

**ALFA BK UNIVERZITET**  
**FAKULTET INFORMACIONIH TEHNOLOGIJA**



**PREDIKCIJA USPEHA STUDENATA U SISTEMIMA  
ZA E-UČENJE PRIMENOM TEHNIKA VEŠTAČKE  
INTELIGENCIJE: RAZVOJ METODOLOGIJE I  
PRAKTIČNE IMPLIKACIJE**

- doktorska disertacija -

**KANDIDAT**

Miloš Ilić 5901/2020

**MENTOR**

prof. dr Boban Vesin

**Beograd, 2024.**

**ALFA BK UNIVERSITY  
FACULTY OF INFORMATION TECHNOLOGIES**



**PREDICTING STUDENT SUCCESS IN  
E-LEARNING SYSTEMS USING ARTIFICIAL  
INTELLIGENCE TECHNIQUES: METHODOLOGY  
DEVELOPMENT AND PRACTICAL IMPLICATIONS**

**- Doctoral Dissertation -**

**CANDIDATE**  
Miloš Ilić 5901/2020

**MENTOR**  
Prof. Dr. Boban Vesin

**Belgrade, 2024.**

**ALFA BK UNIVERZITET**  
**FAKULTET INFORMACIONIH TEHNOLOGIJA**



Datum \_\_\_\_\_

Komisija za ocenu i javnu odbranu doktorske disertacije:

prof. dr Dejan Viduka - predsednik Komisije  
redovni profesor, Fakultet za matematiku i računarske nauke, Alfa BK Univerzitet

---

prof. dr Negovan Stamenković - član Komisije  
redovni profesor, Prirodno-matematički fakultet, Kosovska Mitrovica

---

prof. dr Boban Vesin - mentor  
redovni profesor, Fakultet informacionih tehnologija, Alfa BK Univerzitet

---

Student je odbranio doktorsku disertaciju s ocenom \_\_\_\_\_ (\_\_\_\_\_)

Akademski naziv  
**DOKTOR NAUKA - ELEKTROTEHNIKA I RAČUNARSTVO**

## **Zahvalnica**

*Želim da izrazim neizmernu zahvalnost svima koji su mi pomogli i bili podrška tokom doktorskih studija i koji su svojim nesebičnim zalaganjem doprineli razvoju ove disertacije.*

*Velika zahvalnost mentoru dr Bobanu Vesinu na izuzetnoj posvećenosti i strpljenju, kao i na jasnim instrukcijama i dragocenim savetima bez kojih ova disertacija ne bi dobila svoj konačni sadržaj.*

*Posebna zahvalnost dr Lazaru Kopanji koji me je motivisao da nastavim svoj obrazovni put i upišem doktorske studije i koji mi je bio podrška tokom celokupnih studija.*

*Zahvaljujem dr Goranu Kekoviću na stručnoj podršci, korisnim smernicama i vrednim sugestijama.*

*Zahvalnost upućujem dr Katerini Mangaroskoj na značajnim savetima i kreativnim idejama.*

*Zahvaljujem Mileni Sretić na prijateljskoj podršci i konstruktivnim predlozima.*

*Disertaciju posvećujem majci, ocu i sestri. Ljubav, podrška i razumevanje koje su mi pružili i koji čine moj život neizostavni su pogon koji imam na putovanju ka ostvarivanju svojih snova i ciljeva - disertacija je jedan od njih.*

*Miloš Ilić*

## Sažetak

Predikcija uspeha studenata u sistemima za e-učenje predstavlja važnu komponentu savremenog obrazovnog sistema na svim nivoima. Nastavnici je koriste za unapređenje kvaliteta celokupnog obrazovnog procesa, kroz poboljšanje nastavnog plana i programa, prilagođavanje nastavnog materijala i unapređenje različitih vidova praktične primene znanja. U cilju predikcije uspeha koriste se različite tehnike veštacke inteligencije. Međutim, jedan od ključnih izazova jeste činjenica da mnogi istraživači ne uspevaju da u potpunosti iskoriste potencijal ovih tehnika za ovu namenu.

Pregled literature pokazao je da veliki broj istraživača nasumično bira proizvoljne tehnike veštacke inteligencije bez prethodne analize podataka ili razmatranja koji pristup je najprikladniji za konkretan slučaj, što često rezultira slabijom tačnošću predikcija. Takođe, nedostatak standardizovanih metodologija za predikciju uspeha studenata u sistemima elektronskog učenja predstavlja problem za istraživače koji često pristupaju ovom procesu bez jasnog plana. Usvajanje standardizovanog pristupa doprinelo bi efikasnijem procesu predikcije i boljem kvalitetu rezultata. Iako opšte metodologije za predikciju, koje nisu vezane za specifičnu oblast, mogu biti korisne do određenog stepena, one često izostavljaju ključna objašnjenja i detaljna uputstva koja bi sugerisala adekvatne postupke, metode i tehnike u kontekstu e-učenja. Postojanje sveobuhvatne i efikasne metodologije za predikciju uspeha studenata u sistemima za e-učenje bilo bi od velikog značaja, ne samo za istraživače, nego i za nastavnike.

Cilj ove disertacije je unapređenje procesa predikcije kroz razvoj metodologije koja će omogućiti standardizaciju tog procesa. Njena primena omogućila bi istraživačima da na adekvatan način pristupe predikciji uspeha i da razviju modele koji će postići najveću moguću tačnost. Ključni element u kreiranju ove metodologije, pored opširnog i sistematičnog pregleda literature kojim su identifikovani trenutni nedostaci i potrebe, bilo je i sprovođenje eksperimenata sa studentima u sistemu za e-učenje radi prikupljanja podataka o njihovoj interakciji. Nakon prikupljanja podataka, realizovan je kompletan postupak pretprocesiranja, primenjene su različite prediktivne tehnike veštacke inteligencije, a rezultati su analizirani i evaluirani.

Na osnovu rezultata sprovedenog istraživanja, kao i iskustva i rezultata drugih istraživača, razvijen je predlog metodologije za predikciju uspeha studenata u sistemima za e-učenje. Ova

metodologija, zajedno sa ostalim nalazima studije, imaće značajan uticaj na polju inženjeringu tehnologija učenja i veštačke inteligencije, doprinoseći unapređenju obrazovnog procesa.

**Ključne reči:** e-učenje, sistemi za e-učenje, studenti, predikcija uspeha, metodologija, veštačka inteligencija, preprocesiranje podataka

## **Abstract**

Predicting student success in e-learning systems represents, at all levels, an important component of a modern education system. Teachers use it to enhance the quality of the entire educational process, through improving the curriculum, adapting teaching materials, and enhancing various aspects of practical knowledge application. To predict success, various artificial intelligence techniques are used. However, one of the key challenges is the fact that many researchers fail to fully exploit the potential of these techniques for this purpose.

The literature review has shown that a large number of researchers randomly select arbitrary artificial intelligence techniques without prior data analysis, or consideration of which approach is most appropriate for a specific case, often resulting in lower prediction accuracy. Additionally, the lack of standardized methodologies for predicting student success in e-learning systems represents a problem for researchers who often approach this process without a clear plan. The adoption of a standardized approach would contribute to a more efficient prediction process and results of higher quality. Although general, non-domain-specific prediction methodologies can be beneficial to a certain extent, they often omit key explanations and detailed instructions that would suggest appropriate procedures, methods, and techniques in an e-learning context. The existence of a comprehensive and effective methodology for predicting student success in e-learning systems would be of great importance, not only for researchers but for teachers as well.

The goal of this dissertation is to improve the prediction process through the development of a methodology that will enable the standardization of that process. Its application would allow researchers to adequately approach the success prediction process and develop models that will achieve the highest possible accuracy. A key element in the creation of this methodology, in addition to an extensive and systematic literature review that identified current shortcomings and needs, was conducting experiments with students in the e-learning system to collect data on their interaction with it. After data collection, a complete preprocessing procedure was carried out, various predictive artificial intelligence techniques were applied, and the results were analyzed and evaluated.

Based on the results of the conducted research, as well as the experience and results of other researchers, a methodology proposal was developed for predicting student success in e-learning systems. This methodology, together with the other findings of the study, will have a

significant impact on the field of learning technology engineering and artificial intelligence, contributing to the improvement of the educational process.

**Keywords:** e-learning, e-learning systems, students, success prediction, methodology, artificial intelligence, data preprocessing

# Sadržaj

1.	Uvod .....	12
2.	Teorija i pregled literature .....	17
2.1.	Osnove e-učenja.....	17
2.1.1.	Prednosti e-učenja.....	18
2.1.2.	Nedostaci e-učenja .....	20
2.1.3.	Glavni izazovi e-učenja.....	21
2.2.	Inteligentne tehnike u e-učenju.....	23
2.2.1.	Modelovanje učenika/studenta .....	23
2.2.2.	Obrazovno rudarenje podataka.....	29
2.2.3.	Praćenje znanja .....	31
2.2.4.	Analitika učenja .....	34
2.2.5.	Adaptivna procena znanja .....	37
2.2.6.	Personalizacija u e-učenju .....	39
2.2.7.	Inteligentni agenti .....	44
2.2.8.	Ostale inteligentne tehnike u e-učenju .....	47
2.2.9.	Uloge intelligentnih tehnika u e-učenju .....	50
2.2.10.	Trendovi intelligentnih tehnika .....	51
2.2.11.	Sistemi za e-učenje - kategorije, strategije i uloge intelligentnih tehnika .....	53
2.2.12.	Uticaj intelligentnih tehnika na stavove, motivaciju i uspeh učenika/studenata.....	57
2.2.13.	Izazovi i nedostignut potencijal primene intelligentnih tehnika .....	59
2.3.	Predikcija uspeha učenika/studenata u sistemima za e-učenje.....	62
2.3.1.	Uloga predviđanja uspeha učenika/studenata.....	63
2.3.2.	Tehnike za predikciju uspeha učenika/studenata koje se koriste u e-učenju .....	64
2.3.3.	ANN i tradicionalne ML tehnike u predikciji uspeha učenika/studenata .....	66
2.3.4.	Selekcija ulaznih varijabli za potrebe predviđanja .....	67
2.3.5.	Tipovi podataka koji se koriste kao prediktori .....	71
2.3.6.	Analiza podataka za potrebe predviđanja.....	72
2.3.7.	Izazovi u predikciji uspeha u e-učenju.....	73

3.	Sprovedeno istraživanje.....	76
3.1.	Faze istraživanja .....	76
3.2.	Učesnici.....	77
3.3.	Korišćeni sistem za e-učenje u eksperimentima .....	77
3.4.	Kurs, postavka i opis rada .....	80
3.5.	Prikupljanje podataka.....	81
3.6.	Varijable .....	81
3.7.	Analiza podataka i tehnike veštačke inteligencije .....	82
4.	Rezultati.....	86
4.1.	Deskriptivna statistika .....	86
4.2.	Identifikacija optimalnih ulaznih varijabli .....	87
4.3.	Primena tradicionalnih ML tehniku za predikciju uspeha studenata .....	88
4.4.	Povećanje skupa podataka upotrebom <i>SMOTE</i> algoritma .....	90
4.5.	Primena ANN-a za predikciju uspeha studenata .....	91
5.	Diskusija .....	93
5.1.	Najinformativnije varijable .....	93
5.2.	Predikcija uspeha primenom tradicionalnih ML tehniku i ANN-a.....	94
5.3.	Važnost preprocesiranja podataka za potrebe predikcije .....	98
5.4.	Vizuelizacija uvida u faktore koji utiču na uspeh studenata .....	99
5.5.	Implikacije za dizajn metodologije .....	100
6.	Predlog metodologije za predikciju uspeha studenata u sistemima za e-učenje.....	102
6.1.	Dijagramski prikaz predložene metodologije.....	102
6.2.	Opis koraka predložene metodologije.....	106
7.	Naučni doprinos disertacije .....	117
8.	Implikacije i ograničenja istraživanja.....	119
8.1.	Implikacije .....	119
8.1.1.	Dizajn učenja .....	119
8.1.2.	Vizuelizacija .....	120
8.1.3.	Model za predikciju uspeha.....	121
8.1.4.	Metodologija za predikciju uspeha .....	122
8.2.	Ograničenja istraživanja.....	122

9.	Zaključak i preporuke za buduća istraživanja.....	124
10.	Literatura.....	126
11.	Prilozi.....	167
11.1.	Spisak slika .....	167
11.2.	Spisak grafikona.....	168
11.3.	Spisak tabela .....	169
11.4.	Osnovni elementi <i>UML</i> dijagrama aktivnosti .....	170
12.	Biografija .....	171

## 1. Uvod

Poslednjih godina, svedoci smo porasta broja tehnologija za učenje koje služe kao pomoćno sredstvo tradicionalnom učenju ili se implementiraju kao potpuno nezavisni onlajn kursevi ili studijski programi [1], [2], [3]. S obzirom na rastuću popularnost i važnost e-učenja, posebno u kontekstu savremenog obrazovanja, sve je veća potreba za poboljšanjem alata i metoda za predviđanje uspeha studenata (ili učenika, polaznika kursa itd.) u ovim okruženjima. E-učenje nudi fleksibilnost i pristupačnost, ali takođe nosi sa sobom izazove vezane za praćenje napretka i identifikaciju faktora koji utiču na akademski uspeh studenata. Tradicionalne metode evaluacije i podrške studentima često nisu dovoljno efikasne u digitalnim okruženjima, što može dovesti do povećanog broja odustajanja, loših ocena i nezadovoljstva studenata [4]. Važno je imati u vidu da su današnji učenici drugačiji od prethodnih generacija za koje je tradicionalni način nastave bio kreiran. Stoga je neophodno modernizovati pristup nastavi, od aktuelizacije nastavnih jedinica do evaluacije znanja i procene uspeha studenata.

Navedene činjenice ukazuju na jasnu potrebu za istraživanjem koje bi razvilo i testiralo napredne modele za predikciju uspeha studenata u e-učenju [5]. Takvi modeli bi mogli pomoći obrazovnim institucijama da unaprede podršku studentima, personalizuju obrazovne sadržaje i strategije učenja, kao i da pravovremeno identifikuju one koji su u riziku od neuspeha [4], [6], [7]. Time bi se značajno unapredio kvalitet obrazovanja, povećao stepen završetka kurseva i generalno poboljšalo iskustvo studenata u e-učenju.

Kako bi se prikupljeni podaci o studentima iskoristili za predikciju njihovog uspeha, kao i da se na osnovu njih identifikuju faktori koji utiču na uspeh, potrebno je primeniti određene tehnike i metode. Upravo tehnike veštačke inteligencije imaju moć da obrade veliku količinu podataka, pronađu određene šablone kako bi te informacije iskoristile za proces predikcije. Ove tehnike imaju mnogo prednosti u odnosu na tradicionalne statističke tehnike. One mogu da upravljaju složenim nelinearnim odnosima u podacima, kao i da otkrivaju komplikovanije trendove i obrasce u njima [8]. Takođe, njihova mogućnost učenja iz novih podataka omogućava im da kontinuirano poboljšavaju svoju sposobnost predviđanja i performanse, što ih čini dosta fleksibilnijim i prilagodljivijim [9]. Međutim, najveća prednost tehnika veštačke inteligencije u odnosu na statističke je u većoj tačnosti predviđanja koje postižu [10].

Među tehnikama veštačke inteligencije koje se koriste za predikciju uspeha studenata uglavnom se koriste veštačke neuronske mreže (eng. *Artificial neural network - ANN*, u daljem tekstu: ANN) [11], [12] ili različite tradicionalne tehnike mašinskog učenja (eng. *Machine learning - ML*, u daljem tekstu: ML) [13]. Kada se porede ove tehnike, važno je napomenuti da tradicionalne ML tehnike brže procesiraju podatke, što može biti od velike važnosti kada su u pitanju veliki skupovi podataka [14]. Sa druge strane, ANN su dosta moćnije, pošto imaju sposobnost da nauče složenije obrasce i izvrše detekciju skrivenih relacija u okviru podataka primenom kolekcija jednostavnih matematičkih funkcija koje mogu da se istreniraju [15], pa se stoga koriste za rešavanje komplikovanih problema od tradicionalnih ML tehnika, kao što su npr. zadaci obrade prirodnog jezika (eng. *Natural language processing*) [16], zadaci kompjuterske vizije (eng. *Computer vision*) [17] itd. Takođe, ANN nemaju ograničenja u vidu regresione ili linearne diskriminantne analize i često su superiornije od tradicionalnih ML tehnika [18], [19], [20].

Iako postoji veliki broj studija u kojima se autori bave predikcijom uspeha studenata u sistemima za e-učenje, najveći deo njih ne uspeva da iskoristi pun potencijal i mogućnosti tehnika veštačke inteligencije za ovu svrhu [8], [21], [22]. Struktura podataka u velikoj meri utiče na izbor adekvatne tehnike veštačke inteligencije. Međutim, većina istraživača u oblasti e-učenja koja se bavi predikcijom uspeha studenata zanemaruje proces prethodne analize podataka i nasumično bira proizvoljne tehnike za predikciju [23], [24], [25], [26], [27]. Ovakav istraživački pristup temi ne daje mogućnost da u potpunosti bude iskorišćen kapacitet veštačke inteligencije i tako bude postignuta maksimalna tačnost predviđanja [28]. Deskriptivna statistika (eng. *Descriptive statistics*) može dati širu sliku o podacima dovodeći tako do boljeg izbora tehnike veštačke inteligencije [29], [30]. Rezultati korelaceione analize (eng. *Correlation analysis*) mogu uticati na to da se čitav spektar tradicionalnih ML tehnika uključi, ali takođe i isključi iz opticaja, pa u tom slučaju ANN ostaju jedina opcija. Adekvatnom analizom podataka može se izvršiti odabir ulaznih varijabli, potencijalno povećavajući tačnost predikcije [31]. Posebna pažnja mora se posvetiti preprocesiranju podataka, odnosno pronalaženju strukturnih veza između svojstava ulaznih podataka, kako bi se pravilno odabrale tehnike veštačke inteligencije. Istraživači se takođe suočavaju sa brojnim izazovima u predviđanju uspeha studenata u sistemima za e-učenje zbog nedostatka standardizovanih metodologija za ovu namenu, što često dovodi do razvijanja prediktivnih modela niske tačnosti [30], [32]. Iako opšte metodologije za predikciju, koje nisu

vezane za specifičnu oblast, mogu biti korisne do određenog stepena, one često izostavljaju ključna objašnjenja i detaljna uputstva koja bi sugerisala adekvatne postupke, metode i tehnike u kontekstu e-učenja [33]. Postojanje sveobuhvatne i efikasne metodologije za predikciju uspeha studenata u sistemima za e-učenje, koja će pokriti sve neophodne faze ovog procesa, bilo bi od velikog značaja, ne samo za istraživače, nego i za nastavnike. Njena primena omogućila bi istraživačima da na adekvatan način pristupe predikciji uspeha i da razviju modele koji će postići najveću moguću tačnost. Na ovaj način omogućilo bi se nastavnicima da razvijene modele koriste za unapređenje kvaliteta celokupnog obrazovnog procesa, kroz poboljšanje nastavnog plana i programa, prilagođavanje nastavnog materijala, unapređenje različitih vidova praktične primene znanja, bolju podršku studentima i pravovremenu identifikaciju studenata koji se suočavaju sa poteškoćama.

Iz gore navedenih razloga postavljeni su sledeći ciljevi disertacije:

- 1) Analiza korelacija između aktivnosti studenata u sistemu za e-učenje i njihovog uspeha, kako bi se odredile najuticajnije varijable za predikciju.
- 2) Ispitivanje uloge preprocesiranja podataka i identifikacije optimalnih ulaznih varijabli kako bi se povećala tačnost predikcije tehnikama veštačke inteligencije.
- 3) Kreiranje modela za predikciju uspeha studenata na osnovu podataka prikupljenih iz njihovih interakcija sa sistemom za e-učenje.
- 4) Identifikovanje najefikasnije i najučinkovitije tehnike veštačke inteligencije za predikciju uspeha studenata u sistemima za e-učenje.
- 5) Pružanje uvida u faktore vezane za interakciju studenata sa sistemom za e-učenje koji utiču na uspeh studenata, odnosno identifikacija faktora koji vode ka višim ili nižim ocenama.
- 6) Razvoj sveobuhvatne metodologije za predikciju uspeha studenata u sistemima za e-učenje kao rezultat uvida prikupljenih kroz prethodne ciljeve.
- 7) Predstavljanje praktičnih implikacija i smernica za primenu rezultata i nalaza disertacije.

U svrhu ispunjavanja postavljenih ciljeva, sprovedeno je istraživanje sa univerzitetским studentima. Eksperimenti su uključivali korišćenje sistema za e-učenje na kursu programiranja, pri čemu je praćena interakcija studenata sa sistemom. Prikupljeni podaci korišćeni su za proces predikcije uspeha studenata upotrebom tehnika veštačke inteligencije. Kako bi se dobio bolji uvid u strukturu podataka i odredio optimalan skup prediktora, prvo je izvršena neophodna analiza ovih

podataka. Na osnovu tih rezultata, odabrane su odgovarajuće tehnike veštačke inteligencije i razvijeni modeli za predviđanje uspeha studenata, tačnije njihovih ocena. Nakon toga pristupilo se komparaciji rezultata, odnosno postignutih tačnosti tehnika veštačke inteligencije, kako bi se identifikovala najefikasnija i najučinkovitija tehnika za predikciju uspeha studenata. Takođe, analizom rezultata tehnika veštačke inteligencije izvršena je detekcija faktora vezanih za interakciju studenata sa sistemom za e-učenje koji utiču na uspeh studenata. Kreiranjem odgovarajuće vizuelizacije omogućen je uvid u ove ključne aspekte. Nakon završetka svih ispitivanja i testiranja pristupilo se izradi metodologije za predikciju uspeha studenata u sistemima za e-učenje. Na osnovu analize kako dobijenih rezultata ovog istraživanja tako i nalaza drugih studija, napravljen je predlog metodologije. U finalnom delu izložene su praktične implikacije i smernice za primenu ishoda i nalaza disertacije.

Ostatak disertacije strukturiran je na sledeći način:

- Drugo poglavlje predstavlja teoriju i pregled literature, koje je podeljeno na tri velika potpoglavlja Osnove e-učenja, Inteligentne tehnike u e-učenju i Predikcija uspeha učenika/studenata u sistemima za e-učenje. Prvo potpoglavlje sadrži pregled teorijskih aspekata osnovnih koncepata e-učenja, kao i njegove prednosti, nedostatke i izazove. Drugo potpoglavlje, kao odgovor na izazove e-učenja, ima za cilj da predstavi sve intelligentne tehnike koje se koriste u sistemima za e-učenje, njihov uticaj na učenike/studente, razne trendove i neiskorišćen potencijal. Treće potpoglavlje pruža sveobuhvatan pregled literature vezane za predikciju uspeha učenika/studenata u sistemima za e-učenje i utvrđuje trenutne nedostatke i potrebe u ovoj oblasti.
- Treće poglavlje predstavlja prikaz sprovedenog istraživanja, koje podrazumeva opis faza istraživanja, upoznavanje sa učesnicima eksperimenata, opis korišćenog sistema u eksperimentima, predstavljanje kursa, objašnjavanje postavke, opis rada učesnika, zatim objašnjava proces prikupljanja podataka, daje opis varijabli sistema za e-učenje, i takođe predstavlja planirane analize podataka i tehnike veštačke inteligencije koje će se koristiti.
- U četvrtom poglavlju prezentovani su i objašnjeni rezultati disertacije koji se odnose na proces preprocesiranja podataka i prediktivnih istraživanja tehnikama veštačke inteligencije.
- Peto poglavlje sadrži diskusiju o nalazima istraživanja, odnosno u njemu su predstavljena detaljnija razmatranja rezultata.

- U šestom poglavlju iznet je predlog metodologije za predikciju uspeha studenata u sistemima za e-učenje.
- Sedmo poglavlje razmatra naučni doprinos disertacije.
- Osmo poglavlje odnosi se na implikacije i ograničenja istraživanja, u kome je objašnjena praktična primena rezultata i nalaza ove disertacije, a takođe su opisana i određena ograničenja istraživanja.
- Deveto poglavlje pruža zaključna razmatranja i daje preporuke za buduća istraživanja.

## 2. Teorija i pregled literature

### 2.1. Osnove e-učenja

E-učenje (eng. *E-learning*) može se definisati kao učenje koje se odvija preko interneta uz pomoć modernih tehnologija [34]. E-učenje je danas veoma rasprostranjeno i koristi se u raznim industrijama. Primjenjuje se najviše u obrazovanju, ali upotrebljava se i u zdravstvu, maloprodaji, IT sektoru, građevini i drugim oblastima [35]. Dok se e-učenje u obrazovanju koristi za njegovu osnovnu namenu - učenje ili podršku učenju, u ostalim industrijama koristi se kao sredstvo za trening i obuku zaposlenih, njihovo usavršavanje, kao i praćenje njihovog napretka u poslu.

E-učenje obično se odvija preko određene platforme koja je razvijena i prilagođena upravo za potrebe učenja [36]. Takve platforme nazivaju se sistemi za e-učenje i predstavljaju softverske aplikacije koje omogućavaju kreiranje kurseva, postavljanje nastavnog materijala, osmišljavanje aktivnosti za učenike/studente i slično [37]. Sistemi za e-učenje većinom su jednostavni za korišćenje, kako za nastavnike, tako i za učenike/studente. Projektovani su i izrađeni na takav način da samo okruženje bude intuitivno, lako za snalaženje i jednostavno za rad. Navedene sisteme koriste profesori na univerzitetima, nastavnici u osnovnim i srednjim školama, instruktori na privatnim kursevima, preduzeća za obuku svojih zaposlenih itd.

Ranije su se sistemi za e-učenje uglavnom koristili kao pomoćna sredstva, odnosno podrška tradicionalnom učenju [38]. Učenici/studenti tada su koristili ove sisteme kao dodatni izvor nastavnog materijala za potrebe dopunskog učenja, koje je moglo da se odvija od kuće ili sa bilo koje druge lokacije van obrazovne ustanove. Međutim, danas postoje kursevi, ali i čitavi akreditovani studijski programi na fakultetima, koji su u potpunosti onlajn.

Postoje tri osnovne vrste e-učenja [39]:

- asinhrono e-učenje,
- sinhrono e-učenje,
- mešano učenje.

Asinhrono e-učenje (eng. *Asynchronous e-learning*) odvija se u potpunosti onlajn. Kod ovog pristupa, sistem za e-učenje unapred je opremljen raznim nastavnim materijalima, snimljenim predavanjima, osmišljenim aktivnostima, testovima itd. U ovoj postavci učenje je u potpunosti u rukama učenika/studenta. On je taj koji određuje dinamiku i obim svog učenja - kada

će, koliko i kojom brzinom prelaziti nastavno gradivo. Ovaj pristup vremenski je ograničen i postoji dinamika polaganja predispitnih i ispitnih obaveza.

Sinhrono e-učenje (eng. *Synchronous e-learning*) takođe se u potpunosti odvija onlajn, ali kod ovog pristupa, za razliku od asinhronog učenja, svi učenici/studenti učestvuju u nastavi istovremeno. Postoje unapred zakazana onlajn predavanja koja drži nastavnik i na kojima prelazi određene lekcije, diskutuje sa učenicima/studentima itd. Ova predavanja obično se odvijaju preko nekih alata za video-konferencije koji mogu biti ugrađeni u sistem za e-učenje ili zasebni.

Mešano učenje (eng. *Blended learning*) predstavlja kombinaciju tradicionalnog učenja i e-učenja. Zagovornici mešanog učenja smatraju da se ne mogu sve nastavne aktivnosti obavljati onlajn, ali i da nije potrebno sve realizovati u prostorijama obrazovne ustanove. Kod ovog vida učenja obično se nastava odvija uživo u učionicama, dok se ostale aktivnosti, kao što su predaja domaćih zadataka, vežbanje, testiranje itd. obavljaju onlajn. Na ovaj način mogu da se iskoriste prednostioba načina učenja.

Kada se proces učenja odvija preko mobilnih telefona onda se to zove mobilno učenje, tj. m-učenje (eng. *M-learning*) i ono predstavlja posebnu granu e-učenja [40]. Pojava pametnih mobilnih telefona i ubrzani razvoj mobilnih aplikacija bili su odličan temelj za m-učenje. Ovaj vid učenja brzo je stekao popularnost, pogotovo kod mladih. Kod m-učenja, kao i u e-učenju, učenici/studenti mogu pristupiti nastavnom materijalu sa bilo koje lokacije. Imajući u vidu to da mobilne telefone nosimo svuda sa sobom i da većina ima telefonski paket sa dovoljnom količinom interneta čini m-učenje fleksibilnim i praktičnim. M-učenje pokazalo se proteklih godina kao efikasan način za brzo i lako sticanje novih veština i znanja [41]. Smatra se da će sa daljim razvojem tehnologije i mobilnih telefona m-učenje predstavljati sve bitniji faktor u obrazovanju [42].

### **2.1.1. Prednosti e-učenja**

Prednosti e-učenja su brojne i mogu koristiti učenicima/studentima, nastavnicima i obrazovnim institucijama.

Neke od najvažnijih prednosti e-učenja su [43]:

- sopstvena organizacija učenja,
- učenje svojim tempom,

- učenje putem pokušaja i grešaka,
- neograničen pristup resursima,
- ekonomska isplativost.

Sopstvena organizacija učenja jeste velika pogodnost koje e-učenje nudi. Učenik/student, u skladu sa svojim obavezama, može da organizuje svoje učenje kada i na koji način mu najviše odgovara. Koncept ovakvog učenja mnogo znači zaposlenima, koji ne bi mogli da prate nastavu koja se odvija u određenim terminima. Takođe, mnogi učenici/studenti imaju dobru koncentraciju ujutru, neki tokom dana, a neki uveče. Pohađajući kurs e-učenja oni mogu sami da odrede kada će se posvetiti učenju, što ne bi mogli da urade u tradicionalnom obrazovanju koje se odvija u nastavnim prostorijama. Savremeno tržište rada neretko zahteva i doškolovanje zaposlenih, tako da je ovakav koncept učenja najefektivnije rešenje i za takve potrebe.

Učenje svojim tempom takođe jeste jedna od prednosti e-učenja. Neki učenici/studenti brzo uče i uspevaju lako da savladaju gradivo, dok je drugima potrebno više vremena. Kada se nastava odvija u nastavnim prostorijama, učenici/studenti moraju da se prilagođavaju celoj grupi i da uče opštim tempom. Kod e-učenja je to drugačije, pošto svaki učenik/student može da prati i prelazi gradivo tempom koji njemu odgovara i koji je sam sebi konstruisao. Na ovaj način znatno se može povećati efikasnost učenja učenika/studenata.

Značajna prednost okruženja za e-učenje jeste učenje putem pokušaja i grešaka. Učenici/studenti često se plaše da će im biti neprijatno pred svojim drugovima iz razreda/grupe ako ne uspeju da reše zadatak. Sistemi za e-učenje mogu da obezbede komforntnije okruženje u kome učenici/studenti imaju mogućnost da pokušavaju da savladaju neku lekciju, reše određeni problem ili zadatak i greše i ne uspevaju u tome sve dok ne shvate lekciju i time su pošteđeni straha od sramote. U skladu sa navedenim, ovakva okruženja mogu potencijalno imati značajan uticaj na motivaciju učenika/studenata i, kao rezultat, poboljšati njihov ukupan uspeh.

Neograničen pristup resursima jeste veoma važan segment kod e-učenja. Učenici/studenti u svakom trenutku mogu pristupiti nastavnom materijalu i to sa bilo kog mesta i bilo kog računara, pa čak i mobilnog telefona. Materijal sa kursa učenici/studenti mogu iznova koristiti, realizovati aktivnosti i zadatke rešavati više puta.

Ekonomska isplativost predstavlja isto jednu od pogodnosti, kako za institucije, tako i za učenike/studente. Prilikom organizovanja onlajn kurseva nisu potrebni zakup prostorija, skupa

oprema i ostali nastavni resursi. Ušteda koju institucije ostvaruju organizovanjem onlajn kurseva umesto tradicionalnih je velika. Finansijska sredstva mogu biti preusmerena u cilju da se učenicima/studentima ponude povoljniji onlajn kursevi u odnosu na one koji se održavaju u prostorijama obrazovne ustanove. Osim ove prednosti, učenici/studenti time mogu da uštede i na troškovima putovanja, na kupovini nastavnog materijala i slično.

### **2.1.2. Nedostaci e-učenja**

E-učenje ima i određene nedostatke, ali su mnogo manji u poređenju sa svim prednostima koje donosi.

Neki od najvažnijih nedostataka e-učenja su [44]:

- tehnički problemi,
- nedostatak samodiscipline,
- nedostatak ljudskog kontakta.

Tehnički problemi jesu sastavni deo svakog softvera, pa tako i sistema za e-učenje. Internet konekcija obično predstavlja najveći tehnički izazov sa kojim učenici/studenti mogu da se susretnu. Ukoliko iz nekog razloga konekcija ne radi ili postoje periodični prekidi, učenici/studenti neće biti u mogućnosti da prate nastavu. Kvar računara ili drugog elektronskog uređaja sa koga učenik/student pristupa e-učenju prouzrokuje istu situaciju. Pored navedenih poteškoća, uvek je moguće da se javi i određeni tehnički problemi u okviru samog sistema za e-učenje, koji će onemogućiti učenika/studenta da pravilno izvršava aktivnosti na kursu.

Nedostatak samodiscipline predstavlja veliki problem kod nekih učenika/studenata. Veština lične organizacije jeste ključna za efektivno pohađanje onlajn kurseva. Dok je mnogo učenika/studenata poseduje, drugi u tome oskudevaju, te imaju problema da sebe pokrenu da prate gradivo redovno i uče usled zaokupljenosti drugim stvarima. Kada se nastava odvija u prostorijama koje su za to namenjene, nastavnik je taj koji brine o učenicima/studentima i o tome da ih zainteresuje za gradivo i zadrži njihov fokus na nastavi.

Nedostatak ljudskog kontakta predstavlja možda i najveći problem e-učenja. Iako je onlajn učenje veoma zgodno i mnogi učenici/studenti vole da uče sami, određeni segmenti iz tradicionalnog obrazovanja ne mogu se zameniti e-učenjem. Najpre je važno istaknuti direktni, odnosno, fizički prisutan rad sa nastavnicima i kontakt sa drugim učenicima/studentima. Koncept

e-učenja učenike/studente poprilično prepušta da se sami organizuju, nemajući odgovarajuću podršku. Takođe, ne postoje tokom samog obrađivanja nastavne jedinice diskusije između nastavnika i učenika/studenta. Odsustvo klasične interakcije sa drugim ljudima u sistemima za e-učenje može prouzrokovati da učenicima/studentima posle nekog vremena postane dosadno. Pored ostalog, učenje od kuće može kod učenika/studenta da izazove usamljenost i tako dovede do njegove sve manje zainteresovanosti za učenje, ali i zanemarivanje razvoja socijalnih veština, koje su za budući karijerni put značajne uz eksperatsko znanje u oblasti za koju se učenici/studenti i obrazuju.

### **2.1.3. Glavni izazovi e-učenja**

Postoje mnogi izazovi sa kojima se susreće e-učenje, koji mogu negativno uticati na ceo proces realizacije nastavnog programa i ostvarenja ciljeva, te tako dovesti do konfuzije i nezadovoljstva učenika/studenata, ali i predstavljati problem za nastavnike.

Neki od glavnih izazova e-učenja su [45], [46]:

- prilagođavanje učenika/studenata na e-učenje,
- motivisanje učenika/studenata,
- angažovanje učenika/studenata,
- realna procena rezultata učenika/studenata.

Onlajn kursevi nisu podesni za sve učenike/studente. Postoje oni koji se brže prilagođavaju i lakše prihvataju nove tehnologije, dok drugima treba više vremena da se naviknu na e-učenje. Početak kursa i proces adaptacije može predstavljati pravi izazov. Brzo prilagođavanje procesu učenja na ovakvim kursevima od velike je važnosti. Na ovaj način, učenici/studenti ne bi morali da brinu o tome da će u kasnijim fazama kursa zaostajati za svojom školskom/studijskom generacijom zbog dugog perioda adaptiranja na ovakav model. Takođe, učenici/studenti koji se ne snađu na početku kursa vrlo brzo mogu izgubiti interesovanje za učenje, što potencijalno može dovesti do njihovog odustajanja od kursa. Iz navedenih razloga, usvajanje koncepta e-učenja kao poznatog i komforног okruženja u procesu školovanja/studiranja od strane učenika/studenata jeste jedan od problema koji treba dublje sagledati i istražiti, kako bi se našlo efikasno rešenje.

Konzistentnost motivacije učenika/studenata tokom celog kursa predstavlja jedan od ključnih izazova e-učenja. Dok je kod mnogih učenika/studenata motivacija stabilna i nije im

potrebno stalno ohrabrenje od strane nastavnika, kod drugih to predstavlja problem. Fizičko odsustvo nastavnika i interakcija koja nije u okolnostima nastavnog prostora utiču na usredsređenost pojedinih učenika/studenata i u korelaciji je sa opadanjem nivoa motivacije. Neuspeh u motivisanju učenika/studenata na onlajn kursu može dovesti do gubitka njihove želje za učenjem i negativno se odraziti na njihovo postignuće.

Angažovanje učenika/studenata na kursu e-učenja zavisi od mnogo faktora kao što su relevantnost kursa, njegova zanimljivost, podrška tokom kursa itd. Pored toga, lične karakteristike učenika/studenata, kao što su radoznalost, interesovanje i stepen pažnje takođe imaju dosta uticaja. Da li će se visok nivo angažovanja učenika/studenta održati tokom celog kursa umnogome zavisi i od samog dizajna kursa, odnosno nastavnog plana i programa, aktivnosti, zadataka itd. Održavanje visokog nivoa angažovanja učenika/studenata jedan je od ključnih izazova sa kojima se nastavnici susreću i koji se mora posebno aktuelizovati kako bi se obezbedilo da što više učenika/studenata uspešno završi kurs.

Realna procena rezultata učenika/studenata na onlajn kursevima takođe se nalazi među ovim velikim izazovima. Digitalni oblik komunikacije u nastavnom procesu sužava percepciju nastavnika u domenu ustanavljanja sposobnosti učenika/studenata. Ukoliko pitanja nisu prilagođena znanju i veštinama ispitanika, ostvareni rezultati na testu neće biti pravi pokazatelj njihovog napretka. Takođe, polaganje testova na daljinu povećava rizik od varanja, čime se legitimitet učenikovog/studentovog uspeha dovodi u pitanje. Između ostalog, tokom testiranja mogu se javiti i različiti tehnološki problemi koji mogu uticati na ukupan rezultat učenika/studenata, kao što su pad servera, zamrzavanje ekrana, razni bagovi itd.

Kako bi se prevazišli ovakvi izazovi neophodna su efikasna rešenja i metode. Upravo, rešenje za brojne izazove e-učenja mnogi vide u implementaciji inteligentnih tehnika u sisteme za e-učenje [47], [48]. Inteligentni sistemi za e-učenje podržani ovim tehnikama moći će da odgovore na većinu izazova i tako utiću na veće zadovoljstvo učenika/studenata, njihovu motivaciju i angažovanje. Korišćenje inteligentnih tehnika omogućiće nastavnicima da osavremene onlajn nastavu i unaprede sveukupno iskustvo učenja učenika/studenata na sistemu za e-učenje. Ova disertacija ima za cilj da pomogne u prevazilaženju izazova e-učenja predstavljanjem inteligentnih tehnika koje se koriste u ovoj oblasti, naglašavanjem njihovih prednosti za proces učenja i određivanjem njihovih uloga u unapređenju obrazovnih sistema.

## 2.2. Inteligentne tehnike u e-učenju

Inteligentne tehnike koriste se u e-učenju za unapređenje procesa učenja i imaju važnu ulogu u obezbeđivanju resursa koji su neophodni učenicima/studentima. Metod postignuća ovih tehnika sadržan je u tome što uzimaju u obzir zahteve, motivaciju, ali i emocionalna stanja učenika/studenata [49]. Mnogi istraživači istakli su da postoji potreba za novim intelligentnim tehnologijama koje će na efikasniji način moći da personalizuju proces učenja kroz preporuku sadržaja i sekvenciranje resursa, kao i da osiguraju učenicima/studentima kvalitetnije automatsko navođenje i pruže pouzdanije povratne informacije [47], [50], [51].

Većina intelligentnih tehnika predstavljaju veštačku inteligenciju (kao što su ANN, duboko praćenje znanja, genetski algoritam itd.), dok se neke od njih ne smatraju veštačkom inteligencijom (Elo algoritam, probabilitička teorija testiranja itd.) ali se koriste u sistemima za e-učenje za obezbeđivanje intelligentnih pristupa za postizanje prilagođavanja, procene ili modelovanja učenika/studenata [12]. U nastavku je predstavljen detaljan pregled intelligentnih tehnika koje se primenjuju u e-učenju [12], [52], [53], [54], [55], [56], [57], [58], [59], [60].

### 2.2.1. Modelovanje učenika/studenta

Modelovanje učenika/studenta (eng. *Learner modeling*) jeste proces prikupljanja podataka o učenicima/studentima i stvaranja njihovih modela na osnovu tih podataka [61]. Ovi podaci menjaju se tokom vremena, tako da je modelovanje učenika/studenata zaduženo i za ažuriranje modela na osnovu novih podataka. Stvaranje modela učenika/studenata neophodno je u e-učenju kako bi svaki učenik/student dobio nastavni materijal prilagođen svojim veštinama i potrebama.

Praćenje i beleženje različitih aktivnosti učenika/studenata u sistemima za e-učenje, radi preciznog prikupljanja potrebnih parametara, zahteva određene standarde. Referentni model objekta sa deljivim sadržajem (eng. *Sharable content object reference model*) jeste jedan takav standard koji je dugo godina bio aktuelan [62]. Njega je zbog određene nefleksibilnosti i novih trendova na internetu nasledio takozvani iskustveni API (eng. *Experience API*) [63]. Zahvaljujući njemu, omogućeno je čuvanje aktivnosti učenika/studenata na serveru koji se naziva skladište učenikovih/studentovih zapisa (eng. *Learner record store*) [64]. Prikupljanje ovih podataka determinisano je u sistemima za e-učenje kako bi na osnovu njih određenim tehnikama modelovanja mogli da se kreiraju modeli učenika/studenata.

Postoje dva pristupa prikupljanja podataka o učenicima/studentima na osnovu kojih se mogu napraviti njihovi modeli [65]:

- Pristup zasnovan na znanju - sakuplja potrebne podatke za kreiranje modela kroz razne načine ispitivanja učenika/studenata, popunjavanje upitnika, otkrivanja njihovih interesovanja, preferiranih načina učenja i rutina koje primenjuju.
- Pristup zasnovan na ponašanju - fokusira se na ponašanje učenika/studenata u sistemima za e-učenje i aktivnostima koje oni izvršavaju u njima.

Vrsta podataka koja se prikuplja kako bi na osnovu njih moglo da se izvrši modelovanje učenika/studenta može se podeliti u šest kategorija [66]:

1. Podaci sa profila učenika/studenta - podrazumevaju osnovne podatke koje je učenik/student ostavio pri registraciji kao što su ime, prezime, korisničko ime, godine, pol, država itd.
2. Znanje učenika/studenta - uključuje različite kompetencije, procenu tačnosti završenih zadataka, kao i netačnih i slično.
3. Kognitivne karakteristike učenika/studenta - obuhvataju njegovo ponašanje u sistemu za e-učenje, strategije i taktike koje primenjuje itd.
4. Društvene karakteristike učenika/studenta - sublimiraju društveni stil, kulturu, socijalni status itd.
5. Motivacija učenika/studenta - predstavlja sve ono što ga podstiče da uči, kao što su npr. ciljevi koje je učenik/student postavio.
6. Osobenost učenika/studenta - odražava specifične stvari koje čine njegovu autentičnost.

Postoji 5 tehnik modelovanja kojima može da se napravi model učenika/studenta u sistemima za e-učenje [66]:

- Tehnike prediktivnog modelovanja (eng. *Predictive modeling techniques*) - kreiraju model učenika/studenta tako što se na osnovu postojećih podataka anticipiraju budući rezultati.
- Tehnike grupisanja i klasifikacije (eng. *Clustering and classification techniques*) - formiraju model učenika/studenta tako što dele učenike/studente u grupe, na osnovu sličnih karakteristika, rezultata itd.

- Modelovanje preklapanja (eng. *Overlay modeling*) - tehnika koja pravi model svakog pojedinačnog učenika/studenta kao podskup modela domena, koji predstavlja stručno znanje za određenu oblast.
- Modelovanje nesigurnosti (eng. *Uncertainty modeling*) - predstavlja način stvaranja modela učenika/studenta na osnovu procene karakteristika učenika/studenta koje imaju određene nepreciznosti.
- Modelovanje učenika/studenta zasnovano na ontologiji (eng. *Ontology-based learner modeling*) - tehnika koja na osnovu kombinovanja podataka iz više izvora formira model učenika/studenta.

Modelovanje učenika/studenta predstavlja potrebu svakog modernog sistema za e-učenje. Bez modela učenika/studenata koji se stvaraju putem ovog procesa nije moguće kreirati kurs usklađen sa afinitetima svakog učenika/studenta. Iz navedenih razloga, ovi modeli su od suštinskog značaja za sisteme e-učenja kako bi se na osnovu njih mogli prilagoditi obrazovni sadržaji, nastavni materijali i metodika nastave tako da odgovaraju svakom pojedincu.

Sistem za e-učenje korišćen u ovoj disertaciji za sprovođenje eksperimenata sa studentima modeluje korisnike sistema, prikuplja podatke o njima i beleži njihove aktivnosti. Time su obezbeđeni relevantni podaci za dalja istraživanja, budući da su kurs i nastavni materijal bili prilagođeni svakom studentu na osnovu njihovih modela.

### *Otvoreni model učenika/studenta*

Otvoreni model učenika/studenta (eng. *Open learner model - OLM*, u daljem tekstu: OLM) predstavlja model učenika/studenta koji dozvoljava korisniku sistema, odnosno učeniku/studentu, da vidi svoj trenutni nivo znanja u formi u kojoj mogu da ga razumeju [67]. Na ovaj način učenici/studenti mogu da analiziraju svoje trenutno znanje, saznaju svoje slabosti, odnosno oblasti u kojima nisu ostvarili dobre rezultate. Pomenutim pristupom učenici/studenti mogu bolje da organizuju svoje učenje kako bi se popravili u oblastima koje nisu u potpunosti savladali, a da manje vremena provode u onima koje jesu.

Za predstavljanje nivoa znanja učenika/studenata OLM koristi različite načine prikazivanja. Najčešće su to različite vrste merača veština [68], konceptualne mape [69], kao i hijerarhijske strukture stabla [70].

Merači veština obično prikazuju nivo znanja učenika/studenta u vidu raznih traka napretka. Uz pomoć njih, učenicima/studentima daju se povratne informacije o njihovom prosperitetu u učenju i takođe omogućavaju učenicima/studentima da analiziraju svoje veštine.

Konceptualna mapa predstavlja dijagram uz pomoć kog se prezentuju pojmovi tj. koncepti i veze između njih. Koncepti su predstavljeni uz pomoć čvorova, a veze uz pomoć linija sa strelicama koje povezuju te koncepte. Ovakvim prikazom učenicima/studentima omogućeno je da analiziraju strukturu sopstvenog znanja, kako bi mogli da stvore jasnu sliku svog trenutnog stanja i uoče na kojim stvarima treba dodatno da rade.

Hijerarhijske strukture stabla su tip dijagrama koji predstavljaju podatke u hijerarhijskom obliku. U OLM-u omogućavaju jasan pregled pređenog gradiva i rezultata koje su učenici/studenti ostvarili na njemu.

Pored ovih načina prikazivanja takođe se koriste i oblaci reči (slika napravljena od reči koje formiraju izgled oblaka), mapa stabla (vizuelizacija sastavljena od ugnezđenih pravougaonika različitih boja), grafikoni (prezentovanje podataka u grafičkom formatu uz pomoć traka, linija itd.), tabele (obično matriks tabele sa označenim uspešno i neuspešno rešenim zadacima), radar grafikon (prikazuje multivariantne podatke koji sadrže tri ili više numeričkih varijabli poređanih na osi sa istom centralnom tačkom), histogrami (poseban tip grafikona koji prikazuje distribuciju podataka), krugovi (krugovi podeljeni u sektore koji na osnovu različitih nijansi boja omogućavaju učeniku/studentu pregled njegovog napretka), gridovi (demonstracija progrusa učenika/studenta na različitim lekcijama uz pomoć gridova), smajliji (opis nivoa znanja uz pomoć smajlija pri čemu tužno lice predstavlja najniži nivo, a srećno najviši), zvezde (prikaz podataka u nekoliko nivoa uz pomoć zvezda), nabranja (spisak tema sa nabranjem uz pomoć kružića, gde su kružići ispunjeni određenom količinom boje u odnosu na to koliko je učenik/student spremjan za započetnu lekciju) i mrežni dijagrami (povezani čvorovi koji na osnovu svoje veličine i različite nijanse boje indikuju intezitet teme koju je učenik/student obradio).

Može se identifikovati sedam tipova OLM-a na osnovu ciljeva koje treba postignuti njima [71]:

- Pregledni OLM (eng. *Inspectable OLM*) - omogućava učenicima/studentima da vide svoj model, preko već pomenutih načina prikazivanja. Ovim putem učenici/studenti imaju priliku da vide svoj trenutni nivo znanja, kao i da tokom vremena prate svoj razvoj i napredak [72].

- Promenljivi OLM (eng. *Editable OLM*) - pored toga što pruža pregled modela učenika/studenta, dopušta i njegovu promenu. Učenici/studenti koji nisu zadovoljni kako je OLM predstavio njihov nivo znanja na određenoj lekciji mogu samostalno da izvrše promenu [73]. Ovo je često slučaj kada sistem jednostavno nema još uvek kapacitet da identificuje sve pojedinosti - zabeleži aktivnosti i detektuje odrednice kao što su npr. učenikovo/studentovo postojeće znanje o toj materiji koje on još nije mogao da demonstrira i slično.
- Izazvan OLM (eng. *Challenged OLM*) - dozvoljava učenicima/studentima da unesu nove argumente kojima će osporiti postojeće iskaze sistema date za prikaz znanja u okviru određene teme/oblasti i time opravdaju promene u modelu koje učenici/studenti sami unesu [72].
- Kooperativan OLM (eng. *Co-operative OLM*) - jeste slučaj u kome sistem zajedno sa učenikom/studentom radi na izgradnji njegovog modela kako bi se obrazovala optimalna konfiguracija modela i na taj način izbegla eventualna nezadovoljstva učenika/studenta njegovim prikazanim znanjem [74].
- OLM koji se može ubediti (eng. *Persuaded OLM*) - nudi opciju učenicima/studentima da polaganjem dodatnih kratkih testova ubede sistem da poseduje znanje o nekoj oblasti i tako promene svoj model učenika/studenata [75]. Naravno, model će se promeniti samo ako je učenik/student uspešno rešio jedan ili više testova ili određeni broj testova koje mu je zadao sistem.
- OLM sa dodavanjem dokaza (eng. *Add-evidence OLM*) - dopušta učenicima/studentima da prilože konkretne dokaze kako bi objasnili sistemu da je napravio propust u proceni i prezentovanju njihovog trenutnog znanja, i tako omoguće promenu svog modela učenika/studenta [76].
- Pregovarački OLM (eng. *Negotiated OLM*) - dozvoljava učenicima/studentima da pregovaranjem sa sistemom potencijalno promene svoj model [77]. Navedeni OLM funkcioniše tako što učenik/student mora da ubedi sistem - najčešće putem dijaloga - da poseduje znanje o određenoj temi.

Bitno je napomenuti da je svaki OLM pregledni, ali pored toga može biti i neki od gore navedenih.

U Tabeli 1 prikazani su sistemi za e-učenje koji implementiraju neki od pomenutih tipova OLM-a.

*Tabela 1. Sistemi za e-učenje sa OLM-om*

Tip OLM-a	Sistemi za e-učenje (sa publikacijom)
Pregledni OLM	<i>INSPIREus</i> [78]; Flexi-OLM [69]; AMAS OLE [79]; <i>UM toolkit</i> [80]; <i>Lea's Box</i> [81]; <i>ELM-ART</i> [82]; <i>EI-OSM</i> [83]; <i>Mr. Collins</i> [84]; <i>Next-TELL</i> [85]; <i>StyLE-OLM</i> [86]; <i>EER-Tutor</i> [87]; <i>MasteryGrids</i> [88]; <i>edCrumble</i> [68]; <i>SQL-Tutor</i> [89]; <i>VisMod</i> [90]; <i>VCM</i> [91]; <i>INGRID</i> [70]; <i>QuizMap</i> [92]; <i>GVIS</i> [93]; <i>NavEx</i> [94]; <i>Progessor</i> [95]; <i>E-KERMIT</i> [96]; <i>Subtraction Master</i> [97]; <i>Fraction Helper</i> [98]; <i>QuizPACK</i> [99]; <i>Doubtfire++</i> [100]; <i>TITUS</i> [101]; <i>CALMsystem</i> [102]; <i>PAL3</i> [103]; <i>NDLtutor</i> [75]; <i>Topolor 2</i> [104];
Promenljivi OLM	<i>INSPIREus</i> [78]; <i>Flexi-OLM</i> [69];
Izazvan OLM	<i>AMAS OLE</i> [79]; <i>VisMod</i> [90];
Kooperativan OLM	<i>UM toolkit</i> [80];
OLM koji se može ubediti	<i>Flexi-OLM</i> [69]; <i>Lea's Box</i> [81];
OLM sa dodavanjem dokaza	<i>ELM-ART</i> [82]; <i>EI-OSM</i> [83];
Pregovarački OLM	<i>Flexi-OLM</i> [69]; <i>Mr. Collins</i> [84]; <i>Next-TELL</i> [85]; <i>StyLE-OLM</i> [86]; <i>EER-Tutor</i> [87]; <i>CALMsystem</i> [102]; <i>NDLtutor</i> [75];

Radi omogućavanja funkcionalnosti sistema kao što su dodavanje dokaza i vođenje pregovora sa učenicima/studentima i ostalo, izazvan OLM, kooperativan OLM, OLM koji se može ubediti, OLM sa dodavanjem dokaza i pregovarački OLM koriste razne alate poput menija, alata za saradnju, kao i pregovaranja sa nastavnicima preko četova, ali takođe koriste i alate opremljene

veštačkom inteligencijom - pedagoške agente, konverzacijske agente i igre dijaloga [71], [105], [106].

OLM jeste neophodan deo svakog sistema za e-učenje. Učenicima/studentima pruža uvid u lični napredak i razvoj, podstiče njihovo razmišljanje i bolje rezonovanje, i na taj način im kreira prostor da sami podignu svoj nivo učenja.

Pored vizuelizacija koje pomažu učenicima/studentima da prate svoj napredak, neophodno je razviti i različite vizuelizacije za nastavnike, kao npr. one koje će im pomoći da steknu uvid u faktore vezane za interakciju učenika/studenata sa sistemom za e-učenje, a koji utiču na njihov uspeh. Takvim modulom u sistemu nastavnici bi imali mogućnost da koriste generisane informacije za poboljšanje kvaliteta nastave i učenja. Jedan od ciljeva ove disertacije jeste identifikovanje tih faktora koji doprinose višim ili nižim ocenama, kao i kreiranje vizuelizacije koja će pružiti uvid u ove ključne aspekte.

### 2.2.2. Obrazovno rudarenje podataka

Obrazovno rudarenje podataka (eng. *Educational data mining*) jeste proces koji omogućava analizu velikih količina podataka učenika/studenata, radi identifikacije raznih smislenih obrazaca na osnovu kojih je moguće bolje razumeti učenike/studente [107].

Rudarenje obrazovnih podataka podrazumeva određene faze: prikupljanje podataka, čišćenje podataka, odabir alata, odabir tehnike i analizu podataka (rudarenje) [108]. Slika 1 prikazuje ove faze i njihov redosled izvršavanja.



Slika 1. Faze rudarenja podataka

Najpre je neophodno prikupiti podatke o učenicima/studentima koji će biti obuhvaćeni analizom. Ranije je prikupljanje velike količine podataka učenika/studenata bilo veoma teško sprovesti. Međutim, danas je ovaj proces olakšan, s obzirom na to da se na veoma brz i efikasan način ovi podaci mogu prikupiti iz baza univerzitetskih sistema, kao i sistema za e-učenje. Nakon

prikupljenog neobrađenog materijala, sledi čišćenje podataka, odnosno uklanjanje vrednosti koje su netačne, nepotpune ili van normalnih granica. Ovaj korak je veoma važan kako bi se analiza podataka radila na što kvalitetnijem uzorku, pošto će se tako dobiti bolji i precizniji rezultati. Rudarenje obrazovnih podataka, naravno, nije moguće bez alata namenjenog za ovakve procese, tako da odabir alata predstavlja sledeći korak. Najpoznatiji i najkorišćeniji alati za obrazovno rudarenje podataka su *Weka*, *SPSS*, *RapidMiner*, *KNIME*, *Orange* [108] itd. Sledeći ne manje značajan segment jeste izbor odgovarajuće tehnike obrazovnog rudarenja podataka, što će biti aktuelizovano u nastavku ove sekcije. Poslednja faza jeste i cilj ovog procesa - sama analiza podataka kako bi se dobili određeni rezultati na osnovu kojih će moći da se preduzmu odgovarajući koraci u cilju poboljšanja celokupnog procesa učenja.

Postoji pet osnovnih inteligentnih tehnika obrazovnog rudarenja podataka koje se najčešće koriste [109]:

- Predviđanje (eng. *Prediction*) - funkcioniše tako što se na osnovu ulaznih parametara učenika/studenta radi predikcija njegovih budućih ponašanja, rezultata i slično. Za predviđanje se koristi nekoliko osnovnih tehnika - klasifikacija, regresija i skor gustine [110].
- Grupisanje (eng. *Clustering*) - proces podele učenika/studenata u nekoliko grupa na osnovu njihovih sličnosti, odnosno osobina, odlika i svojstava.
- Relacijsko rudarenje (eng. *Relationship mining*) - podrazumeva prepoznavanje veza u podacima između određenih stavki koje će kasnije biti korišćene za donošenje odluka, predikciju i slično. Postoji nekoliko tehnika ovog tipa rudarenja i to su rudarenje asocijativnih pravila, korelaciono rudarenje, rudarenje sekvencijalnih obrazaca i uzročno rudarenje podataka [110].
- Destilacija za ljudsku procenu (eng. *Distillation for human judgment*) - koristi vizuelizaciju podataka uz pomoć različitih grafikona ili kriva učenja, kako bi ljudi mogli da izvrše identifikaciju ili klasifikaciju podataka, koja bi teško mogla da se sprovede nekom automatizovanom tehnikom rudarenja podataka.
- Otkrivanje pomoću modela (eng. *Discovery with models*) - jeste proces koji je podeljen u dve faze - u prvoj fazi izrađuje se model pomoću ML tehnika ili nekih drugih metoda, kako bi se u drugoj fazi taj model koristio za dalje procene i analize.

U Tabeli 2 prikazani su sistemi za e-učenje koji implementiraju neku od pomenutih tehnika obrazovnog rudarenja podataka.

*Tabela 2. Sistemi za e-učenje sa obrazovnim rudarenjem podataka*

Tehnika	Sistemi za e-učenje (sa publikacijom)
Predviđanje	<i>AL-TESL-e-learning system</i> [111]; <i>Junyi Academy</i> [112];
Grupisanje	<i>dotLRN</i> [113]; <i>ESURBCA</i> [114];
Relacijsko rudarenje	<i>eDisiplin</i> [115]; <i>ESOG</i> [116]; <i>Blockly programming App</i> [117];
Destilacija za ljudsku procenu	<i>Canvas</i> [118];
Otkrivanje pomoću modela	<i>Cisco Networking Academy</i> [119]

Obrazovno rudarenje podataka danas predstavlja potrebu svake obrazovne institucije. Primenom ovog procesa obrazovne institucije biće u mogućnosti da na osnovu rezultata koje dobiju analizom podataka poboljšaju svoje kurseve, unaprede nastavne materijale, povećaju procenat prolaznosti na kursevima, kao i da smanje broj odustajanja od kurseva [120]. Istraživanje ove disertacije obuhvatilo je niz faza obrazovnog rudarenja podataka, uključujući prikupljanje i čišćenje podataka, selekciju odgovarajućih alata i tehnika, nakon čega je usledilo predviđanje uspeha studenata.

### **2.2.3. Praćenje znanja**

Praćenje znanja (eng. *Knowledge tracing*) jeste proces praćenja interakcije učenika/studenata sa sistemom za e-učenje, kako bi na osnovu datih podataka moglo da se predviđi njihovo buduće ponašanje [121].

Dve osnovne inteligentne tehnike koje se koriste za praćenje znanja su:

- Bajesovo praćenje znanja,
- duboko praćenje znanja.

Bajesovo praćenje znanja (eng. *Bayesian knowledge tracing*) jeste tehnika veštačke inteligencije koja se koristi u sistemima za e-učenje za utvrđivanje znanja učenika/studenta na

osnovu postignutog uspeha, kako bi moglo da se predvidi njegovo ovladavanje određenom veštinom [122]. Ova tehnika pokušava da anticipira učenikovo/studentovo ovladavanje veštinom (koje može biti savladano ili nesavladano) samo na osnovu toga kako je učenik/student odgovarao na pitanja ili rešavao problem po principu tačno ili netačno.

Duboko praćenje znanja (eng. *Deep knowledge tracing*), u odnosu na Bajesovo praćenje znanja, jeste novija tehnika veštačke inteligencije za modelovanje znanja učenika/studenta, koja za sam proces modelovanja koristi rekurentnu neuronsku mrežu [121]. Ova tehnika automatski prati stanje znanja učenika/studenta i njegov uspeh ostvaren na zadacima u sistemu za e-učenje, kako bi na osnovu njegovih ranijih odgovora na pitanja ili rešenja zadataka uspeo da izvrši predikciju budućeg uspeha [123].

U Tabeli 3 prikazani su sistemi za e-učenje koji implementiraju neku od pomenutih tehnika praćenja znanja.

*Tabela 3. Sistemi za e-učenje sa praćenjem znanja*

Tehnika	Sistemi za e-učenje (sa publikacijom)
Bajesovo praćenje znanja	<i>CRYSTAL ISLAND</i> [124]; <i>ASSISTment</i> [125]; <i>edX</i> [126]; <i>Coursera</i> [127]; <i>Robot language tutor</i> [128]; <i>SITS</i> [129];
Duboko praćenje znanja	<i>Khan academy</i> [121]; <i>Udacity</i> [130];

Usled velikog broja nedostataka postojećih tehnika, mnogi autori odlučili su se da razviju sopstvene modele za praćenje znanja kako bi unapredili ovaj proces.

Najpoznatiji novorazvijeni modeli za praćenje znanja su:

- dinamičke ključ-vrednost memorijске mreže,
- sekvensijalne ključ-vrednost memorijске mreže,
- analiza faktora performansi,
- duboka analiza faktora performansi,
- praćenje dubokog znanja vođeno preduslovima sa modelovanjem ograničenja,
- praćenje znanja učenika/studenata zasnovano na odlikama,
- samostalni model za praćenje znanja.

Dinamičke ključ-vrednost memoriske mreže (eng. *Dynamic key-value memory networks*) predstavljaju novi pristup za praćenje znanja koji može precizno da odredi nivo kompetencije učenika/studenta za svaki koncept koristeći odnose između osnovnih koncepata [131]. Ovaj model koristi pristup zasnovan na ANN-u sa proširenom memorijom kako bi rešio probleme praćenja znanja [132]. U poređenju sa Bajesovim praćenjem znanja i dubokim praćenjem znanja, ova tehnika postiže znatno bolje rezultate.

Sekvencijalne ključ-vrednost memoriske mreže (eng. *Sequential key-value memory networks*) takođe su novi pristup za praćenje znanja koji kombinuje sposobnost rekurentnog modelovanja i memoriskih kapaciteta standardnih modela dubokog učenja radi postizanja boljih performansi, što su rezultati testiranja i pokazali [133].

Analiza faktora performansi (eng. *Performance factors analysis*) ilustruje jednu od alternativa postojećim tehnikama za praćenje znanja, koja pokazuje donekle bolje rezultate u odnosu na njih [134]. Ovaj pristup koristeći logističku regresiju pokušava da projektuje uspeh učenika/studenta na određenom predmetu na osnovu njegovih ranijih uspešnih i neuspešnih pokušaja rešavanja zadataka.

Duboka analiza faktora performansi (eng. *Deep performance factors analysis*) jeste novija tehnika za praćenje znanja koja kombinuje standardnu analizu faktora performansi sa dubokim praćenjem znanja i koja je pored svoje jednostavne implementacije demonstrirala i bolje rezultate u odnosu na standardne tehnike [135].

Praćenje dubokog znanja vođeno preduslovima sa modelovanjem ograničenja (eng. *Prerequisite-driven deep knowledge tracing with constraint modeling*) jeste još jedan nov pristup za praćenje znanja koji na osnovu definisane matematičke formulacije reguliše model praćenja znanja na osnovu određenih veza između koncepata [136].

Praćenje znanja učenika/studenta zasnovano na odlikama (eng. *Feature aware student knowledge tracing*) predstavlja model praćenja znanja koji pomoću logističke regresije modeluje opšte odlike učenika/studenta kako bi se efikasno predviđao njegov učinak [137].

Samostalni model za praćenje znanja (eng. *Self-attentive model for knowledge tracing*) jeste još jedna tehnika za praćenje znanja koja u toku interakcije učenika/studenta sa sistemom svakom zadatku koji on rešava dodaje određenu vrednost (manju ili veću) kako bi pri procesu modelovanja uzimala u obzir samo relevantne rezultate iz njegovih ranijih pokušaja rešavanja

zadataka, a sve u cilju efikasnijeg predviđanja rezultata koje će učenik/student ostvariti na sledećem zadatku [138].

Praćenje znanja nudi mnoge benefite za e-učenje i neophodna je komponenta svakog sistema za e-učenje. Ovaj mehanizam pomaže u procesu personalizacije [139], pruža nastavnicima povratne informacije o učenicima/studentima i njihovim aktivnostima [140] i poboljšava proces učenja i efikasnost učenika/studenata [141]. Glavni izazovi i poteškoće sa kojima se praćenje znanja trenutno suočava su psihološki i bihevioralni aspekti nastavnog procesa, pogotovo aspekt dizajna učenja. Jedan od ciljeva disertacije je da na osnovu rezultata istraživanja pruži smernice za unapređenje procesa učenja u sistemima za e-učenje, koje potencijalno mogu pomoći u prevazilaženju ovih i sličnih problema vezanih za dizajn učenja.

#### 2.2.4. Analitika učenja

Analitika učenja (eng. *Learning analytics*) jeste proces koji podrazumeva analizu prikupljenih podataka učenika/studenata, odnosno njihove interakcije sa sistemom za e-učenje, kako bi se otkrili određeni trendovi, obrasci i veze u njihovom procesu učenja [142]. Ovo se postiže uz pomoć naprednih alata za analitiku učenja, kao i određenih tehnika, koji omogućavaju sveobuhvatnu analizu podataka kako bi se došlo do ovih rezultata. Neki od najpoznatijih alata za analitiku učenja su *SNAPP*, *eLAT*, *LOCO-Analyst*, *Course Signals*, *GLASS*, *ALAS-KA*, *Student Success System*, *TUT LA tool* [143] itd.

Tehnike koje se koriste za analitiku učenja su [109], [144]:

- tehnike obrazovnog rudarenja podataka,
- analiza društvenih mreža,
- statistička analiza.

Analitika učenja za svoje procese koristi potpuno iste tehnike kao i obrazovno rudarenje podataka, a to su: predviđanje, grupisanje, relacijsko rudarenje, destilacija za ljudsku procenu i otkrivanje pomoću modela [109]. Ove tehnike i način na koji one funkcionišu detaljno su opisane u sekciji Obrazovno rudarenje podataka.

Analitika učenja, pored tehnika obrazovnog rudarenja podataka, takođe koristi i analizu društvenih mreža, kao i statističku analizu [144].

Analiza društvenih mreža (eng. *Social network analysis*) jeste tehnika kojom se analiziraju društvene strukture i pokušavaju da se nađu obrasci između pojedinaca u grupi [145]. Za taj proces ova tehnika prikuplja podatke iz više izvora i koristi mreže i teoriju grafova kako bi istražila i ispitala društvene strukture [146]. Utvrđivanje veza između učenika/studenata u onlajn okuženju, radi dobijanja važnih informacija o njima, predstavlja cilj ove analize [147].

Statistička analiza (eng. *Statistical analysis*) jeste tehnika kojom se putem različitih statističkih operacija analiziraju podaci u svrhu otkrivanja određenih trendova [148]. Tim pristupom dobija se bolji uvid u podatke i omogućava njihovo lakše razumevanje. Pravilno tumačenje rezultata statističke analize može pomoći u boljem donošenju odluka vezanih za proces e-učenja [149].

Kontrolne table za analitiku učenja (eng. *Learning analytics dashboards*) služe za vizuelno prikazivanje rezultata analitike učenja, dobijenih nekom od pomenutih tehnika. Ove table koristeći jedan ili više načina vizuelizacije prikazuju ključne metrike učenika/studenata, njihov proces učenja i rezultate koje su postigli na kursu [150]. Prezentovanje podataka u ovim kontrolnim tablama je veoma jasno i prikazano obično uz bogat korisnički interfejs, na kome se učenici/studenti, ali i nastavnici veoma lako mogu snaći i protumačiti metrike koje predstavljaju znanje. Radi ilustracije ovih podataka, kontrolne table za analitiku učenja koriste razne tipove grafikona, indikatore, trake napretka, tabele i druge elemente. Učenici/studenti tako dobijaju važne povratne informacije o svom učenju, koje mogu da iskoriste za unapređenje svojih kompetencija i veština. Nastavnici ove table koriste za potrebe uočavanja trendova i obrazaca koje učenici/studenti stvaraju svojim aktivnostima u procesu učenja. Izvedeni zaključci služe nastavnicima za preduzimanje odgovarajućih akcija u daljoj realizaciji nastave i izvršenje neophodnih intervencija u vidu modifikovanja kursa, materijala i slično [151], [152].

Kontrolne table za analitiku učenja stoga su veoma slične OLM-u. Zajedničko svojstvo jeste da imaju sličnu namenu i ciljeve - vizuelizacija podataka učenika/studenata. Međutim, distinkcija se ogleda u tome da je OLM više okrenut prikazu podataka učenika/studenta u vidu njihovog trenutnog nivoa znanja, napretka koji postižu vremenom, ali i poteškoća sa kojima se suočavaju, dok kontrolne table za analitiku učenja i uopšteno analitika učenja rezultate učenika/studenta prikazuju u kontekstu predviđanja i donošenja odluka [67], [129]. OLM, između ostalog, prikaz rezultata zasniva na modelu učenika/studenta koji je stvoren u procesu modelovanja

učenika/studenta i kasnijem ažuriranju tih podataka, dok kontrolne table za analitiku učenja svoje rezultate zasnivaju van ovog konteksta, što je izuzetno značajna razlika [153].

U Tabeli 4 prikazani su sistemi za e-učenje koji implementiraju neku od pomenutih tehnika analitike učenja i sistemi koji implementiraju kontrolne table za analitiku učenja.

*Tabela 4. Sistemi za e-učenje sa analitikom učenja*

<b>Tehnika</b>	<b>Sistemi za e-učenje (sa publikacijom)</b>
Tehnike obrazovnog rudarenja podataka	<i>Desire2Learn</i> [154]; <i>Blackboard Vista</i> [118];
Analiza društvenih mreža	<i>OSBЛЕ+</i> [155];
Statistička analiza	<i>OU Analyse</i> [156];
Kontrolna tabla za analitiku učenja	<i>MathSpring</i> [157]; <i>SCELE</i> [158]; <i>Cyber Campus</i> [152]; <i>OUJ system</i> [159]; <i>iTutor</i> [160]; <i>SoftLearn</i> [161];

S obzirom na to da se taktike i strategije učenika/studenata uglavnom otkrivaju uz pomoć anketa ili upitnika, u e-učenju analitika učenja može biti važna komponenta za ovaj proces. Uz pomoć analitike učenja mogu se otkriti taktike i strategije učenika/studenata i te informacije iskoristiti da se ostvari određeni uticaj na njihovo učenje [162]. Analitika učenja to postiže analizom *log* fajlova učenika/studenata, otkrivajući na osnovu toga određene obrasce koje u vidu povratnih informacija dobijaju nastavnici [163]. Ovaj način otkrivanja učenikovih/studentovih stilova učenja mnogo je verodostojniji u odnosu na upotrebu anketa ili upitnika u kojima se učenik/student priseća svojih aktivnosti u sistemu za e-učenje i gde uvek postoji mogućnost da na postavljena pitanja ne odgovara istinito [164]. Analitika učenja može preciznije da odredi taktike i strategije učenika/studenta pošto analizira realne aktivnosti na kojima je učenik/student učestvovao i akcije koje je preduzimao u procesu učenja.

Informacije koje se dobiju pomoću analitike učenja, nakon otkrivanja taktika i strategija učenika/studenata koje oni primenjuju u procesu učenja, dizajneri učenja koriste za potrebe dizajna učenja, odnosno njegovo poboljšanje. Dizajn učenja (eng. *Learning design*) predstavlja postupak kreiranja okruženja za učenje sa odgovarajućim sadržajem i planiranim aktivnostima za učenike/studente [165]. Dizajneri učenja uz pomoć analitike učenja mogu znatno da olakšaju proces učenja i podignu njegov kvalitet. U to su uključeni poboljšanje nastavnog plana i programa,

materijala, zadataka, kvizova, rasporeda aktivnosti itd., a sve na osnovu informacija dobijenih od analitike učenja [166]. Dizajn učenja i analitika učenja zajedno omogućavaju nastavnicima poboljšanje nastavne prakse i pomažu u kreiranju personalizovanog okruženja za učenike/studente [167].

Analitika učenja postala je neophodna komponenta u e-učenju. Pomoću nje mogu da se optimizuju različite funkcije u sistemima za e-učenje, poveća kvalitet nastave i poboljša iskustvo učenja učenika/studenta. Jednostavno rečeno - sistemi za e-učenje mogu iskoristiti analitiku učenja za poboljšanje celokupnog procesa učenja. Kako bi se u okviru istraživanja ove disertacije dobio bolji uvid u podatke i omogućilo njihovo lakše razumevanje, korišćena je statistička analiza kao jedna od standardnih tehnika analitike učenja.

### **2.2.5. Adaptivna procena znanja**

Adaptivna procena znanja (eng. *Adaptive assessment*), poznata i kao kompjutersko adaptivno testiranje (eng. *Computerized adaptive testing*), jeste proces koji podrazumeva prilagođavanje pitanja u okviru testa svakom ispitaniku na osnovu znanja koje on poseduje [168]. Svaki učenik/student dobija jedinstven test koji je sastavljen od pitanja ili zadataka koji su prilagođeni njegovom znanju, sposobnostima i veštinama. Pitanja u testu prilagođavaju se učeniku/studentu na osnovu njegovih odgovora na prethodno pitanje u testu, odnosno ako je tačno odgovorio na prethodno pitanje sledeće će dobiti teže, a ako je netačno odgovorio onda će dobiti lakše naredno pitanje.

Razlog za uvođenje adaptivne procene znanja u sisteme za e-učenje je to što se u tradicionalnom obrazovanju uglavnom prave testovi koji podrazumevaju isti skup pitanja za sve učenike/studente, stoga nije moguće pravilno ustanoviti sposobnosti i veštine svakog pojedinca. Informacije koje se tom prilikom dobiju o učenicima/studentima mogu biti poprilično ograničene i ne mogu biti pravi pokazatelj njihovog znanja i napretka. Upravo iz tog razloga adaptivna procena znanja može preciznije odrediti umeće i kompetencije svakog učenika/studenta. Navedeno podrazumeva dobijanje informacija o učenicima/studentima na osnovu kojih mogu da se odrede njihove potrebe na određenom predmetu ili tokom celog studiranja, praćenje njihovog razvoja i napretka, kao i usmeravanje učenika/studenta ka programima koji su u sferi njegovog interesovanja [169].

Nemogućnost dobijanja istog skupa pitanja na testu kada se koristi adaptivna procena znanja smanjuje verovatnoću za prepisivanjem i varanjem učenika/studenata na testovima. Ranije su nastavnici morali da smišljaju više grupa testova u pokušaju da se izbore sa prepisivanjem, ali sada o tome ne moraju da brinu.

Inteligentne tehnike koje se najčešće koriste za adaptivnu procenu znanja su:

- probabilitička teorija testiranja,
- Elo algoritam za ocenjivanje,
- *TrueSkill*.

Probabilitička teorija testiranja (eng. *Item response theory*) predstavlja statističku tehniku koja se koristi za merenje sposobnosti učenika/studenta na osnovu njegovih odgovora na postavljena pitanja u okviru određenog testa [170]. Ova tehnika našla je svoju primenu u sistemima za e-učenje za adaptivnu procenu znanja kako bi se uz pomoć nje vršila procena težine svih pitanja na testu (na osnovu tačnosti odgovora svih ispitanika) i na osnovu toga nudila pitanja učenicima/studentima prilagođena njihovim sposobnostima.

Elo algoritam za ocenjivanje (eng. *Elo rating algorithm*) prvobitno je razvijen za rangiranje igrača u šahu, ali potom je primenu našao i u sistemima za e-učenje kao tehniku uz pomoć koje se može izmeriti znanje učenika/studenta [171]. Ova tehnika prilagođena je sistemima za e-učenje tako da se učenik/student smatra igračem - njegovog protivnika predstavlja pitanje/problem i tačan odgovor/rešenje označava pobedu, dok netačan označava poraz [172]. Ako učenik/student tačno odgovori na pitanje ili reši problem uspešno njegov rang će se povećati, dok će se u slučaju neuspeha smanjiti.

*TrueSkill* je isto tehniku za adaptivnu procenu znanja koja je prvobitno razvijena za rangiranje igrača u video-igramama [173]. Kao i za Elo algoritam, *TrueSkill* je prilagođen za potrebe e-učenja, kako bi se uz pomoć njega odredila sposobnost učenika/studenta. Funkcioniše tako da je ceo proces konceptualizovan da se umesto nalaženja podudaranja između dva igrača u video-igri uoči podudaranje između učenika/studenta i problema u sistemu za e-učenje, kako bi se ustanovala njegova sposobnost za rešavanje drugih problema [174].

U Tabeli 5 prikazani su sistemi za e-učenje koji implementiraju neku od pomenutih tehniku adaptivne procene znanja.

*Tabela 5. Sistemi za e-učenje sa adaptivnom procenom znanja*

Tehnika	Sistemi za e-učenje (sa publikacijom)
Probabilitička teorija testiranja	<i>UZWEBMAT</i> [175]; <i>MISTRAL</i> [176]; <i>Amrita Learning</i> [177]; <i>SIETTE</i> [178]; <i>UTS</i> [179]; <i>English vocabulary learning system</i> [180]; <i>SamurAI</i> [181]; <i>PEL-IRT</i> [182]; <i>Lexue 100</i> [183];
Elo algoritam za ocenjivanje	<i>ProTuS</i> [184]; <i>Math Garden</i> [185]; <i>Matistikk</i> [186]; <i>ACT Academy</i> [187];
<i>TrueSkill</i>	<i>APACTS</i> [188];

Adaptivna procena znanja čini neizostavni deo svakog sistema za e-učenje. Bez nje nije moguće precizno odrediti znanje svakog učenika/studenta. Korišćenje ovog vida procene znanja može pozitivno uticati na poboljšanje učinka učenika/studenta, njihovu motivaciju, kao i celokupno iskustvo tokom kursa.

Sistem za e-učenje korišćen u ovoj disertaciji za sprovođenje eksperimenata sa studentima opremljen je Elo algoritmom za ocenjivanje. S obzirom na značaj i ulogu adaptivne procene znanja u e-učenju, posebna pažnja posvećena je ispitivanju Elo rejtinga kao potencijalnog prediktora.

#### **2.2.6. Personalizacija u e-učenju**

Personalizovano učenje može se definisati kao pristup učenju koji obezbeđuje materijale, instrukcije i aktivnosti prilagođene svakom učeniku/studentu, odnosno njegovim veštinama, potrebama i interesovanjima [189]. Ovo se postiže na osnovu analize različitih faktora, kao što su određene karakteristike učenika/studenata, njihove navike, preferencije, prethodno znanje, aktivnosti u sistemima za e-učenje itd. Uzimajući u obzir ove faktore, nastavni plan se prilagođava i optimizuje za svakog učenika/studenta ponaosob, tako da svako od njih može da uči sopstvenim tempom.

Veštačka inteligencija pokazuje svoj pun kapacitet i potencijal kada se aktuelizuje stvaranje personalizovanog okruženja za učenike/studente, nudeći veliki broj metoda i tehnika koje mogu da se koriste u svrhu prilagođavanja procesa učenja.

Metode personalizacije koje se najčešće koriste u sistemima za e-učenje su:

- preporuka sadržaja,
- sekvenciranje resursa/nastavnog materijala,
- pružanje automatskih povratnih informacija.

Ove metode personalizacije, koristeći različite tehnike, omogućavaju kustomizovano okruženje u sistemima za e-učenje koje svakom učeniku/studentu pruža jedinstveno iskustvo. Personalizacija je ključni element ove disertacije, jer u sprovođenju eksperimenata sa studentima korišćen je adaptivni sistem za e-učenje. Značajan uticaj ove metode ogleda se u efektu na proces učenja studenata i na njihov uspeh, omogućavajući im personalizovane putanje učenja, preporuke sadržaja i druge prilagođene resurse.

#### *Preporuka sadržaja*

Sistemi za preporuku (eng. *Recommender systems*) mogu se definisati kao softverski mehanizmi koji imaju za cilj da predlože ili preporuče korisnicima određene stavke koje su povezane sa njihovim interesovanjima [190]. U sistemima za e-učenje nalaze primenu uglavnom za preporučivanje nastavnog materijala, zadataka i ostalih nastavnih resursa. Proces preporuke odvija se tako što određeni algoritmi veštačke inteligencije u pozadini sistema vrše identifikaciju raznih obrazaca i trendova, na osnovu kojih se učenicima/studentima preporučuju materijali za učenje koji su relevantni za njih [191].

Tri osnovne tehnike koje sistemi za preporuku koriste su:

- Filtriranje zasnovano na sadržaju (eng. *Content-based filtering*) - predstavlja način preporuke novih objekata sličnih performansi poput onih koje je učenik/student birao u prošlosti.
- Filtriranje zasnovano na znanju (eng. *Knowledge-based filtering*) - jeste tehnika koja radi preporuke na osnovu znanja koje poseduje o učeniku/studentu i njegovim afinitetima, u odnosu na nastavne sadržaje koji su dostupni.
- Kolaborativno filtriranje (eng. *Collaborative filtering*) - radi preporuke na osnovu informacija koje ima o drugim učenicima/studentima i njihovim preferencijama u vezi sa

nastavnim materijalom, koje potom upoređuje sa posmatranim učenikom/studentom i njegovim preferencijama tražeći slične obrasce.

Pored ove tri osnovne tehnike preporuke sadržaja, u e-učenju često se koriste i hibridne tehnike. Ove tehnike za preporuku podrazumevaju kombinaciju dveju ili više standardnih tehnika, kako bi se izvršila preporuka nastavnog sadržaja. Primena istih omogućava prevazilaženje nedostataka standardnih tehnika i ostvarenje efikasnije preporuke učenicima/studentima. Primeri hibridnih tehnika su: kolaborativno filtriranje zasnovano na mašini podržavajućih vektora (eng. *Support vector machine based collaborative filtering*) [192], asocijativna pravila sa filtriranjem zasnovanim na sadržaju i kolaborativnim filtriranjem (eng. *Association rules with content-based and collaborative filtering*) [193], rudarenje sekvencijalnih obrazaca sa filtriranjem zasnovanim na znanju (eng. *Sequential pattern mining with knowledge-based filtering*) [194] itd.

U Tabeli 6 prikazani su sistemi za e-učenje koji implementiraju neku od pomenutih tehnika za preporuku sadržaja.

*Tabela 6. Sistemi za e-učenje sa preporukom sadržaja*

Tehnika	Sistemi za e-učenje (sa publikacijom)
Filtriranje zasnovano na sadržaju	<i>Quickstep</i> [195]; <i>CBNR</i> [196];
Filtriranje zasnovano na znanju	<i>MDB</i> [197]; <i>ADO-Tutor</i> [198]; <i>CSS-Tutor</i> [199]; <i>ScholarLite</i> [200];
Kolaborativno filtriranje	<i>PeerGrade</i> [201]; <i>LAMS</i> [202]; <i>LogCF</i> [203];
Hibridne tehnike	<i>CodERS</i> [204]; <i>RSPP</i> [205]; <i>MoodleRec</i> [206];

Korišćenje sistema za preporuku može pomoći učenicima/studentima da lakše, brže i efikasnije dođu do željenog nastavnog sadržaja koji je prilagođen njihovim interesovanjima i veštinama. Na osnovu navedenih benefita jasno je da oni predstavljaju važne segmente svakog sistema za e-učenje.

#### *Sekvenciranje resursa/nastavnog materijala*

Učenicima/studentima je potrebno obezbediti adekvatan nastavni materijal, odnosno resurse za učenje koje će proučavati tokom kursa kako bi dosegli svoje ciljeve učenja [207]. Ovi

resursi treba da budu dobro osmišljeni od strane nastavnika, uklapljeni u nastavni plan i potom ubačeni u putanju učenja učenika/studenata. Putanja učenja predstavlja proces organizovanja aktivnosti učenja u odgovarajućem redosledu, stvarajući određenu rutu kojom učenici/studenti prolaze tokom svog procesa učenja [208]. Sekvenciranje resursa (eng. *Resource sequencing*) jeste proces koji se odvija u sistemima za e-učenje gde se na osnovu različitih karakteristika učenika/studenta i pokazanog znanja generiše putanja učenja specijalno personalizovana za svakog od njih [209]. Kreiranje optimalne putanje učenja za svakog učenika/studenta predstavlja komplikovan proces u kome veštačka inteligencija ima bitnu ulogu. Veštačka inteligencija može da identificuje probleme sa kojima se učenici/studenti susreću u učenju, kako bi prilagodila putanju učenja, kao i redosled prikazivanja nastavnog materijala i aktivnosti [210].

Postoji veliki broj tehnika koje se koriste za sekvenciranje resursa u sistemima za e-učenje i to su:

- Genetski algoritam (eng. *Genetic algorithm*) - predstavlja tehniku zasnovanu na procesu prirodne selekcije koja se koristi za potrebe pretrage i optimizacije, kao i rešavanje drugih složenih problema [211].
- Memetički algoritam (eng. *Memetic algorithm*) - tehniku za rešavanje teških problema optimizacije, koja obično koristi lokalnu tehniku pretraživanja kako bi mogućnost preuranjene konvergencije sveo na minimum [212].
- Mravlji algoritam (eng. *Ant colony optimization*) - predstavlja tehniku za optimizaciju zasnovanu na ponašanju kolonije mrava pri potrazi za hranom, koja se koristi za generisanje optimalnih putanja [213].
- Optimizacija rojem čestica (eng. *Particle swarm optimization*) - jeste tehniku inspirisana ponašanjem raznih rojeva u prirodi, koja se koristi za nalaženje efikasnih rešenja i generisanje putanja [214].
- Algoritam kolonije pčela (eng. *Artificial bee colony*) - jeste još jedna tehniku koja inspiraciju nalazi u prirodi - ovog puta u roju pčela i njihovoj potrazi za hranom - koja se upotrebljava za rešavanje mnogih problema vezanih za optimizaciju [215].

U Tabeli 7 prikazani su sistemi za e-učenje koji implementiraju neku od pomenutih tehnika sekvenciranja resursa.

*Tabela 7. Sistemi za e-učenje sa sekvenciranjem resursa*

<b>Tehnika</b>	<b>Sistemi za e-učenje (sa publikacijom)</b>
Genetski algoritam	<i>LPRS_EL</i> [216];
Memetički algoritam	<i>TPG</i> [217];
Mravlji algoritam	<i>ACSEL</i> [218]; <i>LPR</i> [219];
Optimizacija rojem čestica	<i>IDRCCS</i> [220];
Algoritam kolonije pčela	<i>PBREL</i> [221];

Sekvenciranje resursa u sistemima za e-učenje, primenom neke od nabrojanih tehnika, može da pruži učenicima/studentima jasno definisan, sveobuhvatan i organizovan pristup učenju, omogućavajući im lakše savladavanje gradiva na kursu kako bi ubrzali svoj napredak. Generisanje personalizovanih putanja učenja može povećati motivaciju i angažovanje učenika/studenta na kursu, za razliku od scenarija gde svi učenici/studenti imaju istu putanju učenja. Celokupan kvalitet učenja može se podići, a učinak učenika/studenata poboljšati ukoliko sistemi za e-učenje implementiraju sekvenciranje resursa za generisanje personalizovane putanje učenja [222].

#### *Automatske povratne informacije*

Jedan od najvažnijih aspekata e-učenja jeste da učenici/studenti tokom celokupnog procesa učenja treba da imaju neku vrstu pomoći i povratne informacije [223]. Povratne informacije mogu se definisati kao komentar ili odgovor koji sistem daje učenicima/studentima na aktivnostima u kojima učestvuju, akcijama koje preduzimaju i rezultatima koje ostvaruju. One na određeni način predstavljaju podršku za učenike/studente tokom kursa i njihova svrha jeste u tome da učenik/student na osnovu njih ostvari određeni napredak u procesu učenja.

U modernim sistemima za e-učenje teži se ka tome da povratne informacije za svakog učenika/studenta budu personalizovane. Generisanje takve vrste povratnih informacija moguće je ukoliko je sistem za e-učenje opremljen veštačkom inteligencijom koja će učiniti optimalnom analizu učenika/studenata i njihovih aktivnosti [224]. Personalizovane povratne informacije kreiraju se na osnovu odlika učenika/studenata, njihovog pristupa učenju, znanja koje prikazuju i slično [225]. Navedeni model davanja povratnih informacija mnogo je korisniji za učenike/studente u odnosu na pristup u kome se iste povratne informacije generišu za sve.

Postoje dve osnovne tehnike, odnosno načina prikazivanja povratnih informacija u sistemima za e-učenje:

- Generisanje tekstualnih povratnih informacija - standardan vid prikazivanja povratnih informacija koji podrazumeva tekstualne poruke upućene učeniku/studentu nakon uspešno ili neuspešno održenog zadatka i slično.
- Generisanje povratnih informacija u formi videa - redi, ali inovativniji način prikaza povratnih informacija koji kao podršku šalje određeni video. Praksa u strukturiranju ovakvih povratnih informacija jeste da kada učenik/student ima problema sa rešavanjem konkretnog zadatka, sistem to prepozna i pošalje učeniku/studentu video sa dodatnim informacijama koji treba da mu pomogne pri rešavanju problema.

U Tabeli 8 prikazani su sistemi za e-učenje koji implementiraju neku od pomenutih tehnika za generisanje personalizovanih povratnih informacija.

*Tabela 8. Sistemi za e-učenje sa generisanjem povratnih informacija*

Tehnika	Sistemi za e-učenje (sa publikacijom)
Generisanje tekstualnih povratnih informacija	<i>SQL Quizbot</i> [226]; <i>Pgtracer</i> [227]; <i>UCOM</i> [228];
Generisanje povratnih informacija u formi videa	<i>ASSET</i> [229];

Pružanje personalizovanih povratnih informacija učenicima/studentima u sistemima za e-učenje može imati pozitivan efekat na njih, njihovo učenje i celokupno iskustvo na kursu. Takođe, može imati veliki uticaj na poboljšanje njihovog uspeha i dostignuća [230].

#### **2.2.7. Inteligentni agenti**

Inteligentni agenti (eng. *Intelligent agents*) predstavljaju softverske entitete koji deluju u sistemima za e-učenje sa ciljem izvršenja određenih akcija i zadataka [231]. Zaduženi su za praćenje aktivnosti učenika/studenata tokom njihovog učenja radi sakupljanja podataka o njima. Ove podatke agenti potom obrađuju i analiziraju kako bi došli do određenih saznanja i zaključaka,

sa namerom da se te informacije iskoriste za optimizaciju okruženja za učenje [232]. Na taj način utiču na pojednostavljenje i poboljšanje celokupnog procesa učenja.

Inteligentni agenti specijalizovani su za nadziranje sistema za e-učenje, kao i njihovih korisnika [233]. Uspešno mogu da identifikuju oblasti u kojima učenici/studenti pokazuju solidno znanje, ali i one u kojima nailaze na poteškoće. Agenti imaju sposobnost da inteligentno sumiraju ove podatke, kako bi učenicima/studentima davali pravovremene povratne informacije, generisali adekvatne preporuke, pomagali im u donošenju odluka i slično [234].

Postoje dve vrste intelligentnih agenata:

- Autonomni intelligentni agenti (eng. *Autonomous intelligent agents*) - obuhvataju agente koji samostalno funkcionišu u sistemu i preduzimaju akcije neophodne za postizanje ciljeva.
- Multi agenti (eng. *Multi-agent*) - predstavljaju kombinaciju više autonomnih intelligentnih agenata koji zajedno deluju u okruženju. Združenim radom rešavaju razne probleme koje je teško prevazići samo uz pomoć pojedinačnih intelligentnih agenata [231].

U Tabeli 9 prikazani su sistemi za e-učenje koji implementiraju autonomne intelligentne agente i multi agent sisteme.

*Tabela 9. Sistemi za e-učenje sa intelligentnim agentima*

Vrsta intelligentnih agenata	Sistemi za e-učenje (sa publikacijom)
Autonomni intelligentni agenti	<i>eTeacher</i> [235]; <i>Mod-Knowledge</i> [236];
Multi agent sistemi	<i>MAS-PLANG</i> [237]; <i>EMASPEL</i> [238]; <i>ALLEGRO</i> [239]; <i>F-SMILE</i> [240]; <i>ISABEL</i> [241]; <i>IAELS</i> [242]; <i>MIPITS</i> [243]; <i>ADOPT</i> [244]; <i>PowerChalk</i> [245]; <i>MetaTutor</i> [246];

Prema stanovištu koje izlažu Kuk i sar. [247], personalizovani pristupi koji se zasnivaju na primeni intelligentnih agenata podrazumevaju da svaki učenik/student u sistemu za e-učenje treba da ima sopstvenog agenta, koji će predstavljati njegovog tutora za vreme celog trajanja kursa kako bi svako od učenika/studenata imao nekoga da ga vodi kroz proces učenja. Ovi agenti predstavljaju vrstu intelligentnih agenata u vidu virtualne osobe ili jednostavnog četa, koji upotrebom veštačke

inteligencije imaju mogućnost da prate učenika/studenta tokom kursa, reaguju u situacijama kada mu je potrebna pomoć i pružaju mu podršku tokom celog procesa učenja [60].

Postoje dve vrste ovakvih agenata:

- Pedagoški agenti (eng. *Pedagogical agents*) - predstavljaju posebnu vrstu agenata, obično manifestovanih u obliku virtuelnog nastavnika, čija je svrha vođenje učenika/studenata kroz kurs i davanje saveta u procesu učenja. Oni pomažu učenicima/studentima kroz ceo kurs pružajući im korisne sugestije na svakom koraku. Kada primete da se učenik/student susreće sa poteškoćama i da nije u stanju da reši određeni zadatak tada ga navode na rešenje ili prikazuju celo rešenje problema.
- Konverzacijski agenti (eng. *Conversational agents*) - jesu tip agenata koji, kao i pedagoški agenti, predstavljaju neku vrstu virtuelnog nastavnika učeniku/studentu, ali za razliku od njih mogu da se upuste u dijalog sa učenikom/studentom, bilo putem dopisivanja u četu ili vođenja pravog glasovnog razgovora. Konverzacijski agenti postižu to koristeći obradu prirodnog jezika, koja im omogućava sposobnost komunikacije sa učenikom/studentom [248].

U Tabeli 10 prikazani su sistemi za e-učenje koji implementiraju pedagoške agente i konverzacijiske agente.

*Tabela 10. Sistemi za e-učenje sa pedagoškim i konverzacijskim agentima*

Sistem za e-učenje	Naziv agenta/agenata	Publikacija
<b>Pedagoški agenti</b>		
ISLA	Jessi	[249]
ATS	Jean	[250]
CALL system	Patti	[251]
APLUS	SimStuden i Mr. Williams	[252]
EC Lab	Professor T. i Lisa	[253]
<b>Konverzacijski agenti</b>		
Geranium	Gera	[254]
Curiosity Notebook	Bez imena	[255]

Inteligentni agenti u sistemima za e-učenje donose potrebnu dinamičnost i podižu proces učenja na viši nivo. Implementacija ovih agenata obezbediće sistemima za e-učenje funkcionalnost sakupljanja neophodnih informacija o učenicima/studentima i njihovim aktivnostima, kako bi te informacije sistemi iskoristili za ispunjenje svojih ciljeva [256]. Unapređenje komunikacije u e-učenju ogleda se i u segmentu postojanja pedagoškog i konverzacijskog agenta, čija bi uloga bila veoma bitna u oblasti predikcije uspeha učenika/studenta u sistemima za e-učenje. Pomenuti agenti imaju isti cilj, a to je da motivišu učenike/studente, povećaju njihovo angažovanje na kursu i omoguće efikasnije učenje, a sve to jednostavnim postavljanjem pitanja, pravilnim navođenjem i predlaganjem rešenja u pravim trenucima [257]. Uvođenje osobe koja bi bila poput mentora tokom trajanja kursa i na raspolaganju svakom učeniku/studentu kako za pitanja tako i da na osnovu rezultata predviđanja blagovremeno reaguje i uputi konstruktivne savete doprinelo bi i boljem ostvarenom uspehu učenika/studenta na kraju kursa.

#### **2.2.8. Ostale inteligentne tehnike u e-učenju**

U prethodnim poglavljima dat je pregled različitih procesa e-učenja i naveden je i opisan veliki broj intelligentnih tehnika koje se koriste za njihovo funkcionisanje. U ovoj sekciji sledi pregled najpoznatijih intelligentnih tehnika koje nude podršku za više različitih uloga, za razliku od prethodnih koje su imale jednu namenu.

Među ovim tehnikama izdvajaju se:

- ANN,
- Bajesova mreža,
- fazi logika,
- stablo odlučivanja,
- skriveni Markovljev model.

ANN predstavljaju tehniku veštačke inteligencije koja funkcioniše po principu ljudskog mozga i koriste se za identifikaciju skrivenih odnosa i pronalaženje raznih obrazaca kako bi se rešili kompleksni problemi [258]. Neke od primena ANN-a u sistemima za e-učenje odnose se na predviđanje uspeha učenika/studenta [259], analiziranje ponašanja učenika/studenta u sistemima za e-učenje [260], prepoznavanje kognitivnog stanja učenika/studenta [261], otkrivanje ljudskog

izražavanja pomoću psiholoških signala [262], predviđanje poteškoća sa kojima učenik/student može da se susretne na kursu [263] itd.

Bajesova mreža (eng. *Bayesian network*) predstavlja grafičku strukturu koja na osnovu izračunate verovatnoće može da reši određene probleme, kao i da pomogne u donošenju odluka [264]. U sistemima za e-učenje primenu nalazi u različitim procesima među kojima su otkrivanje navika učenja učenika/studenta [265], upravljanje modelima učenika/studenata [266], procena učinka nastavnika u nastavi preko sistema za e-učenje [267], podržavanje učenika/studenta procesom personalizacije u sistemu za e-učenje [268], pomaganje učeniku/studentu u sticanju veština koje su potrebne za rešavanja različitih problema [129] itd.

Fazi logika (eng. *Fuzzy logic*) jeste tehnika koja za razliku od tradicionalne Bulove logike u kojoj vrednosti mogu biti samo 0 (netačno) ili 1 (tačno), nudi mogućnost i delimično tačnih vrednosti koje mogu biti predstavljene bilo kojim realnim brojem između 0 i 1 [269]. Fazi logika upotrebljava se u sistemima za e-učenje za evaluaciju i procenu zadataka učenika/studenta [270], proveru kvaliteta i tačnosti predloženih rešenja od strane učenika/studenta [271], praćenje promene znanja učenika/studenta kako bi mu se na osnovu toga prilagodio nastavni plan i program [272], detekciju učenikovih/studentovih taktika na osnovu njegovih karakteristika [273], otkrivanje nesigurnosti u ponašanju učenika/studenta [274] itd.

Stablo odlučivanja (eng. *Decision tree*) predstavlja tehniku koja je zasnovana na hijerarhijskoj strukturi stabla, gde čvorovi grane predstavljaju izbor između jedne ili više opcija koji mogu dovesti do novih čvorova grane ili čvorova listova koji predstavljaju krajnje rezultate odluke [275]. U sistemima za e-učenje koristi se za analizu podataka i dobijanje rezultata [276], izgradnju modela učenika/studenta za potrebe predviđanja njegovog krajnjeg nivoa znanja [181], generisanje personalizovanih putanja učenja [277], izvlačenje podataka o učenicima/studentima i izdvajanje onih najvažnijih [278], klasifikaciju grešaka koje učenik/student pravi u svom procesu učenja [279] itd.

Skriveni Markovljev model (eng. *Hidden Markov model*) jeste tehnika zasnovana na statističkom modelu koji na osnovu distribucije verovatnoće opisuje vezu između niza posmatranih i niza skrivenih varijabli [280]. Primena ove tehnike u sistemima za e-učenje odnosi se na prilagođavanje sadržaja kursa na osnovu učinka koje učenik/student ostvaruje [281], predviđanje akcija koje će učenik/student izvršiti prilikom navigacije u sistemu [282], merenje motivacije i prethodnog znanja učenika/studenta [283], poboljšanje navigacionih sposobnosti osoba sa

oštećenim vidom kako bi lakše pretraživali potrebne materijale [284], automatsku detekciju aktivnosti učenika/studenta na osnovu pokreta miša [285] itd.

U Tabeli 11 prikazani su sistemi za e-učenje koji implementiraju neku od ovih pomenutih tehnika.

*Tabela 11. Sistemi za e-učenje sa ostalim inteligentnim tehnikama*

<b>Tehnika</b>	<b>Sistemi za e-učenje (sa publikacijom)</b>
ANN	<i>ILIAS</i> [259]; <i>Research Quest</i> [260]; <i>CBeL</i> [261]; <i>ReAct!</i> [262]; <i>DEEDS</i> [263];
Bajesova mreža	<i>SAVER</i> [265]; <i>CAMLES</i> [266]; <i>MILE</i> [267]; <i>FB-ITS</i> [268]; <i>SITS</i> [129];
Fazi logika	<i>COALA</i> [270]; <i>DomoSim-TPC</i> [271]; <i>FuzKSD</i> [272]; <i>IT2FLS</i> [273]; <i>Sherlock II</i> [274];
Stablo odlučivanja	<i>MLTutor</i> [276]; <i>SamurAI</i> [181]; <i>PCLS</i> [277]; <i>UoK platform</i> [278]; <i>edb</i> [279];
Skriveni Markovljev model	<i>OPAESFH</i> [281]; <i>AIWBES</i> [282]; <i>Proteus</i> [283]; <i>iVeES</i> [284]; <i>Equation Grapher</i> [285];

Veštačka inteligencija, kao i mnoge druge moderne tehnologije u razvoju, menjaju standardno e-učenje, unapređuju ga i usavršavaju. Veštačka inteligencija donela je mnogo toga korisnog e-učenju i bez nje mnogi procesi ne bi bili mogući. Pomaže u prikupljanju podataka o učenicima/studentima, analizi tih podataka kako bi se korisne informacije iskoristile za poboljšanje iskustva učenja, asistira u pravljenju i generisanju prilagođenih putanja učenja, omogućava personalizovanje celog procesa učenja, pomaže u automatizaciji samog učenja, ali i ocenjivanju, kao i u mnogim drugim procesima. Zasigurno se može reći da veštačka inteligencija u svom punom kapacitetu ima neograničen potencijal u e-učenju i može se iskoristiti za transformaciju celog procesa učenja na bolje. Naglasak ove disertacije je upravo na istraživanju primene veštačke inteligencije u oblasti e-učenja, s posebnim fokusom na upotrebu tehnika za predikciju uspeha učenika/studenata u sistemima za e-učenje.

## 2.2.9. Uloge intelligentnih tehnika u e-učenju

Intelligentne tehnike koriste se za četiri glavne uloge u e-učenju [12]:

- 1) modelovanje učenika/studenta,
- 2) analitiku učenja,
- 3) adaptivnu procenu znanja,
- 4) personalizovano učenje.



Slika 2. Intelligentne tehnike u e-učenju, prilagođeno prema [12]

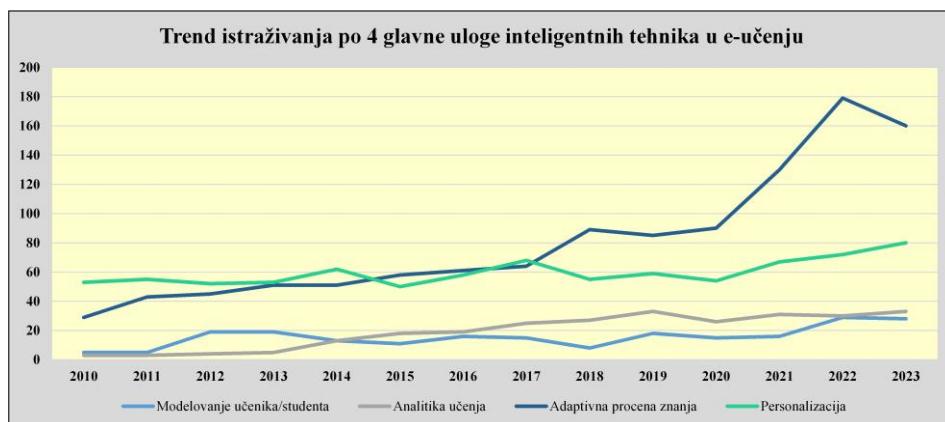
Slika 2 prikazuje veliki broj intelligentnih tehnika koje se koriste u sistemima za e-učenje, kao i osnovne uloge tih tehnika u e-učenju [12]. Kao što se može videti na Slici 2, prva uloga intelligentnih tehnika jeste modelovanje učenika/studenta, koja koristi OLM (za pružanje mogućnosti učenicima/studentima za pregled, proveru i analizu svog modela), obrazovno rudarenje podataka (za sakupljanje podataka učenika/studenata, kao i njihovu analizu) i praćenje znanja (za izvršenje procesa modelovanja, ali i uspešno sprovođenje predviđanja znanja učenika/studenata). Druga uloga intelligentnih tehnika tj. analitika učenja koristi se nakon

kreiranog modela učenika/studenta, za potrebe merenja i prikupljanja podataka o interakciji učenika/studenata sa sistemom, analize tih podataka, kao i generisanje izveštaja o učenicima/studentima na osnovu rezultata analize. Rezultati dobijeni nakon primene analitike učenja potom se koriste kao ulazni parametri koji će pomoći u pripremi i realizaciji adaptivne procene znanja, kao treće uloge inteligenčnih tehnika. Ovim putem omogućava se testiranje koje je prilagođeno svakom učeniku/studentu, obezbeđujući tako tačnije i pouzdano određivanje njegovog znanja. Procena znanja učenika/studenta neophodna je kako bi se pristupilo personalizaciji učenja, kao četvrtoj ulozi inteligenčnih tehnika. Na osnovu procene znanja učenika/studenata, ali i drugih informacija pribavljenih tokom ostalih pomenutih procesa, učenje se prilagođava učenicima/studentima, odnosno njihovom znanju, sposobnostima, interesovanjima i slično. Na taj način učenicima/studentima pruža se potpuno personalizovano iskustvo učenja koje zadovoljava sve njihove potrebe.

#### **2.2.10. Trendovi inteligenčnih tehnika**

U ovom delu prikazani su trendovi inteligenčnih tehnika dobijeni na osnovu broja publikacija po godinama. Podaci su izvučeni uz pomoć alata *Harzing's Publish or Perish tool*. Sve publikacije pomoću ovog alata preuzete su iz baze Gugl akademika (eng. *Google scholar*) na osnovu naslova i obuhvataju period od 2010. do 2023. godine.

Na Grafikonu 1 prikazan je trend istraživanja po četiri glavne uloge inteligenčnih tehnika u e-učenju. Kao što se može primetiti, sve uloge imaju stabilan i stalan tok godišnjih publikacija. Od 2018. pa do 2023. godine adaptivna procena znanja ima najveći broj publikacija.



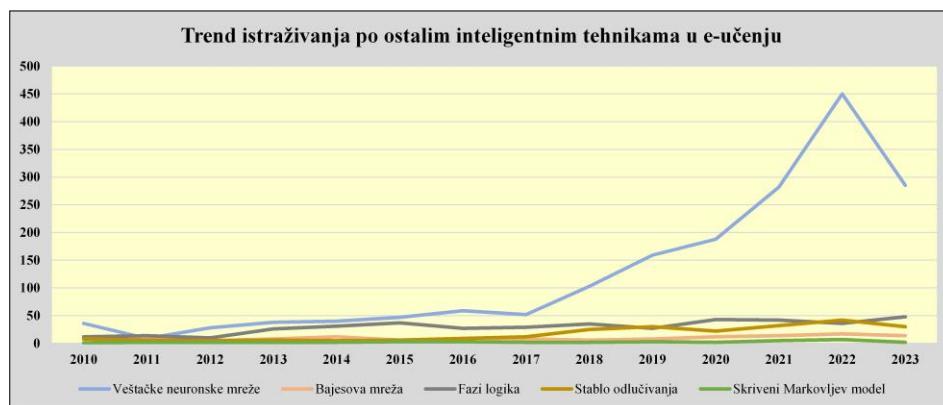
*Grafikon 1. Trend istraživanja 1*

Na Grafikonu 2 prikazan je trend istraživanja po vrstama inteligentnih agenata u e-učenju. Takođe se, kao i na prošlom Grafikonu, može primetiti da svi koncepti imaju stabilan i stalan tok godišnjih publikacija. Uočljivo je da najveći broj publikacija od 2010. pa sve do 2023. godine imaju multi agent sistemi. Važno je napomenuti i da se na Grafikonu može videti stalan porast publikacija konverzacijskih agenata od 2017. godine, pa se tako 2023. godine izjednačavaju sa intelligentnim agentima.



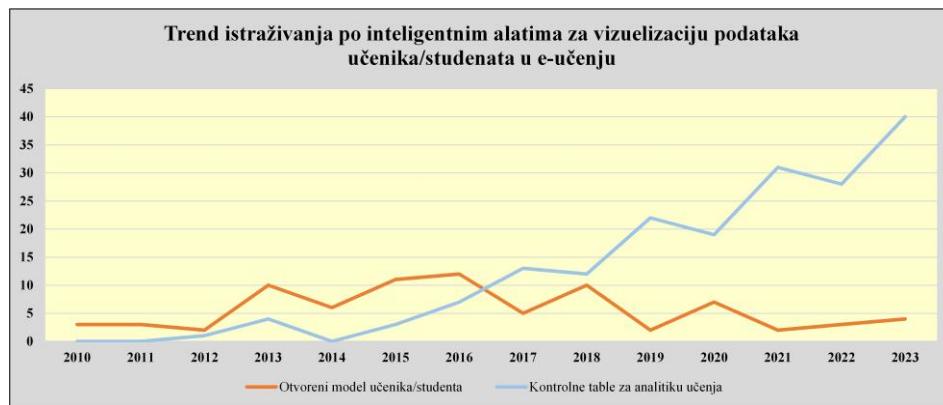
Grafikon 2. Trend istraživanja 2

Na Grafikonu 3 prikazan je trend istraživanja po intelligentnim tehnikama koje se koriste u e-učenju aktuelizovanim u sekciji Ostale intelligentne tehnike. Tu spadaju ANN, Bajesova mreža, fazi logika, stablo odlučivanja i skriveni Markovljev model. Grafikon pokazuje da broj ANN publikacija imaju veliki porast od 2017. godine pa sve do 2022. godine, dok je 2023. primećen veliki pad u odnosu na 2022. godinu, ali i dalje imaju daleko veći broj publikacija od ostalih tehniki.



Grafikon 3. Trend istraživanja 3

Grafikon 4 bavi se trendom istraživanja po inteligentnim alatima za vizuelizaciju podataka učenika/studenata u e-učenju. Na njemu su prikazani trendovi OLM-a i kontrolne table za analitiku učenja. U periodu od 2010. do 2016. godine OLM imao je nešto veći broj publikacija, kada ga 2017. kontrolne table za analitiku učenja prestižu i od tog trenutka preuzimaju primat u broju publikacija.



Grafikon 4. Trend istraživanja 4

### 2.2.11. Sistemi za e-učenje - kategorije, strategije i uloge intelligentnih tehnika

U prethodnim delovima potpoglavlja Inteligentne tehnike u e-učenju problematizovane su inteligentne tehnike koje su zastupljene u e-učenju i razni sistemi za e-učenje u kojima su implementirane. U nastavku u Tabeli 12 sistematizovano su prikazani sistemi za e-učenje prema kategorizaciji intelligentnih tehnika, korišćenih strategija i njihovih osnovnih uloga u okruženjima za e-učenje.

Tabela 12. Sistemi za e-učenje [12]

Strategije	Tehnike	Sistemi za e-učenje (sa publikacijom)
<b>Modelovanje učenika/studenta</b>		
Obrazovno rudarenje podataka	Predviđanje	<i>AL-TESL-e-learning system</i> [111]; <i>Junyi Academy</i> [112];
	Grupisanje	<i>dotLRN</i> [113]; <i>ESURBCA</i> [114];
	Relacijsko rudarenje	<i>eDisiplin</i> [115]; <i>ESOG</i> [116]; <i>Blockly programming App</i> [117];

	Destilacija za ljudsku procenu	<i>Canvas</i> [118];
	Otkrivanje pomoću modela	<i>Cisco Networking Academy</i> [119]
	Autonomni inteligentni agenti	<i>eTeacher</i> [235];
	Multi agenti	<i>ALLEGRO</i> [239]; <i>ISABEL</i> [241]; <i>IAELS</i> [242]; <i>PowerChalk</i> [245];
Praćenje znanja	Bajesovo praćenje znanja	<i>CRYSTAL ISLAND</i> [124]; <i>ASSISTment</i> [125]; <i>edX</i> [126]; <i>Coursera</i> [127]; <i>Robot language tutor</i> [128]; <i>SITS</i> [129];
	Duboko praćenje znanja	<i>Khan academy</i> [121]; <i>Udacity</i> [130];
	Autonomni inteligentni agenti	<i>Mod-Knowledge</i> [236];
	Fazi logika	<i>IT2FLS</i> [273];
Vizuelizacija podataka učenika/studenta	OLM	<i>INSPIREus</i> [78]; <i>Flexi-OLM</i> [69]; <i>AMAS OLE</i> [79]; <i>UM toolkit</i> [80]; <i>Lea's Box</i> [81]; <i>ELM-ART</i> [82]; <i>EI-OSM</i> [83]; <i>Mr. Collins</i> [84]; <i>Next-TELL</i> [85]; <i>Style-OLM</i> [86]; <i>EER-Tutor</i> [87]; <i>MasteryGrids</i> [88]; <i>edCrumble</i> [68]; <i>SQL-Tutor</i> [89]; <i>VisMod</i> [90]; <i>VCM</i> [91]; <i>INGRID</i> [70]; <i>QuizMap</i> [92]; <i>GVIS</i> [93]; <i>NavEx</i> [94]; <i>Progessor</i> [95]; <i>E-KERMIT</i> [96]; <i>Subtraction Master</i> [97]; <i>Fraction Helper</i> [98]; <i>QuizPACK</i> [99]; <i>Doubtfire++</i> [100]; <i>TITUS</i> [101]; <i>CALMsystem</i> [102]; <i>PAL3</i> [103]; <i>NDLtutor</i> [75]; <i>Topolor 2</i> [104];

<b><i>Analitika učenja</i></b>		
Prikupljanje podataka	Tehnike obrazovnog rudarenja	<i>Desire2Learn</i> [154]; <i>Blackboard Vista</i> [118];
Analiza podataka	Analiza društvenih mreža	<i>OSBLE+</i> [155];
	Statistička analiza	<i>OU Analyse</i> [156];
	Stablo odlučivanja	<i>MLTutor</i> [276];
Predviđanje i analiza ponašanja učenika/studenta	ANN	<i>ILIAS</i> [259]; <i>Research Quest</i> [260]; <i>CBeL</i> [261]; <i>ReAct!</i> [262]; <i>DEEDS</i> [263];
	Bajesova mreža	<i>SAVER</i> [265]; <i>CAMLES</i> [266];
	Fazi logika	<i>Sherlock II</i> [274];
	Stablo odlučivanja	<i>SamurAI</i> [181]; <i>UoK platform</i> [278]; <i>edb</i> [279];
	Skriveni Markovljev model	<i>AIWBES</i> [282]; <i>Proteus</i> [283]; <i>iVeES</i> [284];
Vizuelizacija podataka učenika/studenta	Kontrolne table za analitiku učenja	<i>MathSpring</i> [157]; <i>SCELE</i> [158]; <i>Cyber Campus</i> [152]; <i>OUJ system</i> [159]; <i>iTutor</i> [160]; <i>SoftLearn</i> [161];
<b><i>Adaptivna procena znanja</i></b>		
Rangiranje, vrednovanje i ocenjivanje učenika/studenta	Probabilitička teorija testiranja	<i>UZWEBMAT</i> [175]; <i>MISTRAL</i> [176]; <i>Amrita Learning</i> [177]; <i>SIETTE</i> [178]; <i>UTS</i> [179]; <i>English vocabulary learning system</i> [180]; <i>SamurAI</i> [181]; <i>PEL-IRT</i> [182]; <i>Lexue 100</i> [183];
	Elo algoritam za ocenjivanje	<i>ProTuS</i> [184]; <i>Math Garden</i> [185]; <i>Matistikk</i> [186]; <i>ACT Academy</i> [187];
	<i>TrueSkill</i>	<i>APACTS</i> [188];
	Bajesova mreža	<i>MILE</i> [267];
	Fazi logika	<i>COALA</i> [270]; <i>DomoSim-TPC</i> [271]; <i>FuzKSD</i> [272];

<b>Personalizovano učenje</b>		
Preporuka sadržaja	Filtriranje zasnovano na sadržaju	<i>Quickstep</i> [195]; <i>CBNR</i> [196];
	Filtriranje zasnovano na znanju	<i>MDB</i> [197]; <i>ADO-Tutor</i> [198]; <i>CSS-Tutor</i> [199]; <i>ScholarLite</i> [200];
	Kolaborativno filtriranje	<i>PeerGrade</i> [201]; <i>LAMS</i> [202]; <i>LogCF</i> [203];
	Hibridne tehnike	<i>CodERS</i> [204]; <i>RSPP</i> [205]; <i>MoodleRec</i> [206];
	Multi agenti	<i>MIPITS</i> [243]; <i>ADOPT</i> [244]; <i>MetaTutor</i> [246];
Sekvenciranje resursa	Genetski algoritam	<i>LPRS_EL</i> [216];
	Memetički algoritam	<i>TPG</i> [217];
	Mravlji algoritam	<i>ACSEL</i> [218]; <i>LPR</i> [219];
	Optimizacija rojem čestica	<i>IDRCCS</i> [220];
	Algoritam kolonije pčela	<i>PBREL</i> [221];
	Multi agenti	<i>MAS-PLANG</i> [193];
	Stablo odlučivanja	<i>PCLS</i> [277];
	Skriveni Markovljev model	<i>OPAESFH</i> [281]; <i>Equation Grapher</i> [285];
Pružanje povratnih informacija	Generisanje tekstualnih povratnih informacija	<i>SQL Quizbot</i> [226]; <i>Pgtracer</i> [227]; <i>UCOM</i> [228];
	Generisanje povratnih informacija u formi videa	<i>ASSET</i> [229];
Vođenje učenika/studenta kroz kurs	Pedagoški agenti	<i>ISLA</i> [249]; <i>ATS</i> [250]; <i>CALL system</i> [251]; <i>APLUS</i> [252]; <i>EC Lab</i> [253];
	Konverzacijski agenti	<i>Geranium</i> [254]; <i>Curiosity Notebook</i> [255];
	Multi agenti	<i>EMASPEL</i> [238]; <i>F-SMILE</i> [240];
	Bajesova mreža	<i>FB-ITS</i> [268];

## **2.2.12. Uticaj inteligentnih tehnika na stavove, motivaciju i uspeh učenika/studenata**

U mnogim studijama dokazan je pozitivan uticaj intelligentnih tehnika na stavove, motivaciju i ukupan uspeh učenika/studenta u okruženjima za e-učenje, tako da OLM, adaptivna procena znanja, praćenje znanja, analitika učenja, obrazovno rudarenje podataka, sekvenciranje resursa, pedagoški agenti i konverzacijski agenti igraju važne uloge po ovom pitanju [12]. Ipak, svi nabrojani koncepti i njima pripadajuće tehnike ne bi mogli da imaju neki značajan efekat bez procesa modelovanja učenika/studenta pomoću koga se otkrivaju bitne informacije o učenicima/studentima koje će ti koncepti koristiti [12].

Mnogi učenici/studenti nemaju motivaciju za učenje tokom pohađanja kursa e-učenja i kako bi zadržali pozitivan stav i dobili motivaciju potrebno im je stalno ohrabrenje. S druge strane, postoji veliki broj njih koji nemaju takvih problema, već su samomotivisani i proces učenja i trud koji ulažu na kursu ne zavise od akademskog okruženja [286]. Modelovanje učenika/studenta predstavlja proces koji detektuje i prepoznaje odlike i svojstva učenika/studента na osnovu kojih mu se prilagođavaju nastavni sadržaji i aktivnosti, i kao takav direktno je povezan sa motivacijom i samoopredeljenjem učenika/studenta. Takođe, otvaranje modela učenicima/studentima može koristiti za povećanje motivacije i poboljšanje uspeha.

Veštačka inteligencija ima veliki uticaj na e-učenje i kao takva pozitivno deluje na povećanje motivacije kod učenika/studenata, jer ih navodi da preduzmu akcije kako bi ostvarili napredak ka svojim ciljevima. Mnoga istraživanja impliciraju kako adaptivna procena znanja, kao i ulaganje više truda u sam proces ocenjivanja, mogu igrati veliku ulogu u povećanju motivacije i angažovanja učenika/studena [287]. Jasno je da učenici/studenti mogu biti više motivisani kada su pitanja prilagođena njihovim sposobnostima, što adaptivna procena znanja obezbeđuje [288]. Adaptivnom procenom znanja izbegava se razočaranje učenika/studena, kao i njihova frustracija tokom odgovaranja na pitanja. Vidljive prednosti koje se postižu ovim načinom procene znanja su poboljšanje uspeha, ali i celokupnog obrazovnog iskustva. Mane su preveliči konformizam u kome učenici/studenti obitavaju i zanemarivanje iskazivanja znanja uz distrakcije i osećaj konkurentskog okruženja, a što ih nesumnjivo očekuje na tržištu rada i u ličnoj karijeri.

Praćenje znanja takođe može imati dobar uticaj na motivaciju učenika/studenata. Mogućnost automatskog otkrivanja problema i poteškoća sa kojima se učenici/studenti suočavaju

u učenju čini jednu od prednosti, pa tako mogu alarmirati i pokrenuti učenika/studenta u rešavanju tih problema, dovodeći tako do povećanja njihove motivacije [289].

Radi povećanja motivacije učenika/studenta, bitno je da sistem za e-učenje ima mogućnost generisanja personalizovane putanje učenja. Prilagođen nastavni sadržaj, ali i podrška za navigaciju na kursu, pozitivno utiču na motivaciju, interesovanje i uspeh učenika/studenta [222].

Analitika učenja i obrazovno rudarenje podataka uz pomoć veštačke inteligencije imaju mogućnost da na osnovu analize učenikovog/studentovog ponašanja u sistemu za e-učenje pomognu nastavnicima u proceni njihovog znanja koje poseduju, napretka koji ostvaruju i uspeha koji postižu [290]. Uspešna predikcija akademskog uspeha učenika/studenta, koja se može izvršiti korišćenjem tehnika analitike učenja i obrazovnog rudarenja podataka, mogu da utiču na dizajn učenja i na taj način unaprede obrazovne servise i usluge [291]. Sve ovo može imati veliki uticaj na povećanje motivacije i poboljšanje uspeha učenika/studenta.

Pedagoški agenti i konverzacijски agenti - kao virtualni tutori učenika/studenta u sistemu za e-učenje - imaju ogroman uticaj na motivaciju učenika/studenta, ali takođe i na poboljšanje njihovog progrusa tokom vremena. Poput svojevrsnih mentora koji ih vode kroz proces učenja, programirani su da prepoznaju kada je učenik/student u problemu i da davanjem pravovremenih saveta podstaknu učenika/studenta da razmišlja kako bi došao do rešenja zadatka. U slučaju konverzacijskih agenata sve navedeno radi se još i na naprednjem nivou, pošto oni imaju mogućnost da započnu diskusiju sa učenikom/studentom i tako dublje zađu u problematiku.

Sprovedena su razna istraživanja o uticaju intelligentnih tehnika na proces učenja i veliki broj studija pokazuje kako imaju povoljan i snažan efekat na motivaciju učenika/studenata [292], kao i na njihovu unutrašnju motivaciju [293], zatim poboljšanje uspeha [294] i uticaj na njihov stav [287], [295]. Među tehnikama koje su pokazale najveći uticaj na učenike/studente izdvajaju se: adaptivna procena znanja koja pokazuje najbolje rezultate za poboljšanje uspeha učenika/studenata [90], [99], [288], zatim pedagoški i konverzacijski agenti koji najveću ulogu imaju u povećanju motivacije učenika/studenata [296], dok analitika učenja povećava angažovanje na kursu i svest učenika/studenata o tome koliko je e-učenje efikasno [152], [153], [297]. Koliko god bile učinkovite intelligentne tehnike, dizajn učenja nije u mogućnosti da prevaziđe pojedine specifične probleme kao što su samomotivacija učenika/studenata i njihovo upravljanje vremenom na kursu, ali se učenicima/studentima može pružiti pomoć u vidu davanja jasnih uputstava, koncepcije i plana kako da ceo obim posla deluje podesan i realan da se završi [287]. U prilog

tome govore i studije koje navode da sve ono što ima veze sa kompetencijama učenika/studenata (stavovi, znanje, razumevanje, sposobnost itd.) jeste usko povezano sa stepenom individualizovanog učenja koje učenik/student praktikuje u sistemima za e-učenje [298], [299].

### **2.2.13. Izazovi i nedostignut potencijal primene inteligentnih tehnika**

Glavni izazovi primene inteligentnih tehnika u sistemima za e-učenje predstavljaju kvalitet dostupnih podataka, ograničen broj informacija (znanja) u javnom domenu i nedovoljno sprovedenih studija o stavovima učenika/studenata i nastavnika prema sistemima za e-učenje koji implementiraju veštačku inteligenciju u nekom obliku [12]. Nedostignut potencijal primene inteligentnih tehnika u sistemima za e-učenje najviše se odnosi na upotrebu ovih tehnika za razumevanje odnosa između dizajna učenja i optimizacije procesa učenja [12].

Najveći broj studija predstavlja kvalitet podataka kao jedan od glavnih izazova, gde se, pre svega, misli na pravilnu i relevantnu upotrebu informacija koje se dobijaju od različitih tehnologija [120], [300], [301]. Problemi se odnose i na to da nije uvek moguće da se obuhvati ceo proces učenja ili da se on predstavi kako bi trebalo na osnovu samo dostupnih podataka [302]. Istovremeno, izazov je i pribavljanje podataka iz različitih izvora i njihovo objedinjavanje u jedinstvenu bazu podataka [303]. Nastavnici bi trebalo da kontrolišu prisustvo učenika/studenata u sistemima za e-učenje, da ih nadziru kada su aktivni, i redovno prate njihov napredak, a sve na osnovu strategija evaluacije, kao i sistematskog i kontinuiranog prikupljanja podataka. U cilju obezbeđivanja efikasnog procesa učenja neophodno je opremiti sisteme za e-učenje sa personalizovanim putevima učenja, sprovoditi redovnu analizu podataka i uspeha učenika/studenata radi dobijanja pravovremenih informacija, kao i kreirati određene zadatke i aktivnosti koji će biti prilagođeni svakom učeniku/studentu, odnosno njegovim sposobnostima.

Pronalaženje i usmeravanje učenika/studenta na potrebne informacije i obezbeđivanje adekvatnog sadržaja za njih trebalo bi da budu primarna funkcija veštačke inteligencije u e-učenju. Pored toga, još jedna važna uloga veštačke inteligencije treba da bude analiza velikih količina podataka kako bi se otkrili određeni obrasci na osnovu kojih se može poboljšati i optimizovati proces učenja. Najveći broj studija bavi se time da se omogući nastavnicima dobijanje informacija koje će dati sliku svakog pojedinačnog učenika/studenta, odnosno njegovog znanja, učinka, slabosti i poteškoća, koje će u vidu različitih trendova biti ilustrovani dizajnerima učenja.

Iskazanim pristupom mogu se pravovremeno preduzeti neophodne intervencije u procesu učenja. Međutim, problem leži u dostupnosti podataka, pošto su baze podataka u kojima se oni skladiše i kojima pretraživači veštačke inteligencije pristupaju uglavnom ograničene na informacije (znanje) iz javnog domena [304], [305]. Problem dostupnosti podataka leži u tome da univerziteti, i pored toga što često sakupljaju podatke sa onlajn kurseva, nemaju sredstva za njihovo skladištenje [306]. Upravo iz svih navedenih razloga može se reći da dostupnost podataka predstavlja slabu tačku veštačke inteligencije jer su informacije koje su dostupne često generičke i nepotpune, pa nije lako dobiti odgovore i rešenja za specifične upite.

Postoji veliki broj studija koje se bave prezentovanjem i procenom upotrebe različitih intelligentnih tehnika. Međutim, nema mnogo onih koje se bave stavovima učenika/studenata i nastavnika prema sistemima za e-učenje koji implementiraju veštačku inteligenciju [290], [291], [307]. Učenici/studenti imaju velika očekivanja od ovakvih sistema i smatraju da će oni doprineti poboljšanju komunikacije sa nastavnicima, ali isto tako misle i da mogu dobiti nepouzdane odgovore od sistema, što se može negativno odraziti na njihov učinak i krajnje ocene [290]. Još jedna stvar koja brine učenike/studente jeste njihova privatnost povezana sa podacima koji će se beležiti na osnovu njihovih akcija u okviru sistema za e-učenje [291].

Pored malog broja studija povodom ovog pitanja, još jedan problem ogleda se u tome što su u postojećim istraživanjima pretežno učenici/studenti bili uključeni kao ispitanici, tako da su nastavnici i njihovi stavovi o tome poprilično zapostavljeni [308]. Mišljenja nastavnika o veštačkoj inteligenciji i šta ona može da donese e-učenju podjednako su važna kao i mišljenja učenika/studenata, pa se iz tog razloga ne smeju zanemariti. Njihovi stavovi mogu imati bitan uticaj na način upotrebe intelligentnih tehnika u sistemima za e-učenje, kako bi se one iskoristile na najbolji način i dovele do razvoja određenih veština i sposobnosti kod učenika/studenata. Nezadovoljavajući razvoj učenika/studenata, usled neadekvatnog korišćenja veštačke inteligencije, može da stvori otpor i odbojnost učenika/studenata ka učenju u sistemima za e-učenje koji su zasnovani na veštačkoj inteligenciji. Istraživanje sprovedeno u [290] upotpunjuje prethodnu tvrdnju time što otkriva da su nastavnici izrazili zabrinutost da bi učenici/studenti mogli da izgube volju za samostalnim istraživanjem, ukoliko bi se sistemi u prevelikoj meri oslanjali na veštačku inteligenciju i time automatizovali većinu procesa.

Implementacija personalizacije u sisteme za e-učenje, pored svojih brojnih prednosti, može dovesti do prekomerne standardizacije procesa učenja, što može negativno da utiče na

učenike/studente zato što propisuje kako bi oni trebalo da se ponašaju [290]. Tako inteligentne tehnike, iako vrlo bitne i korisne, mogu da ograniče učenike/studente u njihovom eksperimentisanju i istraživanju, što dovodi do sputavanja razvoja novih veština i nemogućnosti učenja iz svojih grešaka. Upravo iz navedenih razloga, važno je da nastavnici i dalje budu uključeni u dizajn nastave zbog određene fleksibilnosti i nadasve nezamenjivog ljudskog faktora. Inteligentne tehnike veoma su korisne za obradu velikih količina podataka, ali mogu naići na probleme kod kompleksnijih zahteva, pa je zato neophodno imati osobu koja će sve to kontrolisati i voditi u pravom smeru.

Utvrđivanje standarda koji se moraju ispuniti predstavljaju prvi korak u uspešnoj integraciji veštačke inteligencije u e-učenje. Osnovna ideja i koncept ovog procesa jeste da se ponude nepristrasne intervencije koje se ne mogu dobiti od nastavnika koji određene pojave mogu posmatrati subjektivno. Primenom ovih rešenja, nastava podržana veštačkom inteligencijom postala bi efikasnija, pravednija za učenike/studente i bila bi zasnovana na obrazovnim modelima utemeljenim na karakteristikama, razumevanju i kapacitetu učenika/studenta.

Primetno je da u mnogim istraživanjima nedostaje razvijanje pedagoških, psiholoških i metodičkih teorija učenja prožetim aspektima tehnologija koje su vođene veštačkom inteligencijom. Usled odsustva navedenog, trebalo bi da se poveća broj istraživanja koja će konkretno raditi na razvoju okvira zaduženih za prikupljanje i sistematizaciju podataka o dizajnu učenja, a koji će biti zasnovani na analitici učenja i teoriji učenja, ali jednako brinuti o tome da se obezbedi dokumentacija celog tog procesa, kako bi kasnije moglo da se utvrdi kako se izbor dizajna učenja za određeni kurs odražava na učenikove/studentove akcije u sistemu, rešavanje zadataka i njihov celokupan uspeh [309].

Za oblast e-učenja potrebno je definisanje univerzalnog i kvalitetnog standarda evaluacije na osnovu koje će uspešno moći da se izmeri efikasnost tehnika veštačke inteligencije u sistemima za e-učenje [308]. Veoma je važno sprovesti komparativna ispitivanja različitih intelligentnih tehnika kako bi se izdvojile najefikasnije među njima [310]. Realizovanje toga uslovljeno je potrebom postojanja sveobuhvatnog modela koji će se sastojati od više dimenzija među kojima su tehnika, pedagoški dizajn, stručno znanje i ludske karakteristike da bi se garantovala validnost i pouzdanost evaluacije [308]. Takođe, u dostupnim istraživanjima može se primetiti nedostatak longitudinalnih studija, veliki broj tehnoloških pilot studija i mnogo kvantitativnih metoda koje ostavljaju prostor za nova naprednija istraživanja usmerena ka učenju podržanom veštačkom

inteligencijom, a koje će biti zasnovano na pristupima i metodama baziranim na dizajnu [291], [311].

Istraživanja koja se sprovode vezana za intelligentne tehnike uglavnom se odnose na kreiranje modela na osnovu analize podataka i nalaženja određenih obrazaca, predikciju za potrebe informisanja, podršku donošenju odluka i razne druge analize uz pomoć ML tehnika [291]. Ovakva istraživanja rade se u sve većoj meri s obzirom na ogroman napredak tehnologije u poslednje vreme, kao i sve većeg broja škola i univerziteta koji sakupljaju podatke o aktivnostima učenika/studenata u različitim sistemima za e-učenje. Analizirajući literaturu o intelligentnim tehnikama uočava se veliki broj izazova u vezi sa predikcijom uspeha učenika/studenata u sistemima za e-učenje. Većina tih izazova proizlazi iz neiskorišćenosti punog potencijala tehnika veštačke inteligencije od strane istraživača za ovu svrhu, zbog zanemarivanja prethodne analize podataka, izbora neadekvatnih tehnika za predikciju u konkretnom slučaju itd. [8], [21], [22]. Posledica neoptimizovanog upravljanja kapacitetima jeste da razvijeni modeli za predikciju često ne postižu zadovoljavajući procenat tačnosti. Jedan od glavnih uzroka tome jeste nedostatak standardizovanog pristupa koji bi omogućio efikasniji proces predikcije i, samim tim, bolje rezultate [312]. Prevazilaženje navedenih aspekata i unapređenje korišćenja svih raspoloživih potencijala jeste jedan od glavnih ciljeva disertacije, a to je, da istraži i adresira ključne izazove u oblasti predikcije uspeha učenika/studenata u e-učenju, sa posebnim fokusom na pružanje okvira za standardizaciju procesa predikcije.

### **2.3. Predikcija uspeha učenika/studenata u sistemima za e-učenje**

Značajan broj radova u naučnoj literaturi aktuelizuje korišćenje prediktivnih tehnika u oblasti e-učenja i to u različite svrhe [313]. Neke od primena ovih tehnika jesu pružanje ranog uvida u rezultate i postignuća učenika/studenata [288], [314], [315], identifikacija tipova učenika/studenata na osnovu njihovog učinka, angažovanja i ponašanja [316], procena zadovoljstva učenika/studenata [317], kao i njihovog zalaganja [318], poboljšanje povratnih informacija za učenike/studente od strane agenta (mentora) kako bi se omogućilo personalizovano iskustvo za svakog učenika/studenta [319], prepoznavanje poteškoća sa kojima se učenici/studenti susreću [320], otkrivanje učenika/studenata za koje postoji rizik da padnu ispit/kurs [321], [322],

[323], rano upozoravanje i savetovanje budućih učenika/studenata [324], [325], podizanje kvaliteta nastave i učenja, kao i celokupnog iskustva učenika/studenata u tom procesu [326] itd.

### **2.3.1. Uloga predviđanja uspeha učenika/studenata**

Predviđanje uspeha učenika/studenata u e-učenju može doneti veliki broj prednosti za nastavnike, učenike/studente i obrazovne institucije [313].

Predikcija uspeha učenika/studenata najviše koristi nastavnicima, koji na ovaj način mogu dobiti važne i korisne uvide o učenicima/studentima, odnosno njihovim sposobnostima, potencijalima i slabostima. Anticipacija dometa učenika/studenta pomaže nastavnicima u njegovoj proceni i utvrđivanju njegovog kapaciteta, kako bi u korelaciji s tim mogli da preduzmu korektivne radnje na vreme [327]. Rezultati predikcije mogu pružiti nastavnicima i važne informacije koje mogu da se iskoriste za dizajn učenja, kao i za pravljenje novog ili modifikovanje postojećeg nastavnog materijala, koji će biti usklađeniji s potrebama učenika/studenata [6]. Značajni su i u detekciji učenika/studenata koji se susreću sa poteškoćama, kako bi im blagovremeno bile pružene dodatna pomoć i podrška, te na taj način sprečavajući ih od eventualnog pada godine ili napuštanja školovanja [4]. Pored ostalog, ovakvi uvidi omogućavaju nastavnicima da prilagode svoj pristup podučavanja i adaptiraju ga prema onim učenicima/studentima koji se nisu snašli na kursu, smanjujući tako šanse da ti učenici/studenti ne završe kurs, ali najvažnije od svega - dovedu do povećanja kvaliteta e-učenja [326].

Učenici/studenti bi najviše koristi od predikcije njihovog uspeha imali ako bi nastavnici uspeli da na odgovarajući i optimalan način primene te rezultate kako bi kreirali adekvatan nastavni plan i sadržaj, omogućavajući učenicima/studentima da uče na osnovu svojih projektovanih rezultata [6]. Na osnovu ishoda predikcije uspeha, učenici/studenti mogu korigovati svoje taktike učenja, kao i napraviti efikasniji plan učenja [328]. Takođe, učenici/studenti mogu iskoristiti ove informacije u cilju odabira odgovarajućih kurseva prema ličnim afinitetima [329].

Obrazovne institucije mogu da iskoriste informacije dobijene predviđanjem uspeha učenika/studenata za donošenje pravovremenih odluka, kao i sprovođenje adekvatnih promena koje će dovesti do boljih rezultata učenika/studenata [330]. Takođe, ovakvi uvidi daju instituciji mogućnost da uspostavi efikasne strateške planove koji će dovesti do kvalitetnijeg obrazovanja [7]. Najvažnije među svim benefitima - obrazovne institucije će na osnovu ovakvih informacija

biti u poziciji da efikasno rukovode upisom učenika/studenata, povećaju procenat njihovog zadržavanja, poboljšaju upravljanje alumni asocijacijom i povećaju efektivnost svog delovanja [312].

Sagledavajući navedene činjenice, može se konstatovati da se predviđanje uspeha učenika/studenata može iskoristiti za unapređenje onlajn obrazovanja, od čega svi u obrazovnom sistemu mogu imati koristi.

### **2.3.2. Tehnike za predikciju uspeha učenika/studenata koje se koriste u e-učenju**

Postoji veliki broj radova u literaturi koji se bave predviđanjem uspeha učenika/studenata u e-učenju koristeći za taj proces jednu ili više različitih tehnika [313]. Među najzastupljenijim tehnikama koje su istraživane u literaturi jesu ANN i različite tradicionalne ML tehnike.

Najčešće tradicionalne ML tehnike koje se koriste za predikciju su [13]:

- stablo odlučivanja (eng. *Decision tree - DT*, u daljem tekstu: DT),
- *Naive Bayes*,
- mašina podržavajućih vektora (eng. *Support vector machine - SVM*, u daljem tekstu: SVM),
- algoritam k-najbližih suseda (eng. *k-Nearest Neighbors - kNN*, u daljem tekstu: kNN),
- nasumična šuma (eng. *Random forest - RF*, u daljem tekstu: RF).

Osim navedenih, logistička regresija (eng. *Logistic regression*) i linearna regresija (eng. *Linear regression*), koje se takođe mogu kategorizovati kao ML tehnike, često se koriste, ali se pored toga smatraju i statističkim tehnikama. U predikciji uspeha učenika/studenata u sistemima za e-učenje pomenute statističke tehnike neretko su prvi izbor istraživača [331], [332], [333]. Te tehnike obično se koriste zato što su jednostavnije za upotrebu i interpretaciju rezultata u odnosu na tehnike veštačke inteligencije [334]. Međutim, literatura sugerira da tehnike veštačke inteligencije za predikciju obično postižu bolje rezultate od statističkih [10]. Tehnike veštačke inteligencije mogu da upravljaju složenim nelinearnim odnosima u podacima, kao i da otkrivaju komplikovanije trendove i obrasce u njima [8]. Takođe, njihova mogućnost učenja iz novih podataka omogućava im da kontinuirano poboljšavaju svoju sposobnost predviđanja i performanse, što ih čini dosta fleksibilnjim i prilagođljivijim [9].

Predikcija uspeha učenika/studenata u e-učenju uglavnom podrazumeva predviđanje akademskog uspeha, odnosno njihovih ocena [335], [336], [337], [338]. Čest je slučaj da se ocene

transformišu u nekoliko kategorija, kao npr. dobre, prosečne i loše, kako bi se potom predviđale te kategorije umesto ocena [339]. Međutim, na anticipaciju kategorisanih ocena autori se neretko odlučuju samo kako bi postigli veću tačnost, pošto je lakše predvideti kategorije u odnosu na tačne ocene. Tako su npr. *Hashim* i sar. [4] kod predikcije kategorija uspeli da postignu tačnost od čak 88,8%, za razliku od ocena gde je ona iznosila samo 68,7%. Takođe, često se u e-učenju predviđa prolaznost na kursu (prošao/pao) [340]. Pored toga, razvijaju se i modeli koji daju predviđanja na nedeljnom nivou u svrhu ranog dobijanja korisnih informacija [323].

Autori u svojim istraživanjima koriste mnoge različite pristupe za predviđanje uspeha učenika/studenata u e-učenju. Oni standardni i najčešći odnose se na razvoj modela za predikciju korišćenjem tradicionalnih ML tehnika [4], [339], kao i oni koji koriste samo ANN [19], [337], [338], [341]. Zastupljena pojava u ovakvim istraživanjima jeste jednostavno poređenje tehnika u svrhu određivanja najboljih, odnosno onih koji postižu najveću tačnost u određenim situacijama [24], [342]. Primetno je da u radovima sa ovom tematikom postoji veliki broj situacija u kojima istraživači nasumično koriste proizvoljne prediktivne tehnike kako bi na taj način dobili ikakve rezultate koje bi potom prikazali, a bez detaljnog objašnjenja zašto su baš te tehnike korišćene [23], [25], [26], [27]. Postoje brojni aspekti koji utiču na izbor tehnike predviđanja, kao što su ciljna varijabla, struktura podataka, konfiguracija i performanse računara [343] itd. Upravo iz navedenih razloga, ako istraživači nasumično biraju tehnike predviđanja, neće biti u mogućnosti da u potpunosti iskoriste kapacitete veštačke inteligencije i razviju modele koji će moći da postignu visoku tačnost.

Naravno, postoje i oni autori koji u svojim radovima upotrebljavaju novije ili ne tako standardne pristupe za proces predikcije uspeha učenika/studenata. Npr. *Jang* i sar. [323] koristili su za tu namenu ML tehnike i objasnjuju veštačku inteligenciju kako bi izvršili predikciju uspeha učenika/studenata u e-učenju. *Jiao* i sar. [344] razvili su kvantitativni model predviđanja koristeći genetsko programiranje, čiji su rezultati nadmašili ishode SVM-a u potpunosti, dok su u poređenju sa ANN-om uspeli da premaže njihovu tačnost na podacima za trening i imali uporedive rezultate sa njima na podacima za testiranje. *Rakić* i sar. [345] uspeli su da dobiju relevantnije rezultate koristeći višemetodski pristup za analizu podataka, koji je podrazumevao analizu društvenih mreža, grupisanje k-srednjih vrednosti i linearnu regresiju. *Wang* i sar. [346] koristili su konvolucione *GRU* (eng. *Gated Recurrent Unit*) i objasnjuje neuronske mreže kako bi razvili prediktivni model koji se pokazao dobro u odnosu na druge slične metode. *Sweta* i sar. [27]

upotrebljavali su analitiku učenja kako bi uspešno predvideli uspeh učenika/studenata u e-učenju. *Saleem* i sar. [347] za potrebe predviđanja uspeha učenika/studenata predložili su model koji treba da predstavlja inteligentni sistem za podršku odlučivanju, koji se pokazao kao efikasna metoda za predviđanje korišćenjem ML tehnika.

Istraživači su u svojim studijama uspeli da razviju modele koji postižu razne tačnosti - od onih nižih pa sve do onih viših, odnosno maksimalnih. Tako neki radovi prijavljuju tačnosti  $< 80\%$  [339], [348], [349], zatim između 80 i 90% [21], [23], [24], [26], [336], [340], [347], [350], [351], potom i između 90 i 95% [25], [352], [353], kao i oni sa najvećom, odnosno  $> 95\%$  [22], [354], [355], [356], [357]. U ovoj poslednjoj grupi radova, koji su postigli najveću tačnost, može se izdvojiti jedan rad u kojem je razvijen hibridni model - sa generalizovanim linearnim modelom i ANN-om, koji predviđa ocene učenika/studenata sa tačnošću od 100% [356].

Primetno je u istraživanjima da se ulaže stalan napor kako bi se obezbedila veća tačnost predviđanja uspeha učenika/studenata u sistemima za e-učenje. Mnoge studije upravo iz ovog razloga predlažu hibridne modele kao način da se zaobiđu nedostaci konvencionalnih tehnika i poveća tačnost. Primeri takvih modela su adaptivni neuro-fazi sistem zaključivanja (eng. *Adaptive neuro-fuzzy inference system*) [354], ANN zasnovane na optimizaciji rojem čestica (eng. *Neural networks based on particle swarm optimization*) [355], generalizovani linearni model sa ANN-om (eng. *Generalized linear model with artificial neural network*) [356] itd. Tu su i drugi načini za povećanje tačnosti predviđanja, kao što je korišćenje ansambl metoda (*bagging*, *boosting*, *stacking* i *voting*) [340], [347], [352], [358].

### 2.3.3. ANN i tradicionalne ML tehnike u predikciji uspeha učenika/studenata

U problematizaciji predviđanja uspeha učenika/studenata u e-učenju, ali takođe i u drugim slučajevima, ANN su značajno robustnije u poređenju sa tradicionalnim ML tehnikama i često mogu postići veću tačnost u odnosu na njih [18]. ANN su dosta moćnije pošto imaju sposobnost rešavanja složenijih problema, bolju detekciju skrivenih relacija u okviru podataka [15], skalabilnije su [359] i nemaju ograničenja u vidu regresione ili linearne diskriminantne analize kao tradicionalne ML tehnike [18], [19], [20].

U literaturi se najčešće nalaze radovi koji obrađuju samo ANN [19], [338], [341] ili samo tradicionalne ML tehnike [326], [353], [360]. Međutim, u radovima gde se koriste i ANN i

tradicionalne ML tehnike za predikciju uspeha učenika/studenata u sistemima za e-učenje, rezultati najvećeg broja radova pokazuju da se veća tačnost ostvaruje pomoću modela razvijenih upotrebom ANN-a. Tako su npr. *Arumugam* i sar. [21] koristili DT (J48), nasumično stablo, višeslojnu perceptronsku neuronsku mrežu i radijalne neuronske mreže, gde su radijalne neuronske mreže postigle najbolje rezultate. *Su* i sar. [350] razvili su modele pomoću ANN-a, RF-a, SVM-a i logističke regresije, gde je ANN model pokazao najbolje performanse. *Rivas* i sar. [348] upotrebljavali su ANN, DT, RF i *XGBoost*, postigavši najveću tačnost putem ANN-a. *Kokoç* i sar. [335] primenili su *Naive Bayes*, kNN, SVM, RF, ANN i *CN2*, gde su ANN isto imale bolje rezultate u odnosu na tradicionalne ML tehnike. *Santamaría-Lopez* i sar. [336] testirali su ANN, RF, *XGBoost*, SVM, kNN i logističku regresiju, gde su ANN takođe ostvarile najveću tačnost predikcije.

Naravno, stav da ANN uvek postižu bolje rezultate, odnosno veću tačnost predikcije, ne može da se generalizuje. Pojedini autori demonstrirali su u svojim istraživanjima da su se u slučaju predviđanja uspeha učenika/studenata u sistemima za e-učenje tradicionalne ML tehnike pokazale bolje od ANN-a ili su eventualno postigle istu tačnost. Tako su npr. *Emirtekin* i sar. [22] koristili kNN, ANN, RF, SVM, *Naive Bayes* i logističku regresiju, gde je kNN postigao najbolje rezultate. *Alsharhan* i sar. [23] primenili su ANN, DT i *Naive Bayes*, gde je najveća prosečna tačnost postignuta uz pomoć *Naive Bayes* tehnike. *Sriram* i sar. [349] koristili su ANN, SVM i linearnu regresiju, gde su rezultati pokazali da su ANN i SVM postigle potpuno istu prosečnu tačnost.

Iz svega navedenog u ovoj sekciji, neophodno je sprovesti dodatna istraživanja kako bi se tačno utvrdilo u kojim slučajevima ANN postižu bolje rezultate u odnosu na tradicionalne ML tehnike i obrnuto.

#### **2.3.4. Selekcija ulaznih varijabli za potrebe predviđanja**

Selekcija ulaznih varijabli (eng. *Input variable selection - IVS*, u daljem tekstu: IVS) vrši se sa ciljem odabira najrelevantnijih prediktora, odnosno skupa prediktora, koji će potencijalno dovesti do veće tačnosti predikcije [313].

Za ovaj proces koriste se tri osnovne metode [361]:

- metode filtracije,
- metode omotača,
- ugrađene metode.

## *Metode filtracije*

Metode filtracije (eng. *Filter methods*) zasnivaju se na statističkoj analizi i analizi korelacija i koriste se u postupku preprocesiranja podataka za određivanje optimalnog skupa prediktora. Dobijanje takvog skupa potencijalno može dovesti do veće tačnosti predviđanja. Upotreba metoda filtracije smanjuje broj prediktora potrebnih za predviđanje, što dovodi do pojednostavljenja prediktivnih modela, smanjenja vremena izračunavanja, kao i sprečavanja pretreniranosti [349]. Rezultat takvog pristupa jeste poboljšavanje interpretabilnosti modela, generalizacije i operativne efikasnosti [28].

Najpoznatije tehnike metoda filtracije koje se koriste za dobijanje najoptimalnijeg skupa prediktora su [362]:

- Algoritam mrMR (minimalna redundantnost - Maksimalna Relevantnost) - predstavlja kriterijum kojim se biraju najinformativnije varijable u pogledu minimalne redundancije, maksimalne relevantnosti i kombinacije ovih kriterijuma.
- Pirsonov koeficijent korelacije (eng. *Pearson correlation coefficient*) - predstavlja statistički test kojim se mere korelacije između dve varijable, u ovom slučaju između potencijalnog prediktora i ciljne varijable, pa se tako za prediktore biraju najbolje varijable, odnosno one koje imaju najveće korelacije ka ciljnoj varijabli.
- Informaciona dobit (eng. *Information gain*) - predstavlja tehniku dobijanja najinformativnijih varijabli koje su odabrane u odnosu na to koliko smanjuju nesigurnost u vezi sa ciljnom varijablom kada se dele podaci.
- Hi-kvadrat test (eng. *Chi-squared test*) - jeste još jedan način da se selektuju ulazne varijable tako što se određuje da li postoji specifična i važna povezanost između svake pojedinačne ulazne varijable i ciljne varijable.

## *Metode omotača*

Metode omotača (eng. *Wrapper methods*) funkcionišu drugačije od metoda filtracije, pošto one odabir najboljeg skupa varijabli rade na osnovu performansi odabrane tehnike veštacke inteligencije [363]. Algoritam za selekciju optimalnog skupa varijabli koristi samu tehniku veštacke inteligencije za evaluaciju skupa varijabli.

Tehnike koje mogu da se koriste u okviru ove metode su [364]:

- Selekcija unapred (eng. *Forward selection*) - funkcioniše po principu dodavanja varijabli koje poboljšavaju performanse modela u skup varijabli sve dok uvođenje nove varijable ne pokvari performanse.
- Selekcija unazad (eng. *Backward elimination*) - deluje tako što se proces započne sa svim varijablama, pa se onda varijable sa najmanjim značajem jedna po jedna uklanjuju sve dok više nema poboljšanja performansi modela.
- Rekurzivna eliminacija karakteristika (eng. *Recursive feature elimination*) - koristi kriterijum rangiranja varijabli i ML algoritam, procenjujući uticaj svake varijable posebno i onda slično kao tehniku selekcije unazad uklanja jednu po jednu varijablu dok ne ostane određen broj varijabli za koji se smatra da je konačan i koji će dati najveću tačnost predviđanja.

### *Ugrađene metode*

U okviru ugrađenih metoda (eng. *Embedded methods*) proces selekcije ulaznih varijabli ugrađen je u tehniku predikcije [363]. Shodno tome, odabir najboljeg skupa varijabli dešava se za vreme treninga, odnosno procesa učenja algoritma. Za razliku od metoda filtracije gde se odabir varijabli dešava nezavisno od tehnike veštačke inteligencije, kod ugrađenih metoda to nije slučaj.

Neke od najpoznatijih tehniki ugrađenih metoda su [365]:

- Laso (eng. *Lasso - Least absolute shrinkage and selection operator*) regularizacija - za potrebe selekcije ulaznih varijabli postavlja koeficijente nevažnih varijabli na nulu i tako ih uklanja iz modela.
- Grebena regresija (eng. *Ridge regression*) - za razliku od laso regularizacije nema mogućnost postavljanja koeficijenta varijabli na nulu, ali može da im postavi veoma niske koeficijente koji su blizu nule, pa se tako varijable sa većim koeficijentima smatraju važnim i one ulaze u izbor konačnog skupa varijabli za predikciju.
- Elastična mreža (eng. *Elastic net*) - jeste tehniku koja kombinuje prethodne dve tehnike kako bi izvršila selekciju ulaznih varijabli.

### *Odabir metode za selekciju ulaznih varijabli*

Odabir metode IVS-a zavisi od strukture podataka i primenjene tehnike veštačke inteligencije. Takođe, svaka od metoda IVS-a dolazi sa svojim prednostima i manama.

Metode filtracije, u poređenju sa drugim dvema metodama, mnogo su brže i skalabilnije [366]. U odnosu na metode omotača i ugrađenih metoda čiji su rezultati vezani samo za određenu ML tehniku, metode filtracije nezavisne su od ML tehnika pa se njeni rezultati mogu primeniti na bilo koju od njih. Razumevanje i tumačenje rezultata selekcije varijabli koji se dobiju metodama omotača i ugrađenim metodama teže je od onih dobijenih metodama filtracije [367]. Metode filtracije takođe su računarski efikasne, pošto varijable procenjuju nezavisno, dok je npr. kod metoda omotača neophodna obuka većeg broja modela što zahteva više vremena i veću kompjutersku snagu [368]. Takođe, manji je rizik od preopterećenja kada se koriste metode filtracije u odnosu na druge dve metode [369]. Važno je napomenuti to da ne podržavaju svi ML algoritmi ugrađene metode, pa je tako nemoguće da se one koriste u svakoj situaciji. Smatra se da je jedna od retkih mana metoda filtracije to što u procesu odabira ulaznih varijabli one nemaju neku vrstu interakcije sa ML algoritmom [369]. Međutim, upravo u tome i jeste suština ovih metoda - njihova nezavisnost od ML tehnika, kako bi se njihovi rezultati mogli iskoristiti za bilo koju ML tehniku.

Shodno iznetim činjenicama i tome da ne postoji univerzalna metoda za selekciju ulaznih varijabli, može se zaključiti da su metode filtracije najbolji izbor kada je u pitanju odabir optimalnog skupa varijabli.

### *Uticaj metoda filtracije na tačnost predviđanja tradicionalnih ML tehnika i ANN-a*

U slučajevima kada se metode filtracije primenjuju na tradicionalne ML tehnike, uviđa se značajna kauzalnost na visinu tačnosti predviđanja, kao što brojne studije pokazuju [28], [340], [352], [370]. Naravno, u literaturi se može naći i veliki broj radova koji nisu koristili metode filtracije kako bi odredili optimalan skup prediktora, koji bi se primenio u procesu predviđanja tradicionalnim ML tehnikama, nego su jednostavno koristili sve varijable čime su propustili šansu da povećaju tačnost predviđanja [4], [21], [22], [23], [24], [26]. Međutim, čak i oni istraživači koji su koristili metode filtracije za izbor varijabli, odlučili su da prikažu samo one rezultate predviđanja dobijene sa odabranim skupom prediktora, a ne i rezultate dobijene sa svim

prediktorima [25], [349], [353]. Ovo dovodi u pitanje da li su te odabrane varijable stvarno doprinele poboljšavanju tačnosti modela, pošto bez testiranja ML algoritama sa svim varijablama, kao i testiranja sa onim odabranim pomoću metoda filtracije to nije moguće potvrditi. Ono što je retkost, ali je ipak moguće, jeste to da metode filtracije nekada mogu da imaju i obrnuti efekat, odnosno da se tačnost ML algoritama smanji ili, u najboljem slučaju, ostane ista kao i kada se koriste sve varijable [371]. Upravo iz navedenih razloga, uvek je najbolje testirati tačnost predviđanja sa svim varijablama i sa onim selektovanim, kako bi se ustanovilo koliko je zapravo poboljšanje tačnosti, ako ga uopšte ima. Direktni uticaj metoda filtracije biće vidljiv jedino tako i znaće se tačan procenat poboljšanja njihovim korišćenjem.

Za razliku od tradicionalnih ML tehnika, primena metoda filtracije kod ANN-a obično nije neophodna. ANN nemaju ograničenja po pitanju ulaznih parametara, za razliku od tradicionalnih ML tehnika [372]. Upravo iz tog razloga ANN uglavnom postižu bolje rezultate kada se ne isključuju određeni prediktori, nego se koriste sve varijable za proces predikcije [19], [337], [338], [351], [355]. Iako je ovo nešto što se dešava u većini slučajeva, ipak se ne može generalizovati, pošto su neke studije postigle bolje rezultate pomoću ANN-a kada su koristile metode filtracije [350].

Iz gore navedenog izvodi se zaključak da tradicionalne ML tehnike mogu imati velike koristi od primene metoda filtracije za potrebe određivanja optimalnog skupa prediktora, dok je kod ANN-a drugačije, odnosno veća je verovatnoća da će se postići bolji rezultati bez primene ovih metoda.

### 2.3.5. Tipovi podataka koji se koriste kao prediktori

Za proces predikcije uspeha učenika/studenata u e-učenju koriste se različite karakteristike, koje mogu da se podele u tri glavne grupe [313]:

- demografski podaci,
- obrazovni podaci,
- različite karakteristike e-učenja.

U grupu demografskih podataka spadaju starost, nacionalnost, mesto rođenja, pol, informacije o roditeljima i drugi podaci [22], [352].

Obrazovni podaci koji se koriste kao prediktori su: ocene učenika/studenata, njihov ukupan uspeh, nivo obrazovanja, smer, semestar, rezultati postignuti na završnim ispitima, prisustvo, broj dana tokom kojih su bili odsutni sa nastave i slično [22], [25], [26].

Kada su u pitanju karakteristike e-učenja koje se koriste u ove svrhe, one mogu da se podele u nekoliko dodatnih kategorija:

- Klikovi (ukupan broj klikova, broj klikova samo levim tasterom, broj klikova samo desnim tasterom, broj klikova točkićem i kretanje miša) [340].
- Vremenske karakteristike (ukupno vreme provedeno u sistemu, vreme provedeno po zadatku, prosečno vreme po zadatku, vreme početka sesije, vreme završetka sesije i vreme mirovanja) [349], [354].
- Korišćeni nastavni resursi (broj poseta nastavnom sadržaju, video materijalu, silabusu, temama i kvizovima) [22], [352], [355].
- Karakteristike uspeha (ukupan broj pokušaja, broj uspešnih pokušaja, broj neuspelih pokušaja, rezultati onlajn kvizova i rezultati onlajn testova) [22], [341].
- Korišćeni servisi (broj poseta forumu, vikiju, rečniku, saopštenjima i učestalost korišćenja poruka ili četova) [326], [355].

Interpretirajući postojeće kategorije prediktivnih karakteristika, u literaturi se može videti da autori za proces predikcije uspeha učenika/studenata u e-učenju nekada koriste samo pojedine kategorije, a nekada više njih istovremeno. Tako se neki modeli za predviđanje razvijaju koristeći samo različite karakteristike e-učenja [21], [326], [340], [341], [349], [354]. Sa druge strane, postoje i modeli koji se kreiraju uz pomoć karakteristika e-učenja i demografskih podataka [351], [355]. Zatim, oni modeli koji kombinuju karakteristike e-učenja i obrazovne podatke [25], [26], [356]. Takođe, postoje i primeri korišćenja svih triju kategorija karakteristika za izgradnju prediktivnih modela [4], [22], [352].

### **2.3.6. Analiza podataka za potrebe predviđanja**

Posmatrajući radeove koji se bave predikcijom uspeha učenika/studenata u e-učenju, može se primetiti da je glavni fokus na rezultatima korišćenja tehnika veštačke inteligencije za klasifikaciju ili regresiju [4], [21], [22], [24]. Mnogi autori ne posvećuju dovoljnu pažnju prethodnoj analizi podataka u svrhu predviđanja ili je uopšte ne praktikuju [22], [23], [27]. Upravo

ta prethodna analiza ulaznih podataka može biti od važnog i suštinskog značaja kada se pristupi odabiru odgovarajuće tehnike za izvršenje procesa predikcije. U literaturi se može naći veliki broj radova u kojima se pominje da su pre procesa predikcije rađene određene analize podataka. Međutim, rezultati dobijeni putem tih analiza često nisu prikazani, niti su obrazloženi razlozi za njihovo neprikazivanje [349], [356]. Još jedan od aspekata koji se može primetiti u različitim studijama ovog tipa jeste da se veoma često ne radi i ne prikazuje deskriptivna statistika varijabli, što onemogućava čitaoce da se bolje upoznaju sa strukturom podataka [26], [358], [360]. Isto tako, autori se retko odlučuju da prikažu raspon vrednosti za ulazne varijable, čime je onemogućeno dublje i preciznije razumevanje tih podataka [19], [347], [360]. Vizuelni prikaz varijabli preko deskriptivne statistike može biti veoma koristan pri odabiru tehnike za proces predikcije [29], [30]. Još jedan segment koji može biti od ključnog značaja za izbor prediktivne tehnike je i korelaciona analiza, koja je jednakom bitna i za ostvarivanje maksimalne tačnosti predviđanja. Određena istraživanja tvrde da se najveća tačnost predikcije postiže upravo sa onim ulaznim varijablama koje imaju visoke korelacije sa ciljnom varijablom i kada nema multikolinearnosti između prediktora [373], [374]. Takođe, jedna studija izveštava da se tačnost ML tehnika može povećati kada se uklone ulazne varijable čije su korelacije ka ciljnoj varijabli  $< 0,35$  [375]. Upravo iz istraživanja ovog tipa i drugih sličnih studija može se videti da struktura podataka utiče na izbor tehnike predviđanja [376], [377]. Međutim, u velikom broju studija autori se nisu odlučili na sprovođenje potrebnih analiza podataka već su nasumično birali tehnike predviđanja [23], [24], [25], [26], [27].

Shodno navedenim činjenicama, može se zaključiti da istraživači koji preskoče početnu analizu podataka neće biti u mogućnosti da dostignu maksimalnu tačnost predviđanja i u potpunosti iskoriste potencijal i kapacitete tehnika veštačke inteligencije.

### **2.3.7. Izazovi u predikciji uspeha u e-učenju**

Veliki problem kod predikcije uspeha učenika/studenata u sistemima za e-učenje jeste nedostatak standardizovanih metodologija za ovu svrhu, koje bi istraživači mogli da koriste za ovaj proces kako bi uspeli da razviju modele koji će postići visoku tačnost predikcije [30], [32]. Istraživači često pristupaju predikciji uspeha učenika/studenata bez jasnog plana [312], [378], umesto da usvoje standardizovan pristup koji bi doprineo efikasnjem procesu predikcije i boljem

kvalitetu rezultata. Cilj većine istraživanja iz ove oblasti jeste prosto da se dođe do nekih rezultata koji će potom biti prikazani [24], [26]. U radu [312], u kome je analiziran veliki broj studija iz ove oblasti, primećeno je da većina autora usvaja sličan pristup za predikciju uspeha učenika/studenata. Taj pristup uglavnom preskače detaljan postupak preprocesiranja podataka i vodi ka nasumičnom biranju tehnika za predikciju nakon čega su rezultati analizirani i predstavljeni u radu. Kao što je već pomenuto, nesprovodenje prethodne analize ulaznih varijabli rezultira manje tačnim modelima predikcije i na taj način istraživači nisu u mogućnosti da u potpunosti iskoriste kapacitete veštačke inteligencije [23], [25], [27].

Iako opšte metodologije za predikciju, koje nisu vezane za specifičnu oblast, mogu biti korisne do određenog stepena, one često izostavljaju ključna objašnjenja i detaljna uputstva koja bi sugerisala adekvatne postupke, metode i tehnike u kontekstu e-učenja [33]. Nedostatak adekvatnih metodologija za ovu svrhu, kao i preskakanja celog postupka ili određenih koraka u postupku preprocesiranja i nasumičnog biranja tehnika predikcije od strane istraživača, dovodi do upotrebe modela koji ne postižu zadovoljavajući nivo tačnosti predviđanja. Svaki procenat tačnosti manje, u zavisnosti od uzorka, znači npr. jednog ili više učenika/studenta čiji uspeh neće biti tačno predviđen, što može dovesti do toga da se intervencije za neke učenike/studente izvrše u pogrešnom smeru [379].

Pregled literature ukazuje na jasnu potrebu za istraživanjem koje bi razvilo i testiralo napredne modele za predikciju uspeha učenika/studenata u e-učenju. Utvrđeno je da se problemi koji se javljaju u procesu predikcije uglavnom odnose na to da većina istraživača ne uspeva da iskoristi pun potencijal tehnika veštačke inteligencije za ovu svrhu. Uočeno je da veliki broj istraživača nasumično bira proizvoljne tehnike veštačke inteligencije bez prethodne analize podataka, kao i bez istraživanja koji pristup je najprikladniji u njihovom slučaju, pa tako ne uspevaju da postignu maksimalnu tačnost predikcije. Zanemarivanje preprocesiranja podataka u predikciji uspeha učenika/studenata od strane istraživača otvara prostor dodatnom istraživanju u ovoj oblasti. Određivanje najpogodnijih ulaznih varijabli za svaku tehniku veštačke inteligencije ostaje relevantno pitanje u ovom domenu. U istoj meri fokus je valjano usmeriti i na istraživanja sa ciljem identifikacije najefikasnije i najučinkovitije tehnike veštačke inteligencije za predikciju uspeha učenika/studenata u sistemima za e-učenje. Može se zaključiti da bi postojanje jedne sveobuhvatne, pouzdane i efikasne metodologije za predikciju uspeha učenika/studenata u sistemima za e-učenje, koja će pokriti sve neophodne faze ovog procesa, bilo od velike važnosti i

koristi za istraživače iz ove oblasti, ali takođe i za sve koji učestvuju u nastavnom procesu - i za učenike/studente i za nastavnike.

Na osnovu identifikovanih nedostataka i izazova, evidentno je da postoji potreba za sprovođenjem opsežnih istraživanja u oblasti predikcije uspeha učenika/studenata u sistemima za e-učenje. Pomenuta istraživanja determinisana su radi postizanja napretka u modernizaciji pristupa nastavi kroz primenu rezultata predikcije. Sprovođenjem izvedenih metoda značajno bi se unapredio kvalitet obrazovanja, povećao stepen završetka kurseva i generalno poboljšalo iskustvo studenata u e-učenju.

### **3. Sprovedeno istraživanje**

Na osnovu utvrđenih potreba za istraživanjem iz prethodnog poglavlja, koje problematizuju aspekte u oblasti predikcije uspeha studenata u sistemima za e-učenje, i u skladu sa postavljenim ciljevima disertacije, istraživanje nastoji da razvije metodologiju koja će omogućiti uspešnu predikciju uspeha studenata u sistemima za e-učenje upotrebom tehnika veštačke inteligencije. Razumevanje faktora koji utiču na uspeh studenata postalo je ključno, posebno u onlajn učenju. Kroz analizu podataka o interakciji studenata sa sistemom za e-učenje, kao i primenom naprednih tehnika veštačke inteligencije, cilj istraživanja je da identificuje ključne varijable i procese koji doprinose povećanju tačnosti predikcije [313]. Rezultati istraživanja poslužiće kao osnova za kreiranje standardizovane metodologije, koja će se koristiti za unapređenje procesa predikcije i donošenje informisanih odluka u okviru obrazovnih sistema.

#### **3.1. Faze istraživanja**

Ukupan istraživački dizajn disertacije zasnovan je na kombinaciji eksperimentalnih metoda i primeni veštačke inteligencije u sistemima za e-učenje. Istraživanje je podeljeno u nekoliko ključnih faza, koje su detaljno obrađene u različitim poglavljima.

Prva faza podrazumevala je prikupljanje podataka. Iz tog razloga sprovedeni su eksperimenti sa studentima u sistemu za e-učenje koji je beležio podatke njihove interakcije sa sistemom, nakon čega su podaci izvučeni i pripremljeni za sledeću fazu. Cilj prve faze bio je obezbeđivanje relevantnih podataka kako bi ostale faze mogle da se realizuju.

Druga faza sastojala se od tri koraka: pretprocesiranje podataka, primena prediktivnih tehnika veštačke inteligencije i analiza rezultata. Svrha prvog koraka bila je ispitivanje uloge pretprocesiranja podataka i identifikacije optimalnih ulaznih varijabli kako bi se povećala tačnost predikcije tehnikama veštačke inteligencije. Taj korak podrazumevao je analizu podataka upotrebom odgovarajućih statističkih metoda. Razlog sprovođenja drugog koraka jeste razvijanje modela za predikciju uspeha studenata u sistemu za e-učenje, utvrđivanje najefikasnije i najučinkovitije tehnike veštačke inteligencije za predikciju u ovoj oblasti, kao i detekcija faktora koji utiču na uspeh studenata. Treći korak obuhvatao je analizu rezultata istraživanja, kako bi se dobile korisne informacije koje će pomoći u konstrukciji predloga metodologije.

Treća faza sveukupno razmatra činjenice dobijene iz prethodne faze i na osnovu izvedenih zaključaka izlaže predlog metodologije za predikciju uspeha studenata u sistemima za e-učenje. Cilj ove faze jeste i glavni cilj disertacije - razvoj adekvatne metodologije koja pruža okvir za standardizaciju procesa predikcije.

### **3.2. Učesnici**

Učesnici ove studije su studenti osnovnih studija informatike (eng. *Computer science*) Univerziteta jugoistočne Norveške (eng. *University of South-Eastern Norway*). Ukupan broj učesnika (studenata) je 121, od kojih je ukupno bilo 96 muških i 25 ženskih učesnika. Uzorak obuhvata dve generacije studenata ovog univerziteta, koji su učestvovali u eksperimentima na kursu „Uvod u programiranje” u zimskim semestrima 2020-21. i 2021-22. akademskih godina, kada su obe generacije bile na drugoj godini osnovnih studija.

Potencijalni učesnici bili su precizno informisani o procesu prikupljanja i analize podataka, što je osiguralo njihovo razumevanje. Uz dobrovoljni pristanak da budu deo studije, ispunjavajući zahteve informisanog pristanka prema opštoj uredbi o zaštiti podataka (eng. *General data protection regulation - GDPR*), učinili su metode ovih eksperimenata i istraživačke ciljeve dostupnim.

### **3.3. Korišćeni sistem za e-učenje u eksperimentima**

Sistem za e-učenje korišćen u ovim eksperimentima je *ProTuS*<sup>1</sup> [380]. *ProTuS* predstavlja sistem za podučavanje programiranja. Naziv je dobio kao skraćenica od *programming tutoring system*, gde su uzeta prva tri slova prve reči, prva dva slova druge reči i prvo slovo treće reči, formirajući tako naziv *ProTuS* [381]. Ovaj sistem nudi interaktivni materijal za vežbanje osnovnih objektno orijentisanih koncepata u programskom jeziku *Java* i koristi se na različitim univerzitetima više od jedne decenije.

Glavna tri segmenta koje *ProTuS* nudi korisnicima za učenje su primeri, izazovi i vežbe kodiranja [380]. Sistem pruža i personalizovano iskustvo za sve korisnike, preporučujući im one

---

<sup>1</sup> <https://protus.idi.ntnu.no/protusapplication/>

zadatke za koje - ustanovljenim parametrima na osnovu analize aktivnosti - proceni da su prikladni njihovom trenutnom znanju i sposobnostima.

Na Slici 3 prikazano je kako izgleda primer u sistemu iz teme/lekcije „*While petlje*”, koji objašnjava određeni kod, konkretno za primer „Izračunavanje proseka ulaznih brojeva”. Sa strane postoji dugme „Objasni program” (eng. *Explain the program*), koje će dati objašnjenje pojedinih linija koda koje su označene znakom pitanja.

Example: Calculating the Average of Input Integers

Construct a program that reads a series of integers from the user, sums them up, and calculates their average. The user enters 0 to indicate the end of the input.

```
1 import java.text.DecimalFormat;
2 import java.util.Scanner;
3 public class JAverage {
4     public static void main(String[] args) {
5         //Step 1: Define the variables that we need for this program
6         int total = 0; ?
7         int count = 0; ?
8         double average; ?
9         //Step 2: Read the first integer that the user enters
10        Scanner scan = new Scanner(System.in); ?
11        System.out.println("Enter an integer (0 to quit): "); ?
12        int num = scan.nextInt(); ?
13        //Step 3: Process the integer that the user has entered, then receive and process the next integers as long as the user
14        //enters a non-zero integer; otherwise stop
15        while (num != 0) { ?
16            count++; ?
17            total += num; ?
18            System.out.println("The sum so far is " + total + ", count = " + count); ?
19            System.out.println("Enter an integer (0 to quit): "); ?
20            num = scan.nextInt(); ?
21        }
22        scan.close(); ?
23        //Step 4: Calculate and print the average of the integers entered by the user
24        if (count == 0) { ?
25            System.out.println("No integers were entered."); ?
26        } else { ?
27            average = (double) total / count; ?
28            DecimalFormat fmt = new DecimalFormat("0.###"); ?
29            System.out.println("The average is " + fmt.format(average)); ?
30        }
31    }
}
```

EXPLAIN THE PROGRAM

Slika 3. Primer u ProTuS-u

Na Slici 4 ilustrovano je kako izgleda izazov u sistemu iz teme/lekcije „*While petlje*”, za zadatak „Prijem ulaznih celih brojeva dok se ne ispunи određeni uslov”. Izazov se rešava tako što se tehnikom prevlačenja i ispuštanja smešta neka od ponuđenih linija koda sa desne strane u prazno polje u okviru glavnog koda. Nakon toga, moguće je proveriti da li je to tačno rešenje klikom na dugme „Proveri” (eng. *Check*).

 Challenge: Receiving Input Integers Until a Certain Condition is Met (Case 3)

Construct a program that receives an integer from the user, outputs that integer, and stops receiving integers when the user enters a negative integer or an integer greater than 1000.

Drag a tile to each missing field to construct this program.

```

1 import java.util.Scanner;
2 public class JInput3 {
3     public static void main(String[] args) {
4         //Step 1: Read the first integer that the user enters
5         Scanner scan = new Scanner(System.in);
6         System.out.println("Enter an integer:");
7         int num = scan.nextInt();
8         //Step 2: Print the integer that the user has entered, then receive the next integers as long as the user enters an integer
9         //that is not negative and is not greater than 1000; otherwise stop
10        System.out.println("The integer entered is " + num);
11        System.out.println("Enter an integer:");
12        num = scan.nextInt();
13    }
14    scan.close();
15    System.out.println("End of input.");
16 }
17 }
```

Drag a tile from here CHECK

```

while ( num >= 0 && num < 1000 ) {
}
while ( num >= 0 && num <= 1000 ) {
}
while ( num > 0 && num < 1000 ) {
}
while ( num >= 0 || num <= 1000 ) {
}
while ( num <= 0 || num > 1000 ) {
```

Slika 4. Izazov u ProTuS-u

Slika 5 predstavlja vežbu kodiranja u sistemu za određeni zadatak iz teme/lekcije „While petlje”. U vežbi kodiranja neophodno je da se iskuca ceo kod od početka za rešavanje zadatka. Posle toga, rešenje je moguće proveriti klikom na dugme „Podnesi” (eng. *Submit*), nakon čega će se prikazati da li je kod ispravan ili nije. Kada se vežba završi, potrebno je kliknuti na dugme u gornjem desnom uglu „Završi vežbu i zatvorи” (eng. *Finish exercise and close*).

Finish exercise and close

### While Loop 3

Given two integer variables *a* and *b*, complete the following code in order to figure out the first multiple of *a* that is greater than *b*. Store the result in an integer variable called *mult*. Assume that the initial value of the variables *a* and *b* is already set to a positive integer.

E.g. 1: if the value of *a* is 2 and the value of *b* is 8, the value of *mult* will be 10.  
E.g. 2: if the value of *a* is 3 and the value of *b* is 5, the value of *mult* will be 6.  
E.g. 3: if the value of *a* is 4 and the value of *b* is 6, the value of *mult* will be 8.

```

1 int mult;
2 // TODO: add your code here
3
4
5
6
```

Submit

Slika 5. Vežba kodiranja u ProTuS-u

### 3.4. Kurs, postavka i opis rada

Sadržaj ovog kursa podeljen je na 20 tema/lekcija, od kojih svaka sadrži više interaktivnih primera, izazova i vežbi kodiranja [380]. Tokom semestra, studenti su pohađali redovna predavanja i vežbe, pri čemu im je omogućen pristup sistemu za e-učenje *ProTuS*. Ovaj sistem mogli su koristiti za pristup dodatnim nastavnim materijalima i za potrebe dodatnog vežbanja. Studenti su mogli slobodno da pretražuju kurs i biraju teme i sadržaj po svom izboru. S obzirom na to da se na ovom kursu uči programski jezik *Java*, primeri predstavljaju objašnjenje osnovnih koncepata *Java* programiranja. Posle svakog primera, postoji izazov u vezi sa primerom koji su prethodno videli, a to podrazumeva da studenti vežbaju sa kodom koristeći tehniku prevlačenja i ispuštanja kako bi pozicionirali delove koda u prazna polja. Vežbe kodiranja glavni su zadatak koji studenti treba da reše u svakoj temi/lekciji, gde se zahteva od njih da napišu ceo kod od početka za postavljeni problem. Tema/lekcija smatra se obrađenom ako je student uspešno uradio bar jednu vežbu kodiranja u zadatoj temi/lekciji. Studentima nije omogućeno neograničeno vreme da završe zadatke - sesije se automatski zatvaraju ako se ne otkrije aktivnost studenta tokom perioda od dva minuta. Ovaj protokol osigurava da ocenjivanje ostane kontrolisano i uporedivo za sve učesnike, čime se održava princip ujednačenog kriterijuma.

Elo algoritam za ocenjivanje koristi se u pozadini za generisanje rejtinga studenata na osnovu njihove sposobnosti da reše probleme definisane vežbama kodiranja [288]. Elo algoritam za ocenjivanje, koji je prvobitno razvijen za rangiranje igrača na šahovskim turnirima, koristi se u onlajn učenju da bi predstavio znanje studenta i težinu sadržaja za učenje [171]. Funkcioniše na pretpostavci da rejting studenta varira na osnovu ishoda pokušaja da reši vežbu kodiranja - u zavisnosti od uspeha, povećava se ili se smanjuje. Rejting studenata korelira sa učinkom i nivoom težine sadržaja i dinamički se prilagođava - uspešan pokušaj rešavanja vežbe visoke težine dovodi do većeg povećanja rejtinga, dok neuspešan dovodi do relativno manjeg gubitka rejtinga [380]. Iako Elo algoritam za ocenjivanje dolazi sa određenim ograničenjima, kao i sve metode za procenu veština ili adaptivnu procenu znanja, poput probabilitičke teorije testiranja [382], odabran je Elo metod iz sledećih razloga: prvo, Elo algoritam za ocenjivanje u potpunosti se oslanja na kvantitativnu procenu učinka studenata, i može da modeluje veštine koje se menjaju tokom vremena, kao što su veštine programiranja [382]; drugo, kada se u sistem doda nova stavka, nema potrebe za dodeljivanjem tačne početne težine stavke, jer će sistem učiti i dodeljivati nivoe težine

za obrazovni sadržaj na osnovu tačnosti odgovora studenta [382]; i treći i poslednji razlog, Elo algoritam za ocenjivanje može da pruži tačnu procenu težine zadataka sa malom veličinom uzorka - nešto što nije moguće sa modelima koji koriste probabilitičku teoriju testiranja [383].

### 3.5. Prikupljanje podataka

Učesnici ovih eksperimenata, odnosno studenti, vršili su stalnu interakciju sa pomenutim sistemom za e-učenje tokom trajanja kursa. Studenti su se upoznavali sa nastavnim materijalom i primerima, rešavali izazove i vežbe kodiranja. Paralelno, prateći njihove aktivnosti, *ProTuS* sistem beležio je i skladišto te podatke interakcije u svojoj bazi podataka. Na kraju eksperimenata, prikupljeni podaci koji uključuju *log* podatke interakcije 121-og studenta izvučeni su iz baze podataka *ProTuS* sistema i prebačeni u *Excel* fajl, kako bi se dalje na tim podacima vršile potrebne analize.

### 3.6. Variable

Pregled varijabli iz sistema e-učenja (prediktora) koje su se koristile u procesu predikcije može se videti u Tabeli 13.

*Tabela 13. Opis ulaznih varijabli [313]*

Ime varijable	Opis	Raspon
<i>total_durationseconds</i>	Ukupno vreme koje je student proveo u sistemu	[0.. $\infty$ ]
<i>interaction_num</i>	Ukulan broj interakcija studenta sa sistemom za e-učenje	[0.. $\infty$ ]
<i>topics_covered</i>	Broj tema/lekcija koje je student uspešno obradio	[0..20]
<i>pcrs_dist_success</i>	Broj uspešno položenih različitih vežbi kodiranja	[0..62]
<i>elo_rating</i>	Konačan Elo rejting studenta	[100..3000]

Razmatrani podaci o interakciji studenata koje je prikupio sistem su: ukupno vreme kada je student aktivno koristio sistem (*total\_durationseconds*), broj značajnih radnji koje je student napravio u sistemu, kao što je poseta određenom nastavnom materijalu, promena lekcije itd.

(*interaction\_num*), broj tema/lekcija koje je student uspešno obradio (*topics\_covered*), broj različitih vežbi kodiranja koje su uspešno podnete od strane studenta i koje su prošle jedinične testove (*pcrs\_dist\_success*) i ukupan rejting studenta (*elo\_rating*).

### 3.7. Analiza podataka i tehnike veštačke inteligencije

U prvom koraku analize izvršeno je čišćenje podataka, tačnije uklonjeni su svi nepotpuni podaci i vrednosti van normalnih granica (eng. *Outliers*). Nakon toga urađena je deskriptivna statistika, radi dobijanja šire slike o strukturi podataka. U skladu sa postavljenim ciljevima i u svrhu uočavanja značaja određenih svojstava ulaznih podataka, korišćen je popularni algoritam mrMR (minimalna redundancija - Maksimalna Relevantnost) [384]. Ovaj kriterijum bira najinformativnije varijable u pogledu minimalne redundancije, maksimalne relevantnosti i kombinacije ovih kriterijuma. Minimalna redundancija podrazumeva minimalne korelacije između ulaznih varijabli, dok se maksimalna relevantnost odnosi na maksimalne korelacije između ulaznih varijabli i ciljne varijable. U okviru mrMR algoritma, korišćena je F-statistika za ispitivanje relevantnosti u slučaju kontinualnih varijabli grupisanih po klasama predviđene varijable (ocena studenata), a Pirsonov koeficijent korelacije korišćen je za ispitivanje redundantnosti. Potom je korišćen pohlepni algoritam za pretragu (eng. *Gready search algorithm*) za izdvajanje ulaznih varijabli kako bi se maksimizirala funkcija cilja na osnovu kriterijuma uzajamnih informacija. Uzajamne informacije  $I(X, Y)$  između dveju diskretnih varijabli data je formulom [385]:

$$I(X, Y) = - \sum_{x,y} p(x, y) \cdot \log \frac{p(x, y)}{p(x) \cdot p(y)} \quad (1)$$

gde je  $p(x, y)$  mešovita distribucija varijabli  $X$  i  $Y$ , dok su  $p(x)$  i  $p(y)$  marginalne distribucije prethodno navedenih varijabli. Značenje uzajamne informacije najbolje se može videti ako se uzme u obzir  $X \cap Y = \{0\}$ , zatim  $p(x, y) = p(x) \cdot p(y)$  i iz gornje formule vidi se potom da je  $I(X, Y) = 0$ . Jednostavno rečeno, ova količina predstavlja količinu informacija o jednoj varijabli koja se odnosi na drugu varijablu.

Izbor ulaznih varijabli ima značajan uticaj na svojstvo generalizacije ML tehnika, zbog čega je prirodna potreba da se rezultati mrMR algoritma uporede sa drugim algoritmima za

selekciju ulaznih varijabli. Uzimajući u obzir prirodu ciljne varijable (diskretna) i prediktora (kontinualni), razmotren je još jedan algoritam, gde je važnost prediktora bila zasnovana na DT ansamblu (RF). RF klasifikator optimizuje se određivanjem broja DT-a (323), kao i njihove dubine (14). Pošto je metodologija ovog algoritma drugačija u odnosu na mrMR algoritam, značaj prediktora je na drugoj skali vrednosti. Iz tog razloga uvedena je relativna važnost prediktora prema formuli:

$$imp_i (\%) = \frac{imp_i}{max(imp)} \cdot 100\% \quad (2)$$

gde  $imp_i$  predstavlja  $i$ -ti prediktor ( $i = 1, 2, \dots, 5$ ). Na ovaj način moguće je uporediti značaj prediktora između različitih algoritama.

Nakon utvrđivanja najinformativnijih varijabli filtracijom ulaznih varijabli, primenjene su tri različite tradicionalne ML tehnike za proveru uticaja ovog izbora na tačnost predviđanja ocena studenata. U tom smislu, korišćen je DT gde je maksimalni broj podela bio 20 i sa *Gini*-indeksom kao kriterijumom razdvajanja, SVM sa Gausovim jezgrom u verziji *One-Vs-One* i kNN sa 10 najbližih suseda i metrikom Euklidske udaljenosti. Za trening i validaciju korišćena je petostruka unakrsna validacija (eng. *Cross-validation*). Navedenim postupkom simulirana je validacija ovih tehnika, uslovno rečeno, na pet neviđenih skupova podataka i tako je postignuta bolja generalizacija.

U cilju provere uticaja veličine uzorka na tačnost tradicionalnih ML tehnika, primenjen je popularni i dobro poznati *SMOTE* (*Synthetic Minority Oversampling Technique*) algoritam [386]. Primenom ovog algoritma generisani su sintetički podaci: svaki sintetički podatak generisan je na osnovu četiri originalna podatka, pri čemu nijedan originalni podatak nije mogao biti uzet u obzir više od dva puta. Originalni skup podataka time je proširen na 302 uzorka, a tačnost svih pomenutih tradicionalnih ML tehnika ponovo je proverena.

S obzirom na činjenicu da predviđanje ne može biti potpuno ako se ne uzme u razmatranje uticaj svih prediktora, korišćene su ANN, pošto u njihovom slučaju nisu postavljena ograničenja kao kod tradicionalnih ML tehnika. Shodno uzorku koji je srednje veličine, prirodan izbor bile su ANN zasnovane na Levenberg-Markuardt (eng. *Levenberg-Marquardt*) algoritmu. U opisanom kontekstu, pokazalo se da se bolji rezultati postižu ako se Bajesova regularizacija zasniva na ovom algoritmu [387].

Ukratko, suština ove metode je da minimizira ciljnu funkciju:

$$F = \alpha E_W + \beta E_D \quad (3)$$

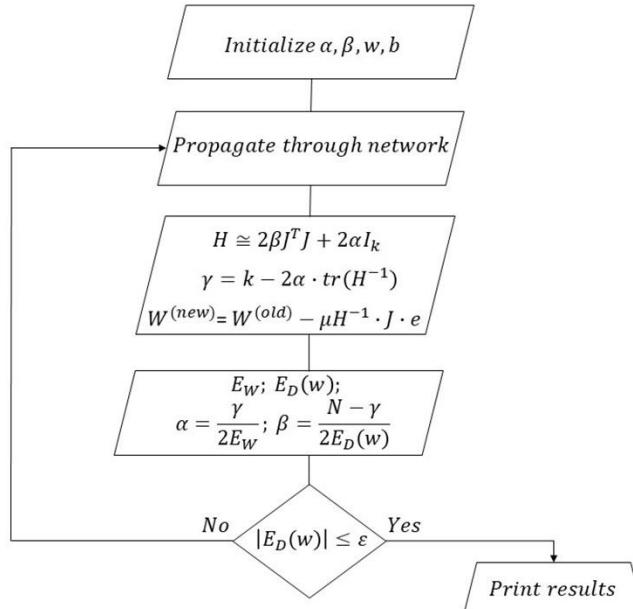
gde je  $E_W$  zbir kvadrata neuronskih težina po svim slojevima  $k$ :

$$E_W = \sum_{k=1}^l \sum_{i,j=1}^m (W_{ij}^{(k)})^{(2)} \quad (4)$$

a  $E_D$  predstavlja standardnu funkciju greske:

$$E_D = \frac{1}{2} \sum_{i=1}^l (y_i - t_i)^2 \quad (5)$$

Minimizacija funkcije zadate formulom (2) vrši se u okviru Bajesove teoreme, određivanjem vrednosti parametara  $\alpha$ ,  $\beta$  i  $\gamma$  u iterativnom postupku do postizanja konvergencije. Detaljan grafički prikaz Bajesovog regularizacionog algoritma zasnovanog na Levenberg-Markuardt algoritmu prezentovan je na Slici 6. Izraz  $J$  označava Jakobijan dobijen metodama iz Levenberg-Markuardt algoritma.



Slika 6. Algoritam Bajesove regularizovane neuronske mreže [313]

Na osnovu gore navedenog, dizajniran je ANN model koji se sastoji od ulaznog sloja, skrivenog sloja (10 neurona) i izlaznog sloja (1 neuron). Srednja kvadratna greška korišćena je kao kost funkcija i data je formulom (4), gde su  $y_i$  i  $t_i$  predviđene i poznate vrednosti ocena studenata i predstavljene su kao  $A = 6$ ,  $B = 5$ ,  $C = 4$ ,  $D = 3$ ,  $E = 2$  i  $F = 1$ . Ukupan broj uzoraka (studenata) bio je  $N = 121$ , dok su prediktori korišćeni kao ulazne varijable bili: *total\_durationseconds*, *interaction\_num*, *topics\_covered*, *pcrs\_dist\_success* i *elo\_rating*, što znači da je matrica ulaznih podataka  $X$  bila  $121 \times 5$ . Podaci su za potrebe ovog procesa podeljeni tako da je 75% bilo za trening, a 25% za testiranje. Kao prenosne funkcije korišćene su redom *tansig* i *logsig*. U svakoj epohi treninga, podaci za trening i testiranje mešaju se kako bi se postigla bolja generalizacija. Numeričke simulacije ANN-a izvedene su u programskom jeziku *MATLAB* (*Mathworks*, verzija 2023b).

## 4. Rezultati

U nastavku su predstavljeni rezultati disertacije [313], odnosno rezultati sprovedenog istraživanja opisanog u prethodnom poglavlju. Ovo poglavlje predstaviće rezultate deskriptivne statistike, identifikaciju optimalnih ulaznih varijabli, ishode testiranja tradicionalnih ML tehnika za predikciju uspeha studenata, efekat povećanja skupa podataka na tačnost predikcije i nalaze primene ANN-a za predikciju uspeha studenata.

### 4.1. Deskriptivna statistika

Deskriptivna statistika predstavlja bitnu stavku preprocesiranja podataka. Ona se sprovodi u svrhu dobijanja šire slike o strukturi podataka, koja pomaže u razumevanju samih karakteristika podataka. Rezultati deskriptivne statistike varijabli prikazani su u Tabeli 14 - srednje vrednosti svih varijabli, zajedno sa standardnim devijacijama.

Tabela 14. Deskriptivna statistika varijabli [313]

Ime varijable	Srednja vrednost ± standardna devijacija	Srednja vrednost/standardna devijacija
<i>total_durationseconds</i> (s)	$43197,55 \pm 36465,06$	1,18
<i>interaction_num</i>	$663,64 \pm 450,07$	1,47
<i>elo_rating</i>	$1466,98 \pm 100,27$	14,63
<i>topics_covered</i>	$10,32 \pm 5,44$	1,90
<i>pcrs_dist_success</i>	$27,47 \pm 17,53$	1,60
ocene	$3,88 \pm 1,75$	2,21

Kao što se može videti u Tabeli 14, postoji velika varijabilnost varijabli na osnovu vrednosti standardnih devijacija. U skladu sa tim je i odnos srednje vrednosti i standardne devijacije, takođe prikazan u ovoj Tabeli. Izuzetak je vrednost za varijablu *elo\_rating*. Veća varijabilnost znači veću verovatnoću da se deo standardne devijacije određene varijable može objasniti varijabilnošću drugih varijabli, što bi ukazivalo na problem multikolinearnosti. Heterogenost i veličina grupe studenata mogu biti uzroci značajnije varijabilnosti.

## 4.2. Identifikacija optimalnih ulaznih varijabli

Još jedan važan element preprocesiranja podataka je identifikacija optimalnih ulaznih varijabli. Primenom mrMR algoritma, kojim se identifikuju najinformativnije varijable, dobijeni su sledeći rezultati: *elo\_rating* (0,8759), *pcrs\_dist\_success* (0,648), *topics\_covered* (0,5925), *total\_durationseconds* (0,5917) i *interaction\_num* (0,4555). Rezultati dobijeni nakon primene mrMR algoritma podrazumevaju sortiranje ulaznih varijabli prema vrednostima njihove važnosti i mogu se videti na Grafikonu 5.



Grafikon 5. Važnost ulaznih varijabli na osnovu mrMR kriterijuma, prilagođeno prema [313]

U tom smislu, najinformativnije varijable su: *elo\_rating*, *pcrs\_dist\_success*, *topics\_covered* i *total\_durationseconds*. Ove varijable su dovoljne za predviđanje [384], pošto postoji oštar pad između vrednosti varijabli *total\_durationseconds* i *interaction\_num*, a važnost varijable *interaction\_num* je  $< 0,5$ .

Kako bi se izvršila verifikacija rezultata mrMR algoritma, odabran je još jedan popularan algoritam za selekciju ulaznih varijabli. U pitanju je RF klasifikacioni algoritam koji je potom primenjen na ulaznim varijablama radi dobijanja optimalnog skupa prediktora. Rezultati mrMR algoritma i RF klasifikacionog algoritma su potom upoređeni u smislu relativne važnosti (%), a podaci su sumirani i prikazani u Tabeli 15.

Tabela 15. Relativna važnost prediktora sa mrMR i RF klasifikacionim algoritmom [313]

Ime varijable	mrMR algoritam	RF klasifikacioni algoritam
<i>total_durationseconds</i>	67,55%	23,68%
<i>interaction_num</i>	52%	57,86%
<i>topics_covered</i>	67,64%	71,6%
<i>pcrs_dist_success</i>	73,98%	80,65%
<i>elo_rating</i>	100%	100%

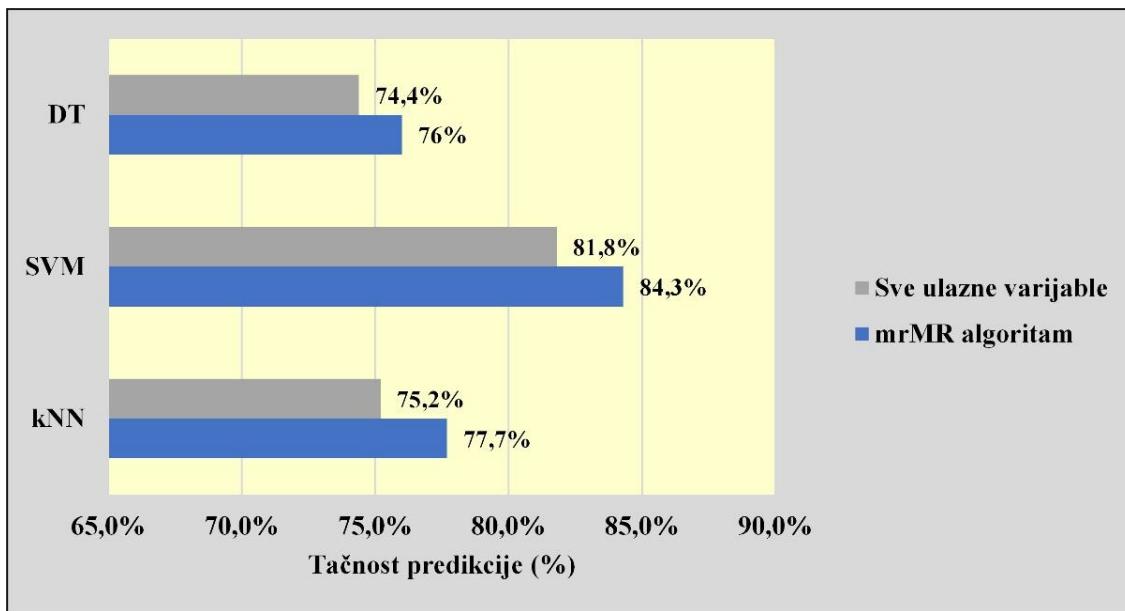
Pregled ove Tabele pokazuje da postoji isti trend između prediktora i kada se primjenjuje RF klasifikacioni algoritam. Takođe, može se primetiti da postoji neslaganje u pogledu varijabli *total\_durationseconds* i *interaction\_num*. Primenom iste metodologije za isključenje varijabli, kao u slučaju mrMR algoritma, može se videti da postoji nagli pad vrednosti između varijabli *interaction\_num* i *total\_durationseconds* u RF klasifikacionom algoritmu. Pošto je vrednost varijable *total\_durationseconds* minimalna, ta varijabla je uklonjena, što znači da su najinformativnije varijable po RF klasifikacionom algoritmu: *elo\_rating*, *pcrs\_dist\_success*, *topics\_covered* i *interaction\_num*.

#### 4.3. Primena tradicionalnih ML tehnika za predikciju uspeha studenata

Rezultati dobijeni pomoću mrMR algoritma provereni su predviđanjem ocena studenata sa tri različite tradicionalne ML tehnike: DT, SVM i kNN.

Predviđanje pomenutim tehnikama izvršeno je tako što su prvo uzete u obzir sve ulazne varijable, a zatim samo odabrane varijable pomoću mrMR kriterijuma. Korelacije prediktora sa cilnjom varijablom bile su relativno visoke ( $\geq 0,68$ ), što je razlog zbog kojeg se mrMR algoritam nametnuo kao prirodan i logičan izbor.

Rezultati ostvarenih tačnosti primenom tradicionalnih ML tehnika sa svim ulaznim varijablama su sledeći: DT 74,4%, SVM 81,8% i kNN 75,2%. Rezultati dobijeni sa selektovanim varijablama pomoću mrMR algoritma su: DT 76%, SVM 84,3% i kNN 77,7%. Radi bolje prezentacije i lakšeg upoređivanja postignutih tačnosti tradicionalnih ML tehnika u oba slučaja, rezultati su prikazani na Grafikonu 6.

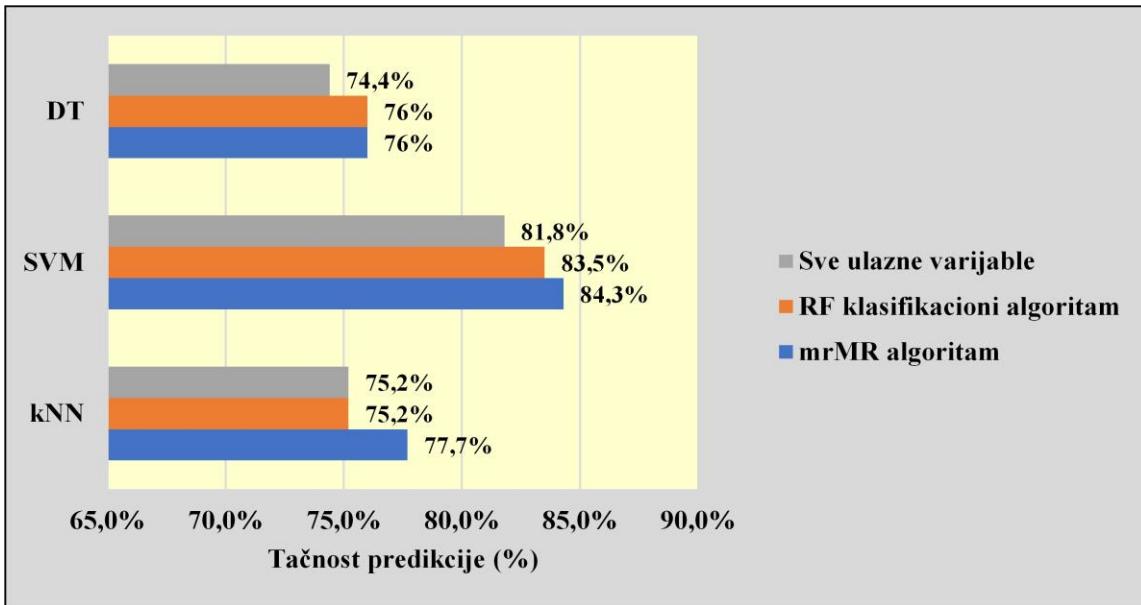


Grafikon 6. Rezultati tačnosti tradicionalnih ML tehnika 1

S obzirom da je utvrđeno da postoji neslaganje između mrMR i RF klasifikacionog algoritma u pogledu važnosti varijabli *total\_durationseconds* i *interaction\_num*, jedini način da se ovo proveri jeste izračunavanje tačnosti tradicionalnih ML tehnika sa skupom varijabli u dva slučaja:

- Prvi slučaj - prediktori *total\_durationseconds*, *topics\_covered*, *pcrs\_dist\_success* i *elo\_rating* za mrMR algoritam,
- Drugi slučaj - prediktori *interaction\_num*, *topics\_covered*, *pcrs\_dist\_success* i *elo\_rating* za RF klasifikacioni algoritam.

Imajući u vidu da su tačnosti tradicionalnih ML tehnika za prvi slučaj već izračunate, gde su rezultati bili: DT 76%, SVM 84,3% i kNN 77,7%, ostalo je još da se izračunaju tačnosti za drugi slučaj. Shodno tome, izvršeno je ponovno testiranje pomenutih tradicionalnih ML tehnika ovog puta sa skupom prediktora određenih RF klasifikacionim algoritmom i postignuti su sledeći rezultati: DT 76%, SVM 83,5% i kNN 75,2%. Ovi rezultati prikazani su na Grafikonu 7, zajedno sa rezultatima tačnosti dobijenih sa svim ulaznim varijablama i rezultatima postignutih tačnosti sa odabranim ulaznim varijablama primenom mrMR algoritma.



Grafikon 7. Rezultati tačnosti tradicionalnih ML tehnika 2, prilagođeno prema [313]

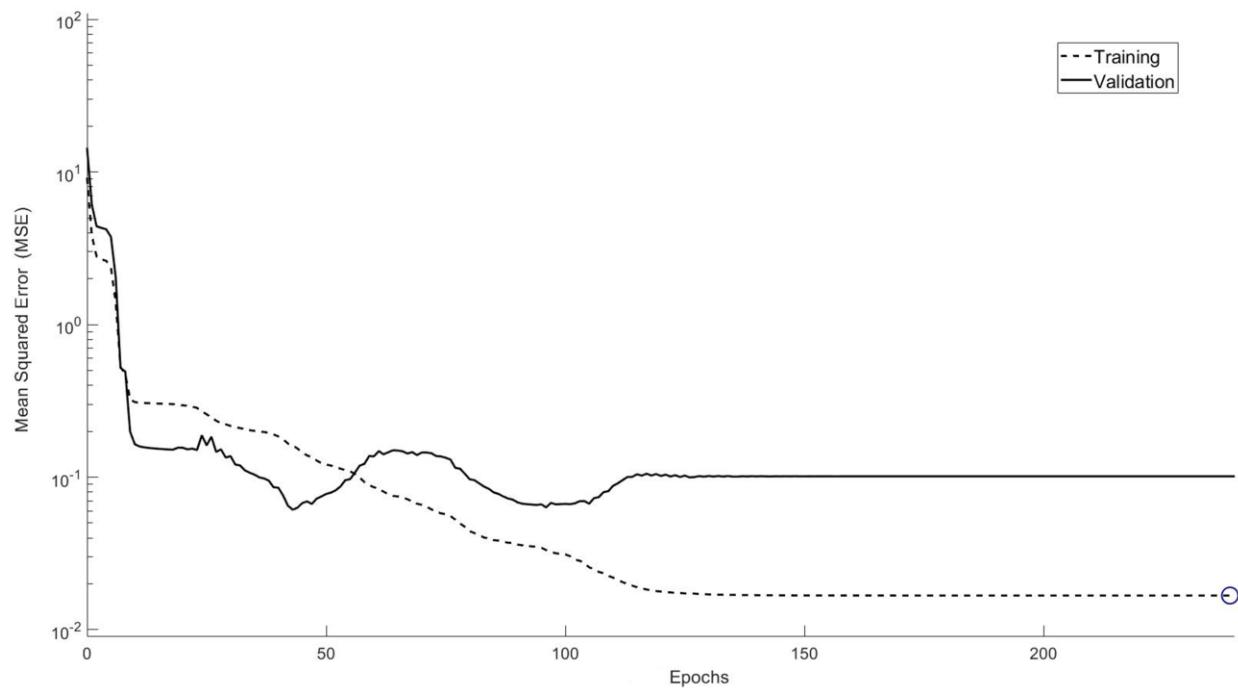
Kao što prikazuje ilustracija, primenom mrMR algoritma postignute su veće tačnosti, što odražava činjenicu da je primena algoritama i metoda za selekciju ulaznih varijabli tehnika preprocesiranja koja u velikoj meri zavisi od strukture podataka. U ovom slučaju, visoke korelacije između prediktora i ciljne varijable imale su odlučujući uticaj na odabir tehnike preprocesiranja.

#### 4.4. Povećanje skupa podataka upotrebom *SMOTE* algoritma

Poznato je da ne rade sve tradicionalne ML tehnike dobro sa manjim uzorcima i da upravo to može biti uzrok nezadovoljavajućih rezultata predikcije. U cilju provere uticaja veličine uzorka na tačnosti tradicionalnih ML tehnika, primenom *SMOTE* algoritma originalni skup podataka proširen je na 302 uzorka. Nakon toga, tradicionalne ML tehnike (DT, SVM i kNN) ponovo su testirane na skupu podataka dopunjeno sintetičkim podacima. Tačnosti primenjenih tehnika za predikciju u tom slučaju su znatno niže i iznose DT 54,5%, SVM 55,4% i kNN 58,4% kada se sve ulazne varijable koriste kao prediktori. Tačnosti se ne menjaju mnogo čak ni kada se uzmu u obzir samo odabrane varijable iz proširenog skupa pomoću mrMR algoritma: DT 52,8%, SVM 58,1% i kNN 60,1%.

#### 4.5. Primena ANN-a za predikciju uspeha studenata

Istraživanje disertacije takođe je obuhvatalo i predviđanje uspeha studenata korišćenjem ANN-a. Nakon formiranja ANN-a i pokretanja algoritma (Levenberg-Markuardt algoritam sa Bajesovom regularizacijom), postignuta je tačnost od 96,69% korišćenjem svih ulaznih varijabli, što znači da su ANN uspešno pogodile 117 od 121 ocene studenata u datom uzorku. Ostvarena tačnost ANN-a sa odabranim varijablama pomoću mrMR algoritma bila je nešto manja i iznosila je 95,87%. Slika 7 pokazuje evoluciju srednje kvadratne greške tokom vremena.



Slika 7. Evolucija srednje kvadratne greške tokom epoha [313]

Na Slici 7 može se videti da je globalni minimum dostignut posle 240 epoha. Treba napomenuti da se izlazna varijabla ANN-a takođe pojavljuje u obliku decimalnog broja. To je rešeno jednostavnim zaokruživanjem na najbliži ceo broj. Poznato je i opisano u širokoj literaturi da se prilikom klasifikacionih zadataka *softmax* sloj i *cross-entropy* koriste kao kost funkcija [388]. S druge strane, donekle otežava proceduru predviđanja ocena studenata, ali u ovom slučaju za tim nije bilo potrebe, jer standardna i mnogo jednostavnija kost funkcija srednje kvadratne greške postiže visoku tačnost.

Na osnovu rezultata ostvarenih pomoću ANN-a dobijena je sledeća formula za predviđanje ocena studenata:

$$\text{Predicted value} = \text{logsig}(W_2 \cdot \tanh(W_1 \cdot X + b_1) + b_2) \quad (6)$$

gde je:  $X(5 \times 1)$  matrica ulaznih podataka (*total\_durationseconds*, *interaction\_num*, *elo\_rating*, *topics\_covered* i *pcrs\_dist\_success*),  $W_1(10 \times 5)$ ,  $W_2(1 \times 10)$  matrice neuronskih težina dobijene iz simulacija ANN-a i konačno  $b_1(10 \times 1)$ ,  $b_2(1 \times 1)$  matrice odgovarajućih bajasa takođe dobijene iz simulacija ANN-a.

## 5. Diskusija

U ovom poglavlju detaljnije će se sagledati, analizirati i diskutovati rezultati disertacije [313]. Prvo će se podrobnije razmatrati odabir najinformativnijih varijabli, odnosno utvrđivanje činilaca koji najviše utiču na uspeh studenata. Nakon toga sledi opširnija diskusija o ostvarenim rezultatima predikcije uspeha studenata primenom tradicionalnih ML tehnika i ANN-a, kao i uticaj selekcije ulaznih varijabli na tačnost predviđanja ovih tehnika. U nastavku je razmatrana važnost i uloga pretprocesiranja podataka za potrebe predikcije. Takođe, demonstrirana je vizuelizacija koja pruža uvid u osnovne faktore vezane za interakciju studenata sa sistemom za e-učenje koji utiču na uspeh studenata. Na kraju, na osnovu rezultata disertacije, predstavljene su implikacije za dizajn metodologije za predikciju uspeha studenata u sistemima za e-učenje, koje su poslužile za konstruisanje samog predloga metodologije.

### 5.1. Najinformativnije varijable

Jedan od ciljeva disertacije bio je utvrđivanje činilaca koji najviše utiču na uspeh studenata, što je podrazumevalo upotrebu određene metode za odabir ulaznih varijabli. Kako bi se izvršila identifikacija optimalnih ulaznih varijabli korišćena je metoda filtracije zasnovana na mrMR kriterijumu [313]. Izabrana metoda zasnovana je na korelacijama i drugim alatima za statističku analizu i pripada podgrupi IVS-a [389].

Koreaciona analiza podataka na osnovu mrMR kriterijuma pokazala je da su najinformativnije varijable: *elo\_rating*, *pcrs\_dist\_success*, *topics\_covered* i *total\_durationseconds*. Ove četiri varijable pokazale su se kao dovoljne za predviđanje kada se koriste tradicionalne ML tehnike, što je distinkcija u odnosu na ANN, jer u njihovom slučaju nisu postavljena ograničenja kada su u pitanju ulazne varijable. Varijabla *elo\_rating* ima najveću vrednost važnosti od 0,8759, što znači da je ukupan rejting studenata na onlajn platformi veoma važan za predviđanje njihovih ocena. S obzirom na to da *elo\_rating* predstavlja rejting studenata na osnovu njihove sposobnosti da reše probleme definisane vežbama kodiranja, jasno je zašto je ovo najvažnija varijabla. Sledeća varijabla po važnosti je *pcrs\_dist\_success*, sa vrednošću važnosti od 0,648. Ovo ukazuje da je broj različitih vežbi kodiranja koje su studenti uspešno položili takođe veoma važan parametar za predviđanje ocena. Varijable *topics\_covered* i *total\_durationseconds*

imaju slične vrednosti važnosti od 0,5925 i 0,5917. Kada je reč o varijabli *topics\_covered*, ona pokazuje značaj broja lekcija koje studenti uspešno prolaze tokom kursa. Varijabla *total\_durationseconds* pokazuje da se vreme provedeno na onlajn platformi takođe može koristiti kao dobar prediktor. Važnost varijable *interaction\_num* bila je  $< 0,5$ , što znači da se ukupan broj značajnih radnji koje studenti naprave u sistemu za e-učenje ne smatraju dobim prediktorom na osnovu ovog kriterijuma.

Rezultati mrMR algoritma takođe su bili verifikovani primenom drugog algoritma za odabir ulaznih varijabli (RF klasifikacioni algoritam), koji je pokazao da im se rezultati poklapaju za tri od četiri varijable prema kriterijumu njihove važnosti. Te varijable bile su *elo\_rating*, *pcrs\_dist\_success* i *topics\_covered*, dok je postojalo neslaganje vezano za varijable *total\_durationseconds* i *interaction\_num*. To neslaganje kasnije je rešeno izračunavanjem tačnosti tradicionalnih ML tehnika, gde se pokazalo da je mrMR algoritam izabrao bolji skup ulaznih varijabli. Upravo ovaj ishod jeste dokaz da su visoke korelacije između prediktora i ciljne varijable imale odlučujući uticaj na izbor tehnike preprocesiranja, odnosno da je bilo logično koristiti mrMR algoritam za ovaj zadatok.

## 5.2. Predikcija uspeha primenom tradicionalnih ML tehnika i ANN-a

Istraživanje disertacije podrazumevalo je primenu i evaluaciju različitih tehnika veštačke inteligencije za potrebe predikcije uspeha studenata u sistemima za e-učenje. Ovo je rađeno sa ciljem razvoja modela za predviđanje uspeha studenata, kao i identifikovanja najefikasnije i najučinkovitije tehnike veštačke inteligencije u ovoj oblasti.

Tradicionalne ML tehnike pokazale su da se veća tačnost može postići kada se mrMR algoritam primenjuje za selekciju ulaznih varijabli nego kada se ne koristi [313]. Sve tri tradicionalne ML tehnike pokazale su se bolje korišćenjem ulaznih varijabli koje su određene ovim kriterijumom (DT 76%, SVM 84,3%, i kNN 77,7%). Rezultati dobijeni sa svim ulaznim varijablama bili su nešto lošiji (DT 74,4%, SVM 81,8%, i kNN 75,2%). U slučajevima SVM-a i kNN-a ostvareno je poboljšanje od 2,5%, dok je kod DT-a poboljšanje bilo 1,6%. Rezultati dobijeni tradicionalnim ML tehnikama pokazali su da se može postići solidna tačnost predviđanja. Najbolji rezultat među tradicionalnim ML tehnikama postignut je korišćenjem SVM-a sa Gausovim jezgrom, gde je tačnost bila 84,3%, sa odabranim varijablama prema mrMR kriterijumu.

Većina drugih istraživanja takođe ističu da upotreba metoda filtracije za selekciju ulaznih varijabli pozitivno utiču na povećanje tačnosti predviđanja kod tradicionalnih ML tehnika [28], [340], [352], [370].

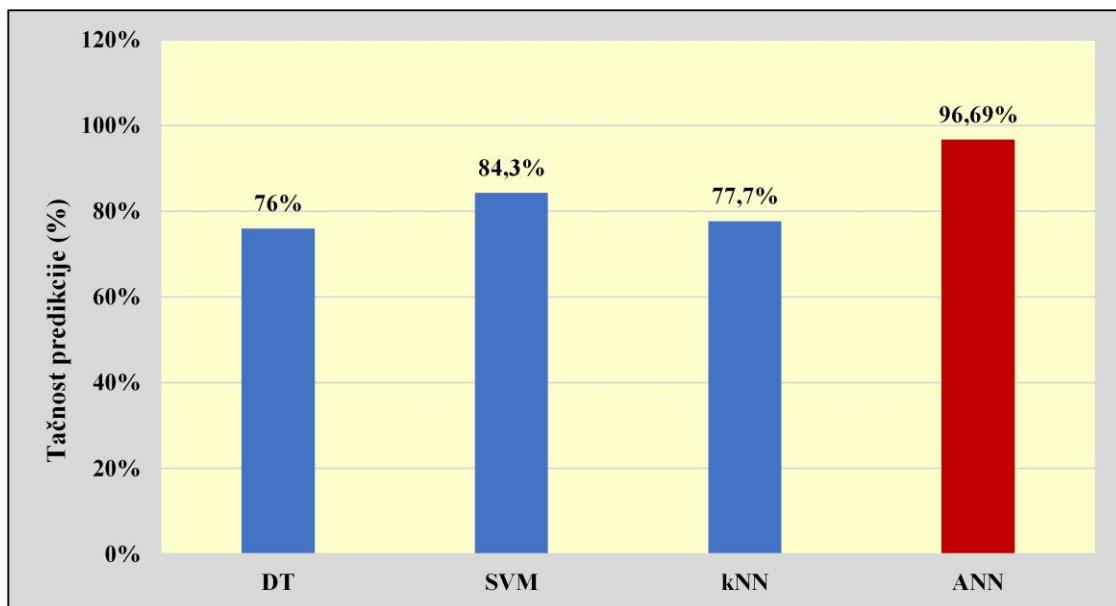
RF klasifikacioni algoritam, kao drugi algoritam za selekciju ulaznih varijabli, poslužio je za verifikaciju rezultata dobijenih mrMR algoritmom. Korišćenjem prediktora odabranih pomoću RF klasifikacionog algoritma ostvareni su već pomenuti rezultati tradicionalnih ML tehnika: DT 76%, SVM 83,5% i kNN 75,2%. Primenom ovog algoritma za selekciju ulaznih varijabli postignute su nešto veće tačnosti predviđanja kod dve od tri tradicionalne ML tehnike u poređenju sa onim ostvarenim sa svim ulaznim varijablama. Tačnije, ostvareno je poboljšanje od 1,6% kod DT tehnike i 1,7% kod SVM-a, dok kod kNN-a nije postignuto povećanje tačnosti. Međutim, kada se porede rezultati tačnosti ostvareni mrMR algoritmom i oni dobijeni primenom RF klasifikacionog algoritma, dolazi se do zaključka da je pravi izbor za selekciju ulaznih varijabli bio mrMR algoritam, pošto su za dve od tri tradicionalne ML tehnike dobijene veće tačnosti predviđanja i za jednu tehniku ista tačnost. Preciznije, mrMR algoritam doprineo je boljim ishodima tačnosti kod SVM-a i kNN-a, dok je za DT postignuta ista tačnost. Ovi rezultati upravo potvrđuju da je struktura podataka ta koja utiče na primenu algoritama i metoda za selekciju ulaznih varijabli kao tehnika pretprecesiranja. Ovde su konkretno glavni uticaj na izbor tehnike pretprecesiranja imale visoke korelacije između prediktora i ciljne varijable.

Rezultati su pokazali da povećanje veličine uzorka nije dovelo do povećanja tačnosti tradicionalnih ML tehnika. Dalje povećanje šuma (ili smanjenje korelacija) za red veličine u odnosu na izlaznu varijablu drastično je smanjila tačnost. Slični rezultati dobijeni su u radu [384], gde su autori menjali veličinu uzorka generisanjem sintetičkih podataka. Tačnost binarne regresione analize i ANN-a merena je na sintetički generisanim uzorcima različitih veličina. Utvrđeno je da veličina uzorka nema značajan uticaj na tačnost navedenih tehnika. Ipak, veći skup ulaznih podataka znači bolju pokrivenost parametarskog prostora. Međutim, time nije determinisano da će tehnike veštačke inteligencije imati bolje rezultate. Na primer, primenom evolucionog algoritma za predviđanje na samo 35 studenata, napravljen je matematički model za predviđanje akademskog uspeha studenata u onlajn obrazovanju [344]. Osim toga, istraživači su pokazali da je najveći skok u tačnosti ML tehnika za veličine uzoraka 100 - 200 [390]. Na ovaj način, izgradnjom modela distribucije vrsta, istraživači su pokazali da se maksimalna tačnost različitih ML tehnika postiže sa veličinama uzoraka od 50 i 100 [391]. Poput ovih, postoje i mnogi

drugi primeri koji ukazuju na to da upravo druga svojstva ulaznih podataka (korelacije, kvalitet, balansirani skup podataka itd.) imaju isti ili čak veći uticaj u odnosu na veličinu uzorka. Veličina uzorka određena je uglavnom na osnovu prethodnih studija, a ovom problemu posvećuje se posebna pažnja u okviru tradicionalne statističke analize. Kada je u pitanju ML, ne postoji veliki izbor studija posvećenih ovom problemu. Ipak, studija [392] ispitivala je uticaj veličine uzorka na tačnost SVM-a i logističke regresione analize. Pokazalo se da manje veličine uzorka ( $< 100$ ) dovode do veće tačnosti ( $> 95\%$ ), dok skupovi podataka (100 - 1000) dovode do značajno manje tačnosti (60% - 70%). Ovaj rezultat je u saglasnosti sa rezultatima istraživanja ove disertacije. Slični rezultati dobijeni su i u radu [393], gde su autori pokazali da povećanje veličine uzorka preko određene granice ne povećava tačnost ML tehnika. Postoji još jedan zanimljiv rezultat gde su istraživači pokazali da postoji granica iznad koje veličina uzorka više ne utiče značajno na tačnost ML tehnika [394]. Vredi pomenuti i jednu izvanrednu studiju, koja se takođe može posmatrati kao pokušaj standardizacije veličine uzorka prema tačnosti ML tehnika [395]. U toj studiji pokazano je kroz numeričko eksperimentisanje na skupu podataka o aritmiji da su sa veličinama uzorka  $< 120$ , oscilacije tačnosti ML tehnika značajno veće u poređenju sa veličinama uzorka  $> 120$ . Ova granica veličine uzorka je veoma blizu veličini uzorka korišćenom u ovoj disertaciji (121). U isto vreme, velike i prosečne *Cohen's d* vrednosti [396] bile su oko 0,8. Dalje povećanje veličine uzorka ( $> 120$ ) nije imalo veći uticaj na primenjene ML tehnike. Takođe, u [395], manipulisanjem kvalitetom podataka (potpunost, doslednost, tačnost itd.) autori su pokazali da povećanje kvaliteta podataka izaziva značajno povećanje tačnosti ML tehnika.

Rezultati disertacije pokazuju da se primenom ANN-a postiže veća tačnost [313]. Najbolji rezultati u predviđanju ocena studenata dobijeni su korišćenjem Levenberg-Markuardt algoritma sa Bajesovom regularizacijom (96,69% sa svim ulaznim varijablama i 95,87% sa odabranim varijablama). Primena mrMR algoritma u slučaju ANN-a doprinela je nešto lošijem rezultatu tačnosti predviđanja nego u slučaju korišćenja svih ulaznih varijabli. Tačnost je smanjena za 0,82% korišćenjem mrMR kriterijuma. Ovo potvrđuje da se u slučaju ANN-a ne postavljuju ograničenja u pogledu ulaznih parametara, kao kod tradicionalnih ML tehnika, i da se kod ANN-a može postići veća tačnost ako se uključi uticaj svih prediktora. Većina istraživača takođe je prijavila bolje rezultate tačnosti ANN-a kada su svi prediktori korišćeni za predviđanje [19], [337], [338], [351], [355].

Grafikon 8 prikazuje najbolje rezultate tačnosti koji su ostvareni primenom tradicionalnih ML tehnika i ANN-a. To su rezultati DT-a, SVM-a i kNN-a sa odabranim varijablama, kao i ANN-a sa svim ulaznim varijablama.



Grafikon 8. Rezultati tačnosti primenom tradicionalnih ML tehnika i ANN-a, prilagođeno prema [313]

Iako su tradicionalne ML tehnike postigle solidne tačnosti predviđanja ocena studenata, njihove tačnosti znatno su niže od rezultata ANN-a (Levenberg-Markardt algoritam sa Bajesovom regularizacijom) - sa tačnošću od 96,69%. Ova tehnika veštačke inteligencije pokazala se kao najefikasnija i najučinkovitija za potrebe predikcije uspeha studenata u sistemima za e-učenje u okviru istraživanja disertacije. ANN su uspele da nadmaše tradicionalne ML tehnike i pokazale se kao robustne i superiorne ne samo u pogledu postignute tačnosti već i u pogledu ograničavanja broja ulaznih varijabli za proces predikcije. Slične rezultate dobili su i drugi istraživači gde su ANN ostvarile bolje ishode predviđanja od tradicionalnih ML tehnika [21], [335], [336], [348], [350]. Njihovi rezultati potvrđuju nalaze prikazane u ovoj disertaciji a to je da su ANN robustnije u poređenju sa tradicionalnim ML tehnikama kada je u pitanju predviđanje uspeha studenata u okruženjima za e-učenje. Stav da ANN uvek postižu veću tačnost u predviđanju od tradicionalnih ML tehnika ne može da se generalizuje, jer su u nekoliko slučajeva one postigle bolje rezultate od ANN-a [22], [23] ili su imale jednaku prosečnu tačnost [349].

### **5.3. Važnost preprocesiranja podataka za potrebe predikcije**

Jedan od važnih segmenata, a ujedno i ciljeva disertacije, bilo je ukazivanje na važnost preprocesiranja podataka za potrebe predikcije.

Sve činjenice iznete u dosadašnjoj diskusiji ukazuju na to da bi korelacije između prediktora i ciljne varijable mogле biti važni faktori u tačnosti primenjenih tehnika predikcije [313]. To znači da je selekcija ulaznih varijabli skoro jednako važna kao i njihova analiza. U ovoj disertaciji, variranje veličine uzorka nije značajno uticalo na krajnje rezultate, ali smanjenje korelacija između ulaznih i izlaznih varijabli jeste. Uviđa se poseban značaj ovoga s obzirom na važnost procene veličine uzorka u statističkoj analizi. Međutim, odnos između metoda IVS-a i veličine uzorka ostaje otvoreno pitanje. U vezi sa ovim stavom, pojedini autori koristili su tehnike za smanjenje dimenzionalnosti ulaznog skupa podataka, kao što su analiza glavnih komponenti i analiza nezavisnih komponenti [397]. Ovaj pristup ima smisla u slučaju velikih uzoraka i smanjuje vreme potrebno za zadatke klasifikacije i regresije korišćenjem tehnika veštačke inteligencije. Nedostatak ovih tehnika jeste u tome što se ne vidi uticaj svake pojedinačne ulazne varijable, što je veoma važno u e-učenju. Postoje i druge metode za selekciju ulaznih varijabli, koje mogu da se klasifikuju u dve grupe: metode omotača i ugrađene metode, koje mogu da obrađuju sve veličine uzorka.

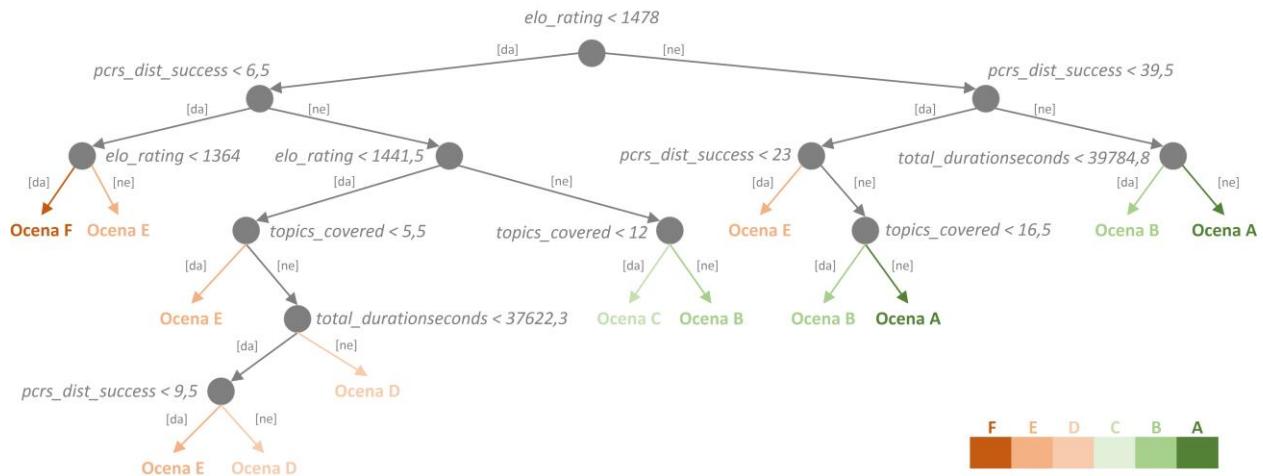
Pored rezultata prikazanih u ovoj disertaciji i drugi autori eksperimentisali su sa svojstvom kolinearnosti ulaznih varijabli, što odgovara kriterijumu minimalne redundancije. U studiji koju su sproveli *Akandea* i sar. [375] pokazalo se da uklanjanje korelacija čije su vrednosti  $< 0,35$  dovodi do povećanja tačnosti primenjenih ML tehnika. Ovi rezultati u skladu su sa nalazima ove disertacije. Pored toga, povećanje korelacija između ulaznih i izlaznih varijabli umanjuje ovaj efekat. U drugoj studiji, autori su teorijski pokazali da velike sopstvene vrednosti autokorelaceione matrice ulaznih podataka usporavaju trening linearog perceptronu [376]. Oni su pokazali da je optimalna vrednost konstante učenja, koja ubrzava obuku perceptronu, obrnuto proporcionalna maksimalnoj sopstvenoj vrednosti autokorelaceione matrice.

Sve što je do sada rečeno o problemu multikolinearnosti i korelacijama ulaznih varijabli razmatrano je u okviru metoda filtracije ili prethodne obrade ulaznih podataka. Većina istraživanja vezanih za podatke u oblasti e-učenja fokusira se na rezultate primene tehnika veštačke inteligencije u smislu regresije ili klasifikacije. Istraživanje sprovedeno u disertaciji pokazalo je

da se posebna pažnja mora posvetiti pretprocesiranju, odnosno izboru ulaznih varijabli. U tom smislu, važno je razgraničiti slučajeve kada je neophodno da se pristupi tome kako bi se tehnika veštačke inteligencije mogla primeniti onda kada se varijabla odbaci jer ne utiče dovoljno na ciljnu varijablu.

#### 5.4. Vizuelizacija uvida u faktore koji utiču na uspeh studenata

Slika 8 predstavlja DT grafik koji demonstrira vizuelizaciju koja pruža uvid u osnovne faktore vezane za interakciju studenata sa sistemom za e-učenje koji utiču na njihov uspeh [313], što je bio jedan od ciljeva disertacije.



Slika 8. DT grafik uvida u faktore koji utiču na uspeh studenata, prilagođeno prema [313]

Vizuelizacija ovakvih uvida izuzetno je bitna za poboljšanje interpretabilnosti rezultata [398], [399]. Na taj način mogu da se prikažu obrasci koji pomažu u objašnjenuju uvida u podatke i pružaju intuitivnija objašnjjenja nego tekst. Vizuelizacija može pomoći u pojednostavljinju složenih rezultata dobijenih tehnikama veštačke inteligencije, omogućavajući nastavnicima da bolje tumače te rezultate. Dakle, informacije predstavljene u vizuelnom kontekstu mogu pomoći nastavnicima da brže i lakše interpretiraju te informacije. Analizom grafika dobijenog DT tehnikom nastavnik može da stekne dragocene informacije iz ulaznog skupa varijabli. Putevi do čvorova lista koji predstavljaju ocene studenata, jasno demonstriraju nastavnicima faktore koji vode do viših i nižih ocena. Tako, na primer, za vrednosti  $1478 > \text{elo\_rating} \geq 1364$  i

$pcrs\_dist\_success < 6,5$ , nastavnici mogu očekivati da će student dobiti ocenu E. Slično, za vrednosti prediktora  $elo\_rating \geq 1478$ ,  $pcrs\_dist\_success \geq 39,5$  i  $total\_durationseconds \geq 39784,8$  može se očekivati maksimalna ocena A itd. Mnoge studije pokazale su da poznavanje elemenata koji utiču na ocene može pomoći nastavnicima da poboljšaju uspeh studenata [400], [401], [402].

Prema studijama, pravilna vizuelizacija za nastavnike, bez obzira na njihov nivo veština i kompetencija, omogućava im da lakše istraže ishode predviđanja i faktore koji do njih dovode i kao rezultat toga da ih efikasno iskoriste za poboljšanje kvaliteta nastave i učenja [403], [404], [405].

## 5.5. Implikacije za dizajn metodologije

Rezultati istraživanja prikazani u ovoj disertaciji imali su veliki uticaj na dizajn većeg dela predloga metodologije za predikciju uspeha studenata u sistemima za e-učenje, dok je opsežan i sistematičan pregled literature pomogao u ostalim segmentima koji nisu obuhvaćeni istraživanjem disertacije.

Istraživanje je ukazalo na važnost preprocesiranja podataka, koje bi trebalo da postane neizostavan deo procesa predikcije uspeha studenata, a što u većini analiziranih istraživanja nije aktuelizovano uopšte ili je u maloj meri tom segmentu posvećena pažnja. Pregled literature sugerisao je ono što su rezultati disertacije i potvrdili - pravilan odabir ulaznih varijabli može povećati tačnost modela za predikciju kod tradicionalnih ML tehnika, dok kod ANN-a postoji veća verovatnoća da se postignu bolji rezultati kada se koriste sve ulazne varijable. Takođe, ustanovljeno je da algoritam/tehniku za selekciju ulaznih varijabli treba pažljivo odabrati u skladu sa tematikom. Rezultati su pokazali da je mrMR algoritam adekvatan za problematiku e-učenja, pošto se varijable odnose na studenta, pa je prepostavka da korelacije imaju bitnu ulogu u strukturi podataka veoma opravdana. U svrhu osiguranja relevantnosti ishoda selekcije ulaznih varijabli, standardna praksa trebalo bi da uključuje verifikaciju rezultata korišćenjem dodatnog algoritma/tehnike, kao što je demonstrirano u disertaciji. Rezultati primene tehnika veštačke inteligencije za predikciju uspeha studenata, kako u literaturi, tako i u ovoj disertaciji govore u korist ANN-a u odnosu na tradicionalne ML tehnike. Levenberg-Markuardt algoritam sa Bajesovom regularizacijom istakao se visokim procentom tačnosti i pokazao se kao dobar izbor

za predikciju uspeha studenata u ovoj disertaciji. U prilog afirmativnom stanovištu prema algoritmu jeste i što se pokazao kao robustan i u drugim studijama [406], [407], stoga je razumno uvrstiti ga u metodologiju kao jednu od glavnih preporuka. Stav da ANN uvek postižu veću tačnost predikcije u odnosu na tradicionalne ML tehnike ne može se generalizovati, kao što je istaknuto u pregledu literature. Iz tog razloga neophodno je vršiti numerička eksperimentisanja i sa tradicionalnim ML tehnikama kako bi se predvideo uspeh studenata. Sličan slučaj je i sa statističkim tehnikama za predikciju, gde tehnike veštačke inteligencije obično postižu bolje rezultate u poređenju sa njima, kako literatura sugeriše [10]. Ipak, zbog nemogućnosti generalizacije ovakve tvrdnje, statističke tehnike takođe treba uzeti u obzir u metodologiji za predikciju uspeha studenata, iako istraživanje u okviru disertacije nije obuhvatilo njihovo testiranje. Na kraju može se konstatovati da će, kako bi se utvrdilo koji će pristup i tehnika postići najveću tačnost u određenom slučaju, biti neophodno proći ceo proces predikcije - od statističkih tehnika, preko tradicionalnih ML tehnika, pa sve do ANN-a.

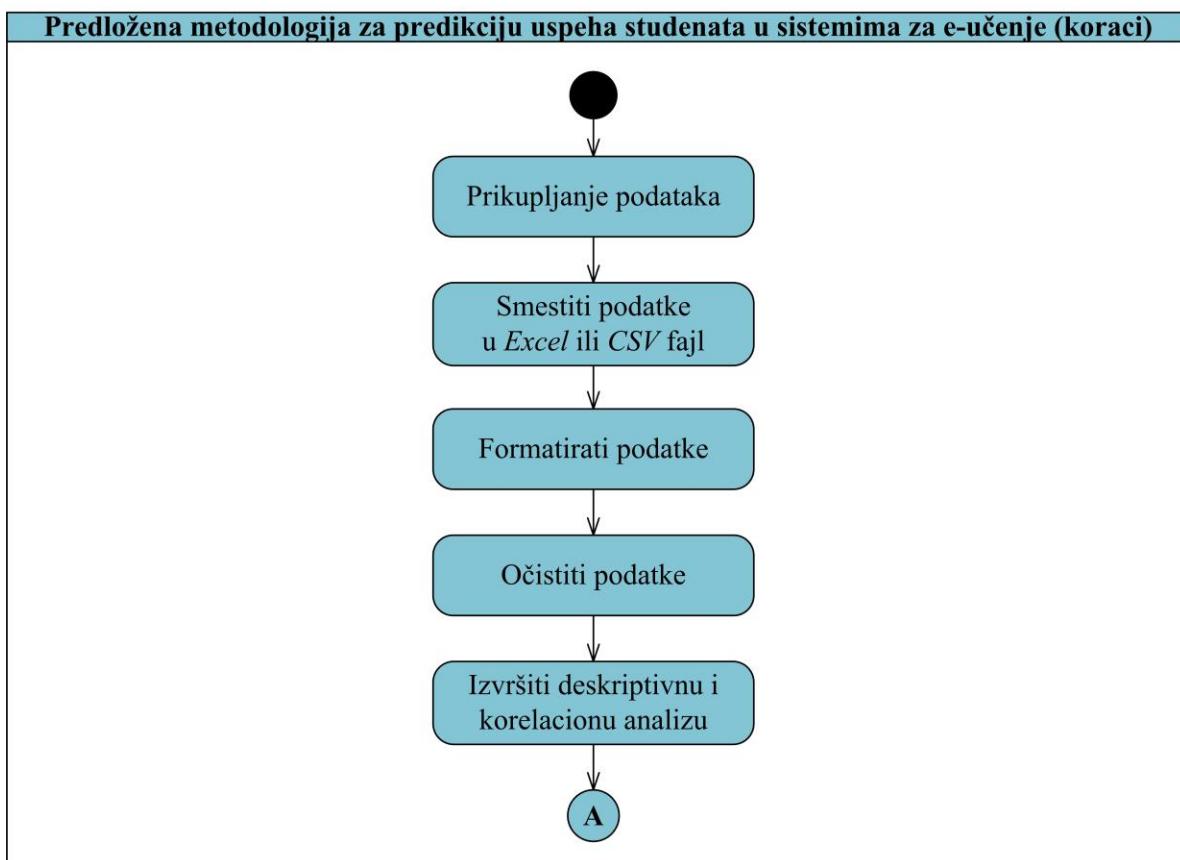
Sveukupnim razmatranjem navedenih činjenica konstruisan je predlog metodologije za predikciju uspeha studenata u sistemima za e-učenje koji je prikazan u sledećem poglavlju. Cilj predloga ove metodologije jeste unapređenje procesa predikcije uspeha studenata u sistemima za e-učenje i pružanje okvira za standardizaciju tog procesa. Njenom upotrebom istraživači će moći da na adekvatan način pristupe procesu predikcije uspeha i da razviju modele koji će potencijalno biti sposobni da postignu maksimalnu tačnost predviđanja.

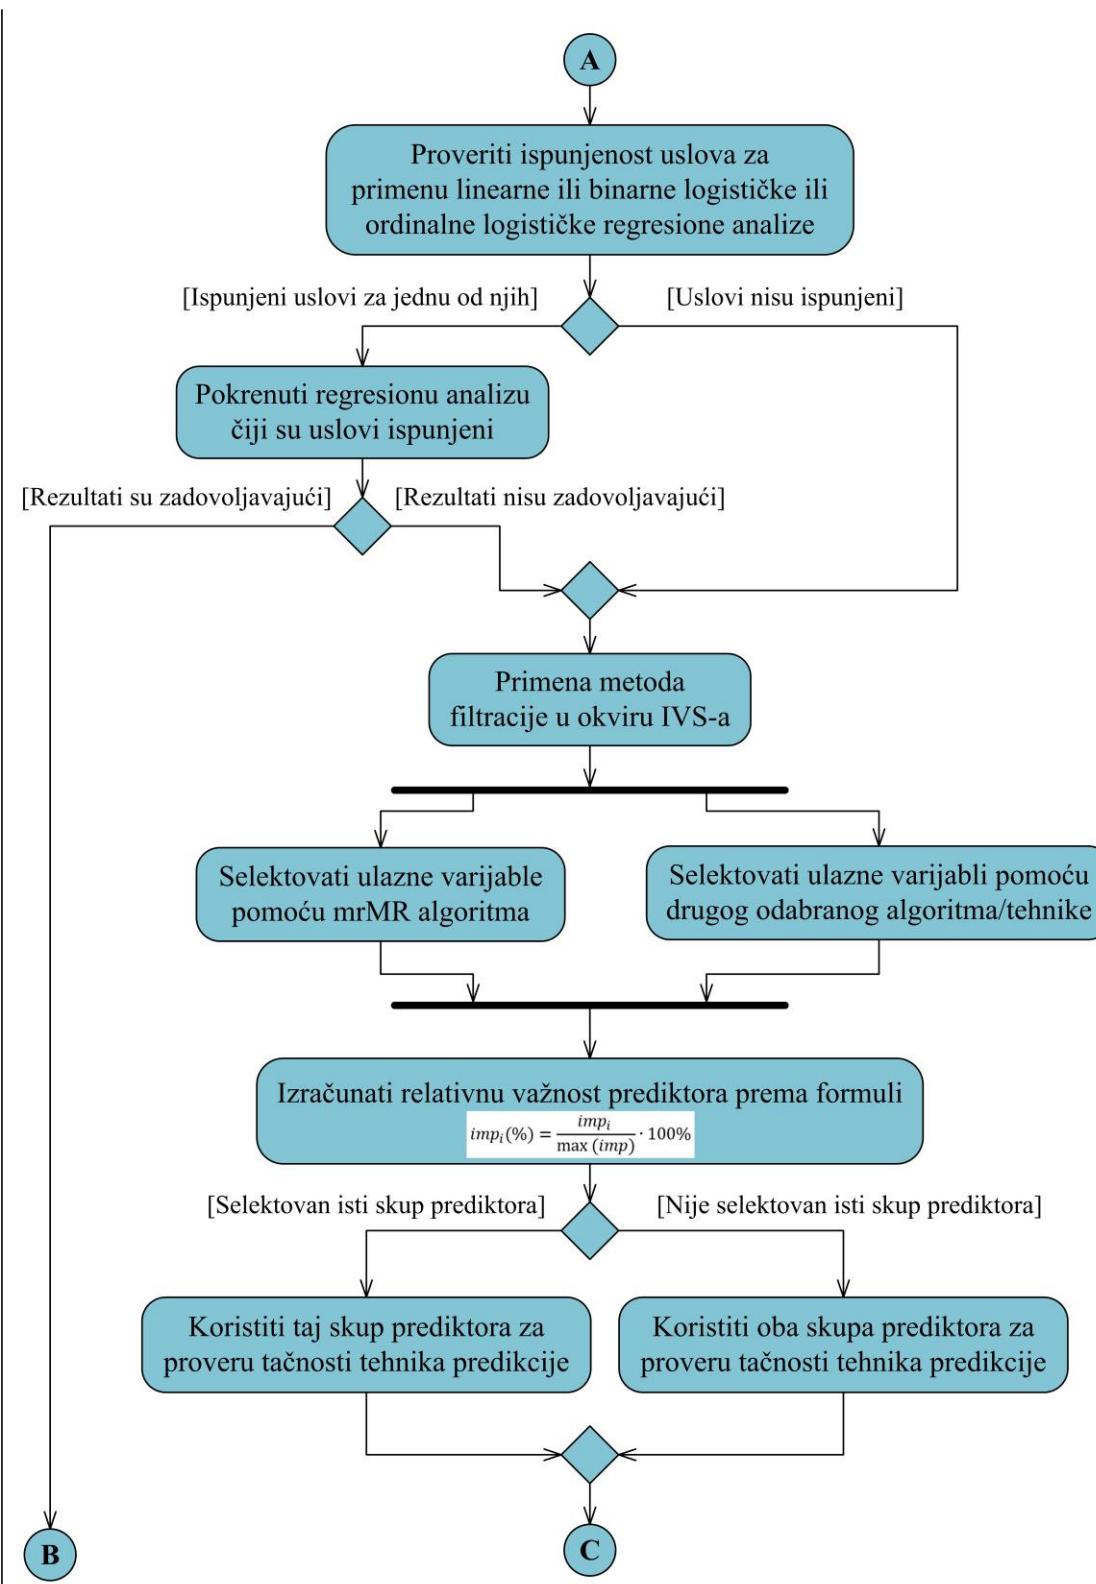
## 6. Predlog metodologije za predikciju uspeha studenata u sistemima za e-učenje

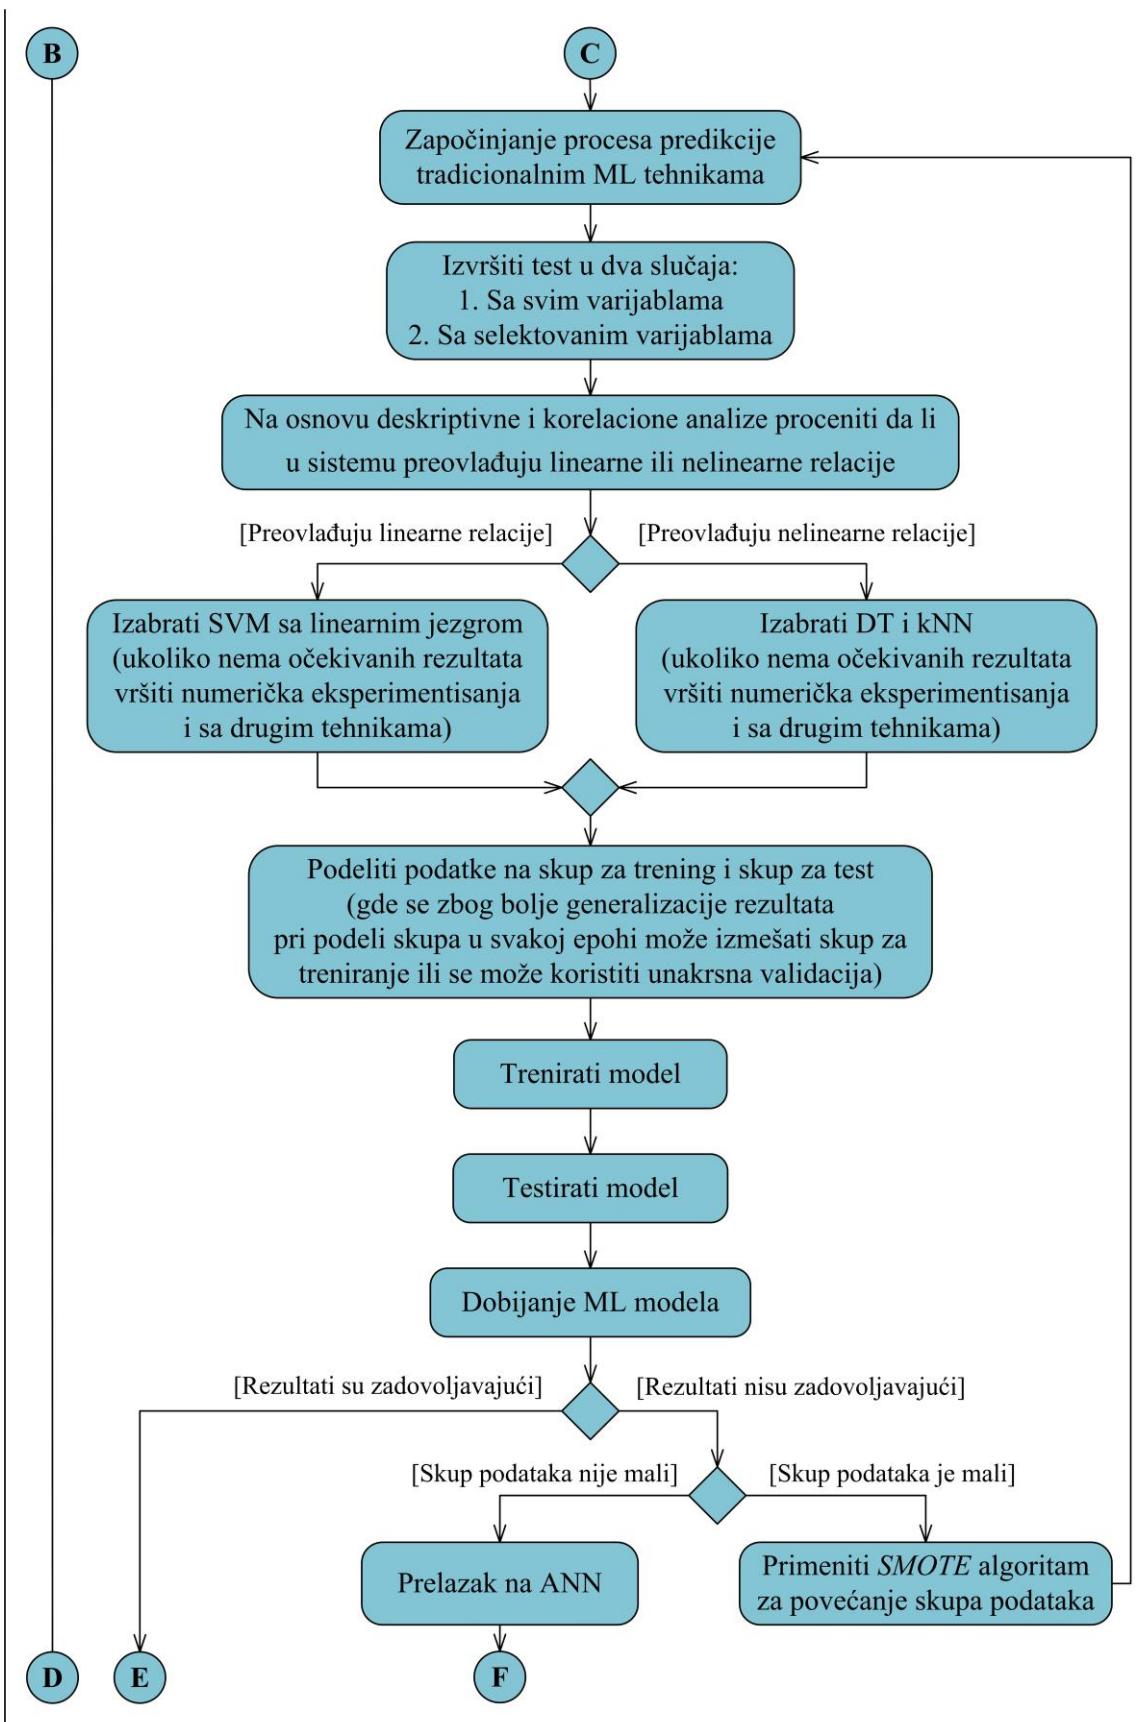
Na osnovu rezultata sprovedenog istraživanja, kao i iskustva i rezultata drugih istraživača, u ovom poglavlju predstavljen je predlog metodologije za predikciju uspeha studenata u sistemima za e-učenje, što je ujedno bio i osnovni cilj disertacije.

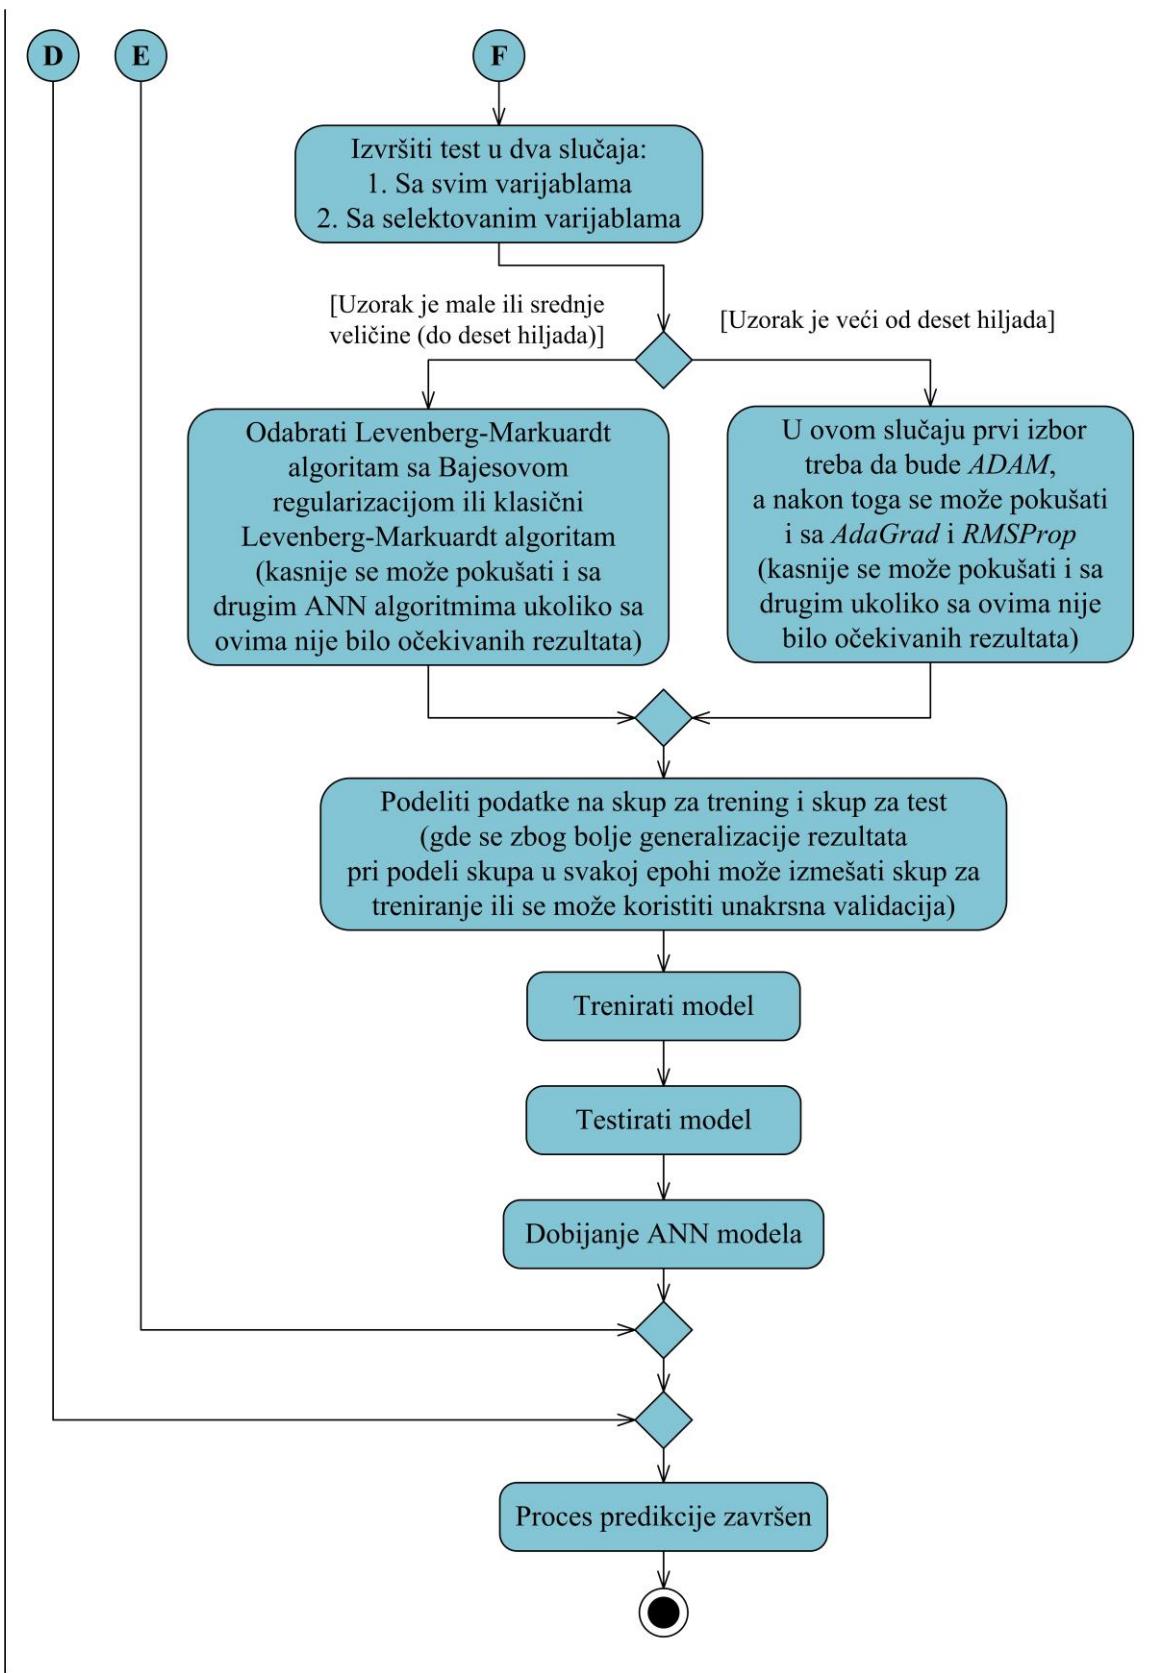
### 6.1. Dijagramska prikaz predložene metodologije

Predložena metodologija za predikciju uspeha studenata u sistemima za e-učenje prikazana je na sledećem *UML* dijagramu aktivnosti (Slika 9), koji pokazuje redosled koraka koje treba ispratiti kako bi bila primenjena. Sam dijagram predstavljen je na četiri stranice zbog veličine, a korišćeni su *UML* konektori (A, B, C itd.) kako bi se označila mesta završetka dijagrama na jednoj stranici i mesta početka na sledećoj stranici. Kako bi se ovaj dijagram lakše razumeo, u sekciji Prilozi u Tabeli 16 nalazi se objašnjenje osnovnih *UML* elemenata dijagrama aktivnosti.









Slika 9. Dijagramski prikaz predložene metodologije

## **6.2. Opis koraka predložene metodologije**

U ovom delu prikazan je detaljniji opis koraka predložene metodologije za predikciju uspeha studenata u sistemima za e-učenje. Za uspešnu predikciju potrebno je ispratiti sledeće korake: prikupljanje podataka, preprocesiranje podataka, predikciju statističkim tehnikama, predikciju tradicionalnim ML tehnikama, primenu *SMOTE* algoritma (u slučaju malog skupa podataka) i predikciju korišćenjem ANN-a.

### **1) Prikupljanje podataka**

Nakon završenog semestra, profesionalnog kursa ili izvršenog eksperimenta sa studentima prvi korak predstavlja prikupljanje podataka iz baze podataka sistema za e-učenje. Podatke je potrebno smestiti u *Excel* ili *CSV* fajl, koji su najpogodniji za učitavanje u druge alate u kojima će se kasnije raditi statističke analize i predviđanje uspeha studenata primenom različitih prediktivnih tehnika. Podaci koji se smeštaju u *Excel* ili *CSV* fajl predstavljaju strukturirane podatke u kojima kolone predstavljaju ulazne varijable. Na ovaj način dobiće se matematički model koji može da se eksportuje i kasnije koristi za predviđanje uspeha drugih grupa studenata.

### **2) Preprocesiranje podataka**

#### *2.1. Formatiranje podataka*

Podaci prikupljeni direktno iz sistema za e-učenje često su u neodgovarajućim formatima, pa je potrebno formatirati ih u adekvatan oblik pre bilo kakve dalje analize. Na primer, ukoliko je ciljna varijabla kategorična, može se uvesti nova varijabla (eng. *Dummy variable*) kojom se kvantitativno (brojno) opisuje vrednost ciljne varijable i pojednostavljuje proces izgradnje matematičkog modela predviđanja uspeha studenata.

Takođe postoje i podaci koje sistemi za e-učenje ne čuvaju, a veoma lako se mogu dobiti kombinacijom drugih varijabli, pa se tako mogu stvoriti dodatni prediktori. To podrazumeva korišćenje različitih aritmetičkih i agregatnih operatora nad postojećim varijablama kako bi se dobile potpuno nove (npr. ukupno vreme u sistemu / brojem logovanja = prosečno vreme po logovanju itd.) [408]. U ovakovom postupku odlučujuću ulogu imaju primenjene metode

preprocesiranja i tehnike za predikciju uspeha studenata, tako da na osnovu njih analitičar može odlučiti o uvođenju novih varijabli kao kombinacije prethodnih.

## 2.2. Čišćenje podataka

Rezultati predikcije uspeha studenata u sistemima za e-učenje, kao i u drugim oblastima, zavise od kvaliteta podataka, pa je pre bilo kakve njihove dalje analize potrebno da prođu i proces čišćenja [409]. *Excel* je program koji omogućava laku manipulaciju podacima, tako da se ceo proces može uraditi upravo u njemu. Na početku ovog procesa potrebno je identifikovati sve vrednosti koje su netačne, nepotpune ili van normalnih granica, kao i duplike, a nakon toga ih ukloniti. To se čini tako što se iz *Excel* tabele uklone vrste sa takvim podacima. Ovaj proces je od suštinskog značaja prilikom pripreme podataka za analizu. Očišćeni i sređeni podaci, pod uslovom da se proces čišćenja izvrši na adekvatan način, doprineće mnogo boljim i pouzdanim rezultatima [410].

Kod nepotpunih podataka postoji i mogućnost njihovog popunjavanja srednjim vrednostima ostalih podataka. Međutim, ovaj proces je delotvoran samo ako nije u pitanju veliki broj podataka koje treba zameniti. Što je veći broj nepotpunih podataka koji se dopunjaju na ovaj način to je veći negativni uticaj na tačnost predikcije, pa se iz tog razloga ovakav način popunjavanja nekompletnih podataka ne preporučuje [411].

## 2.3. Upoznavanje sa skupom podataka

Radi uspostavljanja šire percepcije povodom skupa podataka o interakcijama studenata sa sistemom za e-učenje, prvo je potrebno uraditi deskriptivnu statistiku - kako bi se opisao, odnosno, sumirao dati skup podataka. U cilju brzog i efikasnog načina izvršavanja ove početne analize podataka, potrebno je izabrati odgovarajući alat koji nudi napredne statističke analize, a koji je pritom fleksibilan i lak za korišćenje (*SPSS*, *Stata*, *Minitab*, *SAS* itd.). Deskriptivna statistika za opis skupa podataka koristi mere centralne tendencije kako bi se izračunali srednja vrednost, medijana i modus, kao i mere varijabilnosti da bi se dobili standardna devijacija, minimalna i maksimalna vrednost datih varijabli, kurtozis (eng. *Kurtosis*) i skjunis (eng. *Skewness*) [412]. Koja će od pomenutih mera centralne tendencije biti primenjena zavisi od prirode varijabli, odnosno da li su diskretne ili kontinualne.

Na ovaj način dobiće se šira slika o strukturi podataka i shodno tome pomoći će u razumevanju samih karakteristika podataka.

#### *2.4. Selekcija ulaznih varijabli*

Postoje tri metode IVS-a koje mogu da se koriste u ovom procesu: metode filtracije, metode omotača i ugrađene metode [361].

Svrha metoda IVS-a jeste izbacivanje svih nerelevantnih varijabli sa ciljem odabira optimalnog skupa varijabli koji će obezbediti najveću tačnost predikcije. Nerelevantnim varijablama smatraju se one koje nemaju nikakvu ili imaju slabu povezanost sa ciljnom varijablom i samim tim mogu da utiču na postizanje lošijih rezultata predikcije.

Univerzalna metoda za selekciju ulaznih varijabli ne postoji. Međutim, metode filtracije nezavisne su od ML tehnika pa se rezultati dobijeni putem ove metode (odnosno odabrani skup ulaznih varijabli) mogu primeniti na bilo koju ML tehniku, za razliku od metoda omotača i ugrađenih metoda čiji su rezultati vezani samo za određenu prediktivnu tehniku. Pored toga, metode filtracije su brže i skalabilnije u odnosu na druge dve metode [366]. Upravo iz navedenih razloga preporuka je da se prilikom selekcije ulaznih varijabli koriste metode filtracije.

U okviru metode filtracije potrebno je da se izvrši analiza korelacija, kako bi se uočili mogući odnosi između varijabli. U opštem slučaju ti odnosi mogu biti nelinearni ili kombinacija uzajamnih interakcija više varijabli. Postoji mogućnost da oni neće biti vidljivi na prvi pogled, ali ipak treba pokušati sa korelacijama, kako bi se uočili mogući linearni odnosi i predikcija tehnikama veštačke inteligencije učinila lakšom. Najbolji način da se analiziraju korelacije u okvirima IVS-a jeste korišćenjem mrMR algoritma [413]. Za problematiku e-učenja mrMR algoritam veoma je prikladan, pošto se varijable odnose na studenta, te je potpuno opravdano pretpostaviti da korelacije imaju bitnu ulogu u strukturi podataka. Ovaj način analiza korelacija omogućiće odabir skupa varijabli koji će potencijalno obezbediti maksimalnu tačnost predikcije.

Ovim postupkom izabraće se najinformativnije varijable u pogledu minimalne redundancije (mr), Maksimalne Relevantnosti (MR) i kombinacije ovih kriterijuma. F-statistika koristi se za ispitivanje relevantnosti u slučaju kontinualnih varijabli grupisanih po klasama predviđene varijable, za ispitivanje redundantnosti koristi se Pirsonov koeficijent korelacije, dok se pohlepni algoritam za pretragu koristi za izdvajanje ulaznih varijabli da bi se maksimizirala

objektivna funkcija ili funkcija cilja na osnovu kriterijuma uzajamnih informacija. Uzajamne informacije  $I(X, Y)$  između dveju diskretnih varijabli data je formulom [385]:

$$I(X, Y) = - \sum_{x,y} p(x, y) \cdot \log \frac{p(x, y)}{p(x) \cdot p(y)} \quad (7)$$

gde je  $p(x, y)$  mešovita distribucija varijabli  $X$  i  $Y$ , dok su  $p(x)$  i  $p(y)$  marginalne distribucije prethodno navedenih varijabli. Značenje uzajamne informacije najbolje se može videti ako se uzme u obzir  $X \cap Y = \{0\}$ , zatim  $p(x, y) = p(x) \cdot p(y)$  i iz gornje formule vidi se potom da je  $I(X, Y) = 0$ . Jednostavno rečeno, ova količina predstavlja količinu informacija o jednoj varijabli koja se odnosi na drugu varijablu.

U svrhu izvršenja validacije rezultata mrMR algoritma, najbolje je sprovesti selekciju ulaznih varijabli uz pomoć još jednog algoritma/tehnike (npr. RF klasifikacioni algoritam, informaciona dobit, *variance threshold*, linearna diskriminantna analiza, analiza varijanse - ANOVA itd.) [414].

Metodologija svakog algoritma/tehnike za selekciju ulaznih varijabli je drugačija, pa je tako i značaj prediktora na različitoj skali vrednosti. Zato je najbolje uvesti relativnu važnost prediktora prema formuli:

$$imp_i (\%) = \frac{imp_i}{max(imp)} \cdot 100\% \quad (8)$$

gde  $imp_i$  predstavlja  $i$ -ti prediktor ( $i = 1, 2\dots$ ). Ovom formulom moguće je uporediti značaj prediktora između različitih algoritama/tehnika.

U slučaju da odabrani algoritmi/tehnike selektuju isti skup prediktora iz datog skupa varijabli onda su rezultati potvrđeni i ti prediktori treba da se koriste za potrebe predikcije. Ako se, kojim slučajem, dogodi da algoritmi/tehnike ne odaberu isti skup prediktora, jedini način da se ovo reši jeste da se izračuna tačnost tehnika za predikciju u oba slučaja, odnosno sa ta dva različita skupa odabranih prediktora, kako bi se odabroa onaj koji donosi najveću tačnost.

Treba napomenuti da poboljšanje tačnosti tehnika za predikciju nije zagarantovano upotrebom IVS-a. Retko, ali nije situacija koju treba zanemariti, IVS može ići i u suprotnom smeru, odnosno da ne poboljšava ili smanjuje tačnost [371]. Međutim, u većini slučajeva ta metoda

dovodi do povećanja tačnosti, pa je preporuka uvek pokušati sa njenom primenom. Stoga je najbolje testirati tačnost predikcije tehnika veštačke inteligencije i sa selektovanim varijablama u okviru IVS-a i sa svim ulaznim varijablama, kako bi se utvrdila tačnost predikcije u oba slučaja.

### 3) Predikcija statističkim tehnikama

Iako tehnike veštačke inteligencije za predikciju obično postižu bolje rezultate u odnosu na statističke tehnike, ovaj iskaz ipak nije moguće generalizovati. Iz tog razloga važno je proći ceo proces predikcije od statističkih tehnika do tehnika veštačke inteligencije kako bi se utvrdilo koji će pristup i tehnika postići najveću tačnost u datom slučaju.

U predikciji uspeha studenata u sistemima za e-učenje regresiona analiza jeste i najčešći prvi izbor istraživača [331], [332], [333]. Odabir statističkih tehnika kao prvi korak opravdan je time što su jednostavnije za upotrebu i interpretaciju rezultata u odnosu na tehnike veštačke inteligencije [334]. Kod predikcije uspeha u e-učenju, moguće je predvideti bodove, prolaznost na kursu (prošao/pao) ili ocene. Linearnu regresiju treba koristiti kada se prediktuju bodovi, binarnu logističku regresiju kada je aktuelizovana prolaznost studenata na kursu, a ordinalnu logističku regresiju kada su predmet ocene. Za ovaj proces potrebno je odabrati i odgovarajući program (*SPSS, Stata, SAS* itd.).

Linearna regresija, binarna logistička regresija i ordinalna logistička regresija imaju određene uslove koji moraju biti ispunjeni kako bi mogle da se koriste za proces predikcije.

Za primenu linearne regresije potrebno je da budu ispunjeni sledeći uslovi:

- Kontinualna ciljna varijabla: Ciljna varijabla  $y$  mora biti kontinualna (npr. broj bodova od 0 do 100, gde bodovi mogu biti recimo 53 ili 75,2).
- Linearost: Neophodno je da postoji linearna veza između prediktora  $x$  i varijable koja se predviđa  $y$  (proveriti preko dijagrama rasejanja ili korelacionih statističkih testova da li je ovaj uslov ispunjen).
- Nezavisnost: Potrebno je da ne postoji autokorelacija između uzoraka iste varijable. To se obezbeđuje sa nezavisnim uzorcima, npr. godine i vreme studiranja, dva različita studenta itd.
- Bez multikolinearnosti: Ne treba da postoji multikolinearnost, odnosno prediktori ne treba da budu međusobno jako korelisani (multikolinearnost proveriti pomoću vrednosti faktora

inflacije varijanse (VIF), gde bi ova vrednost trebalo da bude  $< 10$ , a u najboljem slučaju  $< 5$ ).

- Bez ekstremnih odstupanja u vrednostima: Kako bi linearna regresija mogla da se primeni, podaci treba da budu bez ekstremnih odstupanja u vrednostima (ovo proveriti izračunavanjem Kukove razdaljine za svako posmatranje i ako postoje odstupanja onda ih ukloniti ili ih zameniti sa srednjom vrednošću ili medijanom).
- Normalnost: Greške treba da budu normalno raspoređene, odnosno da za svaku fiksnu vrednost  $x$ ,  $y$  treba da bude normalno raspoređena (ovaj uslov može se proveriti histogramom ili  $q-q$  dijagramom).
- Homoskedastičnost: Greške ne treba da variraju, nego da imaju istu varijansu za bilo koju vrednost  $x$ , što znači da njihova distribucija treba da bude neuredna bez nekog obrasca (dijagram rasejanja predstavlja najbolji način za proveru ovog uslova).

Ukoliko su svi navedeni uslovi za linearnu regresiju ispunjeni, tada treba odabratи ovu tehniku kako bi se izvršio proces predikcije.

U slučaju binarne i ordinalne logističke regresije potrebno je da budu ispunjena tri ista uslova kao i kod linearne regresije - nezavisnost, bez multikolinearnosti i bez ekstremnih odstupanja u vrednostima. Pored toga, binarna i ordinalna logistička regresija imaju i jedan dodatni zajednički uslov, kao i posebne. Zajednički uslov jeste veća količina uzorka, pošto su rezultati binarne i ordinalne logističke regresije bolji i pouzdaniiji kada je veći skup podataka.

Binarna logistička regresija, pored navedenih zajedničkih uslova, ima i dva specifična:

- Binarna ciljna varijabla: Vrednosti ciljne varijable treba da imaju samo dve moguće vrednosti, kao npr. prošao/pao, položio/nije položio itd.
- Neophodno je da postoji linearna veza između prediktora i logaritma količnika verovatnoće (logit): Što znači da logaritam količnika verovatnoće za moguće vrednosti ciljne varijable treba da bude linearno povezan sa prediktorima (postojanje linearnosti najlakše se može proveriti uz pomoć *Box-Tidwell* testa).

Ukoliko su svi navedeni uslovi za binarnu logističku regresiju ispunjeni tada treba odabratи tu tehniku za izvršenje procesa predikcije.

Ordinalna logistička regresija, pored navedenih zajedničkih uslova, ima i dva specifična:

- Ciljna varijabla ordinalnog karaktera: Ciljna varijabla mora imati rangirane kategorije (npr. ocene 5, 6, 7, 8, 9 i 10 ili ocene A, B, C, D, E i F i slično).
- Proporcionalni odnos: To bi podrazumevalo da svaka nezavisna varijabla ima isti efekat na svaki kumulativni deo ordinalne ciljne variable (proveriti preko Brantovog testa).

U okolnostima kada su svi navedeni uslovi za ordinalnu logističku regresiju ispunjeni, treba odabrati tu tehniku kako bi se realizovao proces predikcije.

Ako se dobiju zadovoljavajući rezultati nekom od ovih tehnika, nije neophodno preći na tehnike veštačke inteligencije.

#### **4) Prelazak na tradicionalne ML tehnike**

Ukoliko nisu ispunjeni uslovi za linearnu, binarnu logističku ili ordinalnu logističku regresiju, ili su ispunjeni ali nisu dobijeni zadovoljavajući rezultati - tada je potrebno preći na tradicionalne ML tehnike. Ove tehnike, za razliku od linearne, binarne logističke i ordinalne logističke regresije, ne postavljaju tako restriktivna ograničenja i često daju bolje rezultate predikcije [10]. Za realizaciju procesa predikcije tradicionalnim ML tehnikama potrebno je odabrati odgovarajući program ili programski jezik, koji omogućava jednostavan uvoz podataka, podržava veliki broj tradicionalnih ML tehnika i omogućava njihovo jednostavno korišćenje (*MATLAB, Python, Weka, Scilab, Tableau* itd.).

Kod tradicionalnih ML tehnika proces odabira ulaznih varijabli izvršen je u okviru preprocesiranja podataka primenom IVS-a. Veća je verovatnoća da će tradicionalne ML tehnike postići bolje rezultate kada se koriste selektovane variable [28], [340], [352], [370]. Međutim, ovo se ne može generalizovati, pa je iz tog razloga najbolje testirati tačnost predikcije tradicionalnih ML tehnika i sa svim ulaznim varijablama i sa selektovanim varijablama u okviru IVS-a, kako bi se utvrdila tačnost predikcije u oba slučaja.

##### *4.1. Odabir tradicionalnih ML tehnika*

Izbor tradicionalne ML tehnike za predikciju uspeha studenata u sistemima za e-učenje, kao i u drugim oblastima, predstavlja svojevrsni izazov. Njegovo prevazilaženje zavisi od mnogo

faktora, među kojima su problematika, struktura podataka, veličina skupa i mnogi drugi [343]. Istraživači zato uglavnom eksperimentišu sa više tehnika u svrhu dobijanja najboljeg rezultata. Međutim, postoje olakšavajuće komponente i donekle se ipak može odrediti sa kojim tehnikama treba započeti proces predikcije. Na osnovu deskriptivne i korelaceione analize može se proceniti da li u podacima preovlađuju linearne ili nelinearne relacije. Ukoliko preovlađuju linearne (što se može videti iz korelograma), sugestija je prvo pokušati sa tradicionalnom ML tehnikom SVM sa linearnim jezgrom. Ova tehnika, zbog svoje jednostavnosti i robustnosti, predstavlja optimalan izbor kada u podacima preovlađuju linearne relacije, pošto u takvim slučajevima postiže visoku tačnost predikcije [28], [415], [416]. Ako preovlađuju nelinearne relacije - pokušati sa tradicionalnim ML tehnikama DT i kNN. Iako DT i kNN mogu da rade i sa linearnim relacijama, ipak su efikasniji kada u podacima preovlađuju nelinearne relacije [417]. DT u ovakvim slučajevima postiže veću tačnost zbog njegove sposobnosti da modeluje kompleksne obrasce, kao i da identificuje okolnosti u kojima kombinacija više ulaznih varijabli pokazuje moguće ishode [418], [419], [420]. Takođe, kNN poseduje sposobnost prilagođavanja raznim strukturama podataka i svoj rad temelji na lokalnim informacijama koje dobija iz podataka, zbog čega je veoma efikasan za nelinearne relacije [421], [422]. Ukoliko sa predloženim tradicionalnim ML tehnikama nije bilo očekivanih rezultata onda se savetuju numerička eksperimentisanja i sa drugim tradicionalnim ML tehnikama.

#### 4.2. Kreiranje modela za predikciju

Uspešna konstrukcija ML modela za predikciju obuhvata sledeće korake:

- Podelu podataka na skup za trening i skup za test (najčešći način deljenja ulaznog skupa je 75% podataka za treniranje i 25% podataka za testiranje, ali kako bi se postigla bolja generalizacija rezultata može se pri ovakvoj podeli u svakoj epohi izmešati skup za treniranje, a drugi dobar način da se postigne bolja generalizacija jeste da se koristi unakrsna validacija, gde se ulazni skup deli na jednakde delove - obično 5 ili više - tako da jedan deo ima ulogu skupa za testiranje, dok su ostali za treniranje i tako ciklično, dok se svi delovi ne izređaju za testiranje).
- Treniranje modela (proces u kome se ML algoritam trenira, odnosno uči iz skupa podataka određenog za trening).

- Testiranje modela (proces u kome se na skupu podataka određenog za test vrši procena tačnosti istreniranog ML algoritma).



*Slika 10. Kreiranje ML modela*

Ako se dobiju zadovoljavajući rezultati nekom od tradicionalnih ML tehnika, nije neophodno preći na ANN.

## 5) Primena SMOTE algoritma

U slučaju malog skupa podataka studenata, s obzirom na to da ne rade sve tradicionalne ML tehnike dobro sa malim uzorcima i zahtevaju određeni minimalan uzorak za normalno funkcionisanje, tada se može primeniti *SMOTE* algoritam. Kod kurseva e-učenja čest je slučaj da se radi sa malim skupovima podataka, odnosno broj studenata za koje se radi predikcija je mali [344], [345], [353]. Upravo to može biti uzrok nezadovoljavajućih rezultata dobijenih pomoću tradicionalnih ML tehnika. Primenom *SMOTE* algoritma mogu se generisati sintetički podaci i na taj način povećati uzorak. Uvećanjem originalnog skupa izbegava se mogućnost nepravilnog rada određenih tradicionalnih ML tehnika. Ukoliko su ove tehnike postizale loše rezultate u predikciji uspeha studenata zbog malog uzorka, ovom metodom je to moguće utvrditi.

Nakon generisanja sintetičkih podataka i samim tim uvećanja skupa podataka potrebno je ponovo proveriti tačnost tradicionalnih ML tehnika. Međutim, poboljšanje rezultata ovom metodom nije zagarantovano.

Treba, takođe, napomenuti da je uvek bolje raditi sa originalnim podacima i da korišćenje algoritma za generisanje sintetičkih podataka treba uzeti u razmatranje sa rezervom jer nije uvek pouzdano [423].

## 6) Prelazak na predikciju korišćenjem ANN-a

Ukoliko nisu dobijeni zadovoljavajući rezultati sa tradicionalnim ML tehnikama, tada je potrebno preći na ANN. One mogu da reše složenije nelinearne probleme u odnosu na tradicionalne ML tehnike i zbog toga deluju superiornije u odnosu na njih [18], [20] i u većem broju slučajeva postižu bolje rezultate tačnosti predikcije [335], [336], [348], [350], ali treba naglasiti da se ovaj iskaz ne može generalizovati [22], [23]. Kako bi se izvršio proces predikcije pomoću ANN-a, potrebno je odabratи odgovarajući program ili programski jezik (*MATLAB*, *Python*, *Weka*, *Scilab*, *Tableau* itd.).

Kod ANN-a, kao i kod tradicionalnih ML tehnika proces odabira ulaznih varijabli izvršen je u okviru preprocesiranja podataka primenom IVS-a. Međutim, veća je verovatnoćа da će ANN postići bolje rezultate kada se koriste sve varijable [19], [337], [351]. Pošto se ovo ne može generalizovati, iz tog razloga najbolje je testirati tačnost predikcije ANN-a i sa svim ulaznim varijablama i sa selektovanim varijablama u okviru IVS-a, kako bi se utvrdila tačnost predikcije u oba slučaja.

### 6.1. Odabir ANN algoritma

Za predikciju uspeha studenata u sistemima za e-učenje preporuka je korišćenje Levenberg-Markuardt algoritma sa Bajesovom regularizacijom. Ovaj algoritam predložen je upravo zbog rezultata dobijenih iz sprovedenog istraživanja u ovoj disertaciji, gde je razvijen model koji ostvaruje visoku tačnost u predikciji ocena studenata i koji je nadmašio rezultate tradicionalnih ML tehnika. Takođe, brojni autori govore o superiornosti ovog algoritma i postizanju visoke tačnosti predikcije [406], [407], na osnovu čega se može zaključiti da je ovaj algoritam pravi izbor.

Takođe, klasični Levenberg-Markuardt algoritam predstavlja odličan izbor (naravno kasnije se može pokušati i sa drugim ANN algoritmima, ukoliko sa ovima nije bilo očekivanih rezultata). Međutim, Levenberg-Markuardt algoritam sa Bajesovom regularizacijom i klasični Levenberg-Markuardt algoritam dobri su u ovoj nameni ukoliko se radi o uzorku male ili srednje veličine (do deset hiljada) [424]. U e-učenju najčešće se i radi sa uzorcima male ili srednje veličine tako da će u najvećem broju slučajeva to biti pravi izbor. Međutim, ukoliko to ipak nije slučaj i sprovodi se obimnije istraživanje koje bi uključilo više od deset hiljada studenata, tada treba

pristupiti modifikovanim algoritmima propagacije greške unazad (eng. *Backpropagation*) i opadajućeg gradijenta (eng. *Gradient descent*) baziranih na prvom izvodu gradijenta funkcije gubitaka [425]. U ovom slučaju najbolji izbor je *ADAM* [357], [426], [427], a nakon toga može se pokušati i sa *AdaGrad* [428] i *RMSProp* [429] (naravno, ukoliko nije bilo očekivanih rezultata može se pokušati i sa drugim).

## 6.2. Kreiranje modela za predikciju

Uspešna izrada ANN modela za predikciju obuhvata sledeće korake:

- Podelu podataka na skup za trening i skup za test (isto važi kao što je navedeno i kod tradicionalnih ML tehnika).
- Treniranje modela (proces u kome se ANN algoritam trenira, odnosno uči iz skupa podataka određenog za trening).
- Testiranje modela (proces u kome se na skupu podataka određenog za test vrši procena tačnosti istreniranog ANN algoritma).



Slika 11. Kreiranje ANN modela

Ovom metodologijom predstavljen je proces koji je determinisano slediti za uspešnu realizaciju predikcije uspeha studenata u sistemima za e-učenje. Sistematičnom putanjom po navedenim koracima potencijalno se postiže maksimalna tačnost predikcije.

## **7. Naučni doprinos disertacije**

Disertacija prikazuje istraživanje vezano za primenu veštačke inteligencije u oblasti e-učenja za potrebe predikcije uspeha studenata. Istraživanje je, na osnovu identifikovanih ključnih problemskih mesta u literaturi, detaljno analiziralo proces preprocesiranja podataka u svrhu predikcije, te primenilo različite tehnike veštačke inteligencije za sprovođenje prediktivnih analiza. Izvršeni eksperimenti i testiranja, u kombinaciji sa opsežnim pregledom literature, rezultovali su razvojem metodologije za predikciju uspeha studenata u sistemima za e-učenje i predstavljanjem praktičnih implikacija i smernica za primenu ishoda i nalaza disertacije. Rezultati disertacije pružaju značajan naučni doprinos na polju inženjeringu tehnologija učenja i veštačke inteligencije.

Naučni doprinos ovog istraživanja ogleda se u:

- Predloženoj metodologiji za predikciju uspeha studenata u sistemima za e-učenje.
- Definisanim smernicama za preprocesiranje podataka, koje donose bolje razumevanje važnosti tog procesa u svrhu poboljšanja tačnosti predikcije.

Nedostatak standardizovanih metodologija za predikciju uspeha studenata u sistemima za e-učenje identifikovan je kao najveći problem za istraživače koji često pristupaju ovom procesu bez jasnog plana. Predložena metodologija za predikciju osmišljena je tako da pruži ključna objašnjenja i detaljna uputstva za primenu adekvatnih postupaka, metoda i tehnika za predikciju u kontekstu e-učenja. Metodologija predstavlja proces koji treba slediti za uspešnu realizaciju predikcije uspeha studenata u sistemima za e-učenje, gde se praćenjem njenih koraka potencijalno postiže maksimalna tačnost predikcije.

Inovacija predložene metodologije za predikciju, u odnosu na postojeće pristupe, ogleda se u:

- Uvođenju kompletног procesa preprocesiranja podataka kao jednog od obavezних koraka, a koji je često zanemaren od strane istraživača u oblasti e-učenja.
- Datim detaljnim smernicama u kontekstu e-učenja za sve neophodne faze procesa predikcije.
- Realizovanju celog procesa predikcije - od statističkih tehnika, preko tradicionalnih ML tehnika, pa sve do ANN-a.

Upravo ovakav standardizovan pristup nedostajao je istraživačima iz ove oblasti, kako bi na adekvatan način pristupili procesu predikcije i razvili modele visoke tačnosti [312]. Nastavnicima se, putem ovog pristupa, obezbeđuju pouzdani i efikasni modeli za predikciju uspeha.

Pored predloga metodologije, disertacija je doprinela i boljem razumevanju važnosti pretprocesiranja podataka za potrebe predikcije i pruženim smernicama za taj proces. Primetno je bilo zanemarivanje ovog procesa od strane istraživača u oblasti predikcije uspeha studenata u sistemima za e-učenje. Zbog toga je deo sprovedenog istraživanja disertacije bio usmeren upravo ka pretprocesiranju podataka za potrebe predikcije čiji je cilj bio stvaranje detaljnih instrukcija za taj proces. U tom smislu utvrđeno je da ovaj proces treba da sadrži sledeće stavke: formatiranje podataka, čišćenje podataka, deskriptivnu statistiku, korelacionu analizu i selekciju ulaznih varijabli zajedno sa verifikacijom njenih rezultata, nešto što većina analiziranih istraživanja nije aktuelizovala uopšte ili je u maloj meri tom segmentu posvećena pažnja sa samo nekim od navedenih stavki.

Tokom dela sprovedenog istraživanja koje je prethodilo kreiranju predloga metodologije za predikciju uspeha studenata u sistemima za e-učenje ostvarena su još neka bitna postignuća koja je važno napomenuti:

- Razvijen je ANN model za predikciju uspeha studenata u sistemu za e-učenje koji može da predvidi njihove ocene.
- Identifikovana je najefikasnija i najučinkovitija tehnika veštačke inteligencije za potrebe predikcije uspeha studenata u sistemima za e-učenje.
- Predstavljena je vizuelizacija koja pruža uvid u osnovne faktore vezane za interakciju studenata sa sistemom za e-učenje koji utiču na njihov uspeh i koja jasno demonstrira nastavnicima faktore koji vode do viših i nižih ocena.

Nalazi disertacije i uočena problemska mesta predstavljaju odličnu podlogu za neka dalja istraživanja koja će biti definisana u poglavlju Zaključak i preporuke za buduća istraživanja.

## **8. Implikacije i ograničenja istraživanja**

U ovom poglavlju predstavljene su praktične implikacije za primenu rezultata disertacije i navedena su određena ograničenja istraživanja [313].

### **8.1. Implikacije**

Implikacije istraživanja odnose se na: mogućnost primene ishoda i nalaza disertacije za potrebe unapređenja dizajna učenja, upotrebu prezentovane vizuelizacije uvida u faktore koji utiču na uspeh studenata, primenu razvijenog modela za predikciju uspeha studenata i korišćenje metodologije za predikciju uspeha studenata u sistemima za e-učenje zajedno sa benefitima koje ona donosi.

#### **8.1.1. Dizajn učenja**

Rezultati disertacije pružaju dizajnerima učenja važne uvide i korisne informacije za potrebe unapređenja dizajna učenja [313].

Uzimajući u obzir da se ukupan rejting studenata (dobijen putem Elo rangiranja) pokazao kao najinformativniji prediktor u istraživanju prikazanom u ovoj disertaciji, implementaciju Elo algoritma za ocenjivanje treba razmotriti u razvoju svakog sistema za e-učenje, gde se pored njegove upotrebe za adaptivnu procenu znanja, Elo rangiranje studenata može koristiti i za predviđanje njihovog uspeha. Studija u [430] demonstrirala je da se korišćenjem samo ukupnog rejtinga studenata (dobijenog putem Elo rangiranja) kao prediktora mogu postići zadovoljavajući rezultati u predviđanju njihovog budućeg uspeha. Dizajneri učenja takođe treba da razmotre uvođenje rangiranja studenata u sistemima za e-učenje, pošto je ustanovljeno da veći rejting studenata u sistemu vodi do viših ocena, čime u prilog svedoče rezultati prikazani u ovoj disertaciji, ali i sledeće studije [186], [431]. Pored toga, broj različitih zadataka ili vežbi koji su uspešno rešeni u sistemu za e-učenje (u slučaju sistema *ProTuS* vežbe kodiranja) demonstrira da će studenti dobiti bolje ocene ako imaju veći broj rešenih zadataka i niže ako imaju manji broj rešenih zadataka, te na taj aspekt dizajneri učenja treba da se fokusiraju. I drugi autori ukazuju na ovu vrstu odnosa između broja uspešno urađenih zadataka i uspeha studenata [432], [433]. Dizajneri učenja takođe treba da aktuelizuju i broj tema/lekcijskih kojih studenti moraju da pređu tj. polože kako bi ostvarili

dobre rezultate, odnosno dobili visoke ocene. Sledeća istraživanja [434], [435] u kojima je veći broj položenih lekcija studenata doveo do njihovog boljeg uspeha afirmativno govore o tome. Vreme koje studenti provedu koristeći sistem za e-učenje može biti u određenoj meri relevantno za dizajnere učenja, jer su mišljenja o ovom pitanju podeljena, pošto postoje studije koje izveštavaju o irelevantnosti ove karakteristike po pitanju uticaja na uspeh studenata [436], dok ima i onih koje ga pominju kao važan element i da studenti koji provode više vremena na platformama za e-učenje uglavnom postižu bolje rezultate [437]. Zajedničko stanovište svih istraživača jeste u vezi sa ukupnim vremenom provedenim u sistemu za e-učenje - provođenje manje vremena u sistemu povezano je sa slabijim uspehom studenata. Dizajneri učenja ne bi trebalo da budu u mogućnosti da iskoriste broj interakcija koje studenti ostvaruju u sistemu za e-učenje, pošto je u analizama prikazanim u ovoj disertaciji utvrđeno da ne postoji specifičan odnos između ukupnog broja značajnih radnji koje studenti naprave u sistemu i njihovog konačnog uspeha. Slično tome, studija predstavljena u [438] tvrdi da povećana onlajn interakcija studenata sa sistemom za e-učenje nije značajno poboljšala njihov uspeh.

Navedene činjenice dizajneri učenja mogu iskoristiti u budućnosti za razvoj onlajn kurseva koji će biti kreirani po meri studenata.

### **8.1.2. Vizuelizacija**

Vizuelizacija, predstavljena u disertaciji, namenjena je nastavnicima za sticanje korisnih informacija koje se odnose na osnovne faktore vezane za interakciju studenata sa sistemom za e-učenje koji utiču na njihov uspeh.

Ono što je sa metodičke tačke gledišta posebno interesantno, a što mogu da koriste i nastavnici i dizajneri učenja, jesu putevi do čvorova lista koji predstavljaju ocene studenata, kao što je prikazano na Slici 8 [313]. Tako, na primer, za vrednosti  $1478 > elo\_rating \geq 1364$  i  $pcrs\_dist\_success < 6,5$ , nastavnici mogu očekivati da će student dobiti ocenu E. Slično, za vrednosti prediktora  $elo\_rating \geq 1478$ ,  $pcrs\_dist\_success \geq 39,5$  i  $total\_durationseconds \geq 39784,8$  može se očekivati maksimalna ocena A itd. Poznavanje činjenice koji tačno faktori utiču na ocene jeste nešto što nastavnik može da upotrebi za poboljšanje uspeha studenata, što potvrđuju mnoge studije [400], [401], [402]. Štaviše, kao što je već diskutovano, drugi uvidi stečeni kroz

proveru važnosti varijabli mogu se koristiti kao kontrolne tačke za pomoć nastavnicima u razumevanju i redizajniranju kako bi se unapredio proces učenja [403], [404].

Uvid u ove ključne aspekte nastavnicima pruža mogućnost da koriste generisane informacije za poboljšanje kvaliteta nastave i učenja.

### **8.1.3. Model za predikciju uspeha**

Adaptacija nastavnih metoda i dizajna učenja zasnovanih na rezultatima predviđanja može poboljšati uspeh studenata, kao što je izraženo u [439].

Model za predikciju uspeha studenata u disertaciji razvijen je na osnovu podataka prikupljenih po završetku kursa, tako da se za sada ovaj model može primeniti samo nakon kursa, ali pre ispita, što ostavlja dovoljno vremena nastavnicima da preduzmu odgovarajuće akcije. Posedovanje ovih informacija, nastavnicima mogu biti od velikog značaja prilikom obavljanja dodatnih konsultacija sa studentima za koje se anticipira da neće položiti ispit ili da će imati niže ocene. Navedenim podacima mogu blagovremeno razumeti razloge poteškoća studenata sa savladavanjem gradiva i neuspeha u ostvarivanju boljih rezultata. Na ovaj način, nastavnici mogu da organizuju dodatne aktivnosti učenja pre ispita u skladu sa potrebama studenata, sa naglaskom na lekcije i vežbe kodiranja sa kojima imaju problema, radi podizanja nivoa uspeha studenata. Takođe, optimalno je i da nastavnici koriste ovaj model za personalizovane intervencije kako bi pomogli studentima da postignu bolje rezultate u učenju, na uspešan način kako je predočeno u studijama [440], [441]. Međutim, važno je iskoristiti predviđene ishode za intervencije u ranim fazama kursa, pošto studije pokazuju značajno veći uticaj na uspeh studenata kod takvih intervencija u odnosu na one primenjene na kraju kursa [442], [443].

Sa stanovišta studenata, pristup ishodima predviđanja omogućava prilagođeno iskustvo učenja koje je u skladu sa njihovim kompetencijama, potencijalno poboljšavajući njihov uspeh putem informisanih strategija učenja [444], [445]. Međutim, korist od nedeljnih predviđanja uspeha ostaje uglavnom limitirana na nastavnike, ograničavajući tako direktnu korist za studente od takvih dinamičkih uvida [312], [446].

Pravilnom upotrebom ovog modela za predikciju od strane nastavnika može se unaprediti proces učenja studenata u sistemima za e-učenje, povećati njihova efikasnost i, samim tim, uticati na poboljšanje njihovog uspeha.

#### **8.1.4. Metodologija za predikciju uspeha**

Metodologiju za predikciju uspeha studenata u sistemima za e-učenje, predloženu u disertaciji, mogu da koriste mnogi istraživači iz ove oblasti. Iskazana metodologija omogućiće istraživačima da precizno predviđaju uspeh ne samo studenata na fakultetima, nego i učenika u osnovnim i srednjim školama, polaznika na raznim profesionalnim kursevima itd. Njenom upotrebom istraživači mogu da na adekvatan način pristupe procesu predikcije uspeha i da razviju modele koji će potencijalno moći da postignu maksimalnu tačnost predviđanja. Kao što je već pomenuto, svaki procenat tačnosti manje, u zavisnosti od uzorka, znači npr. jednog ili više studenata čiji uspeh neće biti tačno predviđen, što može dovesti do toga da se intervencije za neke studente izvrše u pogrešnom smeru [379]. Korišćenjem ove metodologije tako nešto biće izbegnuto, tačnije svedeno na minimum. Veći procenat tačnosti znači da će se za veći broj studenata moći sa sigurnošću tvrditi da je njihov uspeh tačno predviđen, izbegavajući tako pogrešne intervencije od strane nastavnika. Ova metodologija predstavlja korak ka unapređenju procesa predikcije uspeha studenata u sistemima za e-učenje i pruža okvir za standardizaciju tog procesa. Usvajanje jednog ovakvog pristupa od strane istraživača doveće do efikasnijeg procesa predikcije i boljih rezultata od kojih će nastavnici i studenti imati višestruke benefite.

Sveukupni nalazi disertacije predstavljaju važno postignuće u oblasti e-učenja i veštačke inteligencije, od kojih će istraživači iz ovih oblasti, kao i svi iz obrazovnog sistema imati brojne koristi.

### **8.2. Ograničenja istraživanja**

Rezultati ove disertacije govore u prilog važnosti prethodne obrade podataka, kao i ishoda kada se početna analiza podataka izvrši pre primene tradicionalnih ML tehnika i ANN-a. Međutim, podložni su određenim ograničenjima [313]. Prvo, učesnici uključeni u ovu studiju su studenti prvostepenih studija sa univerziteta u Norveškoj, što ograničava generalizaciju dobijenih nalaza na studente iz različitih populacija sa distinkтивnim veštinama. Drugo, uopštavanje ovih nalaza ograničeno je vežbama i zadacima iz sistema za e-učenje korišćenog u eksperimentima koji zahtevaju specifično znanje o računarstvu i isto tako sam sistem čuva varijable koje su specifične za domen računarskih nauka. Treće, efikasnost Elo algoritma za ocenjivanje zavisi od preciznog procenjivanja složenosti zadataka kodiranja i učinka ostalih studenata - dva faktora koja mogu

stvoriti nedoslednost. Ova nedoslednost može dovesti do pristrasnih predviđanja. Istraživanje različitih pristupa ili poboljšanja Elo sistema za ocenjivanje u budućim studijama moglo bi pomoći u prevazilaženju ovih problema, što bi dovelo do nepristrasnije i pouzdanije evaluacije studentskih sposobnosti i znanja.

## **9. Zaključak i preporuke za buduća istraživanja**

Predikcija uspeha studenata u sistemima za e-učenje predstavlja izazovan zadatak kome se mora pristupiti sa velikom pažnjom. U ovoj disertaciji prikazan je proces razvijanja modela za predikciju uspeha studenata uz pomoć tradicionalnih ML tehnika i ANN-a. Za ovaj zadatak korišćeni su *log* podaci interakcije studenata sa *ProTuS* sistemom za e-učenje. Rezultati su pokazali da su ANN zasnovane na Levenberg-Markuardt algoritmu sa Bajesovom regularizacijom nadmašile rezultate tradicionalnih ML tehnika SVM, KNN i DT. Ovo istraživanje pokazalo je da se specijalna pažnja mora posvetiti preprocesiranju, pošto su sve tradicionalne ML tehnike postigle bolje rezultate kada su pravilno selektovane ulazne varijable. Selekcija je izvršena uz pomoć mrMR algoritma, koji je za problematiku e-učenja veoma prikladan. Nasuprot tome, ANN pokazale su da se bolji rezultati ostvaruju kada se uključe svi prediktori, čime se potvrdilo da se u slučaju ANN-a ne postavljaju ograničenja u pogledu ulaznih varijabli, kao u slučaju tradicionalnih ML tehnika.

Disertacija je, takođe, pružila uvid u faktore koji utiču na uspeh studenata u sistemima za e-učenje. Ovakvi uvidi su od velikog značaja za nastavnike, koji takve informacije mogu da iskoriste za poboljšanje uspeha studenata. Vizuelizacija ovakvih uvida može pomoći u pojednostavljinju složenih rezultata dobijenih tehnikama veštačke inteligencije, omogućavajući nastavnicima da bolje tumače te rezultate. Takođe, rezultati celokupnog istraživanja disertacije mogu biti zanimljivi dizajnerima učenja, jer bi bili u prilici da ih iskoriste za potrebe unapređenja dizajna učenja, koje bi moglo povoljno da se odrazi na konačan uspeh studenata.

Istraživanje sprovedeno u disertaciji pokazalo je da prilikom predikcije uspeha učenika/studenata u sistemima za e-učenje pristup istraživača često nije sistematičan. Metodologija za predikciju uspeha studenata u sistemima za e-učenje, prikazana u disertaciji, predstavlja korak ka usvajanju kvalitetnijeg i efikasnijeg pristupa za predikciju. Predočena metodologija omogućuje istraživačima iz ove oblasti da na adekvatan način produ kroz kompletan proces predikcije koji će ih potencijalno dovesti do razvijanja modela visoke tačnosti, od kojih će nastavnici i studenti imati velike koristi. Nastavnicima se, putem ovog pristupa, obezbeđuju pouzdani i efikasni modeli za predikciju uspeha, koje potom mogu koristiti u okviru svoje nastavne grupe. Nastavnicima će ova metoda pružiti priliku da analiziraju projektovane rezultate za intervencije kod onih studenata za koje se predviđa da će pasti ili imati loše ocene, i odgovarajućim

metodičkim pristupom i aktivnostima moći će blagovremeno da reaguju u cilju poboljšanja uspeha tih studenata. Iz perspektive studenata, modeli predviđanja mogu im doneti velike benefite ako nastavnici na odgovarajući način iskoriste ishode predviđanja kako bi poboljšali proces učenja. Na taj način studenti će moći da se uključe u proces učenja koji više odgovara njihovom znanju i kompetencijama, što može pozitivno uticati na njihov uspeh.

Buduća istraživanja nadovezuju se na predstavljene implikacije studije, gde je za početak predviđeno testiranje razvijenog ANN modela na drugim grupama studenata koji će koristiti *ProTuS* sistem u sklopu istog kursa, ali isto tako i na grupe studenata u okviru drugih kurseva na ovom sistemu. Takođe, planirano je testiranje ovog modela za ranu predikciju uspeha studenata. Nastavnicima bi se omogućilo da dobiju značajne informacije o njihovom uspehu u toku semestra, umesto na samom kraju, pa bi tako mogli da preduzmu odgovarajuće akcije blagovremeno. Fokus će biti i na daljem usavršavanju ANN modela za potrebe nedeljnih predviđanja. Obezbeđivanje ovakvih informacija koje bi bile direktno dostupne studentima omogućile bi im da iz nedelje u nedelju prate svoj napredak i da na osnovu tih parametara isplaniraju dalje aktivnosti vezane za učenje. Buduća istraživanja koja se odnose na predstavljenu metodologiju za predikciju uspeha studenata u sistemima za e-učenje podrazumevaju njeno testiranje na više diferenciranih skupova podataka dobijenih sa različitih obrazovnih institucija - fakulteta, osnovnih i srednjih škola, ali i raznih kurseva. Pored toga, testiranje ove metodologije na skupovima podataka koji nisu u uskoj vezi sa problematikom e-učenja takođe su u planu.

## 10. Literatura

- [1] N. N. Mohd Kasim and F. Khalid, "Choosing the Right Learning Management System (LMS) for the Higher Education Institution Context: A Systematic Review," *International Journal of Emerging Technologies in Learning*, vol. 11, no. 6, pp. 55–61, 2016, doi: 10.3991/ijet.v11i06.5644.
- [2] V. M. Bradley, "Learning Management System (LMS) Use with Online Instruction," *International Journal of Technology in Education*, vol. 4, no. 1, pp. 68–92, 2020, doi: 10.46328/ijte.36.
- [3] E. Mousavinasab, N. Zarifsanaiey, S. R. Niakan Kalhori, M. Rakhshan, L. Keikha, and M. Ghazi Saedi, "Intelligent tutoring systems: a systematic review of characteristics, applications, and evaluation methods," *Interactive Learning Environments*, vol. 29, no. 1, pp. 142–163, 2021, doi: 10.1080/10494820.2018.1558257.
- [4] A. Salah Hashim, W. Akeel Awadh, and A. Khalaf Hamoud, "Student Performance Prediction Model based on Supervised Machine Learning Algorithms," *IOP Conf Ser Mater Sci Eng*, vol. 928, no. 3, pp. 1–18, 2020, doi: 10.1088/1757-899X/928/3/032019.
- [5] R. Chweya, S. M. Shamsuddin, S.-S. M. Ajibade, and S. Moveh, "A Literature Review of Student Performance Prediction in E-Learning Environment," *Journal of Science Engineering Technology and Management*, vol. 1, no. 1, pp. 22–36, 2020, doi: 10.46820/JSETM.2020.1103.
- [6] H. Nawang, M. Makhtar, and W. Hamza, "A systematic literature review on student performance predictions," *International Journal of Advanced Technology and Engineering Exploration*, vol. 8, no. 84, pp. 1441–1453, 2021, doi: 10.19101/IJATEE.2021.874521.
- [7] F. Ünal, "Data Mining for Student Performance Prediction in Education," in *Data Mining - Methods, Applications and Systems*, IntechOpen, 2020, pp. 423–432. doi: 10.5772/intechopen.91449.
- [8] Xindong Wu, Xingquan Zhu, Gong-Qing Wu, and Wei Ding, "Data mining with big data," *IEEE Trans Knowl Data Eng*, vol. 26, no. 1, pp. 97–107, 2014, doi: 10.1109/TKDE.2013.109.
- [9] A. L'Heureux, K. Grolinger, H. F. Elyamany, and M. A. M. Capretz, "Machine Learning With Big Data: Challenges and Approaches," *IEEE Access*, vol. 5, pp. 7776–7797, 2017, doi: 10.1109/ACCESS.2017.2696365.
- [10] B. U. Islam, "Comparison of conventional and modern load forecasting techniques based on artificial intelligence and expert systems," *International Journal of Computer Science Issues (IJCSI)*, vol. 8, no. 5, pp. 504–513, 2011.

- [11] J. L. Rastrollo-Guerrero, J. A. Gómez-Pulido, and A. Durán-Domínguez, “Analyzing and Predicting Students’ Performance by Means of Machine Learning: A Review,” *Applied Sciences*, vol. 10, no. 3, pp. 345–360, 2020, doi: 10.3390/app10031042.
- [12] M. Ilić, V. Mikić, L. Kopanja, and B. Vesin, “Intelligent techniques in e-learning: a literature review,” *Artif Intell Rev*, vol. 56, no. 12, pp. 14907–14953, 2023, doi: 10.1007/s10462-023-10508-1.
- [13] R. Farhat, Y. Mourali, M. Jemni, and H. Ezzedine, “An overview of Machine Learning Technologies and their use in E-learning,” in *2020 International Multi-Conference on: “Organization of Knowledge and Advanced Technologies” (OCTA)*, Tunis, Tunisia: IEEE, 2020, pp. 1–4. doi: 10.1109/OCTA49274.2020.9151758.
- [14] M. Vakili, M. Ghamsari, and M. Rezaei, “Performance Analysis and Comparison of Machine and Deep Learning Algorithms for IoT Data Classification,” *arXiv preprint arXiv:2001.09636*, 2020.
- [15] M. Hassan and M. Hamada, “A Neural Networks Approach for Improving the Accuracy of Multi-Criteria Recommender Systems,” *Applied Sciences*, vol. 7, no. 9, pp. 1–18, 2017, doi: 10.3390/app7090868.
- [16] Y. Goldberg, “A Primer on Neural Network Models for Natural Language Processing,” *Journal of Artificial Intelligence Research*, vol. 57, pp. 345–420, 2016, doi: 10.1613/jair.4992.
- [17] R. K. Sinha, R. Pandey, and R. Pattnaik, “Deep Learning For Computer Vision Tasks: A review,” *arXiv preprint arXiv:1804.03928*, 2018.
- [18] Y. Baashar *et al.*, “Toward Predicting Student’s Academic Performance Using Artificial Neural Networks (ANNs),” *Applied Sciences*, vol. 12, no. 3, pp. 1–16, 2022, doi: 10.3390/app12031289.
- [19] M. Sayed and F. Baker, “E-Learning optimization using supervised artificial neural-network,” *Journal of software engineering and applications*, vol. 8, no. 1, pp. 26–34, 2015.
- [20] A. Remaida, B. Abdellaoui, A. Moumen, and Y. E. B. El Idrissi, “Personality traits analysis using Artificial Neural Networks: A Literature Survey,” in *2020 1st International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET)*, Meknes, Morocco: IEEE, 2020, pp. 1–6. doi: 10.1109/IRASET48871.2020.9092076.
- [21] S. Arumugam, A. Kovalan, and A. E. Narayanan, “A Learning Performance Assessment Model Using Neural Network Classification Methods of e-Learning Activity Log Data,” in *2019 International Conference on Smart Systems and Inventive Technology (ICSSIT)*, IEEE, 2019, pp. 441–448. doi: 10.1109/ICSSIT46314.2019.8987958.

- [22] E. Emirtekin, M. Karatay, and T. Kişla, “Online Course Success Prediction of Students With Machine Learning Methods,” *Journal of Modern Technology and Engineering*, vol. 5, no. 3, pp. 271–282, 2020.
- [23] A. Alsharhan, S. A. Salloum, and A. Aburayya, “Using e-learning factors to predict student performance in the practice of precision education,” *Journal of Legal, Ethical and Regulatory Issues*, vol. 24, no. 6, pp. 1–14, 2021.
- [24] V. Vijayalakshmi and K. Venkatachalapathy, “Comparison of Predicting Student’s Performance using Machine Learning Algorithms,” *International Journal of Intelligent Systems and Applications*, vol. 11, no. 12, pp. 34–45, 2019, doi: 10.5815/ijisa.2019.12.04.
- [25] Y. Abubakar and N. B. H. Ahmad, “Prediction of Studentsâ€™ Performance in E-Learning Environment Using Random Forest,” *International Journal of Innovative Computing*, vol. 7, no. 2, pp. 1–5, 2017.
- [26] S. Sisovic, M. Matetic, and M. B. Bakaric, “Mining student data to assess the impact of moodle activities and prior knowledge on programming course success,” in *Proceedings of the 16th International Conference on Computer Systems and Technologies*, New York, NY, USA: ACM, 2015, pp. 366–373. doi: 10.1145/2812428.2812459.
- [27] S. Sweta, S. Mahato, and L. K. Pathak, “Prediction of Learner’s Performance in Adaptive E-Learning System using Learning Analytics,” *IOP Conf Ser Mater Sci Eng*, pp. 1–6, 2021, doi: 10.1088/1757-899X/1049/1/012006.
- [28] F. Qiu *et al.*, “E-Learning Performance Prediction: Mining the Feature Space of Effective Learning Behavior,” *Entropy*, vol. 24, no. 5, pp. 1–22, 2022, doi: 10.3390/e24050722.
- [29] Y. Riahi, T. Saikouk, A. Gunasekaran, and I. Badraoui, “Artificial intelligence applications in supply chain: A descriptive bibliometric analysis and future research directions,” *Expert Syst Appl*, vol. 173, pp. 1–19, 2021, doi: 10.1016/j.eswa.2021.114702.
- [30] E. Alyahyan and D. Düstegör, “Predicting academic success in higher education: literature review and best practices,” *International Journal of Educational Technology in Higher Education*, vol. 17, no. 3, pp. 1–21, 2020, doi: 10.1186/s41239-020-0177-7.
- [31] S. Visalakshi and V. Radha, “A literature review of feature selection techniques and applications: Review of feature selection in data mining,” in *2014 IEEE International Conference on Computational Intelligence and Computing Research*, Coimbatore, India: IEEE, Dec. 2014, pp. 1–6. doi: 10.1109/ICCIIC.2014.7238499.
- [32] B. Prenkaj, P. Velardi, G. Stilo, D. Distante, and S. Faralli, “A Survey of Machine Learning Approaches for Student Dropout Prediction in Online Courses,” *ACM Comput Surv*, vol. 53, no. 3, pp. 1–34, 2021, doi: 10.1145/3388792.
- [33] P. Moriarty, “Modern Methods of Prediction,” *Encyclopedia*, vol. 3, pp. 520–529, 2023.

- [34] S. Kumar Basak, M. Wotto, and P. Bélanger, “E-learning, M-learning and D-learning: Conceptual definition and comparative analysis,” *E-Learning and Digital Media*, vol. 15, no. 4, pp. 191–216, 2018, doi: 10.1177/2042753018785180.
- [35] Z. Bezovski and S. Poorani, “The evolution of e-learning and new trends,” *Information and Knowledge Management*, vol. 6, no. 3, pp. 50–57, 2016.
- [36] M. Ilić, V. Mikić, L. Kopanja, and B. Vesin, “Gamification Effectiveness in e-Learning Systems,” in *12th International Conference on Applied Internet and Information Technologies - AIIT 2022*, Zrenjanin, 2022, pp. 136–142.
- [37] S. R. Thakkar and H. D. Joshi, “E-Learning Systems: A Review,” in *2015 IEEE Seventh International Conference on Technology for Education (T4E)*, Warangal, India: IEEE, 2015, pp. 37–40. doi: 10.1109/T4E.2015.6.
- [38] B. Vesin, “Personalizacija procesa elektronskog učenja u tutorskom sistemu primenom tehnologija semantičkog veba,” Doctoral dissertation, University of Novi Sad (Serbia), 2014.
- [39] N. L. Ramo, M. Lin, E. S. Hald, and A. Huang-Saad, “Synchronous vs. Asynchronous vs. Blended Remote Delivery of Introduction to Biomechanics Course,” *Biomed Eng Educ*, vol. 1, no. 1, pp. 61–66, 2021, doi: 10.1007/s43683-020-00009-w.
- [40] A. Qashou, “Influencing factors in M-learning adoption in higher education,” *Educ Inf Technol (Dordr)*, vol. 26, no. 2, pp. 1755–1785, 2021, doi: 10.1007/s10639-020-10323-z.
- [41] J.-A. Herrera-Bernal, D. del C. Ramírez-Hernández, and M.-S. Ramírez-Montoya, “Applied Competences for Students by Using M-Learning Devices in Higher Education,” in *Mobile Devices in Education*, IGI Global, 2020, pp. 44–67. doi: 10.4018/978-1-7998-1757-4.ch004.
- [42] D. A. Sizova, T. V. Sizova, and E. S. Adulova, “M-Learning as a New Interactive Technology in Education,” in *Proceedings of the International Scientific Conference “Digitalization of Education: History, Trends and Prospects” (DETP 2020)*, Paris, France: Atlantis Press, 2020, pp. 328–334. doi: 10.2991/assehr.k.200509.060.
- [43] S. Akhter, M. K. Javed, S. Q. Shah, and A. Javaid, “Highlighting the advantages and disadvantages of E-learning,” *Psychology and education*, vol. 58, no. 5, pp. 1607–1614, 2021.
- [44] Z. Akhmedova, “Disadvantages of electronic learning,” in *Current approaches and new research in modern sciences*, Krakow, 2023, pp. 99–109.
- [45] M. Bari, R. Djouab, and C. Phu Hoa, “Elearning current situation and emerging challenges,” *PEOPLE: International Journal of Social Sciences*, vol. 4, no. 2, pp. 97–109, 2018, doi: 10.20319/pijss.2018.42.97109.

- [46] N. Islam, M. Beer, and F. Slack, “E-learning challenges faced by academics in higher education,” *J Educ Train Stud*, vol. 3, no. 5, pp. 102–112, 2015.
- [47] K.-Y. Tang, C.-Y. Chang, and G.-J. Hwang, “Trends in artificial intelligence-supported e-learning: a systematic review and co-citation network analysis (1998–2019),” *Interactive Learning Environments*, vol. 31, no. 4, pp. 2134–2152, 2023, doi: 10.1080/10494820.2021.1875001.
- [48] M. Liu and D. Yu, “Towards intelligent E-learning systems,” *Educ Inf Technol (Dordr)*, vol. 28, no. 7, pp. 7845–7876, 2023, doi: 10.1007/s10639-022-11479-6.
- [49] E. FitzGerald, A. Jones, N. Kucirkova, and E. Scanlon, “A literature synthesis of personalised technology-enhanced learning: what works and why,” *Research in Learning Technology*, vol. 26, pp. 1–16, 2018, doi: 10.25304/rlt.v26.2095.
- [50] A. Klašnja-Milićević, B. Vesin, M. Ivanović, Z. Budimac, and L. C. Jain, *E-Learning Systems*, vol. 112. Cham: Springer International Publishing, 2017. doi: 10.1007/978-3-319-41163-7.
- [51] U. Markowska-Kaczmar, H. Kwasnicka, and M. Paradowski, “Intelligent Techniques in Personalization of Learning in e-Learning Systems,” in *Computational Intelligence for Technology Enhanced Learning. Studies in Computational Intelligence*, vol. 273, Berlin, Heidelberg: Springer, 2010, pp. 1–23. doi: 10.1007/978-3-642-11224-9\_1.
- [52] H. S. Alenezi and M. H. Faisal, “Utilizing crowdsourcing and machine learning in education: Literature review,” *Educ Inf Technol (Dordr)*, vol. 25, no. 4, pp. 2971–2986, 2020, doi: 10.1007/s10639-020-10102-w.
- [53] K. Chrysafiadi and M. Virvou, “Student modeling approaches: A literature review for the last decade,” *Expert Syst Appl*, vol. 40, no. 11, pp. 4715–4729, 2013, doi: 10.1016/j.eswa.2013.02.007.
- [54] D. Hooshyar, M. Pedaste, K. Saks, Ä. Leijen, E. Bardone, and M. Wang, “Open learner models in supporting self-regulated learning in higher education: A systematic literature review,” *Comput Educ*, vol. 154, 2020, doi: 10.1016/j.compedu.2020.103878.
- [55] M. Al-Razgan, A. S. Al-Khalifa, and H. S. Al-Khalifa, “Educational Data Mining: A Systematic Review of the Published Literature 2006–2013,” in *Proceedings of the First International Conference on Advanced Data and Information Engineering (DaEng-2013). Lecture Notes in Electrical Engineering*, vol. 285, T. Herawan, M. Deris, and J. Abawajy, Eds., Singapore: Springer, 2014, pp. 711–719. doi: 10.1007/978-981-4585-18-7\_80.
- [56] M. P. G. Martins, V. L. Migueis, and D. S. B. Fonseca, “Educational data mining: A literature review,” in *2018 13th Iberian Conference on Information Systems and Technologies (CISTI)*, Cáceres, Spain: IEEE, 2018, pp. 1–6. doi: 10.23919/CISTI.2018.8399281.

- [57] M. Dai, J.-L. Hung, X. Du, H. Tang, and H. Li, “Knowledge Tracing: A Review of Available Technologies,” *Journal of Educational Technology Development and Exchange*, vol. 14, no. 2, pp. 1–20, 2021, doi: 10.18785/jetde.1402.01.
- [58] S. K. Banihashem, K. Aliabadi, S. Pourroostaei Ardakani, A. Delaver, and M. Nili Ahmadabadi, “Learning analytics: A systematic literature review,” *Interdisciplinary Journal of Virtual Learning in Medical Sciences*, vol. 9, no. 2, pp. 1–10, 2018.
- [59] M. Soliman and C. Guetl, “Review and perspectives on intelligent multi-agent systems’ support for group learning,” in *Proceedings of ED-MEDIA 2010—world conference on educational multimedia, hypermedia & telecommunications*, Association for the Advancement of Computing in Education (AACE), 2010, pp. 2998–3006.
- [60] A. S. D. Martha and H. Santoso, “The Design and Impact of the Pedagogical Agent: A Systematic Literature Review,” *The Journal of Educators Online*, vol. 16, no. 1, pp. 1–15, 2019, doi: 10.9743/jeo.2019.16.1.8.
- [61] M. A. Tadlaoui, S. Aammou, M. Khaldi, and R. N. Carvalho, “Learner Modeling in Adaptive Educational Systems: A Comparative Study,” *International Journal of Modern Education and Computer Science*, vol. 8, no. 3, pp. 1–10, 2016.
- [62] H. Najafi, “Shareable Content Object Reference Model: A model for the production of electronic content for better learning,” *Education Strategies in Medical Sciences*, vol. 9, no. 5, pp. 335–350, 2016.
- [63] J. M. Kevan and P. R. Ryan, “Experience API: Flexible, Decentralized and Activity-Centric Data Collection,” *Technology, Knowledge and Learning*, vol. 21, no. 1, pp. 143–149, 2016, doi: 10.1007/s10758-015-9260-x.
- [64] C. Labba, A. Roussanaly, and A. Boyer, “An Operational Framework for Evaluating the Performance of Learning Record Stores,” vol. 12315, Cham: Springer, 2020, pp. 45–59. doi: 10.1007/978-3-030-57717-9\_4.
- [65] M. U. Ahmed, N. A. Sanhi, and A. Mahmood, “A Learner Model for Adaptable e-Learning,” *International Journal of Advanced Computer Science and Applications*, vol. 8, no. 6, pp. 139–147, 2017, doi: 10.14569/IJACSA.2017.080618.
- [66] A. Abyaa, M. Khalidi Idrissi, and S. Bennani, “Learner modelling: systematic review of the literature from the last 5 years,” *Educational Technology Research and Development*, vol. 67, no. 5, pp. 1105–1143, Oct. 2019, doi: 10.1007/s11423-018-09644-1.
- [67] J. Kay and S. Bull, “New Opportunities with Open Learner Models and Visual Learning Analytics,” in *Artificial Intelligence in Education*, C. Conati, N. Heffernan, A. Mitrovic, and M. F. Verdejo, Eds., Cham: Springer International Publishing, 2015, pp. 666–669.
- [68] L. Albó, J. Barria-Pineda, P. Brusilovsky, and D. Hernández-Leo, “Concept-Level Design Analytics for Blended Courses,” in *Transforming Learning with Meaningful Technologies*.

*EC-TEL 2019. Lecture Notes in Computer Science*, vol. 11722, M. Scheffel, J. Broisin, V. Pammer-Schindler, A. Ioannou, and J. Schneider, Eds., Cham: Springer, 2019, pp. 541–554. doi: 10.1007/978-3-030-29736-7\_40.

- [69] S. Bull, “There are Open Learner Models About!,” *IEEE Transactions on Learning Technologies*, vol. 13, no. 2, pp. 425–448, 2020, doi: 10.1109/TLT.2020.2978473.
- [70] R. Conejo, M. Trella, I. Cruces, and R. Garcia, “INGRID: A Web Service Tool for Hierarchical Open Learner Model Visualization,” in *Advances in User Modeling. UMAP 2011. Lecture Notes in Computer Science*, L. Ardissono and T. Kuflík, Eds., New York: Springer, 2012, pp. 406–409. doi: 10.1007/978-3-642-28509-7\_38.
- [71] S. Bull and J. Kay, “Open Learner Models,” in *Advances in Intelligent Tutoring Systems*, R. Nkambou, J. Bourdeau, and R. Mizoguchi, Eds., Berlin, Heidelberg: Springer Berlin Heidelberg, 2010, pp. 301–322. doi: 10.1007/978-3-642-14363-2\_15.
- [72] S. Bull, A. Mabbott, R. Johan, M. Johnson, K. Lee-Shim, and T. Lloyd, “Interfaces for Inspectable Learner Models,” Berlin, Heidelberg: Springer, 2010, pp. 275–277. doi: 10.1007/978-3-642-13437-1\_43.
- [73] C. Conati, K. Porayska-Pomsta, and M. Mavrikis, “AI in Education needs interpretable machine learning: Lessons from Open Learner Modelling,” *arXiv:1807.00154*, 2018.
- [74] A. Hamzah, “Learner’s Perception on Open Learner Model,” *International Journal of Modeling and Optimization*, vol. 8, no. 4, pp. 250–253, 2018, doi: 10.7763/IJMO.2018.V8.660.
- [75] R. M. Suleman, R. Mizoguchi, and M. Ikeda, “A New Perspective of Negotiation-Based Dialog to Enhance Metacognitive Skills in the Context of Open Learner Models,” *Int J Artif Intell Educ*, vol. 26, no. 4, pp. 1069–1115, 2016, doi: 10.1007/s40593-016-0118-8.
- [76] J. Kay and B. Kummersfeld, “From data to personal user models for life-long, life-wide learners,” *British Journal of Educational Technology*, vol. 50, no. 6, pp. 2871–2884, 2019, doi: 10.1111/bjet.12878.
- [77] D. Thomson and A. Mitrovic, “Towards a negotiable student model for constraint-based ITSS,” in *Proceedings of the 17th international conference on computers in education*, 2009, pp. 83–90.
- [78] K. A. Papanikolaou, “Constructing Interpretative Views of Learners’ Interaction Behavior in an Open Learner Model,” *IEEE Transactions on Learning Technologies*, vol. 8, no. 2, pp. 201–214, 2015, doi: 10.1109/TLT.2014.2363663.
- [79] B. Yousuf, A. Staikopoulos, and O. Conlan, “Motivating Students to Enhance Their Knowledge Levels Through Personalized and Scrutable Visual Narratives,” in *Lifelong Technology-Enhanced Learning. EC-TEL 2018. Lecture Notes in Computer Science*, vol. 11082, V. Pammer-Schindler, M. Pérez-Sanagustín, H. Drachsler, R. Elferink, and

M. Scheffel, Eds., Cham: Springer, 2018, pp. 136–150. doi: 10.1007/978-3-319-98572-5\_11.

- [80] M. D. Johnson, “Learners’ self-assessment and metacognition when using an open learner model with drill down,” PhD thesis, University of Birmingham, 2018.
- [81] S. Bull, B. Ginon, C. Boscolo, and M. Johnson, “Introduction of learning visualisations and metacognitive support in a persuadable open learner model,” in *Proceedings of the Sixth International Conference on Learning Analytics & Knowledge - LAK '16*, New York, New York, USA: ACM Press, 2016, pp. 30–39. doi: 10.1145/2883851.2883853.
- [82] E. Herder, S. Sosnovsky, and V. Dimitrova, “Adaptive Intelligent Learning Environments,” in *Technology Enhanced Learning*, E. Duval, M. Sharples, and R. Sutherland, Eds., Cham: Springer, 2017, pp. 109–114. doi: 10.1007/978-3-319-02600-8\_10.
- [83] D. Zapata-Rivera, “Open Student Modeling Research and its Connections to Educational Assessment,” *Int J Artif Intell Educ*, vol. 31, no. 3, pp. 380–396, 2021, doi: 10.1007/s40593-020-00206-2.
- [84] S. Bull, “Negotiated learner modelling to maintain today’s learner models,” *Res Pract Technol Enhanc Learn*, vol. 11, no. 10, pp. 1–29, 2016, doi: 10.1186/s41039-016-0035-3.
- [85] S. Bull, M. D. Johnson, D. Masci, and C. Biel, “Integrating and Visualising Diagnostic Information for the Benefit of Learning,” in *Measuring and Visualizing Learning in the Information-Rich Classroom*, P. Reimann, S. Bull, M. Kickmeier-Rust, R. Kiran Vatrapu, and B. Wasson, Eds., Abingdon: Routledge, 2015, pp. 183–196.
- [86] V. Dimitrova and P. Brna, “From Interactive Open Learner Modelling to Intelligent Mentoring: STyle-OLM and Beyond,” *Int J Artif Intell Educ*, vol. 26, no. 1, pp. 332–349, 2016, doi: 10.1007/s40593-015-0087-3.
- [87] A. Mitrović and J. Holland, “Effect of Non-mandatory Use of an Intelligent Tutoring System on Students’ Learning,” in *International conference on artificial intelligence in education*, New York: Springer, 2020, pp. 386–397. doi: 10.1007/978-3-030-52237-7\_31.
- [88] J. Guerra, C. D. Schunn, S. Bull, J. Barria-Pineda, and P. Brusilovsky, “Navigation support in complex open learner models: assessing visual design alternatives,” *New Review of Hypermedia and Multimedia*, vol. 24, no. 3, pp. 160–192, 2018, doi: 10.1080/13614568.2018.1482375.
- [89] M. I. El Agha, A. M. Jarghon, and S. S. Abu-Naser, “Sql tutor for novice students,” *International Journal of Academic Information Systems Research*, vol. 2, no. 2, pp. 1–7, 2018.
- [90] R. B. Kaliwal and S. L. Deshpande, “Design of intelligent e-learning assessment framework using Bayesian belief network,” *Journal of Engineering Education Transformations*, vol. 34, pp. 651–658, 2021.

- [91] S. Ben Salem, L. Cheniti-Belcadhi, and R. Braham, “A concept map based scenario for assessment of short and open answer questions,” in *2017 International Conference on Engineering & MIS (ICEMIS)*, Monastir, Tunisia: IEEE, 2017, pp. 1–7. doi: 10.1109/ICEMIS.2017.8273011.
- [92] P. Brusilovsky, I.-H. Hsiao, and Y. Folajimi, “QuizMap: Open Social Student Modeling and Adaptive Navigation Support with TreeMaps,” in *Towards Ubiquitous Learning. EC-TEL 2011. Lecture Notes in Computer Science*, vol. 6964, C. D. Kloos, D. Gillet, R. M. Crespo García, F. Wild, and M. Wolpers, Eds., Berlin: Springer, 2011, pp. 71–82. doi: 10.1007/978-3-642-23985-4\_7.
- [93] L. Mazzola and R. Mazza, “GVIS: A Facility for Adaptively Mashing Up and Representing Open Learner Models,” in *Sustaining TEL: From Innovation to Learning and Practice. EC-TEL 2010. Lecture Notes in Computer Science*, vol. 6383, M. Wolpers, P. A. Kirschner, M. Scheffel, S. Lindstaedt, and V. Dimitrova, Eds., New York: Springer, 2010, pp. 554–559. doi: 10.1007/978-3-642-16020-2\_53.
- [94] P. Brusilovsky and M. V. Yudelson, “From WebEx to NavEx: Interactive Access to Annotated Program Examples,” *Proceedings of the IEEE*, vol. 96, no. 6, pp. 990–999, 2008, doi: 10.1109/JPROC.2008.921611.
- [95] I.-H. Hsiao, F. Bakalov, P. Brusilovsky, and B. König-Ries, “Progressor: social navigation support through open social student modeling,” *New Review of Hypermedia and Multimedia*, vol. 19, no. 2, pp. 112–131, 2013, doi: 10.1080/13614568.2013.806960.
- [96] A. Jones, “Adaptive robotic tutors for scaffolding self-regulated learning,” PhD thesis, University of Birmingham, 2018.
- [97] S. Bull and M. McKay, “An Open Learner Model for Children and Teachers: Inspecting Knowledge Level of Individuals and Peers,” in *Intelligent Tutoring Systems. ITS 2004. Lecture Notes in Computer Science*, vol. 3220, J. C. Lester, R. M. Vicari, and F. Paraguacu, Eds., Berlin, Heidelberg: Springer, 2004, pp. 646–655. doi: 10.1007/978-3-540-30139-4\_61.
- [98] S. J. Lee and S. Bull, “An open learner model to help parents help their children,” *Technology Instruction Cognition and Learning*, vol. 6, no. 1, pp. 29–51, 2008.
- [99] H. E. Murphy, “Digitalizing paper-based exams: an assessment of programming grading assistant,” in *Proceedings of the 2017 ACM SIGCSE Technical Symposium on Computer Science Education*, New York, NY, USA: ACM, 2017, pp. 775–776. doi: 10.1145/3017680.3022448.
- [100] C.-Y. Law, J. Grundy, A. Cain, R. Vasa, and A. Cummaudo, “User Perceptions of Using an Open Learner Model Visualisation Tool for Facilitating Self-regulated Learning,” in *Proceedings of the Nineteenth Australasian Computing Education Conference*, New York, NY, USA: ACM, 2017, pp. 55–64. doi: 10.1145/3013499.3013502.

- [101] J. P. Martínez Bastida, O. Havrykenko, and A. Chukhray, “Developing a Self-regulation Environment in an Open Learning Model with Higher Fidelity Assessment,” in *Information and Communication Technologies in Education, Research, and Industrial Applications. ICTERI 2017. Communications in Computer and Information Science*, vol. 826, N. Bassiliades, Ed., Cham: Springer, 2018, pp. 112–131. doi: 10.1007/978-3-319-76168-8\_6.
- [102] A. Leonardou, M. Rigou, and J. Garofalakis, “Opening User Model Data for Motivation and Learning: The Case of an Adaptive Multiplication Game,” in *Proceedings of the 11th International Conference on Computer Supported Education*, Heraklion, Crete, Greece: SCITEPRESS - Science and Technology Publications, 2019, pp. 383–390. doi: 10.5220/0007735603830390.
- [103] A. J. Hampton, B. D. Nye, P. I. Pavlik, W. R. Swartout, A. C. Graesser, and J. Gunderson, “Mitigating Knowledge Decay from Instruction with Voluntary Use of an Adaptive Learning System,” in *Artificial Intelligence in Education. AIED 2018. Lecture Notes in Computer Science*, vol. 10948, C. Penstein Rosé, Ed., Cham: Springer, 2018, pp. 119–133. doi: 10.1007/978-3-319-93846-2\_23.
- [104] L. Shi and A. I. Cristea, “Learners Thrive Using Multifaceted Open Social Learner Modeling,” *IEEE MultiMedia*, vol. 23, no. 1, pp. 36–47, 2016, doi: 10.1109/MMUL.2015.93.
- [105] R. Nakahashi and S. Yamada, “Balancing Performance and Human Autonomy With Implicit Guidance Agent,” *Front Artif Intell*, vol. 4, pp. 1–9, Sep. 2021, doi: 10.3389/frai.2021.736321.
- [106] D. Zapata-Rivera, E. Hansen, V. J. Shute, J. S. Underwood, and M. Bauer, “Evidence-based Approach to Interacting with Open Student Models,” *Int J Artif Intell Educ*, vol. 17, no. 3, pp. 273–303, 2007.
- [107] A. Dutt, M. A. Ismail, and T. Herawan, “A Systematic Review on Educational Data Mining,” *IEEE Access*, vol. 5, pp. 15991–16005, 2017, doi: 10.1109/ACCESS.2017.2654247.
- [108] S. Slater, S. Joksimović, V. Kovanovic, R. S. Baker, and D. Gasevic, “Tools for Educational Data Mining,” *Journal of Educational and Behavioral Statistics*, vol. 42, no. 1, pp. 85–106, 2017, doi: 10.3102/1076998616666808.
- [109] M. Bienkowski, M. Feng, and B. Means, “Enhancing Teaching and Learning Through Educational Data Mining and Learning Analytics: An Issue Brief,” Washington, 2012.
- [110] K. Grigorova, E. Malysheva, and S. Bobrovskiy, “Application of data mining and process mining approaches for improving e-learning processes,” in *3rd international conference on information technology and nanotechnology*, 2017, pp. 1952–1958.

- [111] Y. Wang and H.-C. Liao, “Data mining for adaptive learning in a TESL-based e-learning system,” *Expert Syst Appl*, vol. 38, no. 6, pp. 6480–6485, 2011, doi: 10.1016/j.eswa.2010.11.098.
- [112] L. Paquette, J. Ocumpaugh, Z. Li, A. Andres, and R. Baker, “Who’s Learning? Using Demographics in EDM Research,” *Journal of Educational Data Mining*, vol. 12, no. 3, pp. 1–30, 2020.
- [113] M. Köck and A. Paramythios, “Activity sequence modelling and dynamic clustering for personalized e-learning,” *User Model User-adapt Interact*, vol. 21, pp. 51–97, 2011, doi: 10.1007/s11257-010-9087-z.
- [114] D. Suresh and S. Prakasam, “The Impact of E-learning system using Rank-based Clustering Algorithm (ESURBCA),” *Int J Comput Appl*, vol. 83, no. 7, pp. 13–18, 2013, doi: 10.5120/14459-2733.
- [115] M. Man, W. A. W. A. Bakar, and I. A. A. Sabri, “An Association Rule on eDisiplin Case Study: An Educational Data Mining Approach,” *Adv Sci Lett*, vol. 24, no. 3, pp. 1872–1875, 2018, doi: 10.1166/asl.2018.11179.
- [116] S. Ougiaroglou and G. Paschalis, “Association Rules Mining from the Educational Data of ESOG Web-Based Application,” in *Artificial Intelligence Applications and Innovations. AIAI 2012. IFIP Advances in Information and Communication Technology*, vol. 382, L. Iliadis, I. Maglogiannis, H. Papadopoulos, K. Karatzas, and S. Sioutas, Eds., Berlin: Springer, 2012, pp. 105–114. doi: 10.1007/978-3-642-33412-2\_11.
- [117] W.-C. Shih, “Mining Sequential Patterns to Explore Users’ Learning Behavior in a Visual Programming App,” in *2018 IEEE 42nd Annual Computer Software and Applications Conference (COMPSAC)*, Tokyo, Japan: IEEE, Jul. 2018, pp. 126–129. doi: 10.1109/COMPSAC.2018.10216.
- [118] K. E. Arnold and M. D. Pistilli, “Course signals at Purdue,” in *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge*, New York, NY, USA: ACM, 2012, pp. 267–270. doi: 10.1145/2330601.2330666.
- [119] R. J. Mislevy, J. T. Behrens, K. E. Dicerbo, and R. Levy, “Design and discovery in educational assessment: Evidence-centered design, psychometrics, and educational data mining,” *Journal of educational data mining*, vol. 4, no. 1, pp. 11–48, 2012.
- [120] A. Bilal Zorić, “Benefits of Educational Data Mining,” *Journal of International Business Research and Marketing*, vol. 6, no. 1, pp. 12–16, 2020, doi: 10.18775/jibrm.1849-8558.2015.61.3002.
- [121] C. Piech *et al.*, “Deep knowledge tracing,” in *Proceedings of the 28th international conference on neural information processing systems*, 2015, pp. 505–513.

- [122] Y. Gong, J. E. Beck, and N. T. Heffernan, “Comparing Knowledge Tracing and Performance Factor Analysis by Using Multiple Model Fitting Procedures,” Berlin, Heidelberg: Springer, 2010, pp. 35–44. doi: 10.1007/978-3-642-13388-6\_8.
- [123] H. Yang and L. P. Cheung, “Implicit Heterogeneous Features Embedding in Deep Knowledge Tracing,” *Cognit Comput*, vol. 10, no. 1, pp. 3–14, 2018, doi: 10.1007/s12559-017-9522-0.
- [124] J. Rowe and J. Lester, “Modeling User Knowledge with Dynamic Bayesian Networks in Interactive Narrative Environments,” *Proceedings of the AAAI Conference on Artificial Intelligence and Interactive Digital Entertainment*, vol. 6, no. 1, pp. 57–62, 2010, doi: 10.1609/aiide.v6i1.12403.
- [125] Z. A. Pardos and N. T. Heffernan, “Modeling Individualization in a Bayesian Networks Implementation of Knowledge Tracing,” in *User Modeling, Adaptation, and Personalization. UMAP 2010. Lecture Notes in Computer Science*, vol. 6075, P. De Bra, A. Kobsa, and D. Chin, Eds., Berlin, Heidelberg: Springer, 2010, pp. 255–266. doi: 10.1007/978-3-642-13470-8\_24.
- [126] Z. Pardos, Y. Bergner, D. Seaton, and D. Pritchard, “Adapting bayesian knowledge tracing to a massive open online course in edx,” in *Proceedings of the 6th international conference on educational data mining*, 2013, pp. 137–144.
- [127] Z. Wang, J. Zhu, X. Li, Z. Hu, and M. Zhang, “Structured Knowledge Tracing Models for Student Assessment on Coursera,” in *Proceedings of the Third (2016) ACM Conference on Learning @ Scale*, New York, NY, USA: ACM, 2016, pp. 209–212. doi: 10.1145/2876034.2893416.
- [128] T. Schodde, K. Bergmann, and S. Kopp, “Adaptive Robot Language Tutoring Based on Bayesian Knowledge Tracing and Predictive Decision-Making,” in *Proceedings of the 2017 ACM/IEEE International Conference on Human-Robot Interaction*, New York, NY, USA: ACM, 2017, pp. 128–136. doi: 10.1145/2909824.3020222.
- [129] D. Hooshyar, R. B. Ahmad, M. Yousefi, M. Fathi, S.-J. Horng, and H. Lim, “SITS: A solution-based intelligent tutoring system for students’ acquisition of problem-solving skills in computer programming,” *Innovations in Education and Teaching International*, vol. 55, no. 3, pp. 325–335, 2018, doi: 10.1080/14703297.2016.1189346.
- [130] B.-H. Kim, E. Vizitei, and V. Ganapathi, “GritNet: Student performance prediction with deep learning,” *arXiv preprint arXiv:1804.07405*, 2018.
- [131] J. Zhang, X. Shi, I. King, and D.-Y. Yeung, “Dynamic Key-Value Memory Networks for Knowledge Tracing,” in *Proceedings of the 26th International Conference on World Wide Web*, Republic and Canton of Geneva, Switzerland: International World Wide Web Conferences Steering Committee, 2017, pp. 765–774. doi: 10.1145/3038912.3052580.

- [132] X. Sun, X. Zhao, B. Li, Y. Ma, R. Sutcliffe, and J. Feng, “Dynamic Key-Value Memory Networks With Rich Features for Knowledge Tracing,” *IEEE Trans Cybern*, vol. 52, no. 8, pp. 8239–8245, 2022, doi: 10.1109/TCYB.2021.3051028.
- [133] G. Abdelrahman and Q. Wang, “Knowledge Tracing with Sequential Key-Value Memory Networks,” in *Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*, New York, NY, USA: ACM, 2019, pp. 175–184. doi: 10.1145/3331184.3331195.
- [134] P. I. Pavlik Jr, H. Cen, and K. R. Koedinger, “Performance Factors Analysis - A New Alternative to Knowledge Tracing,” in *Proceedings of the 14th international conference on artificial intelligence in education*, 2009, pp. 531–538.
- [135] S. Pu, G. Converse, and Y. Huang, “Deep Performance Factors Analysis for Knowledge Tracing,” in *International Conference on Artificial Intelligence in Education*, Cham: Springer, 2021, pp. 331–341. doi: 10.1007/978-3-030-78292-4\_27.
- [136] P. Chen, Y. Lu, V. W. Zheng, and Y. Pian, “Prerequisite-Driven Deep Knowledge Tracing,” in *2018 IEEE International Conference on Data Mining (ICDM)*, IEEE, 2018, pp. 39–48. doi: 10.1109/ICDM.2018.00019.
- [137] J. González-Brenes, Y. Huang, and P. Brusilovsky, “General features in knowledge tracing to model multiple subskills, temporal item response theory, and expert knowledge,” in *The 7th international conference on educational data mining*, University of Pittsburgh, 2014, pp. 84–91.
- [138] S. Pandey and G. Karypis, “A Self-Attentive model for Knowledge Tracing,” in *Proceedings of the 12th International Conference on Educational Data Mining*, Montreal: International Educational Data Mining Society, 2019, pp. 384–389.
- [139] P. Penmetsa, “Investigate effectiveness of code features in knowledge tracing task on novice programming course,” North Carolina State University, 2021.
- [140] G. Casalino, L. Grilli, P. Limone, D. Santoro, and D. Schicchi, “Deep learning for knowledge tracing in learning analytics: an overview,” in *Proceedings of third workshop of technology enhanced learning environments for blended education - the Italian e-Learning conference*, CEUR-WS, 2021, pp. 1–10.
- [141] S. Shen *et al.*, “Learning Process-consistent Knowledge Tracing,” in *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*, New York, NY, USA: ACM, 2021, pp. 1452–1460. doi: 10.1145/3447548.3467237.
- [142] Á. F. Agudo-Peregrina, S. Iglesias-Pradas, M. Á. Conde-González, and Á. Hernández-García, “Can we predict success from log data in VLEs? Classification of interactions for learning analytics and their relation with performance in VLE-supported F2F and online learning,” *Comput Human Behav*, vol. 31, pp. 542–550, 2014, doi: 10.1016/j.chb.2013.05.031.

- [143] A. del Blanco, A. Serrano, M. Freire, I. Martinez-Ortiz, and B. Fernandez-Manjon, “E-Learning standards and learning analytics. Can data collection be improved by using standard data models?,” in *2013 IEEE Global Engineering Education Conference (EDUCON)*, Berlin, Germany: IEEE, 2013, pp. 1255–1261. doi: 10.1109/EduCon.2013.6530268.
- [144] C. Romero and S. Ventura, “Educational data mining and learning analytics: An updated survey,” *WIREs Data Mining and Knowledge Discovery*, vol. 10, no. 3, pp. 1–21, 2020, doi: 10.1002/widm.1355.
- [145] D. Camacho, Á. Panizo-LLedot, G. Bello-Orgaz, A. Gonzalez-Pardo, and E. Cambria, “The four dimensions of social network analysis: An overview of research methods, applications, and software tools,” *Information Fusion*, vol. 63, pp. 88–120, 2020, doi: 10.1016/j.inffus.2020.05.009.
- [146] E. Otte and R. Rousseau, “Social network analysis: a powerful strategy, also for the information sciences,” *J Inf Sci*, vol. 28, no. 6, pp. 441–453, 2002, doi: 10.1177/016555150202800601.
- [147] B. Wibawa, J. S. Siregar, D. A. Asrorie, and H. Syakdiyah, “Learning analytic and educational data mining for learning science and technology,” in *AIP conference proceedings*, AIP Publishing, 2021, pp. 1–7. doi: 10.1063/5.0041844.
- [148] R. M. Bethea and R. R. Rhinehart, *Applied Engineering Statistics*. Boca Raton: Routledge, 2019. doi: 10.1201/9781315137605.
- [149] P. Leitner, M. Khalil, and M. Ebner, “Learning Analytics in Higher Education - A Literature Review,” in *Learning Analytics: Fundaments, Applications, and Trends. Studies in Systems, Decision and Control*, vol. 94, A. Peña-Ayala, Ed., Cham: Springer, 2017, ch. 1, pp. 1–23. doi: 10.1007/978-3-319-52977-6\_1.
- [150] B. A. Schwendimann *et al.*, “Perceiving Learning at a Glance: A Systematic Literature Review of Learning Dashboard Research,” *IEEE Transactions on Learning Technologies*, vol. 10, no. 1, pp. 30–41, 2017, doi: 10.1109/TLT.2016.2599522.
- [151] K. Verbert *et al.*, “Learning dashboards: an overview and future research opportunities,” *Pers Ubiquitous Comput*, vol. 18, pp. 1499–1514, 2014, doi: 10.1007/s00779-013-0751-2.
- [152] J. Kim, I.-H. Jo, and Y. Park, “Effects of learning analytics dashboard: analyzing the relations among dashboard utilization, satisfaction, and learning achievement,” *Asia Pacific Education Review*, vol. 17, no. 1, pp. 13–24, 2016, doi: 10.1007/s12564-015-9403-8.
- [153] R. Bodily *et al.*, “Open learner models and learning analytics dashboards,” in *Proceedings of the 8th International Conference on Learning Analytics and Knowledge*, New York, NY, USA: ACM, 2018, pp. 41–50. doi: 10.1145/3170358.3170409.

- [154] S. Shehata and K. E. Arnold, “Measuring student success using predictive engine,” in *Proceedings of the Fifth International Conference on Learning Analytics And Knowledge*, New York, NY, USA: ACM, 2015, pp. 416–417. doi: 10.1145/2723576.2723661.
- [155] D. Olivares, O. Adesope, C. Hundhausen, R. Ferreira, V. Rolim, and D. Gasevic, “Using Social Network Analysis to Measure the Effect of Learning Analytics in Computing Education,” in *2019 IEEE 19th International Conference on Advanced Learning Technologies (ICALT)*, IEEE, 2019, pp. 145–149. doi: 10.1109/ICALT.2019.00044.
- [156] C. Herodotou, B. Rienties, M. Hlosta, A. Boroowa, C. Mangafa, and Z. Zdrahal, “The scalable implementation of predictive learning analytics at a distance learning university: Insights from a longitudinal case study,” *Internet High Educ*, vol. 45, 2020, doi: 10.1016/j.iheduc.2020.100725.
- [157] K. Muldner, M. Wixon, D. Rai, W. Burleson, B. Woolf, and I. Arroyo, “Exploring the Impact of a Learning Dashboard on Student Affect,” in *Artificial Intelligence in Education. AIED 2015. Lecture Notes in Computer Science*, C. Conati, N. Heffernan, A. Mitrovic, and M. F. Verdejo, Eds., Cham: Springer, 2015, pp. 307–317. doi: 10.1007/978-3-319-19773-9\_31.
- [158] H. B. Santoso, A. K. Batuparan, R. Y. K. Asal, and W. H. Goodridge, “The Development of a Learning Dashboard for Lecturers: A Case Study on a Student Centered E-Learning Environment,” *Journal of Educators Online*, vol. 15, no. 1, pp. 76–89, 2018, doi: 10.9743/JEO.2018.1.1.
- [159] M. Furukawa, K. Yamaji, Y. Yaginuma, and T. Yamada, “Development of learning analytics platform for OUJ online courses,” in *2017 IEEE 6th Global Conference on Consumer Electronics (GCCE)*, Nagoya, Japan: IEEE, 2017, pp. 557–558. doi: 10.1109/GCCE.2017.8229454.
- [160] D. Wang and H. Han, “Applying learning analytics dashboards based on process-oriented feedback to improve students’ learning effectiveness,” *J Comput Assist Learn*, vol. 37, no. 2, pp. 487–499, 2021, doi: 10.1111/jcal.12502.
- [161] A. Ramos-Soto, B. Vazquez-Barreiros, A. Bugarín, A. Gewerc, and S. Barro, “Evaluation of a Data-To-Text System for Verbalizing a Learning Analytics Dashboard,” *International Journal of Intelligent Systems*, vol. 32, no. 2, pp. 177–193, 2017, doi: 10.1002/int.21835.
- [162] S. Knight, A. Gibson, and A. Shibani, “Implementing learning analytics for learning impact: Taking tools to task,” *Internet High Educ*, vol. 45, 2020, doi: 10.1016/j.iheduc.2020.100729.
- [163] W. Matcha, D. Gašević, N. A. Uzir, J. Jovanović, and A. Pardo, “Analytics of Learning Strategies: Associations with Academic Performance and Feedback,” in *Proceedings of the*

*9th International Conference on Learning Analytics & Knowledge*, New York, NY, USA: ACM, 2019, pp. 461–470. doi: 10.1145/3303772.3303787.

- [164] J. Jovanović, D. Gašević, S. Dawson, A. Pardo, and N. Mirriahi, “Learning analytics to unveil learning strategies in a flipped classroom,” *Internet High Educ*, vol. 33, no. 4, pp. 74–85, 2017, doi: 10.1016/j.iheduc.2017.02.001.
- [165] M. K. Khalil and I. A. Elkhider, “Applying learning theories and instructional design models for effective instruction,” *Adv Physiol Educ*, vol. 40, no. 2, pp. 147–156, 2016, doi: 10.1152/advan.00138.2015.
- [166] D. Ifenthaler, “Are Higher Education Institutions Prepared for Learning Analytics?,” *TechTrends*, vol. 61, no. 4, pp. 366–371, 2017, doi: 10.1007/s11528-016-0154-0.
- [167] L. Lockyer and S. Dawson, “Learning designs and learning analytics,” in *Proceedings of the 1st International Conference on Learning Analytics and Knowledge*, New York, NY, USA: ACM, 2011, pp. 153–156. doi: 10.1145/2090116.2090140.
- [168] E. Triantafillou, E. Georgiadou, and A. A. Economides, “The design and evaluation of a computerized adaptive test on mobile devices,” *Comput Educ*, vol. 50, no. 4, pp. 1319–1330, 2008, doi: 10.1016/j.compedu.2006.12.005.
- [169] R. Raman and P. Nedungadi, “Performance improvements in schools with Adaptive Learning and Assessment,” in *2010 4th International Conference on Distance Learning and Education*, IEEE, 2010, pp. 10–14. doi: 10.1109/ICDLE.2010.5606052.
- [170] L. Cai, K. Choi, M. Hansen, and L. Harrell, “Item response theory,” *Annu Rev Stat Appl*, vol. 3, pp. 297–321, 2016.
- [171] M. Pankiewicz and M. Bator, “Elo Rating Algorithm for the Purpose of Measuring Task Difficulty in Online Learning Environments,” *e-mentor*, vol. 5, no. 82, pp. 43–51, 2019, doi: 10.15219/em82.1444.
- [172] J. Y. Park, S.-H. Joo, F. Cornillie, H. L. J. van der Maas, and W. Van den Noortgate, “An explanatory item response theory method for alleviating the cold-start problem in adaptive learning environments,” *Behav Res Methods*, vol. 51, no. 2, pp. 895–909, 2019, doi: 10.3758/s13428-018-1166-9.
- [173] R. Herbrich, T. Minka, and T. Graepel, “TrueSkill<sup>TM</sup>: a Bayesian skill rating system,” in *Proceedings of the 19th international conference on neural information processing systems*, 2006, pp. 569–576.
- [174] Y. Lee, “Estimating student ability and problem difficulty using item response theory (IRT) and TrueSkill,” *Inf Discov Deliv*, vol. 47, no. 2, pp. 67–75, 2019, doi: 10.1108/IDD-08-2018-0030.

- [175] Ö. Özyurt, H. Özyurt, B. Güven, and A. Baki, “The effects of UZWEBMAT on the probability unit achievement of Turkish eleventh grade students and the reasons for such effects,” *Comput Educ*, vol. 75, pp. 1–18, 2014, doi: 10.1016/j.compedu.2014.02.005.
- [176] S. Oppl, F. Reisinger, A. Eckmaier, and C. Helm, “A flexible online platform for computerized adaptive testing,” *International Journal of Educational Technology in Higher Education*, vol. 14, no. 1, pp. 1–21, 2017, doi: 10.1186/s41239-017-0039-0.
- [177] G. Gutjahr, K. Menon, and P. Nedungadi, “Using an Intelligent Tutoring System to Predict Mathematics and English Assessments,” in *2017 5th IEEE International Conference on MOOCs, Innovation and Technology in Education (MITE)*, IEEE, 2017, pp. 135–140. doi: 10.1109/MITE.2017.00030.
- [178] R. Conejo, B. Barros, and M. F. Bertoia, “Automated Assessment of Complex Programming Tasks Using SIETTE,” *IEEE Transactions on Learning Technologies*, vol. 12, no. 4, pp. 470–484, 2019, doi: 10.1109/TLT.2018.2876249.
- [179] A. Bernardi *et al.*, “On the Design and Development of an Assessment System with Adaptive Capabilities,” in *Methodologies and Intelligent Systems for Technology Enhanced Learning, 8th International Conference*, Cham: Springer, 2019, pp. 190–199. doi: 10.1007/978-3-319-98872-6\_23.
- [180] C.-M. Chen, L.-C. Chen, and S.-M. Yang, “An English vocabulary learning app with self-regulated learning mechanism to improve learning performance and motivation,” *Comput Assist Lang Learn*, vol. 32, no. 3, pp. 237–260, 2019, doi: 10.1080/09588221.2018.1485708.
- [181] M. Uto, D.-T. Nguyen, and M. Ueno, “Group Optimization to Maximize Peer Assessment Accuracy Using Item Response Theory and Integer Programming,” *IEEE Transactions on Learning Technologies*, vol. 13, no. 1, pp. 91–106, 2020, doi: 10.1109/TLT.2019.2896966.
- [182] D. Ferjaoui and L. Cheniti Belcadhi, “A Conceptual Model for Personalized Learning based on Educational Robots,” in *Eighth International Conference on Technological Ecosystems for Enhancing Multiculturality*, New York, NY, USA: ACM, 2020, pp. 29–33. doi: 10.1145/3434780.3436609.
- [183] J. Jia and H. Le, “The Design and Implementation of a Computerized Adaptive Testing System for School Mathematics Based on Item Response Theory,” in *Technology in Education. Innovations for Online Teaching and Learning. ICTE 2020. Communications in Computer and Information Science*, vol. 1302, L.-K. Lee, L. Hou U, F. L. Wang, S. K. S. Cheung, O. Au, and K. C. Li, Eds., Singapore: Springer, 2020, pp. 100–111. doi: 10.1007/978-981-33-4594-2\_9.
- [184] K. Mangaroska, O. Özgöbek, B. Vesin, and M. Giannakos, “Implementation of elo-rating method in recommending coding exercises to programming students,” in *Norsk Konferanse for Organisasjoners Bruk av IT*, 2018, pp. 1–3.

- [185] M. J. S. Brinkhuis, A. O. Savi, A. D. Hofman, F. Coomans, H. L. J. Van der Maas, and G. Maris, “Learning As It Happens: A Decade of Analyzing and Shaping a Large-Scale Online Learning System,” *Journal of Learning Analytics*, vol. 5, no. 2, pp. 29–46, 2018, doi: 10.18608/jla.2018.52.3.
- [186] O. H. Dahl and O. Fykse, “Combining elo rating and collaborative filtering to improve learner ability estimation in an e-learning context,” Master’s thesis, NTNU, 2018.
- [187] M. Yudelson, Y. Rosen, S. Polyak, and J. de la Torre, “Leveraging Skill Hierarchy for Multi-Level Modeling with Elo Rating System,” in *Proceedings of the Sixth (2019) ACM Conference on Learning @ Scale*, New York, NY, USA: ACM, 2019, pp. 1–4. doi: 10.1145/3330430.3333645.
- [188] C. Kawatsu, R. Hubal, and R. P. Marinier, “Predicting Students’ Decisions in a Training Simulation: A Novel Application of TrueSkill,” *IEEE Trans Games*, vol. 10, no. 1, pp. 97–100, 2018, doi: 10.1109/TCIAIG.2017.2680843.
- [189] V. Mikić, M. Ilić, L. Kopanja, and B. Vesin, “Personalisation methods in e-learning - A literature review,” *Computer Applications in Engineering Education*, vol. 30, no. 6, pp. 1931–1958, 2022, doi: 10.1002/cae.22566.
- [190] Q. Zhang, J. Lu, and G. Zhang, “Recommender Systems in E-learning,” *Journal of Smart Environments and Green Computing*, vol. 1, no. 2, pp. 76–89, 2022, doi: 10.20517/jsegc.2020.06.
- [191] J. K. Tarus, Z. Niu, and D. Kalui, “A hybrid recommender system for e-learning based on context awareness and sequential pattern mining,” *Soft comput*, vol. 22, no. 8, pp. 2449–2461, 2018, doi: 10.1007/s00500-017-2720-6.
- [192] L. Ren and W. Wang, “An SVM-based collaborative filtering approach for Top-N web services recommendation,” *Future Generation Computer Systems*, vol. 78, pp. 531–543, 2018, doi: 10.1016/j.future.2017.07.027.
- [193] J. Xiao, M. Wang, B. Jiang, and J. Li, “A personalized recommendation system with combinational algorithm for online learning,” *J Ambient Intell Humaniz Comput*, vol. 9, no. 3, pp. 667–677, 2018, doi: 10.1007/s12652-017-0466-8.
- [194] J. K. Tarus, Z. Niu, and A. Yousif, “A hybrid knowledge-based recommender system for e-learning based on ontology and sequential pattern mining,” *Future Generation Computer Systems*, vol. 72, pp. 37–48, 2017, doi: 10.1016/j.future.2017.02.049.
- [195] P. Lops, M. de Gemmis, and G. Semeraro, “Content-based Recommender Systems: State of the Art and Trends,” in *Recommender Systems Handbook*, F. Ricci, L. Rokach, B. Shapira, and P. B. Kantor, Eds., Boston, MA: Springer US, 2011, pp. 73–105. doi: 10.1007/978-0-387-85820-3\_3.

- [196] D. M. Kandakatla and K. Bandi, “A content based filtering and negative rating recommender system for e-learning management system,” in *Proceedings of the International Conference on Intelligent Computing and Sustainable System (ICICSS 2018)*, 2018, pp. 167–172.
- [197] M. Hiles and M. Agha, “Knowledge-based its for teaching mongo database,” *Eur Acad Res*, vol. 4, no. 10, pp. 8783–8794, 2017.
- [198] I. A. El Haddad and S. S. A. Naser, “Ado-tutor: intelligent tutoring system for leaning ado.net,” *Eur Acad Res*, vol. 4, no. 10, pp. 8810–8821, 2017.
- [199] M. W. Alawar and S. S. A. Naser, “CSS-Tutor: An intelligent tutoring system for CSS and HTML,” *Int J Acad Res Dev*, vol. 2, no. 1, pp. 94–98, 2017.
- [200] H. Samin and T. Azim, “Knowledge Based Recommender System for Academia Using Machine Learning: A Case Study on Higher Education Landscape of Pakistan,” *IEEE Access*, vol. 7, pp. 67081–67093, 2019, doi: 10.1109/ACCESS.2019.2912012.
- [201] D. K. Wind, R. M. Jørgensen, and S. L. Hansen, “Peer feedback with peergrade,” in *ICEL 2018 13th International Conference on e-Learning*, Academic Conferences and publishing limited, 2018, pp. 184–192.
- [202] L. A. Alvarez-Gonzalez, M. Lemarie, and P. Bello, “Using LAMS to support engineering student learning: Two case studies,” in *2017 IEEE Global Engineering Education Conference (EDUCON)*, IEEE, 2017, pp. 275–280. doi: 10.1109/EDUCON.2017.7942859.
- [203] F. Chen and Y. Cui, “LogCF: Deep Collaborative Filtering with Process Data for Enhanced Learning Outcome Modeling,” *Journal of Educational Data Mining*, vol. 12, no. 4, pp. 66–99, 2020.
- [204] W. Chen, Z. Niu, X. Zhao, and Y. Li, “A hybrid recommendation algorithm adapted in e-learning environments,” *World Wide Web*, vol. 17, no. 2, pp. 271–284, 2014, doi: 10.1007/s11280-012-0187-z.
- [205] C. Cobos *et al.*, “A hybrid system of pedagogical pattern recommendations based on singular value decomposition and variable data attributes,” *Inf Process Manag*, vol. 49, no. 3, pp. 607–625, 2013, doi: 10.1016/j.ipm.2012.12.002.
- [206] C. De Medio, C. Limongelli, F. Sciarrone, and M. Temperini, “MoodleREC: A recommendation system for creating courses using the moodle e-learning platform,” *Comput Human Behav*, vol. 104, 2020, doi: 10.1016/j.chb.2019.106168.
- [207] K. R. Premlatha and T. V. Geetha, “Learning content design and learner adaptation for adaptive e-learning environment: a survey,” *Artif Intell Rev*, vol. 44, no. 4, pp. 443–465, 2015, doi: 10.1007/s10462-015-9432-z.

- [208] F. Yang and Z. Dong, “Technical Definition and Concepts,” in *Learning path construction in E-learning. Lecture Notes in Educational Technology*, Singapore: Springer, 2017, pp. 31–38. doi: 10.1007/978-981-10-1944-9\_3.
- [209] R. Queirós, P. Leal, and J. Campos, “Sequencing educational resources with Seqins,” *Computer Science and Information Systems*, vol. 11, no. 4, pp. 1479–1497, 2014, doi: 10.2298/CSIS131005074Q.
- [210] A. Muhammad, Q. Zhou, G. Beydoun, D. Xu, and J. Shen, “Learning path adaptation in online learning systems,” in *2016 IEEE 20th International Conference on Computer Supported Cooperative Work in Design (CSCWD)*, IEEE, 2016, pp. 421–426. doi: 10.1109/CSCWD.2016.7566026.
- [211] M. A. Albadr, S. Tiun, M. Ayob, and F. AL-Dhief, “Genetic Algorithm Based on Natural Selection Theory for Optimization Problems,” *Symmetry (Basel)*, vol. 12, no. 11, pp. 1–31, 2020, doi: 10.3390/sym12111758.
- [212] A. E. Kiouche, M. Bessedik, F. Benbouzid-SiTayeb, and M. R. Keddar, “An efficient hybrid multi-objective memetic algorithm for the frequency assignment problem,” *Eng Appl Artif Intell*, vol. 87, 2020, doi: 10.1016/j.engappai.2019.103265.
- [213] S. Katiyar, N. Ibraheem, and A. Q. Ansari, “Ant colony optimization: a tutorial review,” in *National conference on advances in power and control*, 2015, pp. 99–110.
- [214] D. Wang, D. Tan, and L. Liu, “Particle swarm optimization algorithm: an overview,” *Soft comput*, vol. 22, no. 2, pp. 387–408, 2018, doi: 10.1007/s00500-016-2474-6.
- [215] A. Nayyar, V. Puri, and G. Suseendran, “Artificial Bee Colony Optimization - Population-Based Meta-Heuristic Swarm Intelligence Technique,” in *Data Management, Analytics and Innovation*, V. Balas, N. Sharma, and A. Chakrabarti, Eds., Singapore: Springer, 2019, pp. 513–525. doi: 10.1007/978-981-13-1274-8\_38.
- [216] P. Dwivedi, V. Kant, and K. K. Bharadwaj, “Learning path recommendation based on modified variable length genetic algorithm,” *Educ Inf Technol (Dordr)*, vol. 23, no. 2, pp. 819–836, 2018, doi: 10.1007/s10639-017-9637-7.
- [217] M. L. Nguyen, S. C. Hui, and A. C. M. Fong, “Divide-and-conquer memetic algorithm for online multi-objective test paper generation,” *Memet Comput*, vol. 4, no. 1, pp. 33–47, 2012, doi: 10.1007/s12293-012-0077-z.
- [218] N. C. Benabdellah, M. Gharbi, and M. Bellajkikh, “Content adaptation and learner profile definition: Ant colony algorithm application,” in *2013 8th International Conference on Intelligent Systems: Theories and Applications (SITA)*, Rabat, Morocco: IEEE, 2013, pp. 1–7. doi: 10.1109/SITA.2013.6560812.

- [219] M. Niknam and P. Thulasiraman, “LPR: A bio-inspired intelligent learning path recommendation system based on meaningful learning theory,” *Educ Inf Technol (Dordr)*, vol. 25, no. 5, pp. 3797–3819, 2020, doi: 10.1007/s10639-020-10133-3.
- [220] T. I. Wang and K. H. Tsai, “Interactive and dynamic review course composition system utilizing contextual semantic expansion and discrete particle swarm optimization,” *Expert Syst Appl*, vol. 36, no. 6, pp. 9663–9673, 2009, doi: 10.1016/j.eswa.2008.12.010.
- [221] M. Venkatesh and S. Sathyalakshmi, “Smart learning using personalised recommendations in web-based learning systems using artificial bee colony algorithm to improve learning performance,” *Electronic Government, an International Journal*, vol. 16, no. 1–2, pp. 101–117, 2020, doi: 10.1504/EG.2020.105253.
- [222] V. Vanitha, P. Krishnan, and R. Elakkiya, “Collaborative optimization algorithm for learning path construction in E-learning,” *Computers & Electrical Engineering*, vol. 77, pp. 325–338, 2019, doi: 10.1016/j.compeleceng.2019.06.016.
- [223] O. Shvets, K. Murtazin, and G. Piho, “Providing Feedback for Students in E-Learning Systems: a Literature Review, based on IEEE Explore Digital Library,” in *2020 IEEE Global Engineering Education Conference (EDUCON)*, IEEE, 2020, pp. 284–289. doi: 10.1109/EDUCON45650.2020.9125344.
- [224] N.-T. Le, “A Classification of Adaptive Feedback in Educational Systems for Programming,” *Systems*, vol. 4, no. 2, pp. 1–17, 2016, doi: 10.3390/systems4020022.
- [225] A. T. Bimba, N. Idris, A. Al-Hunaiyyan, R. B. Mahmud, and N. L. B. M. Shuib, “Adaptive feedback in computer-based learning environments: a review,” *Adaptive Behavior*, vol. 25, no. 5, pp. 217–234, 2017, doi: 10.1177/1059712317727590.
- [226] B. Vijayakumar, S. Höhn, and C. Schommer, “Quizbot: Exploring Formative Feedback with Conversational Interfaces,” in *Technology Enhanced Assessment. TEA 2018. Communications in Computer and Information Science*, vol. 1014, S. Draaijer, D. Joosten-ten Brinke, and E. Ras, Eds., Cham: Springer, 2019, pp. 102–120. doi: 10.1007/978-3-030-25264-9\_8.
- [227] T. Kakeshita and K. Ohta, “Student Feedback Function for Web-Based Programming Education Support Tool Pgtracer,” in *2016 5th IIAI International Congress on Advanced Applied Informatics (IIAI-AAI)*, Kumamoto, Japan: IEEE, 2016, pp. 322–327. doi: 10.1109/IIAI-AAI.2016.80.
- [228] R. M. Tawafak, A. B. Romli, and M. Alsinani, “E-learning system of UCOM for improving student assessment feedback in Oman higher education,” *Educ Inf Technol (Dordr)*, vol. 24, no. 2, pp. 1311–1335, 2019, doi: 10.1007/s10639-018-9833-0.
- [229] A. Crook *et al.*, “The use of video technology for providing feedback to students: Can it enhance the feedback experience for staff and students?,” *Comput Educ*, vol. 58, no. 1, pp. 386–396, 2012, doi: 10.1016/j.compedu.2011.08.025.

- [230] M. Awais Hassan, U. Habiba, H. Khalid, M. Shoaib, and S. Arshad, “An Adaptive Feedback System to Improve Student Performance Based on Collaborative Behavior,” *IEEE Access*, vol. 7, pp. 107171–107178, 2019, doi: 10.1109/ACCESS.2019.2931565.
- [231] D. Xu, W. W. Huang, H. Wang, and J. Heales, “Enhancing e-learning effectiveness using an intelligent agent-supported personalized virtual learning environment: An empirical investigation,” *Information & Management*, vol. 51, no. 4, pp. 430–440, 2014, doi: 10.1016/j.im.2014.02.009.
- [232] E. E. Kotova, “Use of intelligent agents in the learning process management tasks,” in *2017 IEEE II International Conference on Control in Technical Systems (CTS)*, IEEE, 2017, pp. 180–183. doi: 10.1109/CTSYS.2017.8109520.
- [233] B. Saeidi Pour, M. Farajolahi, M. R. Sarmadi, and H. Shahsavari, “Modeling of Personalized E-Learning Environment Based on Intelligent Agents,” *Interdisciplinary Journal of Virtual Learning in Medical Sciences*, vol. 8, no. 3, pp. 1–8, 2017, doi: 10.5812/ijvlms.10256.
- [234] J. Meleško and E. Kurilovas, “Adaptive Tutoring System With Application of Intelligent Agents,” *International Journal of Smart Education and Urban Society*, vol. 9, no. 2, pp. 1–11, 2018, doi: 10.4018/IJSEUS.2018040101.
- [235] K. S. Chung, “Design of Intelligent Tutoring Engine for U-Learning Service,” *Journal of Advances in Information Technology*, vol. 6, no. 2, pp. 75–79, 2015, doi: 10.12720/jait.6.2.75-79.
- [236] A. Trifa, A. Hedhili, and W. L. Chaari, “Knowledge tracing with an intelligent agent, in an e-learning platform,” *Educ Inf Technol (Dordr)*, vol. 24, no. 1, pp. 711–741, 2019, doi: 10.1007/s10639-018-9792-5.
- [237] A. Asselman, A. Nasseh, and S. Aammou, “Revealing Strengths, Weaknesses and Prospects of Intelligent Collaborative e-Learning Systems,” *Advances in Science, Technology and Engineering Systems Journal*, vol. 3, no. 3, pp. 67–79, 2018, doi: 10.25046/aj030310.
- [238] M. U. Bokhari and S. Ahmad, “Multi-Agent Based E-Learning Systems,” in *Proceedings of the 2014 International Conference on Information and Communication Technology for Competitive Strategies*, New York, NY, USA: ACM, 2014, pp. 1–6. doi: 10.1145/2677855.2677875.
- [239] A. Asselman, A.-E. Nasseh, and S. Aammou, “Survey of intelligent collaborative E-learning systems,” in *2017 15th International Conference on Emerging eLearning Technologies and Applications (ICETA)*, Stary Smokovec, Slovakia: IEEE, 2017, pp. 1–7. doi: 10.1109/ICETA.2017.8102463.
- [240] A. Alkhatlan and J. Kalita, “Intelligent Tutoring Systems: A Comprehensive Historical Survey with Recent Developments,” *Int J Comput Appl*, vol. 181, no. 43, pp. 1–20, 2019, doi: 10.5120/ijca2019918451.

- [241] J. Aguilar, P. Valdiviezo, J. Cordero, and M. Sánchez, “Conceptual design of a smart classroom based on multiagent systems,” in *Proceedings on the international conference on artificial intelligence (ICAI)*, 2015, pp. 471–477.
- [242] H.-L. Tsai, C.-J. Lee, W.-H. L. Hsu, and Y.-H. Chang, “An adaptive e-learning system based on intelligent agents,” in *Proceedings of the 11th WSEAS international conference on applied computer and applied computational science*, 2012, pp. 139–142.
- [243] E. Lavendelis, “Extending the MASITS Methodology for General Purpose Agent Oriented Software Engineering,” in *Proceedings of the International Conference on Agents and Artificial Intelligence*, SCITEPRESS - Science and Technology Publications, 2015, pp. 157–165. doi: 10.5220/0005202201570165.
- [244] H. Ajroud, I. Tnazefti-Kerkeni, and B. Talon, “ADOPT: A Trace based Adaptive System,” in *Proceedings of the 13th International Conference on Computer Supported Education*, SCITEPRESS - Science and Technology Publications, 2021, pp. 233–239. doi: 10.5220/0010452702330239.
- [245] D.-E. N. V. Rosado, M. Esponda-Argüero, and R. Rojas, “Developing a Multi-Agent System for a Blended Learning Application,” in *New Research in Multimedia and Internet Systems. Advances in Intelligent Systems and Computing*, vol. 314, A. Zgrzywa, K. Choroś, and A. Siemiński, Eds., Cham: Springer, 2015, pp. 135–143. doi: 10.1007/978-3-319-10383-9\_13.
- [246] G. Trevors, M. Duffy, and R. Azevedo, “Note-taking within MetaTutor: interactions between an intelligent tutoring system and prior knowledge on note-taking and learning,” *Educational Technology Research and Development*, vol. 62, no. 5, pp. 507–528, 2014, doi: 10.1007/s11423-014-9343-8.
- [247] K. Kuk, D. Rančić, O. Pronić-Rančić, and D. Randelović, “Intelligent Agents and Game-Based Learning Modules in a Learning Management System,” in *Agent and Multi-Agent Systems: Technology and Applications. Smart Innovation, Systems and Technologies*, vol. 58, G. Jezic, Y. Chen-Burger, R. Howlett, and L. Jain, Eds., Cham: Springer, 2016, pp. 233–245. doi: 10.1007/978-3-319-39883-9\_19.
- [248] M. M. E. Van Pinxteren, M. Pluymakers, and J. G. A. M. Lemmink, “Human-like communication in conversational agents: a literature review and research agenda,” *Journal of Service Management*, vol. 31, no. 2, pp. 203–225, 2020, doi: 10.1108/JOSM-06-2019-0175.
- [249] A. L. Mondragon, R. Nkambou, and P. Poirier, “Evaluating the Effectiveness of an Affective Tutoring Agent in Specialized Education,” in *Adaptive and Adaptable Learning. EC-TEL 2016. Lecture Notes in Computer Science*, vol. 9891, K. Verbert, M. Sharples, and T. Klobučar, Eds., Cham: Springer, 2016, pp. 446–452. doi: 10.1007/978-3-319-45153-4\_41.

- [250] N. Thompson and T. J. McGill, “Genetics with Jean: the design, development and evaluation of an affective tutoring system,” *Educational Technology Research and Development*, vol. 65, no. 2, pp. 279–299, 2017, doi: 10.1007/s11423-016-9470-5.
- [251] T. Carlotto and P. A. Jaques, “The effects of animated pedagogical agents in an English-as-a-foreign-language learning environment,” *Int J Hum Comput Stud*, vol. 95, pp. 15–26, 2016, doi: 10.1016/j.ijhcs.2016.06.001.
- [252] N. Matsuda, C. L. Griger, N. Barbaliros, G. J. Stylianides, W. W. Cohen, and K. R. Koedinger, “Investigating the Effect of Meta-cognitive Scaffolding for Learning by Teaching,” in *Intelligent Tutoring Systems. ITS 2014. Lecture Notes in Computer Science*, vol. 8474, S. Trausan-Matu, K. E. Boyer, M. Crosby, and K. Panourgia, Eds., Cham: Springer, 2014, pp. 104–113. doi: 10.1007/978-3-319-07221-0\_13.
- [253] K. Osman and T. T. Lee, “Impact of Interactive Multimedia Module With Pedagogical Agents on Students’ Understanding and Motivation in the Learning of Electrochemistry,” *Int J Sci Math Educ*, vol. 12, no. 2, pp. 395–421, 2014, doi: 10.1007/s10763-013-9407-y.
- [254] D. Griol, J. M. Molina, and A. S. de Miguel, “The Geranium System: Multimodal Conversational Agents for E-learning,” in *Distributed Computing and Artificial Intelligence, 11th International Conference. Advances in Intelligent Systems and Computing*, vol. 290, S. Omatsu, H. Bersini, J. M. Corchado, S. Rodríguez, P. Pawlewski, and E. Bucciarelli, Eds., Cham: Springer, 2014, pp. 219–226. doi: 10.1007/978-3-319-07593-8\_26.
- [255] N. Chhibber and E. Law, “Using Conversational Agents To Support Learning By Teaching,” *arXiv preprint arXiv:1909.13443*, 2019.
- [256] Z. Fasihfar and H. Rokhsati, “Study of application of intelligent agents in e-learning systems,” *Bulletin de la Société Royale des Sciences de Liège*, vol. 86, pp. 398–405, 2017, doi: 10.25518/0037-9565.6781.
- [257] A. Klašnja-Milićević, B. Vesin, M. Ivanović, Z. Budimac, and L. C. Jain, “Agents in E-Learning Environments,” in *E-Learning Systems. Intelligent Systems Reference Library*, vol. 112, Cham: Springer, 2017, pp. 43–49. doi: 10.1007/978-3-319-41163-7\_5.
- [258] M. Islam, G. Chen, and S. Jin, “An Overview of Neural Network,” *American Journal of Neural Networks and Applications*, vol. 5, no. 1, pp. 7–11, 2019, doi: 10.11648/j.ajnna.20190501.12.
- [259] E. Şuşnea, “Using artificial neural networks in e-learning systems,” *UPB Sci Bull, Series C*, vol. 72, no. 4, pp. 91–100, 2010.
- [260] E. Poitras, K. R. Butcher, M. Orr, M. A. Hudson, and M. Larson, “Predicting student understanding by modeling interactive exploration of evidence during an online science investigation,” *Interactive Learning Environments*, vol. 30, no. 5, pp. 821–833, 2022, doi: 10.1080/10494820.2019.1689146.

- [261] S. Bhattacharya, S. Roy, and S. Chowdhury, “A neural network-based intelligent cognitive state recognizer for confidence-based e-learning system,” *Neural Comput Appl*, vol. 29, no. 1, pp. 205–219, 2018, doi: 10.1007/s00521-016-2430-5.
- [262] Z. Dogmus, E. Erdem, and V. Patoglu, “ReAct!: An Interactive Educational Tool for AI Planning for Robotics,” *IEEE Transactions on Education*, vol. 58, no. 1, pp. 15–24, 2015, doi: 10.1109/TE.2014.2318678.
- [263] M. Hussain, W. Zhu, W. Zhang, S. M. R. Abidi, and S. Ali, “Using machine learning to predict student difficulties from learning session data,” *Artif Intell Rev*, vol. 52, no. 1, pp. 381–407, 2019, doi: 10.1007/s10462-018-9620-8.
- [264] A. T. Misirli and A. B. Bener, “Bayesian Networks For Evidence-Based Decision-Making in Software Engineering,” *IEEE Transactions on Software Engineering*, vol. 40, no. 6, pp. 533–554, 2014, doi: 10.1109/TSE.2014.2321179.
- [265] L. Leka and A. Kika, “Enhancing Moodle to Adapt to Students Different Learning Styles,” in *Proceedings of the 3rd international conference on recent trends and applications in computer science and information technology, RTA-CSIT 2018*, 2018, pp. 186–189.
- [266] V. A. Nguyen and V. C. Pham, “Bayesian Network to Manage Learner Model in Context-Aware Adaptive System in Mobile Learning,” in *Edutainment Technologies. Educational Games and Virtual Reality/Augmented Reality Applications. Edutainment 2011. Lecture Notes in Computer Science*, vol. 6872, M. Chang, W.-Y. Hwang, M.-P. Chen, and W. Müller, Eds., Berlin, Heidelberg: Springer, 2011, pp. 63–70. doi: 10.1007/978-3-642-23456-9\_13.
- [267] X. Xu, F. Ke, and S. Lee, “Evaluating Teaching Competency in a 3d E-Learning Environment Using a Small-Scale Bayesian Network,” *Q Rev Distance Educ*, vol. 17, no. 3, pp. 61–74, 2016.
- [268] M. Eryılmaz and A. Adabashi, “Development of an Intelligent Tutoring System Using Bayesian Networks and Fuzzy Logic for a Higher Student Academic Performance,” *Applied Sciences*, vol. 10, no. 19, pp. 1–18, 2020, doi: 10.3390/app10196638.
- [269] R. Makkar, “Application of fuzzy logic: A literature review,” *International Journal of statistics and applied mathematics*, vol. 3, no. 1, pp. 357–359, 2018.
- [270] F. Jurado, M. Redondo, and M. Ortega, “eLearning standards and automatic assessment in a distributed eclipse based environment for learning computer programming,” *Computer Applications in Engineering Education*, vol. 22, no. 4, pp. 774–787, 2014, doi: 10.1002/cae.21569.
- [271] M. Ortega, “Computer-Human Interaction and Collaboration: Challenges and Prospects,” *Electronics (Basel)*, vol. 10, no. 5, pp. 1–13, 2021, doi: 10.3390/electronics10050616.

- [272] K. Chrysafiadi and M. Virvou, “Fuzzy Logic for Adaptive Instruction in an E-learning Environment for Computer Programming,” *IEEE Transactions on Fuzzy Systems*, vol. 23, no. 1, pp. 164–177, 2015, doi: 10.1109/TFUZZ.2014.2310242.
- [273] K. Almohammadi, H. Hagras, D. Alghazzawi, and G. Aldabbagh, “Users-Centric Adaptive Learning System Based on Interval Type-2 Fuzzy Logic for Massively Crowded E-Learning Platforms,” *Journal of Artificial Intelligence and Soft Computing Research*, vol. 6, no. 2, pp. 81–101, 2016, doi: 10.1515/jaiscr-2016-0008.
- [274] S. Katz, A. Lesgold, G. Eggan, and M. Gordin, “Modeling the Student in Sherlock II,” in *Student Modelling: The Key to Individualized Knowledge-Based Instruction. NATO ASI Series*, vol. 125, J. E. Greer and G. I. McCalla, Eds., Berlin, Heidelberg: Springer, 1994, pp. 99–125. doi: 10.1007/978-3-662-03037-0\_4.
- [275] R. Bajaj and V. Sharma, “Smart Education with artificial intelligence based determination of learning styles,” *Procedia Comput Sci*, vol. 132, pp. 834–842, 2018, doi: 10.1016/j.procs.2018.05.095.
- [276] Y. Akyuz, “Effects of Intelligent Tutoring Systems (ITS) on Personalized Learning (PL),” *Creat Educ*, vol. 11, no. 6, pp. 953–978, 2020, doi: 10.4236/ce.2020.116069.
- [277] C. F. Lin, Y. Yeh, Y. H. Hung, and R. I. Chang, “Data mining for providing a personalized learning path in creativity: An application of decision trees,” *Comput Educ*, vol. 68, pp. 199–210, 2013, doi: 10.1016/j.compedu.2013.05.009.
- [278] A. J. M. Karkar, H. K. Fatlawi, and A. A. Al-Jobouri, “Highlighting E-learning Adoption Challenges using data Analysis Techniques: University of Kufa as a Case Study,” *Electronic Journal of e-Learning*, vol. 18, no. 2, pp. 136–149, 2020, doi: 10.34190/EJEL.20.18.2.003.
- [279] H. Faeskorn-Woyke, B. Bertelsmeier, and J. Strohschein, “A Decision Tree Approach for the Classification of Mistakes of Students Learning SQL,” in *DELFI 2020 - Die 18. Fachtagung Bildungstechnologien der Gesellschaft Für Informatik e.V.*, 2020, pp. 211–216.
- [280] K. Colchester, H. Hagras, D. Alghazzawi, and G. Aldabbagh, “A Survey of Artificial Intelligence Techniques Employed for Adaptive Educational Systems within E-Learning Platforms,” *Journal of Artificial Intelligence and Soft Computing Research*, vol. 7, no. 1, pp. 47–64, 2017, doi: 10.1515/jaiscr-2017-0004.
- [281] M. Rani, R. Vyas, and O. P. Vyas, “OPAESFH: Ontology-based personalized adaptive e-learning system using FPN and HMM,” in *TENCON 2017 - 2017 IEEE Region 10 Conference*, IEEE, 2017, pp. 2441–2446. doi: 10.1109/TENCON.2017.8228271.
- [282] M. Homsi, R. Lutfi, R. M. Carro, and B. Ghias, “A Hidden Markov Model Approach to Predict Students’ Actions in an Adaptive and Intelligent Web-Based Educational system,” in *2008 3rd International Conference on Information and Communication Technologies*:

*From Theory to Applications*, Damascus, Syria: IEEE, 2008, pp. 1–6. doi: 10.1109/ICTTA.2008.4529976.

- [283] J. R. van Seters, M. A. Ossevoort, J. Tramper, and M. J. Goedhart, “The influence of student characteristics on the use of adaptive e-learning material,” *Comput Educ*, vol. 58, no. 3, pp. 942–952, 2012, doi: 10.1016/j.compedu.2011.11.002.
- [284] A. Azeta, C. Ayo, N. Omoregbe, and V. Osamor, “Using hidden-Markov model in speech-based education system for the visually impaired learner,” in *Proceedings of EDULEARN14 Conference*, Barcelona, Spain: IATED, 2014, pp. 4489–4495.
- [285] A. Elbahi, M. N. Omri, M. A. Mahjoub, and K. Garrouch, “Mouse Movement and Probabilistic Graphical Models Based E-Learning Activity Recognition Improvement Possibilistic Model,” *Arab J Sci Eng*, vol. 41, no. 8, pp. 2847–2862, 2016, doi: 10.1007/s13369-016-2025-6.
- [286] M. Montebello, “MOOCs, Crowdsourcing and Social Networks,” in *AI Injected e-Learning. Studies in Computational Intelligence*, vol. 745, Cham: Springer, 2018, pp. 15–25. doi: 10.1007/978-3-319-67928-0\_3.
- [287] T. Wanner and E. Palmer, “Personalising learning: Exploring student and teacher perceptions about flexible learning and assessment in a flipped university course,” *Comput Educ*, vol. 88, pp. 354–369, 2015, doi: 10.1016/j.compedu.2015.07.008.
- [288] K. Mangaroska, B. Vesin, and M. Giannakos, “Elo-Rating Method: Towards Adaptive Assessment in E-Learning,” in *2019 IEEE 19th International Conference on Advanced Learning Technologies (ICALT)*, IEEE, 2019, pp. 380–382. doi: 10.1109/ICALT.2019.00116.
- [289] Y. Zou, X. Yan, and W. Li, “Knowledge Tracking Model Based on Learning Process,” *Journal of Computer and Communications*, vol. 8, no. 10, pp. 7–17, 2020, doi: 10.4236/jcc.2020.810002.
- [290] K. Seo, J. Tang, I. Roll, S. Fels, and D. Yoon, “The impact of artificial intelligence on learner–instructor interaction in online learning,” *International Journal of Educational Technology in Higher Education*, vol. 18, no. 1, pp. 1–23, 2021, doi: 10.1186/s41239-021-00292-9.
- [291] O. Zawacki-Richter, V. I. Marín, M. Bond, and F. Gouverneur, “Systematic review of research on artificial intelligence applications in higher education – where are the educators?,” *International Journal of Educational Technology in Higher Education*, vol. 16, no. 1, pp. 1–27, 2019, doi: 10.1186/s41239-019-0171-0.
- [292] K. Sharma, M. Giannakos, and P. Dillenbourg, “Eye-tracking and artificial intelligence to enhance motivation and learning,” *Smart Learning Environments*, vol. 7, no. 1, pp. 1–19, 2020, doi: 10.1186/s40561-020-00122-x.

- [293] T. Tenorio, S. Isotani, I. I. Bittencourt, and Y. Lu, “The State-of-the-Art on Collective Intelligence in Online Educational Technologies,” *IEEE Transactions on Learning Technologies*, vol. 14, no. 2, pp. 257–271, 2021, doi: 10.1109/TLT.2021.3073559.
- [294] K. Mangaroska, B. Vesin, V. Kostakos, P. Brusilovsky, and M. N. Giannakos, “Architecting Analytics Across Multiple E-Learning Systems to Enhance Learning Design,” *IEEE Transactions on Learning Technologies*, vol. 14, no. 2, pp. 173–188, 2021, doi: 10.1109/TLT.2021.3072159.
- [295] S. Wan and Z. Niu, “An e-learning recommendation approach based on the self-organization of learning resource,” *Knowl Based Syst*, vol. 160, pp. 71–87, 2018, doi: 10.1016/j.knosys.2018.06.014.
- [296] S. Hobert and R. Meyer von Wolff, “Say hello to your new automated tutor - A structured literature review on pedagogical conversational agents,” in *14th international conference on Wirtschaftsinformatik*, 2019, pp. 301–314.
- [297] J. Mamcenko and E. Kurilovas, “On using learning analytics to personalise learning in virtual learning environments,” in *European conference on e-Learning*, Academic Conferences International Limited, 2017, pp. 353–361.
- [298] E. Kurilovas, “Advanced machine learning approaches to personalise learning: learning analytics and decision making,” *Behaviour & Information Technology*, vol. 38, no. 4, pp. 410–421, 2019, doi: 10.1080/0144929X.2018.1539517.
- [299] K. Mangaroska, R. Martinez-Maldonado, B. Vesin, and D. Gašević, “Challenges and opportunities of multimodal data in human learning: The computer science students’ perspective,” *J Comput Assist Learn*, vol. 37, no. 4, pp. 1030–1047, 2021, doi: 10.1111/jcal.12542.
- [300] M. Nasiri, B. Minaei, and F. Vafaei, “Predicting GPA and academic dismissal in LMS using educational data mining: A case mining,” in *6th National and 3rd International Conference of E-Learning and E-Teaching*, IEEE, 2012, pp. 53–58. doi: 10.1109/ICELET.2012.6333365.
- [301] J. A. Reyes, “The skinny on big data in education: Learning analytics simplified,” *TechTrends*, vol. 59, no. 2, pp. 75–80, 2015, doi: 10.1007/s11528-015-0842-1.
- [302] Y.-S. Tsai and D. Gasevic, “Learning analytics in higher education - challenges and policies: a review of eight learning analytics policies,” in *Proceedings of the Seventh International Learning Analytics & Knowledge Conference*, New York, NY, USA: ACM, 2017, pp. 233–242. doi: 10.1145/3027385.3027400.
- [303] Y.-S. Tsai, V. Kovanović, and D. Gašević, “Connecting the dots: An exploratory study on learning analytics adoption factors, experience, and priorities,” *Internet High Educ*, vol. 50, 2021, doi: 10.1016/j.iheduc.2021.100794.

- [304] M. C. Borba, P. Askar, J. Engelbrecht, G. Gadanidis, S. Llinares, and M. S. Aguilar, “Blended learning, e-learning and mobile learning in mathematics education,” *ZDM Mathematics Education*, vol. 48, no. 5, pp. 589–610, 2016, doi: 10.1007/s11858-016-0798-4.
- [305] S. Guri-Rosenblit, “E-Teaching in Higher Education: An Essential Prerequisite for E-Learning,” *Journal of New Approaches in Educational Research*, vol. 7, no. 2, pp. 93–97, 2018, doi: 10.7821/naer.2018.7.298.
- [306] D. Gašević, “Include us all! Directions for adoption of learning analytics in the global south,” in *Learning analytics for the global south*, C. Lim and V. Tinio, Eds., Quezon City: Foundation for Information Technology Education and Development, 2018, pp. 1–22.
- [307] B. Williamson and R. Eynon, “Historical threads, missing links, and future directions in AI in education,” *Learn Media Technol*, vol. 45, no. 3, pp. 223–235, 2020, doi: 10.1080/17439884.2020.1798995.
- [308] X. Zhai *et al.*, “A Review of Artificial Intelligence (AI) in Education from 2010 to 2020,” *Complexity*, vol. 2021, pp. 1–18, 2021, doi: 10.1155/2021/8812542.
- [309] K. Mangaroska and M. Giannakos, “Learning Analytics for Learning Design: A Systematic Literature Review of Analytics-Driven Design to Enhance Learning,” *IEEE Transactions on Learning Technologies*, vol. 12, no. 4, pp. 516–534, 2018, doi: 10.1109/TLT.2018.2868673.
- [310] A. Klašnja-Milićević, M. Ivanović, and A. Nanopoulos, “Recommender systems in e-learning environments: a survey of the state-of-the-art and possible extensions,” *Artif Intell Rev*, vol. 44, no. 4, pp. 571–604, 2015, doi: 10.1007/s10462-015-9440-z.
- [311] M. W. Easterday, D. G. Rees Lewis, and E. M. Gerber, “The logic of design research,” *Learning: Research and Practice*, vol. 4, no. 2, pp. 131–160, 2018, doi: 10.1080/23735082.2017.1286367.
- [312] B. Albreiki, N. Zaki, and H. Alashwal, “A Systematic Literature Review of Student’ Performance Prediction Using Machine Learning Techniques,” *Educ Sci (Basel)*, vol. 11, no. 9, pp. 1–27, 2021, doi: 10.3390/educsci11090552.
- [313] M. Ilić, G. Keković, V. Mikić, K. Mangaroska, L. Kopanja, and B. Vesin, “Predicting Student Performance in a Programming Tutoring System Using AI and Filtering Techniques,” *IEEE Transactions on Learning Technologies*, vol. 17, pp. 1931–1945, 2024, doi: 10.1109/TLT.2024.3431473.
- [314] A. H. Nabizadeh, D. Goncalves, S. Gama, and J. Jorge, “Early Prediction of Students’ Final Grades in a Gamified Course,” *IEEE Transactions on Learning Technologies*, vol. 15, no. 3, pp. 311–325, 2022, doi: 10.1109/TLT.2022.3170494.

- [315] J. Bravo-Agapito, S. J. Romero, and S. Pamplona, “Early prediction of undergraduate Student’s academic performance in completely online learning: A five-year study,” *Comput Human Behav*, vol. 115, pp. 1–25, 2021, doi: 10.1016/j.chb.2020.106595.
- [316] G. Barata, S. Gama, J. Jorge, and D. Goncalves, “Early Prediction of Student Profiles Based on Performance and Gaming Preferences,” *IEEE Transactions on Learning Technologies*, vol. 9, no. 3, pp. 272–284, 2016, doi: 10.1109/TLT.2016.2541664.
- [317] K. F. Hew, X. Hu, C. Qiao, and Y. Tang, “What predicts student satisfaction with MOOCs: A gradient boosting trees supervised machine learning and sentiment analysis approach,” *Comput Educ*, vol. 145, 2020, doi: 10.1016/j.compedu.2019.103724.
- [318] P. Bhardwaj, P. K. Gupta, H. Panwar, M. K. Siddiqui, R. Morales-Menendez, and A. Bhaik, “Application of Deep Learning on Student Engagement in e-learning environments,” *Computers & Electrical Engineering*, vol. 93, pp. 1–11, 2021, doi: 10.1016/j.compeleceng.2021.107277.
- [319] D. Riofrio-Luzcando, J. Ramirez, and M. Berrocal-Lobo, “Predicting Student Actions in a Procedural Training Environment,” *IEEE Transactions on Learning Technologies*, vol. 10, no. 4, pp. 463–474, 2017, doi: 10.1109/TLT.2017.2658569.
- [320] M. Moresi, M. J. Gómez, and L. Benotti, “Predicting Students’ Difficulties From a Piece of Code,” *IEEE Transactions on Learning Technologies*, vol. 14, no. 3, pp. 386–399, 2021, doi: 10.1109/TLT.2021.3092998.
- [321] T. Anagnostopoulos, C. Kytagias, T. Xanthopoulos, I. Georgakopoulos, I. Salmon, and Y. Psaromiligkos, “Intelligent Predictive Analytics for Identifying Students at Risk of Failure in Moodle Courses,” in *Intelligent Tutoring Systems. ITS 2020. Lecture Notes in Computer Science*, vol. 12149, V. Kumar and C. Troussas, Eds., Cham: Springer, 2020, pp. 152–162. doi: 10.1007/978-3-030-49663-0\_19.
- [322] R. Alcaraz, A. Martinez-Rodrigo, R. Zangroniz, and J. J. Rieta, “Early Prediction of Students at Risk of Failing a Face-to-Face Course in Power Electronic Systems,” *IEEE Transactions on Learning Technologies*, vol. 14, no. 5, pp. 590–603, 2021, doi: 10.1109/TLT.2021.3118279.
- [323] Y. Jang, S. Choi, H. Jung, and H. Kim, “Practical early prediction of students’ performance using machine learning and eXplainable AI,” *Educ Inf Technol (Dordr)*, vol. 27, no. 9, pp. 12855–12889, 2022, doi: 10.1007/s10639-022-11120-6.
- [324] F. Braz, F. Campos, V. Stroele, and M. Dantas, “An Early Warning Model for School Dropout: a Case Study in E-learning Class,” in *Brazilian Symposium on Computers in Education*, 2019, pp. 1441–1450. doi: 10.5753/cbie.sbie.2019.1441.
- [325] D. Baneres, M. E. Rodriguez, and M. Serra, “An Early Feedback Prediction System for Learners At-Risk Within a First-Year Higher Education Course,” *IEEE Transactions on Learning Technologies*, vol. 12, no. 2, pp. 249–263, 2019, doi: 10.1109/TLT.2019.2912167.

- [326] F. Qiu *et al.*, “Predicting students’ performance in e-learning using learning process and behaviour data,” *Sci Rep*, vol. 12, no. 1, pp. 1–15, 2022, doi: 10.1038/s41598-021-03867-8.
- [327] Y. T. Badal and R. K. Sungkur, “Predictive modelling and analytics of students’ grades using machine learning algorithms,” *Educ Inf Technol (Dordr)*, vol. 28, no. 3, pp. 3027–3057, 2023, doi: 10.1007/s10639-022-11299-8.
- [328] S. Li and T. Liu, “Performance Prediction for Higher Education Students Using Deep Learning,” *Complexity*, vol. 2021, pp. 1–10, 2021, doi: 10.1155/2021/9958203.
- [329] P. Balaji, S. Alelyani, A. Qahmash, and M. Mohana, “Contributions of Machine Learning Models towards Student Academic Performance Prediction: A Systematic Review,” *Applied Sciences*, vol. 11, no. 21, pp. 1–25, 2021, doi: 10.3390/app112110007.
- [330] G. Ben Brahim, “Predicting Student Performance from Online Engagement Activities Using Novel Statistical Features,” *Arab J Sci Eng*, vol. 47, no. 8, pp. 10225–10243, 2022, doi: 10.1007/s13369-021-06548-w.
- [331] S. J. H. Yang, O. H. T. Lu, A. Y. Q. Huang, J. C. H. Huang, H. Ogata, and A. J. Q. Lin, “Predicting Students’ Academic Performance Using Multiple Linear Regression and Principal Component Analysis,” *Journal of Information Processing*, vol. 26, pp. 170–176, 2018, doi: 10.2197/ipsjjip.26.170.
- [332] F. Widyahastuti and V. U. Tjhin, “Predicting students performance in final examination using linear regression and multilayer perceptron,” in *2017 10th International Conference on Human System Interactions (HSI)*, Ulsan, South Korea: IEEE, 2017, pp. 188–192. doi: 10.1109/HSI.2017.8005026.
- [333] R. G. Santosa and A. R. Chrismanto, “Logistic Regression Model For Predicting First Semester Students GPA Category Based On High School Academic Achievement,” *Researchers World: Journal of Arts, Science and Commerce*, vol. 8, no. 2(1), pp. 58–66, 2017, doi: 10.18843/rwjasc/v8i2(1)/08.
- [334] C. J. Villagrá-Arnedo, F. J. Gallego-Durán, F. Llorens-Largo, P. Compañ-Rosique, R. Satorre-Cuerda, and R. Molina-Carmona, “Improving the expressiveness of black-box models for predicting student performance,” *Comput Human Behav*, vol. 72, pp. 621–631, 2017, doi: 10.1016/j.chb.2016.09.001.
- [335] M. Kokoç and A. Altun, “Effects of learner interaction with learning dashboards on academic performance in an e-learning environment,” *Behaviour & Information Technology*, vol. 40, no. 2, pp. 161–175, 2021, doi: 10.1080/0144929X.2019.1680731.
- [336] T. Santamaría Lopez, D. Patiño Perez, V. González Ruiz, and L. Flores Carvajal, “Implementation of Machine Learning Techniques and Creation of an Artificial Neural Network for the Prediction of the Academic Performance of Students in University

- Environments that Use E-Learning and Streaming,” *Dyna (Medellin)*, vol. 98, no. 3, pp. 282–287, 2023, doi: 10.6036/10760.
- [337] F. Okubo, T. Yamashita, A. Shimada, and H. Ogata, “A neural network approach for students’ performance prediction,” in *Proceedings of the Seventh International Learning Analytics & Knowledge Conference*, New York, NY, USA: ACM, 2017, pp. 598–599. doi: 10.1145/3027385.3029479.
- [338] N. Z. Zacharis, “Predicting Student Academic Performance in Blended Learning Using Artificial Neural Networks,” *International Journal of Artificial Intelligence and Applications*, vol. 7, no. 5, pp. 17–29, 2016, doi: 10.5121/ijaia.2016.7502.
- [339] Engr. S. Bhutto, I. F. Siddiqui, Q. A. Arain, and M. Anwar, “Predicting Students’ Academic Performance Through Supervised Machine Learning,” in *2020 International Conference on Information Science and Communication Technology (ICISCT)*, IEEE, 2020, pp. 1–6. doi: 10.1109/ICISCT49550.2020.9080033.
- [340] K. Fahd, S. J. Miah, and K. Ahmed, “Predicting student performance in a blended learning environment using learning management system interaction data,” *Applied Computing and Informatics*, pp. 1–12, 2021, doi: 10.1108/ACI-06-2021-0150.
- [341] K. . M. G. Noama, A. Khalid, A. A. Muhamram, and I. A. Ahmed, “Improvement of E-learning Based via Learning Management Systems (LMS) Using Artificial Neural Networks,” *Asian Journal of Research in Computer Science*, vol. 4, no. 1, pp. 1–9, 2019, doi: 10.9734/ajrcos/2019/v4i130105.
- [342] E. P. Saputra, Indriyanti, Supriatiningsih, T. Rahman, and A. H. Kahfi, “Comparison of machine learning algorithm for prediction learning achievement on e-learning students,” in *AIP Conference Proceedings*, 2023, pp. 1–6. doi: 10.1063/5.0128538.
- [343] L. Zhou, S. Pan, J. Wang, and A. V. Vasilakos, “Machine learning on big data: Opportunities and challenges,” *Neurocomputing*, vol. 237, pp. 350–361, 2017, doi: 10.1016/j.neucom.2017.01.026.
- [344] P. Jiao, F. Ouyang, Q. Zhang, and A. H. Alavi, “Artificial intelligence-enabled prediction model of student academic performance in online engineering education,” *Artif Intell Rev*, vol. 55, no. 8, pp. 6321–6344, 2022, doi: 10.1007/s10462-022-10155-y.
- [345] S. Rakic, M. Pavlovic, S. Softic, B. Lalic, and U. Marjanovic, “An Evaluation of Student Performance at e-Learning Platform,” in *2019 17th International Conference on Emerging eLearning Technologies and Applications (ICETA)*, IEEE, 2019, pp. 681–686. doi: 10.1109/ICETA48886.2019.9040066.
- [346] X. Wang, P. Wu, G. Liu, Q. Huang, X. Hu, and H. Xu, “Learning performance prediction via convolutional GRU and explainable neural networks in e-learning environments,” *Computing*, vol. 101, no. 6, pp. 587–604, 2019, doi: 10.1007/s00607-018-00699-9.

- [347] F. Saleem, Z. Ullah, B. Fakieh, and F. Kateb, “Intelligent Decision Support System for Predicting Student’s E-Learning Performance Using Ensemble Machine Learning,” *Mathematics*, vol. 9, no. 17, pp. 1–22, 2021, doi: 10.3390/math9172078.
- [348] A. Rivas, A. González-Briones, G. Hernández, J. Prieto, and P. Chamoso, “Artificial neural network analysis of the academic performance of students in virtual learning environments,” *Neurocomputing*, vol. 423, pp. 713–720, 2021, doi: 10.1016/j.neucom.2020.02.125.
- [349] K. Sriram, T. Chakravarthy, and K. Anastraj, “Students Impenetrabilities From Learning Session Data Prediction Using Machine Learning Techniques,” *Compliance Engineering Journal*, vol. 10, no. 7, pp. 69–77, 2020.
- [350] Y.-S. Su, Y.-D. Lin, and T.-Q. Liu, “Applying machine learning technologies to explore students’ learning features and performance prediction,” *Front Neurosci*, vol. 16, pp. 1–9, 2022, doi: 10.3389/fnins.2022.1018005.
- [351] Ş. Aydoğdu, “Predicting student final performance using artificial neural networks in online learning environments,” *Educ Inf Technol (Dordr)*, vol. 25, no. 3, pp. 1913–1927, 2020, doi: 10.1007/s10639-019-10053-x.
- [352] P. Kumari, P. K. Jain, and R. Pamula, “An efficient use of ensemble methods to predict students academic performance,” in *2018 4th International Conference on Recent Advances in Information Technology (RAIT)*, IEEE, 2018, pp. 1–6. doi: 10.1109/RAIT.2018.8389056.
- [353] T. Mahboob, S. Irfan, and A. Karamat, “A machine learning approach for student assessment in E-learning using Quinlan’s C4.5, Naive Bayes and Random Forest algorithms,” in *2016 19th International Multi-Topic Conference (INMIC)*, IEEE, 2016, pp. 1–8. doi: 10.1109/INMIC.2016.7840094.
- [354] M. Raheema, A. M. Al-Khazzar, and J. S. Hussain, “Prediction of Students’ Achievements in E-Learning Courses Based on Adaptive Neuro-Fuzzy Inference System,” *International Journal of Fuzzy Logic and Intelligent Systems*, vol. 22, no. 2, pp. 213–222, 2022, doi: 10.5391/IJFIS.2022.22.2.213.
- [355] E. P. Saputra, Supriatiningsih, Indriyanti, and Sugiono, “Prediction of Evaluation Result of E-learning Success Based on Student Activity Logs With Selection of Neural Network Attributes Base on PSO,” *J Phys Conf Ser*, pp. 1–6, 2020, doi: 10.1088/1742-6596/1641/1/012074.
- [356] Z. Kanetaki, C. Stergiou, G. Bekas, C. Troussas, and C. Sgouropoulou, “A Hybrid Machine Learning Model for Grade Prediction in Online Engineering Education,” *International Journal of Engineering Pedagogy*, vol. 12, no. 3, pp. 4–24, 2022, doi: 10.3991/ijep.v12i3.23873.

- [357] M. K. Kadhim and A. K. Hassan, “Towards Intelligent E-Learning Systems: A Hybrid Model for Predicating the Learning Continuity in Iraqi Higher Education,” *Webology*, vol. 17, no. 2, pp. 172–188, 2020, doi: 10.14704/WEB/V17I2/WEB17023.
- [358] S.-S. M. Ajibade *et al.*, “Utilization of ensemble techniques for prediction of the academic performance of students,” *Journal of Optoelectronics Laser*, vol. 41, no. 6, pp. 48–54, 2022.
- [359] O. I. Abiodun, A. Jantan, A. E. Omolara, K. V. Dada, N. A. Mohamed, and H. Arshad, “State-of-the-art in artificial neural network applications: A survey,” *Heliyon*, vol. 4, no. 11, pp. 1–41, 2018, doi: 10.1016/j.heliyon.2018.e00938.
- [360] H. Heuer and A. Breiter, “Student success prediction and the trade-off between big data and data minimization,” in *DeLFI 2018-Die 16. E-Learning Fachtagung Informatik*, Bonn: Gesellschaft für Informatik, 2018, pp. 219–230.
- [361] U. Stańczyk, “Feature Evaluation by Filter, Wrapper, and Embedded Approaches,” in *Feature Selection for Data and Pattern Recognition. Studies in Computational Intelligence*, vol. 584, Berlin, Heidelberg: Springer, 2015, pp. 29–44. doi: 10.1007/978-3-662-45620-0\_3.
- [362] D. Theng and K. K. Bhoyar, “Feature selection techniques for machine learning: a survey of more than two decades of research,” *Knowl Inf Syst*, vol. 66, no. 3, pp. 1575–1637, 2024, doi: 10.1007/s10115-023-02010-5.
- [363] U. M. Khaire and R. Dhanalakshmi, “Stability of feature selection algorithm: A review,” *Journal of King Saud University - Computer and Information Sciences*, vol. 34, no. 4, pp. 1060–1073, 2022, doi: 10.1016/j.jksuci.2019.06.012.
- [364] M. A. Fahmiin and T. H. Lim, “Evaluating the Effectiveness of Wrapper Feature Selection Methods with Artificial Neural Network Classifier for Diabetes Prediction,” in *Testbeds and Research Infrastructures for the Development of Networks and Communications: 14th EAI International Conference, TridentCom 2019*, Changsha, China: Springer International Publishing, 2019, pp. 3–17. doi: 10.1007/978-3-030-43215-7\_1.
- [365] S. Altelbany, “Evaluation of Ridge, Elastic Net and Lasso Regression Methods in Precedence of Multicollinearity Problem: A Simulation Study,” *Journal of Applied Economics and Business Studies*, vol. 5, no. 1, pp. 131–142, 2021, doi: 10.34260/jaeb.517.
- [366] N. Pudjihartono, T. Fadason, A. W. Kempa-Liehr, and J. M. O’Sullivan, “A Review of Feature Selection Methods for Machine Learning-Based Disease Risk Prediction,” *Frontiers in Bioinformatics*, vol. 2, pp. 1–17, 2022, doi: 10.3389/fbinf.2022.927312.
- [367] T. Yin, H. Chen, Z. Yuan, T. Li, and K. Liu, “Noise-resistant multilabel fuzzy neighborhood rough sets for feature subset selection,” *Inf Sci (N Y)*, vol. 621, pp. 200–226, 2023, doi: 10.1016/j.ins.2022.11.060.

- [368] B. Venkatesh and J. Anuradha, “A Review of Feature Selection and Its Methods,” *Cybernetics and Information Technologies*, vol. 19, no. 1, pp. 3–26, 2019, doi: 10.2478/cait-2019-0001.
- [369] S. Biswas, M. Bordoloi, and B. Purkayastha, “Review on Feature Selection and Classification using Neuro-Fuzzy Approaches,” *International Journal of Applied Evolutionary Computation*, vol. 7, no. 4, pp. 28–44, 2016, doi: 10.4018/IJAEC.2016100102.
- [370] M. Abdullah, M. Al-Ayyoub, S. AlRawashdeh, and F. Shatnawi, “E-learningDJUST: E-learning dataset from Jordan university of science and technology toward investigating the impact of COVID-19 pandemic on education,” *Neural Comput Appl*, vol. 35, no. 16, pp. 11481–11495, 2023, doi: 10.1007/s00521-021-06712-1.
- [371] E. M. Karabulut, S. A. Özal, and T. İbrikçi, “A comparative study on the effect of feature selection on classification accuracy,” *Procedia Technology*, vol. 1, pp. 323–327, 2012, doi: 10.1016/j.protcy.2012.02.068.
- [372] S. Gbashi *et al.*, “Application of a generative adversarial network for multi-featured fermentation data synthesis and artificial neural network (ANN) modeling of bitter gourd-grape beverage production,” *Sci Rep*, vol. 13, no. 1, pp. 1–15, 2023, doi: 10.1038/s41598-023-38322-3.
- [373] M. A. Hall, “Correlation-based feature selection for machine learning,” PhD thesis, The University of Waikato, 1999.
- [374] R. Kohavi and G. H. John, “Wrappers for feature subset selection,” *Artif Intell*, vol. 97, no. 1–2, pp. 273–324, 1997, doi: 10.1016/S0004-3702(97)00043-X.
- [375] K. O. Akande, T. O. Owolabi, and S. O. Olatunji, “Investigating the effect of correlation-based feature selection on the performance of support vector machines in reservoir characterization,” *J Nat Gas Sci Eng*, vol. 22, pp. 515–522, 2015, doi: 10.1016/j.jngse.2015.01.007.
- [376] S. Halkjær and Ole Winther, “The effect of correlated input data on the dynamics of learning,” in *Proceedings of the 9th International Conference on Neural Information Processing Systems*, 1996, pp. 169–175.
- [377] C. Catal and B. Diri, “Investigating the effect of dataset size, metrics sets, and feature selection techniques on software fault prediction problem,” *Inf Sci (N Y)*, vol. 179, no. 8, pp. 1040–1058, 2009, doi: 10.1016/j.ins.2008.12.001.
- [378] Y. Zhang, Y. Yun, R. An, J. Cui, H. Dai, and X. Shang, “Educational Data Mining Techniques for Student Performance Prediction: Method Review and Comparison Analysis,” *Front Psychol*, vol. 12, pp. 1–19, 2021, doi: 10.3389/fpsyg.2021.698490.

- [379] J.-L. Hung, B. E. Shelton, J. Yang, and X. Du, “Improving Predictive Modeling for At-Risk Student Identification: A Multistage Approach,” *IEEE Transactions on Learning Technologies*, vol. 12, no. 2, pp. 148–157, 2019, doi: 10.1109/TLT.2019.2911072.
- [380] B. Vesin, K. Mangaroska, K. Akhuseyinoglu, and M. Giannakos, “Adaptive Assessment and Content Recommendation in Online Programming Courses: On the Use of Elo-rating,” *ACM Transactions on Computing Education*, vol. 22, no. 3, pp. 1–27, 2022, doi: 10.1145/3511886.
- [381] B. Vesin, M. Ivanović, A. Klašnja-Milićević, and Z. Budimac, “Protus 2.0: Ontology-based semantic recommendation in programming tutoring system,” *Expert Syst Appl*, vol. 39, no. 15, pp. 12229–12246, 2012, doi: 10.1016/j.eswa.2012.04.052.
- [382] R. Pelánek, “Application of time decay functions and the elo system in student modeling,” in *Proceedings of the 7th International Conference on Educational Data Mining (EDM 2014)*, 2014, pp. 21–27.
- [383] R. Pelánek, J. Papoušek, J. Řihák, V. Stanislav, and J. Nižnan, “Elo-based learner modeling for the adaptive practice of facts,” *User Model User-adapt Interact*, vol. 27, no. 1, pp. 89–118, 2017, doi: 10.1007/s11257-016-9185-7.
- [384] A. Bailly *et al.*, “Effects of dataset size and interactions on the prediction performance of logistic regression and deep learning models,” *Comput Methods Programs Biomed*, vol. 213, pp. 1–7, 2022, doi: 10.1016/j.cmpb.2021.106504.
- [385] J. Walters-Williams and Y. Li, “Estimation of Mutual Information: A Survey,” in *Rough Sets and Knowledge Technology: 4th International Conference, RSKT 2009*, Gold Coast, Australia: Springer Berlin Heidelberg, 2009, pp. 389–396. doi: 10.1007/978-3-642-02962-2\_49.
- [386] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, “SMOTE: Synthetic Minority Over-sampling Technique,” *Journal of Artificial Intelligence Research*, vol. 16, pp. 321–357, 2002, doi: 10.1613/jair.953.
- [387] E. Sariev and G. Germano, “Bayesian regularized artificial neural networks for the estimation of the probability of default,” *Quant Finance*, vol. 20, no. 2, pp. 311–328, 2020, doi: 10.1080/14697688.2019.1633014.
- [388] Q. Jodelet, X. Liu, and T. Murata, “Balanced softmax cross-entropy for incremental learning with and without memory,” *Computer Vision and Image Understanding*, vol. 225, pp. 1–11, 2022, doi: 10.1016/j.cviu.2022.103582.
- [389] M. Ferdowsi, A. Benigni, A. Monti, and F. Ponci, “Measurement Selection for Data-Driven Monitoring of Distribution Systems,” *IEEE Syst J*, vol. 13, no. 4, pp. 4260–4268, 2019, doi: 10.1109/JSYST.2019.2939500.

- [390] J. Hjort and M. Marmion, “Effects of sample size on the accuracy of geomorphological models,” *Geomorphology*, vol. 102, no. 3–4, pp. 341–350, 2008, doi: 10.1016/j.geomorph.2008.04.006.
- [391] D. R. B. Stockwell and A. T. Peterson, “Effects of sample size on accuracy of species distribution models,” *Ecol Modell*, vol. 148, no. 1, pp. 1–13, 2002, doi: 10.1016/S0304-3800(01)00388-X.
- [392] A. Vabalas, E. Gowen, E. Poliakoff, and A. J. Casson, “Machine learning algorithm validation with a limited sample size,” *PLoS One*, vol. 14, no. 11, pp. 1–20, 2019, doi: 10.1371/journal.pone.0224365.
- [393] J. Faber and L. M. Fonseca, “How sample size influences research outcomes,” *Dental Press J Orthod*, vol. 19, no. 4, pp. 27–29, 2014, doi: 10.1590/2176-9451.19.4.027-029.ebo.
- [394] Z. Cui and G. Gong, “The effect of machine learning regression algorithms and sample size on individualized behavioral prediction with functional connectivity features,” *Neuroimage*, vol. 178, pp. 622–637, 2018, doi: 10.1016/j.neuroimage.2018.06.001.
- [395] D. Rajput, W.-J. Wang, and C.-C. Chen, “Evaluation of a decided sample size in machine learning applications,” *BMC Bioinformatics*, vol. 24, no. 48, pp. 1–17, 2023, doi: 10.1186/s12859-023-05156-9.
- [396] J. Cohen, *Statistical Power Analysis for the Behavioral Sciences*. Hillsdale: Lawrence Erlbaum Associates, 1988. doi: 10.4324/9780203771587.
- [397] I. K. Fodor, “A survey of dimension reduction techniques,” Livermore, CA (US), 2002.
- [398] H. Kaur, H. Nori, S. Jenkins, R. Caruana, H. Wallach, and J. Wortman Vaughan, “Interpreting Interpretability: Understanding Data Scientists’ Use of Interpretability Tools for Machine Learning,” in *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*, New York, NY, USA: ACM, 2020, pp. 1–14. doi: 10.1145/3313831.3376219.
- [399] A. Chatzimparmpas, R. M. Martins, I. Jusufi, and A. Kerren, “A survey of surveys on the use of visualization for interpreting machine learning models,” *Inf Vis*, vol. 19, no. 3, pp. 207–233, 2020, doi: 10.1177/1473871620904671.
- [400] S. Verma and R. K. Yadav, “Effect of Different Attributes on the Academic Performance of Engineering Students,” in *2020 IEEE International Conference on Advent Trends in Multidisciplinary Research and Innovation (ICATMRI)*, IEEE, 2020, pp. 1–4. doi: 10.1109/ICATMRI51801.2020.9398442.
- [401] E. Rubin, C. Roch, and S. Roch, “Grading Teacher Performance Appraisal Systems: Understanding the Implications of Student Test Scores and Performance Information Use,” *Public Performance & Management Review*, vol. 46, no. 2, pp. 257–284, 2023, doi: 10.1080/15309576.2022.2118798.

- [402] M. Alkayed, F. Almasalha, M. Hijjawi, and M. H. Qutqut, “Factors Analysis Affecting Academic Achievement of Undergraduate Student: A study on Faculty of Information Technology Students at Applied Science Private University,” in *2023 International Conference on Business Analytics for Technology and Security (ICBATS)*, IEEE, 2023, pp. 1–12. doi: 10.1109/ICBATS57792.2023.10111100.
- [403] F. Ouyang, M. Wu, L. Zheng, L. Zhang, and P. Jiao, “Integration of artificial intelligence performance prediction and learning analytics to improve student learning in online engineering course,” *International Journal of Educational Technology in Higher Education*, vol. 20, no. 1, pp. 1–23, 2023, doi: 10.1186/s41239-022-00372-4.
- [404] G. Ramaswami, T. Susnjak, A. Mathrani, and R. Umer, “Use of Predictive Analytics within Learning Analytics Dashboards: A Review of Case Studies,” *Technology, Knowledge and Learning*, vol. 28, no. 3, pp. 959–980, 2023, doi: 10.1007/s10758-022-09613-x.
- [405] F. Okubo, A. Shimada, C. Yin, and H. Ogata, “Visualization and prediction of learning activities by using discrete graphs,” in *23rd international conference on computers in education, ICCE 2015*, 2015, pp. 739–744.
- [406] P. Setiaji *et al.*, “Best Model and Performance of Bayesian Regularization Method for Data Prediction,” *J Phys Conf Ser*, vol. 1933, no. 1, pp. 1–9, 2021, doi: 10.1088/1742-6596/1933/1/012030.
- [407] A. Suliman and B. Omarov, “Applying Bayesian Regularization for Acceleration of Levenberg Marquardt based Neural Network Training,” *International Journal of Interactive Multimedia and Artificial Intelligence*, vol. 5, no. 1, pp. 68–72, 2018, doi: 10.9781/ijimai.2018.04.004.
- [408] F. Nargesian, H. Samulowitz, U. Khurana, E. B. Khalil, and D. Turaga, “Learning Feature Engineering for Classification,” in *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence*, California: International Joint Conferences on Artificial Intelligence Organization, 2017, pp. 2529–2535. doi: 10.24963/ijcai.2017/352.
- [409] W. Bagunaid, N. Chilamkurti, and P. Veeraraghavan, “AISAR: Artificial Intelligence-Based Student Assessment and Recommendation System for E-Learning in Big Data,” *Sustainability*, vol. 14, no. 17, pp. 1–22, 2022, doi: 10.3390/su141710551.
- [410] A. Jain *et al.*, “Overview and Importance of Data Quality for Machine Learning Tasks,” in *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, New York, NY, USA: ACM, 2020, pp. 3561–3562. doi: 10.1145/3394486.3406477.
- [411] D. C. Howell, “The treatment of missing data,” in *The Sage handbook of social science methodology*, Thousand Oaks, CA: Sage Publications Ltd, 2007, pp. 208–224.

- [412] R. W. Cooksey, “Descriptive Statistics for Summarising Data,” in *Illustrating Statistical Procedures: Finding Meaning in Quantitative Data*, Singapore: Springer Singapore, 2020, pp. 61–139. doi: 10.1007/978-981-15-2537-7\_5.
- [413] Y. Tint and Y. Mikami, “A minimum redundancy maximum relevance-based approach for multivariate causality analysis,” *International Journal of Advanced Computer Science and Applications*, vol. 8, no. 9, pp. 13–20, 2017.
- [414] S. Cateni, V. Colla, and M. Vannucci, “Improving the Stability of the Variable Selection with Small Datasets in Classification and Regression Tasks,” *Neural Process Lett*, vol. 55, no. 5, pp. 5331–5356, 2023, doi: 10.1007/s11063-022-10916-4.
- [415] V. K. Chauhan, K. Dahiya, and A. Sharma, “Problem formulations and solvers in linear SVM: a review,” *Artif Intell Rev*, vol. 52, no. 2, pp. 803–855, 2019, doi: 10.1007/s10462-018-9614-6.
- [416] Y. Yamasari, A. Qoiriah, N. Rochmawati, K. Yoshimoto, R. A. Ahmad, and O. V. Putra, “Detecting Students’ Behavior on the E-Learning System Using SVM Kernels - Based Ensemble Learning Algorithm,” *International Journal of Intelligent Engineering and Systems*, vol. 16, no. 1, pp. 142–153, 2023, doi: 10.22266/ijies2023.0228.13.
- [417] M. Bansal, A. Goyal, and A. Choudhary, “A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning,” *Decision Analytics Journal*, vol. 3, pp. 1–21, 2022, doi: 10.1016/j.dajour.2022.100071.
- [418] N. A. Priyanka and D. Kumar, “Decision tree classifier: a detailed survey,” *International Journal of Information and Decision Sciences*, vol. 12, no. 3, pp. 246–269, 2020, doi: 10.1504/IJIDS.2020.108141.
- [419] A. Priyam, G. R. Abhijeeta, A. Rathee, and S. Srivastava, “Comparative analysis of decision tree classification algorithms,” *International Journal of current engineering and technology*, vol. 3, no. 2, pp. 334–337, 2013.
- [420] B. Charbuty and A. Abdulazeez, “Classification Based on Decision Tree Algorithm for Machine Learning,” *Journal of Applied Science and Technology Trends*, vol. 2, no. 1, pp. 20–28, 2021, doi: 10.38094/jastt20165.
- [421] P. Cunningham and S. J. Delany, “k-Nearest Neighbour Classifiers - A Tutorial,” *ACM Comput Surv*, vol. 54, no. 6, pp. 1–25, 2022, doi: 10.1145/3459665.
- [422] B. Sun and H. Chen, “A Survey of k Nearest Neighbor Algorithms for Solving the Class Imbalanced Problem,” *Wirel Commun Mob Comput*, vol. 2021, pp. 1–12, 2021, doi: 10.1155/2021/5520990.
- [423] J. Jordon *et al.*, “Synthetic Data - what, why and how?,” *arXiv preprint arXiv:2205.03257*, 2022.

- [424] B. M. Ozyildirim and M. Kiran, “Levenberg–Marquardt multi-classification using hinge loss function,” *Neural Networks*, vol. 143, pp. 564–571, 2021, doi: 10.1016/j.neunet.2021.07.010.
- [425] O. Rudenko, O. Bezsonov, and K. Oliinyk, “First-Order Optimization (Training) Algorithms in Deep Learning,” in *Proceedings of the 4th International Conference on Computational Linguistics and Intelligent Systems (COLINS 2020)*, Lviv, Ukraine, 2020, pp. 921–935.
- [426] D. Yi, J. Ahn, and S. Ji, “An Effective Optimization Method for Machine Learning Based on ADAM,” *Applied Sciences*, vol. 10, no. 3, pp. 1–20, 2020, doi: 10.3390/app10031073.
- [427] S. Hussain, Z. F. Muhsion, Y. K. Salal, P. Theodorou, F. Kurtoğlu, and G. C. Hazarika, “Prediction Model on Student Performance based on Internal Assessment using Deep Learning,” *International Journal of Emerging Technologies in Learning (iJET)*, vol. 14, no. 8, pp. 4–22, 2019, doi: 10.3991/ijet.v14i08.10001.
- [428] F. Giannakas, C. Troussas, I. Voyatzis, and C. Sgouropoulou, “A deep learning classification framework for early prediction of team-based academic performance,” *Appl Soft Comput*, vol. 106, pp. 1–17, 2021, doi: 10.1016/j.asoc.2021.107355.
- [429] C. Desai, “Comparative analysis of optimizers in deep neural networks,” *Int J Innov Sci Res Technol*, vol. 5, no. 10, pp. 959–962, 2020.
- [430] B. Zhang, Y. LI, Y. SHI, and L. Hou, “Recognition and Application of Learner’s Cognitive Ability for Adaptive E-learning,” in *2020 IEEE 20th International Conference on Advanced Learning Technologies (ICALT)*, Tartu, Estonia: IEEE, 2020, pp. 62–64. doi: 10.1109/ICALT49669.2020.00025.
- [431] S. Alstrup, C. Hansen, C. Hansen, N. Hjuler, S. Lorenzen, and N. Pham, “DABAI: A data driven project for e-Learning in Denmark,” in *European Conference on e-Learning*, Academic Conferences International Limited, 2017, pp. 18–24.
- [432] J. B. Wandler and W. J. Imbriale, “Promoting undergraduate student self-regulation in online learning environments,” *Online Learning*, vol. 21, no. 2, pp. 1–16, 2017.
- [433] K. Hamdan and A. Amorri, “The impact of online learning strategies on students’ academic performance,” in *E-learning and digital Education in the twenty-first century*, 2022, ch. 3, pp. 39–56.
- [434] R. Cai, “Adaptive Learning Practice for Online Learning and Assessment,” in *Proceedings of the 2018 International Conference on Distance Education and Learning*, New York, NY, USA: ACM, 2018, pp. 103–108. doi: 10.1145/3231848.3231868.
- [435] L. A. Sharp and M. Hamil, “Impact of a Web-Based Adaptive Supplemental Digital Resource on Student Mathematics Performance,” *Online Learning*, vol. 22, no. 1, pp. 81–92, 2018.

- [436] J. F. Eichler and J. Peeples, “Online Homework Put to the Test: A Report on the Impact of Two Online Learning Systems on Student Performance in General Chemistry,” *J Chem Educ*, vol. 90, no. 9, pp. 1137–1143, 2013, doi: 10.1021/ed3006264.
- [437] M. Hu and H. Li, “Student Engagement in Online Learning: A Review,” in *2017 International Symposium on Educational Technology (ISET)*, IEEE, 2017, pp. 39–43. doi: 10.1109/ISET.2017.717.
- [438] J. Davies and M. Graff, “Performance in e-learning: online participation and student grades,” *British Journal of Educational Technology*, vol. 36, no. 4, pp. 657–663, 2005, doi: 10.1111/j.1467-8535.2005.00542.x.
- [439] K. Karthikeyan and P. Kavipriya, “On Improving Student Performance Prediction in Education Systems using Enhanced Data Mining Techniques,” *International Journal of Advanced Research in Computer Science and Software Engineering*, vol. 7, no. 5, pp. 935–941, 2017, doi: 10.23956/ijarcsse/SV7I5/0348.
- [440] A. Y. Huang *et al.*, “Personalized Intervention based on the Early Prediction of At-risk Students to Improve Their Learning Performance,” *Educational Technology & Society*, vol. 26, no. 4, pp. 69–89, 2023.
- [441] W. Xing and D. Du, “Dropout Prediction in MOOCs: Using Deep Learning for Personalized Intervention,” *Journal of Educational Computing Research*, vol. 57, no. 3, pp. 547–570, 2019, doi: 10.1177/0735633118757015.
- [442] M. Adnan *et al.*, “Predicting at-Risk Students at Different Percentages of Course Length for Early Intervention Using Machine Learning Models,” *IEEE Access*, vol. 9, pp. 7519–7539, 2021, doi: 10.1109/ACCESS.2021.3049446.
- [443] H. Waheed, S.-U. Hassan, R. Nawaz, N. R. Aljohani, G. Chen, and D. Gasevic, “Early prediction of learners at risk in self-paced education: A neural network approach,” *Expert Syst Appl*, vol. 213, pp. 1–21, 2023, doi: 10.1016/j.eswa.2022.118868.
- [444] J. T. Avella, M. Kebritchi, S. G. Nunn, and T. Kanai, “Learning analytics methods, benefits, and challenges in higher education: A systematic literature review,” *Online Learning*, vol. 20, no. 2, pp. 13–29, 2016.
- [445] F. Ofori, E. Maina, and R. Gitonga, “Using machine learning algorithms to predict students’ performance and improve learning outcome: A literature based review,” *Journal of Information and Technology*, vol. 4, no. 1, pp. 33–55, 2020.
- [446] H.-C. Chen *et al.*, “Week-Wise Student Performance Early Prediction in Virtual Learning Environment Using a Deep Explainable Artificial Intelligence,” *Applied Sciences*, vol. 12, no. 4, pp. 1–16, 2022, doi: 10.3390/app12041885.

## **11. Prilozi**

### **11.1. Spisak slika**

Slika 1. Faze rudarenja podataka .....	29
Slika 2. Inteligentne tehnike u e-učenju .....	50
Slika 3. Primer u <i>ProTuS</i> -u .....	78
Slika 4. Izazov u <i>ProTuS</i> -u.....	79
Slika 5. Vežba kodiranja u <i>ProTuS</i> -u.....	79
Slika 6. Algoritam Bajesove regularizovane neuronske mreže .....	84
Slika 7. Evolucija srednje kvadratne greške tokom epoha .....	91
Slika 8. DT grafik uvida u faktore koji utiču na uspeh studenata.....	99
Slika 9. Dijagramski prikaz predložene metodologije .....	105
Slika 10. Kreiranje ML modela .....	114
Slika 11. Kreiranje ANN modela.....	116

## **11.2. Spisak grafikona**

Grafikon 1. Trend istraživanja 1 .....	51
Grafikon 2. Trend istraživanja 2 .....	52
Grafikon 3. Trend istraživanja 3 .....	52
Grafikon 4. Trend istraživanja 4 .....	53
Grafikon 5. Važnost ulaznih varijabli na osnovu mrMR kriterijuma .....	87
Grafikon 6. Rezultati tačnosti tradicionalnih ML tehnika 1 .....	89
Grafikon 7. Rezultati tačnosti tradicionalnih ML tehnika 2 .....	90
Grafikon 8. Rezultati tačnosti primenom tradicionalnih ML tehnika i ANN-a.....	97

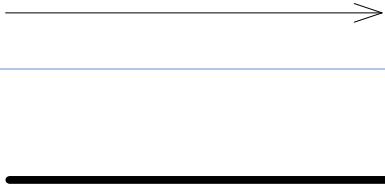
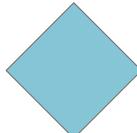
### **11.3. Spisak tabela**

Tabela 1. Sistemi za e-učenje sa OLM-om .....	28
Tabela 2. Sistemi za e-učenje sa obrazovnim rudarenjem podataka .....	31
Tabela 3. Sistemi za e-učenje sa praćenjem znanja .....	32
Tabela 4. Sistemi za e-učenje sa analitikom učenja.....	36
Tabela 5. Sistemi za e-učenje sa adaptivnom procenom znanja.....	39
Tabela 6. Sistemi za e-učenje sa preporukom sadržaja.....	41
Tabela 7. Sistemi za e-učenje sa sekvenciranjem resursa .....	43
Tabela 8. Sistemi za e-učenje sa generisanjem povratnih informacija .....	44
Tabela 9. Sistemi za e-učenje sa inteligentnim agentima.....	45
Tabela 10. Sistemi za e-učenje sa pedagoškim i konverzacijskim agentima .....	46
Tabela 11. Sistemi za e-učenje sa ostalim inteligentnim tehnikama.....	49
Tabela 12. Sistemi za e-učenje .....	53
Tabela 13. Opis ulaznih varijabli .....	81
Tabela 14. Deskriptivna statistika varijabli .....	86
Tabela 15. Relativna važnost prediktora sa mrMR i RF klasifikacionim algoritmom .....	88
Tabela 16. Osnovni elementi <i>UML</i> dijagrama aktivnosti.....	170

## 11.4. Osnovni elementi UML dijagrama aktivnosti

U ovom prilogu u Tabeli 16 prikazani su osnovni *UML* elementi dijagrama aktivnosti, sa ciljem lakšeg razumevanja dijagrama metodologije za predikciju uspeha studenata u sistemima za e-učenje prikazanog na Slici 9, koji je nacrtan uz pomoć *UML* dijagrama aktivnosti.

*Tabela 16. Osnovni elementi UML dijagrama aktivnosti*

<b>UML element</b>	<b>Naziv i kratak opis</b>
	<b>Početni čvor</b> - Početak svakog dijagrama aktivnosti započinje ovim čvorom.
	<b>Akcija</b> - Element koji opisuje akciju koja se trenutno odvija.
	<b>Tranzicija</b> - Strelica kojom se označava pravac kretanja dijagrama aktivnosti.
	<b>Račvanje</b> (eng. Fork) i <b>spajanje</b> (eng. Join) - Dva elementa koja uvek idu u paru i prikazuju se istim simbolom, a služe za prikaz akcija koje se dešavaju istovremeno.
	<b>Odluka</b> (eng. Decision) i <b>spajanje</b> (eng. Merge) - Dva elementa koja često idu u paru, gde prvi označava donošenje odluke na osnovu određenih uslova, a drugi služi za spajanje više tranzicija nastalih usled odluke.
	<b>Konektor</b> - Služi za označavanje mesta završetka dijagrama na jednoj stranici i njegov početak na drugoj stranici.
	<b>Završni čvor</b> - Kraj svakog dijagrama aktivnosti završava ovim čvorom.

## **12. Biografija**

Miloš (Mirko) Ilić rođen je u Beogradu 01.06.1991. godine. Osnovne akademske studije završio je 2016. godine sa prosekom 10,00 na Fakultetu informacionih tehnologija Alfa BK Univerziteta i stekao zvanje diplomirani inženjer informacionih tehnologija. Master akademske studije završio je 2018. godine sa prosekom 10,00, takođe na Fakultetu informacionih tehnologija Alfa BK Univerziteta i stekao zvanje master inženjer informacionih tehnologija. Oblasti njegovog interesovanja su e-učenje, programiranje, baze podataka i veštačka inteligencija. Zaposlen je kao asistent na Fakultetu informacionih tehnologija i Fakultetu za matematiku i računarske nauke Alfa BK Univerziteta. Autor je ili koautor četiri naučna rada u časopisima sa SCI liste, četiri rada u časopisima van SCI liste i petnaest radova na konferencijama.



## IZJAVA O AUTORSTVU

**1. Potpisani:** Miloš Ilić

**2. Broj upisa:** 5901/2020

**3. Izjavljujem da je doktorska disertacija pod naslovom:**

PREDIKCIJA USPEHA STUDENATA U SISTEMIMA ZA E-UČENJE PRIMENOM  
TEHNIKA VEŠTAČKE INTELIGENCIJE: RAZVOJ METODOLOGIJE I PRAKTIČNE  
IMPLIKACIJE

- Rezultat sopstvenog istraživačkog rada.
- Da predložena disertacija u celini ni u delovima nije bila predložena za dobijanje bilo koje diplome prema studijskim programima drugih visokoškolskih ustanova.
- Da su rezultati korektno navedeni.
- Da nisam kršio autorska prava i koristio intelektualnu svojinu drugih lica.

U Beogradu, \_\_\_\_\_

Potpis doktoranda



Алфа БК Универзитет

**IZJAVA O ISTOVETNOSTI ŠTAMPANE I ELEKTRONSKE VERZIJE  
DOKTORSKOG RADA**

**Ime i prezime:** Miloš Ilić

**Broj upisa:** 5901/2020

**Studijski program:** Informaciono-komunikacione tehnologije

**Naslov rada:** Predikcija uspeha studenata u sistemima za e-učenje primenom tehnika veštačke inteligencije: razvoj metodologije i praktične implikacije

**Mentor:** prof. dr Boban Vesin

Izjavljujem:

Da je štampana verzija mog doktorskog rada istovetna elektronskoj verziji koju sam predao za objavlјivanje u repozitorijumu na sajtu Alfa BK Univerziteta.

Dozvoljavam da se objave moji lični podaci vezani za dobijanje naučnog zvanja doktora nauka kao što su ime i prezime, godina i mesto rođenja, podaci o stečenim stručnim i akademskim zvanjima, datum odbrane rada i drugi podaci u funkciji transparentnosti postupka sticanja naučnog zvanja.

Ovi lični podaci mogu se objaviti u publikacijama Alfa BK Univerziteta i dostaviti Ministarstvu prosvete, nauke i tehnološkog razvoja, kao i biti dostupni saglasno Zakonu o slobodnom pristupu i informacijama od javnog značaja.

U Beogradu, \_\_\_\_\_

Potpis doktoranda

## **IZJAVA O KORIŠĆENJU**

Ovlašćujem Alfa BK Univerzitet da u Digitalni repozitorijum Univerziteta unese moju doktorsku disertaciju pod naslovom: „Predikcija uspeha studenata u sistemima za e-učenje primenom tehnika veštačke inteligencije: razvoj metodologije i praktične implikacije”, koja je moje autorsko delo.

Disertaciju sa svim prilozima predao sam u elektronskom formatu pogodnom za trajno arhiviranje.

Moju doktorsku disertaciju pohranjenu u Digitalnom repozitorijumu Univerziteta, dostavljenu repozitorijumu Ministarstva prosvete, nauke i tehnološkog razvoja Republike Srbije i dostupnu u otvorenom pristupu mogu da koriste svi koji poštuju odredbe sadržane u odabranom tipu licence Kreativne zajednice (*Creative Commons*) za koju sam se odlučio.

1. Autorstvo (*CC BY*)
2. **Autorstvo - nekomercijalno (*CC BY-NC*)**
3. Autorstvo - nekomercijalno - bez prerada (*CC BY-NC-ND*)
4. Autorstvo - nekomercijalno - deliti pod istim uslovima (*CC BY-NC-SA*)
5. Autorstvo - bez prerada (*CC BY-ND*)
6. Autorstvo - deliti pod istim uslovima (*CC BY-SA*)

(Molimo da zaokružite samo jednu od šest ponuđenih licenci. Kratak opis licenci je sastavni deo ove izjave).

Potpis autora

U Beogradu, \_\_\_\_\_

\_\_\_\_\_

- 1. Autorstvo.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence, čak i u komercijalne svrhe. Ovo je najslobodnija od svih licenci.
- 2. Autorstvo - nekomercijalno.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence. Ova licenca ne dozvoljava komercijalnu upotrebu dela.
- 3. Autorstvo - nekomercijalno - bez prerada.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, bez promena, preoblikovanja ili upotrebe dela u svom delu, ako se navede ime autora na način određen od strane autora ili davaoca licence. Ova licenca ne dozvoljava komercijalnu upotrebu dela. U odnosu na sve ostale licence, ovom licencom se ograničava najveći obim prava korišćenja dela.
- 4. Autorstvo - nekomercijalno - deliti pod istim uslovima.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence i ako se prerada distribuira pod istom ili sličnom licencom. Ova licenca ne dozvoljava komercijalnu upotrebu dela i prerada.
- 5. Autorstvo - bez prerada.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, bez promena, preoblikovanja ili upotrebe dela u svom delu, ako se navede ime autora na način određen od strane autora ili davaoca licence. Ova licenca dozvoljava komercijalnu upotrebu dela.
- 6. Autorstvo - deliti pod istim uslovima.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence i ako se prerada distribuira pod istom ili sličnom licencom. Ova licenca dozvoljava komercijalnu upotrebu dela i prerada. Slična je softverskim licencama, odnosno licencama otvorenog koda.



Алфа БК Универзитет

**IZJAVA MENTORA O PROCENI ORIGINALONOSTI I SAGLASNOSTI ZA PREDAJU  
URAĐENE DOKTORSKE DISERTACIJE**

Ovim izjavljujem da sam nakon pregledanog rukopisa doktorske disertacije saglasan da kandidat Miloš Ilić može da preda Službi za poslediplomske studije Univerziteta urađenu doktorsku disertaciju pod nazivom: „Predikcija uspeha studenata u sistemima za e-učenje primenom tehnika veštačke inteligencije: razvoj metodologije i praktične implikacije”, radi organizacije njene ocene i odbrane i da ista sadrži originalan naučni doprinos koji se ogleda u: predloženoj metodologiji za predikciju uspeha studenata u sistemima za e-učenje i definisanim smernicama za pretprocesiranje podataka, koje donose bolje razumevanje važnosti tog procesa u svrhu poboljšanja tačnosti predikcije.

U Beogradu, \_\_\_\_\_

---

(potpis mentora)