objašnjenja predstavljaju odvojene funkcije. Adaptivni mehanizam određuje objekte učenja i njihov redosled, dok komponenta za objašnjive preporuke koristi već formirane rezultate modela studenta, pravila ponašajnih tipova, pragove ovladanosti i ontološke relacije kako bi studentu prikazala razlog preporuke. Veliki jezički model, kada se koristi, pripada samo završnom sloju jezičkog formulisanja već strukturiranog obrazloženja i ne određuje slabe tačke, ne bira objekte učenja i ne menja njihov redosled. Detaljna pravila formiranja i objašnjavanja preporuka prikazana su u odeljku 7.3.

Važno je razlikovati arhitekturu originalnog OBSLO artefakta prikazanu u odeljku 5.2 od njegove proširene uloge u konačnoj arhitekturi. Slika 12 prikazuje OBSLO razvijen u ranijoj fazi istraživanja, čije su osnovne funkcije bile izrada ontologije, vizualizacija kroz MCM i povezivanje sa postojećim sistemima za e-učenje [14]. U trećoj fazi ova osnova nije zamenjena, već je proširena modelom studenta, adaptivnim mehanizmom i komponentom za objašnjive

preporuke, što je prikazano na Slici 30. Na taj način konačna arhitektura zadržava ranije razvijene i evaluirane komponente, ali ih uključuje u širi proces koji povezuje dokaze o učenju sa procenom stanja studenta i personalizovanom preporukom.

Prikazana arhitektura predstavlja konačnu arhitekturnu instancu razvijenu u trećoj fazi istraživanja i kumulativno objedinjuje artefakte i projektne odluke nastale tokom prethodnih iteracija. U skladu sa primenjenom metodologijom nauke o projektovanju, razvoj se odvijao iterativno, pri čemu su nalazi i ograničenja utvrđeni evaluacijom svake prethodne faze korišćeni kao projektni zahtevi za narednu fazu. U prvoj fazi ispitane su mogućnosti predikcije studentskog uspeha i identifikovani su pokazatelji relevantni za modelovanje studenata. Druga faza proširila je ovo znanje analizom obrazaca studentskog ponašanja i ukazala na ograničenja predstavljanja studenta samo predikovanom kategorijom ili pripadnošću klasteru. Na osnovu saznanja stečenih u prethodne dve faze, u trećoj fazi razvijen je višeslojni model studenta i ostvareno je povezivanje podataka o proverama znanja i veština sa kompetencijskim modelom nastavnog sadržaja i adaptivnim preporukama. Prikazana arhitektura zato predstavlja kumulativni rezultat iterativnog istraživačkog procesa, u kojem je znanje stečeno evaluacijom svakog prethodnog artefakta usmeravalo razvoj složenijeg i sadržajno preciznijeg rešenja u narednoj fazi.

Sa stanovišta ponovljivosti implementacije, ključne projektne odluke konačnog modela eksplicitno su definisane u prethodnim odeljcima. Za sekvencijalni sloj navedeni su jedinica modelovanja, način formiranja hronoloških nizova, postupak procene BKT parametara, ograničenja parametara, način tretiranja kontinuiranih opservacija, pragovi ovladanosti i pravila ponderisanja dokaza. Za ponašajni sloj definisani su ulazni atributi, njihova standardizacija, opseg broja klastera i konfiguracija k-means algoritma. Adaptivni postupak zasniva se na eksplicitnim pravilima za razlikovanje pokušavanog i nepokušavanog obaveznog sadržaja i na dokumentovanim OR i BA relacijama, dok su konfiguracija generativnog sloja, struktura njegovog ulaza, pravila prihvatljivosti izlaza i korišćeni prompt takođe dokumentovani. Time su obezbeđene informacije potrebne za ponovno sprovođenje osnovnog analitičkog i adaptivnog postupka nad odgovarajuće strukturiranim podacima. Potpuna nezavisna reprodukcija konkretnih numeričkih rezultata, međutim, zahteva i pristup izvornim obrazovnim podacima, konkretnim mapiranjima aktivnosti na objekte učenja i kompetencije i instancama ontologija korišćenih za predmete SE201 i CS202. Zbog prirode institucionalnih obrazovnih podataka, u okviru disertacije se reproducibilnost zato prvenstveno obezbeđuje detaljnim opisom postupka, parametara i pravila, dok nezavisno ponavljanje nad novim

podacima i novom ontološkom instancom predstavlja jači oblik spoljašnje reprodukcije koji ostaje predmet narednih istraživanja.

Poglavlje 7

7. Rezultati i diskusija

U ovom poglavlju prikazani su rezultati empirijskih evaluacija sprovedenih u okviru disertacije, sa ciljem provere razvijenih modela, metoda i softverskih artefakata u skladu sa njihovom namenom i vrstom raspoloživih empirijskih dokaza. Analiza rezultata organizovana je u tri ključne celine:

- **Evaluacija modela nastavnih materijala**, usmerena na praktičnu primenu ontološki organizovanog nastavnog sadržaja, način korišćenja multidimenzionalnih konceptualnih mapa, studentske putanje kroz objekte učenja i korisničko iskustvo. Evaluacija obuhvata iterativnu analizu modela, deskriptivno poređenje OBSLO i LAMS okruženja i povratne informacije korisnika, pri čemu se uočene razlike između okruženja ne tumače kao kontrolisani dokaz uzročnog efekta.
- **Evaluacija modela studenata**, usmerena na proveru različitih načina predstavljanja stanja i ponašanja studenta i njihove uloge u razvoju personalizovanog učenja. Istraživanje je sprovedeno kroz tri faze:
    - Prva faza ispitivala je mogućnost klasifikacije konačnog ishoda studenta na predmetu i povezanost raspoloživih atributa aktivnosti i postignuća sa tim ishodom primenom metoda nadgledanog učenja.
    - Druga faza analizirala je obrasce studentskog angažovanja primenom klasterovanja, sa ciljem identifikovanja grupa studenata sa sličnim obrascima rada u posmatranim skupovima podataka.
    - Treća faza fokusirala se na sekvencijalnu procenu ovladanosti kompetencijama na različitim nivoima dubine primenom BKT-a, dopunjenu odvojenim pokazateljima ostvarenosti aktivnosti i ponašajnim tipovima studenata.
- **Evaluacija adaptivnog modela** kao završnog sloja integrisanog pristupa, kroz povezivanje izlaza modela studenta sa ontološkom strukturom nastavnog sadržaja,

formiranje individualnih uređenih preporuka i proveru njihove strukturne sledljivosti i načina predstavljanja korisniku.

Svaka od ovih sekcija povezana je sa ciljevima istraživanja i obuhvata detaljne analize koje omogućavaju sagledavanje prednosti i ograničenja predloženih pristupa. Na osnovu rezultata, formulisane su preporuke za dalja unapređenja modela, uzimajući u obzir povratne informacije korisnika i uočene izazove u implementaciji sistema.

7.1. Evaluacija modela nastavnih materijala

Evaluacija modela nastavnih materijala implementiranog kroz OBSLO sistem sprovedena je sa ciljem da se ispita praktična primena ontološki organizovanog nastavnog sadržaja i multidimenzionalnih konceptualnih mapa u stvarnom nastavnom okruženju. Poseban akcenat stavljen je na način na koji studenti pristupaju i koriste objekte učenja, putanje koje formiraju kroz nelinearno organizovan sadržaj, uspešnost u rešavanju nastavnih zadataka i njihovo korisničko iskustvo. Dobijeni podaci korišćeni su i kao empirijska povratna informacija za razmatranje izmena ontoloških relacija i organizacije nastavnih materijala.

OBSLO omogućava dinamičko generisanje MCM okruženja iz definisanog ontološkog modela i nelinearan pristup nastavnim sadržajima prema njihovim atributima i semantičkim relacijama. U ovoj fazi personalizacija se odnosi prvenstveno na mogućnost formiranja i korišćenja različitih putanja kroz ontološki organizovan prostor za učenje; dinamičko određivanje individualnih potreba na osnovu višeslojnog modela studenta i automatsko formiranje ontološki uređene preporuke razvijeni su u kasnijoj fazi istraživanja. Evaluacija OBSLO-a izvedena je kroz tri ključna aspekta:

1. **Analiza podataka o učenju studenata -** bazirana je na podacima studenata koji su koristili OBSLO sistem u okviru predmeta Baze podataka. Ova analiza omogućila je identifikovanje obrazaca korišćenja nastavnih sadržaja i pokazatelja povezanih sa napredovanjem studenata, koji su mogli da posluže kao empirijska osnova za razmatranje izmena ontoloških relacija i organizacije nastavnih materijala. Ova analiza uključivala je:
    - Praćenje korišćenih objekata učenja (OU) - Identifikovani su svi edukativni resursi koje su studenti koristili, uključujući digitalne materijale, interaktivne module i dodatne sadržaje.

- Merenje vremena provedenog na učenju - Analizirano je koliko vremena su studenti provodili na pojedinačnim konceptima i nastavnim resursima, što omogućava razumevanje njihovog nivoa angažovanja.
- Sekvencijalna analiza obrazaca učenja - Proučeni su putevi kojima su studenti prolazili kroz materijale, što omogućava razumevanje obrazovnih preferencija i potencijalnih problema u učenju.

2. **Analiza generisanih izveštaja o studentskim aktivnostima i putanjama učenja** - OBSLO uključuje komponentu Assessment Reports (AR), koja koristi podatke zabeležene tokom rada studenata u MCMLEC okruženju za analizu korišćenih objekata učenja, putanja kroz nastavne sadržaje i uspešnosti u rešavanju zadataka. Nastavnik može da pregleda generisane izveštaje i da njihove rezultate koristi kao dodatni izvor informacija pri razmatranju izmena ontologije i nastavnih materijala. Evaluacija je u ovom delu obuhvatila:
    - Analizu putanja učenja studenata - na osnovu zabeleženog redosleda korišćenja objekata učenja analizirano je kojim sadržajima su studenti pristupali tokom rešavanja zadataka i koje su alternativne putanje koristili.
    - Identifikovanje mogućih nedostajućih veza u ontologiji - obrasci korišćenja sadržaja ukazivali su na slučajeve u kojima su studenti koristili alternativne objekte učenja ili koncepte koji prethodno nisu bili povezani odgovarajućom ontološkom relacijom. Takvi nalazi predstavljali su signal nastavniku za semantičku proveru i eventualnu modifikaciju ontologije.
    - Iterativno unapređenje ontologije i nastavnih materijala - na osnovu analize zabeleženih putanja i korišćenja sadržaja nastavnik je mogao da razmotri dodavanje ili izmenu ontoloških relacija i odgovarajuće unapređenje organizacije nastavnih materijala.
3. **Procena korisničkog zadovoljstva** - Korisničko iskustvo je evaluirano kroz anketne upitnike i povratne informacije prikupljene od nastavnika i studenata koji su koristili OBSLO sistem. Ključni aspekti analize obuhvatali su:
    - Percepciju korisnosti sistema - Studenti su ocenili koliko im je OBSLO pomogao u rešavanju zadataka i razumevanju nastavnog sadržaja.
    - Identifikaciju problema i predloga za poboljšanje - Studenti su ukazali na potencijalne prepreke i oblasti u kojima bi sistem mogao biti dodatno unapređen

Evaluacija je izvedena u okviru nastavnog procesa, gde su studenti koristili OBSLO sistem kako bi pristupili nastavnim materijalima, istraživali povezane koncepte kroz MCM vizualizaciju i rešavali zadatke povezane sa nastavnim sadržajem. Nastavnici su imali mogućnost da u realnom vremenu prate putanje učenja studenata, analiziraju njihov napredak i prilagođavaju ontologiju na osnovu podataka generisanih tokom interakcije sa sistemom.

Podaci su prikupljani kroz dva glavna izvora:

1) Automatska analiza interakcija studenata sa sistemom
    - Beleženje korišćenih objekata učenja (OU), uključujući redosled i učestalost pristupa materijalima.
    - Evidencija registrovanog vremena rada sa interaktivnim sadržajem objekata učenja dostupnim kroz sistem.
    - Praćenje izbora između osnovnih i naprednih verzija sadržaja, omogućavajući analizu koje strukture nastavnih materijala su najpogodnije za studente.
    - Analiza uspešnosti studenata na zadacima i testovima, kako bi se utvrdila povezanost između načina učenja i postignutih rezultata.
2) Povratne informacije nastavnika i studenata
    - Ankete prikupljene od studenata kako bi se evaluirala korisnost sistema, preglednost MCM vizualizacija i mogućnost lakšeg razumevanja nastavnih sadržaja.
    - Intervjui sa nastavnicima radi analize kako sistem doprinosi optimizaciji nastavnih materijala i evaluaciji studentskog napretka.
    - Analiza personalizovanih putanja učenja, koja omogućava nastavnicima da sagledaju kako studenti koriste dostupne resurse i koje sekvence učenja su najefikasnije.

Prilikom analize podataka iz sistema, posebna pažnja posvećena je:

- Poređenju personalizovanih putanja učenja studenata u različitim domenima nastavnih materijala.
- Identifikaciji obrazaca u učenju koji mogu doprineti unapređenju ontološkog modela.
- Analizi odnosa između zabeleženih putanja kroz objekte učenja i uspešnosti u rešavanju zadataka, radi uočavanja obrazaca korišćenja sadržaja koji mogu biti relevantni za dalje unapređenje ontološkog modela.

Na osnovu dobijenih podataka, nastavnici su ažurirali ontologiju domena i modifikovali nastavne materijale kako bi dodatno poboljšali organizaciju sadržaja i omogućili još bolje personalizovane putanje učenja. Kako bi se evaluirao ontološki model nastavnih materijala vizuelizovan putem multidimenzionalnih konceptualnih mapa (MCM-ova), sistem OBSLO ocenjen je od strane nastavnika i studenata u dve iteracije. U narednim sekcijama biće predstavljeni konkretni rezultati evaluacije, uključujući analizu podataka prikupljenih kroz sistem i povratne informacije korisnika.

7.1.1. Prva iteracija evaluacije modela nastavnih sadržaja

U okviru prve iteracije evaluacije modela nastavnih materijala, nastavnici su koristili OAT komponentu OBSLO sistema za razvoj ontologije predmeta, dok su studenti pristupali zadacima i obrazovnim materijalima putem MCMLEC okruženja, koristeći MCM vizualizaciju za navigaciju kroz nastavne sadržaje. Ključni cilj prve iteracije bio je da se proceni kako se upotreba ontološkog modela i multidimenzionalnih konceptualnih mapa odražava na učinkovitost učenja, navigaciju kroz nastavne materijale i angažovanje studenata.

Rezultati su upoređeni sa iskustvima studenata iz prethodne školske godine, koji su u okviru istog predmeta *Baze podataka* koristili LAMS sistem, koji je pružao linearnu sekvencijalnu organizaciju nastavnih materijala. Oba razreda koristila su iste nastavne materijale, uključujući tekstualna uputstva, video zapise i primere, ali se način pretrage i vizualizacije obrazovnih sadržaja značajno razlikovao. Studenti koji su koristili OBSLO sistem imali su pristup objektima učenja (OU) kroz MCM strukturu, uz dodatne dinamičke zadatke i automatsku evaluaciju studentskih odgovora. Nasuprot tome, u LAMS sistemu obrazovni materijali su prikazivani isključivo u linearnom redosledu, a zadaci su bili predstavljeni tek nakon završetka lekcije, bez mogućnosti automatskog ocenjivanja. Nastavni zadaci u obe grupe su se fokusirali na iste SQL klauzule i imali su postepenu progresiju od osnovnih do naprednih problema, ali su zadaci u OBSLO sistemu bili dinamički generisani i povezani sa odgovarajućim konceptima ontološkog modela. To je studentima omogućilo interaktivno rešavanje problema uz pregled relevantnih nastavnih materijala u realnom vremenu. S druge strane, studenti u LAMS okruženju morali su samostalno pronalaziti relevantne resurse, što je moglo dovesti do veće kognitivne opterećenosti i sporijeg pristupa ključnim informacijama.

Kako bi se povećala uporedivost evaluacije, zadaci u OBSLO i LAMS sistemima odabrani su tako da obuhvate iste ključne koncepte i ishode učenja i da budu uporedivog nivoa težine.

Primeri zadataka dodeljenih studentima u oba sistema prikazani su u Tabeli 6 i pokazuju manje razlike u formulaciji uz očuvanje zajedničkog nastavnog fokusa. Ipak, dve grupe nisu koristile potpuno identične zadatke niti su pripadale istoj realizaciji predmeta, zbog čega poređenje dobijenih stopa uspešnosti ima deskriptivni karakter i ne predstavlja osnovu za zaključak o uzročnom efektu OBSLO sistema na ishode učenja.

Ova evaluacija imala je tri glavna cilja:

1. Analizirati uspešnost studenata u navigaciji kroz nastavne materijale korišćenjem ontološkog modela i multidimenzionalnih konceptualnih mapa u OBSLO sistemu.
2. Uporediti uspešnost rešavanja zadataka i način korišćenja nastavnih materijala u OBSLO i LAMS okruženju, bez pripisivanja uočenih razlika izolovanom uzročnom efektu sistema.
3. Sprovesti analizu zadovoljstva studenata OBSLO sistemom i prikupiti povratne informacije o percipiranoj korisnosti sistema, pronalaženju relevantnih nastavnih materijala i iskustvu rada sa ontološki organizovanim prostorom za učenje.

Ukupno 50 studenata koristilo je OBSLO sistem, dok je 63 studenta koristilo LAMS sistem u prethodnoj iteraciji predmeta. Studenti iz OBSLO grupe su na kraju evaluacije popunili anketu o korisničkom iskustvu, kako bi se prikupili kvantitativni i kvalitativni podaci o njihovom zadovoljstvu načinom organizacije nastavnog sadržaja, lakoćom navigacije kroz MCM strukture i korisnošću automatskog ocenjivanja zadataka.

Tabela 6. Primeri zadataka dodeljenih OBSLO (SA1-SA3) i LAMS (HQ1-HQ3) grupama studenata.

Pitanja	LAMS Zadaci (HQ)	OBSLO Zadaci (SA)
HQ1/SA1:	a) Kreirajte tabele DOCTOR, PATIENT, DISEASE i DIAGNOSIS koje odgovaraju sledećim relacijama: - DOCTOR (#DoctorID, FirstName, LastName, Specialization) - PATIENT (#PatientID, FirstName, LastName, Address, Phone, Age, DoctorID) - DISEASE (#DiseaseID, Name, Description) - DIAGNOSIS (DiagnosisID, PatientID, DiseaseID, DiagnosisDate) b) Ubacite bar jedan red u svaku tabelu.	a) Kreirajte tabele CUSTOMER, ORDERS, ORDER_ITEMS i PRODUCTS koje odgovaraju sledećim relacijama: - CUSTOMERS (#CustomerID, FirstName, LastName, City, Country, Phone) - ORDERS (#OrderID, OrderDate, OrderNumber, CustomerID, TotalAmount) - PRODUCTS (#ProductID, ProductName, UnitPrice, IsDiscontinued) - ORDER_ITEMS (OrderItemsID, OrderID, ProductID, Quantity, TotalAmountPerItem) b) Ubacite bar jedan red u svaku tabelu.
HQ2/SA2:	Prikažite sve pacijente sa imenom i prezimenom doktora čija je starost veća od 25 godina.	Prikažite sve porudžbine sa imenom i prezimenom kupca čiji je ukupni iznos veći od 5000.
HQ3/SA3:	Prikažite pacijente bez dijagnoze. Lista treba da bude sortirana uzlazno po vrednosti imena pacijenta (od Z do A).	Prikažite kupce koji nisu obavili porudžbine (ukupni iznos je nula). Lista treba da bude sortirana uzlazno po vrednosti imena kupca (od A do Z).

Prva iteracija evaluacije sistema OBSLO obuhvatila je sledeće analize:

1. Uporedna analiza korišćenja OBSLO i LAMS sistema (poglavlje 7.1.2.1.), koja uključuje analizu učinka studenata na istim tipovima zadataka, vreme potrebno za rešavanje problema i broj korišćenih objekata učenja.
2. Analiza zadovoljstva studenata korišćenjem OBSLO sistema (poglavlje 7.1.2.2), koja se oslanja na ankete i intervjue sa korisnicima kako bi se ispitalo kako studenti procenjuju korisnost sistema, njegovu podršku pri rešavanju zadataka, mogućnost pronalaženja relevantnih nastavnih sadržaja i ukupno korisničko iskustvo.

U narednim sekcijama biće detaljno prikazani rezultati ovih analiza, uključujući statističke podatke o uspešnosti studenata, njihovu percepciju korišćenja sistema i mogućnosti daljeg poboljšanja OBSLO modela na osnovu prikupljenih podataka.

7.1.1.1. Uporedna analiza korišćenja OBSLO i LAMS sistema

U ovom poglavlju data je detaljna analiza i poređenje stope uspešnosti studenata u izvršavanju dodeljenih zadataka u dva različita sistema za učenje: LAMS i OBSLO. Rezultati prikazani u ovom pododeljku (Tabele 6-8) potiču iz prve iteracije evaluacije ontološkog modela i MCM vizuelizacije, sprovedene na predmetu Baze podataka i objavljene u radu autora [14]. U disertaciji se navode kao prva, ranije objavljena faza empirijske provere, koja je prethodila razvoju kompetencijskog proširenja, modela studenta i adaptivnog mehanizma. Iako su rezultati prikupljeni iz dve odvojene grupe studenata koje su imale različite nastavnike, za potrebe ove analize pažljivo su odabrani zadaci koji su bili slične prirode i ekvivalentnog nivoa težine, kako bi se obezbedilo što objektivnije i preciznije poređenje.

Dodeljeni zadaci su studentima predstavljeni u rastućem redosledu težine, počevši od jednostavnijih i osnovnih zadataka, pa sve do složenijih problema koji zahtevaju dublje razumevanje gradiva i primenu složenijih koncepata. Tabela 7 prikazuje broj studenata koji su uspešno završili zadatke (označeni oznakama koje počinju na SA) i broj onih koji su tačno rešili zadatke unutar OBSLO sistema. Jedan od najuočljivijih rezultata analize jeste činjenica da je procenat studenata koji su uspešno završili dodeljene zadatke u OBSLO sistemu bio iznad 75%. Međutim, kako se složenost zadataka povećavala, primećena je tendencija smanjenja broja studenata koji su uspevali da ih završe, što sugeriše da je rešavanje naprednijih zadataka predstavljalo ozbiljan izazov za studente.

Tabela 7. Broj studenata koji su koristili OBSLO, završili zadatke i tačno ih rešili.

Zadaci	Broj studenata koji su završili zadatak	Broj studenata koji su tačno rešili zadatak	Procenat tačno rešenih zadataka
SA1	37	33	89,19%
SA2	29	21	72,41%
SA3	25	16	64%
Ukupno	N/A	N/A	75,20%

Sa druge strane, rezultati prikazani u Tabeli 8 pokazuju da se procenat studenata koji su tačno rešili dodeljene zadatke u LAMS sistemu kretao između 21,82% i 68,29%. U OBSLO grupi procenat tačno rešenih zadataka kretao se od 64% do 89,19%. Kada se posmatraju zbirni deskriptivni pokazatelji, ukupna stopa tačno rešenih zadataka iznosila je 38,93% u LAMS grupi i 75,20% u OBSLO grupi. U analiziranoj realizaciji, dakle, studenti koji su koristili OBSLO ostvarili su višu deskriptivnu stopu uspešnosti na posmatranim zadacima. Međutim, ovu razliku nije opravdano tumačiti kao izolovan uzročni efekat OBSLO sistema. Podaci su prikupljeni u različitim realizacijama predmeta i od različitih grupa studenata, sa različitim nastavnicima, dok su zadaci bili slični prema nastavnom ishodu i nivou težine, ali nisu bili potpuno identični. Rezultati zato predstavljaju indikativan nalaz o funkcionisanju ontološki organizovanog prostora za učenje u realnom nastavnom okruženju, ali ne omogućavaju zaključak da je upravo korišćenje OBSLO-a uzrokovalo višu uspešnost studenata.

Tabela 8. Broj studenata koji su koristili LAMS, završili domaće zadatke i tačno ih rešili.

Zadaci	Broj studenata koji su završili domaći zadatak	Broj studenata koji su tačno rešili domaći zadatak	Procenat tačno rešenih domaćih zadataka
HQ1	60	16	26,67%
HQ2	55	12	21,82%
HQ3	41	28	68,29%
Ukupno	N/A	N/A	38,93%

Kako bi se detaljno analizirala efikasnost OBSLO sistema u poređenju sa LAMS-om, posebno je ispitano vreme koje su studenti proveli na svakom relevantnom OU-u (objektu učenja). Tabela 9 pruža pregled registrovanog vremena provedenog na interaktivnim objektima učenja u oba sistema.

OBSLO i LAMS razlikovali su se prema načinu pristupa nastavnim sadržajima. U OBSLO-u multidimenzionalne konceptualne mape omogućavale su studentima nelinearnu navigaciju do koncepata i objekata učenja koje su smatrali relevantnim za rešavanje konkretnog zadatka, dok je LAMS sadržaj prikazivao u linearnoj sekvenci. Registrovano vreme na pojedinim interaktivnim objektima učenja bilo je u većem broju slučajeva duže u OBSLO okruženju.

Ovakav obrazac je kompatibilan sa pretpostavkom da su studenti koristili mogućnost neposrednog pristupa relevantnim sadržajima i njihovog ponovnog pregledanja tokom rešavanja zadataka. Međutim, na osnovu podataka o vremenu nije moguće utvrditi uzrok uočene razlike niti zaključiti da duže vreme provedeno na interaktivnim sadržajima samo po sebi predstavlja veći angažman, dublje učenje ili kvalitetnije stečeno znanje.

Tabela 9. Registrovano vreme rada sa interaktivnim sadržajem objekata učenja (u sekundama po studentu).

OU povezan sa zadatkom	LAMS (sekundi/student)	OBSLO (sekundi/student)
Kreiranje tabele	42	226
Izmena tabele	14	6
Aritmetički operatori	9	14
Logički operatori	7	18
Relacioni operatori	13	64
LIKE operator	11	54
ORDER BY	15	192
GROUP BY HAVING	15	29
INSERT	10	148
Join tabela	59	61

Vredno je napomenuti da ukupno vreme koje su studenti proveli na učenju u oba sistema obuhvata isključivo interaktivni deo lekcija dostupnih putem interneta. U oba slučaja, studentima je bila dostupna opcija da preuzmu lekcije u PDF formatu, ali podaci prikazani u Tabeli 9 ne uključuju informacije o vremenu provedenom na offline učenju iz ovih preuzetih dokumenata.

Ovo ograničenje je važno za tumačenje rezultata iz Tabele 8. Dostupni logovi omogućavaju poređenje vremena provedenog na interaktivnim objektima učenja, ali ne obuhvataju vreme provedeno na preuzetim PDF lekcijama, drugim izvorima na Internetu ili učenju izvan sistema. Zbog toga se na osnovu prikazanih podataka ne može pouzdano rekonstruisati ukupno vreme učenja niti utvrditi da li je razlika u registrovanom vremenu posledica načina navigacije, korišćenja PDF materijala, dodatnih izvora ili drugih razlika između dve grupe. Rezultati zato prvenstveno ukazuju na različit obrazac korišćenja interaktivnog dela nastavnog okruženja, dok bi za izvođenje zaključaka o kvalitetu učenja, dubini razumevanja ili obrazovnom efektu bila potrebna kontrolisanija evaluacija sa potpunijim podacima o aktivnostima studenata.

7.1.1.2. Analiza zadovoljstva studenata korišćenjem OBSLO-a

Ovo poglavlje prikazuje rezultate analize zadovoljstva studenata prilikom korišćenja OBSLO sistema, sprovedene putem upitnika koji je imao za cilj identifikaciju pozitivnih i negativnih aspekata sistema, kao i faktora koji podstiču studente da koriste interaktivne nastavne materijale i rešavaju probleme u njegovom okviru. Upitnik je bio osmišljen sa svrhom da pruži uvid u korisničko iskustvo studenata, ali i da identifikuje moguće oblasti za unapređenje OBSLO-a. Poseban fokus stavljen je na motivacione faktore, tj. šta tačno podstiče studente da se angažuju u učenju kroz ovaj sistem, kao i koje su potencijalne prepreke ili izazovi sa kojima su se susretali.

Podaci prikupljeni putem upitnika, koji su prikazani u Tabeli 10, ukazuju na sledeće ključne nalaze:

1. Korisnost OBSLO-a u rešavanju zadataka - Studenti su generalno pozitivno ocenili u kojoj meri im je materijal predstavljen kroz OBSLO pomogao u rešavanju zadataka, sa prosečnom ocenom 3,38 ± 1,27.
2. Doprinos postizanju ishoda učenja - Studenti su takođe pozitivno ocenili koliko im je rad u OBSLO-u pomogao u postizanju akademskih ciljeva, sa prosečnom ocenom 3,38 ± 0,95.
3. Korišćenje dodatnih izvora van OBSLO-a - Interesantan nalaz je da su studenti često koristili dodatne nastavne materijale sa Interneta, koji nisu bili direktno obezbeđeni u okviru OBSLO-a (3,41 ± 1,53) ili LAMS-a (3,35 ± 1,51). Ovaj podatak ne mora nužno ukazivati na nedostatke u OBSLO-u, već može sugerisati da studenti imaju tendenciju da istražuju dodatne izvore informacija kao deo svog ličnog pristupa učenju. Međutim, ovo može ukazivati i na potencijalne oblasti za unapređenje sadržaja unutar OBSLO-a, kako bi se smanjila potreba za eksternim resursima.
4. Želja za korišćenjem OBSLO-a u drugim predmetima - Studenti su umereno pozitivno ocenili mogućnost korišćenja OBSLO sistema i u drugim predmetima (3,00 ± 1,28), što pokazuje da postoji osnov za dalju implementaciju sistema u različitim oblastima obrazovanja.
5. Autonomija u učenju - Studenti su pokazali visok stepen samostalnosti u radu, što se odražava u prosečnoj oceni 3,74 ± 1,1. Takođe su izrazili da su uspešno identifikovali potrebne objekte učenja za rešavanje zadataka (3,44 ± 1,08).

Iako su rezultati upitnika uglavnom pozitivni, oni istovremeno ukazuju na prostor za unapređenje OBSLO sistema, posebno sa stanovišta korisničkog iskustva, dostupnosti sadržaja

i podrške pri navigaciji. Komentari studenata pružaju smernice za dalji razvoj funkcionalnosti sistema, dok bi eventualni uticaj takvih unapređenja na ishode učenja zahtevao zasebnu empirijsku evaluaciju.

Tabela 10. Rezultati studentskog upitnika o OBSLO-u.

Pitanja	X ± SD	Medijana
Q1. Koliko vam je sadržaj nastavnih materijala prikazanih kroz OBSLO sistem pomogao u rešavanju zadataka? (pomoglo = 5, nije pomoglo = 1)	3,38 ± 1,27	3
Q2. Koliko vam je rad u OBSLO-u pomogao da uspešno završite svoje zadatke? (pomoglo = 5, nije pomoglo = 1)	3,38 ± 0,95	3
Q3. U kojoj meri ste koristili Internet više od nastavnih materijala iz OBSLO sistema dok ste rešavali postavljene zadatke? (koristio = 5, nisam koristio = 1)	3,41 ± 1,53	4
Q4. U kojoj meri ste koristili Internet više od nastavnih materijala iz LAMS sistema dok ste rešavali postavljene zadatke? (koristio = 5, nisam koristio = 1)	3,35 ± 1,51	4
Q5. U kojoj meri ste pronašli materijale koji su vam bili potrebni za rešavanje zadataka u OBSLO sistemu? (nisam pronašao, što je bilo jako loše = 1, pronašao sam sve što mi je trebalo = 5)	3,46 ± 1,1	3
Q6. U kojoj meri ste uspeli da za svaki zadatak izdvojite objekte učenja koji su bili bolji od onih koje ste dobili na početku kao preporučene radne objekte? (nisam uspeo = 1, uspeo sam = 5)	3,44 ± 1,08	3
Q7. U kojoj meri ste bili u mogućnosti da pronađete sadržaj iz prethodnih lekcija koji vam je bio potreban za rešavanje zadataka u OBSLO sistemu? (nisam uspeo = 1, potpuno uspeo = 5)	3,46 ± 1,1	3
Q8. U kojoj meri biste želeli da koristite ovaj stil učenja u drugim predmetima? (nimalo = 1, potpuno = 5)	3,00 ± 1,28	3
Q9. U kojoj meri ste radili sa kolegama dok ste rešavali dodeljene zadatke? (potpuno sam radio sa kolegama = 1, potpuno samostalno = 5)	3,74 ± 1,1	4

Pored numeričkih podataka, studenti su takođe dali kvalitativne komentare o svom iskustvu sa OBSLO-om. Njihovi komentari mogu se podeliti u dve grupe - pozitivne povratne informacije i predlozi za poboljšanja.

Pozitivni komentari - potvrđuju da OBSLO ispunjava svoju osnovnu svrhu, pružajući studentima korisno i lako dostupno okruženje za učenje:

- „Sistem je dobar.“
- „Dobra ideja i zanimljivo za učenje kroz rešavanje problema.“
- „Sviđa mi se sistem i najvažnije je da su nastavni materijali uvek dostupni tokom zadataka.“

Predlozi za poboljšanja sugerišu da bi korisnički interfejs mogao biti dodatno optimizovan, kako bi bio još intuitivniji, kao i da postoji potreba za integracijom dodatnih spoljnih izvora znanja:

- „Sve je u redu, ali prvi grafikon je malo zbunjujući.“
- „Ne vidim svrhu izdvojenog objekta učenja na radnoj stranici.“
- „Linkovi ka onlajn resursima bi bili od pomoći.“

Evaluacija je identifikovala poboljšanja koja treba napraviti i dalje istraživanje koje treba sprovesti. Određene funkcionalnosti interfejsa mogu se unaprediti:

1) S obzirom na to da su neki studenti smatrali da je MCM grafikon pomalo zbunjujući, potrebno je istražiti intuitivniji vizuelni prikaz MCM-a koje će olakšati navigaciju kroz konceptualne mape, i
2) Davanje studentima potpune autonomije da traže sadržaj za učenje potreban za rešavanje dodeljenih problema pokazalo je da studenti nisu uvek mogli da identifikuju potrebne koncepte i da bi se moglo unaprediti isticanjem preporučenog materijala za studente i pružanjem vodiča kroz materijal kako bi se studentima pružila jasnija struktura učenja.

Tokom testiranja OBSLO-a primećeno je da je kreiranje ontologije OU-ova ne samo vremenski zahtevno, već i podložno određenim greškama. Na primer, studenti su identifikovali odnose između OU-a koji nisu bili definisani od strane nastavnika. Studenti su zapravo identifikovali alternativne načine na koje se određeni zadaci mogu rešiti. Zbog toga kreiranje i modifikacija ontologije može biti unapređeno razvijanjem novih modela zasnovanih na korišćenju sistema:

1) Obezbediti automatske sugestije za ontologiju OU-ova, koje mogu biti izvedene iz korišćenja određenog nastavnog sadržaja od strane studenata,
2) Uključivanje studenta i nastavnika u saradnički proces definisanja ontologije domena, čime bi se osiguralo da sistem obuhvati različite pristupe rešavanju problema i postane još fleksibilniji za personalizovano učenje.

7.1.2. Druga iteracija evaluacije modela nastavnih sadržaja

Druga faza evaluacije obuhvatila je ispitivanje sistema u kome je testirana unapređena verzija u poređenju sa onom koja je korišćena u prvoj fazi iteracije. Unapređena verzija omogućava studentima da lakše pronađu potrebne sadržaje za učenje koji su neophodni za rešavanje postavljenih zadataka ili problema (Tabela 11). Pritom, svakom studentu pruža odgovarajući nivo materijala za učenje, ističući koje je predznanje potrebno za uspešno rešavanje zadatka. Sistem je evaluiran sa grupom studenata koji su pohađali predmet Baza podataka. Ova evaluacija je sprovedena na kraju semestra, kada se očekivalo da su studenti

zadržvali većinu gradiva predmeta. Pre ovog predmeta Baza podataka, studenti nisu imali ili su imali minimalno znanje o bazama podataka. Evaluacija je obuhvatila 42 studenta.

Tabela 11. Problemi dodeljeni studentima tokom druge evaluacione faze.

Pitanje	Opis
P1	a. Kreirajte tabele CUSTOMER, ORDERS, ORDER_ITEMS i PRODUCTS koje odgovaraju sledećim relacijama: CUSTOMERS (#CustomerID, FirstName, LastName, City, Country, Phone) ORDERS (#OrderID, OrderDate, OrderNumber, CustomerID, TotalAmount) PRODUCTS (#ProductID, ProductName, UnitPrice, IsDiscontinued) ORDER_ITEMS (OrderItemsID, OrderID, ProductID, Quantity, TotalAmountPerItem) b. Ubacite najmanje jedan red u svaku tabelu.
P2	Prikažite sve proizvode, uključujući ime proizvoda, ukupnu količinu proizvoda i ukupnu vrednost proizvoda, čija imena počinju sa "T", "M" ili "O" i koje su naručili kupci pod imenom "Jovan Jovičić" ili "Nenad Jezdić".
P3	Prikažite sve kupce, bez obzira na to da li su izvršili narudžbinu ili ne. Za kupce bez narudžbina, OrderNumber je NULL, a TotalAmount je nula. Lista treba da bude sortirana opadajućim redosledom po vrednosti TotalAmount.
P4	Prikažite kupce koji nisu izvršili narudžbine (TotalAmount je nula). Lista treba da bude sortirana rastućim redosledom prema imenu kupca (od A do Z).
P5	a. Kreirajte tabelu SUPPLIERS koja odgovara sledećoj relaciji: SUPPLIERS (SupplierID, SupplierName, City, Country) b. Izmenite tabelu PRODUCTS tako da za svaki proizvod bude poznat dobavljač.
P6	Povežite sve kupce i dobavljače po zemlji (prikažite dobavljače koji nemaju kupce u svojoj zemlji, kupce koji nemaju dobavljače u svojoj zemlji i kupce i dobavljače koji su iz iste zemlje).

Evaluacija je zasnovana na sledećem scenariju učenja i prikupljanju podataka:

- Studentima je dato šest zadataka za rešavanje. Tabela 11 prikazuje sve dodeljene zadatke. Treba napomenuti da se P1 i P5 odnose na osnovni nivo znanja u podtemi *Definicija podataka*, te su samim tim lakši za rešavanje. Zadaci P2, P3, P4 i P6 odnose se na SQL manipulaciju podacima, koja uključuje kako osnovni, tako i napredni nivo učenja, pa se mogu smatrati težim za rešavanje.
- Od studenata se tražilo da koriste OBSLO interfejs i navigaciju kroz MCM-ove kako bi pronašli materijal za učenje koji im je potreban za rešavanje ovih zadataka. Svi dodeljeni zadaci odnose se na temu Jezik za upite nad podacima (DQL), pa je studentima prikazan početni MCM, automatski generisan iz kreirane ontologije domena za DQL koncepte koju je nastavnik kreirao pre evaluacije.
- Prikazani MCM omogućio je studentima da pristupe osnovnom i/ili naprednom nivou znanja. U početku su studentima prikazani koncepti osnovnog nivoa

(prikazani crvenom bojom na Slici 31), koji su ukazivali na napredne koncepte znanja prikazane plavom bojom. Napredni nivo MCM-a za DQL koncepte prikazan je na Slici 32.

- Pri odabiru teme ili podteme, studentu je prikazan MCM za taj koncept (eliptične forme), dok bi klikom na OU (pravougaone forme) studentu bio prikazan sadržaj za učenje (Slika 33).
- Tokom procesa rešavanja problema, od studenata se tražilo da sačuvaju sadržaj za učenje koji su smatrali korisnim za pronalaženje rešenja. Od njih se tražilo da označe te OU klikom na ikonu zvezdice, kao što je prikazano na Slici 33.
- Svaki označeni OU je sačuvan i prikazan studentu na radnoj stranici, predviđenoj za pružanje rešenja za određeni problem (Slika 34).
- Studenti su ponovili isti proces korišćenja materijala za učenje koristeći OBSLO kako bi pronašli potreban sadržaj za rešavanje dodeljenih zadataka.
- Da bi se uporedili putevi učenja studenata i njihova rešenja, nastavnik je obezbedio listu ključnih OU-ova za svaki dodeljeni problem. Ova lista nije bila objavljena studentima, već je korišćena za analizu puteva učenja studenata.

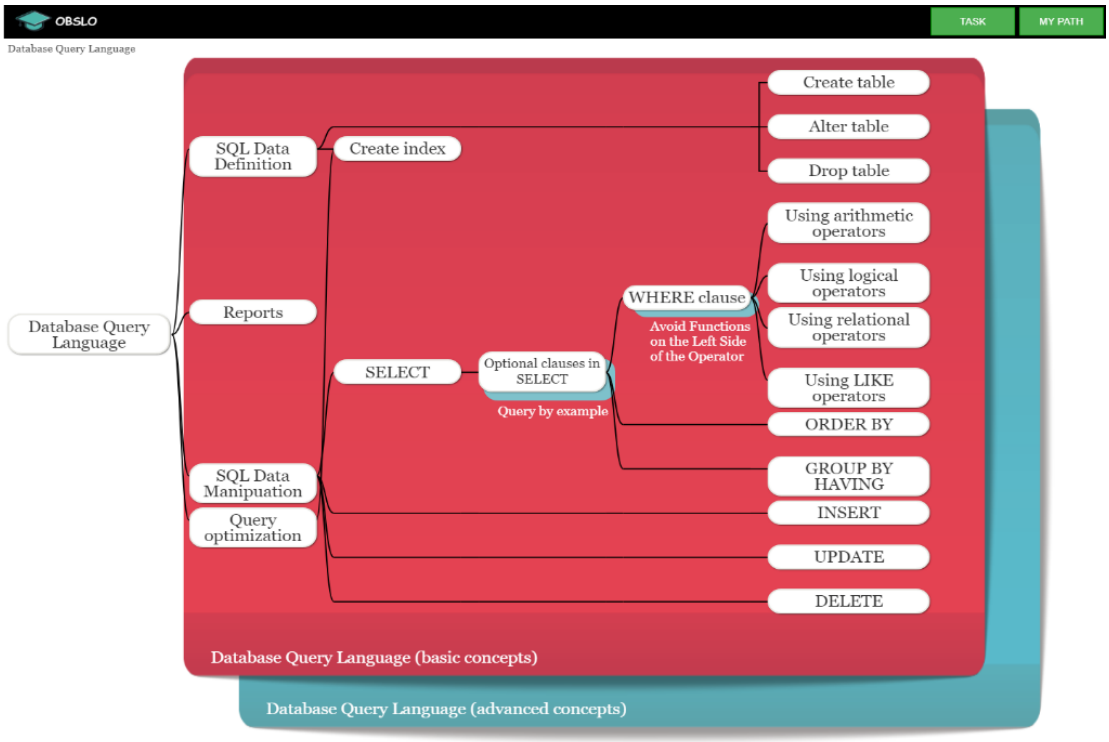

Slika 31. Prikaz MCM-a osnovnog nivoa za Jezik za upite nad podacima u OBSLO-u.

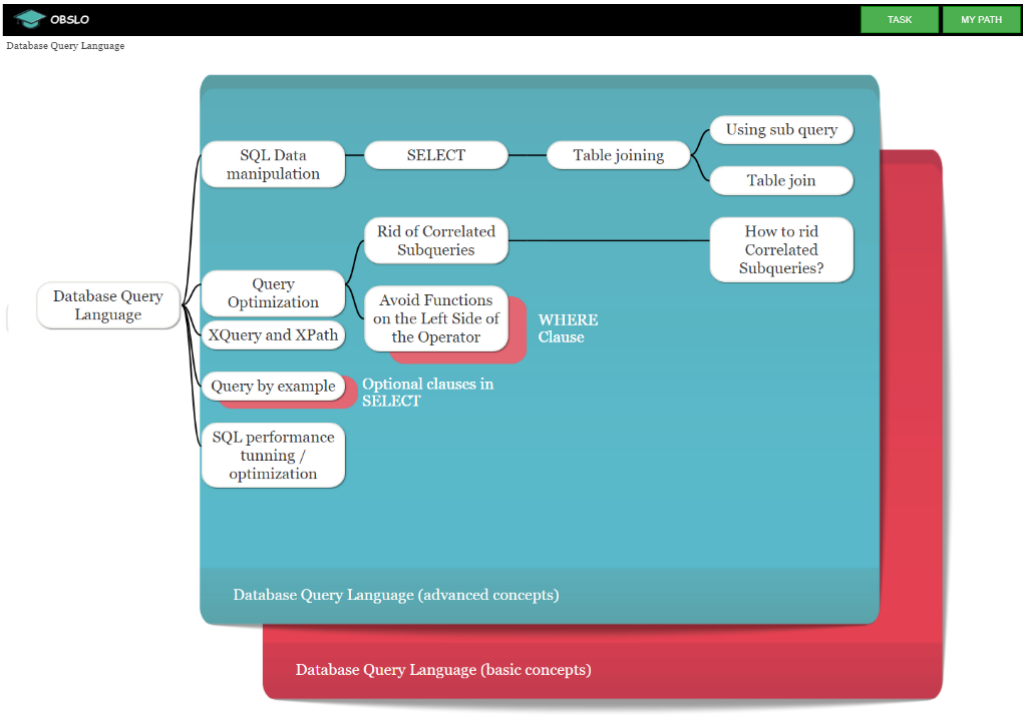

Slika 32. Prikaz MCM-a naprednog nivoa za Jezik za upite nad podacima u OBSLO-u.

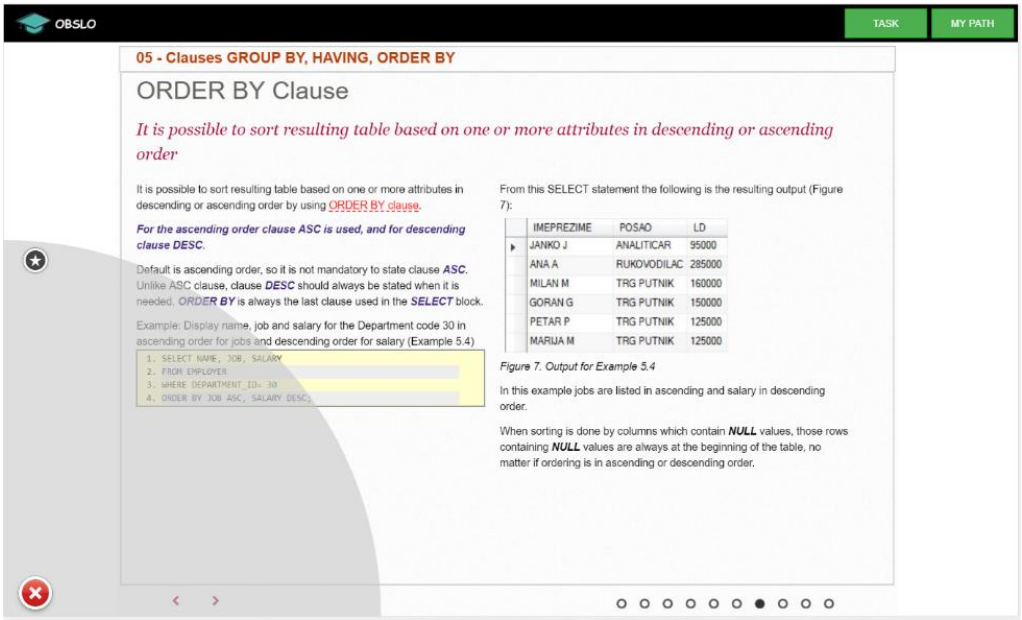

Slika 33. Primer sadržaja za učenje u DQL-GROUP BY, HAVING, ORDER BY OU-u.

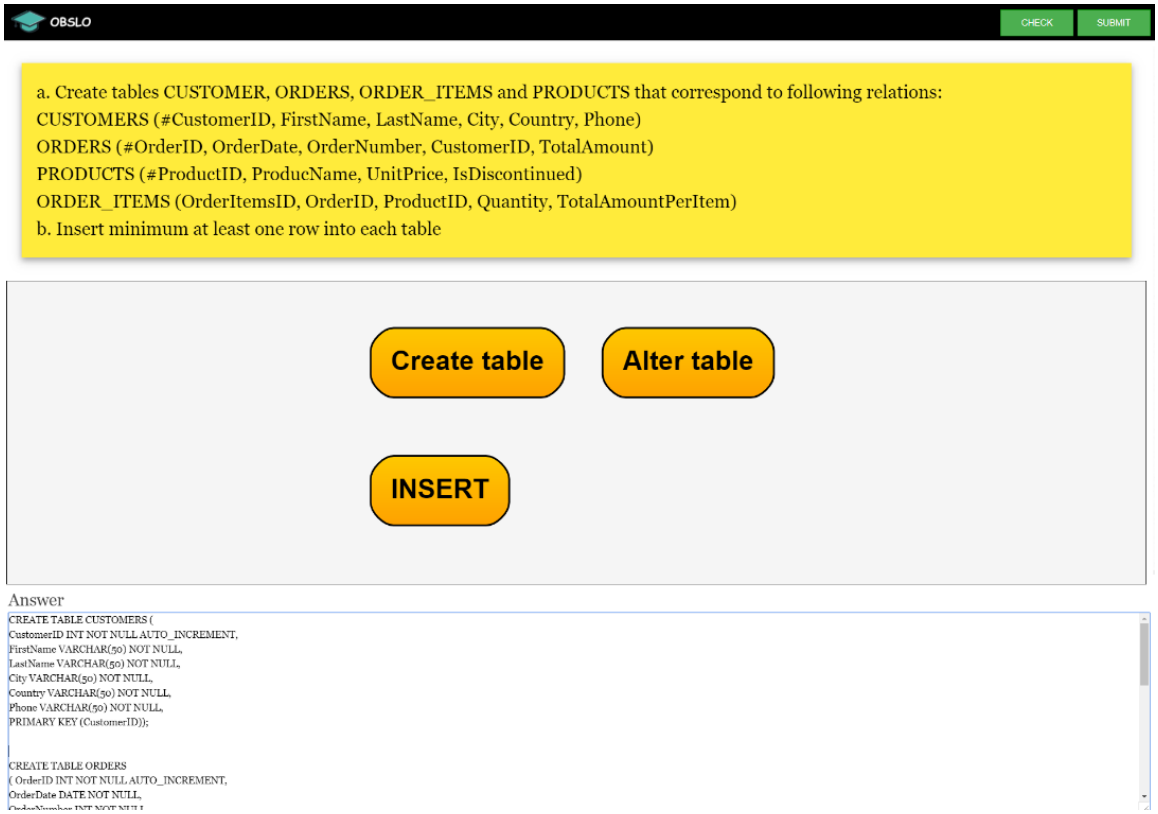

Slika 34. Radna stranica koja prikazuje dodeljeni problem, izabrani OU od strane studenta i prostor za pružanje rešenja.

Tokom evaluacije, sistem je prikupljao podatke kao što su: korišćeni OU sa sekvencom (putem) OU-ova redosledom kojim ih je student koristio, vreme provedeno na OU-u, poslato rešenje zajedno sa rezultatom iz ocenjivača koji može imati jednu od dve vrednosti, tačno ili netačno. Na kraju, od studenata se tražilo da popune upitnik kako bi izrazili svoje iskustvo učenja koristeći sistem. Prikupljeni podaci korišćeni su za analizu puteva učenja studenata sa ciljem poboljšanja ontologije kreirane od strane nastavnika, kao i za procenu zadovoljstva studenata korišćenjem sistema za učenje, kako bi se uneli neophodni zahtevi i promene u softverskoj arhitekturi.

Druga iteracija evaluacije modela nastavnog materijala uključuje sledeće analize:

1. Analiza puteva učenja studenata (odeljak 7.1.2.1) - evaluacija sistema podrazumevala je analizu puteva učenja studenata kako bi se identifikovale potencijalne oblasti za poboljšanje. Ova analiza je uključivala:
    - Praćenje sekvenci OU-ova koje su studenti koristili u rešavanju svakog zadatka.
    - Poređenje ovih sekvenci sa referentnim putevima učenja, odnosno listama ključnih OU-ova koje su prethodno definisali nastavnici.
    - Identifikaciju problematičnih delova ontologije, gde su studenti trošili značajno više vremena nego što je očekivano.

- Preporuke za modifikaciju ontologije, uključujući razmatranje novih BA relacija između odgovarajućih koncepata, optimizaciju prikazanih koncepata i poboljšanje navigacije kroz sadržaj.

2. Modifikacija ontologije (odeljak 7.1.2.2) - na osnovu analize puteva učenja, ontologija je modifikovana tako da bolje odražava stvarne puteve učenja studenata. Uočene su sledeće ključne oblasti za poboljšanje:
    - Potreba za dodatnim BA relacijama između odgovarajućih osnovnih i naprednih koncepata.
    - Uklanjanje redundantnih OU-ova koji nisu bili korišćeni ili su zbunjivali studente.
    - Jasnije označavanje preporučenih i obaveznih OU-ova kako bi se studentima olakšalo donošenje odluka o tome koje materijale koristiti.
3. Analiza zadovoljstva studenata korišćenjem unapređene verzije OBSLO-a (odeljak 7.1.2.3).

7.1.2.1. Analiza puteva učenja studenata

Tokom faze evaluacije, sve aktivnosti studenata su evidentirane u sistemu dok su rešavali dodeljene zadatke. Kao što je prethodno navedeno, problemi Q1 i Q5 imali su osnovni nivo težine, dok su preostala pitanja bila složenija i zahtevala naprednije razumevanje koncepta. Analizirajući brzinu i uspešnost rešavanja problema, može se videti da su Q1 i Q5 ostvarili visoku stopu tačnih odgovora. Konkretno, studenti su uspešno rešili Q1 (92,86%) i Q5 (80,00%), dok su rezultati za složenije zadatke bili znatno slabiji:

- Q2 (47,37%)
- Q3 (3,85%)
- Q4 (20,83%)
- Q6 (42,86%)

Tabela 12 prikazuje ukupan broj studenata koji su pokušali da reše određeni problem, kao i broj onih koji su dali tačan odgovor. Interesantan nalaz je da su svi studenti (42/42) pokušali da reše Q1, dok je za Q6 taj broj bio znatno niži - samo 14 studenata (33%) je pokušalo da odgovori na ovo pitanje.

Tabela 12. Broj studenata koji su pokušali da reše zadate probleme i onih koji su dobili tačan odgovor.

Pitanje	Q1	Q2	Q3	Q4	Q5	Q6
Broj studenata koji su pokušali da reše zadate probleme	42	38	26	24	20	14
Broj studenata koji su dobili tačne odgovore	39	18	1	5	16	6
%	92,86%	47,37%	3,85%	20,83%	80,00%	42,86%

Zbog relativno loših rezultata u rešavanju zadataka Q2, Q3, Q4 i Q6, sprovedena je dublja analiza kako bi se uporedile putanje učenja studenata sa putanjama koju je definisao nastavnik, u cilju unapređenja ontologije sistema. U Tabeli 13 prikazane su putanje učenja studenata i njihova upotreba preporučenih OU-ova od strane nastavnika, zajedno sa brojem studenata koji su koristili određenu putanju i brojem studenata koji su tačno rešili problem.

Tabela 13. Frekvencija putanja učenja po pitanju.

Pitanje	Putanje učenja studenata/nastavnika	Broj studenata koji su koristili određenu stazu učenja	Broj studenata koji su koristili određenu stazu učenja i tačno rešili problem
Q1	Kreiranje tabele (engl. Create table), Ubacivanje (engl. INSERT)	38	36
	Izmena tabele (engl. Alter table), Kreiranje tabele (engl. Create table), Ubacivanje (engl. INSERT)	4	3
	*Izmena tabele (engl. Alter table), Kreiranje tabele (engl. Create table), Ubacivanje (engl. INSERT)		
Q2	Spajanje tabela (engl. Table Join), Korišćenje operatora LIKE (engl. Using LIKE operator), Korišćenje logičkih operatora (engl. Using logical operators)	18	7
	Grupisanje po HAVING (engl. GROUP BY HAVING), Korišćenje operatora LIKE (engl. Using LIKE operator), Korišćenje relacijskih operatora (engl. Using relational operators)	7	5
	Grupisanje po HAVING (engl. GROUP BY HAVING), Sortiranje (engl. ORDER BY), Korišćenje operatora LIKE (engl. Using LIKE operator), Korišćenje logičkih operatora (engl. Using logical operators), Korišćenje relacijskih operatora (engl. Using relational operators)	7	5
	Sortiranje (engl. ORDER BY), Korišćenje logičkih operatora (engl. Using logical operators)	4	0
	Spajanje tabela (engl. Table Join), Korišćenje operatora LIKE (engl. Using LIKE operator), Korišćenje relacijskih operatora (engl. Using relational operators), Korišćenje podupita (engl. Using subquery)	2	1
	*Korišćenje logičkih operatora (engl. Using logical operators), Korišćenje operatora LIKE (engl. Using LIKE operator), Korišćenje aritmetičkih operatora (engl. Using Arithmetic operators), Grupisanje po HAVING (engl.		

	GROUP BY HAVING), Spajanje tabela (engl. Table Join)		
Q3	Sortiranje (engl. ORDER BY), Korišćenje aritmetičkih operatora (engl. Using Arithmetic Operators), Korišćenje logičkih operatora (engl. Using logical operators)	7	0
	Grupisanje po HAVING (engl. GROUP BY HAVING), Sortiranje (engl. ORDER BY), Spajanje tabela (engl. Table Join)	4	0
	Grupisanje po HAVING (engl. GROUP BY HAVING), Sortiranje (engl. ORDER BY), Spajanje tabela (engl. Table Join), Korišćenje logičkih operatora (engl. Using logical operators)	3	0
	Korišćenje operatora LIKE (engl. Using LIKE operator)	3	0
	Grupisanje po HAVING (engl. GROUP BY HAVING), Sortiranje (engl. ORDER BY), Spajanje tabela (engl. Table Join), Korišćenje logičkih operatora (engl. Using logical operators), Korišćenje relacijskih operatora (engl. Using relational operators)	3	0
	Grupisanje po HAVING (engl. GROUP BY HAVING), Sortiranje (engl. ORDER BY)	3	0
	Sortiranje (engl. ORDER BY), Korišćenje logičkih operatora (engl. Using logical operators)	2	0
	Spajanje tabela (engl. Table Join), Korišćenje relacijskih operatora (engl. Using relational operators)	1	1
	*Spajanje tabela (engl. Table Join), Sortiranje (engl. ORDER BY)		
Q4	Korišćenje logičkih operatora (engl. Using logical operators), Korišćenje operatora LIKE (engl. Using LIKE operator), Korišćenje aritmetičkih operatora (engl. Using Arithmetic operators), Grupisanje po HAVING (engl. GROUP BY HAVING), Spajanje tabela (engl. Table Join)	8	1
	Spajanje tabela (engl. Table Join), Korišćenje operatora LIKE (engl. Using LIKE operator), Korišćenje podupita (engl. Using subquery)	4	0
	Grupisanje po HAVING (engl. GROUP BY HAVING), Sortiranje (engl. ORDER BY), Spajanje tabela (engl. Table Join), Korišćenje aritmetičkih operatora (engl. Using Arithmetic Operators), Korišćenje operatora LIKE (engl. Using LIKE operator), Korišćenje logičkih operatora (engl. Using logical operators)	3	3
	Korišćenje relacijskih operatora (engl. Using relational operators)	3	0
	Korišćenje operatora LIKE (engl. Using LIKE operator)	2	0
	Grupisanje po HAVING (engl. GROUP BY HAVING), Sortiranje (engl. ORDER BY), Korišćenje operatora LIKE (engl. Using LIKE operator), Korišćenje relacijskih operatora (engl. Using relational operators)	4	1
	*Spajanje tabela (engl. Table Join), Sortiranje (engl. ORDER BY)		
Q5	Izmena tabele (engl. Alter table), Kreiranje tabele (engl. Create table)	9	7

	Izmena tabele (engl. Alter table), Kreiranje tabele (engl. Create table), Ubacivanje (engl. INSERT), Ažuriranje (engl. UPDATE)	6	5
	Kreiranje tabele (engl. Create table), Ubacivanje (engl. INSERT)	3	2
	Izmena tabele (engl. Alter table)	2	2
	*Izmena tabele (engl. Alter table), Kreiranje tabele (engl. Create table)		
Q6	Grupisanje po HAVING (engl. GROUP BY HAVING), Sortiranje (engl. ORDER BY), Korišćenje operatora LIKE (engl. Using LIKE operator)	5	3
	Ubacivanje (engl. INSERT)	2	1
	Korišćenje relacijskih operatora (engl. Using relational operators)	2	0
	Sortiranje (engl. ORDER BY), Korišćenje logičkih operatora (engl. Using logical operators)	2	0
	Sortiranje (engl. ORDER BY), Korišćenje operatora LIKE (engl. Using LIKE operator), Korišćenje logičkih operatora (engl. Using logical operators), Korišćenje relacijskih operatora (engl. Using relational operators), Korišćenje podupita (engl. Using subquery)	1	1
	Grupisanje po HAVING (engl. GROUP BY HAVING), Korišćenje logičkih operatora (engl. Using logical operators)	2	1
	*Spajanje tabela (engl. Table Join)		

Putanje učenja studenata za pitanja Q1 i Q5 ne razlikuju se mnogo od putanja definisanih od strane nastavnika, a za oba pitanja više od 80% studenata koji su učestvovali u rešavanju ovog zadatka rešili su ova pitanja tačno. Oba pitanja su deo iste teme, a to je definicija podataka u SQL-u. Za Q1 većina studenata nije koristila sadržaj za učenje OU Izmena tabele (engl. *ALTER TABLE*). Treba napomenuti da je OU Izmena tabele opcioni sadržaj, jer se zadatak Q1 mogao rešiti korišćenjem samo Kreiranja tabele (engl. *CREATE TABLE*) i Umetanja podataka (engl. *INSERT*). Rezultujuće studentske putanje za Q5 sadrže oba ili barem jedan preporučeni OU - Izmena tabele i Kreiranje tabele. Rezultati za oba pitanja, Q1 i Q5, pokazuju da dalja modifikacija i poboljšanja ontologije definisane od strane nastavnika nisu potrebna, ali se opcioni OU mogu preporučiti studentima.

Ključni koncepti učenja neophodni za rešavanje pitanja Q2 sadržani su u OU Grupisanje sa uslovom (engl. *GROUP BY HAVING*) i Spajanje tabela (engl. *Table Join*), koji su bili deo putanje učenja definisane od strane nastavnika. Analizom studentskih odgovora može se videti da je od 24 studenta koji nisu koristili OU Grupisanje sa uslovom u svojim putanjama učenja, samo 8 uspešno rešilo problem. S druge strane, 14 studenata je koristilo OU Grupisanje sa uslovom, ali nisu koristili OU Spajanje tabela, koji obuhvata objašnjenje različitih tipova spajanja tabela (engl. *EQUIJOIN, LEFT JOIN, RIGHT JOIN i FULL JOIN*). Uprkos tome, 10

studenata je uspešno rešilo problem. Jedno moguće objašnjenje jeste da su pojedini studenti već raspolagali znanjem potrebnim za spajanje tabela korišćenjem EQUIJOIN-a i da zbog toga nisu pristupali odgovarajućem objektu učenja. Međutim, pošto prethodno znanje nije nezavisno mereno u ovoj fazi evaluacije, takvo objašnjenje se ne može potvrditi samo na osnovu zabeležene putanje kroz sadržaj. Nekorišćenje objekta učenja *Grupisanje sa uslovom* bilo je povezano sa nižom uspešnošću u rešavanju Q2, što ukazuje da bi značaj i primenu ovog sadržaja trebalo jasnije predstaviti studentima. Na osnovu posmatranih podataka, međutim, nije moguće izdvojiti nekorišćenje ovog objekta kao samostalan uzrok neuspešnog rešavanja zadatka. Niska uspešnost na zadacima Q3, Q4 i Q6, koji zahtevaju primenu različitih tipova spajanja tabela, ukazuje na moguće poteškoće studenata pri izboru i primeni odgovarajućih JOIN operacija. Pošto razumevanje pojedinačnih tipova spajanja nije proveravano zasebnim dijagnostičkim instrumentom, na osnovu ovih rezultata nije moguće zaključiti da studenti odgovarajuće koncepte nisu razumeli. Nalaz, međutim, pruža osnovu za preciznije strukturiranje i isticanje sadržaja koji se odnosi na EQUIJOIN, LEFT JOIN, RIGHT JOIN i FULL JOIN.

Slično tome, Q3, Q4 i Q6 se uglavnom odnose na korišćenje sadržaja OU Spajanje tabela. Pored toga, za rešavanje problema Q3, Q4 i Q6, trebalo je koristiti LEVO SPAJANJE (engl. *LEFT JOIN*), DESNO SPAJANJE (engl. *RIGHT JOIN*) i PUNO SPAJANJE (engl. *FULL JOIN*) respektivno. Međutim, relativno mali broj studenata je uspešno rešio ova tri zadatka: 3,85% za Q3, 20,83% za Q4 i 42,86% za Q6, uzimajući u obzir da je svaki sledeći zadatak pokušalo manje studenata. Ovi rezultati ukazuju na moguće teškoće studenata sa tipovima spajanja tabela osim EQUIJOIN-a. Međutim, zbog malog broja studenata koji su pokušali ova pitanja i zato što prethodno znanje nije nezavisno mereno, ovaj nalaz zahteva dodatnu proveru. Kao što je preporučeno za Q2 da se studentima predlože OU koji će biti korisni za rešavanje zadatka, u ovom slučaju, to bi moglo da se postigne modifikacijom ontologije tako da Spajanje tabela postane tema sa svojim OU EQUIJOIN, LEFT JOIN, RIGHT JOIN i FULL JOIN.

Bilo je interesantno analizirati da li postoji veza između vremena provedenog na određenim OU i uspeha u rešavanju zadataka. Tabela 14 prikazuje prosečno vreme po studentu provedeno na sadržaju za učenje koje su nastavnici identifikovali kao ključni sadržaj za učenje za svako pitanje, i za studente koji su tačno rešili problem i za one koji nisu. Prazna polja označavaju da sadržaj OU-ova nije preporučen za korišćenje pri rešavanju problema/zadataka za određena pitanja, dok „0,00“ označava da studenti nisu koristili taj određeni sadržaj za učenje. Analizirajući dva lakša pitanja, Q1 i Q5, koja su imala istu ključnu putanju učenja, može se

videti da su studenti koji su tačno rešili ova pitanja proveli znatno manje vremena na ključnom sadržaju Kreiranje tabele od studenata koji ih nisu tačno rešili (26,49 s prema 471,00 s za Q1, odnosno 2,06 s prema 20,25 s za Q5. Studenti koji nisu tačno rešili problem proveli su više vremena na materijalu za učenje, što može ukazivati na to da im je bilo potrebno više vremena da razumeju ključne koncepte, ili su pokušali da koriste druge resurse (npr. Internet) kako bi pronašli potrebne informacije.

Rezultati za Q2 podržavaju prethodnu opservaciju da studenti koji nisu tačno rešili problem nisu prepoznali da treba da koriste Grupisanje sa uslovom, dok su oni koji jesu, proveli u proseku 5,44 sekunde na ovom sadržaju za učenje. Ovakav obrazac može biti u skladu sa pretpostavkom da su studenti koji su uspešno rešili problem već posedovali deo potrebnog znanja i da su sadržaj OU-a koristili za kratku proveru ili dopunu, ali samo na osnovu vremena zadržavanja nije moguće pouzdano utvrditi njihovo prethodno znanje niti razlog korišćenja konkretnog sadržaja.

Tabela 14. Vreme provedeno na sadržaju OU-a po studentu u sekundama za svako pitanje [sek].

Objekat učenja (OU)	Q1	Q2	Q3	Q4	Q5	Q6
Kreiranje tabele (engl. *CREATE TABLE*)	471,00/26,49				20,25/2,06	
Izmena tabele (engl. *ALTER TABLE*)	4,67/0,26					
Korišćenje aritmetičkih operatora (engl. *Using Arithmetic Operators*)		0,00/0,00				
Korišćenje logičkih operatora (engl. *Using Logical Operators*)		3,95/5,72				
Korišćenje LIKE operatora (engl. *Using LIKE Operator*)		13,90/23,72				
Sortiranje (engl. *ORDER BY*)			63,65/1305,00	0,00/0,00		
Grupisanje sa uslovom (engl. *GROUP BY HAVING*)		0,50/5,44				
Umetanje podataka (engl. *INSERT*)	593,33/220,59					
Spajanje tabela (engl. *Table Join*)		63,40/72,11	4,31/473,00	27,63/51,00		0,88/0,83
Broj studenata koji su netačno/tačno rešili zadatak	3/39	20/18	25/1	19/5	4/16	8/6

Za složenije probleme Q3, Q4 i Q6 bilo je potrebno koristiti dva ključna sadržaja za učenje, **Sortiranje** (engl. *ORDER BY*) i **Spajanje tabela** (engl. *Table Join*). Dok su studenti imali

nisku stopu uspešnosti u rešavanju Q3 i proveli više vremena na ovom sadržaju, sa svakim sledećim pitanjem broj studenata koji su tačno odgovorili blago je porastao, ali je takođe više studenata nije pokušalo sledeća pitanja.

Zaključci koji se mogu izvući za poboljšanje sistema iz ovih rezultata su sledeći:

- Studentima treba pružiti ključni sadržaj za učenje kao preporuku šta će im trebati za rešavanje svakog problema. Sistem treba da koristi ontologiju definisanu od strane nastavnika da prikaže ovaj sadržaj kao MCM. Drugim rečima, svaki problem će imati automatski dodeljen MCM, generisan iz identifikovanog ključnog sadržaja za učenje i ontologije definisane od strane nastavnika.
- Registrovano vreme rada sa pojedinačnim OU kod studenata koji su tačno rešili problem može poslužiti kao dodatni signal nastavniku pri analizi obrazaca korišćenja sadržaja i razmatranju mogućih izmena ontologije, ali samo vreme zadržavanja nije dovoljno za pouzdanu identifikaciju ključnog OU-a.
- Nakon što student pošalje rešenje, treba mu se pružiti tačno rešenje za taj problem i/ili alternativno rešenje, koje će pokazati različite načine na koje se taj problem može rešiti.

7.1.2.2. Modifikacija ontologije

Rezultati pokazuju da, iako je nastavnik identifikovao ključne koncepte za svaki problem, dok su studenti mogli da pregledaju MCM prethodno definisane za celu oblast znanja, očigledno je da su studenti koristili više materijala za učenje za svaki problem nego što se očekivalo. Na primer, prilikom rešavanja Q2, studenti su koristili više OUs nego što je očekivano. Svi OUs koje su studenti koristili prilikom rešavanja Q2 i vreme provedeno na svakom OU prikazani su u Tabeli 15. Može se primetiti da je 16 studenata provelo najviše vremena na sadržaju OU Using relational operation (ukupno 2733 sekundi). Pošto je unapred definisana ontologija od strane nastavnika često osnovna ontologija i možda ne uključuje sve potrebne relacije između koncepata, korišćenje sistema od strane studenata može doprineti kolaborativnom kreiranju ontologije. U ovom slučaju, obrazac korišćenja OU Using relational operation može poslužiti kao signal nastavniku da razmotri modifikaciju ontologije. Pošto se relacione operacije mogu koristiti kao alternativno rešenje prilikom spajanja tabela, može se razmotriti uspostavljanje BA relacije između odgovarajućih koncepata, pri čemu koncept povezan sa sadržajem Table Join predstavlja napredniji koncept u odnosu na koncept povezan sa sadržajem Using relational operation.

Tabela 15. Korišćeni objekti učenja kod Q2.

Q2		
Objekat učenja	**Broj studenata koji su izabrali određeni OU**	**Ukupno vreme provedeno na sadržaju OU [sec]**
Using logical operators	29	182
Using relational operators	16	2733
Using LIKE operator	34	705
ORDER BY	11	136
GROUP BY HAVING	14	108
INSERT	0	0
DELETE	0	0
Using sub query	2	72
Table Join	20	2566

Tabela 16. Korišćeni objekti učenja kod Q4.

Q4		
Learning object	**Broj studenata koji su izabrali određeni OU**	**Ukupno vreme provedeno na sadržaju OU [sec]**
Using Arithmetic Operators	11	183
Using logical operators	13	1580
Using relational operators	13	292
Using LIKE operator	11	333
ORDER BY	5	36
GROUP BY HAVING	5	23
Using sub query	4	280
Table Join	7	780

Slično tome, Tabela 16 prikazuje OU koji su korišćeni i ukupno vreme provedeno na svakom OU-u tokom rešavanja problema Q4. U ovom slučaju, najviše korišćen OU (13 studenata, ukupno 1580 sekundi) bio je OU Using logical operators. Ovaj objekat nije označen kao ključni sadržaj za učenje. Međutim, logičke operacije se takođe mogu koristiti kao alternativno rešenje za spajanje tabela, pa se može razmotriti uspostavljanje BA relacije između odgovarajućih koncepata, pri čemu koncept povezan sa sadržajem Table Join predstavlja napredniji koncept u odnosu na koncept povezan sa sadržajem Using logical operators.

Bez obzira na logičku interpretaciju sadržaja OU-a, zaključci koji se mogu izvući za poboljšanje sistema su:

- Obrasci korišćenja objekata učenja mogu se koristiti kao dodatni signal nastavniku za razmatranje modifikacije ontologije i uvođenje novih BA relacija između odgovarajućih koncepata koji prethodno nisu bili povezani. Takva modifikacija ne treba da bude automatska posledica vremena korišćenja ili učestalosti izbora pojedinačnog OU, već preporuka nastavniku za semantičku proveru mogućeg odnosa između koncepata. Konačnu odluku o opravdanosti BA relacije i o tome koji koncept predstavlja osnovni, a koji napredni koncept, donosi nastavnik na osnovu značenja nastavnog sadržaja i strukture domena.

7.1.2.3. Analiza zadovoljstva studenata korišćenjem unapređene verzije OBSLO-a

Na kraju evaluacije, studentima je zatraženo da popune upitnik prikazan u Tabeli 17. Upitnik je koristio petostepenu Likertovu skalu, u rasponu od najniže tačke (1) do najviše (5) za Q1-3, i DA/NE pitanje za Q4-8. Upitnik je takođe pružao opciju za unos komentara u cilju davanja sugestija i komentara u formi otvorenog pitanja. Pitanja Q1-3 su imala za cilj da daju odgovore na pitanja o zadovoljstvu korišćenjem OBSLO sistema. Analizom tih rezultata, studenti su izrazili da je sadržaj učenja pomogao u postizanju obrazovnih ciljeva, 3,69 ± 1,07 (s medijanom 4,00) tokom učenja zasnovanog na problemima uz relativno lako i intuitivno navigiranje kroz MCM, 3,74 ± 0,96 (s medijanom 4,00). Q1-3 imaju relativno visoku standardnu devijaciju zbog ograničenog broja studenata na predmetu baza podataka. Odgovori na Q3 pokazuju da su studenti tokom rešavanja problema u proseku umereno koristili dostupne nastavne materijale (3,14 ± 1,18; medijana 3,00). Pošto je evaluacija sprovedena na kraju semestra, ovaj nalaz pokazuje da je potreba za ponovnim konsultovanjem sadržaja postojala kod dela studenata, ali ne omogućava zaključak o stepenu zadržavanja prethodno stečenog znanja. Visok procenat, 71% studenata je rekao da su osim materijala prikazanih kroz OBSLO koristili i druge resurse kao što je Internet tokom rešavanja problema. 69% studenata je smatralo da je materijal za učenje pružen kroz OBSLO bio koristan, dok 74% nije bilo u stanju da pronađe bolju putanju učenja od prvobitno date. 74% studenata je odgovorilo da su uspeli da pronađu sadržaj iz prethodnih lekcija potreban za rešavanje dodeljenog problema i 64% njih je izrazilo da su motivisani da koriste ovaj stil učenja i na drugim predmetima.

Otvoreni komentari dodatno pokazuju da je deo studenata pozitivno ocenio korisnost i način rada u OBSLO okruženju, dok su drugi komentari ukazali na probleme u navigaciji i elementima korisničkog interfejsa. Studenti su smatrali da je sistem koristan i zanimljiv:

„Sistem je dobar“, „Dobra ideja i zanimljivo za učenje zasnovano na problemima“, „Sviđa mi se sistem i najvažnije je da su materijali za učenje uvek dostupni tokom rešavanja problema.”

Dodatni komentari i sugestije ukazuju na potrebne unapređene sistema, posebno na unapređenja potrebna na interfejsu: „Sve je dobro, ali je prvi grafikon pomalo zbunjujuć“, „ Navigacija kroz sistem je teška“, „Ne vidim svrhu OU-a izolovanog na radnoj stranici.“

Komentar kao što je: „Linkovi ka lekcijama / onlajn resursima bi bili korisni“ ukazuje da učenici takođe smatraju da bi dodatni onlajn resursi bili korisni ako bi bili povezani sa OU-om ili dodeljenim problemom.

Tabela 17. Rezultati iz upitnika studenata.

Pitanja (Likertova skala)	X ± SD	MED
Q1. Koliko vam je sadržaj učenja pomogao u postizanju obrazovnih ciljeva?	3,69 ± 1,07	4,00
Q2. Koliko je bilo lako i intuitivno navigirati kroz materijal za učenje?	3,74 ± 0,96	4,00
Q3. Da li ste i u kojoj meri koristili materijal za učenje dok ste pokušavali da rešite dodeljene probleme?	3,14 ± 1,18	3,00
Pitanja (DA/NE)	**DA (%)**	**NE (%)**
Q4. Da li ste koristili druge resurse (npr. Internet) više od materijala za učenje dok ste rešavali probleme?	71%	29%
Q5. Da li ste smatrali da je predstavljanje sadržaja učenja tokom personalizovanog učenja zasnovanog na problemima bilo korisno?	69%	31%
Q6. Da li ste izgradili svoju vlastitu putanju materijala za učenje koja je bila bolja od one koju ste prvobitno dobili?	26%	74%
Q7. Da li ste uspeli da pronađete sadržaj iz prethodnih lekcija koji vam je bio potreban za rešavanje postavljenog problema?	74%	26%
Q8. Da li biste želeli da koristite ovaj stil učenja na drugim predmetima?	64%	36%

Zaključci koji se mogu izvući za unapređenje sistema iz ovih rezultata su sledeći:

- Navigacija u sistemu treba da bude intuitivnija i fleksibilnija.
- Potrebno je omogućiti studentima da daju rešenja za dodeljeni problem u bilo kojem trenutku, čak i dok čitaju sadržaj OU-a.
- Važno je pružiti dodatne resurse za OU-e ili dodeljene probleme, kao što su onlajn resursi.

- Važno je studentima pružiti alternativna rešenja kako bi bili izloženi različitim načinima na koje se određeni problem može rešiti.

Ovi rezultati ukazuju i na to da samostalno pronalaženje putanje kroz ontološku strukturu može biti zahtevno za studente, posebno na početnim godinama studija, koji su navikli da uče iz unapred pripremljenih tekstova. Samo 26% studenata navelo je da je izgradilo sopstvenu putanju bolju od prvobitno dobijene (Q6), a deo otvorenih komentara odnosio se na teškoće u navigaciji. U skladu sa tim, u konačnoj fazi istraživanja ontologija se koristi u pozadini sistema: student ne navigira kroz ontološki dijagram, već dobija uređenu putanju i objašnjenje preporuke, dok se ontološke relacije koriste za izbor i redosled sadržaja (odeljak 7.3.1). Na sličan način, personalizovani sadržaj može se studentu ponuditi kao izbor dodatnog teksta, dok se u pozadini oslanja na isti model podataka. Ovakav pristup primenjuje se u pilot primeni na predmetu SE201, u kojoj ontologiju definišu nastavnici, a alat zasnovan na generativnoj veštačkoj inteligenciji na osnovu nje generiše nastavni tekst u skladu sa nivoima dubine i nivoima Bloomove taksonomije. Neposredan prikaz ontološke strukture studentu može biti primereniji naprednijim nivoima studija.

7.2. Evaluacija modela studenata

U okviru evaluacije modela studenata analizira se više aspekata povezanih sa akademskim uspehom, angažovanošću i napretkom studenata kroz različite faze modelovanja. Ovaj proces omogućava dublje razumevanje obrazovnih obrazaca i pruža osnovu za personalizovane intervencije i prilagođavanje nastavnog sadržaja individualnim potrebama studenata. Evaluacija prati faze istraživanja:

- Prva faza evaluacije odnosi se na predikciju studentskog uspeha pomoću algoritama nadgledanog učenja. Poređenjem više klasifikacionih algoritama ispitana je mogućnost klasifikacije konačnog ishoda studenta na predmetu i analizirani su atributi povezani sa akademskim uspehom. Ograničenje ove faze predstavlja statičko modelovanje, koje ne obuhvata hronološke promene stanja studenta niti neposredno povezuje procenu sa konkretnim nastavnim sadržajem.
- Druga faza obuhvata klasterovanje i analizu obrazaca studentskog angažovanja na osnovu njihovih aktivnosti i interakcija sa nastavnim materijalima. Dobijeni klasteri omogućavaju identifikovanje grupa sa sličnim obrascima rada i angažovanja. Oni se u ovoj disertaciji tumače kao empirijski izvedeni ponašajni obrasci u konkretnim skupovima podataka, a ne kao stilovi učenja niti kao trajne karakteristike studenata.

- Treća faza se fokusira na kontinuirano praćenje ovladanosti nastavnim sadržajem, eksplicitno vezano za kompetencijski okvir (odeljak 5.3), što omogućava praćenje napretka studenta kroz vreme na nivou pojedinačne kompetencije i nivoa dubine. Ovaj pristup koristi Bajesovo praćenje znanja (BKT, odeljak 4.3.2) za procenu ovladanosti, dopunjeno slojem ostvarenosti nivoa i ponašajnim klasterovanjem (odeljak 6.5.2). Ova metoda omogućava interpretabilnu procenu ovladanosti na nivou pojedinačnog studenta, uzimajući u obzir dinamiku učenja i hronologiju pokušaja tokom vremena.

Ove faze zajedno omogućavaju sveobuhvatnu analizu studentskog učenja i pružaju osnovu za razvoj adaptivnih obrazovnih sistema koji mogu personalizovati nastavne sadržaje u skladu sa individualnim potrebama studenata. Evaluacija modela studenata ne samo da doprinosi razumevanju ključnih obrazovnih faktora, već pruža i konkretne smernice za unapređenje nastavnog procesa.

7.2.1. Faza 1: Predikcija studentskog uspeha pomoću mašinskog učenja

Rezultati prve faze istraživanja pokazali su da istorijski podaci o studentskim aktivnostima i postignućima sadrže dovoljno informacija za klasifikaciju konačnog ishoda studenta na predmetu. Poređenjem više algoritama mašinskog učenja ispitana je mogućnost razlikovanja studenata koji su predmet položili i onih koji ga nisu položili, kao i povezanost pojedinačnih atributa sa konačnim ishodom. Ova faza predstavljala je početnu proveru mogućnosti primene metoda mašinskog učenja nad raspoloživim obrazovnim podacima. Istovremeno, pokazala je ograničenja statičkog predstavljanja studenta, jer takav model ne prati hronološki razvoj stanja tokom učenja niti povezuje procenu sa konkretnim nastavnim sadržajem na kojem je nastao odgovarajući dokaz. Ova ograničenja predstavljala su jedan od razloga za dalji razvoj modela studenta u narednim fazama istraživanja.

U cilju selekcije karakteristika i analize korelacije između promenljivih, izračunata je korelaciona matrica pomoću Pearsonovog koeficijenta. Slika 35 ilustruje grafikon toplotne mape korelacije ulaznog skupa podataka kreiranog korišćenjem biblioteke Python Pandas. Stepen korelacije klasifikovan je na sledeći način: nizak (ispod 0,29), umeren (od 0,3 do 0,49) i visok (od 0,5 do 1). Na osnovu dobijenih rezultata, može se videti prisustvo umerenih i visokih stepena korelacije između svih promenljivih.

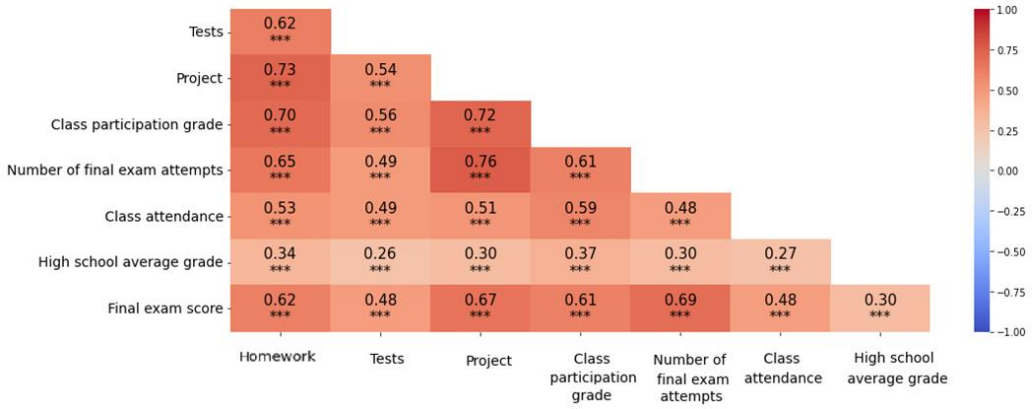

*** - p < 0,001, ** - p < 0,01, * - p < 0,05

Slika 35. Toplotna mapa korelacije.

Bilo je važno analizirati da li korelacija postoji između svih parametara. Na primer, zanimljivo je primetiti da domaći zadaci imaju visoku korelaciju sa testovima (0,62), projektima (0,73), ocenom učešća na času (0,70), brojem pokušaja polaganja završnog ispita (0,65) i prisustvom na času (0,53). Jedno od mogućih objašnjenja uočene povezanosti jeste da studenti koji redovnije prisustvuju nastavi istovremeno češće uspešno realizuju domaće i projektne aktivnosti. Međutim, korelaciona analiza ne omogućava utvrđivanje smera veze niti zaključak da prisustvo samo po sebi uzročno poboljšava rezultate na drugim aktivnostima. Slično tome, projekti pokazuju visoku korelaciju sa ocenom učešća na času (0,72), brojem pokušaja polaganja završnog ispita (0,76) i bodovima na završnom ispitu (0,67). Međutim, fokus analize je stavljen na korelaciju između ocene na završnom ispitu i ostalih parametara. Na osnovu korelacione matrice, može se videti da je najviša korelacija između projekta i broja pokušaja polaganja završnog ispita (0,76). Pored toga, visok nivo korelacije primećen je između rezultata završnog ispita i ocene na projektu (0,67), kao i domaćih zadataka (0,62).

Predmeti koji su uzeti u obzir za skup podataka nisu slični samo po strukturi završne ocene, već i po tipu ocenjivanja. Na primer, svi predmeti su deo nastavnog plana i programa iz oblasti računarstva i imaju visok stepen praktičnih zadataka, a čak su i ocene zasnovane na rešavanju problema koji su uglavnom vezani za programiranje ili neku vrstu tehnoloških (praktičnih) zadataka. Stoga, očekivano je da postoji korelacija između bodova na završnom ispitu i domaćih zadataka i projekata, jer su pitanja na završnom ispitu slična domaćim zadacima i projektnim zadacima. Takođe, treba napomenuti da ocena učešća studenata na času ima visoku korelaciju sa rezultatom na završnom ispitu (0,61), jer ta ocena sama po sebi nosi informaciju o tome koliko je student aktivno i redovno učio tokom semestra, što ukazuje na njegovu pripremu za ispit. Između prosečne ocene iz srednje škole i rezultata završnog ispita utvrđena

je korelacija od 0,30, koja prema primenjenoj klasifikaciji predstavlja umerenu povezanost na njenoj donjoj granici. Ovaj rezultat ukazuje da je u analiziranom skupu podataka povezanost prethodnog školskog uspeha sa rezultatom završnog ispita bila slabija od povezanosti većine atributa ostvarenih tokom samog predmeta. Na osnovu korelacione analize ne može se zaključivati o uzročnom uticaju vrste srednje škole ili prethodno stečenog znanja na prolaznost predmeta. Umerena korelacija je uočena između prisustva na času i testova. Prisustvo na času ne znači nužno da je student aktivan i učestvuje. Zbog toga postoji visoka korelacija između rezultata završnog ispita i ocene učešća na času (0,61), ali samo umerena korelacija između rezultata završnog ispita i prisustva na času (0,48). Slično tome, postoji umerena korelacija između rezultata završnog ispita i ocena na testovima (0,48). Ovo je zanimljivo jer su većina testova pitanja sa višestrukim izborom, uključujući teorijski deo gradiva, dok završni ispit sadrži i teorijska i praktična pitanja. Takođe, vidimo umeren i visok stepen korelacije između različitih karakteristika i ciljnih varijabli (rezultat na završnom ispitu), tako da su sve karakteristike zadržane u skupu podataka.

Kako bismo izabrali klasifikator za predviđanje ishoda završnog ispita (da li je predmet položen ili ne), sprovedena je metoda unakrsne validacije sa 10 podela (10-fold cross-validation). Ova metoda deli skup podataka za treniranje u 10 grupa približno jednake veličine, trenira model na devet grupa i testira ga na desetoj grupi tokom deset iteracija. Rezultati eksperimenata su sumirani korišćenjem tačnosti klasifikatora, koja je izračunata kao prosečna tačnost nakon deset iteracija unakrsne validacije. Za validaciju modela primenjeno je šest algoritama mašinskog učenja. Tačnost klasifikatora za svih deset iteracija predstavljena je pomoću boxplot dijagrama na Slici 36.

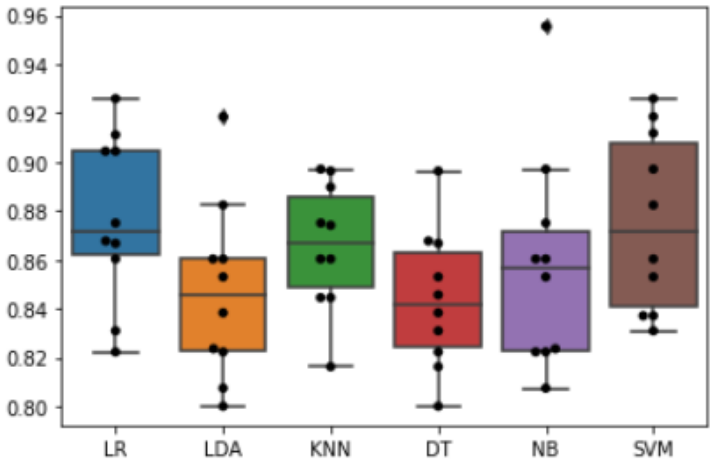

Slika 36. Boxplot dijagram sa tačnošću nakon 10 iteracija unakrsne validacije za šest različitih klasifikatora.

SVM je pokazao najbolje rezultate pri izboru klasifikatora u svih deset iteracija sa prosečnom tačnošću od 88,5%. Ostali analizirani algoritmi pokazali su sledeće prosečne tačnosti: LR (87,6%), LDA (84,6%), KNN (86,5%), DT (84,4%) i NB (85,7%). Dobijeni rezultati su u skladu sa zaključcima iz [271], koji pokazuju da SVM dobro funkcioniše na malim skupovima podataka. Kao algoritam nadgledanog učenja za klasifikacione probleme, SVM daje najbolje performanse kada su granice klasa nelinearne, jer se fokusira samo na granice klasa, dok tačke koje se ionako lako klasifikuju zanemaruje [272].

Nakon obuke modela, testiran je na prikupljenom skupu podataka. Predloženi model za predviđanje akademskog uspeha studenata na osnovu SVM algoritma pokazuje tačnost od 90,3% nakon evaluacije na testnom skupu podataka. Performanse odabranog modela dodatno su procenjene pomoću matrice konfuzije. Matrica konfuzije sumira ukupne performanse odabranog modela, kao što je prikazano na Slici 37.

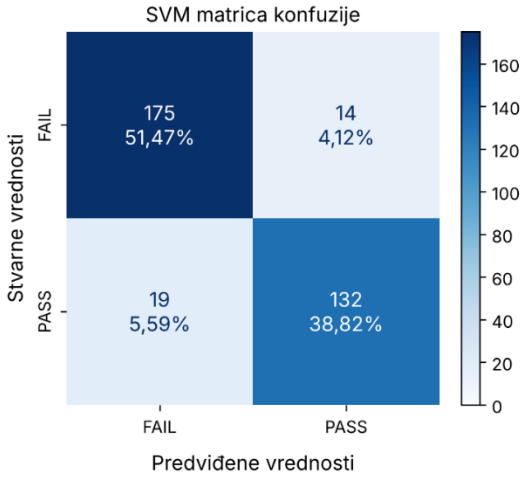

Slika 37. Matrica konfuzije SVM predloženog modela.

Na Slici 37 redovi predstavljaju stvarne, a kolone predviđene vrednosti. Od 189 studenata koji nisu položili ispit, model je tačno klasifikovao 175, dok je 14 pogrešno svrstao u grupu studenata koji su ispit položili. Od 151 studenta koji su položili ispit, model je tačno klasifikovao 132, dok je 19 pogrešno svrstao u grupu studenata koji nisu položili ispit. Ako se neuspeh na ispitu posmatra kao pozitivna klasa, jer je cilj modela pravovremeno prepoznavanje studenata kojima je potrebna podrška, matrica sadrži 175 stvarno pozitivnih (TP), 14 lažno negativnih (FN), 19 lažno pozitivnih (FP) i 132 stvarno negativna (TN) ishoda. Brojevi 175 i 132 predstavljaju samo tačne predikcije, a ne ukupan broj studenata za koje je model predvideo neuspeh, odnosno uspeh. Ukupno je model predvideo neuspeh za 194, a uspeh za 146 studenata. Studenti koji nisu položili ispit čine 55,6% testnog skupa, pa bi model koji uvek predviđa većinsku klasu imao tačnost 55,6%. Ostvarena tačnost od 90,3% zato je znatno iznad tog osnovnog nivoa.

Performanse evaluiranog SVM modela prikazane su kroz preciznost i odziv, kao što je prikazano u Tabeli 18.

Tabela 18. Performanse prediktivnog modela.

	Preciznost (%)	**Odziv (%)**	**F1 (%)**
FAIL	90%	93%	91%
PASS	90%	87%	89%

Na osnovu preciznosti, možemo videti da od svih predikcija „padanja“, 90% studenata zaista nije položilo ispit, dok je od svih predikcija „polaganja“, 90% studenata zaista položilo ispit. S druge strane, na osnovu odziva vidimo da je model tačno predvideo 93% od ukupnog broja studenata koji su zaista pali ispit, dok je za studente koji su položili model tačno predvideo 87% slučajeva. Ove metrike potvrđuju da odabrani model daje veoma zadovoljavajuće rezultate u predviđanju ishoda završnog ispita. Rezultati pokazuju da se izabrani model može koristiti za predviđanje ishoda završnog ispita (da li je predmet položen ili ne) sa dovoljno visokom tačnošću. Ovaj rezultat potvrđuje da analizirani istorijski atributi aktivnosti i postignuća sadrže dovoljno informacija za klasifikaciju konačnog ishoda završnog ispita u posmatranom skupu podataka, ali sam dizajn ove faze ne omogućava zaključak o vremenski ranoj identifikaciji rizika tokom semestra.

Na osnovu dobijenih rezultata, zaključeno je da predloženi model za predikciju akademskog uspeha studenata daje visoku tačnost, pri čemu se SVM algoritam pokazao kao najefikasniji u klasifikaciji podataka o prolaznosti završnog ispita. Ovi nalazi naglašavaju značaj pravilnog izbora karakteristika i korelacionih analiza u procesu modeliranja studentskog uspeha.

Međutim, postoje određena ograničenja koja zahtevaju dalju analizu. Pre svega, potrebno je uvesti sekvencijalno modelovanje studentskog ponašanja, kako bi se omogućilo kontinuirano praćenje interakcija studenata sa nastavnim sadržajem i predavačima. Ovaj pristup može doprineti preciznijim predikcijama, jer u obzir uzima vremenske faktore i obrazovne navike studenata tokom celog semestra. Pored toga, dublja analiza granularnosti obrazovnih sadržaja može poboljšati tačnost modela, naročito kada su u pitanju različite strukture predmeta. Prilagođavanje modela specifičnim nastavnim metodologijama omogućilo bi bolju primenu u različitim akademskim okruženjima.

7.2.2. Faza 2: Klasterovanje i analiza obrazaca učenja

Kako bi se studenti grupisali na osnovu podataka o njihovim aktivnostima i postignućima tokom semestra, sprovedena je druga faza evaluacije primenom k-means klasterovanja. Cilj ove faze bio je da se identifikuju grupe studenata sa sličnim obrascima angažovanja i da se ispita koje karakteristike raspoloživih podataka najviše doprinose razlikovanju dobijenih grupa u dva različita nastavna konteksta. Razmatrani su različiti brojevi klastera, ali su za prikaz i poređenje rezultata između dve institucije izabrana tri klastera. Ovo rešenje korišćeno je kao deskriptivna osnova za komparativnu analizu, a ne kao empirijski potvrđen optimalan broj klastera.

Ukupan broj studenata koji su učestvovali u analizi bio je 409 (97 BMU, 312 FOI), u skladu sa skupom podataka opisanim u poglavlju 6. Za potrebe poređenja rezultata između dve institucije, k-means klasterovanjem formirane su tri deskriptivne grupe:

- **Veoma** aktivni studenti - rezultati sa višim nivoom zabeleženih aktivnosti u raspoloživim atributima, uključujući redovno učešće u nastavnim aktivnostima i više rezultate na pojedinim ocenjenim aktivnostima.
- **Umereno aktivni studenti** - studenti sa srednjim nivoom zabeležene aktivnosti i izraženijim varijacijama u učešću u nastavnim aktivnostima.
- **Pasivni studenti** - studenti sa nižim nivoom zabeležene aktivnosti, uključujući ređe učešće u testovima, zadacima ili drugim evidentiranim aktivnostima.

U ovoj fazi tri klastera korišćena su kao deskriptivno rešenje koje olakšava poređenje dve institucije, a ne kao univerzalna tipologija studenata. Pripadnost klasteru omogućila je opisivanje obrazaca angažovanja, ali nije pružala dovoljno osnova da se iz nje zaključi ovladanost konkretnim nastavnim sadržajem ili da se neposredno odredi šta pojedinačnom

studentu treba preporučiti. Posebno, oznake veoma aktivan, umereno aktivan i pasivan ne treba tumačiti kao ekvivalent visokog, srednjeg i niskog znanja. U izvornom istraživanju razmatrana je mogućnost da se ovako formirani klasteri u budućem sistemu koriste kao dodatna osnova za prilagođavanje podrške studentima, ali su rezultati druge faze u ovoj disertaciji prvenstveno tumačeni kao pokazatelj mogućnosti identifikovanja različitih obrazaca angažovanja i značaja granularnosti podataka za modelovanje studenta. Upravo je ovo ograničenje usmerilo treću fazu ka razdvajanju ponašajnog tipa od procene ovladanosti i ka individualnoj, sadržajno lokalizovanoj preporuci.

Na Slici 38 prikazano je grupisanje rezultata BMU studenata po objektima učenja u tri klastera. Klasterovanje je sprovedeno k-means algoritmom nad atributima BMU skupa podataka opisanim u odeljku 6.4: broj bodova na testu, broj bodova na domaćem zadatku, broj bodova na testovima za samoprocenu i binarni pokazatelj korišćenja svakog objekta učenja. Kako bi se rezultati klasterovanja mogli grafički prikazati, nad podacima je zatim sprovedena redukcija dimenzionalnosti analizom glavnih komponenti (engl. Principal Component Analysis (PCA)), kojom su podaci predstavljeni u tri dimenzije, odnosno pomoću prve tri glavne komponente [19]. PCA je pri tome korišćena samo za vizualizaciju, dok su klasteri formirani nad izvornim atributima. Na Slici 38 prikazane su tri grupe koje zauzimaju pretežno različite oblasti trodimenzionalnog prostora glavnih komponenti. Ovakav prikaz omogućava vizuelno poređenje njihovog međusobnog rasporeda, ali sam po sebi ne potvrđuje optimalnost izbora tri klastera [19]. Interpretacija klastera zasniva se na vrednostima atributa korišćenih za njihovo formiranje.

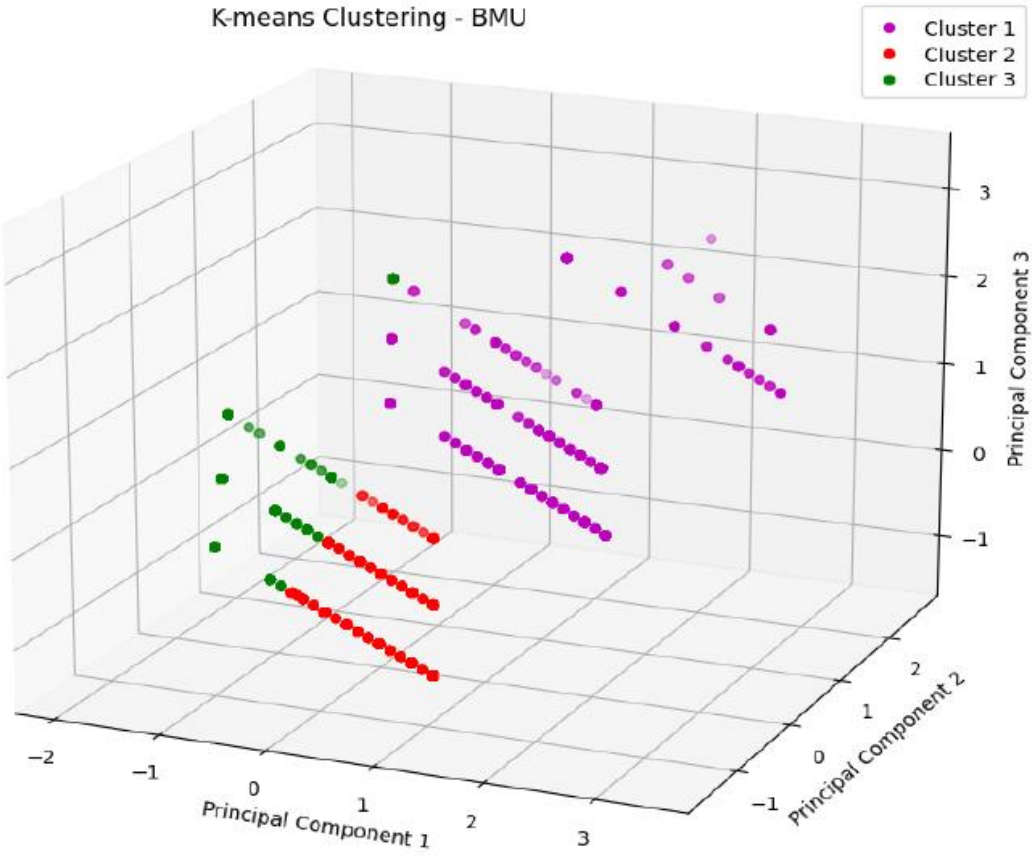

Slika 38. K-means klasterovanje rezultata BMU studenata po objektima učenja nakon redukcije dimenzionalnosti. Preuzeto iz [19].

Raspodela po klasterima za BMU i FOI prikazana je na Slici 39. U skladu sa strukturom skupova podataka, procenti su izračunati na nivou rezultata studenata po objektima učenja na BMU (2435 rezultata za 97 studenata), odnosno po lekcijama na FOI, a ne na nivou studenata. U skupu podataka BMU-a najveći broj rezultata pripada grupi veoma aktivnih, dok je najmanja grupa pasivnih. Nasuprot tome, u FOI skupu podataka više od polovine rezultata svrstano je u grupu pasivnih, a oko trećine u grupu veoma aktivnih.

Raspodela po klasterima razlikovala se između dva skupa podataka, koji su poticali iz različitih nastavnih i institucionalnih konteksta. Jedna od uočenih razlika odnosila se na granularnost nastavnog sadržaja i mapiranja aktivnosti: BMU je koristio objekte učenja kao segmente lekcija i povezivao aktivnosti sa specifičnim OU-vima, dok je FOI koristio celovite lekcije bez preciznijeg mapiranja. Pošto su se predmeti istovremeno razlikovali i prema

instituciji, LMS platformi, načinu izvođenja nastave i skupu raspoloživih atributa, ovom analizom nije moguće izdvojiti granularnost kao samostalan uzrok razlika u raspodeli klastera.

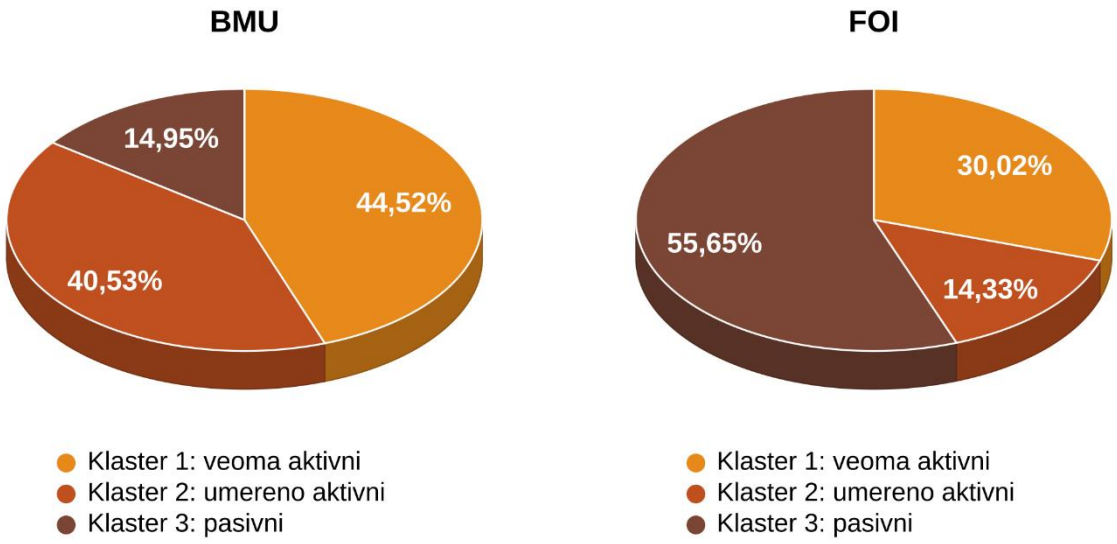

Slika 39. Raspodela rezultata studenata po klasterima na BMU i FOI.

Dodatno, sprovedena je analiza značaja karakteristika, kako bi se identifikovale varijable koje imaju najveći uticaj na diferencijaciju klastera. Za BMU skup podataka, broj bodova na testovima imao je najveći doprinos razlikovanju dobijenih klastera među analiziranim atributima. Ovaj nalaz odnosi se na konkretan skup podataka i korišćene karakteristike i ne znači da rezultati testova predstavljaju univerzalno najprecizniju meru znanja ili angažovanja studenata. Međutim, specifičnost BMU podataka jeste što su svi testovi rađeni tokom pandemije, što može uticati na njihovu objektivnost.

U FOI skupu podataka, kao ključni faktori razlikovanja izdvojili su se „Bodovi sa samoprocenjivanja“ i „Lekcija je pokrenuta“. Podaci ukazuju na izražen vremenski obrazac aktivnosti: angažovanost je bila veća na početku semestra, zatim je opadala tokom njegovog srednjeg dela, a ponovni porast aktivnosti zabeležen je nakon prvog međuispita. Ovakav obrazac ukazuje da se intenzitet studentske aktivnosti menja tokom semestra i da vremenska raspodela angažovanja predstavlja relevantnu informaciju za projektovanje budućeg modela studenta. Razlozi za uočene promene, uključujući moguću promenu motivacije, nisu neposredno ispitivani u ovoj analizi.

Druga faza evaluacije pokazala je da klasterovanje može da izdvoji obrasce angažovanja i da se njihova struktura razlikuje u zavisnosti od nastavnog i institucionalnog konteksta. Analiza je takođe ukazala na značaj granularnosti nastavnog sadržaja i načina beleženja aktivnosti za interpretaciju dobijenih grupa. Međutim, rezultati ove faze nisu korišćeni kao dokaz da

pripadnost klasteru određuje znanje studenta niti kao samostalna osnova za preporuku sadržaja. Nalazi su iskorišćeni kao projektni zahtev za treću fazu, u kojoj se ponašajni obrazac odvaja od ovladanosti i ostvarenosti nivoa, a preporuka se zasniva na individualnim procenama, statusu pokušaja i ontološkim relacijama. Ovi nalazi predstavljali su osnovu za narednu fazu razvoja modela studenta, usmerenu ka individualnom i sekvencijalnom praćenju stanja studenta i sadržajno lokalizovanoj adaptivnoj podršci tokom procesa učenja.

7.2.3. Faza 3: Model kontinuiranog praćenja ovladanosti nastavnim sadržajem

U trećoj fazi evaluacije, model studenta opisan u odeljku 6.5 primenjen je na podatke prikupljene tokom redovne realizacije dva predmeta: SE201, koji je pohađalo 37 studenata, i CS202, koji su pohađala 74 studenta. Analitičku kohortu činili su studenti za koje je postojalo najmanje jedno zapažanje relevantno za procenu ovladanosti, odnosno rezultat aktivnosti provere mapiran na jedan ili više objekata učenja, pripadajuće kompetencije i nivoe dubine.

Cilj evaluacije bio je da se ispita da li predloženi model može:

- da verifikovane rezultate aktivnosti pretvori u interpretabilne procene ovladanosti kompetencijama;
- da razlikuje demonstriranu ovladanost od ostvarenosti aktivnosti predviđenih za odgovarajući nivo dubine;
- da prikaže razlike između pojedinačnih profila studenata koje se ne vide iz ukupne ocene;
- da identifikuje ponašajne tipove studenata nezavisno od njihovog postignuća;
- da obezbedi ulazne podatke za generisanje objašnjivih preporuka zasnovanih na ontološkim relacijama.

Rezultati su prikazani kroz pet međusobno povezanih celina:

- procenu ovladanosti kompetencijama i ostvarenosti nivoa na nivou kohorte;
- individualne profile ovladanosti po kompetencijama;
- ponašajne tipove studenata dobijene klasterovanjem;
- sadržaje identifikovane za podršku i rezultate generisanja preporuka;
- povratne informacije studenata o kontrolnoj tabli, preporukama i njihovim objašnjenjima.

Evaluacija je koncipirana kao provera koncepta na stvarnim podacima iz nastavnog okruženja. Njena svrha je da pokaže izvodljivost i interpretabilnost integrisanog postupka, a ne da potvrdi stabilne populacione vrednosti ili uzročno dejstvo preporuka na ishode učenja. Dobijeni numerički rezultati zato se tumače u okviru posmatranih predmeta, jedne generacije studenata i primenjenih odluka modelovanja.

7.2.3.1. Ovladanost kompetencijama i ostvarenost nivoa na nivou kohorte

Za svaki predmet i nivo dubine izračunate su dve komplementarne mere. Ovladanost kompetencijama predstavlja prosečnu posteriornu procenu dobijenu sekvencijalnim BKT slojem za odgovarajuće kombinacije predmet-kompetencija predmeta-nivo dubine. Ostvarenost nivoa predstavlja udeo osvojenih poena u ukupnom broju poena aktivnosti provere predviđenih za odgovarajući nivo (jednačina 11), pri čemu se u obračun uključuju samo trenutno važeći pokušaji. Prva mera opisuje koliko uspešno studenti savladavaju sadržaj sa kojim su radili, dok druga pokazuje koliki su deo poena predviđenih za dati nivo ostvarili, uključujući i aktivnosti koje nisu realizovali.

U Tabeli 19 prikazani su rezultati za nivoe N1 i N2. Nivo N3 nije uključen u poređenje na nivou kohorte zato što je bio opcioni i za njega nije postojao dovoljan broj zapažanja: na predmetu SE201 nijedan student nije generisao dokaz iz aktivnosti provere na ovom nivou, dok je na predmetu CS202 odgovarajuću esejsku aktivnost realizovalo šest studenata. Odsustvo vrednosti za N3 zato ne predstavlja neuspeh modela niti neuspeh studenata, već posledicu opcione prirode nivoa i ograničenog broja raspoloživih dokaza.

Tabela 19. Prosečna ovladanost kompetencijama i ostvarenost nivoa prema predmetu i nivou dubine.

Predmet	Nivo	Ovladanost kompetencijama	Ostvarenost nivoa
SE201	N1	92,6%	65,0%
SE201	N2	87,0%	45,3%
CS202	N1	86,4%	57,1%
CS202	N2	71,6%	31,5%

Rezultati iz Tabele 19 pokazuju dva zajednička obrasca. Prvo, prosečne vrednosti obe mere niže su na nivou N2 nego na nivou N1 u oba predmeta. Na predmetu SE201 ovladanost kompetencijama opada sa 92,6% na nivou N1 na 87,0% na nivou N2, dok ostvarenost nivoa opada sa 65,0% na 45,3%. Na predmetu CS202 ovladanost opada sa 86,4% na 71,6%, a ostvarenost nivoa sa 57,1% na 31,5%. Rezultati pokazuju da su studenti na nivou N2 ostvarili manji deo predviđenih poena, bilo zato što nisu realizovali sve aktivnosti, bilo zbog slabijih

rezultata na njima, i da je, naročito u predmetu CS202, za ovaj nivo dobijena niža prosečna procena ovladanosti nego za obavezni sadržaj nivoa N1.

Drugo, ovladanost kompetencijama i ostvarenost nivoa razlikuju se u svim posmatranim slučajevima. Razlika je posebno izražena na nivou N2. Na predmetu CS202 prosečna ovladanost kompetencijama na ovom nivou iznosi 71,6%, dok je prosečna ostvarenost nivoa 31,5%. Pošto ostvarenost nivoa zavisi i od broja realizovanih aktivnosti i od poena osvojenih na njima, niža vrednost ove mere ne znači nužno da studenti nisu uradili predviđene aktivnosti, već može odražavati i slabije rezultate na realizovanim aktivnostima. Ipak, relativno visoka ovladanost sadržajima sa kojima su studenti radili upućuje na to da značajan deo neostvarenih poena na nivou N2 potiče od aktivnosti koje nisu realizovane. Ovaj nalaz pokazuje zašto ovladanost i ostvarenost nije opravdano objediniti u jednu vrednost. Jedinstvena agregirana ocena ne bi mogla da razlikuje studenta koji je uspešan na manjem broju pokušavanih aktivnosti od studenta koji je realizovao veći obim aktivnosti, ali na njima nije pokazao odgovarajući nivo ovladanosti. Dvoslojni prikaz zato omogućava preciznije razlikovanje teškoća povezanih sa savladavanjem sadržaja od teškoća povezanih sa nepotpunom realizacijom predviđenih obaveza.

Razlika nije posledica samo nekoliko pojedinačnih rezultata. Na nivou N2 ostvarenost nižu od 50% imalo je 20 od 37 studenata predmeta SE201 i 60 od 74 studenta predmeta CS202. Ostvarenost od najmanje 50% na oba nivoa, N1 i N2, imalo je 16 studenata predmeta SE201 i 13 studenata predmeta CS202. Obrazac je posebno izražen na predmetu CS202, gde većina studenata nije ostvarila ni polovinu poena predviđenih za zahtevnije praktične zadatke i projektni rad, bilo zbog nepotpune realizacije, bilo zbog slabijih rezultata na tim aktivnostima.

Provera osetljivosti i stabilnosti procene ovladanosti. Kako bi se proverilo u kojoj meri dobijeni rezultati zavise od konkretnih odluka modelovanja, sprovedene su dodatne analize osetljivosti pragova ovladanosti i ponderisanja dokaza, kao i unakrsna validacija BKT procena. Analiza pragova obuhvatila je devet kombinacija vrednosti oko pragova korišćenih u osnovnom modelu. Prag za nivo N1 menjan je kroz vrednosti 0,70, 0,80 i 0,90, dok je prag za nivo N2 menjan kroz vrednosti 0,40, 0,50 i 0,60. Analiza je sprovedena za nivoe N1 i N2, za koje je postojao dovoljan broj zapažanja za poređenje na nivou kohorte.

Promena pragova nije uticala na vrednosti ostvarenosti nivoa, jer se ova mera izračunava nezavisno od pragova ovladanosti, na osnovu rezultata propisanih aktivnosti, pri čemu dostupna, ali nerealizovana aktivnost doprinosi vrednošću nula. Očekivano, promena pragova

menjala je broj objekata učenja označenih kao nedovoljno savladani: stroži pragovi povećavali su, a blaži smanjivali njihov broj. Međutim, promene su bile postepene i monotone, bez naglih promena ili preokretanja obrazaca utvrđenih na nivou kohorte. To pokazuje da identifikovani obrasci nisu artefakt konkretno izabranih vrednosti 0,80 za N1 i 0,50 za N2.

Posebno je proverena i osetljivost na ponder relevantnosti kojim nastavnik označava u kojoj meri rezultat određene aktivnosti predstavlja informativan dokaz za objekat učenja sa kojim je aktivnost povezana. U osnovnoj varijanti ponderisano zapažanje određeno je izrazom $o'=0{,}5+(o-0{,}5)\cdot\omega/3$, gde je o ostvareni rezultat, a ω ponder relevantnosti iz skupa $\{1, 2, 3\}$. Ovakvo ponderisanje poređeno je sa dve alternativne varijante: varijantom bez ponderisanja, u kojoj svaka veza prenosi pun signal ($o'=o$), i varijantom samo centralnih veza, u kojoj pun signal prenose isključivo veze sa $\omega=3$, dok se ostale postavljaju na neutralnu vrednost 0,5.

Raspodela pondera pokazuje da oni u podacima nisu bili uniformni. U predmetu SE201 jedna veza imala je ponder 1, 19 veza ponder 2, a 11 veza ponder 3. U predmetu CS202 odgovarajući brojevi iznosili su 17, 23 i 45. Uprkos tome, pri poređenju sve tri varijante ponderisanja prosečna ovladanost kompetencijama na nivou kohorte menjala se za najviše 0,8 procentnih poena na bilo kom nivou dubine u oba predmeta. Ponderisanje zato utiče na fino razlikovanje pojedinačnih dokaza, ali ne menja osnovni obrazac rezultata na nivou kohorte.

Dodatna provera odnosila se na činjenicu da su u osnovnoj realizaciji parametri BKT modela procenjivani na podacima iste kohorte za koju su zatim izračunate posteriorne procene ovladanosti. Zbog toga je sprovedena petostruka unakrsna validacija unutar svake kombinacije predmet-kompetencija predmeta-nivo dubine koja je sadržala podatke za najmanje deset studenata. U svakom koraku parametri modela procenjivani su na 80% studenata, a zatim primenjeni na preostalih 20%. Procene ovladanosti dobijene za izdvojene studente poređene su sa procenama dobijenim kada su parametri procenjeni na kompletnoj kohorti.

Srednja apsolutna razlika između dve procene iznosila je 0,008 za SE201 i 0,010 za CS202. Ovako male vrednosti ukazuju da individualne procene ovladanosti nisu značajno zavisile od toga da li su podaci konkretnog studenta učestvovali u proceni parametara BKT modela. Ovu proveru ipak treba tumačiti kao proveru stabilnosti unutar posmatranih kohorti, a ne kao dokaz generalizacije modela na novu generaciju studenata ili drugi nastavni kontekst. Za takvu tvrdnju bilo bi potrebno naknadno testiranje na nezavisnoj kohorti. Sažeti rezultati provere stabilnosti procena i poređenja prediktivne sposobnosti prikazani su u Tabeli 20.

Tabela 20. Stabilnost procena ovladanosti i poređenje prediktivne sposobnosti kontinuirane i binarne BKT formulacije.

Predmet	Srednja apsolutna razlika procene ovladanosti	Kontinuirani BKT - logaritamski gubitak	Binarni BKT - logaritamski gubitak	Prosečan rezultat - logaritamski gubitak
SE201	0,008	0,5037	0,5053	0,5331
CS202	0,010	0,5280	0,5140	0,5788

Napomena: Srednja apsolutna razlika odnosi se na poređenje procena za izdvojene studente dobijenih parametrima procenjenim na 80% kohorte sa procenama dobijenim parametrima procenjenim na celokupnoj kohorti. Logaritamski gubitak odnosi se na predviđanje narednog zapažanja u okviru iste petostruke unakrsne validacije; za sve tri varijante računat je istom formulom i prema istim kontinuiranim zapažanjima, a binarna formulacija koristi prag 0,5 samo pri ocenjivanju parametara i ažuriranju procene. Niža vrednost označava bolju prediktivnu sposobnost.

Pored provere stabilnosti samih procena, kontinuirana formulacija BKT-a poređena je, u istom postupku petostruke unakrsne validacije, sa standardnom binarnom BKT formulacijom i jednostavnom referentnom varijantom zasnovanom na prosečnom rezultatu. Za poređenje je korišćen logaritamski gubitak pri predviđanju narednog zapažanja. Unakrsna validacija sprovedena je na nivou studenata, za sve kombinacije predmet-kompetencija predmeta-nivo dubine sa najmanje deset studenata, pri čemu su parametri u svakom koraku ocenjivani samo na osnovu studenata iz skupa za obuku. Za svako zapažanje izdvojenog studenta model je, na osnovu njegovih prethodnih zapažanja i pre ažuriranja tekućim rezultatom, predviđao verovatnoću uspeha prema jednačini (1). Gubitak je za sve tri varijante izračunat istom formulom, $-[o \cdot log\ p\ +\ (1-o) \cdot log(1-p)]$, i prema istim ciljnim vrednostima, odnosno kontinuiranim zapažanjima $o \in [0, 1]$ iz sekvence. Binarna formulacija razlikovala se samo po tome što su pri ocenjivanju parametara i ažuriranju procene opažanja binarizovana pragom 0,5 ($o \geq 0{,}5$ kao uspešno, inače kao neuspešno), dok je evaluirana prema istim kontinuiranim rezultatima kao i kontinuirana formulacija. Referentna varijanta za svako zapažanje predviđala je prosečan rezultat svih studenata iz skupa za obuku za odgovarajuću kombinaciju predmet-kompetencija predmeta-nivo dubine. Na taj način razlike u gubitku odražavaju razliku u kvalitetu predikcije, a ne razliku u ciljnim vrednostima ili načinu računanja gubitka. Kontinuirani BKT ostvario je manji logaritamski gubitak od referentne vrednosti zasnovane na prosečnom rezultatu u oba predmeta: 0,5037 prema 0,5331 u SE201 i 0,5280 prema 0,5788 u CS202.

U odnosu na binarnu BKT formulaciju, rezultati su bili slični. U predmetu SE201 kontinuirana formulacija ostvarila je neznatno manji logaritamski gubitak, 0,5037 u odnosu na 0,5053, dok je u predmetu CS202 binarna formulacija bila nešto uspešnija, sa vrednošću 0,5140

u odnosu na 0,5280 za kontinuirani BKT. Zbog toga izbor kontinuirane formulacije nije opravdan tvrdnjom o većoj prediktivnoj tačnosti. Njena prednost u okviru ovog istraživanja jeste očuvanje informacije o parcijalnom uspehu studenta, formalizovano kontinuiranom opservacionom formulacijom iz odeljka 4.3.2.2 (jednačine 5-6). Rezultat od, na primer, 60% ostaje različit od rezultata od 0%, umesto da se oba nužno svedu na istu binarnu kategoriju. Takva razlika je pedagoški relevantna kada se procena koristi za lokalizovanje nedovoljno ovladanih kompetencija i objekata učenja i za formiranje daljih preporuka.

Zajedno posmatrani, rezultati analize osetljivosti i unakrsne validacije podržavaju stabilnost projektnih odluka primenjenih u sloju za procenu ovladanosti. Osnovni odnosi između nivoa i predmeta ostaju očuvani pri promeni pragova, alternativni načini ponderisanja imaju mali uticaj na agregirane procene, a procene dobijene za izdvojene studente veoma su bliske procenama zasnovanim na parametrima cele kohorte. Istovremeno, poređenje sa binarnim BKT-om pokazuje da kontinuiranu formulaciju treba posmatrati prvenstveno kao način očuvanja granularnosti obrazovnog dokaza, a ne kao prediktivno superiorniji algoritam. Ove rezultate ipak ne treba tumačiti kao dokaz da je predmet CS202 u celini pedagoški manje uspešan ili da studenti ovog predmeta imaju niže sposobnosti.

Predmeti se razlikuju prema domenu, vrsti praktičnog rada, strukturi aktivnosti i broju studenata. Poređenje pokazuje da ista arhitektura može da identifikuje različite obrasce ovladanosti i realizacije aktivnosti u različitim nastavnim kontekstima, a ne da jedan predmet rangira u odnosu na drugi. Rezultati na nivou kohorte potvrđuju da dve komponente modela pružaju različite informacije o studentskom napretku. Međutim, prosečne vrednosti ne pokazuju koje su konkretne kompetencije kod pojedinačnih studenata dobro ili nedovoljno savladane. Zbog toga je u narednom koraku analizirana struktura ovladanosti na nivou pojedinačnog studenta, kompetencije i dubine.

7.2.3.2. Individualni profili ovladanosti po kompetencijama

Rezultati na nivou kohorte pokazuju opšti odnos između nivoa dubine i omogućavaju identifikovanje nivoa na kojima su teškoće najizraženije. Međutim, prosečne vrednosti ne pokazuju unutrašnju strukturu postignuća pojedinačnih studenata. Pošto model procenjuje ovladanost zasebno za svaku kombinaciju student-predmet-kompetencija predmeta-nivo dubine, moguće je utvrditi koje kompetencije predstavljaju jake strane studenta, koje su pokušane, ali nedovoljno savladane, i za koje kompetencije ne postoji procena zbog odsustva odgovarajućih zapažanja.

Na Slici 40 prikazani su profili ovladanosti četiri odabrana studenta: jednog studenta sa višim i jednog sa nižim ukupnim postignućem iz svakog od predmeta SE201 i CS202. Stubići za nivo N1 predstavljaju procene ovladanosti obaveznim osnovnim sadržajem, dok stubići za nivo N2 predstavljaju procene ovladanosti sadržajem srednjeg nivoa. Odsustvo stubića za N2 ne označava ovladanost jednaku nuli, već pokazuje da student za datu kompetenciju nije generisao zapažanja na tom nivou i da odgovarajuća procena nije formirana.

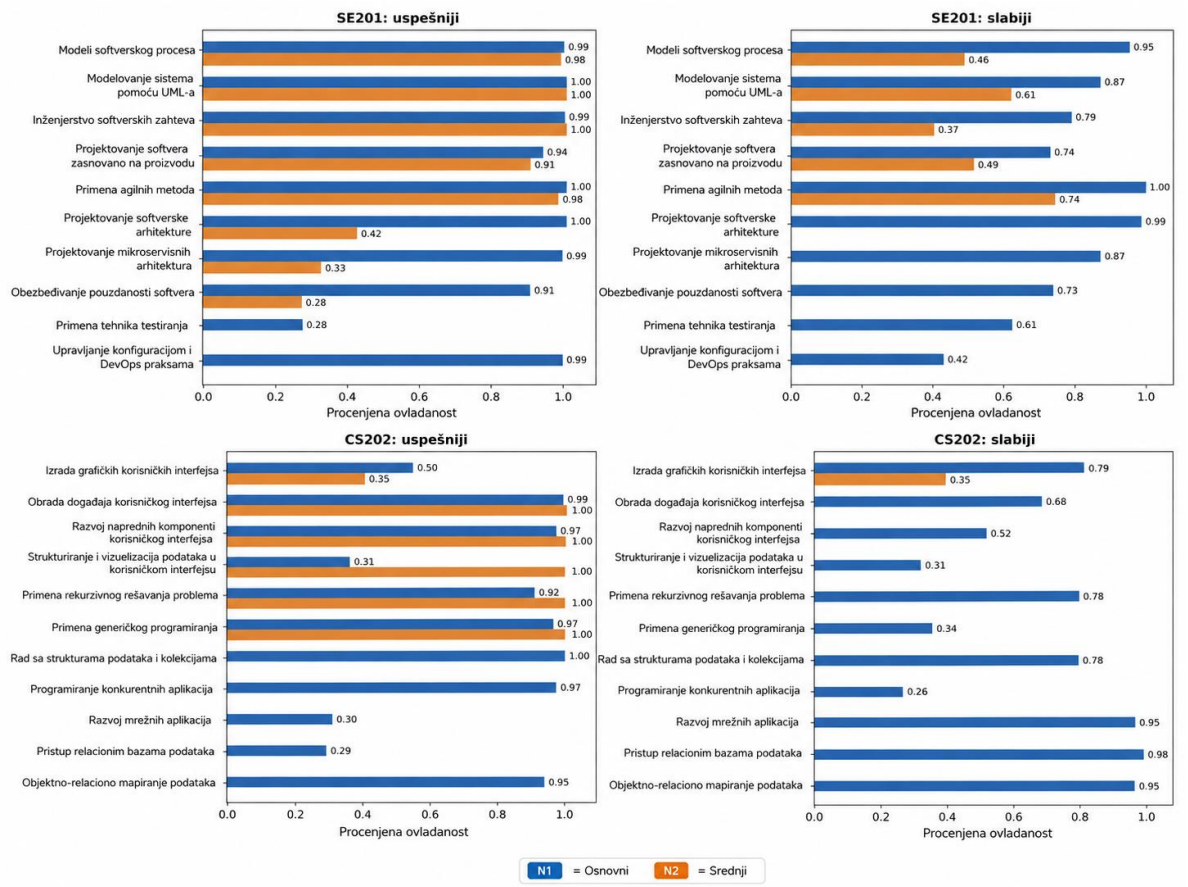

Slika 40. Profili ovladanosti kompetencijama na nivoima dubine N1 i N2 za četiri odabrana studenta, po dva iz predmeta SE201 i CS202.

Napomena: Odsustvo stubića za nivo N2 označava da za datu kombinaciju student-kompetencija-nivo nije formirana procena zbog odsustva relevantnih zapažanja; ne predstavlja procenu ovladanosti jednaku nuli.

Individualni profili pokazuju da ukupna ocena ili jedinstveno rangiranje ne pružaju dovoljno preciznu sliku studentskog postignuća. Student može imati visoko ukupno postignuće, ali istovremeno i jasno lokalizovane slabe tačke, dok student sa nižim ukupnim postignućem može pokazati visok nivo ovladanosti pojedinim kompetencijama. Profili takođe pokazuju da se razlika između nivoa N1 i N2, utvrđena na nivou kohorte, pojavljuje i kod pojedinačnih studenata. Kod studenta sa višim ukupnim postignućem na predmetu SE201 prosečna procena ovladanosti kompetencijama na nivou N1 iznosi 0,91. Iako student pokazuje visoku ovladanost

većinom kompetencija osnovnog nivoa, kod kompetencije koja se odnosi na primenu tehnika testiranja procenjena ovladanost iznosi samo 0,28. Na nivou N2 isti student pokazuje potpunu procenjenu ovladanost kompetencijom modelovanja sistema pomoću UML-a, sa vrednošću 1,00, ali istovremeno ima nisku procenu ovladanosti kompetencijom obezbeđivanja pouzdanosti softvera, koja iznosi 0,28.

Student sa nižim ukupnim postignućem na predmetu SE201 ima prosečnu procenu ovladanosti od 0,80 na nivou N1 i 0,53 na nivou N2. Za nivo N2 procena je formirana samo za pet od ukupno deset kompetencija predmeta. Za preostalih pet kompetencija ne postoji procena ovladanosti na nivou N2, jer student nije generisao relevantna zapažanja na tom nivou. Ovakav profil predstavlja individualni primer manjeg obima rada na srednjem nivou, koji je prethodno utvrđen i u rezultatima cele kohorte.

Profili dva studenta predmeta CS202 posebno jasno pokazuju zašto ukupno rangiranje nije dovoljno za adaptivnu podršku. Njihove jake i slabe kompetencije gotovo su međusobno obrnute. Student sa višim ukupnim postignućem pokazuje potpunu procenjenu ovladanost strukturama podataka i kolekcijama, sa vrednošću 1,00, ali nisku ovladanost pristupom relacionim bazama podataka, sa vrednošću 0,29, kao i nisku ovladanost kompetencijom koja se odnosi na mrežne aplikacije. Nasuprot tome, student sa nižim ukupnim postignućem pokazuje visoku procenjenu ovladanost relacionim bazama podataka, sa vrednošću 0,98, kao i mrežnim aplikacijama. Međutim, kod ovog studenta identifikovana je niska procena ovladanosti konkurentnim aplikacijama, sa vrednošću 0,26, kao i slabija ovladanost strukturiranjem podataka korisničkog interfejsa. Jedinstveno rangiranje postavilo bi jednog studenta iznad drugog, ali profili kompetencija pokazuju da svaki od njih ima različitu osnovu za dalji razvoj i zahteva drugačiji skup preporučenih sadržaja.

Za pravilno tumačenje profila potrebno je razlikovati dva slučaja:

- pokušano, ali nedovoljno savladano - za kompetenciju postoji procena ovladanosti, ali je njena vrednost niža od praga definisanog za odgovarajući nivo dubine;
- nije pokušano na datom nivou - za kompetenciju ne postoji procena jer student nije generisao odgovarajuća zapažanja na tom nivou.

Ova dva slučaja imaju različite pedagoške implikacije. Kada je sadržaj pokušavan, ali je procena ovladanosti niža od odgovarajućeg praga, preporuka se usmerava na obnavljanje konkretnih objekata učenja, njihovih preduslova i osnovnih varijanti. Kada sadržaj nije pokušavan, preporuka treba prvenstveno da ukaže na neobrađeni deo predviđenog ili izabranog

puta učenja. U konačnoj implementaciji ova razlika je operacionalizovana tako što se pokušani objekti sa procenom nižom od odgovarajućeg praga tretiraju kao slabe tačke u ovladanosti, dok se nepokušani obavezni objekti nivoa N1 posebno uključuju kao nedostajući sadržaji visokog prioriteta. Ova dva slučaja i njihov uticaj na formiranje skupa sadržaja za preporuku detaljnije su prikazani u odeljku 7.2.3.4.

Individualni profili lokalizuju konkretne kompetencije na kojima je student uspešan ili mu je potrebna dodatna podrška, ali sami ne objašnjavaju način na koji je student radio tokom predmeta. Zbog toga se u narednom odeljku rezultati procene ovladanosti dopunjuju ponašajnim tipovima studenata, formiranim na osnovu obima aktivnosti, broja aktivnih dana i udela ranijih pokušaja.

7.2.3.3. Ponašajni tipovi studenata

Pored procene ovladanosti kompetencijama i ostvarenosti nivoa, sloj analitike učenja grupiše studente prema načinu na koji pristupaju radu tokom predmeta. Klasterovanje je sprovedeno primenom k-means algoritma nad sledeća tri ponašajna atributa:

- obim aktivnosti, operacionalizovan brojem zapažanja formiranih u modelu studenta;
- broj aktivnih dana;
- udeo ranijih pokušaja u ukupnom broju pokušaja studenta.

Pokazatelji ovladanosti kompetencijama i ostvarenosti nivoa nisu korišćeni kao ulazni atributi klasterovanja. Na taj način ponašajni tip opisuje kako student radi, dok se njegovo znanje i izvršenost obaveza procenjuju odvojeno. Vrednosti ostvarenosti nivoa pridružene su klasterima tek nakon njihovog formiranja, radi interpretacije odnosa između načina rada i postignutih rezultata. Ovakvim razdvajanjem izbegava se cirkularnost u kojoj bi se studenti grupisali prema postignuću, a zatim bi se istim postignućem objašnjavale karakteristike dobijenih grupa.

Broj klastera određen je zasebno za svaki predmet na osnovu najviše vrednosti koeficijenta siluete u razmatranom opsegu od dva do pet klastera. Za predmet SE201 vrednosti koeficijenta siluete iznosile su 0,33 za dva, 0,39 za tri, 0,32 za četiri i 0,32 za pet klastera. Najviša vrednost dobijena je za rešenje sa tri klastera, koje je zato zadržano kao konačno rešenje. Za predmet CS202 vrednosti su iznosile 0,41 za dva, 0,35 za tri, 0,38 za četiri i 0,37 za pet klastera, pa je izabrano rešenje sa dva klastera. Izabrani brojevi ponašajnih tipova, dakle, odgovaraju najbolje razdvojenim rešenjima unutar ispitanog opsega, ali same vrednosti koeficijenta siluete ukazuju

na umerenu, a ne izrazito oštru razdvojenost grupa. Vrednosti koeficijenta siluete za razmatrani broj klastera prikazane su u Tabeli 21.

Tabela 21. Koeficijent siluete za različit broj klastera.

Broj klastera	SE201	CS202
2	0,33	**0,41**
3	**0,39**	0,35
4	0,32	0,38
5	0,32	0,37

Napomena: Podebljane vrednosti predstavljaju najviši koeficijent siluete za odgovarajući predmet i određuju broj klastera korišćen u daljoj analizi.

Tipovi su označeni prema položaju na kombinovanom kontinuumu angažovanja, određenom prvenstveno obimom aktivnosti i brojem aktivnih dana. U predmetu SE201 dobijeni su istrajni, efikasni i minimalistički tip, koji približno odgovaraju visokom, srednjem i niskom položaju na kontinuumu angažovanja. Naziv efikasni dodeljen je naknadnom interpretacijom srednje grupe, jer studenti u njoj postižu ostvarenje nivoa uporedivo sa istrajnim tipom, ali uz znatno manji udeo ponovljenih pokušaja. U predmetu CS202 dobijena su dva krajnja tipa - istrajni i minimalistički. Oznake su opisne i ne predstavljaju rangiranje studenata prema sposobnostima, znanju ili ukupnom uspehu (Tabela 22).

Tabela 22. Ponašajni tipovi studenata prema predmetu: atributi korišćeni za klasterovanje i naknadno pridružena ostvarenost nivoa.

Predmet	Tip	n	Obim aktivnosti	Aktivni dani	Udeo ranijih pokušaja	Ostvarenost N1	Ostvarenost N2
SE201	Istrajni	9	179	6,3	0,25	66%	47%
SE201	Efikasni	22	145	4,8	0,06	72%	52%
SE201	Minimalistički	6	69	2,0	0,03	37%	20%
CS202	Istrajni	21	124	8,7	0,27	55%	35%
CS202	Minimalistički	53	83	4,9	0,06	58%	30%

Prostorni raspored studenata prema dobijenim tipovima prikazan je na Slici 41. Analiza glavnih komponenti korišćena je radi dvodimenzionalne vizuelizacije rasporeda studenata, dok su sami tipovi određeni k-means klasterovanjem na osnovu ponašajnih atributa opisanih u odeljku 6.5.2.3. Zbog umerenih vrednosti koeficijenta siluete, prikazane grupe ne treba tumačiti kao potpuno odvojene prirodne kategorije, već kao interpretabilne obrasce ponašanja unutar posmatranih predmeta.

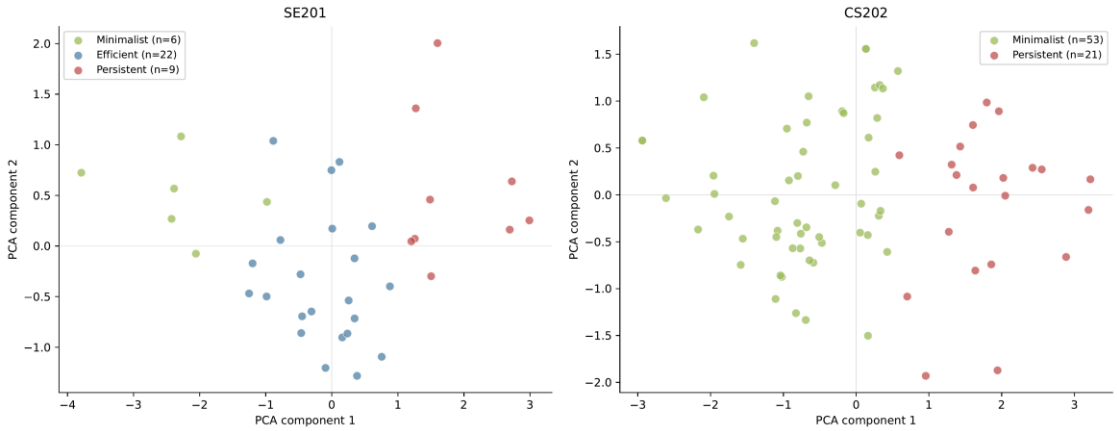

Slika 41. Ponašajni tipovi studenata dobijeni k-means klasterovanjem i prikazani u dvodimenzionalnom prostoru glavnih komponenti: tri tipa za predmet SE201 i dva tipa za predmet CS202.

Napomena: Obim aktivnosti, broj aktivnih dana i udeo ranijih pokušaja korišćeni su kao ulazni atributi klasterovanja. Ostvarenost nivoa N1 i N2 nije korišćena pri formiranju klastera, već je prikazana kao rezultat radi naknadne interpretacije ponašajnih tipova.

Vizualizacija omogućava uvid u relativni položaj grupa, ali sama po sebi ne predstavlja dokaz njihove pedagoške validnosti. Zbog toga se interpretacija ponašajnih tipova prvenstveno zasniva na vrednostima atributa prikazanim u Tabeli 22 i njihovom odnosu sa ostvarenošću nivoa, a ne samo na udaljenosti tačaka u redukovanom prostoru.

Povezivanje ponašajnih tipova sa individualnim profilima prikazanim u odeljku 7.2.3.2 dodatno pokazuje zašto ove dve dimenzije modela treba posmatrati odvojeno. Oba analizirana studenta sa predmeta SE201 pripadaju efikasnom ponašajnom tipu, dok oba analizirana studenta sa predmeta CS202 pripadaju minimalističkom tipu. Ipak, unutar svakog para jedan student ostvaruje više, a drugi niže rezultate, pri čemu se njihovi profili ovladanosti pojedinačnim kompetencijama i vrednosti ostvarenosti nivoa značajno razlikuju. Ponašajni tip, prema tome, ne određuje akademsko postignuće: studenti sa sličnim obrascem rada mogu se znatno razlikovati u tome koje su kompetencije savladali i u kojoj meri su realizovali propisane aktivnosti. Zbog toga se ponašajni tip, profil ovladanosti kompetencijama i ostvarenost nivoa u modelu zadržavaju kao odvojene, ali komplementarne dimenzije.

Provera robustnosti ponašajnih tipova. Zbog relativno malog broja studenata i umerenih vrednosti koeficijenta siluete, stabilnost dobijenih ponašajnih tipova dodatno je proverena kroz tri komplementarne analize: stabilnost pri ponovljenom poduzorkovanju, poređenje sa metodama klasterovanja zasnovanim na gustini i analizu osetljivosti na izbor ponašajnih atributa. Cilj ovih provera nije da se ponašajni tipovi predstave kao prirodno i potpuno odvojene kategorije studenata, već da se utvrdi u kojoj meri se izdvojeni obrasci zadržavaju pri promenama uzorka, metode i skupa atributa. Za proveru stabilnosti pri promeni uzorka

klasterovanje je ponovljeno na 200 slučajno formiranih poduzoraka, od kojih je svaki sadržao 80% studenata odgovarajućeg predmeta, izabranih bez ponavljanja, pri čemu je radi reproduktivnosti korišćeno fiksirano seme generatora slučajnih brojeva. Za svaki poduzorak dobijeni klasteri upareni su sa klasterima formiranim na celokupnoj kohorti, a saglasnost je procenjena pomoću Jaccardovog koeficijenta sličnosti. Prosečna vrednost iznosila je 0,90 za oba predmeta. Za SE201 standardna devijacija iznosila je 0,10, uz raspon od 0,55 do 1,00, dok je za CS202 iznosila 0,16, uz raspon od 0,54 do 1,00.

Dobijene vrednosti pokazuju da se struktura ponašajnih tipova u proseku dobro reprodukuje pri promeni sastava uzorka. Istovremeno, niže vrednosti u manjem broju poduzoraka ukazuju da stabilnost nije apsolutna, što je očekivano imajući u vidu veličinu kohorti, posebno predmet SE201 sa 37 studenata. Rezultate zato treba tumačiti kao podršku prosečnoj stabilnosti izdvojenih obrazaca, a ne kao dokaz postojanja strogo odvojenih i nepromenljivih kategorija studenata.

Kao dodatna provera ispitano je da li metode klasterovanja zasnovane na gustini daju pogodniju strukturu ponašajnih tipova. Na istim standardizovanim atributima primenjeni su DBSCAN i HDBSCAN sa više vrednosti njihovih ključnih parametara. Za DBSCAN ispitane su vrednosti parametra $\varepsilon \in \{0,5; 0,8; 1,0; 1,5\}$, uz min_samples = 4, dok su za HDBSCAN ispitane vrednosti min_cluster_size $\in \{3; 5; 8\}$. Dobijena rešenja nisu bila stabilnija od k-means rešenja. Broj formiranih klastera menjao se u zavisnosti od parametara od nula do četiri, a značajan deo studenata ostajao je označen kao šum, odnosno bez pripadnosti klasteru. Kod najinformativnijih HDBSCAN rešenja bez dodeljenog tipa ostalo je približno 62% studenata u SE201 i 43% u CS202.

Ovakvo svojstvo predstavlja praktično ograničenje u kontekstu predloženog modela, jer adaptivni sloj treba da raspolaže ponašajnim tipom za svakog studenta. K-means, nasuprot tome, svakog studenta pridružuje jednom klasteru, daje interpretabilne tipove i pokazuje dobru prosečnu stabilnost pri poduzorkovanju. Zbog toga je u konkretnoj implementaciji zadržan kao pogodniji izbor za ponašajni sloj modela studenta. Ovaj rezultat ne znači da je k-means opšte superioran u odnosu na metode zasnovane na gustini, već da je pogodniji za zahtev i strukturu podataka posmatrane implementacije.

Na kraju je ispitano koliko svaki od tri ponašajna atributa doprinosi dobijenom rešenju. Klasterovanje je ponovljeno tri puta, pri čemu je u svakoj varijanti izostavljen po jedan atribut, a nova dodela studenata klasterima poređena je sa rešenjem dobijenim korišćenjem sva tri

atributa pomoću prilagođenog Randovog indeksa (engl. Adjusted Rand Index (ARI)). Izostavljanje broja aktivnih dana najmanje je promenilo rezultat (ARI = 0,8380 u SE201 i 0,8379 u CS202). Izostavljanje obima aktivnosti dovelo je do većih promena dodele studenata (ARI = 0,5595 u SE201 i 0,3766 u CS202), a najveće promene nastale su izostavljanjem udela ranijih pokušaja (ARI = 0,3794 u SE201 i 0,2280 u CS202).

Rezultat pokazuje da sva tri atributa doprinose formiranju ponašajnih tipova, ali da udeo ranijih pokušaja i obim aktivnosti nose najveći deo diskriminativnog signala, dok broj aktivnih dana ima najmanji samostalni uticaj. Istovremeno, činjenica da se dodela studenata menja kada se pojedini atributi uklone potvrđuje da tipovi zavise od operativnog načina na koji je ponašanje predstavljeno. Ponašajni profil zato treba tumačiti u odnosu na eksplicitno definisan skup atributa, a ne kao inherentnu ili trajnu karakteristiku studenta.

Pored analize izostavljanja pojedinačnih ponašajnih atributa, dodatno je ispitano kako bi se struktura klastera promenila kada bi se u njihovo formiranje uključili pokazatelji postignuća koji se u predloženom modelu inače vode kao odvojene dimenzije. Osnovno rešenje zasnovano samo na ponašajnim atributima poređeno je sa varijantama u kojima su tim atributima zasebno dodate ostvarenost nivoa N1, ostvarenost nivoa N2, istovremeno ostvarenost nivoa N1 i N2 i prosečna ovladanost kompetencijama. U predmetu SE201 dodavanje N1 ostvarenosti dalo je ARI = 0,765 i koeficijent siluete 0,349, dok je dodavanje N2 ostvarenosti dalo ARI = 0,840 i koeficijent siluete 0,310. Kada su N1 i N2 ostvarenost uključene istovremeno, saglasnost sa osnovnim ponašajnim rešenjem smanjena je na ARI = 0,408, uz koeficijent siluete 0,347. Dodavanje prosečne ovladanosti kompetencijama takođe je promenilo dodelu studenata, sa ARI = 0,515 i koeficijentom siluete 0,298. Osnovno ponašajno rešenje za SE201 imalo je koeficijent siluete 0,389.

U predmetu CS202 efekat je zavisio od načina na koji je postignuće predstavljeno. Kada je ponašajnim atributima dodata samo N1 ili samo N2 ostvarenost, članstvo studenata u klasterima ostalo je nepromenjeno u odnosu na osnovno rešenje (ARI = 1,000), ali se koeficijent siluete smanjio sa 0,414 na 0,318. Nasuprot tome, istovremeno uključivanje N1 i N2 ostvarenosti izrazito je promenilo podelu studenata (ARI = 0,014; koeficijent siluete = 0,270), dok je dodavanje prosečne ovladanosti kompetencijama dalo ARI = 0,379 i koeficijent siluete 0,309. Nijedna od varijanti sa uključenim pokazateljima postignuća nije ostvarila viši koeficijent siluete od osnovnog ponašajnog rešenja. Rezultati zato dodatno podržavaju projektnu odluku da se ponašajni tipovi formiraju samo na osnovu atributa angažovanja, dok se ovladanost i ostvarenost nivoa zadržavaju kao odvojene dimenzije koje se koriste za

naknadno tumačenje dobijenih tipova. Istovremeno, rezultati pokazuju da uključivanje postignuća može značajno promeniti semantiku klastera, naročito kada se ono predstavi kompletnije, kroz više nivoa dubine.

Vizuelni prikaz promena u dodeli studenata klasterima pri dodavanju pokazatelja ostvarenosti i ovladanosti prikazan je na Slici 42. Radi neposrednog poređenja, sve varijante prikazane su u istom dvodimenzionalnom PCA prostoru formiranom na osnovu standardizovanih ponašajnih atributa, dok boja tačaka označava pripadnost klasteru dobijenu za odgovarajući skup ulaznih atributa. Na taj način moguće je vizuelno uočiti da uključivanje pokazatelja postignuća u pojedinim varijantama menja dodelu studenata klasterima, iako položaj studenata u referentnom ponašajnom prostoru ostaje isti.

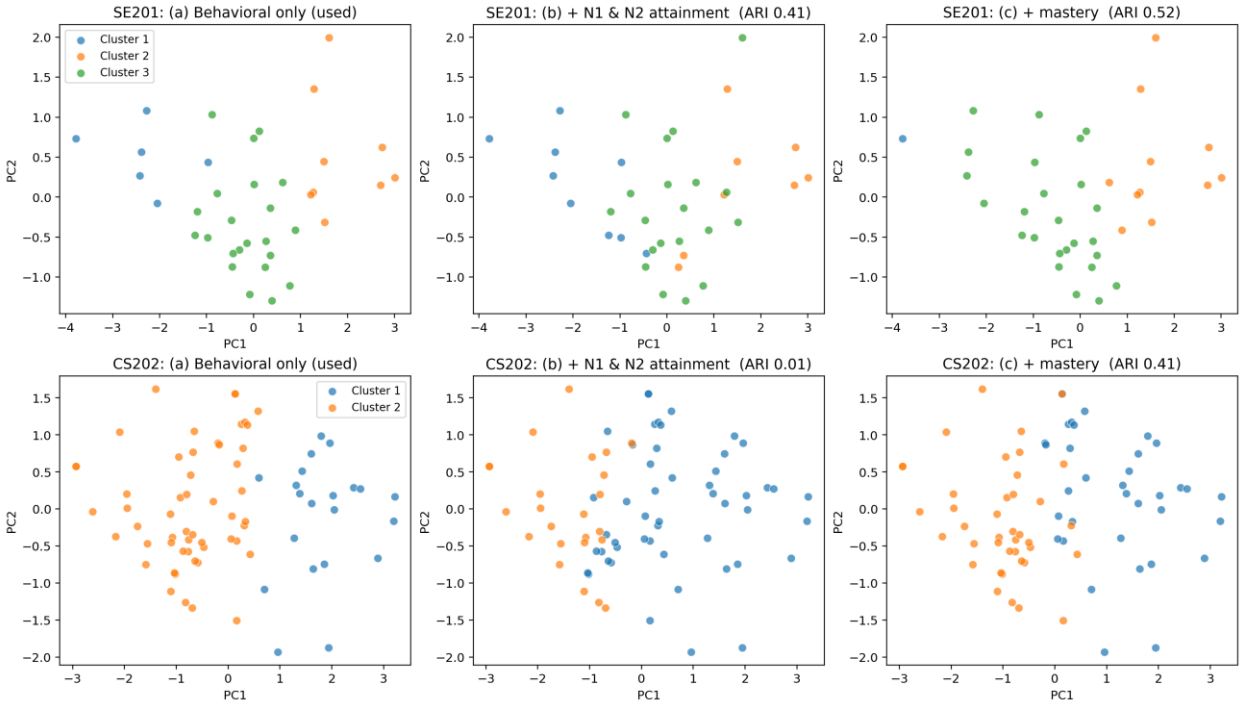

Slika 42. Uticaj dodavanja pokazatelja ostvarenosti i ovladanosti na dodelu studenata k-means klasterima, prikazan u zajedničkom PCA prostoru standardizovanih ponašajnih atributa.

Rezultati sprovedenih provera robusnosti ponašajnog klasterovanja sažeti su u Tabeli 23.

Tabela 23. Sažetak provera robusnosti ponašajnog klasterovanja.

Provera	SE201	CS202	Tumačenje
Izabrani broj klastera	3	2	Najviši koeficijent siluete u opsegu 2-5
Najviši koeficijent siluete	0,39	0,41	Umerena razdvojenost
Prosečan Jaccardov koeficijent	0,90	0,90	Visoka prosečna stabilnost pri poduzorkovanju
Standardna devijacija Jaccardovog koeficijenta	0,10	0,16	Veća varijabilnost u pojedinim poduzorcima CS202
Raspon Jaccardovog koeficijenta	0,55-1,00	0,54-1,00	Pojedini uzorci daju slabiju saglasnost

Udeo šuma kod informativnog HDBSCAN rešenja	62%	43%	Veliki broj studenata bez dodeljenog tipa
ARI bez atributa „broj aktivnih dana“	0,8380	0,8379	Najmanja promena strukture
ARI bez atributa „obim aktivnosti“	0,5595	0,3766	Veća promena strukture
ARI bez atributa „udeo ranijih pokušaja“	0,3794	0,2280	Najveća promena strukture
Dodavanje N1 ostvarenosti	ARI = 0,765; silueta = 0,349	ARI = 1,000; silueta = 0,318	Ne poboljšava razdvojenost u odnosu na ponašajno rešenje
Dodavanje N2 ostvarenosti	ARI = 0,840; silueta = 0,310	ARI = 1,000; silueta = 0,318	U CS202 članstvo ostaje isto, ali se razdvojenost smanjuje
Dodavanje N1 i N2 ostvarenosti	ARI = 0,408; silueta = 0,347	ARI = 0,014; silueta = 0,270	Značajno menja strukturu klastera
Dodavanje prosečne ovladanosti	ARI = 0,515; silueta = 0,298	ARI = 0,379; silueta = 0,309	Menja članstvo bez poboljšanja razdvojenosti

Napomena: ARI vrednosti u analizama promene skupa atributa izražavaju saglasnost dodele studenata sa osnovnim rešenjem formiranim samo na osnovu tri ponašajna atributa. Vrednost ARI = 1 označava identičnu dodelu, dok niže vrednosti ukazuju na veće promene strukture klastera. Koeficijent siluete prikazuje unutrašnju razdvojenost klastera za odgovarajuću varijantu. Vrednosti ARI pri izostavljanju pojedinačnih atributa prikazane su sa četiri decimale, kako bi bila vidljiva razlika između predmeta.

Rezultati pokazuju da se izdvojeni tipovi razlikuju prema ponašajnim atributima korišćenim za klasterovanje i da osnovno ponašajno rešenje pokazuje dobru prosečnu stabilnost unutar analiziranih kohorti. Istovremeno, analize promene skupa atributa pokazuju da struktura tipova zavisi od načina operacionalizacije ponašanja i da uključivanje pokazatelja postignuća može značajno promeniti članstvo klastera, a da pri tome ne poboljša njihovu unutrašnju razdvojenost. Ovi nalazi dodatno opravdavaju razdvajanje ponašajnog profila od ovladanosti i ostvarenosti u konačnom višeslojnom modelu studenta. Istrajni tip u oba predmeta karakterišu najveći obim aktivnosti i najveći udeo ranijih pokušaja, koji iznosi 0,25 u predmetu SE201 i 0,27 u predmetu CS202. Takav obrazac ukazuje na češće vraćanje prethodnim aktivnostima i reviziju rada. Minimalistički tip odlikuju manji obim angažovanja i mali broj ponovljenih pokušaja. U predmetu SE201 studenti ovog tipa imaju prosečno 69 zapažanja, dva aktivna dana i udeo ranijih pokušaja od 0,03. U predmetu CS202 ovaj tip obuhvata 53 od 74 studenta, sa prosečno 83 zapažanja, 4,9 aktivnih dana i udelom ranijih pokušaja od 0,06. Efikasni tip javlja se samo u predmetu SE201 i obuhvata 22 studenta. Prema obimu aktivnosti i broju aktivnih dana nalazi se između istrajnog i minimalističkog tipa, dok ga posebno karakteriše nizak udeo ranijih pokušaja od 0,06. Naziv „efikasni“ dodeljen je naknadno, jer su studenti ovog tipa ostvarili rezultate uporedive sa istrajnim studentima, ali uz manji broj ponovljenih i prerađenih pokušaja.

Poređenje ponašajnih atributa sa ostvarenošću nivoa pokazuje da različiti obrasci rada mogu dovesti do sličnih rezultata. U predmetu SE201 istrajni studenti ostvarili su prosečno 66% nivoa N1 i 47% nivoa N2, dok su efikasni studenti ostvarili 72% nivoa N1 i 52% nivoa N2. Ovi rezultati ne ukazuju na jednostavnu prednost jednog tipa, već na različite načine dostizanja uporedivog stepena realizacije aktivnosti: istrajni studenti kroz više ponavljanja i revizija, a efikasni uz manji broj prethodnih pokušaja. Minimalistički studenti istog predmeta ostvarili su 37% nivoa N1 i 20% nivoa N2, što je u skladu sa manjim obimom aktivnosti.

U predmetu CS202 razlike između tipova bile su manje. Istrajni studenti ostvarili su 55% nivoa N1 i 35% nivoa N2, a minimalistički 58% nivoa N1 i 30% nivoa N2. U posmatranim podacima veći obim aktivnosti i češće ponavljanje nisu bili praćeni proporcionalno višom ostvarenošću nivoa N2. Ovaj deskriptivni odnos ukazuje da ponašajni obrazac sam po sebi nije dovoljan za objašnjenje postignuća na zahtevnijem nivou sadržaja i ne omogućava izvođenje uzročnog zaključka o uticaju obima aktivnosti ili ponavljanja na ostvarene rezultate. Velika zastupljenost minimalističkog tipa u ovom predmetu istovremeno je u skladu sa niskom prosečnom ostvarenošću nivoa N2, utvrđenom u odeljku 7.2.3.1.

Poređenje ponašajnih tipova sa individualnim profilima iz odeljka 7.2.3.2 potvrđuje da način angažovanja i postignuće predstavljaju povezane, ali različite dimenzije modela studenta. Studenti koji pripadaju istom ponašajnom tipu mogu imati različite profile ovladanosti kompetencijama, dok studenti sličnog nivoa postignuća mogu do rezultata doći različitim obrascima rada. U predmetu SE201, na primer, istrajni i efikasni tip ostvaruju relativno slične vrednosti N1 i N2, ali se jasno razlikuju prema učestalosti ponavljanja pokušaja. U predmetu CS202 velika zastupljenost minimalističkog tipa povezana je sa nižom ostvarenošću N2 na nivou predmeta, ali ni ovde ponašajni tip ne predstavlja neposrednu meru znanja. Rezultati provere robustnosti dodatno pokazuju da dobijene tipove treba posmatrati kao empirijski izvedene i relativno stabilne obrasce angažovanja u konkretnom nastavnom kontekstu, a ne kao trajne kategorije ličnosti ili sposobnosti studenata.

Ovaj rezultat podržava višeslojnu strukturu modela studenta u kojoj ponašajni tip opisuje način rada, profil ovladanosti lokalizuje konkretne kompetencije, a ostvarenost nivoa pokazuje udeo ostvarenih poena u predviđenim aktivnostima. Pri generisanju preporuka ponašajni tip zato služi kao kontekst za predstavljanje i obrazloženje podrške, ali ne zamenjuje procenu ovladanosti niti određuje izbor i redosled preporučenog nastavnog sadržaja. Nakon utvrđivanja individualnih profila ovladanosti, ostvarenosti nivoa i ponašajnih tipova, analizirana je mogućnost njihovog povezivanja sa ontološkim modelom nastavnog sadržaja. Posebno je

ispitano da li se objekti učenja čija je procena niža od definisanog praga mogu identifikovati kao slabe tačke i organizovati u objašnjivu putanju za dalje učenje.

7.2.3.4. Identifikovani sadržaji za podršku kao osnova objašnjivih preporuka

Za potrebe adaptivnog sloja identifikovani su objekti učenja kojima je studentu potrebna dodatna pažnja. Konačni skup označenih sadržaja formira se iz dve komplementarne kategorije. Prvu čine pokušani objekti učenja za koje postoji dokaz iz aktivnosti studenta i čija je procena niža od praga ovladanosti definisanog za odgovarajući nivo dubine. Oni predstavljaju slabe tačke u užem smislu, jer je student sa sadržajem radio, ali nije pokazao dovoljan nivo ovladanosti. Drugu kategoriju čine nepokušani obavezni objekti nivoa N1, koji predstavljaju deo osnovnog jezgra predmeta koji student još nije pokušao. Pošto za takve objekte ne postoji dokaz na osnovu kojeg bi se procenila ovladanost, njima se ne dodeljuje veštačka procena jednaka nuli, već se u adaptivnom sloju posebno označavaju kao nedostajući obavezni sadržaji visokog prioriteta. U nastavku se termin pokušane slabe tačke koristi isključivo za prvu kategoriju, dok se obe kategorije zajedno označavaju kao sadržaji identifikovani za podršku.

Sadržaj identifikovan za podršku i konačna preporuka nisu isto. Model studenta obezbeđuje procene ovladanosti i informacije o realizovanim i nerealizovanim aktivnostima, dok adaptivni sloj na osnovu tih izlaza formira početni skup objekata kojima je potrebna dodatna pažnja. Za pokušane objekte osnovu predstavlja procena ovladanosti niža od odgovarajućeg praga, dok se nepokušani obavezni objekti nivoa N1 uključuju na osnovu svog statusa obaveznog jezgra. Konačna preporuka zatim se formira povezivanjem tih objekata sa strukturom ontologije. Pri tome se koriste relacije redosleda (OR), kojima se identifikuju preduslovi, i relacije osnovni/napredni (BA), kojima se napredni sadržaj povezuje sa njegovom osnovnom varijantom. Detaljan postupak formiranja redosleda i objašnjavanja preporučenih objekata učenja prikazan je u odeljku 7.3.1. Mehanizam je primenjen na sve studente predmeta SE201 i CS202, pri čemu je svaki student imao najmanje jedan označeni objekat učenja za dodatnu podršku. Kada se zajedno posmatraju pokušani objekti sa procenom ispod praga i nepokušani obavezni objekti nivoa N1, prosečan ukupan broj označenih sadržaja identifikovanih za podršku iznosio je 33,6 po studentu u predmetu SE201, uz medijanu 29, i 39,8 u predmetu CS202, uz medijanu 38. Od toga je u SE201 prosečno 18,7 objekata predstavljalo pokušani sadržaj sa procenom ovladanosti ispod praga, dok je dodatnih 14,9 pripadalo nepokušanim obaveznim objektima nivoa N1. U CS202 odgovarajuće vrednosti iznosile su 25,5 pokušavanih

nedovoljno savladanih objekata i 14,3 nepokušana obavezna objekta nivoa N1. Rezultati su prikazani u Tabeli 24.

Tabela 24. Identifikovani sadržaji za podršku prema predmetu i vrsti identifikovane potrebe.

Predmet	Broj studenata	Prosečan ukupan broj sadržaja identifikovanih za podršku	Medijana	Pokušane slabe tačke N1	Pokušane slabe tačke N2	Ukupno pokušane slabe tačke	Nepokušani obavezni N1 objekti
SE201	37	33,6	29	8,1	10,6	18,7	14,9
CS202	74	39,8	38	5,1	20,4	25,5	14,3

Napomena: Pokušana slaba tačka predstavlja objekat učenja za koji postoji rezultat aktivnosti i čija je procena niža od praga odgovarajućeg nivoa. Nepokušani obavezni N1 objekti nemaju procenu ovladanosti, već se posebno označavaju kao nedostajući sadržaji visokog prioriteta. Ukupan broj predstavlja zbir ove dve kategorije. Prikazane vrednosti odnose se na broj objekata učenja, a ne na broj kompetencija.

Posmatrano samo među pokušanim sadržajima, u oba predmeta veći prosečan broj slabih tačaka identifikovan je na nivou N2 nego na nivou N1. U predmetu SE201 prosečno je označeno 8,1 pokušavanih objekata nivoa N1 i 10,6 nivoa N2, dok su u predmetu CS202 odgovarajuće vrednosti iznosile 5,1 i 20,4. Razlika je posebno izražena u CS202, gde približno četiri petine pokušavanih objekata sa procenom ispod praga pripada nivou N2. Ovaj rezultat je u skladu sa prethodno utvrđenim nižim vrednostima ovladanosti i ostvarenosti na srednjem nivou dubine i pokazuje da je najveći deo poteškoća među pokušanim sadržajima lokalizovan upravo u zahtevnijim praktičnim aktivnostima nivoa N2.

Uključivanje nepokušavanih obaveznih sadržaja menja, međutim, interpretaciju ukupnog skupa za preporuku. U proseku je identifikovano dodatnih 14,9 nepokušavanih N1 objekata po studentu u SE201 i 14,3 u CS202. Ovi objekti ne predstavljaju dokaz neuspeha na konkretnoj aktivnosti, jer student sa njima nije ostvario dovoljno interakcija za procenu ovladanosti. Oni ukazuju na nedostajući deo obaveznog jezgra koji treba uzeti u obzir pri formiranju dalje putanje učenja. Na taj način model razlikuje sadržaj koji je student pokušao, ali nije dovoljno savladao, od sadržaja koji je obavezan, ali još nije pokušao.

Broj označenih objekata ipak ne treba tumačiti kao samostalnu meru težine predmeta niti kao direktnu meru neuspeha pojedinačnog studenta. On zavisi od granularnosti ontologije, broja objekata učenja na pojedinim nivoima, strukture aktivnosti provere i obima sadržaja sa kojim je student ostvario interakciju. Njegova osnovna funkcija jeste lokalizovanje konkretnog sadržaja koji može da bude uključen u personalizovanu putanju za dalje učenje.

Povezivanje ovih rezultata sa ponašajnim tipovima iz odeljka 7.2.3.3 pokazuje zbog čega je uključivanje nepokušavanog obaveznog N1 sadržaja značajno. Ako bi se posmatrali samo pokušani objekti, minimalistički tip u predmetu SE201 imao bi najmanji prosečan broj

pokušavanih slabih tačaka, svega 8,3, uprkos najnižoj ostvarenosti nivoa. Kod istrajnog tipa prosečno je identifikovano 18,2, a kod efikasnog 21,7 pokušavanih slabih tačaka. Ovakav rezultat nastaje zato što student sa manjim obimom aktivnosti generiše manji broj zapažanja i samim tim manji broj objekata za koje je moguće formirati procenu ovladanosti.

Konačna implementacija ublažava ovaj problem tako što nepokušane obavezne objekte nivoa N1 uključuje kao zasebnu kategoriju visokog prioriteta. Kada se oni dodaju pokušanim slabim tačkama, prosečan ukupan broj označenih objekata za minimalistički tip u SE201 raste na 31,5, što je uporedivo sa 32,0 kod istrajnog i 34,8 kod efikasnog tipa. Na taj način studenti sa veoma ograničenom aktivnošću više nisu sistematski nedovoljno zastupljeni u skupu sadržaja za preporuku samo zato što za veliki deo obaveznog jezgra nisu generisali rezultat aktivnosti.

Ovaj rezultat istovremeno pokazuje zašto je važno zadržati razliku između nedovoljne ovladanosti i odsustva dokaza. Za pokušani objekat postoji procena koja ukazuje da student još nije dostigao odgovarajući prag. Za nepokušani obavezni objekat takva procena ne postoji; sistem samo zna da obavezni sadržaj nije pokušavan. Adaptivni sloj zato oba slučaja može uključiti u putanju učenja, ali ih u objašnjenju treba prikazati različito: prvi kao sadržaj koji treba ponoviti ili dodatno savladati, a drugi kao obavezni sadržaj koji tek treba obraditi.

Rezultati identifikovanja sadržaja za podršku pokazuju da se fino granularni izlazi modela studenta mogu neposredno povezati sa konkretnim objektima učenja. Pri tome konačni skup kandidata za podršku ne zavisi samo od procene ovladanosti pokušanim sadržajem, već obuhvata i nepokušano obavezno jezgro. Sledeći korak predstavlja povezivanje ovih objekata sa ontološkim relacijama i ponašajnim profilom studenta radi formiranja uređene i objašnjive preporuke, što je prikazano u odeljku 7.3.

7.2.3.5. Povratne informacije studenata o kontrolnoj tabli i objašnjivim preporukama

Tehnička evaluacija predložene arhitekture dopunjena je povratnim informacijama studenata o razumljivosti, relevantnosti i percipiranoj korisnosti kontrolne table, preporučenih objekata učenja i pripadajućih objašnjenja. Nakon što su kontrolnu tablu, preporuke i objašnjenja koristili tokom nekoliko nedelja nastave, studenti su popunili upitnik sa pet stavki ocenjenih na Likertovoj skali od 1 do 5. Upitnik je ponuđen svim studentima sa dva analizirana predmeta, ukupno njih 111, a popunilo ga je 86 studenata, što odgovara stopi odziva od 77,5%. Od 86 učesnika, 22 su pohađala predmet SE201, a 64 predmet CS202.

Za svaku stavku izračunati su aritmetička sredina, standardna devijacija i procenat pozitivnih odgovora. Pozitivnim odgovorima smatrane su ocene 4 i 5. Rezultati su prikazani u Tabeli 25.

Tabela 25. Povratna informacija studenata o kontrolnoj tabli i objašnjivim preporukama (n = 86).

Pitanje	Prosek	SD	Pozitivni odgovori (%)
P1: Kontrolnu tablu je bilo lako razumeti.	4,47	0,76	90,7
P2: Preporuke je bilo lako razumeti.	4,17	0,84	79,1
P3: Preporučeni objekti učenja bili su relevantni za moje slabe tačke.	4,52	0,70	93,0
P4: Objašnjenja su mi pomogla da razumem zašto su materijali predloženi.	4,56	0,71	91,9
P5: Koristio/la bih ovakve preporuke u budućem učenju.	4,70	0,65	94,2

Napomena: Pozitivni odgovori obuhvataju ocene 4 i 5 na skali od 1 do 5. SD - standardna devijacija.

Rezultati su pozitivni za svih pet stavki, pri čemu se prosečne vrednosti kreću od 4,17 do 4,70. Najvišu prosečnu ocenu dobila je spremnost studenata da ovakve preporuke koriste u budućem učenju, P5, sa prosekom 4,70 i 94,2% pozitivnih odgovora. Visoko su ocenjene i korisnost objašnjenja razloga za preporuku, P4, sa prosekom 4,56, kao i relevantnost preporučenih objekata učenja za identifikovane slabe tačke, P3, sa prosekom 4,52.

Kontrolna tabla je takođe ocenjena kao razumljiva: stavka P1 ima prosečnu vrednost 4,47 i 90,7% pozitivnih odgovora. Najnižu, iako i dalje pozitivnu ocenu, dobila je stavka P2, koja se odnosi na razumljivost samih preporuka. Njen prosek iznosi 4,17, dok je 79,1% odgovora bilo pozitivno. Ovaj rezultat ukazuje da su preporuke generalno bile razumljive, ali i da način njihovog formulisanja i predstavljanja ostavlja više prostora za unapređenje nego ostali elementi kontrolne table. Ukupna prosečna vrednost svih pet stavki iznosi 4,48, dok je 89,8% odgovora na nivou pojedinačnih stavki imalo vrednost 4 ili 5. Rezultati su pozitivni u oba predmeta: ukupan prosek iznosi 4,41 za predmet SE201 i 4,51 za predmet CS202. Ove vrednosti pokazuju da povoljne ocene nisu ograničene samo na jedan od dva nastavna konteksta. Razlika u ukupnim ocenama između studenata sa predmeta SE201 i CS202 dodatno je proverena Mann-Whitney U testom. Nije utvrđena statistički značajna razlika između dva predmeta ($U = 557,0$; $p = 0,14$), što ukazuje da se ukupna percepcija kontrolne table, preporuka i objašnjenja nije značajno razlikovala između analiziranih nastavnih konteksta. Pošto je upitnik bio anoniman, pojedinačni odgovori nisu mogli da se povežu sa ponašajnim tipovima studenata, pa nije bilo moguće ispitati da li se percepcija preporuka razlikovala između

identifikovanih ponašajnih tipova. Kronbahov koeficijent alfa za skalu od pet stavki iznosi 0,878, što ukazuje na visoku unutrašnju konzistentnost odgovora. Ovaj pokazatelj znači da su stavke međusobno povezane kao elementi iste šire procene iskustva korišćenja sistema. Međutim, visoka unutrašnja konzistentnost sama po sebi ne potvrđuje potpunu konstruktivnu validnost upitnika niti pokazuje da sistem objektivno unapređuje učenje. Pored zatvorenih stavki, studenti su mogli da ostave otvorene komentare. Od ukupno 86 učesnika, 65 studenata, odnosno 76%, ostavilo je komentar u slobodnoj formi. Komentari su pregledani i deskriptivno grupisani prema šest tema koje su se ponavljale, pri čemu je 12 komentara svrstano u više od jedne teme. Teme su izvedene induktivno iz prikupljenih odgovora. Jedan autor je izvršio početno kodiranje komentara, dok je drugi autor proverio izvršene dodele; nejasni slučajevi i neslaganja razrešeni su diskusijom u odnosu na usaglašene definicije tema. Ova analiza nije sprovedena kao zasebna formalna kvalitativna studija, već je korišćena za kontekstualizovanje kvantitativnih rezultata upitnika i identifikovanje ponavljajućih percepcija i predloga za unapređenje.

U komentarima su izdvojene sledeće teme:

- **relevantnost i personalizovanost preporuka** - studenti su navodili da su preporučeni sadržaji odgovarali njihovim slabim oblastima i da preporuke nisu delovale kao jedinstvena, generička lista za sve korisnike;
- **korisnost objašnjenja** - studenti su isticali da im je obrazloženje pomoglo da razumeju zbog čega je određeni objekat učenja uključen u preporuku;
- **usmeravanje pažnje i podrška samostalnom učenju** - kontrolna tabla i preporuke pomogle su studentima da se usmere na sadržaje kojima je potrebna dodatna pažnja;
- **mešovite ili negativne procene** - manji broj studenata naveo je da su neke preporuke bile manje relevantne ili da određena objašnjenja nisu bila dovoljno jasna;
- **predlozi za dodatne nastavne resurse** - predloženo je uključivanje većeg broja primera, video-materijala i naprednijih resursa;
- **predlozi za unapređenje objašnjenja** - studenti su tražili nešto detaljnija objašnjenja i mogućnost postavljanja dodatnih pitanja sistemu, kroz interaktivni ili razgovorni interfejs.

Rezultati deskriptivne analize otvorenih komentara prikazani su u Tabeli 26.

Tabela 26. Teme identifikovane u otvorenim komentarima studenata.

Tema	Broj komentara
Opšte pozitivne povratne informacije	24
Relevantnost i personalizovanost preporuka	16
Korisnost objašnjenja	13
Predlozi za unapređenje	10
Mešovite ili negativne procene	8
Podrška usmeravanju pažnje i samostalnom učenju	6

Napomena: Pojedinačni komentar mogao je biti svrstan u više od jedne teme, zbog čega zbir učestalosti premašuje broj studenata koji su ostavili otvoreni komenta

Otvoreni komentari podržavaju opšti obrazac kvantitativnih rezultata: studenti su uglavnom prepoznali relevantnost i korisnost preporuka, ali su istovremeno ukazali da se objašnjenja mogu dodatno precizirati i dopuniti interaktivnom podrškom. Rezultati ankete pružaju uvid u to kako su studenti doživeli kontrolnu tablu, preporučene sadržaje i objašnjenja koja su im prikazana. Dobijene ocene pokazuju da su učesnici preporuke uglavnom smatrali razumljivim i relevantnim i da su iskazali spremnost da ovakav oblik podrške koriste u budućem učenju. Ilustrativno, studenti su navodili da su „preporuke veoma dobro odgovarale mojim slabim oblastima“ i da su „objašnjenja pomogla da razumem zašto su ovi materijali izabrani“. Pojedini komentari ukazivali su i na prostor za unapređenje; na primer, jedan student je naveo da su „neke preporuke bile korisne, a druge manje relevantne“, dok su među predlozima bili dodatni primeri, video-materijali, detaljnija objašnjenja i mogućnost razgovornog interfejsa za dodatna pitanja.

Međutim, rezultate ankete potrebno je tumačiti u skladu sa načinom na koji je evaluacija sprovedena. Upitnikom su ispitivani stavovi i iskustva studenata, a ne promena njihovog znanja, ponašanja ili rezultata nakon korišćenja preporuka. U istraživanju nije korišćena kontrolna grupa, nisu poređeni rezultati pre i posle korišćenja sistema i nije praćeno u kojoj meri su studenti zaista koristili svaki od preporučenih objekata učenja.

Dodatno ograničenje proizlazi iz anonimnog načina prikupljanja povratnih informacija. Pojedinačni odgovori iz upitnika nisu bili povezani sa identitetom studenta, niti sa ponašajnim tipom koji je za tog studenta određen u okviru modela studenta. Zbog toga na osnovu postojećih podataka nije moguće ispitati da li se percepcija jasnoće, relevantnosti i korisnosti preporuka razlikuje između ponašajnih tipova identifikovanih u analiziranim predmetima. Anonimnost upitnika bila je važna sa stanovišta privatnosti učesnika, ali istovremeno ograničava mogućnost povezivanja subjektivne procene preporuka sa ponašajnim kontekstom konkretnog studenta.

Na osnovu sprovedene ankete može se zaključiti da su studenti pozitivno ocenili:

- razumljivost kontrolne table;
- razumljivost prikazanih preporuka;
- relevantnost preporučenih objekata učenja u odnosu na identifikovane slabe tačke;
- korisnost objašnjenja razloga zbog kojih je određeni sadržaj preporučen;
- mogućnost primene ovakvih preporuka u budućem učenju.

Na osnovu ovih rezultata ne može se zaključiti da je korišćenje preporuka:

- neposredno dovelo do boljih ocena ili rezultata na aktivnostima;
- povećalo nivo ovladanosti kompetencijama;
- povećalo obim realizovanih aktivnosti;
- izazvalo trajnu promenu ponašanja studenata;
- bilo uspešnije od drugih načina pružanja nastavne podrške.

Za ispitivanje stvarnog uticaja preporuka na proces i ishode učenja bilo bi potrebno sprovesti dodatnu evaluaciju koja bi uključila kontrolnu ili uporednu grupu, merenje stanja pre i posle korišćenja preporuka i praćenje stvarnih interakcija studenata sa preporučenim objektima učenja. Na taj način bilo bi moguće utvrditi ne samo da li studenti preporuke smatraju relevantnim i korisnim, već i da li njihova primena dovodi do merljivog napretka u ovladavanju kompetencijama i realizaciji nastavnih aktivnosti.

Rezultati tehničke evaluacije i povratne informacije studenata zajedno pokazuju da predložena arhitektura funkcioniše kao integrisan proces na stvarnim podacima predmeta. Verifikovani rezultati aktivnosti i provera znanja pretvaraju se u interpretabilne procene ovladanosti, povezuju sa ostvarenošću nivoa i ponašajnim tipovima studenata i koriste za identifikovanje konkretnih objekata učenja kojima je potrebna dodatna pažnja. Povezivanjem ovih objekata sa preduslovima i osnovnim varijantama sadržaja formiraju se uređene i objašnjive preporuke koje su studenti uglavnom ocenili kao relevantne, razumljive i korisne.

Time je ostvaren cilj provere koncepta postavljen u odeljku 6.5.1: evaluacija pokazuje izvodljivost i interpretabilnost celog procesa, ali ne utvrđuje njegovu efikasnost u smislu poboljšanja ishoda učenja. U narednom odeljku detaljnije je prikazano kako adaptivni model iz sadržaja identifikovanih za podršku formira uređenu putanju učenja i kako se studentu predstavljaju razlozi za izbor preporučenih objekata.

7.3. Adaptivni model

Adaptivni model predstavlja završnu komponentu predložene arhitekture i povezuje rezultate modela studenta sa strukturom modela nastavnog sadržaja. Njegova uloga nije da ponovo procenjuje znanje studenta, već da lokalne procene ovladanosti, status pokušaja i ostvarenost nivoa, uz ponašajni kontekst, poveže sa pravilima i ontološkim relacijama radi identifikovanja sadržaja za podršku i formiranja uređene preporuke.

U ovom poglavlju prikazana su dva načina primene adaptivnog modela. Prvi se zasniva na neposrednom povezivanju izlaza modela studenta sa objektima učenja i relacijama ontologije, čime se formiraju uređene i objašnjive preporuke. Drugi pokazuje kako se ista preporuka može primeniti u tradicionalnom sistemu za upravljanje učenjem koji nije izvorno projektovan za personalizaciju. Time se ispituje ne samo funkcionalnost mehanizma preporučivanja već i mogućnost njegove integracije u različita obrazovna okruženja.

7.3.1. Adaptivna preporuka na osnovu modela studenta i ontologije

Adaptivni sloj za svakog studenta povezuje izlaze modela studenta sa objektima učenja i relacijama definisanim u ontološkom modelu nastavnog sadržaja. Njegov zadatak nije ponovno procenjivanje stanja studenta, već prevođenje već formiranog profila u konkretan i sledljiv predlog za dalje učenje. Ulaz u ovaj postupak čine:

- lokalne procene ovladanosti i status pokušaja na nivou objekata učenja, na osnovu kojih adaptivni sloj razlikuje pokušane slabe tačke i nepokušani obavezni objekti učenja nivoa N1;
- procene ovladanosti i odgovarajući pragovi za pokušane objekte učenja;
- informacija o statusu pokušaja i obaveznosti objekta učenja;
- nivo dubine objekta učenja;
- procene ovladanosti kompetencijama;
- ostvarenost nivoa;
- ponašajni tip studenta i pravilo koje objašnjava pripadnost tom tipu;
- relacije između objekata učenja i koncepata definisane u ontološkom modelu.

Sekvencijalna BKT procena obezbeđuje informacije o ovladanosti kompetencijama, dok se identifikovanje potreba za podrškom na nivou pojedinačnih objekata učenja zasniva na lokalnim dijagnostičkim indikatorima i statusu pokušaja. Ovi izlazi predstavljaju komplementarne komponente višeslojnog modela studenta.

Postupak generisanja preporuke obuhvata sledeće korake:

1. Adaptivni sloj iz modela studenta preuzima lokalne procene ovladanosti i status pokušaja za objekte učenja. Na toj osnovi formira početni skup sadržaja za podršku: pokušani objekti nivoa N1 označavaju se kao slabe tačke kada je njihova procena ovladanosti niža od 0,80, dok se za pokušane objekte nivoa N2 i N3 koristi prag 0,50. Nepokušani obavezni objekti nivoa N1 uključuju se kao posebna kategorija nedostajućeg obaveznog sadržaja visokog prioriteta. Njima se ne dodeljuje veštačka procena ovladanosti jednaka nuli, jer za takvu procenu ne postoji dokaz iz aktivnosti studenta.
2. Pokušane slabe tačke mogu se uređivati prema rastućoj vrednosti procenjene ovladanosti, tako da se sadržaji sa najnižom procenom razmatraju sa većim prioritetom. Nepokušani obavezni objekti nivoa N1 zadržavaju poseban status visokog prioriteta, jer predstavljaju deo obaveznog jezgra koji student još nije pokušao.
3. Za svaki objekat iz početnog skupa proveravaju se relacije ontološkog modela. Kada postoji obavezna relacija redosleda OR, odgovarajući preduslovni objekat učenja uključuje se u putanju pre objekta koji od njega zavisi.
4. Kada je objekat naprednog nivoa relacijom BA povezan sa osnovnom varijantom koncepta, osnovna varijanta postavlja se pre naprednog sadržaja.
5. Ponašajni tip koristi se samo kao kontekst za predstavljanje i obrazloženje preporuke: ne menja procenu ovladanosti, ne određuje da li objekat predstavlja slabu tačku i ne utiče na izbor, prioritet ni redosled preporučenih objekata učenja.
6. Nakon uključivanja potrebnih preduslova i osnovnih varijanti uklanjaju se eventualna ponavljanja, a konačni skup objekata organizuje se u uređenu putanju učenja koja poštuje strukturu predmeta i relacije definisane ontološkim modelom.

Na ovaj način rezultat preporučivanja nije neuređena lista objekata kod kojih je student ostvario niži rezultat. Ontološke relacije određuju kojim redosledom sadržaje treba obnavljati i da li je pre problematičnog sadržaja potrebno savladati njegove preduslove ili osnovnu varijantu. Model studenta određuje gde je studentu potrebna podrška, dok ontološki model određuje koji sadržaj treba uključiti i kojim redosledom ga treba prikazati.

Funkcionalne odgovornosti u adaptivnom procesu time su eksplicitno razdvojene. Lokalni dijagnostički izlazi modela studenta i odgovarajući pragovi određuju da li pokušani objekat učenja predstavlja sadržaj kojem je potrebna dodatna podrška, dok status pokušaja i obaveznost

sadržaja omogućavaju da se od takvog slučaja odvoji nepokušani obavezni objekat nivoa N1, za koji procena ovladanosti ne postoji. Ontološke OR i BA relacije ne određuju da li student ima potrebu za podrškom, već određuju strukturne zavisnosti i redosled objekata u formiranoj putanji. Ponašajni tip predstavlja dodatni kontekst za predstavljanje i obrazloženje podrške, ali ne označava objekat kao slabu tačku, ne zamenjuje procenu ovladanosti i ne utiče na izbor ni redosled sadržaja. Veliki jezički model, kada se koristi za formiranje tekstualnog objašnjenja, ne učestvuje u identifikovanju potreba, izboru objekata niti određivanju njihovog redosleda, već samo jezički oblikuje prethodno strukturiranu adaptivnu odluku. Na taj način se u okviru arhitekture jasno razdvajaju procena stanja studenta, identifikovanje potrebe za podrškom, strukturno uređivanje preporuke, ponašajni kontekst i jezičko predstavljanje objašnjenja.

Da bi se kvantitativno procenila strukturna vrednost ontološkog uređivanja preporuka, predloženi pristup upoređen je sa jednostavnim referentnim pristupom u kojem su iste identifikovane slabe tačke uređene isključivo prema rastućoj proceni ovladanosti, bez uzimanja u obzir relacija preduslova OR i odnosa osnovnog i naprednog sadržaja BA. U predloženom ontološki zasnovanom pristupu nisu zabeležena kršenja nijednog od ograničenja između preporučenih objekata učenja: 0 od 461 ograničenja na predmetu SE201 i 0 od 2114 ograničenja na predmetu CS202. Nasuprot tome, pristup zasnovan samo na proceni ovladanosti prekršio je 52,9% ovih ograničenja na SE201 i 48,0% na CS202, pri čemu su napredni objekti učenja u pojedinim slučajevima postavljani ispred osnovnih sadržaja ili preduslova od kojih zavise. Uključivanje ontoloških relacija promenilo je preporučeni redosled za 28 od 37 studenata na predmetu SE201 i 68 od 74 studenta na predmetu CS202. Pošto je očuvanje OR i BA relacija ugrađeno u sam postupak ontološkog uređivanja, odsustvo njihovih prekršaja ne predstavlja nezavisnu potvrdu algoritamske superiornosti predloženog postupka. Poređenje sa redosledom zasnovanim samo na procenjenoj ovladanosti koristi se da kvantifikuje koliko bi eksplicitno definisane strukture preduslova i odnosa osnovnog i naprednog sadržaja bilo izgubljeno kada bi se preporuka rangirala bez ontoloških relacija. Ovi rezultati ne predstavljaju dokaz da ontološki uređene preporuke dovode do boljih ishoda učenja, već pokazuju u kojoj meri jednostavno rangiranje prema ovladanosti zanemaruje eksplicitnu strukturu preduslova i odnosa između osnovnih i naprednih nastavnih sadržaja.

Pored strukturnog poređenja sa referentnim redosledom zasnovanim samo na ovladanosti, dodatno je provereno u kojoj meri izbor pragova ovladanosti utiče na individualni skup identifikovanih slabih tačaka i njihov prioritet u konačnoj preporučenoj putanji. Analiza je sprovedena za svih osam alternativnih kombinacija pragova u odnosu na osnovno rešenje N1

= 0,80 i N2 = 0,50. Budući da se nepokušani obavezni objekti nivoa N1 identifikuju nezavisno od procenjene ovladanosti i praga, analiza osetljivosti odnosila se samo na pokušavane objekte identifikovane kao slabe tačke. Za svakog studenta posmatrani su promena broja takvih objekata, Spearmanova korelacija redosleda slabih tačaka zajedničkih osnovnom i alternativnom rešenju i Jaccardova sličnost skupa do pet najviše rangiranih pokušavanih slabih tačaka. Spearmanova korelacija računata je samo za studente koji su u osnovnom i alternativnom rešenju imali najmanje tri zajedničke pokušavane slabe tačke, što je u svakom poređenju obuhvatilo 35 od 37 studenata na predmetu SE201 i 72 od 74 studenta na predmetu CS202. Rezultati pokazuju da je broj identifikovanih pokušavanih slabih tačaka očekivano reagovao na promenu pragova, ali da su najviši prioriteti preporuke ostali relativno stabilni. U SE201 prosečna promena broja pokušavanih slabih tačaka kretala se od −0,9 do +2,4 objekta u odnosu na osnovni prosek od 18,7 objekata, dok se u CS202 kretala od −0,9 do +2,0 objekta u odnosu na osnovni prosek od 25,5 objekata. Prosečna Spearmanova korelacija redosleda iznosila je između 0,889 i 1,000 za SE201 i između 0,858 i 1,000 za CS202. Prosečna Jaccardova sličnost skupa do pet najviših prioriteta kretala se između 0,877 i 1,000 za SE201 i između 0,884 i 1,000 za CS202. Posmatrano kroz sva poređenja studenata sa osam alternativnih kombinacija pragova, vodeće pokušavane slabe tačke, do prve tri dostupne za pojedinačnog studenta, ostale su identične osnovnom rešenju u 90,9% poređenja za SE201 i 86,0% poređenja za CS202. Ovi rezultati ukazuju da promena pragova prvenstveno utiče na granične objekte, odnosno na to da li će objekat čija je procena bliska pragu biti uključen u skup slabih tačaka, dok najviši prioriteti individualne preporuke ostaju znatno stabilniji. Rezultati analize osetljivosti sažeto su prikazani u Tabeli 27.

Tabela 27. Osetljivost identifikovanja pokušavanih slabih tačaka i prioriteta individualne preporuke u odnosu na osnovne pragove N1 = 0,80 i N2 = 0,50.

Predmet	Prag N1	Prag N2	Prosečna promena broja slabih tačaka	Prosečni Spearman ρ	Prosečni Top-5 Jaccard
SE201	0,7	0,4	−0,865	0,960	0,973
SE201	0,7	0,5	−0,243	0,965	0,982
SE201	0,7	0,6	+1,973	0,889	0,881
SE201	0,8	0,4	−0,622	0,990	0,991
SE201	**0,8**	**0,5**	**0,000**	**1,000**	**1,000**
SE201	0,8	0,6	+2,216	0,924	0,899
SE201	0,9	0,4	−0,432	0,990	0,969
SE201	0,9	0,5	+0,189	1,000	0,978
SE201	0,9	0,6	+2,405	0,925	0,877
CS202	0,7	0,4	−0,919	0,917	0,901
CS202	0,7	0,5	0,000	1,000	1,000
CS202	0,7	0,6	+1,838	0,881	0,905
CS202	0,8	0,4	−0,919	0,917	0,901
CS202	**0,8**	**0,5**	**0,000**	**1,000**	**1,000**
CS202	0,8	0,6	+1,838	0,881	0,905
CS202	0,9	0,4	−0,730	0,904	0,884
CS202	0,9	0,5	+0,189	0,974	0,982
CS202	0,9	0,6	+2,027	0,858	0,889

Napomena: Podebljani redovi predstavljaju osnovnu kombinaciju pragova korišćenu u glavnoj analizi. Promena broja odnosi se na pokušavane objekte identifikovane kao slabe tačke u odnosu na osnovno rešenje. Spearmanov koeficijent izračunat je na osnovu položaja zajedničkih slabih tačaka u konačnoj ontološki uređenoj putanji i samo za studente sa najmanje tri zajedničke pokušavane slabe tačke. Top-5 Jaccard predstavlja sličnost skupa do pet najviše rangiranih pokušavanih slabih tačaka dostupnih za pojedinačnog studenta. Nepokušani obavezni N1 objekti nisu obuhvaćeni analizom jer se identifikuju nezavisno od pragova ovladanosti. Osnovni pragovi isti su za oba predmeta, jer su određeni prema nivou dubine, a ne prema predmetu. U predmetu CS202 redovi sa pragom N1 = 0,7 i N1 = 0,8 su identični zato što nijedan pokušani objekat nivoa N1 nije imao procenu ovladanosti u intervalu od 0,70 do 0,80, pa promena praga N1 u tom opsegu nije promenila skup slabih tačaka (prosečno 5,07 po studentu u obe varijante).

Analiza pokazuje i zašto je korisno razlikovati stabilnost procene ovladanosti na nivou kohorte od stabilnosti konačnog adaptivnog izlaza na nivou pojedinačnog studenta. Relativno male promene agregiranih pokazatelja same po sebi ne garantuju da će isti objekti ostati prioritetni u individualnoj preporuci. Dobijene visoke korelacije redosleda i sličnost najviših prioriteta zato predstavljaju dodatnu proveru robustnosti adaptivnog postupka: izbor konkretnih pragova utiče na granicu između ovladanog i slabog sadržaja, ali u analiziranom opsegu uglavnom ne menja najvažnije objekte na koje bi student trebalo prvo da usmeri pažnju. Ovaj nalaz odnosi se na unutrašnju stabilnost preporuka u analiziranim kohortama i ne

predstavlja dokaz da su izabrani pragovi optimalni niti da bi ista stabilnost bila dobijena u drugim predmetima ili populacijama.

Ponašajni tip studenta ne utiče na procenu ovladanosti. Adaptacija se ostvaruje na dva nivoa. Na nivou pojedinačnih objekata učenja izbor i redosled preporučenog sadržaja određuju procena ovladanosti, status pokušaja, nivo dubine, obaveznost sadržaja i ontološke relacije OR i BA. Na nivou strategije učenja ponašajni tip služi kao kontekst za predstavljanje preporuke: prikazuje se na kontrolnoj tabli i prosleđuje se, zajedno sa pravilom koje objašnjava pripadnost tipu, komponenti za jezičko oblikovanje obrazloženja, tako da student uz preporuku dobija i opis svog obrasca rada. Broj i redosled preporučenih objekata učenja namerno ne zavise od ponašajnog tipa, iz dva razloga. Prvo, time se dosledno sprovodi razdvajanje ponašanja od procene znanja: o tome šta student treba dalje da uči odlučuju dokazi o njegovom znanju, a ne pripadnost grupi. Drugo, ponašajni tip je relativno gruba kategorija čija dodela zavisi od izbora atributa i sastava kohorte (odeljak 7.2.3.3). Pravila zasnovana na tipu prenela bi tu nestabilnost u individualne preporuke, pa bi student blizu granice između klastera mogao dobiti drugačiju putanju bez ikakve promene u svom znanju. Potreba da se kod studenata sa manjim angažovanjem naglasi obavezni osnovni sadržaj zato je rešena preko statusa pokušaja, koji se određuje za svakog studenta pojedinačno: nepokušani obavezni objekti nivoa N1 uključuju se u putanju sa najvišim prioritetom. Ovi objekti su najbrojniji upravo kod minimalističkog tipa (prosečno 23,2 u SE201 i 15,2 u CS202, prema 12,0 do 13,8 kod ostalih tipova), pa ovi studenti dobijaju naglasak na obaveznom osnovnom sadržaju i preduslovima na osnovu sopstvenih podataka, a ne na osnovu pripadnosti tipu. Prilagođavanje tona i naglaska obrazloženja prema ponašajnom tipu, bez promene izbora i redosleda sadržaja, predstavlja pravac daljeg razvoja (odeljak 8.4).

Time se zadržava razlika između tri komponente modela:

- procena ovladanosti određuje trenutno stanje znanja;
- ontološke relacije određuju strukturu i redosled nastavnog sadržaja;
- ponašajni tip pruža dodatni opis ponašajnog konteksta uz preporuku, dok je prilagođavanje tona i naglaska obrazloženja planirano za budući rad.

Ovakvo razdvajanje sprečava da se studentu sadržaj preporučuje samo na osnovu pripadnosti određenom ponašajnom tipu. Dva studenta istog tipa mogu imati različite slabe tačke i zato dobijati različite putanje učenja.

Svaki preporučeni objekat učenja prati strukturirano objašnjenje koje studentu i nastavniku omogućava da utvrde zbog čega je sadržaj uključen u putanju. Objašnjenje sadrži:

- naziv preporučenog objekta učenja;
- kompetenciju i nivo dubine kojima objekat pripada;
- razlog njegovog uključivanja u preporuku;
- procenjenu vrednost ovladanosti i odgovarajući prag kada za objekat postoji dokaz iz pokušaja;
- informaciju da je objekat nepokušani obavezni sadržaj nivoa N1 kada procena ovladanosti ne postoji;
- informaciju da li je objekat neposredno identifikovana slaba tačka, preduslov ili osnovna varijanta drugog sadržaja;
- osnovnu varijantu sadržaja, kada postoji odgovarajuća BA relacija;
- preduslovne objekte učenja, kada postoje obavezne OR relacije;
- preporučeni položaj objekta u ukupnoj putanji učenja.

Na taj način se u objašnjenju eksplicitno razlikuju dva slučaja. Za pokušani objekat sa procenom ispod praga može se zaključiti da raspoloživi dokaz ukazuje na nedovoljnu ovladanost. Za nepokušani obavezni objekat nivoa N1 ne tvrdi se da ga student nije savladao, već da za njega ne postoji dokaz o ovladanosti i da pripada obaveznom jezgru koje još nije pokriveno aktivnošću studenta. Objašnjenje zato ne daje samo opštu tvrdnju da je određena oblast „slaba“, već prikazuje konkretne podatke, status aktivnosti i ontološke relacije na kojima je preporuka zasnovana. Jezička prezentacija strukturiranog objašnjenja organizovana je oko tri pitanja povratne informacije prema Hatiju i Timperliju: Kuda idem?, Kako mi ide? i Šta dalje? [263]. Deo Kuda idem? povezuje preporuku sa ciljem učenja, pripadajućom kompetencijom i nivoom dubine. Deo Kako mi ide? prikazuje trenutno stanje kroz procene ovladanosti, ostvarenost nivoa, identifikovane snage i nedostatke i ponašajni kontekst studenta. Deo Šta dalje? predstavlja objekte učenja koje je adaptivni mehanizam već izabrao i uredio, uključujući njihove preduslove i odnose između osnovnog i naprednog sadržaja.

Za završno jezičko oblikovanje strukturiranog objašnjenja u implementiranom sistemu koristi se model Mistral 7B [273], koji se izvršava lokalno preko platforme Ollama. Njegova uloga ograničena je na površinsko jezičko oblikovanje sadržaja koji su prethodno izračunali model studenta, dijagnostička pravila i adaptivni mehanizam. Veliki jezički model ne

identifikuje slabe tačke, ne određuje pragove, ne bira niti uređuje objekte učenja, ne određuje njihove preduslove i ne uvodi nove činjenice u preporuku.

Generisanje je u korišćenoj implementaciji podešeno sa temperaturom 0,0, vrednošću top-p jednakom 1,0, kontekstnim prozorom od 4096 tokena i maksimalnom dužinom generisanog odgovora od 512 tokena. Model kao ulaz dobija strukturirani JSON zapis koji sadrži ponašajni tip studenta i pravilo koje ga objašnjava, vrednosti ostvarenosti nivoa i ovladanosti kompetencijama, identifikovane snage i pokazatelje napretka, hronološki niz rezultata i najviše osam objekata učenja koje je Adaptive Engine prethodno izabrao i uredio. Za svaki od tih objekata prosleđuju se raspoloživi podaci o nivou dubine, proceni ovladanosti i preduslovnim relacijama.

Uputstvo jezičkom modelu zahteva da se studentu obraća podržavajućim jezikom u drugom licu, da koristi isključivo informacije iz strukturiranog ulaza, da ne izmišlja podatke, brojeve, teme ili razloge za preporuku, da ne menja redosled objekata koji je odredio Adaptive Engine i da odgovor organizuje u tačno tri celine: Kuda idem?, Kako mi ide? i Šta dalje?. Kompletan prompt na srpskom jeziku korišćen u implementaciji sistema za generisanje objašnjivih preporuka dat je u Prilogu A.

Pre prikazivanja studentu svaki generisani tekst prolazi kroz automatske provere prihvatljivosti. Objašnjenje se prihvata samo ako su sve tri zahtevane celine prisutne i neprazne, ako ukupan tekst ne prelazi 3500 znakova, ako u slobodno generisanom tekstu nisu uvedene cifre i ako deo Šta dalje? eksplicitno navodi prvi objekat učenja koji je odredio Adaptive Engine. Zabrana uvođenja cifara sprečava generativni sloj da proizvede ili promeni numeričke vrednosti koje se studentu zasebno prikazuju kroz deterministički deo interfejsa. Ako bilo koji od navedenih uslova nije ispunjen, generisani tekst se odbacuje i zamenjuje deterministički formulisanim prikazom istog strukturiranog sadržaja.

Ove provere predstavljaju zaštitne mehanizme generisanja, a ne empirijsku validaciju činjenične vernosti, konzistentnosti, potpunosti, tona ili mogućih jezičkih pristrasnosti generisanog teksta. Zbog toga se tvrdnje ovog istraživanja odnose na ontološki utemeljen sadržaj preporuke i sledljivost njenog strukturiranog obrazloženja, a ne na nezavisno potvrđen kvalitet formulacije koju proizvodi veliki jezički model.

Kao ilustracija rada adaptivnog sloja izabran je student predmeta SE201 koji pripada efikasnom ponašajnom tipu. Student ima relativno visoku ostvarenost osnovnog nivoa, ali njegov individualni profil pokazuje da su pojedini delovi sadržaja ostali nedovoljno savladani

ili nisu bili pokušani. Kod ovog studenta identifikovano je 29 pokušavanih objekata učenja čija je procena ovladanosti niža od odgovarajućeg praga i, odvojeno od njih, 13 nepokušavanih obaveznih objekata nivoa N1. Za drugu grupu nije formirana procena ovladanosti, već su ti objekti označeni kao nedostajući sadržaji obaveznog jezgra visokog prioriteta.

Adaptivni sloj povezuje obe kategorije sa strukturom predmeta i ontološkim relacijama i organizuje ih u jedinstvenu putanju za dalje učenje. Redosled prati strukturu predmeta SE201 i odgovarajuće relacije preduslova i osnovnog i naprednog sadržaja, pri čemu su nepokušani obavezni N1 objekti eksplicitno označeni kao nedostajući deo jezgra. Time se sprečava da se odsustvo aktivnosti pogrešno tumači kao procena ovladanosti jednaka nuli, ali se istovremeno obezbeđuje da sadržaj koji student nije ni pokušao ne bude izostavljen iz preporuke.

Primer takođe pokazuje da adaptivna podrška nije namenjena samo studentima sa niskim ukupnim postignućem. Student može imati dobre rezultate na većem delu predmeta i istovremeno imati jasno lokalizovane pokušane slabe tačke ili nepokrivene obavezne sadržaje kojima je potrebna dodatna pažnja. U tom slučaju preporuka služi za precizno usmeravanje daljeg rada, a ne za opštu klasifikaciju studenta kao uspešnog ili neuspešnog. Objedinjeni prikaz elemenata preporuke dat je na Slici 43. Kontrolna tabla povezuje rezultate modela studenta i strukturu nastavnog sadržaja tako da student može istovremeno da vidi svoje opšte stanje, različite razloge zbog kojih su objekti uključeni u preporuku i predloženi redosled daljeg rada.

Na taj način zatvara se adaptivna povratna sprega prikazana na Slici 2, od dokaza iz aktivnosti studenta do strukturiranog objašnjenja preporuke. Odluka o tome šta treba preporučiti i kojim redosledom ostaje determinisana modelom studenta, pravilima adaptivnog mehanizma i ontološkom strukturom, dok je veliki jezički model ograničen na završno jezičko predstavljanje već donete i proverljive odluke.



Slika 43. Primer kontrolne table sa objašnjivom preporukom za studenta predmeta SE201: ponašajni tip, procene ovladanosti, ostvarenost nivoa, identifikovani sadržaji za podršku, uređena putanja učenja, profil kompetencija i ontološki prostor nastavnog sadržaja.

Kontrolna tabla prikazuje više međusobno povezanih nivoa informacija. Ponašajni tip opisuje opšti način rada studenta, dok procene ovladanosti i ostvarenosti nivoa prikazuju stanje znanja i realizaciju aktivnosti. Prikaz sadržaja identifikovanih za podršku razlikuje pokušane slabe tačke od nepokušavanih obaveznih objekata nivoa N1, dok uređena putanja pokazuje preporučeni redosled daljeg rada. Profil kompetencija omogućava pregled jakih i slabih oblasti,

a ontološki prostor prikazuje položaj preporučenih objekata u širem nastavnom sadržaju. Objašnjivost preporuke zato se ne zasniva samo na tekstualnom obrazloženju. Za pokušani objekat moguće je pratiti raspoložive dokaze, procenu ovladanosti, pripadajuću kompetenciju, nivo dubine i prag, dok se kod nepokušavanog obaveznog objekta nivoa N1 razlog uključivanja zasniva na njegovom statusu obaveznog jezgra i odsustvu pokušaja. Za preporučene objekte dodatno se mogu pratiti ontološke relacije koje određuju uključivanje preduslova, osnovnih varijanti i njihov položaj u putanji. Predloženi mehanizam tako povezuje interpretabilne izlaze modela studenta sa eksplicitnim relacijama modela nastavnog sadržaja, dok se jezičko objašnjenje koristi kao dodatna podrška njihovom razumevanju.

Konačna implementacija zato obuhvata i pokušane objekte učenja čija je procena niža od odgovarajućeg praga i nepokušane obavezne objekte nivoa N1, ali ova dva slučaja u objašnjenju tretira različito. Ovako formirana preporuka u okviru ovog istraživanja prikazana je kroz posebnu kontrolnu tablu i ontološki organizovan prostor za učenje. Istovremeno, strukturirani izlaz adaptivnog mehanizma projektovan je tako da može biti prosleđen i drugim sistemima za isporuku nastavnog sadržaja. Sledeći odeljak zato ne predstavlja novu empirijsku evaluaciju adaptivnog mehanizma, već razmatra mogućnosti njegove integracije sa postojećim sistemima e-učenja, uz jasno razdvajanje implementiranog i evaluiranog rešenja od mogućnosti koje proizlaze iz modularne arhitekture.

7.3.2. Primena i mogućnosti integracije adaptivne preporuke u postojeće sisteme e-učenja

Konačna arhitektura razvijena u ovoj disertaciji nije vezana za jedan konkretan sistem za upravljanje učenjem. Model nastavnog sadržaja, model studenta i adaptivni mehanizam organizovani su kao funkcionalno odvojene komponente koje razmenjuju strukturirane podatke preko servisnih interfejsa, dok sistem za isporuku nastavnog sadržaja zadržava odgovornost za prikaz nastavnih materijala i realizaciju odgovarajućih aktivnosti. Ovakva labava povezanost smanjuje zavisnost analitičke i adaptivne logike od unutrašnje realizacije pojedinačne platforme. Projektovanu modularnost, međutim, ne treba poistovećivati sa empirijski potvrđenom interoperabilnošću sa proizvoljnim sistemom za upravljanje učenjem.

U arhitekturi opisanoj u odeljku 6.5.3 mogu se razlikovati odgovornosti sistema za isporuku sadržaja, sistema za upravljanje obrazovanjem i OBSLO komponenti. Sistem za isporuku nastavnog sadržaja, odnosno ILS/LMS, omogućava studentu pristup obrazovnim resursima i

registruje relevantne interakcije sa njima. EMS upravlja podacima o kurikulumu, silabusu predmeta, aktivnostima provere, pokušajima i ostvarenim rezultatima. OBSLO povezuje ontološki model nastavnog sadržaja sa modelom studenta, adaptivnim mehanizmom i slojem za objašnjavanje preporuke. Semantička veza VERIFY određuje na koji objekat učenja, ishod, kompetenciju i nivo dubine se određeni dokaz iz aktivnosti odnosi. Na toj osnovi model studenta formira procene i druge pokazatelje stanja, dok Adaptive Engine određuje koje objekte učenja treba uključiti u preporuku i kojim redosledom.

Izlaz adaptivnog mehanizma namenjen sistemu za isporuku sadržaja ne mora da sadrži unutrašnje detalje algoritama primenjenih u modelu studenta. Dovoljno je da strukturirani zapis sadrži identifikator preporučenog objekta učenja, razlog njegovog uključivanja, pripadajuću kompetenciju i nivo dubine, status pokušaja, raspoloživu procenu ovladanosti kada ona postoji, relevantne ontološke relacije i položaj objekta u preporučenoj putanji. Za pokušani sadržaj razlog uključivanja može biti procena ovladanosti niža od odgovarajućeg praga. Za nepokušani obavezni objekat nivoa N1 razlog predstavlja činjenica da pripada obaveznom jezgru za koje student još nije pružio dokaz kroz aktivnost, pri čemu se takvom objektu ne dodeljuje veštačka procena ovladanosti.

U zavisnosti od mogućnosti ciljnog sistema, ovakav izlaz može se koristiti na najmanje dva nivoa. Prvi je savetodavni način primene, u kojem se osnovna struktura predmeta ne menja, već student dobija dodatni personalizovani prikaz svog stanja, uređene putanje i razloga zbog kojih su pojedini objekti učenja preporučeni. Ovom načinu odgovara kontrolna tabla implementirana i evaluirana u okviru ovog istraživanja. Student zadržava pristup osnovnom toku predmeta, dok mu adaptivni sloj pruža dodatnu, individualno formiranu podršku za dalje učenje.

Drugi je izvršni način primene, u kojem sistem za isporuku sadržaja podržava uslovno grananje, dinamičko dodeljivanje aktivnosti ili formiranje dodatnih sekvenci. U tom slučaju strukturirana putanja koju je formirao Adaptive Engine mogla bi biti prevedena u konkretnu sekvencu aktivnosti: preduslovni sadržaj mogao bi biti postavljen pre objekta koji od njega zavisi, osnovna varijanta sadržaja pre njegove napredne varijante, a zatim bi se uključili objekti kod kojih je identifikovana nedovoljna ovladanost ili nepokriven obavezni sadržaj.

Kao primer sistema zasnovanog na sekvencama može se posmatrati sistem za upravljanje aktivnostima učenja LAMS, koji omogućava projektovanje i realizaciju tokova sastavljenih od nastavnih resursa i aktivnosti. Zbog takve strukture, LAMS predstavlja pogodan primer za

objašnjenje kako bi uređena lista objekata iz adaptivnog sloja mogla biti preslikana u dodatnu ili alternativnu sekvencu. U okviru ove disertacije, međutim, nije sprovedena produkcijska implementacija u kojoj konačni model studenta i Adaptive Engine automatski menjaju LAMS sekvencu za svakog pojedinačnog studenta. LAMS se zato u ovom odeljku koristi kao primer mogućeg izvršnog okruženja, a ne kao empirijski potvrđena implementacija konačnog adaptivnog mehanizma [274].

U izvršnom scenariju ciklus adaptacije mogao bi da se nastavi nakon realizacije preporučenih aktivnosti. Novi rezultati postali bi verifikovani dokazi povezani sa odgovarajućim elementima nastavnog sadržaja, model studenta bi na osnovu njih ažurirao svoje stanje, a adaptivni mehanizam bi zatim mogao ponovo da izračuna putanju. Na taj način ista arhitektura konceptualno podržava zatvorenu povratnu spregu između aktivnosti, procene stanja i naredne preporuke. Važno je, međutim, da se ova mogućnost ne predstavlja kao eksperimentalno potvrđen efekat automatskog sekvenciranja, jer takva evaluacija nije sprovedena u ovom istraživanju.

Tehnička osnova za ovakav način povezivanja postoji u modularnoj realizaciji sistema. Sloj nastavnog sadržaja zasnovan je na DITA objektima učenja, dok servisni interfejsi omogućavaju razmenu podataka između funkcionalno razdvojenih komponenti. Ranija istraživanja u kojima su učestvovali autori pokazala su i mogućnost objedinjavanja institucionalnih podataka iz Moodle i LAMS okruženja korišćenjem xAPI zapisa i zajedničkog skladišta zapisa o učenju [275]. Takav rezultat potvrđuje mogućnost integracije podataka iz heterogenih obrazovnih sistema, ali ne predstavlja dokaz interoperabilnosti niti skalabilnosti konačne arhitekture razvijene u ovoj disertaciji.

Interoperabilnost konačne arhitekture sa široko korišćenim sistemima za upravljanje učenjem, kao što su Moodle ili Canvas, nije bila predmet evaluacije ove disertacije. Isto važi za formalno usklađivanje ontološkog modela sa standardizovanim šemama metapodataka za objekte učenja, kao što su IEEE LOM ili odgovarajuće IMS/1EdTech specifikacije. Zbog toga se prenosivost razvijenog pristupa zasniva na projektovanoj modularnosti, strukturiranim podacima i servisnim interfejsima, ali se ne tvrdi da je univerzalna interoperabilnost empirijski potvrđena.

Takođe, u istraživanju nije sprovedena sistematska analiza skalabilnosti konačne arhitekture koja bi obuhvatila računarske troškove, vreme obrade, broj istovremenih korisnika, veliki broj predmeta i organizacioni i tehnički napor potreban za integraciju na nivou institucije. Rezultati

zato pokazuju izvodljivost rada arhitekture u analiziranim nastavnim kontekstima, ali ne omogućavaju zaključak o njenim performansama pri masovnoj primeni.

Za potpunu empirijsku proveru izvršnog načina primene bilo bi potrebno implementirati automatsku razmenu podataka između sistema za isporuku sadržaja, modela studenta i adaptivnog sloja i sprovesti kontrolisanu ili kvazieksperimentalnu studiju. Grupa studenata koja koristi ontološki utemeljenu adaptivnu putanju mogla bi se uporediti sa grupom koja prati standardnu linearnu putanju predmeta. Pored tehničke uspešnosti integracije, trebalo bi pratiti objektivne obrazovne pokazatelje, kao što su promena znanja između početnog i završnog merenja, ovladanost kompetencijama, ostvarenost nivoa, realizacija aktivnosti i zadržavanje studenata. Tek bi takva evaluacija omogućila procenu nastavne efikasnosti dinamičkog prilagođavanja, dok rezultati prikazani u ovoj disertaciji potvrđuju izvodljivost i interpretabilnost integrisanog postupka.

7.3.3. Zaključne napomene o adaptivnom modelu

Adaptivni model predstavlja završni operativni sloj integrisane arhitekture razvijene u ovoj disertaciji, a njegovu ulogu potrebno je jasno razlikovati od uloge modela studenta. Model studenta na osnovu verifikovanih dokaza formira procenu trenutnog stanja pojedinačnog studenta, dok adaptivni model to stanje povezuje sa formalno organizovanim nastavnim sadržajem i određuje konkretne naredne korake za dalje učenje. Centralni tok razvijenog pristupa prikazan je na Slici 2**.**

U ovom procesu zadržane su tri konceptualno različite dimenzije modela studenta. **Ovladanost kompetencijom** predstavlja procenu demonstrirane ovladanosti zasnovanu na sekvenci dokaza. Ostvarenost nivoa pokazuje koliki je deo poena predviđenih za aktivnosti odgovarajućeg nivoa dubine student ostvario, uzimajući u obzir samo trenutno važeće pokušaje. Ponašajni tip opisuje obrazac na koji student radi i angažuje se tokom predmeta. Ove dimenzije su međusobno povezane u interpretaciji studentskog napretka, ali se ne svode na jednu zajedničku ocenu i ne koriste se kao međusobne zamene.

Adaptivni mehanizam koristi ovu razdvojenost pri identifikovanju potreba za podrškom. Pokušani objekti učenja čija je procena niža od praga odgovarajućeg nivoa predstavljaju slabe tačke u užem smislu, jer postoji dokaz iz aktivnosti koji ukazuje na nedovoljnu ovladanost. Nepokušani obavezni objekti nivoa N1 predstavljaju drugu kategoriju: za njih ne postoji dovoljan dokaz za procenu ovladanosti, ali pripadaju obaveznom jezgru predmeta i zato se

uključuju kao nedostajući sadržaji visokog prioriteta. Njima se ne dodeljuje veštačka procena ovladanosti jednaka nuli. Ovakvim razdvajanjem konačna implementacija obuhvata i studente sa malim obimom aktivnosti, bez pogrešnog poistovećivanja odsustva dokaza sa neuspehom na sadržaju.

Nakon formiranja početnog skupa objekata za podršku, Adaptive Engine koristi eksplicitne relacije ontološkog modela za njihovo dopunjavanje i uređivanje. Relacije redosleda OR omogućavaju da se neophodni preduslovi postave pre sadržaja koji od njih zavisi, dok relacije osnovni/napredni BA omogućavaju da se osnovna varijanta koncepta uključi pre odgovarajućeg naprednog sadržaja. Na taj način preporuka se ne zasniva samo na vrednosti procene, već i na semantičkoj strukturi nastavnog sadržaja.

Ponašajni tip studenta koristi se kao dodatni kontekst za strategiju podrške, ali ne određuje samostalno koji je objekat učenja slaba tačka. Njegova funkcija jeste da pruži kontekst za predstavljanje i obrazloženje već identifikovanih potreba, dok izbor i redosled sadržaja ostaju određeni procenom ovladanosti, statusom pokušaja i ontološkim relacijama. Time se izbegava da se obrazac angažovanja pogrešno interpretira kao stanje znanja: student može pokazivati sličan nivo ovladanosti kao drugi student, a da do njega dolazi drugačijim obrascem rada, kao što su pokazali ponašajni tipovi identifikovani u predmetima SE201 i CS202.

Objašnjivost adaptivne preporuke ostvaruje se pre svega njenom sledljivošću. Za svaki preporučeni objekat moguće je utvrditi da li je uključen zato što je pokušavan i procenjen ispod praga, zato što predstavlja nepokušani obavezni N1 sadržaj, zato što je preduslov drugog objekta ili zato što predstavlja njegovu osnovnu varijantu. Kada procena ovladanosti postoji, moguće je povezati je sa kompetencijom, nivoom dubine i dokazima na osnovu kojih je formirana. Na taj način objašnjenje nije samo naknadno tekstualno opravdanje odluke, već prikaz podataka, pravila i ontoloških relacija na kojima je odluka zasnovana.

Formiranje adaptivne odluke odvojeno je od njenog završnog jezičkog oblikovanja. Veliki jezički model, kada se koristi, dobija već strukturirani sadržaj preporuke i nema ulogu u identifikovanju slabih tačaka, postavljanju pragova, izboru objekata učenja, određivanju preduslova ili uređivanju putanje. Jezički model služi isključivo za formulisanje već utvrđenog obrazloženja u prirodnom jeziku. Ako generisani tekst ne zadovolji definisane uslove prihvatljivosti, koristi se deterministički formulisana verzija istog strukturiranog sadržaja. Time se zadržava mogućnost da odluka ostane proverljiva nezavisno od generativnog sloja.

Automatske provere generisanog objašnjenja predstavljaju zaštitne mehanizme implementacije, ali ih ne treba tumačiti kao nezavisnu empirijsku validaciju kvaliteta generisanog jezika. U okviru ovog istraživanja nije sprovedena sistematska ljudska evaluacija činjenične vernosti, konzistentnosti, potpunosti, tona ili mogućih jezičkih pristrasnosti svih generisanih objašnjenja. Tvrdnja o objašnjivosti zato se prvenstveno odnosi na sledljivost strukturiranog sadržaja preporuke i mogućnost povezivanja odluke sa podacima i pravilima iz kojih je izvedena.

Empirijska evaluacija pokazala je da je ovakav lanac moguće operacionalizovati na stvarnim podacima dva predmeta različitog nastavnog karaktera. Verifikovani rezultati aktivnosti povezani su sa objektima učenja, kompetencijama i nivoima dubine; formirane su sekvencijalne procene ovladanosti i odvojene mere ostvarenosti nivoa; identifikovani su ponašajni tipovi i konkretne potrebe za podrškom; a ti izlazi zatim su povezani sa ontološkim relacijama radi generisanja uređene i objašnjive putanje za dalje učenje. Time je pokazana izvodljivost integrisanog postupka na realnim obrazovnim podacima, što predstavlja centralni cilj završne faze istraživanja.

Evaluacija kontrolne table sprovedena sa 86 studenata pružila je dodatne podatke o korisničkoj percepciji adaptivnog sloja. Rezultati pokazuju da su studenti preporuke i njihova objašnjenja uglavnom ocenili kao razumljive, relevantne za sopstvene slabe oblasti i korisne za dalje učenje. Ovi rezultati predstavljaju početni dokaz prihvatljivosti i percipirane korisnosti razvijenog pristupa, ali ne predstavljaju dokaz da je korišćenje preporuka uzročno povećalo znanje, ovladanost kompetencijama, akademski uspeh, angažovanje ili stopu realizacije aktivnosti.

Rezultat istraživanja zato treba tumačiti kao dokaz izvodljivosti i interpretabilnosti integrisane arhitekture u analiziranim nastavnim kontekstima. Arhitektura je projektovana kao modularna i u osnovi domenski nezavisna, jer se njena ontološka struktura, kompetencijska dimenzija i nivoi dubine mogu instancirati za različite obrazovne domene. Ipak, evaluacija je sprovedena na dva dodiplomska predmeta iz oblasti računarstva, na jednoj instituciji i jednoj generaciji studenata. Primena u drugim disciplinama, na drugim nivoima studija i u drugim institucijama zahteva dodatnu empirijsku proveru.

Isto ograničenje važi za tehničku prenosivost. Servisno zasnovana, labavo povezana arhitektura omogućava projektovanje integracije sa drugim sistemima, ali u ovom istraživanju nisu empirijski potvrđene interoperabilnost sa široko korišćenim LMS platformama,

usklađenost sa različitim standardima metapodataka niti skalabilnost pri velikom broju predmeta i korisnika. Ove osobine zato predstavljaju zahteve za narednu fazu validacije, a ne rezultate koje je sadašnje istraživanje već dokazalo.

Na osnovu predstavljenih rezultata može se zaključiti da adaptivni model ostvaruje svoju osnovnu funkciju u okviru razvijene arhitekture: procenjeno stanje studenta i identifikovana potreba za podrškom prevode se u konkretan skup nastavnih sadržaja, taj skup se uređuje pomoću eksplicitnih ontoloških relacija, a studentu se pruža sledljivo obrazloženje razloga i redosleda preporuke. Time se zatvara centralni doprinos disertacije: kompetencijski i ontološki strukturiran nastavni sadržaj povezuje se sa verifikovanim dokazima o učenju, iz njih se formira dinamički i interpretabilan model studenta, a identifikovana potreba prevodi se u konkretnu, uređenu i objašnjivu preporuku za dalje učenje.

Poglavlje 8 sumira rezultate ovog procesa u odnosu na postavljena istraživačka pitanja, ciljeve i hipoteze, razdvaja potvrđene doprinose od ograničenja istraživanja i definiše pravce potrebne za dalju empirijsku validaciju razvijene arhitekture.

Poglavlje 8

8. Zaključci i budući rad

8.1. Zaključci istraživanja

Istraživanje sprovedeno u ovoj disertaciji bilo je usmereno na razvoj integrisanog pristupa personalizovanom i adaptivnom e-učenju u kojem se podaci o aktivnostima i rezultatima pojedinačnog studenta neposredno povezuju sa formalno organizovanim nastavnim sadržajem. Polazište istraživanja bilo je da sama dostupnost velike količine podataka o studentskim aktivnostima nije dovoljna za formiranje pedagoški smislenih preporuka. Da bi se iz rezultata aktivnosti izvela konkretna odluka o tome gde je studentu potrebna podrška i šta bi trebalo dalje da uči, potrebno je uspostaviti sledljivu vezu između nastavnog sadržaja, dokaza o učenju, procenjenog stanja studenta i adaptivne odluke.

U skladu sa metodologijom nauke o projektovanju, istraživanje je realizovano kao iterativni razvoj više međusobno povezanih artefakata. Pojedinačne faze nisu predstavljale izolovana istraživanja, već su rezultati i ograničenja prethodnih rešenja korišćeni za formulisanje zahteva naredne iteracije. Konačni rezultat zato nije jedan algoritam ili jedna softverska komponenta, već arhitektura u kojoj se povezuju model nastavnog sadržaja, model studenta i adaptivni mehanizam.

Prvi deo istraživanja odnosio se na razvoj ontološkog modela nastavnog sadržaja zasnovanog na objektima učenja. Model formalizuje oblasti i jedinice znanja, teme, podteme, objekte učenja i njihove resurse, kao i semantičke relacije kojima se predstavljaju hijerarhija sadržaja, redosled izučavanja i odnosi između osnovnih i naprednih sadržaja. Njegova vizualizacija pomoću multidimenzionalnih konceptualnih mapa omogućila je nelinearno kretanje kroz nastavni sadržaj i dinamičko formiranje prostora učenja. Dve iteracije evaluacije u stvarnom nastavnom okruženju pokazale su da takva organizacija može da podrži pronalaženje i povezivanje nastavnih materijala i rešavanje zadataka u ontološki organizovanom prostoru.

Ontološki model je zatim integrisan sa kompetencijski vođenim okvirom u kojem se objekti učenja povezuju sa ishodima učenja, kompetencijama, komponentama znanja i veštine, nivoima dubine i elementima za verifikaciju naučenog. Posebna vrednost integrisanog modela jeste u semantičkoj operacionalizaciji veze između objekta učenja i dokaza nastalog u aktivnosti provere. Element VERIFY pri tome nije nova komponenta za proveru znanja, već semantička veza kojom se određuje na koji objekat učenja, ishod, kompetenciju i nivo dubine se rezultat aktivnosti evidentiran u sistemu za upravljanje obrazovanjem odnosi. Na taj način rezultat testa, zadatka, projekta ili druge aktivnosti prestaje da bude samo brojčana vrednost i postaje strukturirani dokaz koji može da se koristi za modelovanje stanja studenta.

Razvoj modela studenta sproveden je kroz tri iteracije. Prva faza pokazala je mogućnost primene algoritama mašinskog učenja za predikciju akademskog uspeha, ali je istovremeno ukazala na ograničenje agregiranog predstavljanja studenta. Druga faza pokazala je da klasterovanje može otkriti različite obrasce angažovanja i da se ti obrasci razlikuju u zavisnosti od nastavnog i institucionalnog konteksta. Međutim, ni ukupna predikcija uspeha ni pripadnost grupi nisu omogućavali dovoljno precizno određivanje konkretnog nastavnog sadržaja kojem je pojedinačnom studentu potrebna dodatna pažnja. Ovi nalazi predstavljali su osnovu za razvoj treće, konačne iteracije modela.

Konačni model studenta organizovan je kao višeslojna reprezentacija u kojoj se odvojeno posmatraju ovladanost kompetencijama, ostvarenost nivoa i ponašajni obrazac studenta. Sekvencijalna procena ovladanosti realizovana je primenom Bajesovog praćenja znanja na nivou kombinacije predmet-kompetencija predmeta-nivo dubine. Pri proceni se koristi puna hronološka sekvenca dokaza, uključujući ranije pokušaje, dok se ostvarenost nivoa izračunava odvojeno na osnovu trenutno važećih aktivnosti. Time se demonstrirana ovladanost sadržajem razlikuje od udela predviđenih poena koje je student ostvario, na koji utiču i nerealizovane aktivnosti.

Empirijski rezultati pokazali su da ova dva pokazatelja zaista nose različite informacije. U oba analizirana predmeta vrednosti ovladanosti i ostvarenosti bile su niže na zahtevnijem nivou N2 nego na osnovnom nivou N1, ali se njihov međusobni odnos razlikovao između predmeta i studenata. Student može dobro rešavati aktivnosti koje pokušava, a istovremeno ne realizovati značajan deo propisanog rada. Takva razlika nije vidljiva u jednoj agregiranoj oceni, dok višeslojni model omogućava da se razlikuje problem nedovoljne ovladanosti od problema nedovoljne realizacije aktivnosti.

Stabilnost ovog dela modela dodatno je proverena analizama osetljivosti i unakrsnom validacijom. Promena pragova ovladanosti u ispitanom opsegu menjala je očekivani broj pokušavanih objekata označenih kao slabe tačke, ali nije menjala osnovne obrasce na nivou kohorte, dok je ostvarenost nivoa ostala nepromenjena jer se izračunava nezavisno od tih pragova. Alternativni načini ponderisanja dokaza menjali su prosečne procene ovladanosti za najviše 0,8 procentnih poena. Petostruka unakrsna validacija dala je srednju apsolutnu razliku procena od 0,008 za SE201 i 0,010 za CS202, što podržava stabilnost procena unutar analiziranih kohorti.

Poređenje kontinuirane i binarne BKT formulacije pokazalo je da kontinuirana varijanta nije uniformno prediktivno superiorna. U predmetu SE201 ostvarila je neznatno bolji rezultat, dok je u CS202 binarna formulacija imala nešto manji logaritamski gubitak. Zbog toga izbor kontinuiranog BKT-a u disertaciji nije zasnovan na tvrdnji o opštoj prediktivnoj nadmoći, već na njegovoj sposobnosti da očuva informaciju o delimičnom uspehu studenta i time pruži granularniji obrazovni dokaz za dalju dijagnostiku i preporučivanje.

Ponašajni sloj modela formiran je nezavisno od procene znanja, korišćenjem tri atributa angažovanja: obima aktivnosti, broja aktivnih dana i udela ranijih pokušaja. U predmetu SE201 identifikovana su tri ponašajna tipa, a u CS202 dva. Procene ovladanosti i ostvarenosti nisu korišćene kao ulaz u klasterovanje, već su pridružene naknadno radi interpretacije. Time je omogućeno da se ponašajni tip tumači kao opis načina rada, a ne kao mera sposobnosti ili znanja.

Dodatne provere pokazale su da su izdvojeni ponašajni obrasci u proseku stabilni pri promeni sastava uzorka. Pri 200 ponovljenih poduzoraka koji su sadržali po 80% studenata prosečna Jaccardova sličnost sa rešenjem dobijenim nad celom kohortom iznosila je 0,90 za oba predmeta. Metode zasnovane na gustini nisu dale pogodnije rešenje za potrebe adaptivnog modela, jer su u informativnijim konfiguracijama značajan deo studenata označavale kao šum. Analiza izostavljanja atributa dodatno je pokazala da udeo ranijih pokušaja i obim aktivnosti nose najveći deo diskriminativnog signala. Ove rezultate ipak treba tumačiti kao podršku stabilnosti obrazaca u posmatranim kohortama, a ne kao dokaz postojanja univerzalnih i trajnih kategorija studenata.

Fino granularna veza između dokaza i objekata učenja omogućila je da se potrebe za podrškom lokalizuju na konkretnom nastavnom sadržaju. Konačna implementacija razlikuje dve kategorije. Prvu čine pokušani objekti učenja kod kojih raspoloživi dokaz dovodi do

procene ovladanosti niže od odgovarajućeg praga. Drugu čine nepokušani obavezni objekti nivoa N1. Za drugu kategoriju ne postoji procena ovladanosti i zato se takvim objektima ne dodeljuje veštačka vrednost nula; oni se u adaptivnom sloju označavaju kao nedostajući sadržaji obaveznog jezgra visokog prioriteta.

Ovakva dopuna mehanizma posebno je važna za studente sa malim obimom aktivnosti. Kada bi se analizirali samo pokušani sadržaji, student koji je radio veoma malo mogao bi imati mali broj identifikovanih slabih tačaka samo zato što za veliki deo gradiva nije generisao nikakav dokaz. U konačnoj implementaciji nepokušani obavezni N1 sadržaji uključeni su u skup za podršku, čime se odsustvo dokaza jasno razlikuje od dokaza o nedovoljnoj ovladanosti i izbegava sistematsko podoznačavanje studenata sa ograničenom aktivnošću.

Adaptivni mehanizam zatim prevodi identifikovanu potrebu u konkretnu putanju za dalje učenje. Objekti iz početnog skupa povezuju se sa ontološkim relacijama redosleda i preduslova i sa odnosima između osnovnog i naprednog sadržaja. Neophodni preduslovi uključuju se pre sadržaja koji od njih zavisi, a osnovne varijante koncepata pre njihovih naprednih varijanti. Rezultat zato nije samo lista „slabih tema“, već uređena putanja zasnovana na formalnoj strukturi nastavnog sadržaja.

Ponašajni tip služi kao kontekst za predstavljanje i obrazloženje podrške, ali ne određuje procenu ovladanosti niti izbor i redosled preporučenog sadržaja. Na taj način u arhitekturi se zadržava jasna razlika između procene stanja, ponašajnog konteksta i adaptivne odluke.

Objašnjivost preporuke zasnovana je pre svega na sledljivosti odluke. Za pokušani sadržaj može se utvrditi dokaz, procena ovladanosti, kompetencija, nivo dubine i prag koji je doveo do njegovog uključivanja. Za nepokušani obavezni N1 sadržaj razlog uključivanja predstavlja njegov status obaveznog jezgra i odsustvo pokušaja. Dodatno je moguće utvrditi da li je određeni objekat uključen kao neposredno identifikovana potreba, preduslov ili osnovna varijanta drugog objekta.

Formiranje adaptivne odluke odvojeno je od njenog završnog jezičkog predstavljanja. Veliki jezički model u implementiranom rešenju nema ulogu u određivanju slabih tačaka, izboru objekata, postavljanju pragova ili uređivanju putanje. Njegova uloga ograničena je na jezičko formulisanje već strukturiranog obrazloženja. Generisani izlaz prolazi kroz definisane provere prihvatljivosti, a kada uslovi nisu ispunjeni koristi se deterministički formulisana verzija istog strukturiranog sadržaja. Ovakva kontrola povećava sledljivost procesa, ali se ne

tumači kao nezavisna empirijska validacija činjenične vernosti, potpunosti ili odsustva jezičke pristrasnosti LLM izlaza.

Povratne informacije 86 studenata pokazale su da su kontrolna tabla, preporučeni objekti učenja i objašnjenja uglavnom ocenjeni kao razumljivi, relevantni i korisni. Ovi rezultati pružaju početni dokaz percipirane prihvatljivosti i korisnosti adaptivnog sloja iz perspektive studenata. Oni, međutim, ne predstavljaju dokaz da je korišćenje preporuka uzročno poboljšalo znanje, ovladanost kompetencijama, akademski uspeh, angažovanje ili realizaciju aktivnosti. Istraživanje nije uključilo kontrolisani pre-test/post-test dizajn niti poređenje sa grupom koja bi koristila standardnu linearnu putanju.

Na osnovu razvijenih modela, njihove implementacije i sprovedenih empirijskih analiza, na istraživačka pitanja postavljena u odeljku 1.2 može se odgovoriti na sledeći način:

- IP1: Na koji način metode analitike učenja i algoritmi mašinskog učenja mogu podržati razvoj modela studenta koji omogućava praćenje napretka i procenu nivoa ovladanosti nastavnim sadržajem u odnosu na određene ciljeve učenja, ishode učenja ili kompetencije?

  Rezultati istraživanja pokazuju da metode analitike učenja i mašinskog učenja mogu imati različite i komplementarne uloge u modelu studenta, ali da njihova korisnost za adaptivno učenje zavisi od granularnosti i semantičkog konteksta u kojem se njihovi izlazi tumače. Prediktivni modeli omogućili su izdvajanje atributa povezanih sa akademskim ishodom, dok je klasterovanje omogućilo identifikovanje obrazaca studentskog angažovanja. Ove informacije korisne su za razumevanje studenata, ali same po sebi nisu dovoljne za određivanje konkretnog sadržaja kojem je pojedinačnom studentu potrebna podrška. U konačnom modelu sekvencijalna procena ovladanosti primenom BKT-a povezana je sa kompetencijom i nivoom dubine, dok se ostvarenost aktivnosti i ponašajni obrazac vode kao odvojene dimenzije. Time se napredak studenta može pratiti kroz više komplementarnih pokazatelja, bez njihovog svođenja na jednu ocenu ili kategoriju. Dobijena ovladanost predstavlja modelom izvedenu procenu na osnovu raspoloživih dokaza, a ne neposredno merenje stvarnog znanja, jer u istraživanju nije korišćen nezavisni spoljašnji kriterijum za takvu validaciju. Sprovedene analize osetljivosti, unakrsna validacija i analize robustnosti podržavaju unutrašnju stabilnost ovih izlaza u analiziranim kohortama, ali ne predstavljaju potvrdu njihove univerzalne generalizacije.

- IP2: Na koji način se podaci o aktivnostima, rezultatima i proverama znanja studenata mogu povezati sa strukturom nastavnog sadržaja radi formiranja personalizovanih preporuka za dalje učenje?

  Povezivanje se ostvaruje semantičkim mapiranjem aktivnosti provere i njihovih rezultata na odgovarajuće objekte učenja, ishode učenja, kompetencije i nivoe dubine u ontološkom modelu. Na taj način rezultat testa, zadatka, projekta ili druge aktivnosti ne ostaje izolovan brojčani podatak, već postaje strukturirani dokaz sa eksplicitno određenim značenjem u modelu nastavnog sadržaja. Sekvence takvih dokaza koriste se za formiranje procene ovladanosti, dok se informacije na nivou konkretnog objekta učenja zadržavaju radi lokalne dijagnostike. Adaptivni mehanizam razlikuje pokušani sadržaj za koji raspoloživi dokazi ukazuju na potrebu za dodatnom podrškom od nepokušavanog obaveznog sadržaja nivoa N1, za koji ne postoji procena ovladanosti. Tako identifikovane potrebe povezuju se sa ontološkim relacijama radi izbora i uređivanja konkretnih objekata učenja. Time se uspostavlja sledljiva veza od aktivnosti i njenog rezultata do preporučenog sadržaja, prikazana na Slici 2. Kvalitet ovog postupka zavisi od ispravnosti stručnog mapiranja aktivnosti na nastavne elemente; saglasnost više nezavisnih eksperata pri takvom mapiranju nije proveravana i predstavlja ograničenje i pravac buduće validacije.
- IP3: Na koji način se ontološki model nastavnog sadržaja može automatski vizualizovati i koristiti za dinamičko kreiranje personalizovanog prostora za učenje u sistemu za e-učenje?

  Razvijeni pristup pokazuje da se formalna struktura ontologije može automatski transformisati u multidimenzionalne konceptualne mape koje studentu omogućavaju postepenu vizualizaciju i nelinearnu navigaciju kroz povezane koncepte i objekte učenja. Ontološki atributi i relacije predstavljaju osnovu za generisanje različitih pogleda na isti prostor nastavnog sadržaja, dok OBSLO i MCM omogućavaju povezivanje vizuelnog prikaza sa konkretnim nastavnim resursima. U konačnom adaptivnom modelu funkcija ontologije dodatno je proširena: personalizovani prostor nije određen samo izborom i navigacijom studenta, već i izlazima individualnog modela studenta. Identifikovane potrebe za podrškom povezuju se sa relacijama redosleda i preduslova, kao i odnosima između osnovnog i naprednog sadržaja, tako da se formira individualno uređena putanja. Poređenje sa redosledom zasnovanim samo na procenjenoj ovladanosti pokazalo je da ontološka struktura

čuva eksplicitne semantičke zavisnosti koje jednostavno rangiranje može da zanemari. Ovaj rezultat potvrđuje strukturnu ulogu ontologije u formiranju putanje, ali se ne tumači kao dokaz da takva putanja uzročno dovodi do boljih ishoda učenja.

- IP4: Na koji način modularna arhitektura razvijenog modela studenta i modela nastavnog sadržaja smanjuje njihovu zavisnost od konkretnog sistema za e-učenje i omogućava jednostavniju integraciju u različite adaptivne i personalizovane obrazovne sisteme i kontekste, i koje prednosti ta integracija donosi?

  Razvijeni modeli podržavaju integraciju prvenstveno kroz modularnu arhitekturu, razdvajanje funkcionalnih odgovornosti i razmenu strukturiranih podataka preko servisnih interfejsa. Model nastavnog sadržaja obezbeđuje semantičku strukturu onoga što se uči, model studenta obrađuje individualne dokaze i formira interpretabilne izlaze, dok adaptivni mehanizam te izlaze povezuje sa ontološkim relacijama radi izbora i uređivanja preporučenog sadržaja. Ovakvo razdvajanje smanjuje neposrednu zavisnost analitičke i adaptivne logike od unutrašnje implementacije jednog konkretnog LMS-a i omogućava da se razvijene komponente koriste kao dodatni sloj nad postojećom obrazovnom infrastrukturom. Prednosti takve integracije ogledaju se u modularnosti, mogućnosti nezavisnog razvoja komponenti, zadržavanju sledljivosti između izvornog podatka i preporuke i mogućnosti korišćenja iste strukturirane adaptivne odluke u različitim načinima prikaza ili isporuke sadržaja. Međutim, odgovor na IP4 ostaje ograničen na arhitekturnu izvodljivost i demonstrirano modularno povezivanje. Produkcijska integracija konačnog modela sa više nezavisnih LMS platformi, interoperabilnost sa različitim standardima i skalabilnost nisu empirijski proverene, pa se na osnovu sprovedenog istraživanja ne može zaključiti da je integracija univerzalno jednostavna u svim tehnološkim okruženjima.

Posmatrani zajedno, rezultati pokazuju da razvijena arhitektura omogućava operacionalizaciju kompletnog lanca prikazanog na Slici 2, od strukturiranog nastavnog sadržaja i verifikovanog dokaza do sledljivog objašnjenja preporuke.

Centralni doprinos disertacije zato nije razvoj novog algoritma mašinskog učenja, već integracija kompetencijski i ontološki strukturiranog nastavnog sadržaja, interpretabilnog višeslojnog modela studenta i adaptivnog mehanizma u jedinstven, sledljiv proces personalizovanog e-učenja. Ontološki model određuje šta se uči i kako su sadržaji međusobno povezani; VERIFY semantički povezuje objekte učenja sa dokazima iz aktivnosti; model studenta formira procenu ovladanosti na osnovu

raspoloživih dokaza, pokazuje koliki je deo poena predviđenih za aktivnosti student ostvario i opisuje njegov obrazac angažovanja; adaptivni mehanizam utvrđenu potrebu prevodi u uređenu putanju; a objašnjivi sloj studentu i nastavniku prikazuje podatke i pravila na kojima je ta odluka zasnovana.

Empirijski nalazi potvrđuju izvodljivost i interpretabilnost ovog integrisanog postupka u analiziranim obrazovnim kontekstima. Oni ne potvrđuju njegovu univerzalnu prenosivost, nastavnu efikasnost u drugim domenima niti produkcijsku interoperabilnost i skalabilnost na institucionalnom nivou. Granice ovih zaključaka detaljnije su razmotrene u odeljku 8.3, dok se ispunjenost pojedinačnih ciljeva i hipoteza istraživanja posebno analizira u odeljcima 8.5 i 8.6.

8.2. Prednosti razvijenog pristupa

Osnovna prednost razvijenog pristupa jeste povezivanje modela nastavnog sadržaja, modela studenta i adaptivnog sloja u jedinstven i sledljiv proces. Umesto da se podaci o studentu, struktura nastavnog sadržaja i logika preporučivanja razvijaju kao međusobno nezavisne komponente, oni se povezuju preko objekata učenja, kompetencija, nivoa dubine i dokaza nastalih u aktivnostima provere. Time se omogućava neposredno prevođenje podataka o učenju u interpretabilnu procenu stanja, a zatim u konkretnu preporuku za dalje učenje.

Ključne prednosti razvijenog pristupa su:

- **Fleksibilna i proširiva organizacija nastavnog sadržaja.** Ontološki model organizuje sadržaj kroz hijerarhiju koncepata i eksplicitne relacije između koncepata, objekata učenja i njihovih resursa. Novi koncepti, objekti, atributi i relacije mogu se dodavati bez promene osnovne strukture modela. Ova osobina omogućila je da se prvobitni model proširi ishodima učenja, kompetencijama, komponentama znanja i veštine, nivoima dubine i elementima za verifikaciju naučenog. Time se pokazuje da ontološki model može da se razvija zajedno sa promenama nastavnog i kompetencijskog okvira, bez potrebe za napuštanjem njegove osnovne strukture.
- **Semantičko povezivanje nastavnog sadržaja sa kompetencijama i dokazima iz aktivnosti provere.** Objekti učenja nisu predstavljeni samo kao digitalni resursi, već su povezani sa ishodima učenja, kompetencijama, komponentama znanja i veštine i nivoima dubine. Element VERIFY iz kompetencijskog okvira dodatno je semantički operacionalizovan tako da povezuje objekat učenja sa dokazom nastalim u odgovarajućoj aktivnosti provere, dok se sama aktivnost, pokušaji i ostvareni

rezultati vode u sistemu za upravljanje obrazovanjem. Rezultat testa, zadatka, projekta ili druge aktivnosti zato može da se tumači kao strukturirani dokaz povezan sa konkretnim nastavnim sadržajem i kompetencijom, a ne samo kao broj poena koji doprinosi konačnoj oceni.

- **Podrška nelinearnoj organizaciji i navigaciji kroz nastavni sadržaj.** Multidimenzionalne konceptualne mape omogućavaju studentu da sagleda odnose između oblasti znanja, tema, podtema i objekata učenja i da razlikuje osnovne i napredne sadržaje. Za razliku od isključivo linearnog prikaza lekcija, ovakav pristup omogućava istraživanje međusobno povezanih sadržaja i formiranje različitih putanja kroz isti domen. Evaluacija ontološki organizovanog prostora pokazala je da studenti mogu da koriste takvu strukturu za pronalaženje sadržaja i rešavanje nastavnih zadataka, uz rezultate koji su u analiziranim scenarijima bili povoljniji od linearnog okruženja sa istim nastavnim materijalima.
- **Kontinuirano i fino granularno modelovanje trenutnog stanja studenta.** Konačni model ne koristi samo završnu ocenu ili zbirnu vrednost postignuća, već obrađuje hronološke nizove dokaza i prati promenu procenjene ovladanosti tokom vremena. Sekvencijalna procena formira se na nivou kombinacije predmet-kompetencija predmeta-nivo dubine, dok se veze sa pojedinačnim objektima učenja zadržavaju radi lokalne dijagnostike. Time se šira procena napretka može povezati sa konkretnim sadržajem na kojem je nastao dokaz.
- **Razlikovanje nedovoljne ovladanosti od odsustva dokaza.** Model i adaptivni sloj ne izjednačavaju objekat koji je student pokušao i nedovoljno savladao sa objektom koji nije pokušao. Za pokušani sadržaj moguće je formirati procenu ovladanosti i uporediti je sa pragom odgovarajućeg nivoa dubine. Za nepokušani obavezni objekat nivoa N1 takva procena se ne formira, već se objekat označava kao nedostajući sadržaj obaveznog jezgra visokog prioriteta. Ovakva razlika je posebno značajna kod studenata sa manjim obimom aktivnosti, jer sprečava da odsustvo zapažanja bude pogrešno predstavljeno kao ovladanost jednaka nuli, ali istovremeno sprečava da nepokušani obavezni sadržaj ostane izvan adaptivne podrške.
- **Razdvajanje ovladanosti od ostvarenosti aktivnosti.** Dvoslojni prikaz razlikuje koliko je student uspešno ovladao sadržajem sa kojim je radio od toga koliki je deo poena predviđenih za aktivnosti određenog nivoa dubine ostvario. Time je moguće

razlikovati studenta koji postiže dobre rezultate na manjem broju pokušavanih aktivnosti od studenta koji je realizovao veliki obim rada, ali nije pokazao dovoljan nivo ovladanosti. Ova razlika ostala bi skrivena kada bi se stanje studenta predstavljalo samo jednom agregiranom ocenom.

- **Razdvajanje ponašajnog obrasca od znanja i postignuća.** Ponašajni tipovi formiraju se na osnovu obima aktivnosti, broja aktivnih dana i udela ranijih pokušaja, bez korišćenja procene ovladanosti i ostvarenosti nivoa kao ulaznih atributa. Tip zato opisuje način na koji student radi, a ne njegovu sposobnost ili nivo znanja. Ovo omogućava da dva studenta istog ponašajnog tipa dobiju različite preporuke kada imaju različite profile ovladanosti i različite potrebe za podrškom.
- **Proverena stabilnost ključnih projektnih odluka unutar analiziranih kohorti.** Ključne odluke modela proverene su na više nivoa: osetljivost na pragove i ponderisanje dokaza, unakrsna validacija procena ovladanosti, poređenje kontinuirane i binarne BKT formulacije, stabilnost individualnih prioriteta preporuke i robustnost ponašajnog klasterovanja (odeljci 7.2.3 i 7.3.1). Ove provere ne predstavljaju dokaz spoljašnje generalizacije, ali smanjuju verovatnoću da su glavni nalazi unutar analiziranih kohorti posledica jednog proizvoljnog izbora praga, pondera, uzorka ili skupa atributa.
- **Formiranje uređene putanje, a ne samo liste sadržaja sa niskim procenama.** Početni skup sadržaja za podršku povezuje se sa eksplicitnim ontološkim relacijama, pa se obavezni preduslovi postavljaju pre objekata koji od njih zavise, a osnovne varijante sadržaja pre odgovarajućih naprednih varijanti. Preporuka tako predstavlja semantički uređenu putanju kroz nastavni sadržaj, koja čuva relacije koje bi jednostavno rangiranje prema procenjenoj ovladanosti moglo da naruši (odeljak 7.3.1). Ova prednost odnosi se na strukturni kvalitet putanje, a ne na dokazan uticaj na ishode učenja.
- **Sledljivost od izvornog dokaza ili statusa sadržaja do preporučene putanje.** Za svaki preporučeni objekat moguće je utvrditi zbog čega je uključen. Kada je sadržaj pokušavan, mogu se pratiti aktivnost i rezultat, pripadajuća kompetencija i nivo dubine, procena ovladanosti i odgovarajući prag. Kada je objekat nepokušani obavezni sadržaj nivoa N1, razlog uključivanja zasniva se na njegovom statusu obaveznog jezgra i odsustvu pokušaja, bez izmišljanja procene ovladanosti. Pored toga, može se utvrditi da li je objekat uključen kao neposredna potreba za podrškom,

preduslov ili osnovna varijanta drugog sadržaja. Ovakva sledljivost čini adaptivnu odluku proverljivom za studenta i nastavnika.

- **Razdvajanje adaptivne odluke od njenog jezičkog objašnjenja.** Izbor i redosled objekata određuju model studenta, pravila adaptivnog mehanizma i ontološke relacije. Veliki jezički model ne određuje slabe tačke, ne postavlja pragove, ne bira nastavne objekte i ne menja njihov redosled, već se koristi samo za završno jezičko formulisanje strukturiranog obrazloženja. Dodatne automatske provere i deterministička rezervna varijanta omogućavaju da preporuka ostane dostupna i kada generisani tekst ne zadovolji definisane uslove prihvatljivosti. Time generativni sloj ne postaje izvor obrazovne odluke, već način njenog predstavljanja.
- **Modularna softverska arhitektura i razdvojene odgovornosti komponenti.** Institucionalni sistem za učenje, sistem za upravljanje obrazovanjem i OBSLO razmenjuju strukturirane podatke preko servisnih interfejsa, dok model nastavnog sadržaja, model studenta, adaptivni mehanizam i komponenta za objašnjive preporuke imaju jasno razdvojene odgovornosti. Ovakva labava povezanost olakšava nezavisnu izmenu ili zamenu pojedinačnih komponenti i predstavlja osnovu za buduće povezivanje sa drugim sistemima. U skladu sa određenjem jednostavnije integracije iz odeljka 1.1, ova prednost odnosi se na modularnost arhitekture i njenu razdvojenost od konkretnog LMS-a, a ne na interoperabilnost sa drugim LMS platformama, koja nije proveravana.
- **Mogućnost prikaza složenih analitičkih rezultata u obliku razumljivom studentu.** Kontrolna tabla objedinjuje profil ovladanosti, ostvarenost nivoa, ponašajni kontekst, različite vrste identifikovanih potreba i uređenu putanju za dalje učenje. Povratne informacije 86 studenata pokazuju pozitivnu percepciju razumljivosti, relevantnosti i korisnosti prikazanih preporuka i objašnjenja. Ovaj rezultat predstavlja prednost sa aspekta prihvatljivosti pristupa i mogućnosti njegovog predstavljanja krajnjem korisniku, ali ne predstavlja dokaz da je korišćenje kontrolne table uzročno poboljšalo ishode učenja.

Navedene prednosti proizlaze prvenstveno iz integracije komponenti i očuvanja semantičke veze između njih. Ontološki model bez dinamičkog modela studenta omogućavao bi organizovanje i pronalaženje sadržaja, ali ne bi određivao trenutne potrebe pojedinačnog studenta. Model studenta bez formalnog modela sadržaja mogao bi da pokaže gde postoji problem ili nedostatak dokaza, ali ne bi sam obezbedio semantičku osnovu za određivanje

konkretnog narednog nastavnog sadržaja i njegovog položaja u putanji. Adaptivni mehanizam povezuje ta dva izvora i prevodi identifikovanu potrebu u konkretnu nastavnu intervenciju.

Razvijeni pristup zato omogućava prelazak sa opštih pokazatelja uspeha i angažovanja na ciljanu, kompetencijski i sadržajno utemeljenu podršku pojedinačnom studentu. Pri tome ostaje moguće proveriti kako je procena nastala, zašto je određeni objekat uključen u preporuku, koja ontološka relacija određuje njegov položaj i koja komponenta sistema je odgovorna za svaki korak. Prednosti razvijenog pristupa zbog toga treba posmatrati zajedno sa granicama sprovedene evaluacije, koje su prikazane u narednom odeljku.

8.3. Nedostaci i ograničenja istraživanja

Ograničenja sprovedenog istraživanja odnose se na razvoj i održavanje modela nastavnog sadržaja, obim i strukturu empirijskih podataka, način mapiranja dokaza, pojedine projektne odluke u modelu studenta, ponašajno klasterovanje, adaptivni mehanizam, generisanje objašnjenja i opseg sprovedene evaluacije. Dodatne analize osetljivosti i robustnosti uvedene u konačnoj fazi istraživanja smanjile su neizvesnost u vezi sa pojedinim projektnim odlukama, ali ne uklanjaju potrebu za spoljnom validacijom i proverom obrazovnih efekata razvijenog pristupa.

Izrada i održavanje ontološkog modela. Kreiranje ontologije zahteva detaljnu analizu nastavnog sadržaja, određivanje odgovarajuće granularnosti i definisanje hijerarhijskih i semantičkih odnosa između koncepata, objekata učenja, kompetencija, ishoda učenja i dokaza iz aktivnosti provere. Ovaj proces zahteva angažovanje stručnjaka iz predmetnog domena i nastavnika i postaje zahtevniji sa povećanjem broja predmeta i objekata učenja. Promene nastavnih planova, kompetencijskih okvira i sadržaja takođe zahtevaju održavanje odgovarajućih ontoloških veza. Zbog toga organizacioni i vremenski troškovi razvoja i održavanja predstavljaju važno ograničenje za primenu pristupa u velikom broju predmeta.

Reproduktivnost ekspertski definisanih ontoloških relacija. Iako su u predloženom pristupu eksplicitno definisani semantika i kriterijumi za uspostavljanje obaveznih i opcionih OR relacija i BA relacija, njihovo definisanje i dalje zahteva stručnu semantičku procenu nastavnika ili projektanta predmeta. U okviru sprovedene provere koncepta nije izvršeno nezavisno anotiranje iste ontološke strukture od strane više nastavnika ili stručnjaka iz predmetnog domena. Zbog toga nije empirijski provereno u kojoj meri bi različiti projektanti, primenjujući ista pravila, izabrali isti tip relacije i isti smer veze između odgovarajućih objekata učenja ili koncepata. Ovo ograničenje ne utiče na determinističku primenu jednom definisane

ontologije u adaptivnom postupku, ali ograničava zaključke o reproduktivnosti procesa njenog semantičkog projektovanja između različitih autora nastavnog sadržaja.

Različit nivo evaluacije osnovnog i kompetencijski proširenog modela sadržaja. Osnovni ontološki model i njegova vizualizacija pomoću multidimenzionalnih konceptualnih mapa neposredno su evaluirani kroz rad studenata, rešavanje zadataka, analizu putanja i korisničke povratne informacije. Kompetencijski prošireni model, koji uključuje ishode učenja, kompetencije, komponente znanja i veštine, nivoe dubine i VERIFY, evaluiran je prvenstveno kroz svoju funkcionalnu ulogu u povezivanju nastavnog sadržaja sa dokazima, modelom studenta i adaptivnim preporukama. Nije sprovedena zasebna korisnička studija kojom bi se ispitalo u kojoj meri studenti, nastavnici i autori nastavnog sadržaja razumeju i lako koriste celokupnu kompetencijski proširenu strukturu.

Ograničenja uporedne evaluacije OBSLO i LAMS okruženja. Prva iteracija evaluacije osnovnog ontološkog modela i MCM vizuelizacije uključivala je poređenje rezultata studenata koji su koristili OBSLO sa rezultatima studenata istog predmeta koji su u prethodnoj školskoj godini koristili LAMS. Iako su obe grupe koristile isti nastavni sadržaj i analizirani zadaci odnosili su se na iste ishode učenja i uporediv nivo težine, zadaci su bili prilagođeni konkretnom nastavnom okruženju i nisu bili potpuno identični. Pored toga, podaci su prikupljeni u različitim realizacijama predmeta, sa različitim grupama studenata i različitim nastavnicima. Zbog toga razlike u stopama uspešnosti između OBSLO i LAMS grupa ne mogu biti pripisane isključivo načinu organizacije i vizuelizacije nastavnog sadržaja u OBSLO sistemu. Rezultati ove evaluacije predstavljaju indikativan deskriptivni nalaz o primeni ontološki organizovanog prostora za učenje u realnom nastavnom kontekstu, ali ne predstavljaju kontrolisani dokaz uzročnog efekta OBSLO-a na postignuće studenata.

Ograničen obim i kontekst konačnog empirijskog skupa. Konačna faza modela studenta ispitana je na dva dodiplomska predmeta iz oblasti računarstva u okviru jedne institucije i jedne školske godine. SE201 obuhvata 37, a CS202 74 studenta. Dva predmeta razlikuju se prema oblasti i strukturi aktivnosti i zato omogućavaju proveru da ista arhitektura može da prikaže različite obrasce u dva nastavna konteksta. Ipak, takav uzorak nije dovoljan za zaključak da će iste procene, parametri ili ponašajni tipovi biti reprodukovani u drugim institucijama, disciplinama, nivoima studija ili generacijama. Rezultate treće faze zato treba tumačiti kao proveru koncepta u stvarnim obrazovnim uslovima, a ne kao statističku generalizaciju na širu populaciju.

Ograničena količina dokaza na naprednom nivou N3. Empirijska analiza na nivou kohorte bila je prvenstveno usmerena na N1 i N2, jer za N3 nije postojao dovoljan broj zapažanja za pouzdano poređenje. U predmetu SE201 studenti nisu generisali N3 dokaze, dok je u CS202 takve dokaze kroz odgovarajuće aktivnosti generisalo samo šest studenata. Zbog toga rezultati ne omogućavaju jednako snažne zaključke o ponašanju modela na naprednom nivou kao za N1 i N2.

Zavisnost od kvaliteta mapiranja aktivnosti na nastavne sadržaje. Aktivnosti provere koje obuhvataju više objekata učenja povezuju se sa relevantnim objektima, pri čemu nastavnik određuje i stepen relevantnosti pojedinačne veze. Ovakav postupak omogućava da rezultati testova, zadataka i projekata predstavljaju dokaze za više elemenata nastavnog sadržaja, ali istovremeno uvodi stručnu procenu nastavnika kao jedan od izvora varijabilnosti. Analiza osetljivosti pokazala je da su agregirane procene ovladanosti u posmatranim kohortama malo osetljive na ispitane alternative ponderisanja, ali u istraživanju nije proverena saglasnost više nezavisnih nastavnika pri samom izboru veza i dodeljivanju njihove relevantnosti. Različito semantičko mapiranje može da promeni strukturu ulaznih sekvenci i zato ostaje važan izvor moguće varijabilnosti. Pored toga, aktivnost koja obuhvata više objekata iste kompetencije doprinosi njenom sekvencijalnom nizu sa više zapažanja, pa granularnost mapiranja utiče i na relativni uticaj pojedinih aktivnosti na procenu ovladanosti i na meru obima aktivnosti. Pošto je zahtevnost aktivnosti u modelu određena nivoom dubine, nedosledno određen nivo dovodi do toga da se kao uporedivi tretiraju dokazi iz aktivnosti različite zahtevnosti.

Granice provere BKT modela. Pragovi za N1 i N2 provereni su kroz devet kombinacija, ispitane su tri varijante ponderisanja dokaza, a stabilnost procena proverena je petostrukom unakrsnom validacijom. Rezultati pokazuju stabilnost osnovnih obrazaca pri tim promenama i veoma male razlike procena u unakrsnoj validaciji. Ipak, unakrsna validacija je sprovedena unutar istih kohorti: parametri su procenjivani na delu studenata, a primenjivani na izdvojenom delu iste populacije. Ona zato predstavlja proveru unutrašnje stabilnosti, a ne nezavisnu validaciju modela na novoj generaciji ili drugoj instituciji.

Pored toga, analizom osetljivosti nisu iscrpljene sve moguće projektne odluke. Granularnost jedinice modelovanja, količina dostupnih dokaza po kombinaciji predmet-kompetencija predmeta-nivo dubine, način regularizacije početne verovatnoće i izbor hronoloških podataka koji ulaze u model mogu uticati na procene u drugim nastavnim kontekstima. Korišćene vrednosti i pravila zato predstavljaju dokumentovanu implementaciju razvijenu za posmatrane podatke, a ne univerzalno optimalnu konfiguraciju BKT modela.

Ograničena kriterijumska validacija procene ovladanosti. Sprovedene analize omogućavaju procenu unutrašnje stabilnosti modela i njegove sposobnosti predviđanja narednog zapažanja, ali u istraživanju nije korišćena posebna nezavisna provera znanja ili veština koja bi služila kao spoljašnji kriterijum za validaciju procenjene ovladanosti. Zbog toga se BKT procena tumači kao modelom izvedena procena trenutnog stanja na osnovu raspoloživih dokaza, a ne kao neposredno izmerena veličina stvarnog znanja studenta. Isto važi i za lokalni dijagnostički indikator na nivou objekta učenja: on pokazuje stanje raspoloživih dokaza za konkretan sadržaj i koristi se za usmeravanje adaptivne podrške, ali sam po sebi ne predstavlja nezavisnu potvrdu da student tim sadržajem objektivno nije ovladao.

Kontinuirana BKT formulacija nije pokazala uniformnu prediktivnu prednost. Poređenje predviđanja narednog zapažanja pokazalo je da je kontinuirani BKT nešto uspešniji od binarne formulacije u SE201, dok je binarna formulacija ostvarila manji logaritamski gubitak u CS202. Kontinuirana formulacija je u disertaciji zadržana prvenstveno zato što čuva informaciju o delimičnom uspehu i time omogućava granularnije predstavljanje obrazovnog dokaza, a ne zato što je empirijski potvrđena kao prediktivno superiorna u svim kontekstima. Ovo ograničava zaključke koji se mogu izvesti o njenoj algoritamskoj prednosti.

Ograničenja ponašajnog klasterovanja. Dobijeni ponašajni tipovi zavise od operativnog izbora atributa, karakteristika kohorte i broja klastera. Koeficijenti siluete od 0,39 za izabrano troklastersko rešenje SE201 i 0,41 za dvoklastersko rešenje CS202 ukazuju na umerenu, a ne izrazito oštru razdvojenost grupa. Stabilnost je dodatno proverena na 200 poduzoraka i prosečan Jaccardov koeficijent iznosio je 0,90 za oba predmeta, ali su pojedini poduzorci davali znatno nižu saglasnost. Posebno treba imati u vidu da minimalistički tip u SE201 obuhvata samo šest studenata. Tipove zato ne treba tumačiti kao prirodne, trajne ili univerzalne kategorije studenata, već kao empirijski izvedene obrasce angažovanja u konkretnim kohortama.

Poređenje sa DBSCAN i HDBSCAN metodama dodatno je pokazalo da alternativni algoritmi nisu dali stabilniju strukturu pogodnu za potrebe ovog adaptivnog sistema. To ipak ne dokazuje opštu superiornost k-means algoritma. Njegov izbor zasniva se i na konkretnom funkcionalnom zahtevu da svaki student dobije ponašajni tip, dok su metode zasnovane na gustini značajan deo studenata ostavljale bez dodeljenog klastera. Analiza izostavljanja atributa pokazala je i da se struktura tipova značajno menja kada se uklone pojedini atributi, što dodatno potvrđuje da ponašajni tip zavisi od načina na koji je ponašanje operacionalizovano.

Zavisnost ponašajnih tipova od izbora ulaznog prostora dodatno je ispitana uključivanjem pokazatelja postignuća koji se u konačnom modelu vode kao odvojene dimenzije. Kada su ponašajnim atributima istovremeno dodate ostvarenosti nivoa N1 i N2, saglasnost sa osnovnim ponašajnim rešenjem smanjena je na ARI = 0,408 u SE201 i ARI = 0,014 u CS202. Dodavanje prosečne ovladanosti kompetencijama takođe je promenilo dodelu studenata klasterima, sa ARI = 0,515 u SE201 i ARI = 0,379 u CS202. Istovremeno, nijedna od analiziranih varijanti sa dodatim pokazateljima postignuća nije ostvarila viši koeficijent siluete od osnovnog rešenja zasnovanog samo na ponašajnim atributima. Ovi rezultati podržavaju projektnu odluku da se ponašajni tip definiše nezavisno od ovladanosti i ostvarenosti, kako bi predstavljao obrazac angažovanja, a ne prikrivenu kategoriju akademskog uspeha. Međutim, oni istovremeno pokazuju da dobijena struktura klastera nije invarijantna na izbor atributa: uključivanje drugačije reprezentacije studenta može materijalno promeniti pripadnost tipovima.

Ponašajni tip predstavlja agregirani obrazac za posmatrani period. Konačna implementacija formira ponašajni tip na osnovu aktivnosti prikupljenih tokom posmatranog nastavnog perioda. Model zato ne predstavlja eksplicitno prelaze studenta između ponašajnih stanja tokom semestra. Student može, na primer, biti veoma aktivan u jednom delu semestra i znatno smanjiti aktivnost u drugom, a konačna oznaka sažima takve promene u jedan obrazac. Za intervencije koje treba da reaguju na trenutnu promenu angažovanja bilo bi potrebno vremenski zavisno ponašajno modelovanje.

Granice adaptivnog mehanizma. Nepokušani obavezni objekti nivoa N1 uključuju se u preporuku kao sadržaji visokog prioriteta, odvojeno od pokušanih objekata sa procenom ispod praga. Otvoreno ostaje pitanje optimalne prioritizacije i obima konačne putanje.

Adaptivni mehanizam koristi definisana pravila, pragove, status obaveznosti i ontološke relacije kako bi izabrao i uredio objekte, ali u ovom istraživanju nisu sistematski poređene različite strategije za određivanje koliko objekata istovremeno treba prikazati, kako balansirati ponavljanje slabije savladanog sadržaja i novi obavezni sadržaj i kako prilagoditi dužinu putanje raspoloživom vremenu studenta. Takođe, nepokušani sadržaji nivoa N2 i N3 s razlogom se ne tretiraju isto kao nepokušano obavezno jezgro nivoa N1. N2 predstavlja dodatni i produbljeni srednji nivo, dok N3 predstavlja opcioni napredni nivo, pa izbor i prioritizacija nepokušanog sadržaja izvan obaveznog N1 jezgra zahtevaju dodatno modelovanje ciljeva, strukture predmeta i izbora studenta.

Ograničenja evaluacije objašnjenja generisanih velikim jezičkim modelom. U implementaciji je generativni sloj namerno ograničen na jezičko oblikovanje već strukturiranih rezultata i uvedene su automatske provere koje sprečavaju da model menja redosled preporuke, uvodi numeričke vrednosti ili proizvede odgovor bez zahtevanih celina. Ovi mehanizmi smanjuju određene rizike, ali ne predstavljaju nezavisnu empirijsku proveru činjenične vernosti, konzistentnosti, potpunosti, tona ili mogućih jezičkih pristrasnosti generisanog teksta. Potrebna je zasebna evaluacija u kojoj bi eksperti i korisnici sistematski procenjivali kvalitet generisanih objašnjenja u odnosu na determinističku osnovu iz koje su nastala.

Ograničenje korisničke evaluacije adaptivnih preporuka. Evaluacija kontrolne table sa 86 studenata pokazuje da su studenti preporuke i objašnjenja uglavnom ocenili kao razumljive, relevantne i korisne. Međutim, anketa meri **percepciju korisnika**, a ne promenu znanja ili kompetencija. Nije sprovedeno randomizovano ili kvazieksperimentalno poređenje grupe koja koristi adaptivne preporuke sa grupom koja prati standardnu putanju, niti pre-test/post-test merenje kojim bi se utvrdio obrazovni efekat intervencije. Zato se rezultati ankete ne mogu koristiti kao dokaz da je razvijeni sistem uzročno povećao akademski uspeh, ovladanost, angažovanje ili realizaciju aktivnosti. Dodatno, zbog anonimnog načina prikupljanja podataka odgovori iz upitnika nisu mogli biti povezani sa ponašajnim tipovima, pa nije ispitano da li se percepcija preporuka razlikuje između tipova. Finalna evaluacija podržava izvodljivost i interpretabilnost integrisanog postupka, ali ne njegovu nastavnu efikasnost.

Ograničenja produkcijske integracije, interoperabilnosti i skalabilnosti. Arhitektura je projektovana modularno, sa razdvojenim komponentama i servisnim interfejsima, što u smislu određenja iz odeljka 1.1 smanjuje njenu zavisnost od konkretnog LMS-a i omogućava konceptualno povezivanje sa različitim sistemima za isporuku sadržaja. Međutim, konačni model studenta i Adaptive Engine nisu u okviru ovog istraživanja produkcijski integrisani sa više različitih LMS platformi tako da automatski menjaju individualnu nastavnu sekvencu u realnom vremenu. LAMS je korišćen kao primer okruženja u kojem bi uređena putanja mogla da se izvršava, ali takva produkcijska integracija konačnog modela nije empirijski evaluirana.

Takođe nisu sistematski provereni interoperabilnost sa široko korišćenim platformama i različitim standardima obrazovnih metapodataka, niti performanse arhitekture pri velikom broju istovremenih korisnika, predmeta, objekata učenja i procena. Zbog toga modularnost predstavlja projektovano svojstvo arhitekture, dok univerzalna interoperabilnost i skalabilnost ostaju zahtevi koje je potrebno empirijski potvrditi.

Posmatrana sa stanovišta validnosti istraživanja, prethodno navedena ograničenja mogu se objediniti u nekoliko međusobno povezanih grupa:

- **Konstruktivna validnost.** Ključni konstrukti operacionalizovani su preko eksplicitno definisanih pokazatelja: procena ovladanosti izvodi se iz sekvenci dokaza povezanih sa kompetencijama i nivoima dubine, ostvarenost nivoa iz poena ostvarenih na predviđenim aktivnostima, a ponašajni tip iz pokazatelja angažovanja. Ovakvo razdvajanje smanjuje rizik poistovećivanja različitih aspekata stanja studenta, ali zaključci i dalje zavise od načina operacionalizacije, odsustva spoljašnjeg kriterijuma za ovladanost, stručnog mapiranja dokaza i izbora atributa za ponašajno klasterovanje.
- **Interna validnost.** Sprovedene evaluacije omogućavaju proveru funkcionalne izvodljivosti, unutrašnje stabilnosti i sledljivosti razvijenih artefakata, ali ni poređenje OBSLO i LAMS okruženja ni završna korisnička evaluacija nemaju dizajn koji bi omogućio uzročne zaključke o efektu na znanje, postignuće ili angažovanje.
- **Eksterna validnost.** Konačni model studenta evaluiran je na dva predmeta u jednoj instituciji tokom jedne školske godine, uz ograničenu količinu dokaza na nivou N3, a interoperabilnost i skalabilnost arhitekture nisu proverene. Rezultati zato ne omogućavaju statističku generalizaciju na druge discipline, institucije, nivoe studija ili generacije.
- **Validnost zaključivanja.** Analize osetljivosti, petostruka unakrsna validacija, poređenje kontinuirane i binarne BKT formulacije, analize stabilnosti klasterovanja i analiza osetljivosti individualnih prioriteta preporuke uvedene su kako bi se proverilo u kojoj meri zaključci zavise od pojedinačnih projektnih odluka. Dobijeni rezultati pružaju podršku unutrašnjoj stabilnosti ključnih izlaza u analiziranim kohortama, ali ne dokazuju optimalnost izabranih pragova, pondera, BKT konfiguracije ili algoritma klasterovanja.
- **Ponovljivost i reproduktivnost.** Postupci modelovanja i evaluacije definisani su kroz opis jedinica modelovanja, parametara, pragova, pravila adaptacije i konfiguracija korišćenih algoritama, čime se omogućava ponavljanje analitičkog postupka nad istim ili odgovarajuće strukturiranim podacima. Ipak, mapiranje aktivnosti provere na objekte učenja i kompetencije i definisanje OR i BA relacija

zavise od ekspertske semantičke procene, čija reproduktivnost između različitih projektanata nije empirijski potvrđena.

Navedena ograničenja određuju granice zaključaka disertacije. Sprovedene analize podržavaju tvrdnju da se predloženi modeli mogu povezati i operacionalizovati nad stvarnim obrazovnim podacima, da njihovi ključni izlazi mogu biti interpretabilni i da se na njihovoj osnovi može formirati sledljiva, ontološki utemeljena preporuka. Ne omogućavaju, međutim, zaključak da su svi parametri optimalni, da će isti empirijski obrasci biti dobijeni u drugim populacijama, da su adaptivne preporuke uzročno poboljšale učenje ili da je arhitektura već potvrđena kao skalabilno i univerzalno interoperabilno produkcijsko rešenje. Pravci za proveru ovih pitanja predstavljeni su u narednom odeljku.

8.4. Budući rad

Budući rad biće prvenstveno da bude usmeren na proširenje empirijske validacije razvijene arhitekture izvan konteksta u kojem je sprovedena ova disertacija, kao i na proveru obrazovnih efekata adaptivnih preporuka tokom redovne realizacije nastave. Sprovedeno istraživanje pokazalo je da se ontološki i kompetencijski strukturiran nastavni sadržaj, verifikovani dokazi iz aktivnosti, višeslojni model studenta i adaptivni mehanizam mogu povezati u funkcionalan i interpretabilan proces. Sledeća faza treba da utvrdi u kojoj meri se takvo rešenje može reprodukovati u drugim kohortama, predmetima, institucijama i disciplinama i da li njegova primena dovodi do merljivih promena u učenju.

Važan pravac predstavlja zasebna evaluacija kompetencijski proširenog modela nastavnog sadržaja. Osnovni ontološki model i njegova vizualizacija pomoću multidimenzionalnih konceptualnih mapa neposredno su evaluirani kroz rad studenata, dok je kompetencijski prošireni model u konačnoj fazi prvenstveno vrednovan kroz svoju funkcionalnu ulogu u povezivanju sadržaja, dokaza, modela studenta i preporuke. Buduća evaluacija trebalo bi da uključi studente, nastavnike i autore nastavnih sadržaja i da ispita koliko su im razumljive veze između objekata učenja, ishoda učenja, kompetencija, komponenti znanja i veštine, nivoa dubine i dokaza iz aktivnosti provere. Posebno bi trebalo ispitati da li različiti korisnici zahtevaju različit nivo detalja u prikazu iste semantičke strukture. Studentu bi mogao biti prikazan samo deo strukture potreban za razumevanje sopstvenog napretka i putanje učenja, dok bi nastavniku i autoru sadržaja bio dostupan detaljniji prikaz kompetencija, dokaza, mapiranja i ontoloških relacija.

Šira empirijska validacija modela studenta zahteva primenu na većem broju predmeta, generacija i visokoškolskih institucija. Posebno je važno uključiti predmete koji se razlikuju prema oblasti, nastavnom dizajnu, vrsti aktivnosti provere, granularnosti nastavnog sadržaja i načinu korišćenja sistema za e-učenje. Takva evaluacija omogućila bi da se utvrdi koji elementi arhitekture ostaju stabilni, a koji zahtevaju prilagođavanje konkretnom nastavnom kontekstu. Longitudinalno praćenje više uzastopnih generacija istog predmeta omogućilo bi dodatnu proveru stabilnosti procena ovladanosti, ponašajnih obrazaca i identifikovanih potreba za podrškom. Posebno značajna bila bi validacija BKT parametara na nezavisnoj kohorti, jer je petostruka unakrsna validacija sprovedena u ovoj disertaciji proveravala stabilnost unutar postojećih kohorti, ali ne i prenos parametara na novu populaciju. Analize osetljivosti i unakrsne validacije zato predstavljaju dobru osnovu, ali ne zamenjuju spoljašnju validaciju.

Buduća istraživanja trebalo bi dodatno da ispitaju kalibraciju procena ovladanosti, odnosno odnos između procenjene verovatnoće ovladanosti i rezultata na naknadnim nezavisnim proverama znanja i veština. Pragovi za nivoe N1 i N2 i alternativni načini ponderisanja dokaza već su sistematski analizirani u ovoj disertaciji, pa njihova osnovna analiza osetljivosti više ne predstavlja otvoren zadatak. Dalje istraživanje treba umesto toga da ispita projektne odluke koje nisu iscrpno poređene, kao što su granularnost jedinice modelovanja, minimalna količina dokaza potrebna za pouzdanu procenu, različite strategije regularizacije i mogućnost prenosa procenjenih parametara između uzastopnih kohorti istog predmeta.

Posebnu pažnju treba posvetiti kvalitetu semantičkog mapiranja aktivnosti provere na objekte učenja i kompetencije. U sadašnjoj implementaciji veze i njihovu relevantnost određuje nastavnik, što omogućava pedagoški smisleno mapiranje, ali uvodi i komponentu stručne procene. Buduća studija mogla bi da uključi više nastavnika koji nezavisno mapiraju iste aktivnosti i dodeljuju stepene relevantnosti, nakon čega bi se merila njihova međusobna saglasnost. Na taj način bilo bi moguće utvrditi koji tipovi aktivnosti i nastavnih elemenata dovode do stabilnog mapiranja, a kod kojih postoji veća interpretativna neizvesnost.

Odvojeno od validacije mapiranja aktivnosti provere na objekte učenja i kompetencije, potrebno je ispitati i reproduktivnost ekspertski definisanih OR i BA relacija u ontološkom modelu. Buduća studija trebalo bi da uključi više nastavnika ili stručnjaka iz istog predmetnog domena koji bi, nezavisno jedni od drugih, anotirali zajednički podskup koncepata i objekata učenja primenom istih kriterijuma za obavezni OR, opcioni OR i BA odnos. Nakon nezavisnog anotiranja potrebno je kvantitativno proceniti saglasnost u izboru tipa relacije i, kada je relacija usmerena, njenog smera, a zatim kvalitativno analizirati slučajeve neslaganja. Na ovaj način

bilo bi moguće utvrditi u kojoj meri eksplicitno definisana pravila dovode do reproduktivne ontološke strukture između različitih projektanata predmeta i identifikovati relacije čije definisanje zahteva dodatno preciziranje kriterijuma ili smernica za anotiranje.

Dodatna softverska podrška mogla bi da olakša ovaj proces tako što bi nastavniku predlagala potencijalne veze na osnovu teksta pitanja ili zadatka, ishoda učenja, pripadajuće kompetencije i metapodataka objekta učenja. Takva podrška ne bi trebalo da automatski donosi konačnu odluku o mapiranju, jer upravo ta veza određuje značenje dokaza koji ulazi u model studenta. Nastavnik bi zato zadržao odgovornost za potvrdu veze i njenog stepena relevantnosti.

Konačna implementacija već razlikuje pokušani sadržaj sa procenom ispod praga od nepokušavanog obaveznog N1 sadržaja, pa odvojeno modelovanje ova dva slučaja više ne predstavlja budući zadatak. Dalji razvoj treba da se usmeri na prioritizaciju sadržaja unutar već formiranog skupa za podršku. Posebno je potrebno ispitati kako balansirati ponavljanje pokušavanog, ali nedovoljno savladanog sadržaja sa obaveznim sadržajem koji student još nije pokušao i kako ograničiti broj neposrednih narednih koraka tako da preporuka ostane praktično upotrebljiva. Adaptivni mehanizam bi mogao da uzme u obzir razliku između procene i praga ovladanosti, broj sadržaja koji zavise od konkretnog preduslova, obaveznost kompetencije, ostvarivanje nivoa i raspoloživo vreme do sledeće aktivnosti provere. Jedan od pravaca daljeg razvoja jeste i prilagođavanje tona i naglaska obrazloženja prema ponašajnom tipu studenta. Na primer, kod minimalističkog obrasca rada mogli bi se isticati mali, redovni koraci i obavezni sadržaj, a kod istrajnog obrasca ciljaniji rad sa manje ponavljanja. Takvo prilagođavanje ne bi menjalo izbor ni redosled preporučenih objekata učenja, koji ostaju zasnovani na proceni ovladanosti, statusu pokušaja i ontološkim relacijama, ali bi zahtevalo zasebnu evaluaciju njegovog uticaja na razumljivost i prihvatanje preporuka.

Posebno istraživačko pitanje ostaje tretman nepokušavanih izbornih sadržaja nivoa N2 i N3. Oni ne mogu imati isti status kao nepokušano obavezno jezgro nivoa N1, jer student nije obavezan da ih sve realizuje. Njihovo uključivanje u preporuku trebalo bi zato povezati sa ciljevima studenta, prethodno demonstriranim kompetencijama, izborom pravca napredovanja i eventualno nastavničkim preporukama. Time bi adaptivni mehanizam mogao da razlikuje potrebu za nadoknađivanjem obaveznog sadržaja od mogućnosti za dalje produbljivanje kompetencija.

Potrebno je i prikupiti znatno veći broj dokaza na nivou N3. U sadašnjim podacima ovaj nivo nije omogućio pouzdanu kohortnu analizu, jer u SE201 nije bilo N3 dokaza, dok ih je u

CS202 generisao mali broj studenata. Buduća evaluacija treba da uključi dovoljan broj aktivnosti koje zahtevaju analizu, evaluaciju, kreiranje rešenja, povezivanje više koncepata i primenu znanja u novim situacijama. Posebno treba ispitati kako sekvencijalna procena funkcioniše kada dokazi potiču iz složenijih i otvorenijih aktivnosti, kao što su projekti, studije slučaja i eseji.

Ponašajni sloj modela takođe pruža prostor za dalji razvoj. U sadašnjoj implementaciji ponašajni tip predstavlja agregirani obrazac rada tokom posmatranog perioda. Budući model mogao bi da uvede vremenski zavisnu reprezentaciju u kojoj se ponašaj studenta prati kroz više vremenskih tačaka tokom semestra. Time bi bilo moguće razlikovati stabilan obrazac od kratkotrajne promene, ranije identifikovati pad angažovanja i ispitati da li se ponašanje menja nakon pružene preporuke [276]. Ovaj pravac je kompatibilan sa ranijim istraživanjima autora u kojima su analizirane promene obrazaca studentskog napretka tokom semestra, ali bi u okviru sadašnje arhitekture vremenska komponenta bila povezana i sa procenama ovladanosti i ontološki utemeljenim preporukama.

Najvažniji empirijski korak predstavlja kontrolisana ili kvazieksperimentalna provera efekta adaptivnih preporuka. Evaluacija sprovedena u ovoj disertaciji pokazala je izvodljivost integrisanog procesa i pozitivnu percepciju razumljivosti, relevantnosti i korisnosti preporuka, ali ne omogućava zaključak da preporuke uzročno poboljšavaju znanje ili angažovanje. Buduća studija trebalo bi da uporedi studente koji koriste ontološki utemeljenu adaptivnu kontrolnu tablu sa studentima koji prate standardnu linearnu putanju predmeta. Po mogućstvu bi trebalo koristiti početno i završno merenje i pratiti objektivne pokazatelje kao što su promena znanja, ovladanost kompetencijama, ostvarenost nivoa, realizacija aktivnosti, korišćenje preporučenih sadržaja i zadržavanje studenata. Time bi se postojeća potvrda izvodljivosti mogla proširiti proverom nastavne efikasnosti.

Buduće korisničke evaluacije trebalo bi da omoguće i analizu percepcije adaptivnih preporuka u odnosu na ponašajne tipove studenata. U sadašnjoj evaluaciji anonimnost upitnika onemogućila je povezivanje pojedinačnih odgovora sa ponašajnim tipom određenim modelom studenta. U narednim istraživanjima privatnost bi mogla da se očuva tako što bi se u skupu podataka za analizu zadržala samo deidentifikovana oznaka ponašajnog tipa, dok bi individualni identifikatori studenata bili uklonjeni pre analize. Takav dizajn omogućio bi poređenje ocena jasnoće, relevantnosti i korisnosti preporuka, kao i tema izdvojenih iz otvorenih komentara, između ponašajnih tipova na nivou kohorte. Na taj način moglo bi se ispitati da li studenti sa različitim obrascima angažovanja različito doživljavaju istu vrstu

adaptivne podrške i da li je, pored izbora nastavnog sadržaja, potrebno prilagođavati i način predstavljanja preporuke i njenog objašnjenja.

Dalji razvoj objašnjivosti treba usmeriti na interaktivne i korisnički prilagođene prikaze. Student bi, pored početnog obrazloženja, mogao da postavi dodatno pitanje o razlogu preporuke, aktivnosti na kojoj je procena zasnovana, ulozi određenog preduslova ili uslovima za dostizanje narednog nivoa. Takva interakcija ne bi smela da omogući generativnom modelu da samostalno menja preporuku ili uvodi novu činjeničnu osnovu, već bi odgovori morali da ostanu vezani za strukturirane podatke, model studenta i ontološke relacije.

Posebno je potrebna nezavisna evaluacija jezički generisanih objašnjenja. Konačna implementacija već koristi automatske provere prihvatljivosti i determinističku rezervnu varijantu, dok otvoreno pitanje predstavlja njihova empirijska validacija. Potrebno je sistematski porediti generisani tekst sa strukturiranim ulazom i procenjivati činjeničnu vernost, potpunost, terminološku doslednost, jasnoću, ton, stabilnost i moguće jezičke pristrasnosti. U evaluaciju bi trebalo uključiti nastavnike i studente, a različiti modeli i načini generisanja mogli bi se porediti sa determinističkim prikazom istog sadržaja. Ovo je važno zato što trenutne automatske provere predstavljaju zaštitne mehanizme, ali nisu empirijska potvrda kvaliteta LLM formulacije.

Generativna veštačka inteligencija može se dodatno istražiti i izvan formulacije preporuka, posebno za kontrolisanu podršku pripremi nastavnih materijala. Kompetencijski i ontološki model mogao bi da obezbedi strukturirani kontekst za generisanje dodatnih primera, formativnih pitanja, varijanti zadataka i alternativnih objašnjenja prilagođenih konkretnom nivou dubine. Takav sadržaj morao bi da bude eksplicitno povezan sa odgovarajućim ishodom učenja i kompetencijom i da prođe nastavničku proveru stručne tačnosti i pedagoške prikladnosti pre uključivanja u repozitorijum. Ovaj pravac predstavlja proširenje arhitekture, a ne deo empirijski potvrđenog adaptivnog mehanizma u sadašnjoj disertaciji.

Ukoliko se generativna veštačka inteligencija u budućnosti koristi i za kreiranje ili dopunjavanje objekata učenja, nastavničku proveru bilo bi korisno podržati strukturiranim višekriterijumskim postupkom procene kvaliteta generisanog sadržaja. U ranijem istraživanju autora razvijen je okvir za evaluaciju obrazovnog sadržaja generisanog velikim jezičkim modelima koji obuhvata šest grupa kriterijuma: tačnost i profesionalnu korektnost, dubinu i obuhvat sadržaja, primere i praktičnu primenu, pedagošku jasnoću i didaktički kvalitet, vizuelnu i strukturnu prezentaciju i jezički stil i akademski ton [277]. Okvir je

operacionalizovan kroz 25 potkriterijuma, a relativni značaj kriterijuma određen je ekspertskom procenom primenom AHP i FAHP metoda. U sprovedenoj evaluaciji tačnost i profesionalna korektnost izdvojene su kao najznačajnija grupa kriterijuma, što je posebno relevantno za kontrolu stručne pouzdanosti eventualno generisanih nastavnih materijala [277]. Takav okvir mogao bi u budućoj implementaciji da posluži kao dopunski sloj kontrole kvaliteta pre nego što LLM-generisani sadržaj dobije status objekta učenja i bude povezan sa ishodom, kompetencijom, nivoom dubine i ontološkim relacijama. Njegova primena u toj ulozi predstavlja predloženi pravac budućeg povezivanja dva istraživačka rezultata, a nije evaluirana kao deo arhitekture razvijene u ovoj disertaciji.

Poseban pravac budućih istraživanja predstavlja automatsko ocenjivanje predispitnih obaveza i ispitnih odgovora tekstualnog karaktera. Za programske predmete automatska provera rešenja, na primer SQL upita ili programskog koda, danas je izvodljiva, ali ocenjivanje testova sa otvorenim odgovorima, izveštaja o projektima, seminarskih radova i studija slučaja ostaje otvoren problem, posebno na predmetima višeg inženjerskog nivoa kao što su predmeti softverskog inženjerstva. Za razvijeni model studenta ovo pitanje je neposredno važno, jer se njegove procene formiraju iz rezultata aktivnosti provere, pa bi brže i pouzdanije ocenjivanje ovakvih aktivnosti omogućilo pravovremenije ažuriranje procena i preporuka. Primenu generativne veštačke inteligencije pri tome treba razmatrati odvojeno u fazi pripreme nastavnih materijala i predispitnih obaveza, koja bi u institucionalnom okruženju Univerziteta Metropolitan pripadala alatu iCreate, i u fazi ocenjivanja podnetih predispitnih obaveza i ispitnih odgovora, koja bi pripadala sistemima iLearn i iMet [278]. Ocenjivanje zahteva veću pouzdanost i proverljivost od pripreme sadržaja, a kod velikog broja studenata može biti i znatno skuplje. Jedan od mogućih pravaca jeste ispitivanje u kojoj meri se kriterijumi koje primenjuje generativni model mogu prevesti u algoritamsko rešenje koje ne zahteva stalno korišćenje takvih alata, uz ograničenja svojstvena svakom algoritamskom pristupu. Rezultati dobijeni na programskim predmetima zato ne bi trebalo tumačiti kao rešenje problema ocenjivanja u opštem slučaju.

Produkcijska primena zahteva razvoj zatvorenog adaptivnog ciklusa u kojem se novi rezultati aktivnosti automatski preuzimaju iz obrazovnog sistema, povezuju sa odgovarajućim dokazima u ontološkom modelu, koriste za ažuriranje modela studenta, a zatim dovode do formiranja nove preporučene putanje. Sistem bi pri tome trebalo da beleži i da li je student preporučeni sadržaj otvorio, koristio i nakon njega generisao novi dokaz. Takva

implementacija omogućila bi proveru rada modela u realnom vremenu i analizu načina na koji se procene i preporuke menjaju kroz semestar.

Važan pravac budućih istraživanja jeste i provera interoperabilnosti konačne arhitekture sa drugim sistemima za upravljanje učenjem. DITA objekti učenja i RESTful interfejsi daju tehničku osnovu za labavo povezivanje komponenti, ali ova disertacija nije empirijski proverila integraciju konačnog modela sa široko korišćenim platformama kao što su Moodle ili Canvas, niti usklađenost ontološkog sloja sa standardizovanim šemama metapodataka za objekte učenja, kao što su IEEE LOM ili odgovarajuće IMS/1EdTech specifikacije. Budući rad zato treba da proveri koje su transformacije podataka i dodatni interfejsi potrebni da bi se arhitektura povezala sa takvim okruženjima.

Sa produkcijskom integracijom povezana je i skalabilnost. U sadašnjem istraživanju nije analizirano kako se vreme obrade, memorijski zahtevi, broj BKT jedinica, veličina ontologije i trošak generisanja preporuka menjaju sa velikim brojem predmeta, studenata i istovremenih korisnika. Buduća analiza treba da obuhvati računarske performanse, opterećenje servisnih interfejsa, organizacioni napor mapiranja velikog broja nastavnih elemenata i troškove održavanja ontologije i kompetencijskih veza. Tek takva evaluacija može pokazati da li se arhitektura može primeniti na nivou većeg broja studijskih programa ili čitave institucije.

Navedeni pravci budućeg rada predstavljaju nastavak, a ne promenu osnovne logike razvijene arhitekture. Model nastavnog sadržaja i dalje bi obezbeđivao formalnu i semantičku strukturu onoga što se uči, model studenta bi na osnovu novih dokaza ažurirao procene trenutnog stanja, a adaptivni sloj bi te procene i status obaveznog sadržaja povezivao sa ontološkim relacijama radi izbora narednih koraka. Dalji razvoj treba prvenstveno da pokaže koliko je takav proces stabilan van analiziranih kohorti, koliko je tehnički održiv pri većem obimu primene i, najvažnije, da li njegova redovna upotreba proizvodi merljive obrazovne koristi.

8.5. Ispunjenost ciljeva istraživanja

Ispunjenost ciljeva istraživanja ocenjena je na osnovu razvijenih artefakata, njihove implementacije i rezultata evaluacije prikazanih u prethodnim poglavljima. Pri tome se razlikuju ciljevi čije su ključne funkcionalnosti neposredno implementirane i empirijski evaluirane od ciljeva kod kojih je ostvarenje pokazano prvenstveno na nivou projektovane arhitekture i mogućnosti integracije. Ovakvo razgraničenje je značajno jer sprovedeno istraživanje potvrđuje izvodljivost i interpretabilnost razvijenog pristupa u analiziranim

obrazovnim kontekstima, ali ne omogućava jednake zaključke o svim njegovim mogućim načinima produkcijske primene.

Cilj 1 - razviti i evaluirati model nastavnog sadržaja zasnovan na ontologiji, koji omogućava strukturiranje, povezivanje, pretragu i vizualizaciju nastavnih materijala, kao osnovu za njihovo preporučivanje u sistemu za e-učenje.

Prvi cilj ostvaren je razvojem ontološkog modela nastavnog sadržaja predstavljenog u Poglavlju 5. Model formalizuje hijerarhijsku organizaciju nastavnog domena kroz oblasti i jedinice znanja, teme, podteme i objekte učenja i uključuje eksplicitne relacije kojima se predstavljaju veze između koncepata i objekata, pripadnost resursa, redosled izučavanja i odnosi između osnovnih i naprednih sadržaja. Razdvajanjem konceptualne strukture od konkretnih nastavnih resursa omogućeno je menjanje i ponovno korišćenje sadržaja bez narušavanja osnovne organizacije domena.

Za vizuelno predstavljanje ontološke strukture razvijene su multidimenzionalne konceptualne mape, koje omogućavaju postepeno prikazivanje delova domena i nelinearnu navigaciju kroz povezane nastavne sadržaje. Model i njegova vizualizacija implementirani su u OBSLO okruženju i evaluirani kroz dve iteracije u stvarnom nastavnom kontekstu (odeljak 7.1), koje su pokazale da se ontološki organizovan prostor može koristiti za pronalaženje, povezivanje i nelinearno korišćenje nastavnih materijala.

Osnovni ontološki model je zatim integrisan sa kompetencijski vođenim okvirom tako da objekti učenja mogu biti povezani sa ishodima učenja, kompetencijama, komponentama znanja i veštine, nivoima dubine i elementima za verifikaciju naučenog. Uloga VERIFY elementa dodatno je semantički operacionalizovana povezivanjem objekata učenja sa dokazima koji nastaju u aktivnostima provere. Time je ontološki model, pored organizacije i vizuelizacije sadržaja, dobio i ulogu semantičke osnove za povezivanje nastavnog sadržaja sa modelom studenta i adaptivnim mehanizmom. Na osnovu razvijenog modela, njegove implementacije i dve iteracije evaluacije zaključuje se da je **Cilj 1 ostvaren**.

Cilj 2 - istražiti, razviti i evaluirati model studenta zasnovan na aktivnostima i rezultatima studenata u digitalnim okruženjima za učenje, koji može da podrži kontinuirano praćenje napretka i procenu nivoa ovladanosti nastavnim sadržajem povezanim sa određenim ciljem učenja, ishodom učenja i/ili kompetencijom.

Drugi cilj ostvaren je kroz iterativni razvoj modela studenta prikazan u Poglavlju 6. Prva faza istraživanja ispitala je mogućnost predikcije akademskog uspeha primenom algoritama

mašinskog učenja, dok je druga faza analizirala obrasce studentskog angažovanja primenom klasterovanja u različitim institucionalnim i nastavnim kontekstima. Ove dve faze pokazale su da se iz obrazovnih podataka mogu izdvojiti korisni prediktivni i ponašajni obrasci, ali su istovremeno ukazale na ograničenja predstavljanja stanja pojedinačnog studenta samo kroz predikciju ukupnog ishoda ili pripadnost grupi.

Na osnovu tih nalaza razvijen je konačni višeslojni model studenta. Sekvencijalna procena ovladanosti formira se primenom BKT-a na nivou kombinacije predmet-kompetencija predmeta-nivo dubine i koristi punu hronološku sekvencu raspoloživih dokaza. Ostvarenost nivoa izračunava se odvojeno na osnovu trenutno važećih aktivnosti, dok se ponašajni tip formira na osnovu obima aktivnosti, broja aktivnih dana i udela ranijih pokušaja. Time su demonstrirana ovladanost, obim realizovanog rada i način angažovanja predstavljeni kao povezane, ali konceptualno različite dimenzije.

Model je evaluiran na predmetima SE201 i CS202 (odeljak 7.2.3). Rezultati su pokazali da formira interpretabilne procene ovladanosti, razlikuje ovladanost kompetencijama od ostvarenosti nivoa i prikazuje individualne profile koji nisu vidljivi iz jedne ukupne ocene. Analize osetljivosti, ponderisanja dokaza i unakrsne validacije podržale su stabilnost ključnih projektnih odluka. Ponašajni sloj proveren je ponovljenim poduzorkovanjem, metodama zasnovanim na gustini i promenama skupa ulaznih atributa (odeljak 7.2.3.3). Provere su podržale odluku da se ponašajni tip formira nezavisno od ovladanosti i ostvarenosti, uz napomenu da tipove treba tumačiti kao obrasce angažovanja u konkretnim kohortama, a ne kao trajne kategorije studenata.

Sprovedene evaluacije zato podržavaju izvodljivost, interpretabilnost i unutrašnju stabilnost konačnog modela u analiziranim nastavnim kontekstima. One ne predstavljaju dokaz da su procene ili parametri optimalni za sve predmete i populacije niti zamenjuju validaciju na nezavisnoj kohorti. U granicama postavljenog cilja zaključuje se da je Cilj 2 ostvaren.

Cilj 3 - osmisliti, projektovati, implementirati i evaluirati model studenta i model nastavnog sadržaja koji zajedno mogu da podrže personalizovano učenje u sistemu za e-učenje kroz organizovanje objekata učenja, praćenje napretka studenta, davanje objašnjivih preporuka nastavnog sadržaja i vizualizaciju personalizovanog prostora za učenje.

Treći cilj ostvaren je povezivanjem kompetencijski proširenog modela nastavnog sadržaja, višeslojnog modela studenta i adaptivnog mehanizma u integrisanu arhitekturu. Model

nastavnog sadržaja određuje formalnu strukturu nastavnih elemenata i njihove semantičke odnose, dok model studenta obezbeđuje procene ovladanosti, ostvarivanja nivoa, lokalne informacije o pokušajima i ponašajni kontekst. Na toj osnovi adaptivni mehanizam formira početni skup sadržaja kojima je potrebna dodatna pažnja i povezuje ga sa ontološkim relacijama radi izgradnje uređene putanje.

Analize na nivou individualnih preporuka (odeljak 7.3.1) pokazale su da su najviši prioriteti relativno stabilni pri promeni pragova ovladanosti i da ontološko uređivanje čuva relacije preduslova i odnose osnovnog i naprednog sadržaja koje rangiranje samo prema procenjenoj ovladanosti zanemaruje.

Objašnjivost je realizovana tako što razlog uključivanja svakog objekta ostaje sledljiv do stanja studenta, statusa sadržaja i odgovarajućih ontoloških relacija. Adaptivna odluka pri tome je odvojena od njenog završnog jezičkog oblikovanja: veliki jezički model ne bira i ne uređuje objekte učenja, već samo verbalizuje već strukturirano obrazloženje, uz definisane automatske provere i determinističku rezervnu varijantu.

Integrisani postupak operacionalizovan je nad stvarnim podacima predmeta, od dokaza nastalih u aktivnostima do procene stanja, identifikovanja potreba i formiranja uređene preporuke. Kontrolna tabla objedinjuje ove rezultate i prikazuje ih studentu zajedno sa objašnjenjem i položajem preporučenog sadržaja u ontološkom prostoru. Povratne informacije 86 studenata pokazuju da su kontrolna tabla, preporuke i objašnjenja uglavnom ocenjeni kao razumljivi, relevantni i korisni.

Ova evaluacija pokazuje da razvijeni modeli zajedno mogu da podrže funkcionalan i objašnjiv proces personalizacije, ali ne predstavlja kontrolisani dokaz da njihova primena uzročno povećava znanje, akademski uspeh ili angažovanje. U skladu sa sadržajem samog cilja, koji zahteva projektovanje, implementaciju i evaluaciju sposobnosti modela da podrže navedene funkcionalnosti, zaključuje se da je Cilj 3 ostvaren, uz ograničenje da obrazovna efikasnost adaptivnih preporuka ostaje predmet buduće kontrolisane ili kvazieksperimentalne evaluacije.

Cilj 4 - osmisliti i razviti model studenta i model nastavnog sadržaja kao modularne komponente, razdvojene od konkretnog sistema za e-učenje, kako bi se omogućila njihova jednostavnija integracija u različite adaptivne i personalizovane kontekste e-učenja.

Četvrti cilj adresiran je projektovanjem modularne i labavo povezane arhitekture u kojoj su odgovornosti modela nastavnog sadržaja, modela studenta, adaptivnog mehanizma i sistema za isporuku nastavnog sadržaja razdvojene. Razmena se zasniva na strukturiranim podacima i servisnim interfejsima, tako da analitička i adaptivna logika nisu neposredno vezane za unutrašnju realizaciju jednog konkretnog sistema za upravljanje učenjem. U okviru razvijene arhitekture pokazano je kako se podaci o aktivnostima mogu povezati sa modelom studenta i kako se njegov strukturirani izlaz može proslediti adaptivnom sloju i sistemu za prikaz preporučenih sadržaja.

Međutim, konačni model studenta i adaptivni mehanizam nisu produkcijski integrisani i evaluirani na više nezavisnih LMS platformi, niti su sistematski merene performanse, skalabilnost i interoperabilnost integracionih interfejsa (odeljak 8.3). Cilj 4 je ostvaren u smislu u kojem je formulisan: modeli su razvijeni kao modularne komponente čije razdvojene odgovornosti i strukturirani interfejsi smanjuju zavisnost od konkretnog sistema i omogućavaju definisanje scenarija povezivanja sa drugim okruženjima. Empirijska potvrda jednostavnije integracije kroz produkcijsku primenu u više nezavisnih sistema nije bila deo ovog cilja (odeljak 1.1) i predstavlja jedan od ključnih pravaca budućeg rada.

Posmatrani zajedno, rezultati pokazuju da su sva četiri cilja istraživanja ostvarena u okviru opsega definisanog ovom disertacijom. Ovako utvrđena ispunjenost ciljeva predstavlja osnovu za razmatranje hipoteza u narednom odeljku.

8.6. Ispunjenost hipoteza

Ispunjenost hipoteza razmatrana je na osnovu razvijenih modela, njihove implementacije i rezultata evaluacije prikazanih u poglavljima 5, 6 i 7. Pri tumačenju rezultata koristi se izraz *podržana*, a ne apsolutno potvrđena hipoteza, jer se empirijski nalazi odnose na analizirane predmete, kohorte i obrazovna okruženja. Posebno je značajno razlikovati hipoteze za koje postoji neposredna empirijska evaluacija od hipoteze koja se odnosi na mogućnost integracije i za koju je podrška prvenstveno arhitekturna.

Opšta polazna hipoteza istraživanja glasi: OH - Odgovarajućim modelom studenta, zasnovanim na metodama analitike učenja i algoritmima mašinskog učenja, kao i modelom nastavnog sadržaja zasnovanim na ontologiji, moguće je podržati personalizovano i adaptivno (prilagodljivo) e-učenje kroz praćenje napretka studenta, organizaciju nastavnih sadržaja i formiranje preporuka za dalje učenje.

Rezultati istraživanja podržavaju opštu hipotezu. Razvijen je ontološki model kojim se nastavni sadržaj formalno organizuje kroz koncepte, objekte učenja i njihove međusobne relacije, a zatim je povezan sa kompetencijama, ishodima učenja, komponentama znanja i veštine, nivoima dubine i dokazima nastalim u aktivnostima provere. Semantičkim povezivanjem nastavnog sadržaja i dokaza omogućeno je da rezultati aktivnosti predstavljaju ulaz u model studenta, a ne samo agregirane pokazatelje uspeha.

Istovremeno je razvijen višeslojni model studenta koji koristi podatke o aktivnostima i rezultatima za sekvencijalnu procenu ovladanosti kompetencijama, odvojeno praćenje ostvarenosti aktivnosti i opisivanje ponašajnog obrasca studenta. Ove dimenzije nisu svedene na jednu ukupnu vrednost, čime je omogućeno razlikovanje modelom procenjenog nivoa ovladanosti na osnovu raspoloživih dokaza, obima aktivnosti koje je student realizovao i načina na koji se angažovao tokom nastavnog procesa

Povezivanjem modela studenta sa ontološkim modelom formiran je adaptivni sloj koji stanje studenta prevodi u uređenu putanju nastavnog sadržaja. Konačna implementacija razlikuje pokušane objekte sa procenom ovladanosti nižom od odgovarajućeg praga i nepokušane obavezne objekte nivoa N1. Za nepokušane obavezne sadržaje ne formira se veštačka procena ovladanosti, već se oni označavaju kao nedostajući sadržaji obaveznog jezgra visokog prioriteta. Ontološke relacije zatim omogućavaju uključivanje potrebnih preduslova i osnovnih varijanti sadržaja i određivanje njihovog položaja u preporučenoj putanji.

Implementacija je pokazala da se ceo lanac, od dokaza iz aktivnosti do procene stanja i preporučenog sadržaja, može operacionalizovati na stvarnim obrazovnim podacima. Dodatne analize osetljivosti, unakrsne validacije i robustnosti podržale su stabilnost ključnih rezultata unutar analiziranih kohorti. Kontrolna tabla omogućila je prikaz rezultata modela i adaptivne preporuke krajnjem korisniku, a studenti su preporuke i njihova objašnjenja uglavnom ocenili kao razumljive, relevantne i korisne.

Ovi rezultati predstavljaju podršku tvrdnji da kombinacija odgovarajućeg modela studenta i ontološkog modela nastavnog sadržaja može da podrži praćenje napretka, organizaciju

nastavnog sadržaja i formiranje personalizovanih preporuka. Podrška se, međutim, odnosi na izvodljivost i interpretabilnost razvijenog procesa i ne predstavlja dokaz da njegova primena sama po sebi uzročno poboljšava akademski uspeh, ovladanost kompetencijama ili angažovanje studenata. Za takav zaključak potrebna je kontrolisana ili kvazieksperimentalna evaluacija. U navedenim granicama zaključuje se da je **opšta hipoteza podržana**.

PH1: Softverski sistem koji povezuje model studenta, razvijen primenom metoda analitike učenja i algoritama mašinskog učenja nad podacima o aktivnostima i rezultatima studenata u sistemu za e-učenje, i model nastavnog sadržaja, zasnovan na objektima učenja i strukturiran korišćenjem ontologije, može da podrži praćenje napretka studenta tokom učenja, kao i dinamičko određivanje i vizualizaciju nastavnog sadržaja koji se studentu preporučuje za dalji rad.

Hipoteza PH1 ispitana je povezivanjem modela studenta, ontološkog modela nastavnog sadržaja i adaptivnog mehanizma. Model studenta obrađuje hronološki organizovane dokaze iz aktivnosti i formira procene ovladanosti na nivou kombinacije predmet-kompetencija predmeta-nivo dubine, dok se lokalne informacije o pojedinačnim objektima učenja koriste za fino granularnu dijagnostiku i preporučivanje. Odvojeno se prate ostvarenost nivoa i ponašajni kontekst studenta.

Na osnovu ovih izlaza adaptivni sloj određuje sadržaj kojem je potrebna dodatna pažnja. Pokušani objekti sa procenom ispod praga predstavljaju slabe tačke u užem smislu, dok se nepokušani obavezni objekti nivoa N1 evidentiraju kao nedostajući obavezni sadržaji bez formiranja procene ovladanosti. Tako formiran skup povezuje se sa ontološkim relacijama redosleda i preduslova i odnosima između osnovnog i naprednog sadržaja, čime se dinamički formira individualna uređena putanja.

Rezultati se prikazuju kroz kontrolnu tablu i personalizovani prostor nastavnog sadržaja. Studentu se mogu prikazati procene ovladanosti, ostvarenost nivoa, ponašajni kontekst, različiti razlozi zbog kojih su objekti uključeni u preporuku, njihov preporučeni redosled i položaj u širem ontološkom prostoru. Evaluacija je pokazala da su studenti takve preporuke i objašnjenja uglavnom ocenili kao razumljive i relevantne.

Važno je da je dinamičko određivanje sadržaja realizovano determinističkim povezivanjem modela studenta, adaptivnih pravila i ontoloških relacija. Veliki jezički model, kada se koristi, ne određuje koji će sadržaj biti preporučen niti njegov redosled, već samo jezički oblikuje prethodno strukturirano obrazloženje. Time je demonstriran povezan rad modela studenta i

modela nastavnog sadržaja od ulaznih podataka o aktivnostima do individualno formirane i vizuelno predstavljene preporuke. U granicama sprovedene evaluacije zaključuje se da je hipoteza PH1 podržana.

PH2: Analiza podataka o aktivnostima i rezultatima studenata u onlajn aktivnostima učenja, primenom metoda analitike učenja i algoritama mašinskog učenja, može podržati procenu nivoa ovladanosti određenim nastavnim sadržajem i identifikaciju delova sadržaja u kojima je studentu potrebna dodatna podrška, čime se omogućava bolje usklađivanje preporučenih sadržaja sa njegovim trenutnim stanjem učenja.

Hipoteza PH2 neposredno je ispitana primenom modela studenta na podatke predmeta SE201 i CS202. Rezultati aktivnosti i provera povezani su sa objektima učenja, kompetencijama i nivoima dubine i organizovani u hronološke sekvence zapažanja. BKT je korišćen za formiranje individualnih procena ovladanosti na nivou kombinacije predmet-kompetencija predmeta-nivo dubine, dok je ostvarenost aktivnosti izračunavana odvojeno. Takva struktura omogućila je da se trenutno stanje studenta ne predstavlja jednom agregiranom ocenom, već kroz više interpretabilnih dimenzija.

Fino granularno povezivanje dokaza sa objektima učenja omogućilo je identifikovanje konkretnih delova sadržaja kojima je potrebna dodatna podrška. Kod pokušavanih objekata ova odluka zasniva se na raspoloživom dokazu i proceni ovladanosti u odnosu na odgovarajući prag. Kod nepokušavanog obaveznog N1 sadržaja ne postoji procena ovladanosti, ali njegov status obaveznog jezgra i odsustvo pokušaja opravdavaju uključivanje u adaptivni sloj kao visokoprioritetnog nedostajućeg sadržaja. Ovim je omogućeno bolje usklađivanje preporuke i sa studentima sa manjim obimom aktivnosti, bez poistovećivanja odsustva dokaza sa neuspehom.

Stabilnost procene i identifikovanja potreba dodatno je proverena analizom pragova, alternativnim ponderisanjem dokaza i petostrukom unakrsnom validacijom (odeljak 7.2.3.1), kao i na nivou individualnog skupa i redosleda slabih tačaka (odeljak 7.3.1). Promene pragova menjale su prvenstveno granične slabe tačke, dok su osnovni obrasci na nivou kohorte i najviši prioriteti preporuke ostali relativno stabilni. Ovi rezultati podržavaju unutrašnju stabilnost u analiziranim kohortama, ali ne predstavljaju nezavisnu validaciju na novoj populaciji niti dokaz optimalnosti izabranih pragova. Dodatno ponašajno modelovanje pruža kontekst o načinu rada studenta, ali se procene ovladanosti i ostvarenosti ne koriste kao atributi za formiranje ponašajnih klastera. Ponašajni tip zato nije zamena za procenu znanja i ne određuje delove

sadržaja kojima je potrebna podrška. Rezultati tako pokazuju da analiza podataka o aktivnostima i rezultatima može da podrži procenu ovladanosti i lokalizovanje različitih vrsta potreba za podrškom na konkretnom nastavnom sadržaju i da se takvi izlazi mogu neposredno koristiti pri formiranju personalizovane preporuke. Pri tome se procena ovladanosti tumači kao modelom izvedena veličina zasnovana na raspoloživim dokazima, a ne kao nezavisno izmereno znanje, jer u istraživanju nije korišćen zaseban spoljašnji kriterijum provere; njena upotrebljivost pokazana je kroz unutrašnju stabilnost i sledljivu vezu sa preporukom, dok kalibracija u odnosu na nezavisnu proveru ostaje predmet budućeg rada. U granicama analiziranih predmeta i kohorti zaključuje se da je hipoteza PH2 podržana.

PH3: Primena ontološkog modela za organizaciju objekata učenja može podržati proces personalizacije nastave i olakšati pronalaženje, povezivanje i vizualizaciju obrazovnih materijala.

Hipoteza PH3 ispitana je razvojem i evaluacijom sistema OBSLO, u kojem je ontološki model nastavnog sadržaja vizuelizovan pomoću multidimenzionalnih konceptualnih mapa. Sistem omogućava dinamičko prikazivanje relevantnih delova ontologije, razlikovanje osnovnih i naprednih sadržaja i nelinearno kretanje kroz povezane objekte učenja.

U prvoj iteraciji evaluacije, objavljenoj u [14], studenti koji su koristili OBSLO ostvarili su ukupnu stopu tačno rešenih zadataka od 75,20%, dok je u uporednom linearnom okruženju ostvarena stopa od 38,93%. Ove vrednosti odnose se na konkretne grupe, srodne zadatke i analizirani nastavni kontekst i zato se ne tumače kao univerzalna veličina efekta ontološke organizacije. Povratne informacije studenata pokazale su da su u OBSLO okruženju mogli da pronalaze relevantne materijale, vraćaju se na sadržaje prethodnih lekcija i samostalno formiraju putanje kroz nastavne objekte, dok je druga iteracija evaluacije pokazala da se analiza stvarnih studentskih putanja može koristiti za unapređenje ontologije (odeljak 7.1.2). U konačnoj fazi istraživanja uloga ontologije proverena je i neposredno u adaptivnom postupku (odeljak 7.3.1). Poređenje sa redosledom zasnovanim samo na procenjenoj ovladanosti pokazalo je da ontološko uređivanje čuva relacije preduslova i odnose osnovnog i naprednog sadržaja koje takvo rangiranje može da naruši. Time je pokazano da ontologija ne služi samo organizaciji i vizuelizaciji resursa, već i usklađivanju redosleda individualne preporuke sa strukturom nastavnog sadržaja.

Rezultati zato podržavaju tvrdnju da ontološka organizacija i multidimenzionalna vizualizacija mogu da olakšaju pronalaženje, povezivanje i korišćenje nastavnih materijala u

personalizovanom prostoru za učenje, dok eksplicitne ontološke relacije dodatno omogućavaju strukturno uređivanje individualne preporučene putanje. Pošto nije sproveden zaseban kontrolisani eksperiment kojim bi se izolovano merila efikasnost pretraživanja svakog nastavnog objekta, zaključak ostaje ograničen na sprovedene evaluacione scenarije. U tim granicama zaključuje se da je **hipoteza PH3 podržana**.

PH4: Razvijeni model studenta i model nastavnog sadržaja, realizovani kao modularne komponente razdvojene od konkretnog sistema za e-učenje, mogu obezbediti jednostavniju integraciju u različite adaptivne i personalizovane kontekste e-učenja.

Hipoteza PH4 razmatrana je prvenstveno na osnovu projektovane arhitekture i demonstriranog povezivanja njenih komponenti. OBSLO je razvijen tako da ne zamenjuje postojeću infrastrukturu za e-učenje, već da je proširuje ontološkim prostorom, analitičkim funkcijama, modelom studenta i adaptivnim mehanizmom. Razdvajanje odgovornosti između sistema za isporuku nastavnog sadržaja, sistema za upravljanje obrazovanjem i OBSLO komponenti omogućava da se podaci i rezultati razmenjuju preko servisnih interfejsa.

Konačni model studenta i adaptivni sloj takođe su realizovani kao funkcionalno razdvojene komponente. Njihovi izlazi predstavljeni su strukturiranim podacima koji obuhvataju procene ovladanosti, ostvarenost nivoa, ponašajni kontekst, status pokušaja, identifikovane potrebe za podrškom i uređene liste preporučenih objekata učenja. Zbog toga analitička i adaptivna logika nisu neposredno vezane za unutrašnju implementaciju jednog konkretnog LMS-a.

U skladu sa formulacijom hipoteze i napomenom uz ciljeve istraživanja u odeljku 1.1, jednostavnija integracija se u ovoj disertaciji ne meri kao smanjenje vremena, troškova ili tehničke složenosti integracije. PH4 se zato proverava prema tome da li arhitektura obezbeđuje razdvojene funkcionalne odgovornosti, razmenu strukturiranih podataka preko servisnih interfejsa i uključivanje razvijenih komponenti kao dodatnog sloja nad postojećim sistemom za upravljanje učenjem, bez njegove zamene. Razvijena arhitektura demonstrira tehničke i modelske preduslove za takvo povezivanje i pokazuje kako se podaci iz obrazovnog sistema mogu proslediti modelu studenta, kako se njegovi strukturirani izlazi mogu koristiti u adaptivnom sloju i kako se rezultat adaptacije može vratiti sistemu za prikaz i isporuku nastavnog sadržaja. Time je pokazana arhitekturna izvodljivost modularnog povezivanja razvijenih komponenti sa postojećim obrazovnim okruženjem. Međutim, konačni model studenta i Adaptive Engine nisu produkcijski integrisani i evaluirani na više nezavisnih LMS platformi, niti su sistematski ispitani interoperabilnost sa različitim standardima obrazovnih

metapodataka, performanse integracionih interfejsa i skalabilnost pri većem broju korisnika, predmeta i institucija.

Hipoteza PH4 je zato podržana u smislu definisanom u odeljku 1.1: modeli su razvijeni kao modularne komponente razdvojene od konkretnog sistema za e-učenje, njihovi ulazi i izlazi su strukturirani, a njihovo uključivanje kao dodatnog sloja nad postojećim institucionalnim sistemom, bez njegove zamene, je demonstrirano. Ova podrška ne obuhvata tvrdnju da je integracija jednostavnija i u drugim sistemima, jer konačni model studenta i adaptivni mehanizam nisu integrisani i evaluirani na više nezavisnih LMS platformi, niti je proces integracije meren u odnosu na alternativne arhitekture. Takva provera zahtevala bi implementaciju u više tehnološki nezavisnih obrazovnih sistema i poređenje procesa integracije prema unapred definisanim kriterijumima, kao što su potrebne izmene sistema, složenost interfejsa, vreme integracije, pouzdanost razmene podataka i performanse.

8.7. Zaključna razmatranja

Polazni problem ove disertacije bio je nesklad između velike količine podataka dostupnih u savremenim sistemima e-učenja i njihove ograničene primene za pružanje konkretne, individualizovane podrške studentima. Podaci o aktivnostima i rezultatima pokazuju kako student radi i kakve rezultate postiže, ali sami po sebi ne određuju na koji deo nastavnog sadržaja se rezultat odnosi niti šta bi student trebalo dalje da uči. Formalno organizovan nastavni sadržaj, sa druge strane, predstavlja strukturu znanja, ali bez dinamičkog modela studenta ne sadrži informaciju o trenutnom stanju i potrebama pojedinca.

Centralni doprinos disertacije jeste pristup u kome se ova dva dela povezuju u jedinstven i sledljiv proces, prikazan na Slici 2. Dokaz iz aktivnosti provere dobija semantički kontekst u ontološkom i kompetencijskom modelu nastavnog sadržaja, iz niza takvih dokaza formira se višeslojna procena stanja studenta, a identifikovane potrebe se preko ontoloških relacija prevode u uređenu i obrazloženu putanju za dalje učenje. Doprinos se ne zasniva na novom algoritmu. Ontologije, kompetencijski modeli, BKT, klasterovanje i sistemi preporuka su postojeće metode, a novina je u postupcima koji ih povezuju tako da pojedinačni dokaz zadrži svoje značenje od nastanka do preporuke. Rezultati disertacije pokazuju da stanje studenta ne mora da se svodi na jednu ocenu ili na pripadnost grupi. Razdvajanjem ovladanosti kompetencijama, ostvarenosti nivoa i ponašajnog obrasca nad istim dokazima dobija se model u kome svaka dimenzija ima jasno određeno značenje i ulogu u adaptaciji, a razlike koje bi u

zbirnoj oceni ostale skrivene postaju vidljive. Takav model je interpretabilan po konstrukciji, jer se svaka procena odnosi na imenovanu kompetenciju, nivo dubine i objekat učenja.

Disertacija pokazuje da ontologija može imati operativnu, a ne samo organizacionu ulogu. Element VERIFY, koji u kompetencijskom okviru ostaje na konceptualnom nivou, dobija konkretno značenje veze između objekta učenja i dokaza, a relacije preduslova i odnosa osnovnog i naprednog sadržaja postaju deo same adaptivne odluke. Preporuka se time ne završava rangiranom listom slabih tačaka, već postaje putanja koja poštuje strukturu domena. Za objašnjivu veštačku inteligenciju u obrazovanju značaj pristupa je u tome što objašnjivost nije naknadni dodatak. Svaka preporuka može se slediti unazad do dokaza, procene, pravila i ontološke relacije na kojima počiva, dok veliki jezički model samo jezički oblikuje već donetu odluku. Ovakvo razdvajanje odlučivanja od jezičkog oblikovanja predstavlja obrazac primenljiv i u drugim obrazovnim sistemima koji koriste generativne modele, jer čuva proverljivost odluke nezavisno od kvaliteta generisanog teksta.

Navedeni pristup disertacije oslanja se na podatke koje institucije već prikupljaju, rezultate testova, zadataka i projekata, i na mapiranje aktivnosti na nastavni sadržaj koje sprovodi nastavnik. Modularna arhitektura omogućava da se razvijene komponente uvedu kao dodatni sloj nad postojećim sistemom za e-učenje. Student i nastavnik pri tome ne dobijaju samo informaciju da problem postoji, već i na koji se nastavni sadržaj odnosi, zašto je identifikovan i kojim redom ga treba savladati.

Ovi zaključci važe u okviru vrste dokaza prikupljenih u istraživanju. Evaluacija na dva predmeta podržava izvodljivost, interpretabilnost, unutrašnju stabilnost i sledljivost razvijenog pristupa, dok uzročni efekat preporuka na učenje, spoljašnja generalizacija, kriterijumska validacija procene ovladanosti i interoperabilnost sa drugim platformama ostaju otvorena pitanja, razmotrena u odeljcima 8.3 i 8.4.

Disertacija time pokazuje da personalizacija u sistemima e-učenja ne mora da se zasniva samo na agregiranoj oceni, pripadnosti grupi ili sličnosti sa drugim studentima. Moguće je razviti pristup u kome se individualna podrška zasniva na eksplicitnoj vezi između onoga što student treba da nauči, dokaza koje je tokom učenja pružio, procene njegovog trenutnog stanja i strukture sadržaja koji mu može pomoći u daljem radu. Upravo ta sledljiva veza predstavlja završni rezultat disertacije i osnovu za dalji razvoj kompetencijski zasnovanih i objašnjivih sistema za personalizovano e-učenje.

Prilog A. Prompt za generisanje objašnjivih preporuka

Tokom izvršavanja, oznaka <STUDENT_DATA_JSON> zamenjuje se strukturiranim JSON objektom koji generišu model studenta i pravilima vođen adaptivni mehanizam. JSON sadrži isključivo prethodno izračunate vrednosti modela studenta i objekte učenja koje je adaptivni mehanizam prethodno izabrao i uredio. U nastavku je dat izvorni prompt korišćen u srpskoj jezičkoj verziji aplikacije.

Prompt:

Ti si ljubazan i podržavajući akademski mentor koji se direktno obraća studentu univerziteta u vezi sa njegovim napretkom. Dobijaš podatke o studentu izvedene iz kompetencijski zasnovanog modela studenta. Napiši ohrabrujuću, detaljnu, ali lako razumljivu poruku od približno 5-8 rečenica na srpskom jeziku.

Smernice:

- Obraćaj se studentu u drugom licu, neposredno, podržavajuće i lično.
- Započni isticanjem stvarnih jakih strana studenta, koristeći podatke o jakim stranama i kompetencijama sa visokom procenom ovladanosti.
- Ako podaci ukazuju na razliku, jasno objasni razliku između **PROCENJENE OVLADANOSTI KOMPETENCIJAMA**, izvedene iz raspoloživih dokaza, i **OSTVARENOSTI AKTIVNOSTI** predviđenih za odgovarajući nivo dubine. Nemoj procenu ovladanosti predstavljati kao neposredno izmereno ili sigurno utvrđeno znanje studenta. Naglasi da neizvršena obaveza nije isto što i dokaz nepoznavanja sadržaja.
- Ako je podatak type_student prisutan, ukratko i razumljivim jezikom objasni zbog čega je student svrstan u odgovarajući ponašajni tip, na osnovu uslova navedenog u podacima. Nemoj mehanički navoditi stablo odlučivanja ili pragove, već opiši obrazac njegovog načina rada koji stoji iza te klasifikacije.

- Zatim navedi konkretne naredne korake: imenuj preporučene teme prema redosledu koji je dat u ulaznim podacima i, ako neka tema ima preduslove, objasni studentu da najpre treba da ovlada odgovarajućim preduslovom.
- Budi precizan i koristi stvarne nazive tema navedene u podacima.
- Ohrabri studenta i završi poruku motivišućim tonom.
- Nemoj izmišljati podatke, brojeve, teme ili činjenice o preporukama koje nisu sadržane u ulaznim podacima.
- Nemoj prikazivati JSON niti koristiti nabrajanja; napiši povezane i studentu razumljive rečenice.

Organizuj poruku u tačno tri dela koji odgovaraju sledećim pitanjima:

(1) **Kuda idem?** - cilj u okviru ovog predmeta;
(2) **Kako mi ide?** - trenutne jake strane i trenutno stanje;
(3) **Šta dalje?** - konkretni, uređeni naredni koraci.

Prikaži rezultat tačno u sledećem formatu, pri čemu svaka oznaka mora biti u posebnom redu i ništa ne sme prethoditi prvoj oznaci:

```
###1###
<2-3 rečenice o cilju>

###2###
<2-3 rečenice o trenutnom stanju>

###3###
<3-4 rečenice o narednim koracima>

Podaci o studentu (JSON):

<STUDENT_DATA_JSON>
```

Napiši poruku sada.

9. Literatura

1. El-Sabagh, H.A. Adaptive E-Learning Environment Based on Learning Styles and Its Impact on Development Students' Engagement. *Int. J. Educ. Technol. High. Educ.* **2021**, *18*, doi:10.1186/s41239-021-00289-4.
2. Pelánek, R. Adaptive Learning Is Hard: Challenges, Nuances, and Trade-Offs in Modeling. *Int. J. Artif. Intell. Educ.* **2024**, doi:10.1007/s40593-024-00400-6.
3. Shemshack, A.; Spector, J.M. A Systematic Literature Review of Personalized Learning Terms. *Smart Learn. Environ.* **2020**, *7*, doi:10.1186/s40561-020-00140-9.
4. Wang, X.; Maeda, Y.; Chang, H.-H. Development and Techniques in Learner Model in Adaptive E-Learning System: A Systematic Review. *Comput. Educ.* **2025**, *225*, 105184, doi:10.1016/j.compedu.2024.105184.
5. Tan, L.Y.; Hu, S.; Yeo, D.J.; Cheong, K.H. Artificial Intelligence-Enabled Adaptive Learning Platforms: A Review. *Computers and Education: Artificial Intelligence* **2025**, *9*, 100429, doi:10.1016/j.caeai.2025.100429.
6. Ilić, M.; Mikić, V.; Kopanja, L.; Vesin, B. Intelligent Techniques in E-Learning: A Literature Review. *Artif. Intell. Rev.* **2023**, doi:10.1007/s10462-023-10508-1.
7. Lu, Y.; Tong, L.; Cheng, Y. Advanced Knowledge Tracing: Incorporating Process Data and Curricula Information via an Attention-Based Framework for Accuracy and Interpretability. **2024**, doi:10.5281/ZENODO.13712553.
8. Askarbekuly, N.; Luković, I. Learning Outcomes, Assessment, and Evaluation in Educational Recommender Systems: A Systematic Review. *arXiv [cs.HC]* 2024.
9. Gašević, D.; Dawson, S.; Rogers, T.; Gasevic, D. Learning Analytics Should Not Promote One Size Fits All: The Effects of Instructional Conditions in Predicting Academic Success. *Internet High. Educ.* **2016**, *28*, 68–84, doi:10.1016/j.iheduc.2015.10.002.
10. Rienties, B.; Toetenel, L. The Impact of Learning Design on Student Behaviour, Satisfaction and Performance: A Cross-Institutional Comparison across 151 Modules. *Comput. Human Behav.* **2016**, *60*, 333–341, doi:10.1016/j.chb.2016.02.074.
11. Corbett, A.T.; Anderson, J.R. Knowledge Tracing: Modeling the Acquisition of Procedural Knowledge. *User Model. User-adapt Interact.* **1995**, *4*, 253–278, doi:10.1007/bf01099821.
12. Rahayu, N.W.; Ferdiana, R.; Kusumawardani, S.S. A Systematic Review of Ontology Use in E-Learning Recommender System. *Computers and Education: Artificial Intelligence* **2022**, *3*, 100047, doi:10.1016/j.caeai.2022.100047.
13. Tarus, J.K.; Niu, Z.; Mustafa, G. Knowledge-Based Recommendation: A Review of Ontology-Based Recommender Systems for e-Learning. *Artif. Intell. Rev.* **2018**, *50*, 21–48, doi:10.1007/s10462-017-9539-5.
14. Jović, J.; Raspopović Milić, M.; Cvetanović, S. Multidimensional Concept Map Representation of the Learning Objects Ontology Model for Personalized Learning. *Journal of Internet Technology* **2023**, *24*, 1043–1054, doi:10.53106/160792642023092405003.
15. Domazet, D. Competences-Driven and GenAI-Supported Hybrid Personalized Learning. In *Proceedings of the 16th International Conference on eLearning (eLearning 2025)*; Belgrade, Serbia; Belgrade Metropolitan University; Belgrade, Serbia, 2025.
16. Khosravi, H.; Shum, S.B.; Chen, G.; Conati, C.; Tsai, Y.-S.; Kay, J.; Knight, S.; Martinez-Maldonado, R.; Sadiq, S.; Gašević, D. Explainable Artificial Intelligence in Education. *Computers and Education: Artificial Intelligence* **2022**, *3*, 100074, doi:10.1016/j.caeai.2022.100074.

17. Kisić, E.; Raspopović Milić, M.; Jović, J.; Zdravković, N. Tracking Student Progress and Generating Personalized Recommendations Using Clustering and Explainable Artificial Intelligence. *Univers. Access Inf. Soc.* **2026**, *25*, doi:10.1007/s10209-025-01295-3.
18. Jović, J.; Cvetanović, S.; Milić, M.R.; Chandra, K. Authoring Tool for Ontology Development for Online Learning. In *Proceedings of the 9th International Conference on eLearning (eLearning-2018)*; Belgrade, Serbia, 2018; pp. 69–74.
19. Oreški, D.; Kisić, E.; Jovic, J.; Milić, M.R. Student Modeling with Clustering: Comparative Analysis of Case Studies in Two Higher Educational Institutions from Different Countries. In *The Fourteenth International Conference on E-Learning*; 2023.
20. Jović, J.L.; Domazet, D.S.; Zdravković, N. A Competence-Based Architecture for Personalized Adaptive Learning. *Appl. Sci. (Basel)* **2026**, *16*, 9992, doi:10.3390/app16209992.
21. Madunić, M. Through Growth to Achievement: Report of the Review to Achieve Educational Excellence in Australian Schools - Prikaz Knjige. *Acta Iadert.* **2021**, *18*, doi:10.15291/ai.3404.
22. Peng, H.; Ma, S.; Spector, J.M. Personalized Adaptive Learning: An Emerging Pedagogical Approach Enabled by a Smart Learning Environment. *Smart Learn. Environ.* **2019**, *6*, doi:10.1186/s40561-019-0089-y.
23. Zhong, L. A Systematic Review of Personalized Learning in Higher Education: Learning Content Structure, Learning Materials Sequence, and Learning Readiness Support. *Interact. Learn. Environ.* **2023**, *31*, 7053–7073, doi:10.1080/10494820.2022.2061006.
24. Gunawardena, M.; Bishop, P.; Aviruppola, K. Personalized Learning: The Simple, the Complicated, the Complex and the Chaotic. *Teach. Teach. Educ.* **2024**, *139*, 104429, doi:10.1016/j.tate.2023.104429.
25. Dewey, J. *The Child and the Curriculum (1902)*; Literary Licensing, 2014; ISBN 9781498161183.
26. Bloom, B.S. Recent Developments in Mastery Learning[1]. *Educ. Psychol.* **1973**, *10*, 53–57, doi:10.1080/00461527309529091.
27. (1) Rationalist English Educators (2) the Montessori Method: Scientific Pedagogy as Applied to Child Education in “the Children’s Houses” (3) the Evolution of Educational Theory. *Nature* **1912**, *90*, 99–100, doi:10.1038/090099a0.
28. Unesco, I. *Reaching out to All Learners: A Resource Pack for Supporting Inclusive Education*; 2016;
29. McLeod, S.A. Personalized Learning Available online: https://www.simplypsychology.org/personalized-learning.html (accessed on 7 June 2023).
30. Spector, J.M. Conceptualizing the Emerging Field of Smart Learning Environments. *Smart Learn. Environ.* **2014**, *1*, doi:10.1186/s40561-014-0002-7.
31. Halverson, R. Personalization in Practice: Observations from the Field. *Wisconsin Center for Education Research* **2015**.
32. Chen, X.; Zou, D.; Xie, H.; Cheng, G.; Liu, C. Two Decades of Artificial Intelligence in Education. *Educational Technology & Society* **2022**, *25*, 28–47.
33. Student Modelling in Adaptive E-Learning Systems. *Knowl. Manag. E-learn.: Int. J.* **2011**, 342–355, doi:10.34105/j.kmel.2011.03.025.
34. Becker, P.; Cummins, M.; Davis, A.; Freeman, A.; Giesinger, C.; Ananthanarayanan, V. *Higher Education Edition (The New Media Consortium)*; Austin, 2017;
35. Shute, V.; Towle, B. Adaptive E-Learning. In *Educational Psychologist*; Routledge, 2018; pp. 105–114 ISBN 9780203764664.
36. du Plooy, E.; Casteleijn, D.; Franzsen, D. Personalized Adaptive Learning in Higher Education: A Scoping Review of Key Characteristics and Impact on Academic

Performance and Engagement. *Heliyon* **2024**, *10*, e39630, doi:10.1016/j.heliyon.2024.e39630.
37. Cui, W.; Xue, Z.; Thai, K.-P. Performance Comparison of an AI-Based Adaptive Learning System in China. In Proceedings of the 2018 Chinese Automation Congress (CAC); IEEE, November 2018.
38. Gligorea, I.; Cioca, M.; Oancea, R.; Gorski, A.-T.; Gorski, H.; Tudorache, P. Adaptive Learning Using Artificial Intelligence in E-Learning: A Literature Review. *Educ. Sci. (Basel)* **2023**, *13*, 1216, doi:10.3390/educsci13121216.
39. Dziuban, C.; Howlin, C.; Moskal, P.; Johnson, C.; Parker, L.; Campbell, M. Adaptive Learning: A Stabilizing Influence across Disciplines and Universities. *Online Learn.* **2018**, *22*, doi:10.24059/olj.v22i3.1465.
40. Cavanagh, T.; Chen, B.; Lahcen, R.A.M.; Paradiso, J. Constructing a Design Framework and Pedagogical Approach for Adaptive Learning in Higher Education: A Practitioner's Perspective. *Int. Rev. Res. Open Distrib. Learn.* **2020**, *21*, 172–196, doi:10.19173/irrodl.v21i1.4557.
41. Mirata, V.; Hirt, F.; Bergamin, P.; van der Westhuizen, C. Challenges and Contexts in Establishing Adaptive Learning in Higher Education: Findings from a Delphi Study. *Int. J. Educ. Technol. High. Educ.* **2020**, *17*, doi:10.1186/s41239-020-00209-y.
42. Erümit, A.K.; Çetin, İ. Design Framework of Adaptive Intelligent Tutoring Systems. *Educ. Inf. Technol.* **2020**, *25*, 4477–4500, doi:10.1007/s10639-020-10182-8.
43. Jović, J.; Gavrilović, N.; Domazet, D. Intelligent Tutoring Systems: A Systematic Review. In *Proceedings of the 10th International Conference on e-Learning (eLearning-2019)*; Belgrade, 2019.
44. Mikić, V.; Ilić, M.; Kopanja, L.; Vesin, B. Personalisation Methods in e-learning-A Literature Review. *Comput. Appl. Eng. Educ.* **2022**, *30*, 1931–1958, doi:10.1002/cae.22566.
45. Shemshack, A.; Kinshuk; Spector, J.M. A Comprehensive Analysis of Personalized Learning Components. *J. Comput. Educ.* **2021**, *8*, 485–503, doi:10.1007/s40692-021-00188-7.
46. Talaghzi, J.; Bennane, A.; Himmi, M.M.; Bellafkih, M.; Benomar, A. Online Adaptive Learning. In Proceedings of the Proceedings of the 13th International Conference on Intelligent Systems: Theories and Applications; ACM: New York, NY, USA, September 23 2020.
47. Sucheta, V.; Kolekar, R.M.; Pai, M.; Pai, M. Adaptive User Interface for Moodle Based E-Learning System Using Learning Styles. *Procedia Computer Science* **2018**, *135*, 606–615.
48. Rani, M.; Nayak, R.; Vyas, O.P. An Ontology-Based Adaptive Personalized E-Learning System, Assisted by Software Agents on Cloud Storage. *arXiv [cs.CY]* 2017.
49. Madani, Y.; Erritali, M.; Bengourram, J.; Sailhan, F. Social Collaborative Filtering Approach for Recommending Courses in an E-Learning Platform. *Procedia Comput. Sci.* **2019**, *151*, 1164–1169, doi:10.1016/j.procs.2019.04.166.
50. Gulzar, Z.; Leema, A.A.; Deepak, G. PCRS: Personalized Course Recommender System Based on Hybrid Approach. *Procedia Comput. Sci.* **2018**, *125*, 518–524, doi:10.1016/j.procs.2017.12.067.
51. Ennouamani, S.; Mahani, Z. An Overview of Adaptive E-Learning Systems. In Proceedings of the 2017 Eighth International Conference on Intelligent Computing and Information Systems (ICICIS); IEEE, December 2017; pp. 342–347.
52. Lumertz, P.R.; Ribeiro, L.; Duarte, L.M. User Interfaces Metamodel Based on Graphs. *J. Vis. Lang. Comput.* **2016**, *32*, 1–34, doi:10.1016/j.jvlc.2015.10.026.

53. Hssina, B.; Erritali, M. A Personalized Pedagogical Objectives Based on a Genetic Algorithm in an Adaptive Learning System. *Procedia Comput. Sci.* **2019**, *151*, 1152–1157, doi:10.1016/j.procs.2019.04.164.
54. Dharshini, A.; Chandrakumarmangalam, S.; Arthi, G. Ant Colony Optimization for Competency Based Learning Objects Sequencing in E-Learning. *Applied Mathematics and Computation* **2015**, *263*, 332–341.
55. Caputi, V.; Garrido, A. Student-Oriented Planning of e-Learning Contents for Moodle. *J. Netw. Comput. Appl.* **2015**, *53*, 115–127, doi:10.1016/j.jnca.2015.04.001.
56. Radwan, N. An Adaptive Learning Management System Based on Learner's Learning Style. *International Arab Journal of e-Technology* **2014**, *3*, 228–234.
57. Ali, N.A.; Eassa, F.; Hamed, E. Personalized Learning Style for Adaptive E-Learning System. *International Journal of Advanced Trends in Computer Science and Engineering* **2019**, *8*, 223–230.
58. Anitha, D.; Kavitha, D. KLSAS-An Adaptive Dynamic Learning Environment Based on Knowledge Level and Learning Style. *Computer Applications in Engineering Education* **2018**.
59. Bradac, V.; Walek, B. A Comprehensive Adaptive System for E-Learning of Foreign Languages. *Expert Syst. Appl.* **2017**, *90*, 414–426, doi:10.1016/j.eswa.2017.08.019.
60. Nafea, S. *An Adaptive Learning Ontological Framework Based on Learning Styles and Teaching Strategies*; 2017;
61. Néstor, D.; Duque-Méndez, V.; Tabares-Morales, D.A. Intelligent Agents System for Adaptive Assessment. In *Methodologies and Intelligent Systems for Technology Enhanced Learning, 9th International Conference (Advances in Intelligent Systems and Computing)*; 2020; pp. 164–172.
62. Louhab, F.E.; Bahnasse, A.; Talea, M. Towards an Adaptive Formative Assessment in Context-Aware Mobile Learning. *Procedia Comput. Sci.* **2018**, *135*, 441–448, doi:10.1016/j.procs.2018.08.195.
63. Yang, A.C.M.; Flanagan, B.; Ogata, H. Adaptive Formative Assessment System Based on Computerized Adaptive Testing and the Learning Memory Cycle for Personalized Learning. *Computers and Education: Artificial Intelligence* **2022**, *3*, 100104, doi:10.1016/j.caeai.2022.100104.
64. Mavroudi, A.; Giannakos, M.; Krogstie, J. Supporting Adaptive Learning Pathways through the Use of Learning Analytics: Developments, Challenges and Future Opportunities. *Interact. Learn. Environ.* **2018**, *26*, 206–220, doi:10.1080/10494820.2017.1292531.
65. Alhalalmeh, Z.R.; Fouda, Y.M.; Rushdi, M.A.; El-Mikkawy, M. Automating Assessment and Providing Personalized Feedback in E-Learning: The Power of Template Matching. *Sustainability* **2023**, *15*, 14234, doi:10.3390/su151914234.
66. Derntl, M.; Hummel, K.A. Modeling Context-Aware e-Learning Scenarios. In Proceedings of the Third IEEE International Conference on Pervasive Computing and Communications Workshops; IEEE, 2005.
67. Jović, J.; Raspopović Milić, M.; Domazet, D.; Chandra, K. Educational Data Mining and Learning Analytics Tools for Online Learning. In *Proceedings of the 12th International Conference on e-Learning (eLearning-2021)*; Belgrade, 2021.
68. Tetzlaff, L.; Schmiedek, F.; Brod, G. Developing Personalized Education: A Dynamic Framework. *Educ. Psychol. Rev.* **2021**, *33*, 863–882, doi:10.1007/s10648-020-09570-w.
69. Brusilovsky, P.; Millán, E. User Models for Adaptive Hypermedia and Adaptive Educational Systems. In *The Adaptive Web*; Springer Berlin Heidelberg: Berlin, Heidelberg, 2007; pp. 3–53 ISBN 9783540720782.

70. Jović, J.; Milić, M.; Cvetanović, S.; Gavrilović, N.; Domazet, D.; Nikolić, R.; Vejar, E.S. Intelligent Recommender System for Personalized Online Learning (IREP). In *Proceedings of the 11th International Conference on eLearning (eLearning-2020)*; Belgrade, Serbia, 2020; pp. 22–29.
71. Vesin, B.; Ivanovic, M. Modern Educational Tools. In *Proceedings of PRIM2004, 16th Conference on Applied Mathematics*; Budva, Montenegro, 2004; pp. 293–302.
72. Premlatha, K.R.; Geetha, T.V. Learning Content Design and Learner Adaptation for Adaptive E-Learning Environment: A Survey. *Artif. Intell. Rev.* **2015**, *44*, 443–465, doi:10.1007/s10462-015-9432-z.
73. Pelánek, R. Managing Items and Knowledge Components: Domain Modeling in Practice. *Educ. Technol. Res. Dev.* **2020**, *68*, 529–550, doi:10.1007/s11423-019-09716-w.
74. Martin, F.; Chen, Y.; Moore, R.L.; Westine, C.D. Systematic Review of Adaptive Learning Research Designs, Context, Strategies, and Technologies from 2009 to 2018. *Educ. Technol. Res. Dev.* **2020**, *68*, 1903–1929, doi:10.1007/s11423-020-09793-2.
75. Vandewaetere, M.; Desmet, P.; Clarebout, G. The Contribution of Learner Characteristics in the Development of Computer-Based Adaptive Learning Environments. *Comput. Human Behav.* **2011**, *27*, 118–130, doi:10.1016/j.chb.2010.07.038.
76. Artin, F.; Markant, D. *The SAGE Encyclopedia of Higher Education*; David, M.E., Amey, M.J., Eds.; Sage: London, 2019;
77. Simon, B. Do E-Learning Standards Meet Their Challenges? In *Proceedings des Workshops' Standardisierung im eLearning*; Frankfurt, Deutschland, 2002.
78. Wiley, D.A. *The Instructional Use of Learning Objects. Agency for Instructional Technology*; Bloomington, Indiana, 2002;
79. Barker, P. What Is IEEE Learning Object Metadata/IMS Learning Resource Metadata? **2005**, *1*.
80. *The Learning Object Metadata Standard-IEEE Learning Technology Standards Committee*; IEEE;
81. Pitkanen, S.H.; Silander, P. Criteria for Pedagogical Reusability of Learning Objects Enabling Adaptation and Individualised Learning Processes. In Proceedings of the IEEE International Conference on Advanced Learning Technologies, 2004. Proceedings; IEEE, 2004.
82. Noor, S.F.M.; Yusof, N.; Hashim, S.Z.M. Creating Granular Learning Object towards Reusability of Learning Object in E-Learning Context. In Proceedings of the Proceedings of the 2011 International Conference on Electrical Engineering and Informatics; IEEE, July 2011.
83. Singh, R.G.; Bernard, M.; Gardler, R. Creating Sharable Learning Objects from Existing Digital Course Content. In Proceedings of the Proceedings of the 2004 workshop on Computer architecture education held in conjunction with the 31st International Symposium on Computer Architecture - WCAE '04; ACM Press: New York, New York, USA, 2004.
84. Wiley, D.A. Connecting Learning Objects to Instructional Design Theory: A Definition, a Metaphor, and a Taxonomy. *The instructional use of learning objects* **2000**, 1–35.
85. Griffith, R. *Academic Advanced Distributed Learning Co-Lab Publication*; 2003;
86. Ostyn, C. SCORM 1.2 Content Cookbook for Developers Available online: https://scorm.com/wp-content/assets/cookbook/CookingUpASCORM_v1_2.pdf.
87. *OASIS Darwin Information Typing Architecture (DITA) Architectural Specification*;
88. Raspopovic, M.; Cvetanovic, S.; Jankulovic, A. Challenges of Transitioning to E-Learning System with Learning Objects Capabilities. *Int. Rev. Res. Open Distrib. Learn.* **2016**, *17*, doi:10.19173/irrodl.v17i1.2172.

89. Cohen, E.; Nycz, M. Learning Objects and E-Learning: An Informing Science Perspective. *Interdiscip. J. E-ski. Lifelong Learn.* **2006**, *2*, 023–034, doi:10.28945/399.
90. Nash, S. Learning Objects, Learning Object Repositories, and Learning Theory: Preliminary Best Practices for Online Courses. *Interdisciplinary Journal of E-Learning and Learning Objects* **2005**, 217–228.
91. Wright, P.; Jochems, W.; van Merriënboer, J.; Koper, R.; van Merrienboer, J. Integrated E-Learning: Implications for Pedagogy, Technology & Organization. *Can. J. Educ.* **2005**, *28*, 227, doi:10.2307/1602168.
92. Joshi, S.; Thakur, N.; Mehrotra, D. Schemes and Practices of Learning Object Repository: A Literature Review. *International Journal of Computer Applications* **2013**.
93. Verdonck, M.; Gailly, F.; de Cesare, S.; Poels, G. Ontology-Driven Conceptual Modeling: A Systematic Literature Mapping and Review. *Appl. Ontol.* **2015**, *10*, 197–227, doi:10.3233/ao-150154.
94. Asthana, A. Multimedia in Education. In *Encyclopedia of Multimedia*; Springer US: Boston, MA, 2008; pp. 549–554 ISBN 9780387747248.
95. May, M.; Hussmann, P.M.; Jensen, A.S.; Rootzen, H.; Markvorsen, S.; Schmidt, K.; Enemark, S. Constraints on Reusability of Learning Objects: Didactic Aspects of Modular e-Learning in Engineering Education. In *2nd International Conference on Computer Supported Education*; 2010; pp. 325–332.
96. Hernandez, N.; Mothe, J.; Ralalason, B.; Ramamonjisoa, B.; Stolf, P. A Model to Represent the Facets of Learning Object. *Interdiscip. J. E-ski. Lifelong Learn.* **2008**, *4*, 065–082, doi:10.28945/367.
97. Gaeta, M.; Miranda, S.; Orciuoli, F.; Paolozzi, S.; Poce, A. An Approach To Personalized E-Learning. *Journal of Education, Informatics & Cybernetics* **2013**.
98. Noy, N.F.; Mcguinness, D.L. *Ontology Development 101: A Guide to Creating Your First Ontology*; Stanford, CA, 2001;
99. Neri, M.A.; Colombetti, M. Ontology-Based Learning Objects Search and Courses Generation. *Appl. Artif. Intell.* **2009**, *23*, 233–260, doi:10.1080/08839510802715134.
100. Paquette, G.; Marino, O.; Bejaoui, R. A New Competency Ontology for Learning Environments Personalization. *Smart Learn. Environ.* **2021**, *8*, doi:10.1186/s40561-021-00160-z.
101. Ilkou, E.; Abu-Rasheed, H.; Tavakoli, M.; Hakimov, S.; Kismihók, G.; Auer, S.; Nejdl, W. EduCOR: An Educational and Career-Oriented Recommendation Ontology. In *The Semantic Web – ISWC 2021*; Lecture Notes in Computer Science; Springer International Publishing: Cham, 2021; pp. 546–562.
102. Zouri, M.; Ferworn, A. An Ontology-Based Approach for Curriculum Mapping in Higher Education. In Proceedings of the 2021 IEEE 11th Annual Computing and Communication Workshop and Conference (CCWC); IEEE, January 27 2021.
103. Piriyapongpipat, P.; Goldin, S.; Ditcharoen, N. An Alternative Approach to Ontology-Based Curriculum Development in Higher Education. *Smart Learn. Environ.* **2024**, *11*, doi:10.1186/s40561-024-00307-8.
104. Milosz, M.; Nazyrova, A.; Mukanova, A.; Bekmanova, G.; Kuzin, D.; Aimicheva, G. Ontological Approach for Competency-Based Curriculum Analysis. *Heliyon* **2024**, *10*, e29046, doi:10.1016/j.heliyon.2024.e29046.
105. Freeman, L.A.; Urbaczewski, A. Using Concept Maps to Assess Students' Understanding of Information Systems. *Journal of Information Systems Education* **2020**, *12*.
106. Okafor, P.N.; Udeani, U. The Effect of Concept Mapping Instructional Strategy on the Biology Achievement of Senior Secondary School Slow Learners. *Journal of Emerging Trends in Educational Research and policy studies* **2012**, *3*, 137–142.

107. Novak, J.D.; Gowin, D.B.; Kahle, J.B. Learning about Learning. In *Learning How to Learn*; Cambridge University Press: Cambridge, 1984; pp. 1–14 ISBN 9780521265072.
108. Chung, H.S.; Kim, J.M. Ontology Design for Creating Adaptive Learning Path in E-Learning Environment. *Proceedings of the International MultiConference of Engineers and Computer Scientists* **2012**, *1*.
109. Huang, H.-S.; Chiou, C.-C.; Chiang, H.-K.; Lai, S.-H.; Huang, C.-Y.; Chou, Y.-Y. Effects of Multidimensional Concept Maps on Fourth Graders' Learning in Web-Based Computer Course. *Comput. Educ.* **2012**, *58*, 863–873, doi:10.1016/j.compedu.2011.10.016.
110. Chiou, C.-C. The Effect of Concept Mapping on Students' Learning Achievements and Interests. *Innov. Educ. Teach. Int.* **2008**, *45*, 375–387, doi:10.1080/14703290802377240.
111. Puntambekar, S.; Stylianou, A.; Hübscher, R. Improving Navigation and Learning in Hypertext Environments with Navigable Concept Maps. *Hum.-Comput. Interact.* **2003**, *18*, 395–428, doi:10.1207/s15327051hci1804_3.
112. Kulkarni, P.V.; Rai, S.; Kale, R. Recommender System in eLearning: A Survey. In *Proceeding of International Conference on Computational Science and Applications*; Springer Singapore: Singapore, 2020; pp. 119–126 ISBN 9789811507892.
113. Roy, D.; Dutta, M. A Systematic Review and Research Perspective on Recommender Systems. *J. Big Data* **2022**, *9*, doi:10.1186/s40537-022-00592-5.
114. Sharma, R.; Gopalani, D.; Meena, Y. Collaborative Filtering-Based Recommender System: Approaches and Research Challenges. In Proceedings of the 2017 3rd International Conference on Computational Intelligence & Communication Technology (CICT); IEEE, February 2017.
115. Chen, Y.-H.; Tseng, C.-H.; Huang, C.-L.; Deng, L.Y.; Lee, W.-C. Recommendation System Based on Rule-Space Model of Two-Phase Blue-Red Tree and Optimized Learning Path with Multimedia Learning and Cognitive Assessment Evaluation. *Multimed. Tools Appl.* **2017**, *76*, 18237–18264, doi:10.1007/s11042-016-3717-3.
116. Huo, Y.; Wong, D.F.; Ni, L.M.; Chao, L.S.; Zhang, J. Knowledge Modeling via Contextualized Representations for LSTM-Based Personalized Exercise Recommendation. *Inf. Sci. (Ny)* **2020**, *523*, 266–278, doi:10.1016/j.ins.2020.03.014.
117. Yago, H.; Clemente, J.; Rodriguez, D. Competence-Based Recommender Systems: A Systematic Literature Review. *Behav. Inf. Technol.* **2018**, *37*, 958–977, doi:10.1080/0144929x.2018.1496276.
118. Clemente, J.; Yago, H.; de Pedro-Carracedo, J.; Bueno, J. A Proposal for an Adaptive Recommender System Based on Competences and Ontologies. *Expert Syst. Appl.* **2022**, *208*, 118171, doi:10.1016/j.eswa.2022.118171.
119. Capuano, N.; Gaeta, M.; Marengo, A.; Miranda, S.; Orciuoli, F.; Ritrovato, P. LIA: An Intelligent Advisor for e-Learning. *Interact. Learn. Environ.* **2009**, *17*, 221–239, doi:10.1080/10494820902924912.
120. Kontopoulos, E.; Vrakas, D.; Kokkoras, F.; Bassiliades, N.; Vlahavas, I. An Ontology-Based Planning System for e-Course Generation. *Expert Syst. Appl.* **2008**, *35*, 398–406, doi:10.1016/j.eswa.2007.07.034.
121. Amane, M.; Aissaoui, K.; Berrada, M. ERSDO: E-Learning Recommender System Based on Dynamic Ontology. *Educ. Inf. Technol.* **2022**, *27*, 7549–7561, doi:10.1007/s10639-022-10914-y.
122. Yago, H.; Clemente, J.; Rodriguez, D.; Fernandez-de-Cordoba, P. ON-SMMILE: Ontology Network-Based Student Model for MultIple Learning Environments. *Data Knowl. Eng.* **2018**, *115*, 48–67, doi:10.1016/j.datak.2018.02.002.

123. Santos, O.C.; Boticario, J.G. Requirements for Semantic Educational Recommender Systems in Formal E-Learning Scenarios. *Algorithms* **2011**, *4*, 131–154, doi:10.3390/a4030131.
124. Santos, O.C.; Boticario, J. Affective Issues in Semantic Educational Recommender Systems. **2012**, 71–82.
125. Imran, H.; Belghis-Zadeh, M.; Chang, T.-W.; Kinshuk; Graf, S. PLORS: A Personalized Learning Object Recommender System. *Vietnam J. Comput. Sci.* **2016**, *3*, 3–13, doi:10.1007/s40595-015-0049-6.
126. Bourkoukou, O.; Computer Sciences, Cadi Ayyad University, Marrakesh, Morocco; Bachari, E.E.; Adnani, M.E. A Personalized E-Learning Based on Recommender System. *Int. J. Learn. Teach.* **2016**, doi:10.18178/ijlt.2.2.99-103.
127. Tane, J.; Schmitz, C.; Stumme, G.; Staab, S.; Studer, R. *The Courseware Watchdog: An Ontology-Based Tool for Finding and Organizing Learning Material*; 2003;
128. Nejdl, W. *Personalized Access to Distributed Learning Resources (PADLR)*; 2001;
129. Gaeta, M.; Orciuoli, F.; Ritrovato, P. Advanced Ontology Management System for Personalised E-Learning. *Knowl. Based Syst.* **2009**, *22*, 292–301, doi:10.1016/j.knosys.2009.01.006.
130. Lee, M.-C.; Ye, D.Y.; Wang, T.I. Java Learning Object Ontology. In Proceedings of the Fifth IEEE International Conference on Advanced Learning Technologies (ICALT'05); IEEE, 2005.
131. Demertzi, V.; Demertzis, K. A Hybrid Adaptive Educational eLearning Project Based on Ontologies Matching and Recommendation System. **2020**, doi:10.48550/ARXIV.2007.14771.
132. Zhang, Y.; Chen, X. Explainable Recommendation: A Survey and New Perspectives. *Found. Trends® Inf. Retr.* **2020**, *14*, 1–101, doi:10.1561/1500000066.
133. Pesovski, I.; Bogdanova, A.M.; Trajkovik, V. Systematic Review of the Published Explainable Educational Recommendation Systems. In Proceedings of the 2022 20th International Conference on Information Technology Based Higher Education and Training (ITHET); IEEE, November 7 2022; pp. 1–8.
134. Abyaa, A.; Khalidi Idrissi, M.; Bennani, S. Learner Modelling: Systematic Review of the Literature from the Last 5 Years. *Educ. Technol. Res. Dev.* **2019**, *67*, 1105–1143, doi:10.1007/s11423-018-09644-1.
135. Jeremić, Z.; Jovanović, J.; Gašević, D. Student Modeling and Assessment in Intelligent Tutoring of Software Patterns. *Expert Syst. Appl.* **2012**, *39*, 210–222, doi:10.1016/j.eswa.2011.07.010.
136. Chrysafiadi, K.; Virvou, M. Student Modeling Approaches: A Literature Review for the Last Decade. *Expert Syst. Appl.* **2013**, *40*, 4715–4729, doi:10.1016/j.eswa.2013.02.007.
137. Kaser, T.; Klingler, S.; Schwing, A.G.; Gross, M. Dynamic Bayesian Networks for Student Modeling. *IEEE Trans. Learn. Technol.* **2017**, *10*, 450–462, doi:10.1109/tlt.2017.2689017.
138. Yang, G.; Kinshuk, K.; Graf, S. A Practical Student Model for a Locationaware and Context-Sensitive Personalized Adaptive Learning System. In *2010 International Conference on Technology for Education*; IEEE, 2010; pp. 130–133.
139. Vagale, V.; Niedrite, L. Learner Model's Utilization in the E-Learning Environments. In *DB&Local Proceedings*; 2012; pp. 162–174.
140. Felder, R.M. How Students Learn: Adapting Teaching Styles to Learning Styles. In Proceedings of the Proceedings Frontiers in Education Conference; IEEE, 2003.
141. Kirschner, P.A. Stop Propagating the Learning Styles Myth. *Comput. Educ.* **2017**, *106*, 166–171, doi:10.1016/j.compedu.2016.12.006.

142. Prashnig, B. *Power of Diversity: New Ways of Learning and Teaching through Learning Styles*; A&C Black: London, 2004;
143. Chaplot, D.S.; Rhim, E.; Kim, J. Personalized Adaptive Learning Using Neural Networks. In Proceedings of the Proceedings of the Third (2016) ACM Conference on Learning @ Scale; ACM: New York, NY, USA, April 25 2016.
144. Papamitsiou, Z.; Economides, A.A. Student Modeling in Real-Time during Self-Assessment Using Stream Mining Techniques. In Proceedings of the 2017 IEEE 17th International Conference on Advanced Learning Technologies (ICALT); IEEE, July 2017.
145. Pirolli, P.; Kairam, S. A Knowledge-Tracing Model of Learning from a Social Tagging System. *User Model. User-adapt Interact.* **2013**, *23*, 139–168, doi:10.1007/s11257-012-9132-1.
146. Bakry, M.R.; Faculty of Computers and Artificial Intelligence, Beni-Suef University, Egypt A Survey of Psychological Personality Classification Approaches. *Futur. Comput. Inform. J.* **2020**, *4*, 79–89, doi:10.54623/fue.fcij.4.2.3.
147. Heinström, J. The Impact of Personality and Approaches to Learning on Information Behaviour. *Information Research* **2000**, *5*.
148. Noftle, E.E.; Robins, R.W. Personality Predictors of Academic Outcomes: Big Fve Correlates of GPA and SAT Scores. *Journal of Personality and Social Psychology* **2007**, *93*.
149. Caprara, G.V.; Vecchione, M.; Alessandri, G.; Gerbino, M.; Barbaranelli, C. The Contribution of Personality Traits and Self-Efcacy Beliefs to Academic Achievement: A Longitudinal Study. *British Journal of Educational Psychology* **2011**, *81*, 78–96.
150. Myers, I.B.; Mccaulley, M.H. *Manual: A Guide to the Development and Use of the Myers-Briggs Type Indicator*; Consulting Psychologists Press: Palo Alto, CA, 1985;
151. Keshtkar, F.; Burkett, C.; Li, H.; Graesser, A.C. Using Data Mining Techniques to Detect the Personality of Players in an Educational Game. In *Educational Data Mining*; Studies in computational intelligence; Springer International Publishing: Cham, 2014; pp. 125–150 ISBN 9783319027371.
152. Oseguera, L.; Conchas, G.Q.; Mosqueda, E. Beyond Family and Ethnic Culture: Understanding the Preconditions for the Potential Realization of Social Capital. *Youth and Society* **2011**, *43*, 1136–1166.
153. Lu, J.; Churchill, D. The Efect of Social Interaction on Learning Engagement in a Social Networking Environment. *Interactive Learning Environments* **2014**, *22*, 401–417.
154. Kožuh, I.; Jeremić, Z.; Sarjaš, A.; Bele, J.L.; Devedžić, V.; Debevc, M. Social Presence and Interaction in Learning Environments: The Efect on Student Success. *Journal of Educational Technology and Society* **2015**, *18*.
155. Zhang, D.J.; Allon, G.; Van Mieghem, J.A. Does Social Interaction Improve Learning Outcomes? Evidence from Feld Experiments on Massive Open Online Courses. *Manufacturing and Service Operations Management* **2017**, *19*, 347–367.
156. Sek, Y.; McKay, E.; Deng, H. A Conceptual Framework for Enhancing the Motivation in an Open Learner Model Learning Environment. In Proceedings of the 2014 IEEE Conference on e-Learning, e-Management and e-Services (IC3e); IEEE, December 2014.
157. Huang, W.; Huang, W.; Diefes-Dux, H.; Imbrie, P.K. A Preliminary Validation of Attention, Relevance, Confdence and Satisfaction Model-Based Instructional Material Motivational Survey in a Computer-Based Tutorial Setting. *British Journal of Educational Technology* **2006**, *37*, 243–259.
158. Valdes, B.; Ramirez, C.; Ramirez, J. Sharing Student Models That Use Machine Learning. In *Lecture Notes in Computer Science*; Lecture notes in computer science; Springer International Publishing: Cham, 2015; pp. 877–880 ISBN 9783319197722.

159. Koh, C. Understanding and Facilitating Learning for the Net Generation and Twenty-First-Century Learners through Motivation, Leadership and Curriculum Design. In *Motivation, Leadership and Curriculum design*; Springer Singapore: Singapore, 2015; pp. 1–10 ISBN 9789812872296.
160. Robles Mucho, J.L.; Andrade-Girón, D.C.; Benites-Tirado, V.R.; Quispe-Maquera, N.B.; Ayala-Jara, C.; Tito Chura, H.E.; Luna-Victoria, F.M.; Laura-De La Cruz, K.M.; Rivera-Lozada, O.; Cerna Salcedo, A.A.; et al. Open Learner Models and Pedagogical Strategies in Higher Education: A Meta-Synthesis of Approaches to Self-Regulated Learning. *Front. Educ.* **2026**, *10*, doi:10.3389/feduc.2025.1760183.
161. Council Recommendation of 22 May 2018 on Key Competences for Lifelong Learning (2018/C 189/01). *Official Journal of the European Union* **2018**, *189*, 1–13.
162. Vištica, M.; Grubišic, A.; Žitko, B. Applying Graph Sampling Methods on Student Model Initialization in Intelligent Tutoring Systems. *Int. J. Inf. Learn. Technol.* **2016**, *33*, 202–218, doi:10.1108/ijilt-03-2016-0011.
163. Pelánek, R. Bayesian Knowledge Tracing, Logistic Models, and beyond: An Overview of Learner Modeling Techniques. *User Model. User-adapt Interact.* **2017**, *27*, 313–350, doi:10.1007/s11257-017-9193-2.
164. Hawkins, W.J.; Hefernan, N.T. Using Similarity to the Previous Problem to Improve Bayesian Knowledge Tracing. In *EDM (Workshops)*; 2014.
165. Hernández, Y.; Cervantes-Salgado, M.; Pérez-Ramírez, M.; Mejía-Lavalle, M. Data-Driven Construction of a Student Model Using Bayesian Networks in an Electrical Domain. In *Advances in Soft Computing*; Lecture notes in computer science; Springer International Publishing: Cham, 2017; pp. 481–490 ISBN 9783319624273.
166. Nedungadi, P.; Remya, M.S. Incorporating Forgetting in the Personalized, Clustered, Bayesian Knowledge Tracing (PC-BKT) Model. In Proceedings of the 2015 International Conference on Cognitive Computing and Information Processing(CCIP); IEEE, March 2015.
167. Piech, C.; Spencer, J.; Huang, J.; Ganguli, S.; Sahami, M.; Guibas, L.; Sohl-Dickstein, J. Deep Knowledge Tracing. *arXiv [cs.AI]* 2015.
168. Khajah, M.; Lindsey, R.V.; Mozer, M.C. How Deep Is Knowledge Tracing? *arXiv [cs.AI]* 2016.
169. Shen, S.; Liu, Q.; Huang, Z.; Zheng, Y.; Yin, M.; Wang, M.; Chen, E. A Survey of Knowledge Tracing: Models, Variants, and Applications. *IEEE Trans. Learn. Technol.* **2024**, *17*, 1858–1879, doi:10.1109/tlt.2024.3383325.
170. Liu, Z.; Guo, T.; Liang, Q.; Hou, M.; Zhan, B.; Tang, J.; Luo, W.; Weng, J. Deep Learning Based Knowledge Tracing: A Review, a Tool and Empirical Studies. *IEEE Trans. Knowl. Data Eng.* **2025**, *37*, 4512–4536, doi:10.1109/tkde.2025.3552759.
171. Neubauer, K.; Rudolph, Y.; Brefeld, U. Principled Transformers for Predictive Performance in Knowledge Tracing. **2026**, doi:10.5281/ZENODO.18518653.
172. Labra, C.; Santos, O.C. Theory-Based Interpretability in Deep Knowledge Tracing via Grounded Transformers. *Appl. Sci. (Basel)* **2026**, *16*, 3138, doi:10.3390/app16073138.
173. Yao, S.; Song, Y.; Liu, Y.; Chen, J.; Zhao, D.; Wang, X. ANT-KT: Adaptive NAS Transformers for Knowledge Tracing. *Electronics (Basel)* **2025**, *14*, 4148, doi:10.3390/electronics14214148.
174. Lin, C.; Shen, S.; Chi, M. Incorporating Student Response Time and Tutor Instructional Interventions into Student Modeling. In Proceedings of the Proceedings of the 2016 Conference on User Modeling Adaptation and Personalization; ACM: New York, NY, USA, July 13 2016.

175. Reddy, P.D.; Sasikumar, M. Student Model for an Intelligent Language Tutoring System. In Proceedings of the 2014 IEEE 14th International Conference on Advanced Learning Technologies; IEEE, July 2014.
176. Li, Y.; Hu, Q. Research on Student Modeling of Intelligent Learning System Based on CMA Mechanism. In Proceedings of the Proceedings of 2013 3rd International Conference on Computer Science and Network Technology; IEEE, October 2013.
177. Adda, S.A.; Amar, B. The Impact of Digital Library in Detecting of Learning Difficulties. In Proceedings of the 2014 4th International Symposium ISKO-Maghreb: Concepts and Tools for knowledge Management (ISKO-Maghreb); IEEE, November 2014.
178. Heacox, D. *Differentiating Instruction in the Regular Classroom: How to Reach and Teach All Learners*; Free Spirit Publishing: Minneapolis, MN, 2012;
179. Furtak, E.M.; Kiemer, K.; Circi, R.K.; Swanson, R.; de León, V.; Morrison, D.; Heredia, S.C. Teachers' Formative Assessment Abilities and Their Relationship to Student Learning: Findings from a Four-Year Intervention Study. *Instr. Sci.* **2016**, *44*, 267–291, doi:10.1007/s11251-016-9371-3.
180. Khursheed, S.; Shahid, M. To Analyze the Impact of Formative Assessment in Fostering the Students Learning Competencies. *Voyage Journal of Educational Sciences* **2023**, *3*, 184–206, doi:10.58622/vjes.v3i1.40.
181. Whitelock, D.; Bektik, D. Progress and Challenges for Automated Scoring and Feedback Systems for Large-Scale Assessments. In *Handbook of Comparative Studies on Community Colleges and Global Counterparts*; Springer International Publishing: Cham, 2018; pp. 1–18 ISBN 9783319389097.
182. Van Der Kleij, F.M. Comparison of Teacher and Student Perceptions of Formative Assessment Feedback Practices and Association with Individual Student Characteristics.Teaching and Teacher Education. **2019**, *85*, 175–189.
183. Jovic, J.; Domazet, D.; Milic, M.; Chandra, K. Student Model in Inteligent Tutoring Systems - a Systematic Review. In *Proceedings of the 11th International Conference on eLearning (eLearning-2020)*; Belgrade, Serbia, 2020; pp. 24–25.
184. Jović, J.; Kisić, E.; Raspopović MIlić, M.; Domazet, D.; Chandra, K. Prediction of Student Academic Performance Using Machine Learning Algorithms. In Proceedings of the Proceedings of the 13th International Conference on eLearning (eLearning-2022); Belgrade Metropolitan University, 2022; pp. 35–43.
185. Liu, R. Data Analysis of Educational Evaluation Using K-Means Clustering Method. *Comput. Intell. Neurosci.* **2022**, *2022*, 1–10, doi:10.1155/2022/3762431.
186. Chang, W. Analysis of University Students' Behavior Based on a Fusion K-Means Clustering Algorithm, " NATO Adv. *Adv. Sci. Inst. Ser. E Appl. Sci* **2020**, *10*.
187. Souabi, S.; Retbi, A.; Idrissi, M.K.; Bennani, S. A Recommendation Approach in Social Learning Based on K-Means Clustering. *Adv. Sci. Technol. Eng. Syst. J.* **2021**, *6*, 719–725, doi:10.25046/aj060178.
188. Pasina, I.; Bayram, G.; Labib, W.; Abdelhadi, A.; Nurunnabi, M. Clustering Students into Groups According to Their Learning Style. *MethodsX* **2019**, *6*, 2189–2197, doi:10.1016/j.mex.2019.09.026.
189. Chatti, M.A.; Dugoija, D.; Thus, H.; Schroeder, U. Learner Modeling in Academic Networks. In Proceedings of the 2014 IEEE 14th International Conference on Advanced Learning Technologies; IEEE, July 2014.
190. Oeda, S.; Asai, K. Student Modeling Method Integrating Knowledge Tracing and IRT with Decay Efect. **2016**, 19–26.

191. Guzmán, E.; Conejo, R. Measuring Misconceptions through Item Response Theory. In *Lecture Notes in Computer Science*; Springer International Publishing: Cham, 2015; pp. 608–611 ISBN 9783319197722.
192. Pelánek, R.; Jarušek, P. Student Modeling Based on Problem Solving Times. *Int. J. Artif. Intell. Educ.* **2015**, *25*, 493–519, doi:10.1007/s40593-015-0048-x.
193. Moseley, L.G.; Mead, D.M. Predicting Who Will Drop out of Nursing Courses: A Machine Learning Exercise. *Nurse Educ. Today* **2008**, *28*, 469–475, doi:10.1016/j.nedt.2007.07.012.
194. Thammasiri, D.; Delen, D.; Meesad, P.; Kasap, N. A Critical Assessment of Imbalanced Class Distribution Problem: The Case of Predicting Freshmen Student Attrition. *Expert Syst. Appl.* **2014**, *41*, 321–330, doi:10.1016/j.eswa.2013.07.046.
195. Dewan, M.A.A.; Lin, F.; Wen, D.; Kinshuk Predicting Dropout-Prone Students in E-Learning Education System. In Proceedings of the 2015 IEEE 12th Intl Conf on Ubiquitous Intelligence and Computing and 2015 IEEE 12th Intl Conf on Autonomic and Trusted Computing and 2015 IEEE 15th Intl Conf on Scalable Computing and Communications and Its Associated Workshops (UIC-ATC-ScalCom); IEEE, August 2015.
196. Iyanda, A.D.; Ninan, O.; Ajayi, A.G.; Anyabolu, O. Predicting Student Academic Performance in Computer Science Courses: A Comparison of Neural Network Models. *Int. J. Mod. Educ. Comput. Sci* **2018**, *10*, 1–9.
197. Nespereira, C.G.; Elhariri, E.; El-Bendary, N.; Vilas, A.F.; Redondo, R.P.D. Machine Learning Based Classification Approach for Predicting Students Performance in Blended Learning. In *Advances in Intelligent Systems and Computing*; Advances in intelligent systems and computing; Springer International Publishing: Cham, 2016; pp. 47–56 ISBN 9783319266886.
198. Jing, S.; Tang, Y.; Liu, X.; Gong, X. A Learner Model Integrating Cognitive and Metacognitive and Its Application on Scratch Programming Projects. *IFAC-PapersOnLine* **2020**, *53*, 644–649, doi:10.1016/j.ifacol.2021.04.154.
199. Chrysafadi, K.; Virvou, M. *Advances in Personalized Web-Based Education*; Springer: New York, 2015;
200. Ferreira, H.N.M.; Brant-Ribeiro, T.; Araujo, R.D.; Dorca, F.A.; Cattelan, R.G. An Automatic and Dynamic Student Modeling Approach for Adaptive and Intelligent Educational Systems Using Ontologies and Bayesian Networks. In Proceedings of the 2016 IEEE 28th International Conference on Tools with Artificial Intelligence (ICTAI); IEEE, November 2016.
201. Huang, Y. Deeper Knowledge Tracing by Modeling Skill Application Context for Better Personalized Learning. In Proceedings of the Proceedings of the 2016 Conference on User Modeling Adaptation and Personalization; ACM: New York, NY, USA, July 13 2016.
202. Chen, Y.; Wuillemin, P.-H.; Labat, J.-M. Bayesian Student Modeling Improved by Diagnostic Items. In *Intelligent Tutoring Systems*; Lecture notes in computer science; Springer International Publishing: Cham, 2014; pp. 144–149 ISBN 9783319072203.
203. Permanasari, A.E.; Hidayah, I.; Nugraha, S. A Student Modeling Based on Bayesian Network Framework for Characterizing Student Learning Style. *Advanced Science Letters* **2014**, *20*, 1936–1940.
204. Ting, C.-Y.; Cheah, W.-N.; Ho, C.C. Student Engagement Modeling Using Bayesian Networks. In Proceedings of the 2013 IEEE International Conference on Systems, Man, and Cybernetics; IEEE, October 2013.
205. Hammad, R.; Odeh, M. eLEM: A Novel e-Learner Experience Model. *International Arab Journal of Information Technology* **2017**, *14*, 586–597.

206. Grivokostopoulou, F.; Perikos, I.; Hatzilygeroudis, I. Using Semantic Web Technologies in a Web Based System for Personalized Learning AI Course. In Proceedings of the 2014 IEEE Sixth International Conference on Technology for Education; IEEE, December 2014.
207. Mohammed, P.; Mohan, P. Contextualised Student Modelling for Enculturated Systems. *AIED 2013 Workshops Proceedings* **2013**, *5*.
208. Ouf, S.; Abd Ellatif, M.; Salama, S.E.; Helmy, Y. A Proposed Paradigm for Smart Learning Environment Based on Semantic Web. *Comput. Human Behav.* **2017**, *72*, 796–818, doi:10.1016/j.chb.2016.08.030.
209. Jović, J.; Raspopović Milić, M.; Cvetanović, S.; Chandra, K. Implementation of Machine Learning Based Methods in E-Learning Systems. In *Proceedings of the 10th International Conference on e-Learning (eLearning-2019)*; Belgrade, 2019; pp. 39–44.
210. Sharipova, M.; McCalla, G. Modelling Students' Knowledge of Ethics. In *Lecture Notes in Computer Science*; Lecture notes in computer science; Springer Berlin Heidelberg: Berlin, Heidelberg, 2013; pp. 721–724 ISBN 9783642391118.
211. Kisić, E.; Milić, M.; Jović, J.; Zdravković, N.; Selimović, F. Comparative Analysis of Student Performance across Different Cohorts in Higher Education. In *Proceedings of the 15th International Conference on eLearning*; Belgrade, Serbia, 2024; pp. 24–31.
212. Mojarad, S.; Essa, A.; Mojarad, S.; Baker, R.S. Data-Driven Learner Profiling Based on Clustering Student Behaviors: Learning Consistency, Pace and Effort. In *Intelligent Tutoring Systems*; Lecture Notes in Computer Science; Springer International Publishing: Cham, 2018; pp. 130–139 ISBN 9783319914633.
213. Zhang, T.; Taub, M.; Chen, Z. A Multi-Level Trace Clustering Analysis Scheme for Measuring Students' Self-Regulated Learning Behavior in a Mastery-Based Online Learning Environment. In Proceedings of the LAK22: 12th International Learning Analytics and Knowledge Conference; ACM: New York, NY, USA, March 21 2022.
214. Conati, C.; Barral, O.; Putnam, V.; Rieger, L. Toward Personalized XAI: A Case Study in Intelligent Tutoring Systems. *arXiv [cs.AI]* 2019.
215. Abu Zohair, L.M. Prediction of Student's Performance by Modelling Small Dataset Size. *Int. J. Educ. Technol. High. Educ.* **2019**, *16*, doi:10.1186/s41239-019-0160-3.
216. Stol, K.-J.; Fitzgerald, B. The ABC of Software Engineering Research. *ACM Trans. Softw. Eng. Methodol.* **2018**, *27*, 1–51, doi:10.1145/3241743.
217. Stol, K.-J.; Fitzgerald, B. Guidelines for Conducting Software Engineering Research. In *Contemporary Empirical Methods in Software Engineering*; Springer International Publishing: Cham, 2020; pp. 27–62 ISBN 9783030324889.
218. March, S.T.; Smith, G.F. Design and Natural Science Research on Information Technology. *Decis. Support Syst.* **1995**, *15*, 251–266, doi:10.1016/0167-9236(94)00041-2.
219. Hevner, A.; Chatterjee, S. Design Science Research in Information Systems. In *Integrated Series in Information Systems*; Springer US: Boston, MA, 2010; pp. 9–22 ISBN 9781441956521.
220. Wieringa, R. Design Science as Nested Problem Solving. In Proceedings of the Proceedings of the 4th International Conference on Design Science Research in Information Systems and Technology - DESRIST '09; ACM Press: New York, New York, USA, 2009.
221. *Contemporary Empirical Methods in Software Engineering*; Felderer, M., Travassos, G.H., Eds.; 2020;
222. van Aken, J.E. Management Research Based on the Paradigm of the Design Sciences: The Quest for Field-tested and Grounded Technological Rules. *J. Manag. Stud.* **2004**, *41*, 219–246, doi:10.1111/j.1467-6486.2004.00430.x.

223. Runeson, P.; Engström, E.; Storey, M.-A. The Design Science Paradigm as a Frame for Empirical Software Engineering. In *Contemporary Empirical Methods in Software Engineering*; Springer International Publishing: Cham, 2020; pp. 127–147 ISBN 9783030324889.
224. Wieringa, R.J. *Design Science Methodology for Information Systems and Software Engineering*; Springer: Berlin, 2014;
225. Van Den Akker, J.; Gravemeijer, K.; Mckenney, S.; Nieveen, N. Introducing Educational Design Research. In *Educational design research*; Van Den Akker, J., Gravemeijer, K., Mckenney, S., Nieveen, N., Eds.; Routledge: London, 2006; pp. 3–7.
226. Wieringa, R.; Daneva, M. Six Strategies for Generalizing Software Engineering Theories. *Sci. Comput. Program.* **2015**, *101*, 136–152, doi:10.1016/j.scico.2014.11.013.
227. Wieringa, R.; Moralı, A. Technical Action Research as a Validation Method in Information Systems Design Science. In *Lecture Notes in Computer Science*; Lecture notes in computer science; Springer Berlin Heidelberg: Berlin, Heidelberg, 2012; pp. 220–238 ISBN 9783642298622.
228. Engström, E.; Storey, M.-A.; Runeson, P.; Höst, M.; Baldassarre, M.T. How Software Engineering Research Aligns with Design Science: A Review. *Empir. Softw. Eng.* **2020**, *25*, 2630–2660, doi:10.1007/s10664-020-09818-7.
229. Noy, N.F.; Mcguinness, D.L. Ontology Development 101: A Guide to Creating Your First Ontology. In *and Stanford Medical Informatics*; Santa Clara, California, 2001.
230. Domazet, D.; Gavrilović, N.; Jović, J. Efficiency of Development of E-Learning Materials Based on Learning Objects. In *Proceedings of the 10th International Conference on e-Learning (eLearning-2019)*; Belgrade, 2019.
231. Domazet, D.; Jović, J.; Damnjanović, M.; Grković, V. Značaj Informacionog Sistema Univerziteta Metropolitan u Obrazovnom Procesu (The Importance of Using Information System at the Metropolitan University in Educational Process). In *Zbornik radova XXVI skupa „Trendovi razvoja: Inovacije u modernom obrazovanju“ (TREND 2020)*; Kopaonik, 2020; Vol. 2020, pp. 16–19.
232. Chandrasekaran, B.; Josephson, J.R.; Benjamins, R. ‘What Are Ontology, and Why Do We Need Them?’ *IEEE Intelligent Systems* **1999**, *14*, 20–26.
233. Uschold, M.; Gruninger, M. Ontologies: Principles, Methods, and Applications. *Knowledge Engineering Review* **1996**, *11*, 1–63.
234. Neches, R.; Fikes, R.E.; Finin, T.; Gruber, T.R.; Senator, T.; Swartout, W.R. ‘Enabling Technology for Knowledge Sharing.’ *AI Magazine* **1991**, *12*, 36–41.
235. Maedche, A.; Staab, S. ‘Mining Ontology from Text.’ In *Proceedings of the EKAW-2000- 12th International Conference on Knowledge Engineering and Knowledge Management*; Springer: Juan-les-Pins, France, LNAI; Berlin, 2000.
236. Sowa, J.F. *Knowledge Representation - Logical, Philosophical, and Computational Foundations*; Pacific Grove, CA, USA: Brooks/Cole, 2000;
237. Mizoguchi, R.; Bourdeau, J. Using Ontological Engineering to Overcome Common AI-ED Problems. *International Journal of Artificial Intelligence in Education* **2000**, *11*, 107–121.
238. Devedžić, V. *Semantic Web and Education*; Springer US;
239. Boyce, S.; Pahl, C. Developing Domain Ontologies for Course Content. *Journal of Educational Technology and Society* **2007**, *10*, 275–288.
240. Novak, J.D.; Cañas, A.J. Theoretical Origins of Concept Maps, How to Construct Them, and Uses in Education. *Reflecting education* **2007**, *3*, 29–42.
241. Ausubel, D.P. *The Psychology of Meaningful Verbal Learning*; Grune & Stratton, 1963;

242. Miller, G.A. The Magical Number Seven, plus or Minus Two: Some Limits on Our Capacity for Processing Information. *Psychol. Rev.* **1994**, *101*, 343–352, doi:10.1037/0033-295x.101.2.343.
243. Chen, C.-H.; Huang, C.-Y.; Chou, Y.-Y. Effects of Augmented Reality-Based Multidimensional Concept Maps on Students' Learning Achievement, Motivation and Acceptance. *Univers. Access Inf. Soc.* **2019**, *18*, 257–268, doi:10.1007/s10209-017-0595-z.
244. Chiou, C.-C.; Tien, L.-C.; Lee, L.-T. Effects on Learning of Multimedia Animation Combined with Multidimensional Concept Maps. *Comput. Educ.* **2015**, *80*, 211–223, doi:10.1016/j.compedu.2014.09.002.
245. Anderson, L.W.; Krathwohl, D.R. *A Taxonomy for Learning, Teaching, and Assessing: A Revision of Bloom's Taxonomy of Educational Objectives: Complete Edition*; Addison Wesley Longman, Inc, 2001;
246. Biggs, J. Enhancing Teaching through Constructive Alignment. *High. Educ. (Dordr.)* **1996**, *32*, 347–364, doi:10.1007/bf00138871.
247. Dempster, A.P.; Laird, N.M.; Rubin, D.B. Maximum Likelihood from Incomplete Data via the *EM* Algorithm. *J. R. Stat. Soc. Series B Stat. Methodol.* **1977**, *39*, 1–22, doi:10.1111/j.2517-6161.1977.tb01600.x.
248. Baker, R.S.J. d.; Corbett, A.T.; Aleven, V. More Accurate Student Modeling through Contextual Estimation of Slip and Guess Probabilities in Bayesian Knowledge Tracing. In *Intelligent Tutoring Systems*; Lecture Notes in Computer Science; Springer Berlin Heidelberg: Berlin, Heidelberg, 2008; pp. 406–415 ISBN 9783540691303.
249. Van de Sande, B. Properties of the Bayesian Knowledge Tracing Model. **2013**, doi:10.5281/ZENODO.3554629.
250. Wang, Y.; Heffernan, N. Extending Knowledge Tracing to Allow Partial Credit: Using Continuous versus Binary Nodes. In *Lecture Notes in Computer Science*; Lecture Notes in Computer Science; Springer Berlin Heidelberg: Berlin, Heidelberg, 2013; pp. 181–188 ISBN 9783642391118.
251. Ostrow, K.; Donnelly, C.; Adjei, S.; Heffernan, N. Improving Student Modeling through Partial Credit and Problem Difficulty. In Proceedings of the Proceedings of the Second (2015) ACM Conference on Learning @ Scale; ACM: New York, NY, USA, March 14 2015.
252. Macqueen, J. Some Methods for Classification and Analysis of Multivariate Observations. In *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*; University of California Press: Berkeley, CA, USA, 1967; Vol. 1, pp. 281–297.
253. Lloyd, S. Least Squares Quantization in PCM. *IEEE Trans. Inf. Theory* **1982**, *28*, 129–137, doi:10.1109/tit.1982.1056489.
254. Rousseeuw, P.J. Silhouettes: A Graphical Aid to the Interpretation and Validation of Cluster Analysis. *J. Comput. Appl. Math.* **1987**, *20*, 53–65, doi:10.1016/0377-0427(87)90125-7.
255. Adadi, A.; Berrada, M. Peeking inside the Black-Box: A Survey on Explainable Artificial Intelligence (XAI). *IEEE Access* **2018**, *6*, 52138–52160, doi:10.1109/access.2018.2870052.
256. Barredo Arrieta, A.; Díaz-Rodríguez, N.; Del Ser, J.; Bennetot, A.; Tabik, S.; Barbado, A.; Garcia, S.; Gil-Lopez, S.; Molina, D.; Benjamins, R.; et al. Explainable Artificial Intelligence (XAI): Concepts, Taxonomies, Opportunities and Challenges toward Responsible AI. *Inf. Fusion* **2020**, *58*, 82–115, doi:10.1016/j.inffus.2019.12.012.
257. Ribeiro, M.T.; Singh, S.; Guestrin, C. "why Should I Trust You?": Explaining the Predictions of Any Classifier. *arXiv [cs.LG]* 2016.

258. Lundberg, S.; Lee, S.-I. A Unified Approach to Interpreting Model Predictions. *arXiv [cs.AI]* 2017.
259. Guidotti, R.; Monreale, A.; Ruggieri, S.; Turini, F.; Giannotti, F.; Pedreschi, D. A Survey of Methods for Explaining Black Box Models. *ACM Comput. Surv.* **2019**, *51*, 1–42, doi:10.1145/3236009.
260. Rudin, C. Stop Explaining Black Box Machine Learning Models for High Stakes Decisions and Use Interpretable Models Instead. *Nat. Mach. Intell.* **2019**, *1*, 206–215, doi:10.1038/s42256-019-0048-x.
261. Breiman, L.; Friedman, J.H.; Olshen, R.A.; Stone, C.J. *Classification And Regression Trees*; Routledge, 2017; ISBN 9781315139470.
262. Quinlan, J.R. Induction of Decision Trees. *Mach. Learn.* **1986**, *1*, 81–106, doi:10.1007/bf00116251.
263. Hattie, J.; Timperley, H. The Power of Feedback. *Rev. Educ. Res.* **2007**, *77*, 81–112, doi:10.3102/003465430298487.
264. Feldman-Maggor, Y.; Cukurova, M.; Kent, C.; Alexandron, G. The Impact of Explainable AI on Teachers' Trust and Acceptance of AI EdTech Recommendations: The Power of Domain-Specific Explanations. *Int. J. Artif. Intell. Educ.* **2025**, *35*, 2889–2922, doi:10.1007/s40593-025-00486-6.
265. Dakshit, S.; Mokhtari, K.; Khalid, A. Designing Understandable and Fair AI for Learning: The PEARL Framework for Human-Centered Educational AI. *Educ. Sci. (Basel)* **2026**, *16*, 198, doi:10.3390/educsci16020198.
266. Shute, V.; Towle, B. Adaptive E-Learning. *Educ. Psychol.* **2003**, *38*, 105–114, doi:10.1207/s15326985ep3802_5.
267. Lunt, B.; Ekstrom, J.; Gorka, S.; Hislop, G.; Kamali, R.; Lawson, E.; LeBlanc, R.; Miller, J.; Reichgelt, H. *Curriculum Guidelines for Undergraduate Degree Programs in Information Technology*; Association for Computing Machinery: New York, United States, 2008;
268. Jović, J.; Cvetanović, S.; Raspopović, M. System for Learning Objects Retrieval in Ontology-Based Database Course. In *The Seventh International Conference on eLearning*; Belgrade, Serbia, 2016; pp. 28–32.
269. Ardis, M.; Budgen, D.; Hislop, G.W.; Offutt, J.; Sebern, M.; Visser, W. SE 2014: Curriculum Guidelines for Undergraduate Degree Programs in Software Engineering. *Computer (Long Beach Calif.)* **2015**, *48*, 106–109, doi:10.1109/mc.2015.345.
270. Task Group on Information Technology Curricula *Information Technology Curricula 2017: Curriculum Guidelines for Baccalaureate Degree Programs in Information Technology*; Association for Computing Machinery, 2017; ISBN 9781450364164.
271. Bucos, M.; Drăgulescu, B. Predicting Student Success Using Data Generated in Traditional Educational Environments. *TEM Journal* **2018**, *7*, 617–625, doi:10.18421/TEM73-19.
272. Pratiyush, G.; Manu, S. Classifying Educational Data Using Support Vector Machines: A Supervised Data Mining Technique. *Indian J. Sci. Technol.* **2016**, *9*, doi:10.17485/ijst/2016/v9i34/100206.
273. Jiang, A.Q.; Sablayrolles, A.; Mensch, A.; Bamford, C.; Chaplot, D.S.; Casas, D. de las; Bressand, F.; Lengyel, G.; Lample, G.; Saulnier, L.; et al. Mistral 7B. *arXiv [cs.CL]* 2023.
274. Dalziel, J. Implementing Learning Design: The Learning Activity Management System (LAMS). In *Interact, Integrate, Impact: Proceedings of the 20th Annual Conference of the Australasian Society for Computers in Learning in Tertiary Education (ASCILITE)*; Adelaide, Australia, 2003; pp. 593–596.

275. Conde, M.Á.; Georgiev, A.; López-Pernas, S.; Jovic, J.; Crespo-Martínez, I.; Raspopovic Milic, M.; Saqr, M.; Pancheva, K. Definition of a Learning Analytics Ecosystem for the ILEDA Project Piloting. In *Lecture Notes in Computer Science*; Lecture Notes in Computer Science; Springer Nature Switzerland: Cham, 2023; pp. 444–453 ISBN 9783031344107.
276. Metropolitan University: Belgrade, RS; Grujić, A.; Jović, J.; Metropolitan University: Belgrade, Serbia, RS; Opačić, M.; Metropolitan University: Belgrade, Serbia, RS; Kisić, E.; Metropolitan University: Belgrade, Serbia, RS; Zdravković, N.; Metropolitan University: Belgrade, Serbia, RS Improving Student Engagement through Learning Analytics and Early Interventions with Learning Locker. In Proceedings of the ELEARNING2025; Belgrade Metropolitan University, 2025; pp. 40–57.
277. Jović, J.L.; Domazet, D.S.; Vesić, N.O.; Ranđelović, B.M.; Simjanović, D.J. An Integrated AHP–Fuzzy AHP Evaluation Framework for Large Language Models in Software Engineering Education. *Mathematics* **2026**, *14*, 1637, doi:10.3390/math14101637.
278. Domazet, D.; Jović, J. Teaching, Research and Application of AI at Belgrade Metropolitan University. *Interdiscip. Descr. Complex Syst.* **2026**, *24*, 761–773, doi:10.7906/indecs.24.6.7.