



PRIRODOSLOVNO-MATEMATIČKI FAKULTET

IVAN PERAIĆ

**PRIMJENA ANALITIKE UČENJA ZA
NAPREDNO VREDNOVANJE ODGOJNO-
OBRAZOVNIH ISHODA**

DOKTORSKI RAD

MENTOR: prof. dr. sc. Ani Grubišić

Split, 2025.



FACULTY OF SCIENCE

IVAN PERAIĆ

**APPLYING LEARNING ANALYTICS
FOR ENHANCED EVALUATION OF
EDUCATION OUTCOMES**

DOCTORAL THESIS

SUPERVISOR: Full Professor Ani Grubišić, Ph.d.

Split, 2025.

ZAHVALA

Draga mentorice, prof. dr. sc. Ana Grubišić, od srca Vam zahvaljujem što ste me pratili na ovom putu i što ste u svakom trenutku bili uz mene. Vaše strpljenje, savjeti i podrška bili su mi stalni oslonac. Kada bih ponovno trebao prolaziti kroz isti proces, bez razmišljanja bih ponovno odabrao upravo Vas za svoju mentoricu. Osim što ste mi pomogli u profesionalnom razvoju i otvorili nove vidike, Vaša ljudska toplina i razumijevanje činili su svaki korak ovoga puta lakšim.

Hvala svim članovima povjerenstva, prof. dr. sc. Branku Žitku, izv. prof. dr. sc. Dijani Plantak Vukovac, doc. dr. sc. Angelini Gašpar, doc. dr. sc. Divni Krpan i doc. dr. sc. Jeleni Nakić, na vremenu, pažnji i vrijednim sugestijama.

Zahvaljujem se svim članovima tima *Enhancing Adaptive Courseware based on Natural Language Processing*, a posebno našem dragom profesoru Slavomiru Stankovu, koji mi je uvijek pružao podršku i čija su vrata bila otvorena u svakom trenutku.

Hvala mojim roditeljima, obitelji i prijateljima, koji su imali razumijevanja kada nisam imao vremena. Također, zahvaljujem se i kolegama s Odjela za informacijske znanosti Sveučilišta u Zadru te svima koji su na bilo koji način pridonijeli oblikovanju ove doktorske disertacije, bilo savjetom, sudjelovanjem u istraživanju ili stvaranjem pozitivne atmosfere.

Na kraju, posebna zahvala mojoj Ivani. Hvala ti što sve razumiješ i što si me stalno poticala da napredujem. I vama, zbog kojih sve ovo ima smisla, Karmela, Iris i Pave. Nadam se da ćete jednoga dana krenuti tatinim stopama i nositi istu strast i želju za istraživanjem i profesionalnim razvojem.

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Splitu

Doktorska disertacija

Prirodoslovno-matematički fakultet

Poslijediplomski sveučilišni studij

„Istraživanje u edukaciji u području prirodnih i tehničkih znanosti

PRIMJENA ANALITIKE UČENJA ZA NAPREDNO VREDNOVANJE ODGOJNO - OBRAZOVNIH ISHODA

IVAN PERAIĆ

Prirodoslovno-matematički fakultet

Ruđera Boškovića 33, 21 000 Split, Croatia

Sažetak:

Tijekom posljednjeg desetljeća sve se više prepoznaje potencijal analitike učenja (engl. Learning Analytics) za unaprjeđenje obrazovnih procesa. Jedan od najčešćih oblika njezine primjene su nadzorne ploče analitike učenja (engl. *Learning Analytics Dashboard*, LAD). Imajući u vidu specifične izazove poučavanja i učenja programiranja u visokom obrazovanju, ova disertacija istražuje mogućnosti primjene LAD-ova u tom kontekstu. U fokusu disertacije su dvije razvijene nadzorne ploče: Nadzorna ploča analitike učenja za studente (*Learning Analytics Dashboard for Students*, LAD-s) i Nadzorna ploča analitike učenja za nastavnike (*Learning Analytics Dashboard for Teachers*, LAD-t).

U teorijskom dijelu disertacije analizirani su i sistematizirani ključni koncepti razvoja analitike učenja, od njezinih temeljnih odrednica, preko primjene prediktivne analitike, do uloge LAD-ova u kontekstu digitalne transformacije obrazovanja. Teorijska osnova uključuje i sustavni pregled znanstvene literature, koji pruža uvid u dosadašnju primjenu i istraženost njihovog utjecaja u visokom obrazovanju.

Primjenom metoda prediktivnog modeliranja na stvarne podatke o studentskim aktivnostima na Moodle kolegiju Programiranje1 identificirani su čimbenici s najvećim utjecajem na akademski uspjeh u učenju i poučavanju programiranja. Time se omogućuje ranije prepoznavanje onih studenata kojima je potrebna dodatna podrška te oblikovanje nastavnih intervencija usmjerenih na ključne aspekte uspjeha. Nadalje, disertacija donosi novi konceptualni i tehnološki okvir vrednovanja ostvarenosti ishoda učenja integracijom analitike učenja u nastavni proces. Razvojem i primjenom nadzornih ploča analitike učenja, LAD-s i LAD-t, omogućeno je kontinuirano i realno praćenje napretka i postignuća učenika, čime se nadopunjuju tradicionalni pristupi vrednovanju.

Ovaj inovativni pristup omogućuje pravovremeno pružanje povratne informacije i prilagodbu nastavnih aktivnosti s ciljem učinkovitijeg učenja i poučavanja. Konačno, disertacija nudi skup empirijski utemeljenih i praktično primjenjivih preporuka za unaprjeđenje nastave programiranja kroz integraciju analitike učenja. Te preporuke proizlaze izravno iz empirijskih istraživanja i usmjerene su na specifične izazove u poučavanju programiranja, što im daje posebnu vrijednost i mogućnost da utječu na pedagošku praksu.

Ključne riječi: e-učenje, analitika učenja, nadzorna ploča analitike učenja, predviđanje uspjeha učenika, ishodi učenja

Mentor: prof. dr. sc. Ani Grubišić

Ocjenjivači:

1. prof. dr. sc. Branko Žitko
2. izv. prof. dr. sc. Dijana Plantak Vukovac
3. doc. dr. sc. Angelina Gašpar
4. doc. dr. sc. Divna Krpan
5. doc. dr. sc. Jelena Nakić
6. doc. dr. sc. Nikola Marangunić

BASIC DOCUMENTATION CARD

University of Split

Doctoral Thesis

Faculty of Science

Doctoral program

„Science and Engineering Education Research“

APPLYING LEARNING ANALYTICS FOR ENHANCED EVALUATION OF EDUCATION OUTCOMES

IVAN PERAIĆ

Faculty of Science

Ruđera Boškovića 33, 21 000 Split, Croatia

Abstract:

Over the past decade, the potential of Learning Analytics for enhancing educational processes has become increasingly recognized. One of its most common applications is the Learning Analytics Dashboard (LAD). In light of the specific challenges associated with teaching and learning programming in higher education, this dissertation investigates the use of LADs in that context. The study focuses on two purpose-built dashboards: LAD-s (Learning Analytics Dashboard for Students) and LAD-t (Learning Analytics Dashboard for Teachers). In the theoretical part of the dissertation, key concepts in the evolution of Learning Analytics are analyzed and systematized, ranging from its foundational principles and the application of predictive analytics to the role of LADs in the context of the digital transformation of education. The theoretical framework also includes a systematic review of the relevant scholarly literature, providing an overview of existing research on LADs in higher education.

By applying predictive modeling techniques to real data on student activities and behaviors, the factors with the greatest impact on academic success in programming education were identified. This enabled the early detection of students who require additional support and the design of targeted instructional interventions focusing on critical success factors.

Furthermore, the dissertation introduces a novel conceptual and technological framework for assessing learning outcomes through the integration of Learning Analytics into the teaching process. The development and deployment of the LAD-s and LAD-t dashboards facilitate continuous, real-time monitoring of learning progress and achievements, thereby complementing traditional assessment methods.

This innovative approach enables timely feedback and adaptation of instructional activities to support more effective teaching and learning. Finally, the dissertation offers a set of empirically grounded, practically applicable recommendations for improving programming instruction through the integration of Learning Analytics. These recommendations arise directly from empirical research and address the specific challenges of programming pedagogy, endowing them with particular value and the potential to impact educational practice.

Keywords: e-learning, learning analytics, learning analytics dashboard, prediction of students success, learning outcomes

Supervisor: Full Professor Ani Grubišić, PhD.

Reviewers:

1. Full Professor Branko Žitko, PhD
2. Associate Professor Dijana Plantak Vukovac, PhD
3. Assistant Professor Angelina Gašpar, PhD
4. Assistant Professor Divna Krpan, PhD
5. Assistant Professor Jelena Nakić, PhD
6. Assistant Professor Nikola Marangunić, PhD

SADRŽAJ

1. UVOD	1
1.1. CILJEVI ISTRAŽIVANJA I ISTRAŽIVAČKA PITANJA	4
2. PREGLED LITERATURE	6
2.1. DIGITALNA TRANSFORMACIJA OBRAZOVANJA	7
2.1.1. UČENJE NA DALJINU	7
2.1.2. INFORMACIJSKO-KOMUNIKACIJSKA TEHNOLOGIJA U OBRAZOVANJU	9
2.1.3. OBLICI UČENJA	11
2.1.4. E-UČENJE	11
2.1.5. SUSTAVI E-UČENJA	13
2.2. DEFINICIJE ANALITIKE UČENJA I RAZLIKE U ODNOSU NA SRODNE DISCIPLINE	16
2.2.1. RAZLIKE IZMEĐU ANALITIKE UČENJA I RUDARENJA PODATAKA U OBRAZOVNE SVRHE	18
2.2.2. RAZLOZI PORASTA KORIŠTENJA ANALITIKE U OBRAZOVANJU	22
2.2.3. PROCESNO OKRUŽENJE ANALITIKE UČENJA	23
2.2.4. MODELI ANALITIKE UČENJA	25
2.3 . NADZORNA PLOČA ANALITIKE UČENJA	34
2.3.1. POV RATNA INFORMACIJA KAO MOST IZMEĐU PODATAKA I AKCIJE	34
2.3.2. DEFINICIJA I KLASIFIKACIJA NADZORNIH PLOČA ANALITIKE UČENJA	35
2.3.3. RAZVOJ I PRIMJENA NADZORNE PLOČE ANALITIKE UČENJA TEMELJENE NA PODACIMA IZ LMS-A	37
2.3.4. DIZAJN NADZORNE PLOČE ANALITIKE UČENJA	39
2.4. PREDIKTIVNA ANALITIKA	42
2.4.1. UMJETNA INTELIGENCIJA I STROJNO UČENJE	42
2.4.2. KATEGORIJE STROJNOG UČENJA U PREDIKTIVNOJ ANALITICI	43
2.4.3. ISTRAŽIVANJA I TREND OVI U PREDVIĐANJU USPJEHA UČENIKA	46
2.5. ISHODI UČENJA	48
2.5.1. PRIMJENA ISHODA UČENJA U OBRAZOVNI PROCES: ULOGA KONSTRUKTIVNOG PORAVNANJA	48
2.5.2. TAKSONOMIJE OBRAZOVNIH CILJEVA/ISHODA	49
2.5.3. VAŽNOST ISHODA UČENJA	51
3. STANJE ISTRAŽENOSTI	53
3.1. ISTRAŽIVANJA O LAD-OVIMA U PROCESU UČENJA I POUČAVANJA	53

3.2.	SUSTAVNI PREGLED LITERATURE O LAD-OVIMA U PROCESU UČENJA I POUČAVANJA.....	56
3.2.1.	REZULTATI.....	59
3.3.	OSVRT NA REZULTATE SUSTAVNOG PREGLEDA LITERATURE	69
4.	NADZORNA PLOČA ANALITIKE UČENJA ZA UČENIKE I NASTAVNIKE	72
4.1.	IMPLEMENTACIJA LAD-OVA U MOODLE LMS	73
4.1.1.	PRISTUP I MANIPULACIJA PODACIMA.....	74
4.1.2.	PRINCIPI PRIKAZA POVRATNIH INFORMACIJA	75
4.1.3.	MODELIRANJE LAD-OVA PREMA ISHODIMA.....	76
4.2.	LAD-S	77
4.2.1.	KOMPONENTA AKTIVNOSTI.....	78
4.2.2.	KOMPONENTA USPJEHA.....	81
4.2.3.	KOMPONENTA PREDVIĐANJA	84
4.3.	LAD-T	85
4.3.1.	KOMPONENTA AKTIVNOSTI I USPJEHA	86
4.3.2.	KOMPONENTA ISHODI UČENJA	90
4.3.3.	KOMPONENTA PREDVIĐANJA	93
5.	METODOLOGIJA ISTRAŽIVANJA	95
5.1.	PREDMET I PROBLEM ISTRAŽIVANJA.....	97
5.2.	KONTEKST ISTRAŽIVANJA.....	98
5.3.	OBLIKOVANJE I VREDNOVANJE MODELA PREDVIĐANJA USPJEHA STUDENATA	102
5.4.	VREDNOVANJE	118
5.4.1.	VREDNOVANJE LAD-S.....	118
5.4.2.	VREDNOVANJE LAD-T.....	130
5.5.	PREPORUKE ZA UNAPRIJEĐENJE PRAKSE U NASTAVI PROGRAMIRANJA 141	
6.	ZAKLJUČAK	143
	LITERATURA.....	147
	PRILOZI.....	166
	ŽIVOTOPIS I POPIS JAVNO OBJAVLJENIH RADOVA	205

POPIS TABLICA

Tablica 1 Ključne razlike LA i EDM [pripremljeno prema: (Siemens & Baker, 2012)].....	20
Tablica 2 Neke od uobičajenih metoda LA i EDM [pripremljeno prema: (Romero & Ventura, 2013)]	21
Tablica 3 Preporuke za dizajn LAD-a i njihova primjena u praksi [pripremljeno prema (Jivet i ostali, 2018)].....	41
Tablica 4 Komparativna analiza rezultata	47
Tablica 5 Ciljevi razvoja LAD-ova	60
Tablica 6 Vrste podataka korištenih u pregledu prema učestalosti	62
Tablica 7 Analiza korisnika LAD-ova prema vrsti	62
Tablica 8 Tipovi povratnih informacija korišteni u LAD-ovima	63
Tablica 9 Povezanost ishoda učenja i nastavnih elemenata na kolegiju Programiranje 1	99
Tablica 10 Opis značajki skupa podataka korištenog za predviđanje uspjeha studenata.....	104
Tablica 11 Deskriptivna statistika skupa podataka	106
Tablica 12 Rezultati deset najboljih modela predviđanja prema mjerama i korištenim značajkama	113
Tablica 13 Rezultati skaliranih modela	115
Tablica 14 Skala za interpretaciju srednjih vrijednosti stavova izraženih na Likertovoj skali [pripremljeno prema (Alkharusi, 2022)]	120
Tablica 15 Deskriptivna statistika anketnih odgovora – upitnik A1	122
Tablica 16 Deskriptivna statistika anketnih odgovora – upitnik A2	123
Tablica 17 Deskriptivna statistika anketnih odgovora – upitnik A1	124
Tablica 18 Deskriptivna statistika anketnih odgovora – upitnik A2	125
Tablica 19 Vrijeme završetka zadataka za sve sudionike	137
Tablica 20 Problemi upotrebljivosti LAD-t	140

POPIS SLIKA

Slika 1 Broj radova o LA objavljenih u bazi Scopus i WoS	17
Slika 2 Glavna područja povezana s EDM [pripremljeno prema: (Romero & Ventura, 2013)]	19
Slika 3 Procesno okruženje LA prema Elias [pripremljeno prema (Elias, 2011)]	23
Slika 4 Procesno okruženje LA prema Chatti [pripremljeno prema (Chatti i ostali, 2012)] ..	24
Slika 5 Referentni model analitike učenja [pripremljeno prema (Chatti i ostali, 2012)]	26
Slika 6 Generički model analitike učenja [pripremljeno prema (Greller & Drachsler, 2012)]	31
Slika 7 Prikaz ponašanja učenika kroz LAD (Mazza & Dimitrova, 2004)	38
Slika 8 LAD Course Signals na Sveučilištu Purdue (Saqr, 2018)	39
Slika 9 Tri glavne kategorije ML i njihova primjena	43
Slika 10 Broj radova prema godini objave	58
Slika 11 Odabir komponente unutar LAD-a (učenici lijevo, nastavnici desno)	75
Slika 12 Modeliranje LAD-ova prema ishodima	76
Slika 13 Arhitektura LAD-s	77
Slika 14 Povratna informacija ukupnog broja aktivnosti	78
Slika 15 Povratna informacija o broju aktivnosti u posljednjih sedam dana	78
Slika 16 Povratna informacija o korištenju sustava tijekom procesa učenja i poučavanja (prikaz broja aktivnosti učenika na predmetu).	79
Slika 17 Obavijest o aktivnosti učenika tijekom procesa učenja i poučavanja	80
Slika 18 Komponenta aktivnosti	81
Slika 19 Povratna informacija o uspjehu na provjerama	82
Slika 20 Povratna informacija o provjerama koje dolaze (prikazuje naziv svake provjere znanja te maksimalan broj bodova koji se može ostvariti)	82
Slika 21 Povratna informacija o oblicima sudjelovanja u procesu učenja i poučavanja	83
Slika 22 Povratna informacija o općem uspjehu učenika	83
Slika 23 Komponenta uspjeha	84
Slika 24 Povratna informacija o predviđenom uspjehu učenika	85
Slika 25 Arhitektura LAD-t	86
Slika 26 Opće informacije	87
Slika 27 Popis učenika	88
Slika 28 Povratna informacija o broju pregleda nastavnih materijala	88

Slika 29 Oblici sudjelovanja na predmetu.....	89
Slika 30 Pregled aktivnosti po tjednima.....	89
Slika 31 Komponenta aktivnosti i uspjeha	90
Slika 32 Prikaz stupnja postignutosti ishoda učenja - individualno	92
Slika 33 Prikaz stupnja postignutosti ishoda učenja vezanog za nastavne elemente	92
Slika 34 Ishodi učenja po postotku	93
Slika 35 Komponenta predviđanja	94
Slika 36 Isječak skupa podataka korištenog za predviđanje uspjeha studenata	105
Slika 37 Distribucija svih značajki skupa podataka	107
Slika 38 Vremenski slijed provedbe istraživanja o percepciji učinkovitosti alata LAD-s.....	121
Slika 39 Vremenski slijed provedbe istraživanja	135
Slika 40 Prosječno vrijeme završetka zadataka.....	138
Slika 41 Usporedba prosječnog vremena dovršetka zadataka između naprednih korisnika i početnika	138

1. UVOD

Suvremeni svijet je nemoguće zamisliti bez informacijske i komunikacijske tehnologije, IKT (engl. Information and Communication Technology, ICT). Razvoj i primjena IKT-a donijeli su velike promjene u suvremeno društvo u kojem osobni razvoj pojedinca ovisi o znanju. Potreba za kvantitetom i kvalitetom znanja i vještina u što kraćem vremenu utječe na stalni rast ljudskog znanja.

Korištenje IKT-a u obrazovanju donosi brojne prednosti za stjecanje znanja i vještina, pri čemu se računala ističu kao ključni alat za unapređenje procesa učenja i poučavanja. Prednosti IKT-a potaknule su digitalnu transformaciju obrazovanja (Wi & Hwang, 2010), što je rezultiralo razvojem novih oblika nastave koji nadilaze tradicionalne oblike nastave ili nastavu u učionici. Nastava podržana IKT-om, mješovita (hibridna) nastava i online nastava, nude inovativne pristupe za unapređenje procesa učenja i poučavanja. Ipak, jedan od ključnih izazova primjene obrazovnih tehnologija odnosi se na omogućavanje adekvatne interakcije s učenicima, koja je neophodna za unapređenje istih. Kako bi se zadovoljile individualne potrebe učenika, potrebno je osigurati podršku tijekom procesa učenja i poučavanja (Hutinski & Aure, 2009).

U kontekstu digitalne transformacije obrazovanja posebno se ističe elektroničko učenje ili e-učenje (engl. e-learning) kao alternativni pristup učenju, koji je značajno proširio i unaprijedio metode učenja i poučavanja, osobito u visokom obrazovanju (Cappel & Hayen, 2004). E-učenje „najjednostavnije se definira kao učenje i poučavanje elektroničkim putem“ (Plantak Vukovac, 2012, str. 59). Razvoj e-učenja bilježi značajan napredak od 1980-ih godina, zahvaljujući kontinuiranom tehnološkom razvoju i sve većoj integraciji digitalnih tehnologija u sustave koji se koriste pri procesu učenja i poučavanja (Valsamidis i ostali, 2011). U usporedbi s tradicionalnim obrazovanjem, e-učenje nudi brojne prednosti kao što je fleksibilnost u učenju vlastitim tempom, uklanjajući vremenska i prostorna ograničenja učenicima. U društvu temeljenom na znanju, e-učenje ima ključnu ulogu u razvoju inovativnih ideja u obrazovanju (Kahiigi i ostali, 2008).

Jedni od ključnih alata za provedbu e-učenja su sustavi za upravljanje učenjem (engl. Learning Management Systems, LMS). LMS-ovi su web platforme koje pružaju interaktivno okruženje za učenje, te istovremeno olakšavaju administraciju, organizaciju, distribuciju i praćenje obrazovnih sadržaja te rezultata učenika (Turnbull i ostali, 2020).

Bez obzira na način korištenja LMS-a, interakcije korisnika sa sustavom generiraju digitalne tragove koji omogućuju primjenu analitike učenja (engl. Learning Analytics, LA) (Ferguson, 2012). Svaka aktivnost u LMS-u, poput klika mišem, posjeta web-stranici, interakcija s aplikacijom ili drugi oblik korištenja digitalnog alata, ostavlja podatkovni trag koji predstavlja digitalni otisak. LA omogućuje interpretaciju ovih podataka kako bi pružila dublji uvid u uspjeh učenika i njihove potrebe, s ciljem poboljšanja njihovih rezultata (Elias, 2011). Također, omogućuje i bolji uvid u potrebe učenika tijekom procesa učenja i poučavanja (Ali i ostali, 2013).

LA se primjenjuje kroz četiri vrste analitike (El Morr Christoand Ali-Hassan, 2019), (Susnjak i ostali, 2022): deskriptivna analitika (engl. descriptive analytics), dijagnostička analitika (engl. diagnostic analytics), prediktivna analitika (engl. predictive analytics, PA) i preskriptivna analitika (engl. prescriptive analytics). Deskriptivna analitika odgovara na pitanje „Što se dogodilo?“, dijagnostička na „Zašto se to dogodilo?“, dok PA odgovara na pitanje „Što će se dogoditi?“. Svaka od ovih vrsta analitike koristi različite tehnike analize podataka, od prepoznavanja obrazaca do predviđanja budućih događaja. PA, koja se temelji na algoritmima strojnog učenja (engl. Machine Learning, ML), često se koristi za predviđanje uspjeha učenika (Leitner i ostali, 2017). Ova vrsta analitike može pomoći učenicima u poboljšanju rezultata (He, 2013), dok nastavnici mogu prepoznati poteškoće učenika na vrijeme i pružiti im potrebnu podršku za daljnji napredak (Lust i ostali, 2013). Preskriptivna analitika predstavlja najnapredniju vrstu analitike jer se ne zaustavlja samo na opisivanju prošlih događaja (deskriptivna analitika) niti na predviđanju budućih trendova (PA), već odgovara na pitanje „Kako ostvariti željeni ishod?“ (Frazzetto i ostali, 2019). Drugim riječima, preskriptivna analitika predlaže konkretne odluke i akcije koje vode prema boljim rezultatima (Susnjak i ostali, 2022).

Vizualizacija podataka i izvještavanje ključni su za učinkovitost LA (Brown, 2012). Istraživanja pokazuju da vizualni prikazi relevantnih i ažuriranih podataka, mogu značajno poboljšati način na koji nastavnici podržavaju učenike i pomažu im u postizanju boljih rezultata (Vieira i ostali, 2018).

Nadzorna ploča analitike učenja (engl. Learning Analytics Dashboard, LAD) smatra se jednim od učinkovitih načina vizualizacije ostvarenih rezultata i izvještavanja, koji se nudi učenicima i nastavnicima. LAD pruža vizualni prikaz koji integrira informacije i pomaže korisnicima u procesu donošenja odluka. Glavna ideja je omogućiti korisnicima praćenje

aktivnosti kroz interakcije s LMS-om, kako bi mogli analizirati vlastiti napredak i usporediti se s drugima. LAD može koristiti različite vizualizacije kako bi složene informacije učinio lakšima za razumijevanje nastavnicima i učenicima (Elias, 2011). Prednosti uključuju prepoznavanje rizičnih učenika u smislu smanjenih performansi, što omogućava pružanje prilagođene pomoći (Gasevic i ostali, 2015), povećanje angažmana i sudjelovanja učenika (R. Bodily & Verbert, 2017), te općenito, podršku u poboljšanju iskustava učenja i poučavanja (Park & Jo, 2015; Sedrakyan i ostali, 2018). Na taj način učenici mogu samostalno upravljati svojim učenjem. Povratne informacije putem LAD-a pomažu nastavnicima u praćenju napretka učenika prema očekivanim odgojno-obrazovnim ishodima.

Odgojno-obrazovni ishodi učenja (u nastavku ishodi učenja) čine temelj procesa učenja i poučavanja, usmjeravajući ga prema jasno definiranim ciljevima koji omogućuju procjenu napretka učenika. Obrazovanje temeljeno na ishodima (engl. Outcome-based education) razvilo se kao suvremeni pristup koji u posljednje vrijeme sve više postaje prihvaćen i primjenjivan (Macayan, 2017). Ishodi učenja definiraju se kao jasni i nedvosmisleni iskazi o tome što se očekuje od učenika u određenoj domeni ili predmetnom području tijekom procesa učenja i poučavanja (Smjernice za vrednovanje procesa učenja i ostvarenosti ishoda u osnovnoškolskome i srednjoškolskome odgoju i obrazovanju, 2020). Jednostavno rečeno, ishodi učenja odnose se na znanja, vještine i vrijednosti koje učenici trebaju steći do završetka obrazovnog programa ili pojedinog predmeta/kolegija/tečaja (Premalatha, 2019). Bez obzira na razinu obrazovanja, ishodi učenja pomažu učenicima i nastavnicima da jasnije razumiju očekivane rezultate procesa učenja i poučavanja. U kontekstu učenja i poučavanja programiranja, jasno definirani ishodi učenja pomažu učenicima da bolje razumiju što se od njih očekuje, dok nastavnicima omogućuju učinkovitije praćenje napretka učenika.

S obzirom na važnost informatičkog obrazovanja, programiranje se ističe kao ključna vještina koja će imati presudnu ulogu u budućnosti (Ball & Zorn, 2015). Učenje programiranja razvija važne vještine poput rješavanja problema, dizajniranja sustava i analize podataka, te je postalo sastavni dio mnogih inženjerskih obrazovnih programa (Topalli & Cagiltay, 2018). Međutim, učenje programiranja može biti izazovno za početnike koji često brzo gube motivaciju i odustaju (Mladenovic i ostali, 2016), jer tradicionalni pristup učenju i poučavanju programiranja ne uvažava različite potrebe učenika. Taj izazov je ujedno i **motivacija** za izradu ove doktorske disertacije, jer smatramo da, u kontekstu učenja i poučavanja programiranja, LAD može pomoći učenicima u praćenju vlastitog napretka i prepoznavanju područja za

poboljšanje, dok nastavnicima omogućava praćenje napretka učenika u odnosu na postavljene ishode učenja. Budući da je pregledom literature utvrđena tek jedna primjena LAD alata koja uključuje vizualizaciju stupnja postignutosti ishoda učenja (Buvari i ostali, 2023), taj potencijal nije dovoljno iskorišten. Stoga će ovo istraživanje analizirati moguće prednosti takvog pristupa u kontekstu poboljšanja obrazovnih praksi, osobito u učenju i poučavanju programiranja.

1.1. CILJEVI ISTRAŽIVANJA I ISTRAŽIVAČKA PITANJA

Doktorska disertacija ima dva cilja.

- **Cilj 1: Identificirati ključne pokazatelje uspješnosti učenja programiranja putem analize podataka generiranih kroz nastavne aktivnosti i razviti model predviđanja uspjeha studenata.**
- **Cilj 2: Razviti novi pristup vrednovanju ostvarenosti ishoda učenja u nastavi programiranja korištenjem alata temeljenih na analitici učenja.**

U svrhu ostvarivanja ovih ciljeva definirani su sljedeći podciljevi:

Podcilj 1.1. Analizirati podatke generirane tijekom nastavnih aktivnosti kako bi se identificirali ključni pokazatelji uspješnosti učenja programiranja.

Podcilj 1.2. Izgraditi modele predviđanja uspjeha studenata primjenom algoritama strojnog učenja, nad svim mogućim kombinacijama značajki usporediti performanse modela koristeći standardne mjere (točnost, preciznost, odziv i F1 mjeru) kako bi se najbolji model mogao integrirati u nadzorne ploče analitike učenja.

Podcilj 2.1. Razviti i implementirati nadzornu ploču analitike učenja za studente koja omogućuje studentima kontinuirano praćenje vlastitog napretka i pruža podršku njihovoj samoregulaciji učenja.

Podcilj 2.2. Razviti i implementirati nadzornu ploču analitike učenja za nastavnike koja omogućuje praćenje ostvarenosti ishoda učenja studenata.

Podcilj 2.3. Vrednovati razvijene nadzorne ploče analitike učenja sa stvarnim korisnicima kako bi se ispitala njihova učinkovitost i upotrebljivost.

Podcilj 2.4. Formulirati konkretne preporuke za integraciju analitike učenja u postojeće prakse poučavanja u svrhu unaprjeđenja nastave programiranja.

U skladu s definiranim ciljevima i podciljevima, postavljaju se sljedeća istraživačka pitanja na koja se želi dobiti odgovor:

IP 1. Koji ključni pokazatelji uspješnosti učenja programiranja, identificirani analizom podataka generiranih kroz nastavne aktivnosti, imaju najveći prediktivni značaj za uspjeh studenata?

IP 2. Kakva je percepcija studenata o učinkovitosti nadzorne ploče analitike učenja?

IP 3. Kakva je upotrebljivost nadzorne ploče analitike učenja za nastavnike, te koji su mogući problemi u primjeni i smjernice za eventualna poboljšanja?

IP 4. Koje su preporuke za učinkovitu primjenu nadzornih ploča analitike učenja u svrhu poboljšanja nastavne prakse u području programiranja?

Kako bi dobili odgovore na istraživačka pitanja, istraživanje je strukturirano u tri faze:

- **Faza 1:** Oblikovanje i vrednovanje modela predviđanja uspjeha studenata.
- **Faza 2:** Izrada nadzornih ploča analitike učenja.
- **Faza 3:** Studenti i nastavnici vrednuju model nadzornih ploča

Ostatak rada strukturiran je na sljedeći način.

U **drugom** poglavlju razmatra se digitalna transformacija obrazovanja koja omogućava stvaranje podataka kroz nove oblike učenja. Nakon toga, slijedi potpoglavlje o LA kao ključnoj znanstvenoj disciplini za prikupljanje, analizu i interpretaciju nastalih podataka te potpoglavlje o LAD-u kao učinkovitom načinu prikazivanja podataka prikupljenih putem LMS-a, s posebnim osvrtom na važnost PA. Na kraju, obrađujemo važnost implementacije jasno definiranih ishoda učenja unutar ovog sustava. U **trećem** poglavlju je dan pregled trenutnog stanja istraženosti iz dvije ključne perspektive. Početni pregled postojećih LAD-ova u kontekstu obrazovanja obuhvaća analizu 101 LAD-a. Analizirani su korisnici, prikazani podaci, ciljevi razvoja te metode i tehnike prezentacije informacija. Nadalje, detaljno se istražuje primjena PA u LAD-ovima i rezultati vrednovanja LAD-ova u procesu učenja i poučavanja.

U **četvrtom** poglavlju detaljno se opisuje model nadzorne ploče napravljene u okviru istraživanja za ovu doktorsku disertaciju. U tom kontekstu, predstavlja se model nadzorne ploče analitike učenja za učenike (LAD-s) i model nadzorne ploče analitike učenja za nastavnike (LAD-t). U **petom** poglavlju opisuje se metodologija istraživanja. Istraživanje je provedeno u tri faze. Prva faza odnosi se na oblikovanje i vrednovanje modela predviđanja uspjeha studenta, a potom slijedi vrednovanje LAD-s i LAD-t. U **šestom** poglavlju daje se osvrt na doktorsku disertaciju i iznose se pojedini znanstveni doprinosi.

2. PREGLED LITERATURE

Akademski uspjeh učenika ključna je komponenta procesa učenja i poučavanja jer se smatra jednim od temeljnih kriterija za procjenu kvalitete obrazovnih institucija (*National Commission for Academic Accreditation & Assessment*, 2015). Autori često u literaturi definiraju akademski uspjeh učenika na različite načine, a jedan od njih je da „Uspjeh učenika podrazumijeva akademsko postignuće, sudjelovanje u obrazovno svrhovitim aktivnostima, zadovoljstvo, stjecanje željenog znanja, vještina i kompetencija, ustrajnost, ostvarenje ishoda učenja te uspjeh nakon završetka studija“ (Kuh i ostali, 2006, str. 7). York i ostali definiraju uspjeh učenika kao „Akademsko postignuće, zadovoljstvo, stjecanje vještina i kompetencija, ustrajnost, postizanje ishoda učenja i uspjeh u karijeri“ (York i ostali, 2015, str. 10). Unatoč ovim definicijama, u širem smislu, većina istraživanja definira akademski uspjeh učenika u užem smislu, najčešće kroz akademska postignuća mjerena ocjenama (Alyahyan & Dustegor, 2020). Prema N. Choi (2005), akademsko postignuće najčešće se kvantificira putem ocjena koje učenici ostvaruju tijekom procesa učenja i poučavanja. Stoga će se u nastavku ove disertacije termin 'uspjeh učenika' koristiti za bilo koju vrstu akademskog uspjeha učenika koja se mjeri ocjenama tijekom procesa učenja i poučavanja.

Za razliku od formativnog vrednovanja koje se ne ocjenjuje nego daje informaciju nastavnicima o trenutnom učinku studenata tijekom procesa učenja/poučavanja, sumativno vrednovanje podrazumijeva procjenu razine postignuća studenata na kraju procesa učenja (na kraju nastavne cjeline, na sredini ili na kraju semestra) te u pravilu rezultira ocjenom. (MZO, 2020).

2.1. DIGITALNA TRANSFORMACIJA OBRAZOVANJA

Elektroničko učenje ili (e-učenje) sve je popularniji način poučavanja i učenja, posebno u akademskim zajednicama koje su među prvima prihvatile ovaj pristup. Takav oblik obrazovanja pruža veću fleksibilnost u pristupu sadržaju, omogućuje prilagodbu individualnim potrebama i često nudi razinu interaktivnosti koju klasična nastava ne može postići.

2.1.1. UČENJE NA DALJINU

Odgojno-obrazovni proces (u daljnjem tekstu obrazovni proces) je sustavno organizirana zajednička aktivnost nastavnika i učenika na ostvarenju zadataka odgoja i obrazovanja (Bognar & Matijević, 2002). Obrazovanje na daljinu, koje uključuje i e-učenje, postoji već godinama te se razvija s napredovanjem moderne tehnologije. Kada se govori o obrazovanju, kao zasebnom društvenom području, nužno je istaknuti kako se ono treba svakodnevno prilagođavati gospodarskom i tehnološkom napretku.

Povijest obrazovanja na daljinu seže u 19. stoljeće. U Europi je 1840. godine osnovana prva dopisna škola (engl. correspondence school), dok je 1883. u New Yorku uveden prvi sveučilišni dopisni program (engl. correspondence program) (USDLA, 2011). Tijekom prve polovice 20. stoljeća ovaj se oblik obrazovanja širio kroz nove komunikacijske medije. Godine 1921. izdana je prva licenca za obrazovni radijski program (engl. educational radio program), a 1950. Državno sveučilište Iowa pokreće prve televizijske obrazovne programe (engl. educational TV programs). Jedan od najpoznatijih primjera ranog obrazovanja na daljinu jest „škola na daljinu“ (engl. School of the Air), koja je 1951. godine započela rad putem radija, a taj model i danas postoji u nekim izoliranim zajednicama. Godine 1969. osnovan je British Open University, dok je 1993. pokrenuto prvo akreditirano online sveučilište (engl. *online accredited university*) (USDLA, 2011). Osim kroz povijesni pregled, razvoj obrazovanja na daljinu može se sagledati i kroz različite generacije (Simpson & Anderson, 2012).

Prva generacija obrazovanja na daljinu imala je za cilj omogućiti pristup obrazovanju pojedincima koji su imali ograničen ili nikakav pristup obrazovnim resursima i institucijama (Simpson & Anderson, 2012). Zbog ograničenih mogućnosti dvosmjerne komunikacije u tehnologijama tog vremena, prva generacija obrazovanja na daljinu temeljila se na biheviorističkoj teoriji učenja, koje naglašavaju učenje kroz opažanje ponašanja i promjene ponašanja, a ne unutarnjih mentalnih procesa. Učenje nastaje putem povezanosti podražaja i reakcija, a tu povezanost upravo omogućuju obrazovne tehnologije (Buhamad, 2024).

Drugu generaciju obrazovanja na daljinu potaknule su tehnologije emitiranja putem radija i televizije. Iako su te tehnologije otvorile nove mogućnosti interakcije, kontakt između nastavnika i učenika ostao je na minimumu (Simpson & Anderson, 2012). Obrazovanje na daljinu oduvijek je bilo posredovano tehnologijom koja ga je ujedno definirala i oblikovala. Razvoj novih tehnologija omogućio je dostavu različitih sadržaja u obrazovanju na daljinu.

Treću generaciju obrazovanja na daljinu potaknule su mogućnosti dvosmjerne komunikacije, poput audio/video konferencija i računalne komunikacije u stvarnom vremenu (sinkrono) i odgođeno (asinkrono) (Simpson & Anderson, 2012). Povećana interakcija dovodi do prepoznavanja važnosti interakcije u programima obrazovanja na daljinu. Na sličan način, digitalne tehnologije i različite vrste komunikacije koje pružaju učvrstile su važnost interakcije u obrazovnim procesima.

Prema Davis i ostali (2009) kraj 1990-ih predstavlja prijelomnu točku između tradicionalnog učenja i inovativnih oblika učenja. U tom je razdoblju upravljanje učenjem prešlo s učionice, kakvu svi poznajemo, kakva i danas postoji, na novu razinu razvoja. Isti autori navode kako su tada „tradicionalna iskustva u učionici bila prenesena online, redizajnirana (ili barem drugačije konfigurirana) za računalno posredovanu isporuku i distribuirana putem interneta“ (Davis i ostali, 2009, str. 4).

Jedna od posebnosti obrazovanja na daljinu je njegova „lokacija“. Povijesno gledano, obrazovanje na daljinu uključivalo je određeni oblik „geografske razdvojenosti“ između učitelja i učenika, kao i među samim učenicima (Simonson i ostali, 2011). Međutim, s pojavom interneta, geografska razdvojenost između učitelja i učenika, odnosno među samim učenicima, može biti neznatna ili potpuno izostati, budući da dvije osobe mogu sudjelovati u obrazovanju na daljinu dok sjede jedna uz drugu, ali koristeći dva različita računala. Obrazovanje na daljinu u 21. stoljeću odvija se bilo gdje jer učenik može pristupiti materijalima za učenje na daljinu, što se najčešće odvija putem interneta (pomoću računala povezanog na mrežu).

Definirajući obrazovanje na daljinu, Moore & Diehl (2018) ističu kako su nastavnik i učenik u obrazovnom procesu odvojeni tako da se komunikacija između učenika i nastavnika odvija pomoću tehnologije. Danas se obrazovanje na daljinu smatra jednom od najobuhvatnijih obrazovnih metoda jer koristi IKT kako bi prevladalo prepreke u prijenosu i stjecanju znanja (Franco, 2022). Međutim, primjena tehnologija u obrazovanju na daljinu donosi promjene na

svim razinama društva, stoga se obrazovanje na daljinu sve više nameće u kontekstu trenutnih potreba i zahtjeva suvremenog društva.

2.1.2. INFORMACIJSKO-KOMUNIKACIJSKA TEHNOLOGIJA U OBRAZOVANJU

Informacijsko-komunikacijska tehnologija (IKT) obuhvaća računala, internet i elektroničke sustave za prijenos, kao što su radio, televizija i projektori, među ostalim, te je široko primijenjena u današnjem obrazovnom sustavu (J. S. Fu, 2013). IKT se sve uspješnije primjenjuje u poučavanju, učenju i vrednovanju znanja i smatra se važnim alatom za promjene u obrazovanju. Prikladna upotreba IKT može poboljšati kvalitetu obrazovanja i povezati učenje sa stvarnim životnim situacijama (Lowther i ostali, 2008). Prema Weert & Tatnall (2005), učenje je kontinuirana aktivnost koja traje cijeli život, pri čemu učenici mijenjaju svoja očekivanja u potrazi za znanjem, što se razlikuje od tradicionalnih pristupa. Kako vrijeme prolazi, od učenika će se očekivati da budu spremni tražiti nove izvore znanja, a vještine u korištenju IKT-a bit će ključne za uspjeh učenika.

Istraživanja pokazuju da IKT ima ključnu ulogu u transformaciji obrazovanja, usmjeravajući ga prema učenicima (Castro Sánchez & Alemán, 2011). Koristeći IKT u učionicama, učenici su aktivni sudionici u obrazovnom procesu, a nastavnici im omogućuju da donose vlastite odluke i planiraju (Lu i ostali, 2010). IKT otvara nove mogućnosti i resurse za učenike i za nastavnike. Prednosti uključivanja IKT-a u obrazovni proces definira J. S. Fu (2013), a neke od prednosti uključuju:

- **Učinkovit pristup digitalnim informacijama** - IKT omogućuje učenicima brz i učinkovit pristup informacijama. Kako navode Brush i ostali (2008), IKT je alat koji pomaže učenicima u istraživanju tema, rješavanju problema i pronalaženju rješenja tijekom obrazovnog procesa. Kroz IKT, učenici imaju pristup širokom spektru resursa, čime poboljšavaju svoje razumijevanje koncepata kroz praktičnu primjenu.
- **Podrška učenju usmjerenom na učenike i samostalnom učenju** - IKT omogućuje učenicima da značajno koriste računala (Castro Sánchez & Alemán, 2011). Učenici grade svoje znanje prikupljanjem, vrednovanjem i organiziranjem informacija, što im omogućuje veću samostalnost u učenju. Ova angažiranost potiče razvoj kritičkih vještina vrednovanja, jer učenici uče kako procijeniti kvalitetu informacija s kojima se susreću.

- **Stvaranje kreativnog okruženja za učenja** - IKT potiče kreativnost učenika, ohrabrujući ih da koriste nove pristupe učenju (Chai i ostali, 2010). Na primjer, e-knjige i interaktivne aplikacije za čitanje nude personalizirane aktivnosti koje zadovoljavaju različite preferencije u učenju. Ovi alati posebno su dizajnirani da inovativno zadovolje različite potrebe obrazovnog procesa.
- **Promicanje suradničkog učenja u okruženju učenja na daljinu** - Mustafa (2005) ističe da IKT olakšava suradnju među učenicima, omogućujući im da komuniciraju i dijele ideje u bilo kojem trenutku i s bilo kojeg mjesta. Na taj način stvaraju se tzv. virtualne učionice koje omogućuju učenicima iz cijelog svijeta međusobnu interakciju i zajednički rad, nudeći jedinstvene prilike za analizu problema, istraživanje koncepata i pronalaženje suradničkih rješenja.
- **Razvoj kritičkih vještina mišljenja** - IKT podržava konstruktivistički pristup učenju, usmjeravajući učenike na kritičko razmišljanje i rješavanje problema (Levin & Wadmany, 2006).
- **Poboljšanje kvalitete poučavanja i učenja** - Prema Lowther i ostali (2008), učinkovita integracija IKT-a poboljšava autonomiju, sposobnost i kreativnost učenika. Promicanjem autonomnog učenja, učenici stječu povjerenje, usavršavaju vještine i primjenjuju novo stečeno znanje na inovativne načine.

Olakšan pristup sadržaju predmeta – Nastavnici imaju ključnu ulogu u integraciji IKT-a u učionice što potvrđuje istraživanje Watts-Taffe i ostali (2003) u kojem se ističe da uz adekvatnu institucionalnu podršku, nastavnici lakše integriraju tehnologiju koja utječe na promjenu nastavnih metoda te omogućuje nastavnicima prilagodbu sadržaja i kreiranje zadataka koji potiču veću angažiranost učenika.

2.1.3. OBLICI UČENJA

Uvođenjem IKT u nastavu, pojavili su se novi oblici učenja. Obrazovne institucije u pravilu razlikuju četiri oblika učenja i izvođenja nastave (*Strategija e-učenja FOI-a.*, 2007)

- **klasična nastava** (engl. face-to-face) – je nastava u učionici, licem u lice, bez primjene IKT-a (osim npr. nastavnica za pripremu nastave),
- **nastava podržana IKT-om** (engl. ICT-supported teaching and learning) – IKT se koristi u svrhu poboljšanja klasične nastave. Koriste se tehnologije poput PowerPoint prezentacija, multimedijских CD-ROM-ova, web mjesta predmeta s hipermedijским nastavnim materijalima, programi za provjeru znanja, a za komunikaciju učenika i nastavnika elektronička pošta, distribucijske liste i forumi,
- **mješovita (hibridna) nastava** (engl. blended, mixed, hybrid learning) – kombinacija klasične nastave i nastave podržane IKT-om koju karakterizira upotreba sustava e-učenja, npr. LMS-a te videokonferencija. Obrazovni sadržaj u sustavu e-učenja koristi se tijekom nastave ili ga učenici koriste samostalno, izvan učionice.
- **online nastava** (engl. online learning) – učenje i poučavanje u potpunosti se izvodi s pomoću IKT-a, na daljinu, bez direktnog kontakta učenika i nastavnika. Sadržaj predmeta se dostavlja putem web sjedišta ili LMS-a, dok se za komunikaciju i poučavanje koriste videokonferencije.

Ova disertacija je usmjerena na mješovitu (hibridnu) nastavu, ali se za predviđanje uspjeha učenika koriste se podatci prikupljeni tijekom online nastave.

2.1.4. E-UČENJE

Elektroničko učenje ili e-učenje (engl. e-learning) najjednostavnije se definira kao učenje i poučavanje elektroničkim putem. Godine 2001., Europska komisija (engl. Commission of the European Communities) pokrenula je akcijski plan za e-učenje s ciljem oblikovanja obrazovanja budućnosti, poticanja primjene e-učenja u obrazovnim sustavima te pripreme sveučilišta za njegove učinke i neizbježne kulturne promjene (*Commission of the European Communities*, 2001). Te iste godine, Castells (2001) je predvidio da će tehnološka revolucija značajno utjecati na društvo i obrazovanje, gdje će tehnologija postati alat koji potiče sudjelovanje i otvorenost, istovremeno oblikujući procese učenja i komunikacije u kontekstu cjeloživotnog učenja. Ta predviđanja se ostvaruju, gdje danas istražujemo način na koji

nastavnici i učenici u današnjim obrazovnim sustavima koriste IKT za učenje i poučavanje u učionicama. Postoji niz istraživanja koja su potvrdila da je internet fleksibilan alat za učenje, omogućujući učenicima da uče vlastitim tempom, a ujedno proširuje mogućnosti modernog poučavanja i učenja (Hardaker & Singh, 2011; Macharia PhD & Pelser, 2012; Moos & Azevedo, 2009). Jedan od ciljeva elektroničkog učenja je razvoj individualiziranog, razumljivog, dinamičnog sadržaja za učenje, u realnom vremenu.

Demiray (2010) navodi da „e“ označava uključivanje i primjenu IKT, koja je omogućila prijelaz učenja iz analognog u digitalni svijet, dok „učenje“ upućuje na obrazovni proces. Dva osnovna smjera razvoja e-učenja su tehnički i pedagoški. Tehnički aspekt tehnologije usmjeren je na korištenje tehnologije kao sredstva za predstavljanje sadržaja, te ističe potrebu za pristupom koji učenika stavlja u središte obrazovnog procesa u kojem je e-učenje zapravo samoučenje. Smjer razvoja koji stavlja naglasak na pedagoški aspekt, usmjeren je na objašnjenje načina na koji učenici uče, kako stječu vještine i usvajaju informacije.

2.1.4.1. SINONIMI I DEFINICIJE E-UČENJA

B. Khan (2001) koristi pojam e-učenje za predstavljanje otvorenog, fleksibilnog i distribuiranog učenja, a sinonimi koje koristi su web-utemeljeno učenje (engl. Web-Based Learning), web utemeljena nastava (engl. Web-Based Instruction), web-utemeljena poduka (engl. Web-Based Training), vježbanje utemeljeno na internetu (engl. Internet-Based Training), raspodijeljeno učenje (engl. Distributed Learning), napredno raspodijeljeno učenje (engl. Advanced Distributed Learning), učenje na daljinu (engl. Distance Learning), online učenje (engl. Online Learning), mobilno učenje (engl. Mobile Learning, m-Learning, Nomadic Learning), daljinsko učenje (engl. Remote Learning).

Laurillard (2006), e-učenje definira kao interakciju u kojoj učenici koriste različite vrste IKT-a tijekom učenja. Strategija e-učenja Sveučilišta u Zagrebu (2007, str. 5) navodi kako je „e-učenje proces obrazovanja (proces učenja i poučavanja) uz uporabu informacijske i komunikacijske tehnologije, koja doprinosi unapređenju kvalitete toga procesa i kvalitete ishoda obrazovanja“. Aldrich (2003) navodi da e-učenje objedinjuje „procese, sadržaj i infrastrukturu“ te koristi računala i internet kako bi unaprijedilo i lanac učenja, koji obuhvaća upravljanje i isporuku obrazovnih sadržaja. Bhuasiri i ostali, (2012, str. 843) opisuju e-učenje kao „inovativan pristup u isporuci obrazovanja putem elektroničkih oblika informacija koji poboljšavaju znanje,

vještine ili druge aspekte uspješnosti učenika“. E-učenje također predstavlja internetski i web-sustav koji podržava obrazovni proces putem softverskih aplikacija i alata (Cassidy, 2016).

E-učenje se često opisuje kao interakcija učenika s digitalnim okruženjem koje je povezano s područjem znanja koje zanima učenika. Ovo digitalno okruženje u slučaju online učenja može obuhvatiti internet (u različitim oblicima), intranet mreže, kao i kompaktne diskove. U svim tim oblicima, e-učenje pruža efikasno okruženje kroz interaktivno korištenje teksta, slika, zvučnih i video materijala, animacija, te simulacija. Uz to, može uključivati i cijelo virtualno okruženje, omogućujući učenicima samostalno ili grupno učenje te vlastitim tempom upravljanje napretkom.

E-učenje ima brojne prednosti u usporedbi s tradicionalnim obrazovanjem u učionici. Prije svega, omogućuje prilagodljiv tempo rada za svakog učenika, često s nižim troškovima, bez vremenskog i prostornog ograničenja. Također, materijali za učenje lakše se ažuriraju, čime se osigurava njihova relevantnost i aktualnost. Obrazovanje u kontekstu društva znanja ima ključnu ulogu u razvoju novih ideja u učenju i poučavanju putem e-učenja (Kahiigi i ostali, 2008).

2.1.5. SUSTAVI E-UČENJA

Živimo u vremenu kada tradicionalno učenje u učionici postaje sve manje važno. Danas su učenici često nezadovoljni načinom provođenja nastave jer im se nameće određeno vrijeme i mjesto za učenje. Zahvaljujući novim tehnologijama i mobilnim uređajima, nova generacija može učiti i istraživati bez potrebe za fizičkim okupljanjem. Razvojni inženjeri i obrazovne institucije prepoznali su taj trend i počeli koristiti sustave koji olakšavaju izvođenje predmeta i komunikaciju s učenicima na daljinu.

Postoji mnogo pojmova vezanih uz online učenje i tehnologije koje ga podržavaju, a često dolazi do zabune kod korištenja termina sustav za upravljanje sadržajem (engl. Content Management System, CMS) i sustav za upravljanje učenjem (LMS). CMS su softverske aplikacije koje pomažu u stvaranju i upravljanju digitalnim sadržajem u suradničkom okruženju. LMS, prema Watson & Watson (2007), se koristi, uglavnom, za online ili mješovitu (hibridnu) nastavu. LMS pomaže u postavljanju nastavnih materijala na mrežu, povezivanju učenika s predmetima, praćenju uspjeha učenika, pohrani njihovih radova i olakšavanju komunikacije između učenika i nastavnika. Ova razlika između CMS-a i LMS-a nije uvijek potpuno jasna, pa mnogi smatraju da su ti pojmovi sinonimi.

Da bi situacija bila još složenija, neki stručnjaci koriste termin sustav za upravljanje sadržajem za učenje (engl. Learning Content Management System, LCMS). LCMS sustavi mogu se promatrati kao nadogradnja LMS-a, a omogućuju oblikovanje, pospremanje, korištenje i ponovnu upotrebu sadržaja za učenje (Kats, 2010). Većina LCMS-ova ima osnovnu funkcionalnost LMS-ova, a analogno tome mnogi LMS-ovi uključuju aspekte upravljanja sadržajem. Primarni cilj LMS-a je upravljanje polaznicima, praćenje njihova napretka i performansi kroz sve tipove aktivnosti, dok je cilj LCMS-a upravljanje sadržajem i predmetom učenja koji se nude pravom polazniku u pravo vrijeme (Bulić, 2018). U daljnjem tekstu koristiti ćemo akronim LMS pod kojim će se podrazumijevati karakteristike sustava koje ima i LMS i LCMS/CMS.

2.1.5.1. POVIJEST I RAZVOJ LMS-A

Prema Lang (2023), Sidney Pressey zaslužan je za razvoj prvog LMS-a, Teaching Machine, 1924. godine. Godine 1956. Gordon Pask dizajnirao je SAKI (engl. Self Adaptive Keyboard Instruction). SAKI je imao sposobnost prilagoditi upute prema razini vještina korisnika. PLATO (engl. Programmed Logic for Automated Teaching Operations), razvijen 1960. na Sveučilištu Illinois, koji je omogućavao učenje u različitim disciplinama, čime je postavio temelje digitalnog obrazovanja. Plato je bio prvi distribuirani sustav koji je radio na više od 7.000 terminala, distribuirajući materijale u više od 150 predmeta do 1980. godine.

Godine 1980., The Learning Manager predstavljen je kao sljedeća generacija LMS-a (R. Khan & Hassan, 2021). Prema Yousaf i ostali (2021), sustav Andrew, uveden 1982. na Sveučilištu Carnegie Mellon, ponudio je napredan paket alata za izradu i uređivanje dokumenata, razmjenu poruka, pristup oglasnim pločama te rad na projektima.

MIT je 1983. pokrenuo Projekt ATHENS kako bi učenicima omogućio pristup računalima diljem sveučilišta (Balkovich i ostali, 1985). Kent Norman je 1990. na Sveučilištu Maryland predstavio inovativni LMS HyperCourseware (Yousaf i ostali, 2021), dok je iste godine tvrtka SoftArc razvila FirstClass (Al-Dhief i ostali, 2024).

Veliki napredak dogodio se 1996. kada je Murray Goldberg razvio WebCT na Sveučilištu British Columbia (Turnbull i ostali, 2020). Sljedeće godine pojavila se platforma Blackboard, koja je i danas jedan od najpopularnijih LMS-ova u svijetu. Moodle (engl. Modular Object-Oriented Dynamic Learning Environment), kao jedan od najvažnijih LMS-ova, prvi put je predstavljen 2002. godine (Dougiamas & Taylor, 2003).

2.1.5.2. DEFINICIJE LMS-A

LMS je alat koji unapređuje iskustvo učenja i razumijevanje različitih tema u obrazovanju (Kasim & Khalid, 2016). Riječ je o web platformama koje pružaju interaktivno okruženje za učenje, olakšavaju administraciju, organizaciju, isporuku i praćenje obrazovnih sadržaja i rezultata učenika (Turnbull i ostali, 2020). LMS ima ključnu ulogu u pedagogiji, omogućujući pristup, fleksibilnost i ekonomičnost u visokom obrazovanju (Chaubey & Bhattacharya, 2015). Berking & Gallagher, (2016, str. 6) dodatno naglašavaju važnost LMS-a, opisujući ga kao „ključnu tehnologiju koja omogućuje pristup sadržaju za učenje i administraciju bilo kada i bilo gdje”. LMS kao virtualno okruženje povezuje učenike, nastavnike i administrativno osoblje, čime omogućuje bolje praćenje i personalizaciju obrazovnog procesa (Başaran & Mohammed, 2020).

Prema Kaya Keleş & Özel (2016), danas postoji velik broj različitih LMS-ova. Među najčešće korištenima su Moodle, Blackboard, Brightspace, Canvas, Docebo, Google Classroom, Schoology i Edmodo (Simon i ostali, 2024). Moodle se najviše koristi kao otvoreni LMS, dok je Blackboard, prethodno poznat kao WebCT, najčešće korišten komercijalni LMS zbog svojih naprednih analitičkih funkcionalnosti, mogućnosti praćenja učenika i alata za procjenu (Lim & Atkinson, 2013; Soykan & Şimşek, 2017). Altınpulluk & Kesim (2021) otkrili su da otvoreni sustavi, posebno Moodle LMS, dominiraju u globalnom obrazovanju, s preko 148 milijuna korisnika do 2019. godine.

Kako LMS omogućuje praćenje napretka učenika i organizaciju obrazovnih sadržaja, on ima i širi utjecaj na nastavne metode. LMS olakšava distribuciju nastavnih materijala, komunikaciju među učenicima i nastavnicima te podršku u pripremi ispita i zadataka, čime znatno unapređuju interaktivnost i dostupnost sadržaja (Awang & Darus, 2012; Chaubey & Bhattacharya, 2015). LMS također donosi veću fleksibilnost za učenike, omogućujući im pristup obrazovnim resursima bez obzira na vrijeme i mjesto, što obrazovanje čini pristupačnijim i ekonomičnijim, posebno u visokom obrazovanju (Sekhar i ostali, 2024; Yadav, 2024). Međutim, upotreba LMS-a nosi i izazove. Uvođenje LMS tehnologije može zahtijevati promjene u pedagoškim praksama, prilagodbu nastavnog osoblja te redefiniranje načina vrednovanja znanja i angažmana učenika.

Ukratko, LMS je postao ključni alat u modernom obrazovanju, pružajući podršku fleksibilnom i interaktivnom učenju te omogućujući nastavnicima i institucijama učinkovito upravljanje

obrazovnim procesima (Romero & Ventura, 2010). Podaci prikupljeni putem LMS-a, koji bilježe razne aspekte aktivnosti učenika u digitalnom okruženju, temelj su razvoja znanstvene discipline analitike učenja. Nastali podaci omogućuju dublji uvid u obrazovni proces, te otvaraju put za primjenu analitičkih metoda usmjerenih na optimizaciju učenja, što je predmet rasprave u narednom poglavlju.

2.2. DEFINICIJE ANALITIKE UČENJA I RAZLIKE U ODNOSU NA SRODNE DISCIPLINE

Prema prvoj međunarodnoj konferenciji analitike učenja (engl. Learning Analytics and Knowledge, LAK), LA je „mjerjenje, prikupljanje, analiza i priprema izvještaja o učenicima i njihovim kontekstima, u svrhu razumijevanja i optimiziranja učenja i sredine u kojoj se učenje odvija“ (Siemens & Long, 2011, str. 34). Elias opisuje LA kao „disciplinu u nastajanju u kojoj se koriste sofisticirani analitički alati koji se koriste za poboljšanje učenja i obrazovanja“ (Elias, 2011, str. 2). LA, prema definiciji (CETIS¹, 2012), obuhvaća proces razvijanja djelotvornih uvida kroz definiranje problema i primjenu statističkih modela i analiza na postojeće i/ili simulirane buduće podatke. Time se omogućuje institucijama da eksperimentiraju s podacima radi stjecanja uvida te identificiranja poboljšanja.


Ova definicija ističe ključne karakteristike LA, poput naglašavanja djelotvornih akcija, što omogućuje institucijama ne samo bolje razumijevanje trenutnih događanja i prošlih zbivanja, već i predviđanje budućih s visokom razinom pouzdanosti. Pojava znanstvene discipline analitike učenja donosi značajan iskorak u primjeni analitičkih metoda u obrazovanju s ciljem poboljšanja procesa učenja i obrazovnih ishoda. Ipak, LA se ne može promatrati izolirano jer je usko povezana s drugim disciplinama, poput rudarenja podataka u obrazovne svrhe (engl. Educational Data Mining, EDM). Obje discipline dijele zajednički cilj – unapređenje obrazovnih sustava, ali se razlikuju po metodama i primjenama.

Tijekom posljednjeg desetljeća, potencijal analitike i rudarenja podataka – metoda koje iz velikih skupova podataka (engl. data mining) izvlače korisne i primjenjive uvide – snažno je utjecao na mnoge znanstvene discipline (Ranjeeth i ostali, 2020). Kada se ove metode primjenjuju u obrazovanju, nazivaju se analitikom učenja (LA) i rudarenjem podataka u obrazovne svrhe (EDM) (Baker & Siemens, 2014).

¹ Centar za obrazovnu tehnologiju, interoperabilnost i standarde (engl. Centre for Educational Technology, Interoperability and Standards)

U usporedbi s disciplinama poput fizike, biologije i medicine, znanost o obrazovanju relativno kasno započinje korištenje analitičkih metoda. Prvi časopis posvećen primjeni analitike u biološkim znanostima, Računala u biologiji i medicini (engl. *Computers in Biology and Medicine*), pokrenut je 1970. godine. Nasuprot tome, prvi časopis usmjeren na analitiku u obrazovnoj znanosti, Rudarenje podataka u obrazovne svrhe (engl. *Journal of Educational Data Mining*), pokrenut je tek 2009. godine, a godinu dana ranije održana je i Prva međunarodna konferencija o rudarenju podataka u obrazovne svrhe (engl. *First International Conference on Educational Data Mining*).

Ubrzo nakon toga, 2011. godine, pokrenuta je i Konferencija o analitici učenja i znanja (engl. *International Conference on Learning Analytics and Knowledge*), a 2014. godine počinje izlaziti i časopis Analitika učenja (engl. *Journal of Learning Analytics*). Ovaj ubrzani razvoj i povećan interes za analitiku u obrazovanju u kratkom su vremenu afirmirali LA i rudarenje podataka u obrazovne svrhe kao važne smjerove u znanosti o obrazovanju. Graf prikazuje rastuću važnost LA kao znanstvene discipline prema broju objavljenih radova o LA u bazi podataka Scopus i WoS (Slika 1). Jasno je kako interes za ovo područje kontinuirano raste u razdoblju od 2011. do 2024. godine, jer je uočljiv gotovo paralelan rast broja objavljenih radova u navedenim bazama do 2018, a potom stagnacija rasta u WoS-u u odnosu na Scopus.



Slika 1 Broj radova o LA objavljenih u bazi Scopus i WoS

U nastavku o glavnim razlikama između LA i EDM.

2.2.1. RAZLIKE IZMEĐU ANALITIKE UČENJA I RUDARENJA PODATAKA U OBRAZOVNE SVRHE

LA i EDM počeli su se razvijati početkom 2000-ih, a u posljednjim su godinama doživjeli značajan rast u smislu istraživačkih inicijativa, primjena u obrazovnim institucijama i tehnoloških napredaka (Romero & Ventura, 2020). Očekuje se da će ovaj rast nastaviti, s obzirom na neosporne koristi i relevantnost istraživanja temeljenih na skupovima podataka. Svijet postaje vođen podacima, a važnost ova dva područja raste, čak i u zemljama gdje takav pristup podacima do nedavno nije bio uobičajen ili ga nije bilo.

Međunarodno društvo za rudarenje podataka u obrazovne svrhe (engl. The Society for Learning Analytics Research, SoLAR) definiralo je EDM kao „područje, koje se bavi razvijanjem metoda za istraživanje jedinstvenih vrsta podataka koji dolaze iz obrazovnih okruženja i korištenje tih metoda kako bi se bolje razumjeli učenici i okruženja u kojima uče“ (Siemens & Baker, 2012, str. 252). EDM postaje učinkovit alat za istraživanje skrivenih veza u obrazovnim podacima i predviđanje uspjeha učenika (Yagci, 2022).

Istraživači u području općenito se slažu da obje discipline, LA i EDM, koriste iste vrste podataka, dijele slične ciljeve i zajednički teže unapređenju obrazovanja (Cerezo i ostali, 2024). Baker & Siemens (2014) ističu da se discipline LA i EDM preklapaju u istraživačkim temama. Kao istraživačko područje, EDM se može smatrati „sestrinskim“ područjem LA (Baker & Inventado, 2014). Mnogi istraživači zainteresirani za ove discipline često se pitaju predstavljaju li zapravo isti koncept (Cerezo i ostali, 2024). No, iako su obje discipline usko povezane i dijele mnoge zajedničke elemente, između njih postoji suptilna, ali jasna razlika (Dormezil i ostali, 2019).

EDM (Slika 2) se može predstaviti kao spoj triju glavnih područja: računalne znanosti (engl. computer science), obrazovanja (engl. education) i statistike (engl. statistics). Na sjecištu ovih područja nastaju i brojna srodna područja blisko povezana s EDM-om, poput obrazovanja temeljenog na računalu (engl. computer-based education), rudarenja podataka (engl. data mining) i strojnog učenja (ML) te LA (Romero & Ventura, 2013). Svako od ovih područja doprinosi različitim aspektima analize obrazovnih podataka. Na primjer, računalne znanosti omogućuju razvoj algoritama i softverskih alata za obradu i analizu skupova podataka, dok statistika pruža metodološke okvire za interpretaciju obrazovnih rezultata. Umjetna inteligencija (engl. Artificial Intelligence) i strojno učenje koriste se za razvoj modela

predviđanja. Takva širina povezanosti omogućava dublje razumijevanje obrazovnih procesa i izazova, no istovremeno komplicira primjenu specifičnih metoda i alata.



Slika 2 Glavna područja povezana s EDM [pripremljeno prema: (Romero & Ventura, 2013)]

Iako se radi o dvije različite discipline, mnogi stručnjaci teško mogu precizno odrediti razlike među njima. Obje koriste sličnu terminologiju i dijele zajednički interes za analizu podataka s ciljem unapređenja obrazovnog procesa. Unatoč zajedničkom interesu, razlikuju se u pristupima, premda se njihovi pojmovi često koriste naizmjenično (Baek & Doleck, 2021; Lemay i ostali, 2021). Zbog značajnog preklapanja u istraživačkim temama, metodama i ciljevima, lakše je uočiti njihove sličnosti nego razlike (Calvet Liñán & Juan Pérez, 2015). Siemens & Baker (2012), ističu pet glavnih razlika između LA i EDM, kako prikazuje Tablica 1.

Ključna razlika je u cilju otkrića (engl. discovery) koje se preferira. U obje discipline nalazimo istraživanja koja koriste automatizirana otkrića, kao i istraživanja koja se oslanjaju na ljudske procjene kroz vizualizaciju i druge metode. Međutim, EDM je više usmjeren na automatizirana otkrića, dok LA stavlja veći naglasak na korištenje ljudskih procjena. Čak se u istraživanjima koja kombiniraju oba pristupa, može uočiti ta preferencija. Istraživanja unutar EDM, koja uključuju ljudske procjene to često čine kako bi klasificirali učenike, dok LA istraživanja koja

koriste automatizirana otkrića to obično rade kako bi informirala ljude koji donose konačne odluke.

Tablica 1 Ključne razlike LA i EDM [pripremljeno prema: (Siemens & Baker, 2012)]

KARAKTERISTIKE	LA	EDM
Cilj otkrića (engl. Discovery)	Ključno je iskoristiti ljudsku prosudbu gdje je automatizirano otkriće alat za postizanje tog cilja	Automatizirano otkriće je ključno, a korištenje ljudske prosudbe je alat za postizanje tog cilja.
Prilagodba i personalizacija (engl. Adjustment and Personalization)	Veći naglasak na informiranju i osnaživanju nastavnika i učenika	Veći fokus na automatskoj prilagodbi (npr. računalom bez ljudske intervencije).
Redukcija (engl. Reduction)	Veći fokus na razumijevanju cijelih sustava, u njihovoj potpunoj složenosti	Veći fokus na smanjenju na dijelove i analizi svake pojedinačne komponente te odnosima između njih.
Podrijetlo (engl. Origin)	LA ima jače korijene u semantičkom webu, „inteligentnom kurikulumu“, predviđanju ishoda i intervencijama prema učenicima	EDM ima čvrste korijene u obrazovnom softveru i modeliranju učenika, s fokusom u predviđanju
Tehnike i metode (engl. Techniques and Methods)	Analiza društvenih mreža, analiza utjecaja, predviđanje uspjeha učenika, analiza koncepata, modeli razumijevanja	Klasifikacija, grupiranje, Bayesovo modeliranje, identificiranje i analiziranje veza, modeliranje, vizualizacija

Ova je razlika povezana s još jednom razlikom između LA i EDM: vrstom prilagodbe i personalizacije koje se obično podržavaju u svakom području. EDM modeli se češće koriste kao osnova za automatiziranu prilagodbu, koju provodi računalni sustav. Nasuprot tome, LA modeli uglavnom su osmišljeni kako bi informirali i osnažili nastavnike i učenike.

Treća je razlika u pristupu analizi. U istraživanju unutar EDM, koristi se redukcija gdje je veći fokus na smanjenju na dijelove i analizi svake pojedinačne komponente te odnosima između njih. Nasuprot tome, istraživanja unutar LA, obično snažnije naglašavaju pokušaj razumijevanja sustava kao cjeline, u njihovoj punoj složenosti.

Dvije dodatne razlike odnose se na podrijetlo, te korištene tehnike i metode istraživača. Podrijetlo istraživača obično utječe na preferirane pristupe (Tablica 1). No nužno je naglasiti kako preferirani pristup, također utječe na odabir metoda i tehnika.

Korištenje istih metoda dodatno ilustrira poteškoće u naglašavaju razlika LA i EDM. Jedan od ključnih istraživačkih ciljeva ovog rada je prva metoda, **predviđanje** (engl. prediction), koja nastoji predvidjeti vrijednosti ciljane varijable na temelju poznatih vrijednosti ostalih varijabli. Neke od uobičajenih zajednički metoda prema Romero & Ventura (2013), korištenih u obje discipline, navedene su u sljedećoj tablici (Tablica 2).

Tablica 2 Neke od uobičajenih metoda LA i EDM [pripremljeno prema: (Romero & Ventura, 2013)]

METODA	OPIS	PRIMJENA
Predviđanje (engl. prediction)	Predviđanje vrijednosti ciljane varijable iz poznatih vrijednosti ostalih varijabli.	Predviđanje uspjeha učenika
Grupiranje (engl. grouping)	Identificiranje skupina sličnih opažanja.	Grupiranje učenika na temelju njihovih uzoraka učenja.
Rudarenje odnosa (engl. relationship mining)	Za proučavanje odnosa između varijabli i kodiranje pravila	Identifikacija odnosa u obrascima ponašanja učenika i dijagnostika
Otkrivanje izdvojenih slučajeva (engl. discovering outstanders)	Uočavanje značajno različitih pojedinaca	Otkrivanje učenika s poteškoćama.
Analiza društvenih mreža (engl. social network analysis)	Analizirati društvene odnose između entiteta u mrežnoj informaciji.	Tumačenje strukture i odnosa u suradničkim aktivnostima.
Tekstualno rudarenje (engl. text mining)	Izdvajanje visokokvalitetnih informacija iz teksta.	Analiza sadržaja foruma, dokumenata, web stranica.

Dok (Calvet Liñán & Juan Pérez, (2015)))) smatraju da je EDM više usmjeren na tehnike, a LA se više bavi praktičnim primjenama, Papamitsiou & Economides (2014) naglašavaju ontološke razlike u njihovim počecima, a još važnije, temama koje ih osobito zanimaju. Ipak, smatra se preciznijim opisivati ove discipline kao dvije povezane domene s velikim stupnjem preklapanja (EDM i LA), ili ih promatrati kao jedno šire područje – LA, u kojoj EDM predstavlja istaknuti podskup (Dormezil i ostali, 2019).

Prema Fergusonu (2012, str. 8), LA i EDM razlikuju se prema specifičnim izazovima koje svako od ovih područja nastoji riješiti. EDM se primarno bavi tehničkim izazovom izvlačenja korisnih informacija iz skupova podataka povezanih s učenjem, do je LA usmjerena na obrazovni izazov optimizacije prilika za učenje u online okruženju.

U ovoj doktorskoj disertaciji prihvaćamo stajalište, prema kojem EDM predstavlja podskup, dok LA smatramo širim istraživačkim područjem. Budući da je tema disertacije usmjerena na

optimizaciju prilika za učenje u mješovitom (hibridnom) okruženju, daljnja razmatranja u radu usmjerena su isključivo na LA kao primarno područje istraživanja.

2.2.2. RAZLOZI PORASTA KORIŠTENJA ANALITIKE U OBRAZOVANJU


Primjena analitike u obrazovanju značajno je porasla u posljednjem desetljeću, zahvaljujući četiri ključna čimbenika (Baker & Siemens, 2014):

- **Količina podataka** - Prvi ključni faktor je eksponencijalni porast obrazovnih podataka, što istraživačima omogućuje dublje razumijevanje obrazovnog procesa. Široka primjena digitalnih tehnologija omogućuje automatsko bilježenje interakcija učenika s digitalnim uređajima, stvarajući skupove podataka, koji se smatraju vrijednim izvorom informacija za analizu.
- **Poboljšanje formata podataka** - Za prvu analizu obrazovnih log podataka, Baker ističe da je bilo potrebno gotovo dva mjeseca samo za pripremu podataka u upotrebljivom formatu. Danas, međutim, standardizirani formati podataka znatno ubrzavaju ovaj proces.
- **Povećana računalna snaga i brzina obrade** - Razvoj analitike također je bio potaknut napretkom u računalnoj tehnologiji, budući da npr. pametni telefoni danas imaju procesorsku snagu usporedivu s osobnim računalima, a računala su u mogućnosti obraditi skupove podataka koji su prije nekoliko godina bili nezamislivi. Računalna moć sada omogućuje provođenje naprednih istraživanja i analize podataka u raznim područjima.
- **Razvoj analitičkih alata** - Neki od najvažnijih napredaka ostvareni su u razvoju alata za upravljanje skupovima podataka, čime se olakšava pohrana, organizacija i filtriranje podataka za analizu. Osim alata za upravljanje podacima, sve je više alata za podršku analizi podataka, čija je sofisticiranost i jednostavnost omogućila pristup širokom krugu znanstvenika, bez potrebe za naprednim znanjem programiranja. Mnogi od tih alata prvotno su razvijeni za područje poslovne inteligencije (engl. Business Intelligence) i korišteni u sektoru za prediktivnu analitiku (PA) i donošenje odluka, analizom i vizualizacijom skupova podataka.

2.2.3. PROCESNO OKRUŽENJE ANALITIKE UČENJA

Elias (2011), uvodi koncept kontinuiranog trofaznog ciklusa, koji naglašava stalno praćenje, analizu i optimizaciju obrazovnog procesa s ciljem poboljšanja. Prema Elias, LA se oslanja na četiri glavna resursa: organizaciju, računalne sustave, ljude i teorije (Slika 3) . Tri ključne faze ovog ciklusa su:


1. Prikupljanje podataka (engl. data gathering): obuhvaća prikupljanje i selekciju podataka.
2. Obrada informacija (engl. information processing): uključuje agregiranje i predviđanje.
3. Primjena znanja (engl. knowledge application): obuhvaća korištenje, rafiniranje i dijeljenje rezultata.



Slika 3 Procesno okruženje LA prema Elias [pripremljeno prema (Elias, 2011)]

Elias naglašava važnost ljudske uloge, osobito pri primjeni teorija i donošenju odluka, te značaj organizacijskih karakteristika: spremnosti na podršku odlukama, djelovanju i stilu vođenja (Elias, 2011). Chatti i ostali (2012) razvijaju sličan koncept kroz terminologiju vezanu uz procese u LA, identificirajući ponovno koncept kontinuiranog trofaznog ciklusa (Slika 4). Ključne faze ovog procesa su:

1. Prikupljanje i predobrada podataka (engl. data collection and pre-processing),
2. Analitika i djelovanje (engl. analytics and action), te
3. Naknadna obrada podataka (engl. post-processing).



Slika 4 Procesno okruženje LA prema Chatti [pripremljeno prema (Chatti i ostali, 2012)]

Prikupljanje i predobrada podataka temelj su procesa LA. Ovaj korak je ključan kako bi se otkrili korisni uzorci u podacima. Prikupljanje i predobrada podataka uključuju njihovo filtriranje, integraciju, pretvorbu, redukciju, modeliranje, identifikaciju korisnika i sesija te završetak putanje (engl. path completion). Analitika i djelovanje se temelje na predobradi podataka LA. Različite LA tehnike mogu se primijeniti na podatke s ciljem otkrivanja skrivenih uzoraka koji mogu pomoći da se osigura učinkovitije iskustvo učenja. Te aktivnosti uključuju praćenje, analizu, predviđanje, intervenciju, procjenu, prilagodbu, personalizaciju, preporuku i refleksiju (odraz). Naknadna obrada uključuje sastavljanje novih podataka iz dodatnih izvora podataka, poboljšanje skupa podataka, određivanje novih atributa potrebnih za novu iteraciju, identificiranje novih pokazatelja i nove metrike, mijenjanja varijabli analize ili odabir nove metode za analizu.

2.2.4. MODELI ANALITIKE UČENJA

Modeli analitike učenja (LA) pružaju okvir za razumijevanje i primjenu obrazovnih podataka s ciljem poboljšanja ishoda učenja. Omogućuju praćenje napretka učenika, prepoznavanje njihovih potreba i prilagodbu obrazovnih strategija radi postizanja boljih rezultata.

Najčešće korišteni modeli LA uključuju:


1. Referentni model analitike učenja (engl. Reference Model for Learning Analytics) – prikazuje ključne komponente i funkcije sustava LA, olakšavajući razumijevanje njegovog rada i identificiranje mogućnosti za poboljšanje (Chatti i ostali, 2012).
2. Generički model analitike učenja (engl. Generic Model for Learning Analytics) – opisuje osnovne korake u procesu LA, od prikupljanja i obrade podataka do njihove primjene u obrazovnom kontekstu (Greller & Drachsler, 2012).

Prethodno predstavljeni modeli pružaju jednostavan i učinkovit okvir za korištenje podataka nastalih kroz obrazovni proces, omogućujući nastavnicima i obrazovnim institucijama da unaprijede načine poučavanja i pruže učenicima kvalitetniju podršku.

2.2.5.1. REFERENTNI MODEL ANALITIKE UČENJA

Referentni model analitike učenja se temelji na četiri dimenzije i treba odgovoriti na sljedeća pitanja (Chatti i ostali, 2012) kako prikazuje Slika 5.

1. Koju vrstu podataka sustav prikuplja, upravlja i koristi za analizu? (**Što**)
2. Tko je cilj analize? (**Tko**)
3. Kako sustav izvodi analizu prikupljenih podataka? (**Kako**)
4. Zašto sustav analizira prikupljene podatke? (**Zašto**)



Slika 5 Referentni model analitike učenja [pripremljeno prema (Chatti i ostali, 2012)]

KOJU VRSTU PODATAKA SUSTAV PRIKUPLJA; UPRAVLJA I KORISTI ZA ANALIZU? (ŠTO)

LA se temelji na podacima prikupljenima iz različitih obrazovnih izvora, koji se mogu podijeliti u dvije glavne skupine: centralizirane sustave u obrazovanju (engl. centralized educational systems) i distribuirana okruženja za učenje (engl. distributed learning environments) (Chatti i ostali, 2012). Centralizirani sustavi, poput LMS-a, prikupljaju podatke o aktivnostima učenika, kao što su pristup i interakcija s obrazovnim sadržajem (prema Romero & Ventura, 2007; u: Chatti i ostali, 2012). Distribuirana okruženja za učenje kao što je personalizirano okruženje za učenje (engl. personal learning environment), prikupljaju podatke iz različitih formalnih i neformalnih izvora izvan LMS-a. Ti podaci često dolaze kroz različite kanale i formate, a njihova fragmentiranost predstavlja izazov za analizu (Suthers & Rosen, 2011).

Kako se alati i resursi za učenje sve više premještaju u oblak, izazov je kako objediniti i integrirati sirove podatke iz različitih izvora, često u različitim formatima, kako bi se stvorio koristan obrazovni skup podataka koji odražava aktivnosti učenika i vodi do preciznijih rezultata LA. Upravljanje skupovima podataka predstavlja tehnički izazov jer je potrebno implementirati učinkovite analitičke metode i alate koji će pružiti smislene rezultate, omogućujući pravovremene reakcije.

TKO SU SUDIONICI? (TKO)

Primjena LA može biti usmjerena prema različitim sudionicima, poput učenika, nastavnika, tutora, obrazovnih institucija, znanstvenika i dizajnera sustava, koji imaju različite ciljeve i očekivanja. Učenike zanima kako im LA može pomoći u poboljšanju ocjena i oblikovanju osobnog okruženja za učenje, dok nastavnici traže načine za unapređenje nastave. Obrazovne institucije mogu koristiti analitičke alate za donošenje informiranih odluka i prepoznavanje „rizičnih“ učenika s ciljem poboljšanja njihovog uspjeha (Campbell i ostali, 2007).

Znanstvenici se usmjeravaju na istraživanje utjecaja integracije LA u svakodnevnu praksu te razvoj alata koji će biti korisni i onima koji nisu stručnjaci u rudarenju podataka. Ovi alati trebaju omogućiti korisnicima dobivanje ciljane povratne informacije

Integracija LA u svakodnevnu praksu zahtijeva usklađivanje didaktičkih i organizacijskih okvira, uz pažljivo razmatranje etičkih pitanja, privatnosti podataka i nadzora. Ključno je spriječiti zloupotrebu podataka i osigurati zaštitu identiteta korisnika (Chatti i ostali, 2012).

KOJI SU CILJEVI? (ZAŠTO)

Ciljevi LA ovise o perspektivama različitih sudionika. Mogući ciljevi uključuju praćenje (engl. monitoring), analizu (engl. analysis), predviđanje (engl. prediction), intervenciju (engl. intervention), tutorstvo/mentorstvo (engl.: tutoring/mentoring), procjenu (engl. assessment), povratne informacije (engl. feedback), adaptaciju (engl. adaptation), personalizaciju (engl. personalization), preporuku (engl. recommendation) i refleksiju (engl. reflection) (Chatti i ostali, 2012). U nastavku se opisuje svaki od mogućih ciljeva.

1. **Praćenje i analiza:** Cilj praćenja u LA je pratiti aktivnosti učenika i generirati izvještaje koji pomažu nastavnicima ili obrazovnim institucijama u donošenju odluka. Praćenje također uključuje nastavnikovu ocjenu procesa učenja kako bi se kontinuirano unaprijedilo okruženje za učenje. Analizom načina na koji učenici

koriste sustav za upravljanje učenjem i njihovih postignuća, nastavnici mogu uočiti obrasce u njihovom napretku i donijeti bolje odluke o budućim nastavnim aktivnostima.

2. **Predviđanje i intervencija:** Cilj predviđanja u LA je razviti model koji omogućava predviđanje uspjeha učenika, temeljenog na njegovim trenutnim aktivnostima i postignućima. Ovaj pristup može se koristiti za pravovremene intervencije u slučajevima kada učenici zahtijevaju dodatnu pomoć. Kvalitetna analiza podataka i predviđanje omogućuju nastavnicima i obrazovnim institucijama da prepoznaju slabije učenike i poduzmu potrebne mjere za poboljšanje njihovih rezultata, čime se osigurava veća podrška učenicima.
3. **Tutorstvo i mentorstvo:** Tutorstvo je primarno usmjereno na pružanje pomoći učenicima u rješavanju konkretnih zadataka, često vezanih uz specifičan predmet. U tom kontekstu, tutor ima glavnu ulogu i kontrolu nad procesom, a naglasak je na prijenosu znanja i obrazovnom procesu. S druge strane, mentorstvo pruža širu podršku učeniku tijekom cijelog školovanja. Mentori ne samo da prate napredak učenika, već i pomažu u planiranju karijere, razvijanju profesionalnih vještina, postavljanju i postizanju ciljeva te pripremi za buduće izazove. U mentorstvu, učenik ima veću kontrolu nad vlastitim razvojem, te se potiče na samostalno učenje i osobni rast.
4. **Procjena i povratne informacije:** Cilj LA je podržati (samo)procjenu poboljšanja učinkovitosti i kvalitete obrazovnog procesa. Time se učenicima i nastavnicima/mentorima pružaju korisne povratne informacije koje im omogućuju praćenje napretka, prepoznavanje slabosti i prilagodbu strategija učenja ili poučavanja radi postizanja boljih rezultata.
5. **Adaptacija:** Adaptaciju provode nastavnici/tutorski sustavi ili obrazovne institucije. Cilj LA u ovom kontekstu je pružiti učenicima smjernice o tome što bi trebali poduzeti sljedeće, pri čemu se resursi za učenje i nastavne aktivnosti adaptivno organiziraju u skladu s individualnim potrebama svakog učenika.
6. **Personalizacija i preporuke:** Personalizacija u LA stavlja učenika u središte obrazovnog procesa, s naglaskom na kreiranje i prilagodbu osobnog okruženja za učenje kako bi što učinkovitije ostvario svoje ciljeve. U tom kontekstu, sustavi za

preporuke imaju ključnu ulogu u poticanju samostalnog učenja. Cilj LA je podržati učenike u donošenju odluka o daljnjim koracima, pružajući im preporuke za relevantne resurse za učenje te olakšavajući povezivanje s vršnjacima koji dijele slične interese i preferencije.

7. **Refleksija:** LA može biti snažan alat za poticanje refleksije. Omogućuje učenicima i nastavnicima da uspoređuju podatke o postignućima unutar istog predmeta, između različitih grupa ili čak različitih institucija. Ovakva usporedba pruža priliku za analizu i donošenje zaključaka o učinkovitosti vlastitog učenja ili nastavnih strategija.

LMS je vrlo koristan alat u LA jer prikuplja podatke o aktivnostima učenika i angažmanu tijekom obrazovnog procesa. Na temelju tih podataka moguće je pratiti napredak učenika, prepoznati potencijalne probleme u učenju i pravovremeno identificirati učenike koji bi mogli imati poteškoća u postizanju željenih rezultata.

KOJE SU METODE? (KAKO)

LA primjenjuje različite metode za otkrivanje zanimljivih obrazaca/uzoraka skrivenih u skupovima podataka koji nastaju tijekom obrazovnog procesa. Chatti i ostali (2012), navode četiri glavne metode koje primjenjuje LA: statistika (engl. Statistics), vizualizacija informacija (engl. Information Visualization), rudarenje podataka (engl. Data Mining) i analiza socijalnih mreža (engl. Social Network Analysis). U nastavku opisujemo svaku od navedenih metoda.


- **Statistika:** Većina LMS-ova implementira alate za izvještavanje koji pružaju osnovne statistike o interakciji učenika s platformom. Primjeri tih statistika uključuju vrijeme provedeno online, ukupan broj posjeta, broj posjeta po stranici, raspodjelu posjeta tijekom vremena, učestalost postova i odgovora učenika, te postotak pročitane materijala. Ovi statistički alati obično generiraju jednostavne statističke operacije kao što su prosjek, srednja vrijednost i standardna devijacija. Takvi podaci omogućuju praćenje učenikovog angažmana i napretka te pružaju temelj za daljnju analizu i prilagodbu obrazovnog procesa.
- **Vizualizacija informacija:** Statistike u obliku izvještaja i tablica podataka nisu uvijek lako razumljive korisnicima obrazovnog sustava. Predstavljanje rezultata dobivenih metodama LA u vizualno pristupačnom obliku može značajno olakšati interpretaciju i analizu obrazovnih podataka. Mazza & Dimitrova (2007) ističu da je

vizualna prezentacija često učinkovitija od običnog teksta ili brojčanih podataka. Različite tehnike vizualizacije informacija, poput grafikona, dijagrama raspršenja i 3D prikaza, mogu se koristiti za predstavljanje podataka na jasan i razumljiv način (Romero & Ventura, 2007). Prepoznajući snagu vizualnih prikaza, tradicionalni izvještaji temeljeni na tablicama podataka sve više se zamjenjuju LAD-om, koje grafički prikazuju različite pokazatelje i omogućuju brzu i intuitivnu analizu podataka.

- **Rudarenje podataka:** Rudarenje podataka predstavlja proces otkrivanja korisnih obrazaca ili znanja iz različitih izvora podataka, poput baza podataka, tekstova, slika ili interneta (Liu & Bing, 2007). Općenito, metode rudarenja podataka, koje su široko zastupljene u literaturi o EDM, uključuju nekoliko glavnih kategorija: nadzirano učenje (engl. supervised learning), nenadzirano učenje (engl. unsupervised learning) i učenje uz podršku (engl. reinforcement learning, poznato i kao „učenje pojačavanjem“ ili „podržano učenje“) (Han & Kamber, 2000; Liu & Bing, 2007).
- **Analiza društvenih mreža:** Alati za upravljanje, vizualizaciju i analizu društvenih mreža postaju sve popularniji (Tabassum i ostali, 2018). Društvena mreža sastoji se od skupa čvorova i odnosa, odnosno veza, koje ih povezuju (Wasserman & Faust, 1994). Uobičajeni zadaci analize društvenih mreža uključuju prepoznavanje najutjecajnijih ili najvažnijih članova mreže, identifikaciju čvorišta i autoriteta, te proučavanje načina širenja informacija unutar mreže (Tabassum i ostali, 2018). U kontekstu LA, analiza društvenih mreža može se koristiti za praćenje interakcija među učenicima, nastavnicima i drugim sudionicima tijekom obrazovnog procesa. Proučavanje načina na koji se informacije šire mrežom može pomoći u razumijevanju kako se znanje prenosi među učenicima, što može biti korisno za optimizaciju nastave i poboljšanje učinkovitosti učenja.

2.2.5.2. GENERIČKI MODEL ANALITIKE UČENJA

Greller & Drachsler (2012) razlikuju šest ključnih dimenzija LA koje se trebaju uzeti u obzir prilikom njenog oblikovanja kako bi se osiguralo primjereno korištenje prilikom obrazovnog procesa (Slika 6). Šest dimenzija predloženog modela analitike učenja (LA) uključuje: sudionike (engl. stakeholders), ciljeve (engl. objectives), podatke (engl. data), instrumente (engl. instruments), vanjska ograničenja (engl. external constraints) i unutarnja ograničenja (engl. internal limitations). U nastavku predstavljamo svaku od dimenzija generičkog modela analitike učenja (LA).



Slika 6 Generički model analitike učenja [pripremljeno prema (Greller & Drachsler, 2012)]

SUDIONICI (engl. STAKEHOLDERS)

U ovom modelu nastavnici su označeni kao korisnici podataka (engl. data clients), dok se učenici nazivaju subjektima podataka (engl. data subjects). Korisnici podataka koriste rezultate LA i djeluju na temelju tih podataka, dok su subjekti podataka davatelji podataka, obično putem svog ponašanja prilikom pretraživanja i interakcije. Osim nastavnika i učenika, prema prikazanom modelu, važnu ulogu imaju i obrazovne institucije. Ove skupine sudionika mogu biti proširene ili zamijenjene drugim skupinama, poput istraživača, pružatelja usluga ili vladinih agencija.

Učenicima se mogu pružiti vizualizacije koje prikazuju njihov napredak u odnosu na prosječne rezultate na predmetu, zajedno s personaliziranim preporukama za učenje i resursima. Nastavnici mogu koristiti sustave za praćenje kako bi uočili praznine u znanju učenika i usmjerili svoju pažnju na one kojima je potrebna dodatna pomoć. Obrazovne institucije mogu pratiti uspjeh učenika.

CILJEVI (engl. OBJECTIVES)

Glavni ciljevi LA, prema Greller & Drachsler (2012), su otkrivanje i kontekstualizacija skrivenih informacija iz podataka koji nastaju tijekom obrazovnog procesa te njihova priprema za različite korisnike. Autori razlikuju dva osnovna cilja: refleksiju (engl. reflection) i predviđanje (engl. prediction).

Refleksija se smatra ključnim oblikom samo-vrednovanja učenika, temeljenim na njihovim vlastitim podacima kako bi stekli samospoznaju. Wolf (2009) ovaj proces naziva „kvantificirano ja“ (engl. Quantified Self), odnosno samopraćenjem i reagiranjem na vlastite log podatke.

LA se također koristi za predviđanje uspjeha učenika, omogućujući pravovremenu intervenciju (npr. smanjenje stope odustajanja). Korištenjem strojnog učenja, predviđanje može poboljšati učinkovitost i omogućiti donošenje automatiziranih odluka.

PODACI (engl. DATA)

LA koristi dostupne skupove podataka iz različitih LMS-ova i drugih izvora. Obrazovne institucije već posjeduju skupove podataka o učenicima, a povezivanje tih podataka omogućuje razvoj aplikacija koje poboljšavaju personalizaciju i usluge usmjerene na učenike. S obzirom na činjenicu da LA uvelike ovisi o podacima o učenicima, jedan od najvećih izazova predstavlja dostupnost javnih skupova podataka. Naime, većina podataka koje generiraju institucije zaštićena je zakonom.

INSTRUMENTI (engl. INSTRUMENTS)

Različite tehnologije mogu imati ključnu ulogu u razvoju usluga i aplikacija koje se koriste u obrazovanju. LA koristi alate poput rudarenja podataka, strojnog učenja i statističke analize za obradu podataka nastalih u obrazovnom procesu.

Dimenzija instrumenata obuhvaća različite metode obrade podataka, uključujući teorijske modele i algoritme. Ove metode pretvaraju osnovne podatke u korisne informacije, a kvaliteta tih informacija ovisi o odabranoj tehnici. Različite metode primijenjene na iste podatke mogu proizvesti različite rezultate, što može utjecati na odluke koje se donose.

VANJSKA OGRANIČENJA (engl. EXTERNAL CONSTRAINTS)

Različita ograničenja mogu utjecati na primjenu LA. Greller & Drachsler (2012) razlikuju tri glavna ograničenja: etička, pravna i društvena. Problemi privatnosti i etike nastaju jer se podaci o učenicima često prikupljaju bez njihove suglasnosti. Također, važno je pitanje vlasništva nad tim podacima, osobito s novim tehnologijama poput praćenja lokacije ili prepoznavanja lica. Podaci u obrazovnim institucijama trebaju se koristiti jasno i etički, kako bi se izbjegla njihova zloupotreba i osigurala kreativnost u učenju.

UNUTARNJA OGRANIČENJA (engl. INTERNAL LIMITATIONS)

Unutarnja ograničenja, koja se nadovezuju na vanjska, odnose se na ljudski faktor, poput kompetencija i prihvaćanja LA. LA zahtijeva nove vještine kako bi se ispravno primijenila u obrazovanju. Rezultati koje generiraju algoritmi trebaju biti pravilno prikazani i interpretirani, jer samo tada mogu poboljšati učenje. Greller & Drachsler (2012) ističu važnost vještine vrednovanja prikazanih podataka, jer površno tumačenje može dovesti do pogrešnih zaključaka.

Nakon osvrta na ključne pojmove i modele LA, slijedi prikaz važne komponente u primjeni analitike u sustavu obrazovanja – **nadzorne ploče analitike učenja (LAD)**. LAD predstavlja praktičan alat koji omogućuje vizualizaciju podataka i njihovih analiza na način koji je korisnicima lakše razumljiv, čime se poboljšava donošenje odluka u obrazovnom procesu.

2.3. NADZORNA PLOČA ANALITIKE UČENJA

Tradicionalni izvještaji i statistike o učenju često su bili ograničeni u svom obliku i pristupu, a LAD omogućuje dinamično i interaktivno praćenje, od aktivnosti učenika do predviđanja uspjeha učenika. Ovaj oblik vizualizacije podataka postaje posebno važan u kontekstu različitih ciljeva LA, poput praćenja napretka učenika, predviđanja problema, personalizacije učenja i pružanja povratnih informacija.

Jedan od učinkovitih načina prikazivanja podataka prikupljenih korištenjem LMS-a je putem LAD-a. LAD predstavlja vizualni prikaz koji integrira informacije i vodi korisnike u procesima donošenja odluka. Zbog utjecaja IKT, LAD zahtijeva sve više pažnje u domeni obrazovanja, a osnovna ideja je omogućiti korisnicima praćenje svojih aktivnosti kako bi se omogućila samo-analiza i usporedba s drugim korisnicima, te kako bi učenici, nastavnici i savjetnici poduzeli odgovarajuće radnje implicirajući kako su vizualizacija i izvještavanje elementi koji čine LA zaista djelotvornom (Brown, 2012). Kada se govori o prikazu vizualizacije i izvještavanju, treba imati na umu da se pruža povratna informacija (engl. feedback) koja predstavlja most između prikupljenih podataka i akcija koje iz njih proizlaze.

2.3.1. POV RATNA INFORMACIJA KAO MOST IZMEĐU PODATAKA I AKCIJE

Prema Wiggins (2012) povratna informacija je informacija koja nam govori koliko uspješno napredujemo u postizanju postavljenog cilja. Povratna informacija sadrži informacije o procesu učenja, rezultatu ili napredovanju učenika tijekom ili nakon vrednovanja kao sastavnog dijela obrazovnog procesa (*Smjernice za vrednovanje procesa učenja i ostvarenosti ishoda u osnovnoškolskome i srednjoškolskome odgoju i obrazovanju*, 2020).

Posebno su korisne povratne informacije koje govore o procesu učenja i koje su usmjerene na strategije i trud koji je učenik uložio u učenje. Svrha povratne informacije jest da učenici budu svjesni što su postigli i u kojim je specifičnim područjima potrebno poboljšanje. Poboljšanje učenika zahtijeva povratne informacije koje su promišljene, relevantne i dubinske (A. Cohen & Singh, 2020). Povratna informacija pomaže u planiranju odluka o sljedećim koracima učenja i poučavanja te u poticanju razvoja odgovornosti za vlastito učenje.

Kroz povratnu informaciju učenik se ne osvrće samo na kvalitetu onoga što je trenutno postigao, već i na što kvalitetnije ispunjavanje krajnjeg ishoda. Na taj način povratna informacija ne služi

samo kao odraz napretka, već i kao snažan motivacijski alat koji potiče učenika na daljnji rad, usavršavanje i postizanje postavljenih ciljeva (Zmuda i ostali, 2015).

Prema Zmuda i ostali (2015) povratna informacija treba biti:

- redovna - učenici konstantno trebaju imati uvid u ispravnost onoga što rade, a što se zadatak bliži kraju, učestalost povratne informacije dodatno se povećava
- smisljena - povratna informaciju učeniku mora biti smisljena, odnosno razumljiva i jasna.
- poticajna - učenike treba podsjetiti na napredak umjesto da ih se neprestano vraća na pogreške.

Budući da je proces usvajanja povratne informacije nužan za razvoj vještine praćenja i vrednovanja vlastitoga procesa učenja, povratna informacija treba biti neposredna i pravovremena te učenike informirati o njihovoj učinkovitosti. Na temelju povratne informacije učenici trebaju znati kako poboljšati svoj proces učenja i kako ona pozitivno djeluje na njihov osjećaj kompetentnosti i motivaciju za učenjem. S vremenom učenici postaju uspješniji u usklađivanju samo-vrednovanja i vrednovanja u kojemu ih drugi vrednuju te na kraju svoje učenje reguliraju u potpunosti samostalno.

2.3.2. DEFINICIJA I KLASIFIKACIJA NADZORNIH PLOČA ANALITIKE UČENJA

Prema Fewu, LAD je „vizualni prikaz najvažnijih informacija potrebnih za postizanje jednog ili više ciljeva; raspoređene na ekranu tako da informacije mogu biti praćene u jednom pogledu” Few (2013, str. 26). U LA, LAD se specifično smatra „prikazom koji agregira jednu ili više vizualizacija različitih pokazatelja o učenicima, procesu učenja i/ili kontekstu učenja“ (Schwendimann i ostali, 2016, str. 37).

Verbert, Govaerts, i ostali (2013) navode kako LAD obično bilježi i vizualizira tragove aktivnosti učenja kako bi se promicala svijest i refleksija, te omogućila učenicima definiranje ciljeva i praćenje napretka prema tim ciljevima. Konkretno, LAD je usmjeren na praćenje aktivnosti učenja i konteksta u kojem se te aktivnosti događaju, s ciljem promicanja svijesti i refleksije kroz algoritamsku analizu ili vizualizaciju podataka. Verbert, Govaerts, i ostali (2013) također razlikuju različite tipove LAD-a. U nastavku prikazujemo njihovu klasifikaciju LAD-ova.

- Nadzorne ploče koje podržavaju tradicionalno učenje, licem u lice – Koriste se za pružanje podrške nastavnicima u stvarnom vremenu, omogućujući im prilagodbu nastave i učinkovitije angažiranje učenika tijekom procesa učenja.
- Nadzorne ploče koje podržavaju rad licem u lice i organizaciju u učionici – Omogućuju nastavnicima praćenje aktivnosti pojedinih učenika ili grupa, čime im pomažu u boljoj organizaciji rada i upravljanju učioničkim aktivnostima.
- Nadzorne ploče koje podržavaju online učenje ili kombinirano učenje – Pružaju učenicima i nastavnicima uvid u aktivnosti poput vremena provedenog na zadacima i/ili praćenja napretka s ciljem poboljšanja učinkovitosti i prilagodbe strategija učenja.

S aspekta svrhe, Schwendimann i ostali (2016) klasificiraju LAD-ove prema funkciji u tri kategorije:

1. Samopraćenje – korisno za učenike kako bi analizirali vlastiti napredak.
2. Praćenje drugih – omogućava nastavnicima praćenje aktivnosti učenika ili grupa učenika.
3. Administrativno praćenje – koristi se na razini institucije za nadzor i analizu općih trendova u obrazovanju.

Siemens i ostali (2011) identificiraju četiri vrste korisnika LAD-a: učenik, nastavnik, istraživač i obrazovna institucija. Prema njima, učenici imaju mogućnost pregledati svoj napredak i usporediti ga s kolegama (uz isključenje osobnih podataka kada je to potrebno). Nastavnici imaju uvid u različite prikaze aktivnosti učenika, uključujući detalje o razvoju svakog pojedinog učenika te njihov napredak u razumijevanju ključnih pojmova. Istraživači koriste prikupljene podatke za analizu obrazovnih procesa, razvoj teorijskih modela te prepoznavanje obrazaca u ponašanju i učenju.

U ovoj disertaciji fokus je na trećoj kategoriji prema Verbert, Govaerts, i ostali (2013), odnosno LAD-u koju podržava online i mješovitu (hibridnu) nastavu. Također, ciljni korisnici LAD-a u ovoj disertaciji su učenici i nastavnici, kako je već navedeno u uvodnom dijelu.


2.3.3. RAZVOJ I PRIMJENA NADZORNE PLOČE ANALITIKE UČENJA TEMELJENE NA PODACIMA IZ LMS-A

Proučavanje aktivnosti učenika u online okruženju započelo je gotovo desetljeće prije nego što je analitika učenja (LA) službeno definirana 2011. godine. Jedan od ranih primjera takvog istraživanja dolazi iz 2000. godine, kada je otkriveno da su broj pristupa stranicama predmeta i objave na forumima povezani s uspjehom učenika (Wang & Newlin, 2000a). Isti autori kasnije su istraživali kako podaci iz LMS-a mogu pomoći nastavnicima u razumijevanju načina na koji učenici uče i predviđanju njihovih rezultata (Wang & Newlin, 2002b). Istraživanje je obuhvatilo 121 učenika na predmetu iz istraživačkih metoda u psihologiji, a analizirani su podaci o broju pregleda stranica, objavama na forumima i pročitanoj sadržaju. Rezultati su pokazali da rani pregledi stranica pozitivno koreliraju s uspjehom učenika na predmetu.

Ramos & Yudko (2008) istražili su kako različite online aktivnosti utječu na uspješan završetak predmeta kod 67 učenika. Koristili su višestruku regresijsku analizu (engl. multiple regression analysis) kako bi predvidjeli uspjeh učenika na temelju podataka o aktivnostima LMS-a. Dawson i ostali (2009) ispitali su povezanost motivacije učenika s podacima iz LMS-a. Rezultati su pokazali da postoji pozitivna veza između sudjelovanja u forumima i učenikove usmjerenosti na postizanje boljih rezultata. Macfadyen & Dawson (2010) proširili su ovo istraživanje dodavanjem analize podataka i razvili sustav ranog upozorenja za nastavnike, koji je omogućio identifikaciju 81% učenika koji nisu uspjeli završiti predmet.


Jedan od prvih primjera LAD-a za vizualizaciju aktivnosti učenika predstavili su Mazza & Dimitrova (2004). Koristili su vizualizacije kako bi nastavnicima omogućili lakše prepoznavanje učenika kojima je potrebna dodatna pažnja. Slika 7 prikazuje vizualizaciju aktivnosti učenika „Francesco“. Vizualizacija obuhvaća nekoliko dimenzija: pristupi sadržaju po temama (engl. accesses to content pages by topics) prikazani su kvadratićima, što omogućuje uvid u to koje je stranice učenik pregledavao i koliko često; ukupni pristupi predmetu (engl. global accesses to the course) prikazani su histogramom, čija visina odražava broj dnevnih pristupa; napredovanje prema rasporedu predmeta (engl. progress with the course schedule) vidljivo je kroz položaj oznaka na osi y – od početnih prema završnim sadržajima; sudjelovanje u komunikaciji (engl. messages) označeno je rombovima različitih boja, ovisno o vrsti interakcije (čitanje, objava, odgovor); predaje kvizova i zadataka (engl. quiz and assignment submissions) označene su slovima „Q“ i „A“ na odgovarajuće datume. Prikaz pokazuje da je

učenik bio dosljedan i metodičan u učenju, za razliku od nekih drugih studenata koji su preskakali dijelove sadržaja ili pokazivali nižu razinu aktivnost.



Slika 7 Prikaz ponašanja učenika kroz LAD (*Mazza & Dimitrova, 2004*)

Prva značajna primjena LAD-a, kao sustava ranog upozorenja bila je u projektu Course Signals na Sveučilištu Purdue, gdje je sustav u obliku semafora korišten za prikaz uspjeha učenika (Arnold & Pistilli, 2012). Course Signals pratio je aktivnosti učenika u stvarnom vremenu i na temelju tih aktivnosti omogućio predviđanje uspjeha učenika. Korišteni algoritam za predviđanje je koristio četiri vrste podataka: demografske podatke učenika (spol, dob, lokacija), prethodni uspjeh učenika (ocjene iz srednje škole), trenutnu učinkovitost učenika (zbroj ostvarenih ocjena) i trud (mjereno prema podacima LMS-a, uspoređujući ga s trudom drugih učenika). Algoritam je računao uspjeh svakog učenika i prikazivao ga u obliku semafora: crveno, žuto ili zeleno svjetlo (Slika 8). Crveno svjetlo označavalo je visoki rizik od neuspjeha, zeleno svjetlo visoku vjerojatnost uspjeha, a žuto svjetlo granični status (Arnold & Pistilli, 2012).



Slika 8 LAD Course Signals na Sveučilištu Purdue (Saqr, 2018)

S pojavom Međunarodne konferencije o analitici učenja, koja je održana 2011. godine, istraživanje u ovom području značajno je poraslo. Danas možemo reći da većina sveučilišta prepoznaje potrebu za sličnim alatima. LAD može koristiti višestruke vizualizacije podataka kako bi prikazala složene podatke na način koji ih čini lako razumljivima i korisnima, nastavnicima i učenicima (Elias, 2011). Prednosti uključuju identifikaciju učenika koji su u riziku kako bi im se pružila prilagođena pomoć (Gasevic i ostali, 2015), povećanje sudjelovanja i angažmana učenika (R. Bodily & Verbert, 2017), te općenito podršku nastavnicima i učenicima u unapređivanju obrazovnog procesa (Park & Jo, 2015; Sedrakyan i ostali, 2018).

2.3.4. DIZAJN NADZORNE PLOČE ANALITIKE UČENJA

Razumijevanje različitih reakcija učenika na informacije o vlastitoj izvedbi ključno je za oblikovanje učinkovitih LAD-ova. Neka istraživanja pokazuju da učenici s nižim sposobnostima preferiraju povratne informacije koje im omogućuju usporedbu s drugima, dok učenici s većim iskustvom i vještinama češće cijene informacije koje im pomažu pratiti vlastiti napredak tijekom vremena (Ruble & Flett, 1988).

2.3.4.1. PRIMJENA TEORIJA DRUŠTVENE I VREMENSKE USPOREDBE U LAD-U

Usporedba rezultata može pomoći učenicima da sagledaju svoj napredak, procijene jesu li zadovoljni postignutim te prepoznaju načine za daljnje unapređenje (Fleur i ostali, 2023). Takve usporedbe mogu biti vremenske (engl. Temporal Comparison Theory), kada se uspoređuju u različitim vremenskim trenucima, ili društvene, (engl. Social Comparison Theory) kada se uspoređuju s rezultatima drugih učenika.

- **Teorija društvene usporedbe** naglašava mehanizme putem kojih LAD može utjecati na samoučinkovitost učenika, prvenstveno pružanjem informacija o društvenom modeliranju. Prema ovoj teoriji, pojedinci procjenjuju svoje sposobnosti uspoređujući se s drugima (Festinger, 1954). Uspoređivanje s vršnjacima može pomoći učenicima u procjeni vlastite sposobnosti. Društvene usporedbe oblikuju vjerovanja o samoučinkovitosti, jer pružaju informacije o društvenom modeliranju, a učenici, promatrajući uspjehe svojih kolega, mogu procijeniti vlastite sposobnosti za izvršavanje određenih zadataka (Cleary, 2009).
- **Teorija vremenske usporedbe** bavi se usporedbom vlastite izvedbe u različitim vremenskim trenucima (Albert, 1977). LAD koji primjenjuje ovu teoriju može utjecati na samoučinkovitost učenika pružanjem informacija o njihovim iskustvima u savladavanju zadataka. Na primjer, učenici mogu pratiti svoju izvedbu u različitim vremenskim razdobljima i usporediti je kako bi procijenili svoj napredak.

Konert i ostali (2016) su razvili LAD za Moodle LMS, koji učenicima omogućuje usporedbu vlastitog znanja i vremena uloženog u učenje s kolegama. Istraživanje je pokazalo da su učenici funkciju usporedbe ocijenili kao najkorisniju među svim prikazanim informacijama u LAD-u. Slično tome, Guerra i ostali (2016) implementirali su LAD s integriranim funkcijama društvenih i vremenskih usporedbi. Rezultati su pokazali da su društvene usporedbe značajno poboljšale angažman i učinkovitost učenika, dok su obje vrste usporedbi dobile pozitivne ocjene, osobito od motiviranih učenika. Kombiniranje obje vrste usporedbi u LAD-u može učenicima pružiti dublji uvid u njihov napredak i potaknuti ih na daljnji rad.

2.3.4.2. PREPORUKE ZA DIZAJN NADZORNE PLOČE ANALITIKE UČENJA

Jivet i ostali (2018), donose ključne preporuke za dizajn nadzornih ploča analitike učenja (LAD-ova). Dizajn učinkovitog LAD-a trebao bi se temeljiti na pedagoškim načelima koja potiču kognitivni, bihevioralni i emocionalni razvoj učenika. Tablica 3 prikazuje preporuke i njihovu primjenu u dizajnu LAD-a .

Tablica 3 Preporuke za dizajn LAD-a i njihova primjena u praksi [pripremljeno prema (Jivet i ostali, 2018)]

SMJERNICE ZA DIZAJN LAD-A	PRIMJER KORIŠTENJA PREPORUKE ZA DIZAJN LAD-A
Dizajnirati LAD kao pedagoški alat koji potiče svijest i razmišljanje, te doprinosi promjenama u kognitivnim, bihevioralnim i emocionalnim sposobnostima.	Pružajući povratne informacije o izvedbi, učenici postaju svjesni svojih snaga i slabosti, čime se potiče razvoj njihovih sposobnosti u svim tim područjima.
Koristiti koncepte iz znanosti o učenju za donošenje dizajnerskih odluka.	Dizajn LAD-a trebao bi se temeljiti na teorijama vremenske i društvene usporedbe kako bi bio učinkovit.
Pažljivo koristiti društvenu usporedbu.	Uspoređujući se s vršnjacima, učenici mogu procijeniti svoje sposobnosti u obavljanju specifičnih zadataka. Društvene usporedbe oblikuju uvjerenja o vlastitoj učinkovitosti jer služe kao izvor informacija za modeliranje ponašanja.
Prilagoditi LAD različitim skupinama korisnika kako bi osigurali jednaku podršku za sve.	S obzirom na to da postoje učenici s različitim razinama uspjeha, potrebno je implementirati poruke koje odgovaraju njihovim rezultatima. Motivirajuće poruke za uspješne učenike, a poruke podrške za učenike s lošijim rezultatima.
Integrirati LAD u obrazovno okruženje i svakodnevne aktivnosti učenika.	Ova preporuka podrazumijeva da LAD pruža povratne informacije u realnom vremenu, čime učenicima omogućuje stalni pristup informacijama i praćenje svojih aktivnosti.

Iako se dizajni pojedinačnih LAD-ova razlikuju, većina se, prema Afzaal i ostali (2021), oslanja na dvije vrste analitike: deskriptivnu i prediktivnu. Deskriptivna analitika analizira podatke kako bi otkrila trendove temelje na digitalnim tragovima koje učenici ostavljaju tijekom svojih interakcija u virtualnim okruženjima. Također, pruža učenicima uvid u njihov trenutni napredak, pomažući im da bolje razumiju svoje navike u procesu učenja i razvoj tijekom vremena (Ramaswami i ostali, 2023).

Prediktivna analitika (PA) usmjerena je na budućnost. Predviđa uspjeh učenika na nadolazećim zadacima ili završne ocjene na kraju predmeta. Kombinacija deskriptivne i PA omogućuje dublje uvide i povećava vrijednost LAD-ova. Ipak, PA tek je u ranoj fazi primjene u LAD-ovima (Ramaswami i ostali, 2022).

2.4. PREDIKTIVNA ANALITIKA

U obje discipline, EDM i LA, termin prediktivna analitika (PA) se često koristi za opisivanje procesa predviđanja uspjeha učenika. Iako je ovaj pojam u LA preuzet iz šireg područja analize podataka, PA posebno se ističe primjenom ML za izgradnju modela predviđanja. Ova vrsta analitike postala je temeljna praksa istraživača, s posebnim naglaskom na predviđanje uspjeha učenika (Brooks & Thompson, 2022). Za potrebe ove disertacije, PA smatra vrstom LA-e koja se koristi za predviđanje uspjeha učenika temeljenog na podacima nastalim iz njihovih prethodnih interakcija u obrazovnom okruženju. Za potrebe izrade ove disertacije koristi se skup podataka (engl. dataset) prikupljen tijekom online nastave.

PA predstavlja granu analize podataka koja primjenjuje statističke metode, ML algoritme i tehnike modeliranja kako bi predviđala buduće događaje na temelju povijesnih i trenutnih podataka. Ova se vrsta LA temelji na pretpostavci da povijesni podaci sadrže obrasce i informacije koji mogu pomoći u razumijevanju i predviđanju uspjeha učenika. PA ima korijene u klasičnoj statistici, no tehnološki napredak, osobito u području ML-a, omogućio je razvoj preciznijih, skalabilnijih i automatiziranih modela predviđanja. S obzirom na to da se PA u velikoj mjeri oslanja na pristupe ML-a, nužno je predstaviti osnovne pojmove vezane uz ovo područje

2.4.1. UMJETNA INTELIGENCIJA I STROJNO UČENJE

Umjetna inteligencija (engl. *Artificial Intelligence*, AI) omogućuje računalnim sustavima da procesiraju podatke, prepoznaju uzorke, donose odluke i rješavaju probleme na način sličan ljudskom razmišljanju (Patel i ostali, 2022). AI se sastoji od dvije ključne komponente: „umjetno“, što označava da je sustav stvorio čovjek, i „inteligencije“, što podrazumijeva sposobnost zaključivanja i donošenja odluka. AI je sposobnost strojeva da imitiraju ljudsku inteligenciju (Ma & Sun, 2020). Razvoj AI-a ubrzan je zahvaljujući dostupnosti skupova podataka, naprednijim algoritmima i povećanoj računalnoj snazi (Goar, 2022). Danas su tehnologije poput neuronskih mreža (engl. *neural networks*), ekspertnih sustava (engl. *expert systems*) i obrade prirodnog jezika (engl. *natural language processing*) postale ključni dio AI sustava (Akuji i ostali, 2024). AI je osobito koristan u područjima koja zahtijevaju automatizaciju, uključujući obrazovanje, gdje omogućuje predviđanje uspjeha učenika.

ML, kao podskup AI, predstavlja znanstveno proučavanje algoritama koji omogućuju računalnim sustavima da automatski uče iz podataka i prilagođavaju se bez izravnog ljudskog

programiranja (Collins i ostali, 2021). Ključna svrha ML-a je prepoznavanje uzoraka u podacima, što omogućuje stvaranje modela za predviđanje. Danas je strojno učenje ključni element informacijske tehnologije i, iako često nevidljivo, ima značajan utjecaj na naš svakodnevni život. S obzirom na rastuće količine dostupnih podataka, očekuje se da će analitika imati sve važniju ulogu kao neizostavan dio tehnološkog napretka, čime ML postaje jedno od najbrže rastućih područja računalnih znanosti sa širokim mogućnostima primjene (Akinsola, 2017). Prema Mahesh (2019), ML predstavlja znanstveno proučavanje algoritama i statističkih modela koje računalni sustavi koriste za obavljanje zadataka. Korištenjem algoritama, modeli se treniraju na podacima, što im omogućuje prepoznavanje obrazaca i predviđanje (Akuji i ostali, 2024).

2.4.2. KATEGORIJE STROJNOG UČENJA U PREDIKTIVNOJ ANALITICI

U području ML-a, razlikujemo nekoliko glavnih kategorija (Slika 9): nadzirano učenje (engl. Supervised Learning), nenadzirano učenje (engl. Unsupervised Learning) i učenje uz podršku/ojačanje (engl. reinforcement learning, poznato i kao „učenje pojačavanjem“ ili „podržano učenje“). Svaka od ovih kategorija obuhvaća algoritme i metode koje se koriste za treniranje specifičnih modela, npr. stabla odluke (engl. Decision Trees, DT). Također, razlikujemo pojmove algoritma i modela: algoritam je niz uputa koje definiraju proces učenja modela, dok model predstavlja matematički opis odnosa između ulaza i izlaza temeljen na podacima.



Slika 9 Tri glavne kategorije ML i njihova primjena

- Nadzirano učenje jedno je od najpopularnijih i najčešće korištenih kategorija strojnog učenja (Akuji i ostali, 2024). Cilj nadziranog učenja jest razviti funkciju koja ulazne podatke transformira u željene izlaze, omogućujući predviđanje novih podataka na temelju obrazaca naučenih tijekom procesa treniranja (Verbraeken i ostali, 2020). Treniranje modela strojnog učenja provodi se na skupu podataka podijeljenom na skup za treniranje (koji sadrži ulazne i izlazne vrijednosti) i skup

za testiranje, čime se omogućuje vrednovanje performansi modela (Mahesh, 2019). Ova tehnika nalazi široku primjenu u rješavanju problema poput predviđanja, klasifikacije i donošenja odluka u raznim domenama.

- Nenadzirano učenje primjenjuje se na skup podataka koji ne uključuju izlazne varijable. Glavni cilj ovih metoda je prepoznavanje obrazaca ili struktura u podacima bez prethodnog znanja o njihovoj klasifikaciji (Verbraeken i ostali, 2020). Primjer uključuje grupiranje učenika prema stilovima učenja, čime se omogućuje prilagodba nastavnih metoda njihovim potrebama.
- Učenje uz podršku/ojačanje koristi povratne informacije temeljene na funkcijama nagrade i kazne za optimizaciju djelovanja sustava u dinamičnim okruženjima (Verbraeken i ostali, 2020). Učenje uz podršku/ojačanje ima široku primjenu, uključujući igranje složenih igara (npr. AlphaGo), optimizaciju robotike te inteligentne sustave za preporuke u obrazovanju. Primjer u obrazovnom kontekstu uključuje sustave koji koriste pokušaje i pogreške kako bi unaprijedili preporuke sadržaja za učenike (Jain & Kumar, 2022).

2.4.2.1. TEHNIKE I ALGORITMI NADZIRANOG UČENJA U PREDIKTIVNOJ ANALITICI

Nadzirano učenje koristi se za predviđanje mjerenja učenja, poput uspjeha učenika, stjecanja vještina, kao i za procjenu učinkovitosti metoda poučavanja. Nadzirano učenje obuhvaća dvije glavne vrste tehnika: 1) Klasifikacija (engl. Classification), koristi skup podataka kako bi naučila pridruživati pripadajuću klasu određenim ulazima, dok izlazna značajka ima diskretne vrijednosti i 2) Regresija (engl. Regression), koja modelira vezu između značajki (ulaznih varijabli) i kontinuirane ciljane značajke (izlaza).

Neki od klasifikacijskih i regresijskih algoritama nadziranog učenja koji se koriste za izgradnju modela predviđanja u području LA su: linearna regresija (engl. Linear Regression, LR), logistička regresija (engl. Logistic Regression, LogR), metoda k-najbližih susjeda (engl. k-Nearest Neighbors, kNN), stablo odlučivanja (engl. Decision Tree, DT), Naivni Bayesov algoritam (engl. Naïve Bayes, NB), stroj potpornih vektora (engl. Support Vector Machines, SVM) i umjetna neuronska mreža (engl. Artificial Neural Network, ANN). Uz navedene algoritme, koriste se i tzv. Boosting algoritmi, poput AdaBoost, Gradient Boosting, XGBoost ili drugi iz ove grupe. Ovisno o prirodi problema, prethodno navedeni algoritmi primjenjuju se za klasifikacijske, regresijske ili obje vrste zadataka.

2.4.2.2. KORACI U IZGRADNJI MODELA PREDVIĐANJA

Koraci za izgradnju modela predviđanja uključuju nekoliko ključnih koraka koji omogućuju izgradnju učinkovitog modela temeljenog na podacima. Svaki od tih koraka ima specifičnu ulogu u cijelom procesu. Prema Brooks & Thompson (2022), koraci za izgradnju modela predviđanja su:

a) **identifikacija problema (engl. problem identification)**, — potrebno je odabrati problem koji će se ponavljati u budućnosti i koji ima mjerljive karakteristike, jasan ishod, mogućnost intervencije i dostupan skup podataka;

b) **prikupljanje podataka (engl. data collection)** — istraživač treba identificirati ciljnu značajku (npr. konačna ocjena ili razina postignuća) te moguće ulazne značajke (npr. spol, prethodna ocjena, broj pristupa LMS-u).

c) **inženjering značajki (engl. feature engineering)** — sirovi podaci se transformiraju u značajke koje se mogu koristiti u modelima predviđanja.

d) **odabir značajki (engl. feature selection)** — kako bi se izgradio i primijenio model predviđanja, potrebno je odabrati prediktivne (ulazne) značajke koje su povezane s ciljnom (izlaznom) značajkom, vrijednošću koja se predviđa. Neki modeli koriste sve dostupne značajke predviđanja, bez obzira na to jesu li visoko informativne ili ne, dok drugi primjenjuju neku formu odabira značajki kako bi uklonili neinformativne značajke iz modela. Ovisno o algoritmu koji se koristi za izgradnju modela predviđanja, može biti korisno ispitati korelaciju između značajki i ukloniti visoko korelirane značajke (problem multikolinearnosti u regresijskim analizama). Utjecaj nedostajućih podataka uvelike ovisi o izboru algoritma za učenje. Nedostajuće vrijednosti u skupu podataka mogu se obraditi na nekoliko načina, a pristup koji se koristi ovisi o tome nedostaju li podaci jer su nepoznati ili jer nisu primjenjivi. Neki algoritmi mogu napraviti predviđanje čak i kada neke vrijednosti nedostaju; nedostajuće vrijednosti jednostavno nisu korištene u modelu.

e) **izgradnja modela (engl. model building)** — Algoritmi strojnog učenja koriste se za izgradnju modela predviđanja.

f) **vrednovanje modela (engl. model evaluation)** — Kako bi se procijenila kvaliteta modela predviđanja, potreban je skup podataka s poznatim oznakama. Predviđanja koja model napravi na testnom skupu mogu se usporediti s poznatim stvarnim oznakama testnog skupa kako bi se

vrednovao model. Dostupan je širok spektar mjera za uspoređivanje sličnosti poznatih stvarnih oznaka i predviđenih oznaka, kao što su točnost (engl. accuracy), preciznost (engl. precision) i odziv (engl. recall).

2.4.3. ISTRAŽIVANJA I TRENDVI U PREDVIĐANJU USPJEHA UČENIKA

Brojni znanstvenici već su uspješno predviđali uspjeh učenika. U nastavku slijedi komparativna analiza nekoliko sustavnih pregleda literature koji se bave predviđanjem uspjeha učenika.

Abu Saa i ostali (2019) u sustavnom pregledu literature (2009-2018) analiziraju radove o korištenju modela za predviđanje uspjeha učenika, koji se najčešće povezuje s učenikovim prethodnim uspjehom i demografskim podacima, a također ističu i važnost log podataka dobivenih iz LMS-a. Klasifikacija je najčešće korištena tehnika, a najčešće korišteni algoritmi su DT, NB, ANN, regresija (LR, LogR) i SVM.

Roslan & Chen (2022) u sustavnom pregledu literature (2015-2021) analiziraju metode korištene za predviđanje uspjeha učenika. Autori ističu da se za predviđanje uspjeha učenika najčešće koristi prethodni uspjeh učenika (rezultati ispita, ocjene na provjerama znanja, prosječna ocjena, kumulativna prosječna ocjena i prisutnost na nastavi) te demografski podaci (dob, spol, geografska pripadnost, etnička pripadnost, nacionalnost, bračni status, socioekonomski status i dr.). Od tehnika predviđanja, najčešće je korištena klasifikacija, a najčešće korišteni algoritmi su DT, NB, RF i SVM.

Alyahyan & Dustegor (2020) u sustavnom pregledu literature također navode da je klasifikacija najčešće korištena tehnika, a najčešće korišteni algoritmi DT i NB. DT se koristi u gotovo polovici svih analiziranih radova. Za predviđanje uspjeha učenika najčešće se koriste prethodni uspjeh učenika (ocjene iz prethodne razine obrazovanja) i demografski podaci (spol, dob, etnička pripadnost, obrazovanje i zanimanje roditelja, mjesto prebivališta, veličina obitelji i obiteljski prihod).

Dhankhar i ostali (2021) tvrde da ključne značajke za predviđanje uspjeha učenika uključuju podatke o interakcijama u LMS-u, prethodni uspjeh i demografske podatke. Od korištenih tehnika, klasifikacija je najčešće primijenjena, a najčešće korišteni algoritmi su DT, regresije (LR i LogR) te ANN u predviđanju uspjeha učenika.

Iako je predviđanje uspjeha učenika steklo značajnu pažnju, relativno mali broj istraživanja se bavi predviđanjem uspjeha u učenju programiranja. Jedini pregledni rad o predviđanju uspjeha učenika u učenju programiranja objavili su W. C. Choi i ostali (2023). Njihovo istraživanje obuhvatilo je baze podataka ACM Digital Library, IEEE Xplore, ScienceDirect i ProQuest, pri čemu su analizirali 40 relevantnih radova. Rezultati pokazuju da su se autori većinom bavili sveučilišnom razinom obrazovanja, s posebnim naglaskom na tekstualne programske jezike poput Jave i Pythona. Najčešći izvori za izradu skupa podataka uključuju LMS, pri čemu platforme poput Moodle-a dominiraju u prikupljanju podataka o ocjenama i ponašanju učenika. Modeli predviđanja uglavnom koriste algoritme nadziranog učenja, s naglaskom na klasifikaciju i regresiju. Algoritmi poput SVM, RF i LR pokazali su se najefikasnijima. Također, istraživanje ističe da autori često koriste prethodni uspjeh učenika kao ključne značajke modela predviđanja. Osim toga, koriste se i zapisi o aktivnostima učenika na predmetu. Sažetak navedenih pregleda prikazan je u Tablica 4.

Tablica 4 Komparativna analiza rezultata

PUBLIKACIJA	REZULTATI		
	Identificirane značajke	Najčešće korištene tehnike	Najčešće korišteni algoritmi
Abu Saa i ostali (2019)	Prethodni uspjeh učenika, demografski podaci, log podaci iz LMS-a	Klasifikacija	DT, NB, ANN, LR, LogR, SVM
Alyahyan & Dustegor (2020)	Prethodni uspjeh učenika i demografski podaci	Klasifikacija	DT, NB
Dhankhar i ostali (2021)	Podaci o interakcijama u LMS-u, prethodni uspjeh učenika i demografski podaci	Klasifikacija	DT, LR, LogR, ANN
Roslan & Chen (2022)	Prethodni uspjeh učenika i demografski podaci	Klasifikacija	DT, NB, RF i SVM
W. C. Choi i ostali (2023).	Prethodni uspjeh učenika, log podaci iz LMS-a sustava	Klasifikacija	SVM, RF i LR

U sljedećem potpoglavlju osvrnut ćemo se na ishode učenja kao temeljni dio obrazovnog procesa, te jasno istaknuti njihovu važnost.

2.5. ISHODI UČENJA

Ishodi učenja predstavljaju temeljni dio obrazovnog procesa, usmjeravajući ga prema jasno definiranim ciljevima koji omogućuju procjenu napretka učenika. U posljednjih tridesetak godina psihologija sve više naglašava važnost samoregulacije, motivacije, kognicije, emocija i djelovanja, što omogućuje pojedincu da preuzme aktivnu ulogu u vlastitom razvoju, prilagodbi i napredovanju (Bandura, 2001). Stoga se može reći da se fokus pomaknuo s nastavnika i sadržaja koji se prenosi na samoga učenika, koji sada ima središnju ulogu kao aktivni sudionik vlastitog procesa učenja.

Suprotno novom pristupu u kojemu je u središtu aktivan učenik, tradicionalni pristup više je pažnje posvećivao samom sadržaju učenja i nastavniku kao „prenositelju“ tog sadržaja. Obrazovanje temeljeno na ishodima (engl. Outcome-based education) razvilo se kao suvremeni pristup u obrazovanju, a u novije vrijeme sve se više prihvaća i primjenjuje (Macayan, 2017). Ishodi učenja predstavljaju jasne i nedvosmislene iskaze o tome što se očekuje od učenika u određenoj domeni ili predmetnom području tijekom pojedine godine učenja i poučavanja (*Smjernice za vrednovanje procesa učenja i ostvarenosti ishoda u osnovnoškolskome i srednjoškolskome odgoju i obrazovanju*, 2020). Jednostavno rečeno, ishodi učenja odnose se na znanja, vještine i vrijednosti koje učenici trebaju steći do završetka razdoblja obrazovanja ili do kraja određenog predmeta (Premalatha, 2019). U ovoj disertaciji ishodi učenja se mjere na kraju predmeta.

2.5.1. PRIMJENA ISHODA UČENJA U OBRAZOVNI PROCES: ULOGA KONSTRUKTIVNOG PORAVNANJA

Sorić (2014) naglašava važnost konstruktivnog poravnanja (engl. constructive alignment) za kvalitetu obrazovnog procesa. Konstruktivno poravnanje u poučavanju podrazumijeva čvrstu povezanost između ishoda učenja koje učenici trebaju ostvariti, aktivnosti koje im omogućuju postizanje tih ishoda, te metoda vrednovanja kojima provodimo provjeru ostvarenosti tih ishoda (*Smjernice za vrednovanje procesa učenja i ostvarenosti ishoda u osnovnoškolskome i srednjoškolskome odgoju i obrazovanju*, 2020).

Pristup obrazovanju temeljen na ishodima učenja naglašava važnost dobrog definiranja ishoda učenja već u fazi planiranja kurikuluma, odnosno, što će učenici biti u stanju postići nakon što ispune sve obveze i zahtjeve određenog predmeta. Međutim, bez obzira na to koliko su dobro definirani ishodi učenja, ako se ne usklade s načinom poučavanja (metode poučavanja) s

očekivanim ishodima kao i načinima provjere njihove ostvarenosti (metode vrednovanja), proces poučavanja neće biti uspješan i neće dovesti do željenih promjena u znanju, vještinama i stavovima učenika.

2.5.2. TAKSONOMIJE OBRAZOVNIH CILJEVA/ISHODA

U skladu s novom paradigmom u obrazovanju, koja naglašava aktivnu ulogu učenika u obrazovnom procesu, ishodi učenja predstavljaju tvrdnje koje formuliraju nastavnici, a kroz koje se jasno pojašnjava što se od učenika očekuje da zna, razumije i/ili da bude sposoban pokazati nakon završetka obrazovnog procesa (*Priručnik za izradu ishoda učenja*, 2018).

Ciljevi predstavljaju namjere nastavnika i odnose se na ono što planiraju ili namjeravaju poučavati. Stoga ciljeve pišu nastavnici, gledajući ih iz vlastite perspektive. S druge strane, ishodi učenja odnose se na učenje, odnosno na specifična ponašanja (kognitivna, psihomotorna i afektivna) koja će učenik usvojiti tijekom procesa učenja. Ishode učenja također formuliraju nastavnici, ali iz perspektive učenika.

Taksonomije obrazovnih ciljeva predstavljaju konceptualne okvire koji pomažu u planiranju i definiranju ishoda učenja. Taksonomije omogućuju organiziranje i sistematizaciju različitih elemenata obrazovnog procesa prema određenim klasifikacijskim principima. Najpoznatija i najčešće primjenjivana taksonomija u ovom području je Bloomova taksonomija.

2.5.2.1. BLOOMOVA TAKSONOMIJA

Bloom je prepoznao tri područja učenja, kognitivno, afektivno i psihomotorno. U svakom je području uočio da učenje može napredovati prema sve složenijim razinama. Njegov rad najviše je razrađen u kognitivnom području, gdje je stvorio klasifikaciju misaonih procesa, od jednostavnog prisjećanja činjenica do analize i vrednovanja. Njegova knjiga *Taxonomy of Educational Objectives: Handbook 1, the Cognitive Domain* (Bloom i ostali, 1956) postala je popularan alat za planiranje kurikuluma i procjenu znanja. Taksonomija daje okvir koji omogućuje napredovanje prema složenijem razumijevanju na temelju prethodnog učenja (Kennedy i ostali, 2007).

Originalna Bloomova taksonomija uključuje šest razina:

- **Znanje (pamćenje):** Prisjećanje činjenica i informacija.
- **Shvaćanje:** Shvaćanje značenja pojmova i informacija.
- **Primjena:** Korištenje znanja za rješavanje problema ili izvršavanje zadataka.
- **Analiza:** Razlaganje informacija na dijelove radi boljeg razumijevanja.
- **Sinteza:** Kombiniranje elemenata u nešto novo ili rješavanje složenijih problema.
- **Vrednovanje:** Donošenje zaključaka temeljenih na određenim kriterijima.

Ove su razine kognitivnih procesa hijerarhijski poredane od najjednostavnijih do najsloženijih i od konkretnih prema apstraktnim, i pritom se ne može prijeći na višu razinu dok nije savladana prethodna, niža razina.

2.5.2.2. REVIDIRANA BLOOMOVA TAKSONOMIJA

Godine 2001. Bloomova taksonomija je revidirana pod vodstvom Krathwohla i Andersona, bivšeg učenika Benjamina Blooma. Cilj revizije je prilagođavanje taksonomije suvremenim spoznajama o učenju i olakšati njezinu primjenu u obrazovanju. U revidiranoj verziji također je šest kategorija kognitivnih procesa, ali su preimenovane: znanje u pamćenje, shvaćanje u razumijevanje, sinteza u stvaranje, a dvije su zamijenile mjesta tako da je stvaranje, a ne vrednovanje, najviša kategorija kognitivnih procesa. Šest kategorija revidirane taksonomije prema Anderson i ostali (2001):

- pamćenje, koje se određuje kao učenikovo dosjećanje relevantnog znanja iz dugotrajnog pamćenja (prepoznati, dosjetiti se);
- razumijevanje, koje podrazumijeva da učenik može odrediti značenja nastavnih poruka, usmenih, pismenih i grafičkih (interpretirati, tumačiti, klasificirati, rezimirati, zaključiti, usporediti, objasniti);
- primjena, koje znači da učenik može provoditi ili koristiti određeni postupak u danoj situaciji (izvršavati, implementirati);
- analiza, koje predstavlja učenikovu mogućnost rastavljanja gradiva (materijala) u njegove sastavne dijelove uz razumijevanje međusobnih povezanosti tih dijelova i njihova odnosa prema cjelini (razlikovati, organizirati, pripisati);
- vrednovanje, koje predstavlja mogućnost procjenjivanja prema određenim kriterijima ili standardima (provjeriti, kritizirati) i

- stvaranje, koje se određuje kao mogućnost sastavljanja postojećih elemenata u novu koherentnu cjelinu ili originalni proizvod (generirati, planirati, proizvesti).

Krathwohl (2002) u revidiranoj verziji Bloomove taksonomije dva su ključna aspekta, imenica i glagol. Imenica definira dimenziju znanja, dok glagol definira dimenziju kognitivnih procesa. Revidirana taksonomija zadržava šest kategorija kognitivnih procesa (navedenih ranije), dok dimenzija znanja, u kojoj se ti procesi odvijaju, obuhvaća četiri kategorije:

- činjenično znanje,
- konceptualno znanje,
- proceduralno znanje i
- metakognitivno znanje

2.5.3. VAŽNOST ISHODA UČENJA

Ishodi učenja koriste se za različite svrhe: unutar kvalifikacijskih okvira, kvalifikacijskih standarda, standarda zanimanja i kurikulumu (na razini programa, modula, predmeta ili nastavne jedinice), razlikujući se pri tome s obzirom na razinu specifičnosti (*Priručnik za izradu ishoda učenja*, 2018). Usmjerenost na ostvarene ishode učenja dovodi nas do kompetencija koje se mogu razumjeti kao ostvareni ishodi učenja vrednovani kroz sposobnost učenika da samostalno primjenjuje znanja i vještine u praksi. Bez obzira o kojoj razini govorili, ishodi učenja pomažu da korisnici (učenici, nastavnici, poslodavci) bolje razumiju koje se posljedice ili rezultati očekuju na kraju obrazovnog procesa.

Prema Vizek-Vidović (2009) ishodi učenja doprinose:

- nastavnicima da jasno definiraju određeni broj ishoda koje žele postići poučavanjem na određenome predmetu te u skladu s tim odaberu nastavne sadržaje, zatim da odaberu primjerene metode poučavanja kojima će ostvariti željene ishode i primjerene načine praćenja učenikovog napredovanja te načine provjere i vrednovanja ishoda.
- učenicima da bolje razumiju što se od njih očekuje i što mogu očekivati od pojedine nastavne jedinice ili predmeta.

Ova disertacija bavi se razvojem modela za vizualizaciju **stupnja postignutosti ishoda učenja** u LAD, s naglaskom na podršku nastavnicima u praćenju napretka i uspješnosti učenika. Pri

definiranju ishoda učenja koristi se revidirana Bloomova taksonomija, o čemu više riječi u petom poglavlju. LAD, razvijen na temelju predloženog modela, osmišljen je kao alat koji omogućava nastavnicima jasan, pregledan i intuitivan uvid u stupanj ostvarenja definiranih ishoda učenja. Nastavnici mogu vidjeti koliko učenika ostvaruje određene ishode, tko ima poteškoće s ključnim konceptima ili vještinama, te koji su ishodi najčešće ostvareni.

Cilj predloženog modela je unaprijediti proces donošenja odluka u obrazovanju pružanjem podataka koji su jasni i brzo dostupni. Nastavnici, koristeći ovaj alat, mogu prilagoditi nastavu potrebama učenika, fokusirati se na specifične ishode učenja koji zahtijevaju dodatnu pažnju te brzo reagirati na uočene poteškoće.

3. STANJE ISTRAŽENOSTI

Kako bi se osiguralo bolje razumijevanje trenutnog stanja istraženosti, ovo poglavlje nudi sustavni pregled literature o nadzornim pločama analitike učenja (LAD-ovima). Pregled je strukturiran prema dvije ključne perspektive. Prva perspektiva obuhvaća analizu postojećih LAD-ova u obrazovanju, istražujući korisničke skupine, vrste prikazanih podataka, ciljeve razvoja i metode prezentacije povratnih informacija. Razmatra se povratna informacija prezentirana LAD-om, jer su, kako je prethodno napisano u potpoglavlju 2.3.1 važan element u unapređenju procesa učenja i poučavanja. Druga perspektiva istražuje primjenu prediktivne analitike (PA) u okviru LAD-ova, s fokusom na razumijevanje njihovog doprinosa u prilagodbi i personalizaciji obrazovnih procesa te na rezultate vrednovanja ovih alata od strane učenika i/ili nastavnika u procesu učenja i poučavanja.

3.1. ISTRAŽIVANJA O LAD-OVIMA U PROCESU UČENJA I POUČAVANJA

Kronološki, prvi pregled LAD-ova dali su Verbert, Duval, i ostali (2013). Autori predstavljaju konceptualni model sastavljen od četiri elementa: samosvijest (engl. self-awareness), refleksija (engl. reflection), stvaranje osjećaja (engl. sense making) i utjecaj (engl. behavioral change). Verbert, Govaerts, i ostali (2013) nastavljaju prethodni rad i daju novu kategorizaciju LAD-ova: LAD-ovi koji se koriste pri tradicionalnoj nastavi, LAD-ovi koji se koriste pri grupnom radu i LAD-ovi koji se koriste za učenje na daljinu.

Schwendimann i ostali (2016) predstavljaju prvi sustavni pregled literature o LAD-ovima. Pregledano je ukupno 55 radova, a rezultati su kategorizirani u četiri glavna područja: vrsta doprinosa (npr. teoretski prijedlozi ili implementacije), kontekst učenja (npr. vrsta korisnika, razina obrazovanja ili pedagoški pristup), podaci (npr. svrha, izvori podataka ili vrste platformi) i vrednovanje. Najvažnija saznanja iz pregleda ukazuju na to da LAD-ovi slijede tradicionalnu paradigmu u kojoj nastavnik aktivno prati učenike. Autori također navode kako se LAD-ovi najviše koriste u visokom obrazovanju, no očekuje se porast primjene u srednjoškolskom obrazovanju. Dvije trećine istraženih LAD-ova oslanja se na podatke o zapisima aktivnosti učenika na predmetu kao ključne izvore podataka, dok veći broj cilja nastavnike kao glavnu skupinu kojoj se prezentiraju podaci.

R. Bodily & Verbert (2017) daju drugi sustavni pregled literature o LAD-ovima koji je usmjeren na alate koji učenicima pružaju povratne informacije, bilo kroz LAD, sustave za preporuke ili druge oblike poruka temeljene na analitici učenja. Istraživali su pet kategorija: funkcionalnost (prednosti koje sustav pruža učenicima), izvore podataka (vrste podataka koji se prikupljaju, analiziraju i prikazuju učenicima), analizu dizajna (dizajnerski principi i postupci koji se razmatraju prije testiranja ili implementacije), percepcije učenika (percepcije učenika nakon korištenja LAD-a) i mjereni utjecaj (utjecaj koji alat ostavlja na učenika). Autori zaključuju da je potrebno usmjeriti istraživanja na dizajn i razvoj LAD-ova. Poseban naglasak potrebno je usmjeriti na istraživanja koja ispituju utjecaj ovih alata na ponašanje učenika, njihove obrazovne ishode i razvoj vještina. Takva istraživanja trebala bi obuhvatiti detaljne analize načina na koje učenici koriste sustav, kako bi se osigurala dublja razumijevanja njihovog utjecaja i učinkovitosti.

Jivet i ostali (2017) pružaju teoretski okvir za razumijevanje pedagoških i psiholoških temelja koji oblikuju razvoj LAD-ova. Utvrdili su da trenutni dizajni često potiču natjecanje među učenicima umjesto ovladavanja znanjem, pri čemu nude neodgovarajuće okvire za usporedbu. Jivet i ostali (2018) provode sustavni pregled literature koja obuhvaća 53 rada, te su istražili u kojoj su mjeri teorije učenja integrirane u razvoj LAD-ova. Uočena je značajna neusklađenost između ciljeva LAD-a i načina vrednovanja. Većina LAD-ova usmjerena je na podršku metakognitivnim procesima učenika, dok se znatno manji broj bavi kognitivnim ili emocionalnim aspektima učenja.

Matcha i ostali (2019) navode da je nedostatak teorijskog uporišta pri izgradnji LAD-ova jedna od glavnih kritika u postojećoj literaturi. Autori predlažu model korisniku usmjerenih sustava analitike učenja (engl. Model of User-Centered Learning Analytics Systems - MULAS), čiji je cilj usmjeriti razvojne stručnjake i istraživače u njihovim nastojanjima da bolje razumiju i optimiziraju proces učenja i poučavanja, te okruženje u kojem se ono odvija.

Predstavljeni model stavlja naglasak na učenike i sam proces učenja i poučavanja, temeljeći se na četiri ključne dimenzije: teorija (engl. theory), dizajn (engl. design), povratne informacije (engl. feedback) i vrednovanje (engl. evaluation).

Također, autori definiraju četiri ključna aspekta samoreguliranog učenja:

1. Identifikacija zadatka (engl. Task Identification) – razvijanje percepcije kako riješiti zadatak.
2. Postavljanje ciljeva i planiranje (engl. Goal Setting and Planning) – postavljanje ciljeva aktivnosti učenja i formuliranje strategija u skladu s tim ciljevima.
3. Provedba strategija učenja (engl. Enactment of Learning Strategies) – faza u kojoj većina aktivnosti tijekom učenja ovisi o primjeni odabranih strategija.
4. Adaptacija (engl. Adaptation) – prilagodba ponašanja učenika na temelju metakognitivnog praćenja i kontrole izvedbe.

Ramaswami i ostali (2022) provode sustavni pregled literature o korištenju prediktivne analitike u LAD-ovima te zaključuju da je broj istraživanja na ovu temu nedovoljan budući da su postojeća istraživanja prvenstveno usmjerena na predviđanje postignuća učenika u predmetu i određivanje pokazatelja rizika.

Pregledni rad Williamson & Kizilcec (2022) naglašava kako većina istraživanja navode osnovne demografske podatke, ali ne ulaze u dublje aspekte identiteta i istraživačkog pozicioniranja. Također, ukazuju na nedostatak prilagodbe LAD alata specifičnim pedagoškim potrebama fakulteta što umanjuje njihovu korisnost, naglašavajući da je većina rješenja teško prenosiva jer nedostatak otvorenog koda ograničava primjenu u širim kontekstima. Prema tome preporučuju internacionalnu suradnju i razvoj prilagodljivih, otvorenih rješenja za LAD alate, i uvođenje pedagoških teorija.

Kaliisa i ostali (2024) provode sustavni pregled utjecaja na postignuća, motivaciju, sudjelovanje i stavove studenata, ispitujući jesu li LAD-ovi ispunili očekivanja. Autori tvrde kako je utjecaj LAD-ova na motivaciju i stavove umjeren. Značajno je da su LAD-ovi pokazali relativno znatan utjecaj na sudjelovanje studenata, što sugerira da LAD-ovi mogu poticati angažman i interakciju u online okruženjima za učenje. Istraživačima se predlaže korištenje rigorozne metode procjene i uspostava jasnih standarda za vrednovanje LAD-ova. Takvi napori mogu unaprijediti naše razumijevanje potencijala LAD-ova za poboljšanje rezultata učenja te pružiti vrijedne uvide, kako za nastavnike i učenike, tako i za istraživače.

S obzirom da je LA relativno mlado područje istraživanja, ne iznenađuje ograničen broj sustavnih pregleda literature o LAD-ovima. Iako postoji rad (Ramaswami i ostali, 2022) koji obrađuje upotrebu prediktivne analitike (PA) u LAD-ovima, ipak ne uključuje analizu povratnih

informacija i ciljeve razvoja LAD-ova. Također, u posljednje vrijeme nedostaje analiza vrednovanja LAD-ova u empirijskim istraživanjima.

3.2. SUSTAVNI PREGLED LITERATURE O LAD-OVIMA U PROCESU UČENJA I POUČAVANJA

Sustavni pregled literature, koji je proveden u okviru istraživanja za potrebe ove disertacije, obuhvatio je 101 publikaciju prikupljenu iz baza podataka ACM Digital Library, IEEE Xplore, Web of Science, kao i publikacije s konferencija o analitici učenja i znanja (engl. International Conference on Learning Analytics and Knowledge, LAK). Smjernice za strukturiranje preglednog rada preuzete su iz Webster & Watson (2002). Rezultati su prikazani u obliku konceptualne matrice (engl. concept matrix), koja je omogućila sustavno organiziranje ključnih informacija i karakteristika tijekom pregleda radova. Prilikom pretraživanja svih baza podataka, postavljena su vremenska ograničenja. Godina 2011. se uzima kao relevantna jer je te godine održana prva konferencija LAK-a, pa je vremensko ograničenje postavljeno za razdoblje od 2011. do 2024. godine.

Pojam „dashboard“ u kontekstu LA smatra se relativno novim, pa se pretpostavlja da znanstvenici često koriste pojam „alat“ umjesto „dashboard“. Zbog toga je pojam pretrage proširen na riječ „tool“. U svim navedenim izvorima pretraživano je isključivo polje naslov (engl. *title*), a ključne riječi korištene u pretraživanju bile su: “learning analytics dashboard” i “learning analytics tool”.

Pretragom baze ACM Digital Library pronađeno je 81 rezultata, IEEE Xplore 55 rezultata, SCOPUS 198 rezultata, Web of Science 119 rezultata. Prema tome, ukupno je identificirano 453 radova. Pretraživanjem zbornika radova konferencije LAK izdvojeno je i pregledano 864 rada objavljena u razdoblju od 2011. do 2024. godine.

Fokus istraživanja je nadzorna ploča ili alat za analitiku učenja (LA) koji pruža povratnu informaciju učenicima i/ili nastavnicima. U obzir su uzeti svi alati koji su identificirani ovim pregledom, bez obzira na to jesu li već ranije obuhvaćeni u sličnim pregledima literature. Isključeni su radovi koji nisu na engleskom jeziku, radionice, paneli, posteri, demosi, i radovi


koji se odnose na korištenje analitike učenja izvan domene obrazovanja, te knjige ili dijelovi knjiga.

U fazi pregledavanja radova, očekivano su se pojavili isti radovi među bazama, stoga je proveden postupak odbacivanja duplikata, nakon kojeg su ostala 364 rada. Deset radova nije bilo na engleskom jeziku, pa su i oni odbačeni. Nakon pregleda sažetaka preostalo je ukupno 263 rada. Detaljnim čitanjem tih radova, konačan broj smanjen je na 66 radova, koji su zadovoljili sve sljedeće kriterije za uključivanje:

- rad prikazuje sustav koji koristi analitiku učenja za pružanje povratne informacije učenicima i/ili nastavnicima,
- rad uključuje vrednovanje takvog sustava,
- sustav je implementiran u stvarnom obrazovnom okruženju.

Nakon pregledavanja sažetaka radova sa LAK konferencija, odabrano je 257 radova za detaljniji pregled. Popis je uspoređen sa popisom publikacija pregledanih u bazama radi provjere o preklapanju, nakon čega su odbačena 32 rada. Detaljnijim čitanjem preostalih 225 broj relevantnih radova znatno je smanjen na 28 radova, na temelju prethodno definiranih kriterija za uključivanje.

U idućoj fazi, pregledane su reference identificiranih publikacija na temelju kojih su pronađena 92 alata. Pet radova obuhvaćenih u ovom preglednom radu jer zadovoljavaju kriterije selekcije su May i ostali (2011), (Govaerts i ostali 2012), Jovanovic i ostali (2012), Podgorelec & Kuhar (2011) i Gómez Aguilar i ostali (2013). Dva rada, Akçapınar & Bayazit (2019) i Volaric & Ljubić (2017), naknadno su dodana u pregled jer predstavljaju alat korišten u obrazovanju u vidu povratne informacije učenicima ili nastavnicima. Ukupno 101 rad obuhvaćen je u ovom pregled. Slika 10 prikazuje broj odabranih radova s obzirom na godinu objavljivanja.



Slika 10 Broj radova prema godini objave

Na samom početku analizirani su ciljevi razvoja LAD-ova, a zatim su istražene korištene vrste podataka u LAD-ovima, kategorizirane na sljedeći način:

1. Statični podaci – podaci koji ostaju nepromjenjivi u određenom vremenskom razdoblju, poput imena, identifikacijskog broja (ID) ili drugih osnovnih atributa.
2. Podaci zapisa o aktivnostima učenika na predmetu – informacije o broju i vremenu pristupa sustavu, koje omogućuju praćenje aktivnosti korisnika.
3. Korištenje nastavnih materijala i postignuća – informacije o učestalosti korištenja resursa i rezultatima učenika, uključujući podatke o najčešće korištenim resursima ili uspjehu na ispitima.
4. Podaci društvenih mreža – aktivnosti korisnika na mrežnim platformama, poput broja poruka u forumima ili na društvenim mrežama (npr. Twitter).
5. Vremenski podaci – vrijeme utrošeno na pojedine zadatke, uključujući pregledavanje resursa, rješavanje zadataka ili rješavanje ispita.
6. Psihološki podaci – informacije o emocionalnom stanju učenika, dobivene analizom interakcija ili drugih relevantnih pokazatelja.
7. Povijesni podaci – informacije o prethodnim postignućima i ponašanjima učenika, koje se često koriste za izradu prediktivnih modela, primjerice podaci o uspjehu u prethodnim razredima ili ispitima.

Analizirani su korisnici sustava LAD-ova, pri čemu su korisnici kategorizirani u dvije skupine: učenici i nastavnici. Tip povratne informacije razvrstan je u tri kategorije: obavijesti, vizualizacije i tekstualni prikazi. S obzirom na to da LA često koristi napredne metode analize podataka, istraživanje je obuhvatilo i primjenu prediktivne analitike (PA). Analizirano je u kojoj mjeri se PA koristi unutar LAD-ova i koje algoritme koristi za isto.

S tehničkog aspekta, LAD alati nisu novost, no ključno je pitanje njihove prihvaćenosti među učenicima i nastavnicima te stvarnog utjecaja na proces učenja i poučavanja. Iako većina LAD-ova uključuje fazu prezentacije podataka, Verbert, Duval, i ostali (2013) ističu da je ključno razumjeti njihovu primjenu u procesu učenja i poučavanja, posebno u kontekstu promjene ponašanja. Stoga je analiza usmjerana na vrednovanje ključnih nalaza vezanih uz korištenje ovih alata iz perspektive učenika i nastavnika. U ovom dijelu analizirani su empirijski dokazi o korištenju LAD-ova, uključujući istraživanja koja su primjenom eksperimentalnih metoda ispitivala utjecaj LAD-ova na proces učenja i poučavanja.

3.2.1. REZULTATI

Analiza publikacija uključenih u sustavni pregled literature nalazi se u Prilogu A, dok u nastavku rada prikazujemo ključne usporedbe i rezultate. Primjerice, ciljevi razvoja LAD-ova obrađeni su u Prilogu A2, dok se u Prilogu A3 nalazi pregled primjene PA. Napominjemo da se, zbog sažetosti, iduće potpoglavlje temelji na frekvencijama publikacija iz pregleda literature, uzimajući u obzir sve publikacije uključene u analizu.

3.2.1.1. CILJEVI RAZVOJA LAD-OVA

Pregledom literature identificirali smo 11 ciljeva razvoja LAD-ova. Pritom, jedan alat može ostvarivati više ciljeva, ovisno o njegovoj namjeni. Tablica 5 prikazuje distribuciju identificiranih ciljeva razvoja LAD-ova.

Tablica 5 Ciljevi razvoja LAD-ova

Identificirani cilj	Broj publikacija	Postotak
Praćenje i podrška	39	38,61%
Vizualizacija	20	19,80%
Metakognitivno poimanje	20	19,80%
Predviđanje	15	14,85%
Analiza	15	14,85%
Personalizacija	7	6,93%
Detekcija /identifikacija	6	5,94%
Komunikacija i dijalog	3	2,97%
Grupiranje	2	1,98%
Usporedba	2	1,98%
Analitika u radnom okruženju	1	0,99%

Najveći broj ciljeva razvoja (N=39, 38,61%) odnosi se na kategoriju „Praćenje i podrška“. Praćenje se odnosi na dimenziju koja obuhvaća proces učenja i poučavanja. Uključuje praćenje učenikova angažmana, korištenja LMS-a, prisutnosti, aktivnosti, emocija te podataka s društvenih mreža. Podrška je usmjerena na proces donošenja odluka. Primarno olakšava nastavnicima, a zatim i učenicima, donošenje odluka koje podržavaju učenje i poboljšavaju izvedbu tijekom procesa učenja.

Vizualizacija je drugi najčešće spominjani cilj razvoja, naveden u 20 publikacija (19,80%). Povratna informacija u vidu vizualizacije ima pozitivan utjecaj kako na učenike, tako i na nastavnike. Statistički podaci u obliku tablica i izvještaja nisu uvijek jednostavni za razumijevanje korisnicima obrazovnog sustava. Vizualizacije imaju za cilj podržati praćenje aktivnosti učenika te donošenje odluka učenika i nastavnika unutar obrazovnog sustava. Budući da svi sudionici imaju različite potrebe i sposobnosti, teško je jednom vizualizacijom obuhvatiti sve probleme. Vizualizacija može pomoći učenicima u postizanju obrazovnih ciljeva, podržavajući njihovo promišljanje i donošenje odluka. Prepoznajući snagu vizualnog predstavljanja, tradicionalni izvještaji temeljeni na tablicama podataka sve se više zamjenjuju LAD-ovima koji grafički prikazuju različite pokazatelje performansi.

Iako se većina povratnih informacija temelji samo na pokazateljima uspješnosti učenika, djelotvorne povratne informacije trebaju se temeljiti i na regulatornim mehanizmima na kojima počivaju procesi učenja te na svjesnosti učenika o ciljevima učenja (Sedrakyan i ostali, 2018). Metakognitivno poimanje je treći najčešće spominjani cilj razvoja, identificiran u 20 radova (19,80%), a obuhvaća nekoliko kategorija:

- poticanje refleksije učenika o njihovom uspjehu,
- samosvijest o napretku i učenikovu stanju,
- samoregulacija kao analiza i procjena vlastitih aktivnosti,
- povećanje motivacije kao cilj analitičkih alata,
- podrška metakognitivnim strategijama.

U ovom pregledu, 15 (14.85%) radova navelo je predviđanje kao jedan od ciljeva razvoja LAD-a. Analizu je kao cilj navelo 15 (14,85%) radova. U okviru analize, autori se bave analizom podataka s foruma, podataka o ponašanju, aktivnostima i uspjehu učenika, te analizom laboratorijskih vježbi. Ispitivanjem načina na koji učenici koriste LMS i analizom njihovih uspjeha, nastavnici mogu otkriti obrazce i donositi bolje odluke o budućem dizajnu nastavnih aktivnosti. Ostali ciljevi odnose se na personalizaciju (N=7, 6,93 %), detekciju ili identifikaciju učenika (N=6, 5,94 %), komunikaciju i dijalog (N=3, 2,97 %), grupiranje učenika temeljem kognitivnog stila i aktivnosti (N=2, 1,98 %), usporedbu (N=2, 1,98 %) te analitiku u radnom okruženju (N=1, 0,99 %).

3.2.1.2. KORIŠTENE VRSTE PODATAKA U LAD-OVIMA

U ovom pregledu identificirane su različite vrste podataka koje se prate u LAD-ovima. U četiri rada nije jasno navedeno koji su konkretni podaci korišteni, stoga su rezultati prikazani na temelju radova u kojima su podaci jasno opisani. Tablica 6 prikazuje podatke korištene u literaturi.

Tablica 6 Vrste podataka korištenih u pregledu prema učestalosti

Vrsta podataka	Broj publikacija	Postotak
Korištenje nastavnih materijala i postignuća	84	86,60%
Vremenski podaci	79	81,44%
Podaci zapisa aktivnosti učenika	74	76,29%
Statični podaci	67	69,07%
Podaci društvenih mreža	43	44,33%
Povijesni podaci	19	19,59%
Psihološki podaci	7	7,21%

U najvećoj mjeri koriste se podaci o korištenju nastavnog materijala i postignuća učenika (N=84, 86,60 %), zatim vremenski podaci (N=79, 81,44 %) te podaci zapisa o aktivnostima učenika na predmetu (N=74, 76,29 %). Statični podaci pojavljuju se u (N=67, 69,07 %) publikacija, podaci društvenih mreža u (N=43, 44,33 %), dok su povijesni podaci (N=19, 19,59 %) i psihološki podaci (N=7, 7,21 %) najmanje zastupljeni.

3.2.1.3. KORISNICI LAD-OVA

Dva rada nisu navela korisnike alata, stoga su rezultati prikazani na temelju onih koji su ih jasno identificirali. Analiza korisnika LAD-ova prikazana je u Tablica 7.

Tablica 7 Analiza korisnika LAD-ova prema vrsti

Korisnici	Broj publikacija	Postotak
Nastavnici	42	42,42%
Nastavnici i učenici	31	31,31%
Učenici	26	26,26%

Prema rezultatima analize, 42 LAD-ova (N=42, 42,42 %) prvenstveno su dizajnirana za izvještavanje nastavnika. Dodatnih 26 alata (26,26 %) usmjereno je isključivo učenicima, dok 31 LAD (31,31 %) uključuje i nastavnike i učenike kao krajnje korisnike alata.

3.2.1.4. POVRATNA INFORMACIJA

U ovom pregledu definirali smo obavijesti, vizualizaciju i tekst kao različite tipove prezentacije povratnih informacija. Broj i postotak korištenja obavijesti, vizualizacija ili tekst u svrhu povratne informacije prikazani su u Tablica 8.

Tablica 8 Tipovi povratnih informacija korišteni u LAD-ovima

Vrsta povratne informacije	Broj publikacija	Postotak
Vizualizacija	90	89,11%
Tekst	65	64,35%
Obavijest	40	39,61%

Vizualizacija se kao sredstvo prikazivanja povratne informacije koristi najčešće (N=90, 89,11%). Tekst kao sredstvo prikazivanja povratne informacije koristi 65 LAD-ova (64,35%). Prezentacija teksta kao povratne informacije najčešće se odvija kroz tablice. Tekst u tablici prikazuje rezultate testa, najčešće korištene sadržaje, statistiku učenika i slično. Također, omogućeno je preuzimanje podataka u različitim formatima (npr. CSV).

Obavijest, kao povratna informacija, se koristi u 40 LAD-ova, što čini 39,61% svih analiziranih LAD-ova. Radi se o personaliziranim porukama koje pružaju informacije o postignućima i najčešće su temeljene na analizi aktivnosti učenika. Također, obavijesti mogu biti računalno generirane, što većina učenika smatra osobnom komunikacijom s nastavnikom. Cilj obavijesti je motivirati i usmjeriti učenike na razmišljanje o vlastitom napretku. Drugi tip obavijesti čine preporuke sustava, koji se dijele na preporuke sadržaja i strategija. Preporuke sustava temelje se na učenikovim postignućima i služe kao vodič za nastavak procesa učenja s ciljem poboljšanja uspjeha (Ruipérez-Valiente i ostali, 2015).

3.2.1.5. KORIŠTENJE PREDIKTIVNE ANALITIKE U LAD-OVIMA

U okviru analize korištenja PA, identificirano je ukupno 19 radova koji primjenjuju različite tehnike PA u LAD-ovima (N = 19, 18,81%). Šest radova spominje korištenje PA u LAD-ovima, ali ne definiraju jasno tehnike, algoritme, niti ciljeve njezine primjene. Stoga se analiza temelji na preostalih 13 publikacija, s fokusom na primijenjene tehnike i postignute rezultate predviđanja uspjeha učenika.

Anh i ostali (2018) primijenili su tehniku regresije kako bi predvidjeli uspjeh učenika. Njihov model predviđanja temeljen je na algoritmu linearne regresije. Hussain i ostali (2018) koristili su tehniku klasifikacije za predviđanje aktivnih i neaktivnih učenika. U istraživanju su primijenili FURIA algoritam. Cobos & Olmos Camarena (2018) usredotočili su se na izgradnju modela predviđanja za prepoznavanje učenika sklonih odustajanju i predviđanje onih koji će uspješno završiti predmet. Bayesian Generalized Linear Model algoritam pokazao se kao najuspješniji za predviđanje odustajanja, dok su Boosting algoritmi i NB algoritam bili najučinkovitiji za predviđanje završetka predmeta. Azcona i ostali (2018) koristili su tehniku klasifikacije kako bi predvidjeli uspjeh učenika. U istraživanju su testirani različiti algoritmi, a rezultati su pokazali da za svaki predmet najbolju točnost postiže drugačiji model. Autori ovu nekonzistentnost objašnjavaju razlikama u sadržaju, težini gradiva i angažmanu učenika među predmetima. Ovo otkriće ukazuje na izazov u razvoju univerzalnog modela koji bi bio učinkovit za sve predmete i sve učenike.

Arnold & Pistilli (2012) razvili su model predviđanja rizičnih skupina učenika. Njihov sustav koristi signalizaciju putem boja na početnoj stranici predmeta: crveno označava veliku vjerojatnost neuspjeha, žuto ukazuje na potencijalni rizik, dok zeleno predstavlja veliku vjerojatnost uspjeha. De Quincey i ostali (2019) primijenili su DT za predviđanje uspjeha učenika. Njihov LAD omogućava predviđanja u tjednim intervalima, pružajući tako kontinuirani uvid u uspjeh učenika. Jovanovic i ostali (2012) koristili su tehniku klasifikacije za predviđanje uspjeha učenika. Njihovo istraživanje uključilo je osam različitih algoritama, pri čemu su ANN i Boosting algoritam postigli najbolje rezultate. Akçapınar & Bayazit (2019) razvili su klasifikacijski model s ciljem predviđanja uspjeha učenika koristeći podatke o interakciji učenika s LMS-om. Cechinel i ostali (2021) koristili su Boosting algoritme za rano otkrivanje rizika odustajanja. Hasnine i ostali (2023) primijenili su Perspective-n-Point algoritam za predviđanje angažmana studenata na temelju afektivnog stanja. Susnjak i ostali (2022) koriste bosting algoritam za predviđanje rizika odustajanja. Ramaswami i ostali (2023)

koriste Boosting algoritme, KNN, NB, LogR i RF u identifikaciji rizičnih studenata. Kaur & Chahal (2024) koriste RF, SVM, KNN, Boosting i DT algoritme za predviđanje uspjeha studenata.

3.2.1.6. VREDNOVANJE LAD-OVA

U okviru analize vrednovanja identificirano je 68 radova (67,32%) koji vrednuju LAD-ove iz perspektive učenika i/ili nastavnika. U analiziranim radovima primijenjena su tri pristupa vrednovanja: (1) istraživanja usmjerena na subjektivne procjene utjecaja LAD-a na proces učenja i poučavanja, (2) istraživanja usmjerena na ispitivanje utjecaja primjene LAD-a koristeći eksperimentalne studije (istraživački dizajn u kojem istraživač sustavno manipulira jednom ili više nezavisnih varijabli s ciljem promatranja njihovog utjecaja na zavisne varijable), te (3) analiza podataka o načinu kako korisnici koriste LAD. Napominjemo da su nekim od tih radova vrednovanja provedena zasebno za učenike i nastavnike, što rezultira višim ukupnim brojem vrednovanja. Rezultate ove analize prikazujemo prema korištenim pristupima i ključnim nalazima.

SUBJEKTIVNE PROCJENE UTJECAJA LAD-A NA UČENJE

U okviru prvog pristupa, autori su istraživali subjektivne procjene utjecaja LAD-a na proces učenja i poučavanja (N = 74, 74,74 %). Budući da su u nekim radovima LAD-ovi vrednovani pojedinačno, sa učenicima i nastavnicima broj istraživanja provedenih na učenicima nešto je veći (N = 38, 55,88%) u odnosu na istraživanja usmjerena na nastavnike (N = 36, 52,94%).

Pokazalo se da su upitnici najčešće primijenjena tehnika prikupljanja podataka (N = 49, 72,05%). Među standardiziranim upitnicima najčešće se koristio SUS (eng. System Usability Scale) (N = 13, 19,11%), dok je upitnik o korisničkom iskustvu (engl. User Experience Questionnaire, UEQ) primijenjen u dva istraživanja (N = 2, 2,94%), a CSUQ (engl. Computer System Usability Questionnaire) i EFLA (engl. Evaluation Framework for Learning Analytics) korišteni su po jednom (N = 1, 1,47%).

Ostali autori razvili su vlastite upitnike ili su, kao u slučaju R. Bodily i ostali (2018) koristili upitnike iz prethodnih istraživanja [npr. (Verbert, Duval, i ostali, 2013), (Verbert, Govaerts, i ostali, 2013), (Park & Jo, 2015),], prvenstveno za procjenu korisnosti i promjena u ponašanju tijekom korištenja LAD-a. Za dodatne subjektivne mjere, autori koriste intervju kao tehniku prikupljanja podataka (N=19, 27,94%), diskusije u fokus grupama (engl. focus group

discussions, FGD) (N = 5, 7,35%) te metodu razmišljanja naglas (engl. think-aloud, thinking aloud) (N = 4, 5,88%). Većina publikacija pokazuje da učenici percipiraju LAD kao korisne alate za učenje, iako postoje ograničenja vezana uz motivaciju i dugoročnu angažiranost.

Moreno-Marcos i ostali (2018), Naranjo Delgado i ostali (2019) te Guenaga i ostali (2015) navode kako učenici smatraju LAD-ove korisnima u procesu učenja. R. Bodily i ostali (2018) izvještavaju da velik broj (79 %) studenata LAD doživljava intuitivnima i zanimljivima, dok Aljohani & Davis (2013) navode da čak 84 % studenata ocjenjuje korisnim LAD. Santos i ostali (2012) ističu da učenici često nisu motivirani za njihovu kontinuiranu upotrebu. Choi i ostali (2023) ukazuju na potencijal LAD-ova u poticanju aktivnijeg sudjelovanja u učenju. Millecamp i ostali (2018) naglašavaju da LAD-ovi pružaju jasan pregled akademskog puta studenata i doprinose njihovoj samorefleksiji u procesu učenja.

Istraživanja usmjerena na nastavnike ističu LAD-ove kao korisne alate za praćenje napretka učenika, ali i naglašavaju izazove u njihovoj praktičnoj primjeni. Nastavnici ih prepoznaju kao podršku u donošenju pedagoških odluka i identifikaciji rizičnih studenata. Tervakari i ostali (2014); Martinez-Maldonado i ostali (2015). van der Stappen (2018) ističe da LAD omogućava pravovremene uvide u proces učenja, dok Rodríguez Groba i ostali, (2014) preporučuju njihovu širu primjenu. Nadalje, Govaerts i ostali (2012) navode da LAD-ovi pomažu nastavnicima u praćenju angažmana studenata i olakšavaju donošenje odluka u nastavi.

Unatoč prepoznatim prednostima, postoje značajni izazovi u interpretaciji podataka, kao i u etičkoj i tehničkoj integraciji LAD-ova u obrazovne sustave. Bayer i ostali (2024) naglašavaju potrebu za osiguravanjem jednakosti i inkluzije u visokom obrazovanju prilikom implementacije LAD-ova. C. Wang i ostali (2024) potvrđuju da nastavnici pozitivno ocjenjuju LAD-ove u smislu korisnosti i jednostavnosti korištenja, no naglašavaju potrebu za jasnijim smjernicama za njihovu učinkovitu primjenu.

ISPITIVANJE UTJECAJA LAD-A

U drugom pristupu, neke publikacije (N=5, 7,35%) usmjerile su istraživanja na utjecaj LAD-ova na učenike ili nastavnike tijekom procesa učenja i poučavanja, koristeći statističke analize za kvantificiranje učinka. Park & Jo (2015) ispitivali su utjecaj LADa na akademska postignuća, pri čemu su učenici u eksperimentalnoj skupini ostvarili nešto bolje rezultate, ali bez statistički značajne razlike. Valle i ostali (2021) također navode da nije bilo značajnih razlika između skupina u pogledu konačnih rezultata na ispitima. Aljohani i ostali (2018) utvrdili su značajno

veći angažman učenika koji su koristili LAD u odnosu na kontrolnu skupinu, dok su Jayashanka i ostali (2022) zaključili da LADovi poboljšavaju interakciju i akademske rezultate studenata jer su učenici u eksperimentalnoj skupini znatno češće pristupali online resursima te su ostvarili više ocjene na završnom ispitu. Nadalje, 94 % studenata ocijenilo je vizualizacije korisnima za motivaciju, identifikaciju slabih područja i praćenje napretka, čime se potvrđuje njihov doprinos samoreguliranom učenju.

Dokaz o utjecaju LAD-ova na nastavnike pruža Bao i ostali (2021), pokazujući da su nastavnici iz eksperimentalne skupine imali značajno veći fokus na pružanje pozitivnih povratnih informacija i individualiziran pristup, što ukazuje na to da LADovi omogućavaju pravovremenu podršku učenju.

ANALIZA INTERAKCIJA KORISNIKA S LAD-OM

U trećem pristupu, 18 publikacija analiziralo je interakcije korisnika s LAD alatima (26,47%), primjenjujući različite metrike, uključujući broj klikova, trajanje sesija i broj pregledanih stranica. Od ukupnog broja publikacija, 16 (23,53%) ih se fokusiralo na učenike, dok su 2 (2,94%) publikacije istraživale interakcije nastavnika s LAD-ovima.

Rezultati pokazuju značajnu varijabilnost u angažmanu studenata prilikom korištenja LAD-ova. Moreno-Marcos i ostali (2018) utvrdili su da, iako je početna aktivnost studenata na zadovoljavajućoj razini, ona postupno opada. Slično, Ramaswami i ostali (2023) pokazali su da se povećana razina angažmana održava samo tijekom prvih 15 dana korištenja, nakon čega dolazi do smanjenja interakcije sa alatom. Ruiz i ostali (2016) identificirali su porast pozitivnog utjecaja LAD-a na ponašanje studenata, pri čemu se udio studenata koji su smatrali LAD korisnim povećao s 55 % na 73 % nakon duljeg korištenja. Nadalje, Arnold & Pistilli (2012) povezali su implementaciju LAD-a s povećanjem broja viših ocjena i smanjenjem broja nižih ocjena. Eickholt i ostali (2022) dodatno su utvrdili da učenici koji redovito koriste LAD ostvaruju statistički značajno bolje prosječne ocjene u odnosu na učenike koji ga ne koriste. De Quincey i ostali (2019) tvrde da je angažiranost studenata poboljšana u odnosu na prethodne generacije, no korištenje LAD-a i dalje je bilo nisko u nekim predmetima. Duan i ostali (2022) navode da postoji statistički značajna korelacija između učestalosti korištenja LAD-a i poboljšanog ponašanja (ranija predaja zadataka) što potvrđuje pozitivan utjecaj LAD-ova.

Seidel i ostali (2024) te Kia i ostali (2020) pokazuju da učenici najčešće koriste LAD za praćenje napretka, uključujući vizualizacije napretka i distribucije ocjena. Kia i ostali (2020) također su identificirali različite obrasce korištenja među učenicima. Učenici s nižim akademskim uspjehom češće pregledavaju informacije o pristupu nastavnim materijalima i distribuciji ocjena, dok visoko samoregulirani učenici kombiniraju te funkcionalnosti s alatima za planiranje i organizaciju zadataka.

Međutim, određene studije ukazale su na prepreke u korištenju LAD-ova. Owatari i ostali (2020) naglasili su potrebu za implementacijom obavijesti u stvarnom vremenu i personaliziranih preporuka kako bi se povećala korisnost alat. Haynes-Magyar (2020) ističu da učenici preferiraju jednostavne i intuitivne vizualizacije u odnosu na složene prikaze, sugerirajući potrebu za optimizacijom korisničkog sučelja LAD-a.

Analiza interakcija nastavnika s LAD-om pokazuje da LAD-ovi imaju potencijalnu primjenu u identifikaciji rizičnih studenata i poboljšanju nastavnog procesa, ali i da postoje izazovi u njihovoj dosljednoj upotrebi. Herodotou i ostali (2017) utvrdili su da su nastavnici generalno zainteresirani za korištenje LAD-ova, posebno u kontekstu prepoznavanja studenata s povećanim rizikom od neuspjeha. Međutim, istraživanje je također pokazalo varijabilnost u učestalosti korištenja LAD-ova, pri čemu su razlike ovisile o specifičnostima nastavnog predmeta, što upućuje na neujednačenu primjenu alata u praksi.

van Leeuwen & Rummel (2020) istražili su utjecaj LAD-ova na nastavničke odluke te utvrdili da alati koji nude vizualne i tekstualne povratne informacije poboljšavaju sposobnost nastavnika u detekciji problematičnih skupina studenata. Dodatno, korištenje LAD-ova smanjilo je kognitivno opterećenje nastavnika te povećalo njihovo samopouzdanje u procesu donošenja pedagoških odluka.

3.3. OSVRT NA REZULTATE SUSTAVNOG PREGLEDA LITERATURE

Prema rezultatima, ciljevi razvoja LAD-ova primarno se usmjeravaju na praćenje i podršku tokom procesa učenja i poučavanja, vizualizaciju podataka, metakognitivno poimanje, a potom i na predviđanje i analizu. Korišteni podaci najčešće uključuju informacije o korištenju nastavnih materijala i postignućima učenika, vremenske podatke te podatke o zapisima aktivnosti učenika na predmetu. Siemens (2013) kao najveći problem ističe poznavanje opsega i kvalitete podataka. Prema njemu, jedno od pitanja LA jest koliko podataka treba prikupiti i koliko različiti ti podaci trebaju biti. Ova pitanja se odnose na opseg podataka. Kvaliteta podataka, odnosi se na pouzdanost podataka. Učenje predstavlja složen proces u kojem moramo uzeti u obzir mnoge varijable, stoga možemo zaključiti kako brojenje klikova mišem nije dovoljno (Fincham i ostali, 2019). Ukratko, ne postoji konsenzus o tome koji su podaci o ponašanju i interakcijama korisnika prikladni za mjerenje, razumijevanje i modeliranje procesa učenja, poučavanja i testiranja znanja, kao i njegovog učinka. Gasevic i ostali (2016) navode kako LA modeli ne mogu odgovarati svima jednako i kao takvi ne mogu prikupljati opće podatke. Stoga bi se trebalo fokusirati na određene opsege visoke kvalitete podataka kako bi se bolje razumio proces učenja i poučavanja. Većina LAD-ova dizajnirana je za nastavnike kao korisnike, što je u skladu sa nalazima Schwendimann i ostali (2016).

Povratna informacija ima ključnu ulogu u korištenju LAD-ova za proces učenja i poučavanja, jer LA nastoji poboljšati procese učenja kroz prikupljanje i mjerenje podataka povezanih s učenjem, te pružiti povratne informacije učenicima i nastavnicima (Rienties i ostali, 2015; Siemens, 2013). Povratne informacije koje se pružaju putem LAD-a omogućuju učenicima uvid u njihovu uspješnost, angažman u aktivnostima učenja, te ocjenjivanje (Corrin & de Barba, 2014). Pružanje povratne informacije definira se kao proces u kojem učenici koriste informacije iz različitih izvora kako bi stvorili svijest o svom učenju i unaprijedili kvalitetu ili strategije vlastitog učenja (Carless & Boud, 2018) prema (Boud & Molloy, 2012). Ova definicija nadilazi ideje o povratnoj informaciji koja se temelji samo na ocjenama, jer stavlja središnju ulogu učenika u stvaranju svijesti potrebne za unapređenje učenja.

U svakom trenutku treba imati na umu kako su iskustva učenika sa povratnim informacijama individualna i sklona promjenama. Verbert, Duval, i ostali (2013) navode da povratna informacija mora biti djelotvorna i pravovremena kako bi imala željeni učinak, što potvrđuju Owatari i ostali (2020). Pokazalo se da pravovremena isporuka povratne informacije učinkovito utječe na učenikov proces učenja (Irons & Elkington, 2021). Konačni cilj LAD-a je regulirati

proces učenja i poučavanja pružanjem povratnih informacija o saznanjima tijekom samog procesa. Vizualizacija podataka predstavlja najčešće korištenu kategoriju povratnih informacija u LAD-ovima, dok se uz vizualizacije koriste i tekstualne povratne informacije te obavijesti.

Na temelju provedenih analiza korištenja PA u LAD-ovima, utvrđeno je da relativno mali broj LAD-ova koristi PA, što je u skladu s nalazima Ramaswami i ostali (2022). S obzirom na sveprisutnost strojnog učenja danas, pomalo je iznenađujuće da se PA nije pojavila u većem postotku pregledanih LAD-ova. Moguće objašnjenje je da su istraživači još uvijek fokusirani na istraživanja deskriptivne analitike i vrednovanje LAD-ova, jer, većinom su LAD-ovi usmjereni, kako je prethodno napisano, na praćenje i podršku. Različite tehnike i algoritmi pružaju specifične uvide u predviđanje uspjeha učenika. Premda ti modeli pokazuju varijabilne točnosti predviđanja, zajednički zaključak je da nijedan algoritam nije univerzalno primjenjiv za sve učenike i sve predmete. Mnogi faktori utječu na proces učenja, stoga se postavlja pitanje koje značajke uzeti u obzir pri predviđanju, a s time se mora razmotriti i u kojim uvjetima predviđanje ima smisla. Essa & Ayad (2012) sugeriraju kako ne možemo jednostavno pretpostaviti da će model predviđanja razvijen za jednu grupu učenika i obrazovnu instituciju imati istu vrijednost za drugu grupu učenika u drugoj obrazovnoj instituciji. Ovo ukazuje na potrebu za razvojem prilagođenih i dinamičnih modela koji će uvažavati specifičnosti konteksta učenja i raznolikost učenika.

Analiza vrednovanja LAD-ova pokazuje da učenici uglavnom percipiraju LAD-ove kao korisne alate koji doprinose samorefleksiji i praćenju napretka, no dugoročna angažiranost opada nakon početnog razdoblja, stoga su rezultati našeg pregleda literature u skladu sa Kaliisa i ostali (2024). Eksperimentalna istraživanja ukazala su na različite učinke na akademska postignuća. Dok neke studije ne nalaze statistički značajne razlike, druge ukazuju na pozitivne promjene u ponašanju i ocjenama. Dodatno, analiza interakcija naglašava važnost prilagodbe funkcionalnosti LAD-a, jer učenici preferiraju alate za praćenje napretka. Za nastavnike, LAD olakšava prepoznavanje rizičnih studenata, no njihova dosljedna primjena ovisi o specifičnostima nastavnog predmeta. Ukupno gledano, vrednovanje LAD-ova potvrđuje njihov potencijal u podršci procesu učenja, ali i identificira potrebe za daljnjim unaprjeđenjima, posebno u području dugoročne motivacije i prilagodljivosti.

Unatoč značajnom doprinosu dosadašnjih istraživanja, u literaturi nedostaju jasno definirani alati koji bi omogućili vizualizaciju stupnja postignutosti ishoda učenja na način koji bi bio neposredno primjenjiv za unaprjeđenje procesa učenja i poučavanja. Vizualizacija stupnja

postignutosti ishoda učenja je identificirana u radu (Buvari i ostali, 2023). Ova disertacija je usmjerena na razvoj LAD-a koji će omogućiti vizualizaciju stupnja postignutosti ishoda učenja, pružajući nastavnicima informacije koje im mogu pomoći u oblikovanju ili prilagodbi modela poučavanja specifičnim potrebama učenika.

Osim toga, važnost integracije PA u ovakvim alatima, osobito u kontekstu predmeta s visokim stopama odustajanja, poput predmeta usko vezanih za učenje i poučavanje programiranja. PA može pomoći u prepoznavanju učenika koji imaju veći rizik od poteškoća, te na temelju toga omogućiti pravovremene intervencije.

U kombinaciji s vizualizacijom stupnja postignutosti ishoda učenja, ovi alati mogu pružiti nastavnicima ne samo uvid u trenutni uspjeh učenika, već i smjernice za optimizaciju strategija poučavanja, dok učenicima omogućuju praćenje napretka i poticanje samorefleksije. Stoga je nastavak disertacije usmjeren na izradu LAD-a za učenike i nastavnike koji će koristiti podatke Moodle LMS-a, tijekom poučavanja, pružajući povratnu informaciju u realnom vremenu te stavljajući naglasak na ishode učenja i prediktivnu analitiku (PA).

4. NADZORNA PLOČA ANALITIKE UČENJA ZA UČENIKE I NASTAVNIKE

U prethodnom poglavlju analizirani su LAD-ovi pri čemu su detaljno razmotreni njihovi ključni aspekti, uključujući ciljeve razvoja, vrste podataka koji se koriste, korisničke skupine, povratne informacije, primjenu prediktivne analitike (PA) i rezultate vrednovanja. Na temelju stečenih uvida iz analiziranih radova, u ovom poglavlju predlažemo vlastiti konceptualni dizajn LAD-a, prilagođen potrebama učenika i nastavnika.

Ciljevi razvoja LAD-ova u kontekstu ove disertacije uključuju praćenje i podršku, vizualizaciju te predviđanje. Praćenje i podrška odnose se na nadzor aktivnosti i uspjeha učenika, omogućujući nastavnicima i učenicima pravovremenu intervenciju. Vizualizacija se koristi za intuitivno prikazivanje podataka, čime se olakšava njihovo razumijevanje, osobito u kontekstu praćenja ishoda učenja. Predviđanje podrazumijeva razvoj modela koji će biti detaljno razrađeni u idućem poglavlju.

Korisnici LAD-a su nastavnici i učenici, a vrste korištenih podataka bit će objašnjene u nastavku ovog poglavlja, pri opisu povratnih informacija prikazanih unutar LAD-ova. Iako je u analizi povratnih informacija načinjena kategorizacija prema vizualizaciji, obavijestima i tekstu, u daljnjem tekstu koristi se termin povratna informacija kao opći pojam, budući da granice između tih kategorija ponekad nisu jasno definirane.

Jedan od najvažnijih alata za podršku online poučavanju u Republici Hrvatskoj jest Moodle LMS, pod upravom Sveučilišnog računskog centra (SRCA). Moodle LMS široko je prihvaćen u hrvatskim obrazovnim institucijama, uključujući Sveučilište u Splitu koje koristi standardnu verziju Moodle LMS-a, dok se na Sveučilištu u Zadru koristi njegova prilagođena inačica Merlin.

4.1. IMPLEMENTACIJA LAD-OVA U MOODLE LMS

Implementacija LAD-ova unutar Moodle LMS-a odabrana je iz dva ključna razloga:

- Široka primjena: Moodle je najzastupljeniji sustav za e-učenje u Hrvatskoj, čime je osigurana njegova dostupnost korisnicima iz različitih obrazovnih institucija.
- Modularnost: Moodle omogućuje proširivanje funkcionalnosti putem dodataka (engl. plugins), koji omogućuju prilagodbu sustava specifičnim potrebama korisnika

Moodle dodaci predstavljaju ekstenzije ili proširenja koje omogućuju dodatne funkcionalnosti unutar Moodle LMS-a. Dodaci se razvijaju kao skup PHP skripti, a budući da je Moodle slobodan softver otvorenog koda, korisnici mogu sami razviti i koristiti vlastite dodatke. Iako je inicijalno razmatrana upotreba postojećih dodataka², niti jedna od njih nije zadovoljila zahtjeve za integracijom elemenata deskriptivne i prediktivne analitike. Stoga je razvijen vlastiti dodatak koji omogućuje učenicima i nastavnicima pristup povratnim informacijama unutar Moodle LMS-a. Dodatak je u potpunosti samostalno razvijen u okviru ove disertacije.

LAD je u ovoj disertaciji osmišljen kao alat koji zadovoljava potrebe učenika i nastavnika. U skladu s tim, definirana su dva modela nadzorne ploče:

- LAD-s (engl. Learning Analytics Dashboard for Students), model prilagođen učenicima.
- LAD-t (engl. Learning Analytics Dashboard for Teachers), model prilagođen nastavnicima

LAD-s i LAD-t mogu se integrirati u bilo koji predmet unutar Moodle LMS-a. Sve njihove komponente implementirane su u programskom jeziku PHP, dok su za razvoj korisničkog sučelja korištene tehnologije HTML, CSS i JavaScript. Dodatno, *komponenta predviđanja* uspjeha učenika koristi Python i biblioteku scikit-learn za integraciju algoritama strojnog učenja, temeljenih na analizi podataka učenika s Moodle LMS-om, tijekom procesa učenja i poučavanja. Na temelju ovih podataka, model klasificira predviđeni uspjeh učenika u jednu od tri kategorije:

² Više informacija o postojećim dodacima dostupno je na službenoj Moodle dokumentaciji: https://docs.moodle.org/33/en/Learning_analytics

- Dobar uspjeh,
- Prosječan uspjeh,
- Loš uspjeh.

Trenirani model predviđanja je lokalno razvijen, a potom integriran u LAD-s i LAD-t. Nakon implementacije, model se poziva iz LAD-ova i pruža povratnu informaciju o predviđenom uspjehu učenika. Modeli predviđanja korišteni u LAD-ovima temeljito su prikazani u potpoglavlju 5.3., gdje se analizira njihova točnost u predviđanju uspjeha učenika na temelju podataka iz Moodle LMS-a.

Dizajn LAD-s i LAD-t oslanja se na smjernice predstavljene u potpoglavlju 2.3.4. i koristi kombinaciju deskriptivne i prediktivne analitike.

4.1.1. PRISTUP I MANIPULACIJA PODACIMA

Za pristup i manipulaciju podacima unutar Moodle LMS-a, razvijeni dodatak koristi Moodle Data Manipulation API³. Ovaj API omogućava sigurnu i apstraktnu interakciju s bazom podataka, osiguravajući kompatibilnost s različitim relacijskim bazama podataka (engl. Relational Database Management Systems, RDBMS). Pristup podacima realiziran je korištenjem \$DB objekta, koji je instanca klase moodle_database i automatski se instancira tijekom pokretanja sustava.

S obzirom na to da se u povratnim informacijama predloženih dodataka koriste termini poput „aktivnosti“ i „provjera“, važno je na početku jasno definirati njihovo značenje. U ovom kontekstu, „aktivnosti“ se odnose na podatke o korištenju Moodle LMS-a, prikupljene putem zapisa o radnjama učenika unutar određenog predmeta. Ti se podaci automatski bilježe i pohranjuju u Moodleovu bazu podataka, konkretno u tablicu *mdl_logstore_standard_log*.

U skladu s definicijom iz poglavlja 2., uspjeh učenika u ovoj disertaciji obuhvaća sve akademske rezultate izražene ocjenama. Na LAD-ovima se prikazuju rezultati provjera (kvizovi, testovi, zadaci), koji predstavljaju konkretne komponente tog uspjeha. Podaci o tim metodama ocjenjivanja pohranjuju se u specifične tablice unutar Moodle baze podataka: *mdl_quiz* (kvizovi), *mdl_assign* (zadaci) i *mdl_grade_items* (ocjene i stavke ocjenjivanja). Ove

³ Moodle Developers. *Data Manipulation API*. MoodleDocs. Dostupno na: <https://moodledev.io/docs/5.0/apis/core/dml>

tablice omogućuju praćenje različitih vrsta procjena, što doprinosi cjelokupnoj analizi uspjeha učenika i omogućava praćenje njihovog napretka unutar Moodle LMS-a.

4.1.2. PRINCIPI PRIKAZA POVRATNIH INFORMACIJA

Potrebno je objasniti nekoliko ključnih odluka vezanih uz prikaz podataka unutar ovih nadzornih ploča analitike učenja. Naime, korištene su komponente koje se prvo prikazuju korisnicima (učenicima i nastavnicima), a zatim korisnici odabiru koje komponente žele koristiti u trenutku kada im to odgovara (Slika 11). Ovaj pristup je odabran iz dva glavna razloga:

1. Konzistentnost i preglednost LAD-a: Kako bi se osigurala intuitivnost i jednostavnost korištenja, količina prikazanih informacija na LAD-ovima je ograničena. Time se postiže da alati ostanu pregledni i konzistentni, bez suvišnih podataka koji bi mogli opterećivati korisnike.
2. Istraživanje načina korištenja LAD-ova: Prema R. Bodily & Verbert (2017), istraživanja o LAD-ovima trebaju uključivati detaljne analize načina na koji učenici koriste alate, kako bi se osiguralo dublje razumijevanje utjecaja i učinkovitosti tih sustava. Prezentiranjem povratnih informacija na ovaj način, u budućnosti bi se moglo detaljno istražiti koje povratne informacije najviše privlače njihovu pažnju.

Aktivnosti

Uspjeh

Predviđanje

Aktivnosti i postignuća

Ishodi učenja

Predviđanje

Slika 11 Odabir komponente unutar LAD-a (učenici lijevo, nastavnici desno)


Druga odluka koju je trebalo donijeti odnosi se na upotrebu boja. Kada god je to bilo moguće, koristili smo boje po uzoru na Arnold & Pistilli (2012). Crvena boja označava loš rezultat, žuta se koristi za prosječan rezultat, dok zelena boja označava dobar rezultat. Ovi rezultati mogu se odnositi na aktivnosti, zadovoljenje ishoda učenja ili rezultate predviđanja.

Treća odluka koja zahtijeva pojašnjenje odnosi se na način prikazivanja funkcionalnosti LAD-s i LAD-t u kontekstu ove disertacije, pri čemu se posebno ističe pitanje etičkih načela. Slade & Prinsloo (2013) te Swenson (2014) ističu da se primjena LA razvija brže nego što se

razmatraju etička pitanja vezana uz njezinu upotrebu. Iako se u ovoj disertaciji ne bavimo detaljnom analizom etičkih pitanja, za potrebe prikaza pojedinih dijelova LAD-s i LAD-t koristimo anonimne podatke. Naime, Moodle LMS omogućava anonimizaciju podataka putem integriranih funkcionalnosti koje uklanjaju osobne informacije i zamjenjuju ih generiranim identifikatorima (npr. umjesto imena, navodi se „anonfirstname11“).

4.1.3. MODELIRANJE LAD-OVA PREMA ISHODIMA

Prije nego što se detaljno opišu funkcionalnosti LAD-s i LAD-t, prikazat će se model oblikovanja LAD-ova temeljen na ishodima učenja (Slika 12). Taj model ujedno prikazuje međusobnu povezanost LAD-s i LAD-t. Svaki ishod učenja povezan je s nastavnim elementima kojima učenik pristupa tijekom nastave. Na ovaj način, LAD-s prikuplja podatke o aktivnosti i uspjehu, a učenik u svakom trenutku može imati uvid u vlastito ponašanje tijekom procesa učenja. Paralelno s tim, nastavnik evidentira postignuća povezana s određenim nastavnim elementima, čime se omogućuje napredno vrednovanje odgojno-obrazovnih ishoda primjenom analitike učenja u LAD-t. Nastavnik preko LAD-t ima uvid u ponašanje učenika tijekom procesa učenja i poučavanja s ciljem pravovremene intervencije.



Slika 12 Modeliranje LAD-ova prema ishodima


Alati LAD-s i LAD-t omogućuju pravovremeno prepoznavanje uspješnih i manje uspješnih učenika. Kada alat prepozna učenika s nižom razinom angažmana i negativnim predviđanjem uspjeha, smatramo da pravovremena i jasna povratna informacija može imati poticajan učinak. U tom slučaju, učenik postaje svjestan vlastitog stanja, što može dovesti do promjene ponašanja i aktivnijeg pristupa učenju. Učenicima koji bilježe visoku razinu aktivnosti i pozitivan

napredak, alat pruža potvrdu o uspješnosti, što može povećati samopouzdanje i doprinijeti osjećaju zadovoljstva. Takva personalizirana povratna informacija ima izraženu motivacijsku vrijednost i potiče kontinuitet u radu.

Nastavnicima je, putem LAD-t alata, omogućen detaljan uvid u ponašanje i napredovanje učenika, čime se osigurava utemeljena osnova za pedagoške odluke. U slučaju prepoznavanja učenika koji pokazuje znakove zaostajanja, nastavnik može pravovremeno intervenirati i pružiti dodatnu podršku. Istovremeno, kod učenika koji napreduju iznad očekivanja, nastavnik može uputiti pohvalu, čime se dodatno doprinosi pozitivnoj nastavnoj klimi i potiče daljnji razvoj kompetencija.

4.2. LAD-S

LAD-s sastoji se od tri glavne komponente: *komponente aktivnosti*, *komponente uspjeha* i *komponente predviđanja*, koje generiraju povratne informacije prikazane učenicima. Arhitekturu LAD-s prikazuje Slika 13.



Slika 13 Arhitektura LAD-s


LAD-s je implementiran kao plugin za Moodle LMS. Učenik interakcijom s predmetom generira aktivnosti koje se pohranjuju u bazu podataka. LAD-s komponente (aktivnosti, uspjeh, predviđanje) dohvaćaju podatke iz baze i učeniku pružaju povratne informacije. Dvosmjerna strelica između učenika i predmeta označava uzajamnu interakciju (učenik stvara aktivnosti, a

predmet omogućuje pristup sadržajima), dok jednosmjerne strelice između baze i komponenti predstavljaju dohvat podataka.

LAD-s koristi društvenu i vremensku usporedbu kao temeljne elemente za pružanje povratnih informacija učenicima. Društvena usporedba omogućuje prikaz aktivnosti ili uspjeha pojedinca u odnosu na grupu učenika, pri čemu se koriste statističke mjere poput medijana, prosjeka, minimalnih i maksimalnih vrijednosti. Vremenska usporedba prati promjene aktivnosti ili rezultata učenika kroz različite vremenske intervale tijekom trajanja predmeta.


4.2.1. KOMPONENTA AKTIVNOSTI

Za interpretaciju komponente aktivnosti razvijene su sljedeće povratne informacije: ukupne aktivnosti, aktivnosti u posljednjih sedam dana, korištenje sustava po tjednima i obavijest sustava. Ova povratna informacija pruža uvid u ukupan broj aktivnosti učenika u predmetu (Slika 14, lijevo). Osim osnovnog prikaza broja aktivnosti, ukupan broj aktivnosti omogućava društvenu usporedbu koja se prikazuje na slici (Slika 14, desno). Na ovaj način učenici mogu procijeniti vlastite aktivnosti u odnosu na ostale članove grupe.



Slika 14 Povratna informacija ukupnog broja aktivnosti


Druga povratna informacija odnosi se na aktivnosti u posljednjih sedam dana. Prikazuje se broj aktivnosti u posljednjih sedam dana za svakog učenika (Slika 15, lijevo) uz korištenje društvene usporedbe (Slika 15, desno).



Slika 15 Povratna informacija o broju aktivnosti u posljednjih sedam dana

Aktivnosti od početka predmeta i aktivnosti u posljednjem tjednu predstavljaju različita vremenska razdoblja. Stoga, ovaj tip povratne informacije omogućava vremensku usporedbu između ukupnog broja aktivnosti tijekom cijelog trajanja predmeta i aktivnosti u posljednjem tjednu.

Za analizu aktivnosti po tjednima, korišten je stupčasti grafikon koji prikazuje broj aktivnosti učenika po tjednima (Slika 16). Ova povratna informacija omogućava vremensku analizu angažmana učenika unutar cijelog procesa učenja i poučavanja (najčešće 15 tjedana u visokom obrazovanju), pružajući uvid u njihove tjedne aktivnosti.




Slika 16 Povratna informacija o korištenju sustava tijekom procesa učenja i poučavanja (prikaz broja aktivnosti učenika na predmetu).

Komponenta aktivnosti generira personalizirane obavijesti kako bi pružila povratne informacije o aktivnostima učenika. Obavijesti su oblikovane kao motivacijske poruke koje informiraju učenike o njihovom trenutnom napretku, ističući njihov trud ili sugerirajući potrebu za većim trudom. Za postizanje rezultata i pravilno određivanje odgovarajuće obavijesti, aktivnost učenika se klasificira kroz pragove definirane percentilima. Budući da sličan pristup nije pronađen u literaturi, pragovi su definirani kako bi se omogućilo slanje prilagođenih povratnih informacija:

- Jako niska aktivnost – Aktivnost ispod 21. percentila označava minimalan angažman, pri čemu učenik prima motivacijsku poruku: „Tvoj trud na predmetu je jako nizak. Potrudi se više molim te!“
- Niska aktivnost – Aktivnost između 22. i 44. percentila zahtijeva dodatni trud, s porukom: „Tvoj trud na predmetu je nizak. Potrudi se više molim te!“


- Prosječna aktivnost – Aktivnost između 45. i 64. percentila označava srednju razinu angažmana, uz poruku: „Tvoj trud na predmetu je prosječan. Potrudi se više molim te!“
- Visoka aktivnost – Aktivnost između 65. i 87. percentila ukazuje na višu razinu angažmana, s porukom: „Tvoj trud na predmetu je visok. Nastavi tako!“
- Jako visoka aktivnost – Aktivnost iznad 88. percentila označava izuzetno visoku razinu angažmana, pri čemu učenik prima pohvalnu poruku: „Tvoj trud na predmetu je izuzetan. Nastavi tako i sigurno ćeš uspjeti!“

Osim obavijesti, korišteni su i vizualni elementi s bojama, gdje zelena označava visoku i jako visoku aktivnost, žuta prosječnu i nisku aktivnost, te crvena jako nisku aktivnost. Slika 17 prikazuje primjer obavijesti za učenika čiji trud pokazuje izuzetno visoku aktivnost, uz pripadajuću zelenu boju koja simbolizira pozitivnu razinu aktivnosti.



Slika 17 Obavijest o aktivnosti učenika tijekom procesa učenja i poučavanja

Slika 18 prikazuje komponentu aktivnosti koja uključuje sve prethodno navedene elemente i kao takva se prikazuje učeniku.



Slika 18 Komponenta aktivnosti

4.2.2. KOMPONENTA USPJEHA

Za interpretaciju uspjeha razvijene su sljedeće povratne informacije: rezultati provjera, provjere koje dolaze, oblici sudjelovanja u procesu učenja i poučavanja te usporedba uspjeha. U nastavku prikazujemo svaku od navedenih povratnih informacija.

Povratna informacija o provjerama prikazana je na Slika 19, lijevo, gdje se vide ocjene učenika postignute na provjerama kojima su pristupili. Ova povratna informacija omogućuje analizu uspjeha učenika kroz različite oblike provjere znanja. Kako bi se omogućila društvena i vremenska usporedba, učenik može pristupiti detaljnoj analizi svog uspjeha. Klikom na Prikaži, otvara se prozor koji pruža dublju analizu uspjeha. Ova funkcionalnost omogućuje društvenu usporedbu prikazom rezultata u odnosu na uspjeh cijele grupe (Slika 19, desno). Osim toga, takva analiza omogućuje vremensku usporedbu jer prikazuje promjene u uspjehu kroz različite vremenske intervale. Budući da različite provjere znanja u Moodle LMS-u nose različit broj maksimalnih bodova, u ovom sustavu ne koristi se unaprijed definirana optimalna vrijednost uspjeha. Umjesto toga, učenicima se prikazuje broj osvojenih bodova uz maksimalan broj mogućih bodova za svaki pojedini ispit. Na taj način moguće je prikazati uspjeh bez obzira na vrstu i težinu provjere znanja, a učenici sami mogu interpretirati svoj rezultat.

REZULTATI PROVJERA				*Test 1 – Uvod u SQL	
Broj	Naziv	Moja Ocjena	Detalji	Moj rezultat : 6	
1	Test 1 – Uvod u SQL	6	Prikaži	Minimalna ocjena razreda : 6	
				Max ocjena razreda : 10	
				Prosječna ocjena razreda: 8.6	
				Medijan razreda : 8.5	
2	Test 2 – Osnovne naredbe u SQL	14	Prikaži		

Slika 19 Povratna informacija o uspjehu na provjerama

Povratna informacija pruža učenicima pregled nadolazećih provjera, omogućujući im bolju organizaciju učenja i pravilnu pripremu (Slika 20). Kroz prikaz nadolazećih provjera, učenici mogu postaviti ciljeve za učenje i učinkovito raspodijeliti svoje vrijeme. Stoga, može se reći da ova funkcionalnost potiče proaktivno upravljanje vlastitim učenjem, očekujući povećavanje učenikove odgovornosti i angažman u procesu učenja.

PROVJERE KOJE DOLAZE	
Naziv resursa	Max broj bodova
Test 8 – myplugin	7
Test 3 – SQL upiti nad Moodle bazom	6
Test 4 – PHP	9
Test 5 – PHP	13
Test 6 – PHP	13
Test 7 – PHP	10
Kolokvij	53

Slika 20 Povratna informacija o provjerama koje dolaze (prikazuje naziv svake provjere znanja te maksimalan broj bodova koji se može ostvariti)

Moodle LMS omogućuje različite oblike sudjelovanja u procesu učenja, uključujući slanje domaćih zadaća, pregledavanje resursa, rješavanje kvizova te druge oblike provjera znanja. Oblici sudjelovanja predstavljaju ključne elemente učenja koji se mjere i prate tijekom procesa učenja i poučavanja. Kako bi se prikazalo sudjelovanje koje učenici obavljaju, učenicima se prikazuje grafikon (Slika 21). Grafikon prikazuje broj predanih materijala, broj pregleda lekcija te broj završenih kvizova.




Slika 21 Povratna informacija o oblicima sudjelovanja u procesu učenja i poučavanja

Povratna informacija koja služi kao društvena usporedba omogućuje učenicima praćenje njihovih rezultata u odnosu na grupu. Cilj ove povratne informacije je prikazati opći uspjeh učenika u odnosu na prosječni uspjeh grupe. U tu svrhu, u LAD-s-u je razvijena funkcija koja prikuplja podatke o svim provjerama znanja kojima je učenik pristupio unutar predmeta. Funkcija izračunava ukupni uspjeh učenika na temelju zbroja ostvarenih ocjena u odnosu na maksimalno moguće ocjene svih provjera znanja. Povratna informacija postaje dostupna nakon prve provjere, kada se prikupe početni rezultati. Na taj način učenici dobivaju uvid u svoj položaj u grupi. Za prikaz rezultata korišten je grafik (Slika 22).


Usporedba uspjeha sa svim kolegama

PRIKAŽUJE NAKON PRVE PROVJERE



Slika 22 Povratna informacija o općem uspjehu učenika

Slika 23 prikazuje komponentu uspjeha koja uključuje sve prethodno navedene elemente i kao takva se prikazuje učeniku.




Slika 23 Komponenta uspjeha

4.2.3. KOMPONENTA PREDVIĐANJA

Primarni cilj komponente predviđanja jest omogućiti učenicima povratnu informaciju njihovog predviđenog uspjeha na temelju podataka prikupljenih tijekom procesa učenja i poučavanja u sustavu Moodle LMS. Detaljan opis ulaznih podataka, procesa treniranja i vrednovanja te izlaznih rezultata modela predviđanja prikazan je u potpoglavlju 5.3.

Prilikom pristupa komponenti predviđanja u LAD-s alatu, izvršava se Python skripta koja koristi joblib za učitavanje unaprijed treniranog modela strojnog učenja. Skripta očekuje ulazne značajke u JSON formatu, koje se pretvaraju u DataFrame, a zatim se nad modelom poziva metoda `predict()`. Dobivena klasifikacijska oznaka reflektira procijenjeni uspjeh učenika temeljen na njegovim najnovijim podacima.

Primjer povratne informacije o predviđanju uspjeha prikazuje Slika 24, gdje se prikazuje rezultat predviđanja za učenika s prosječnim uspjehom. Kao što je već prethodno naglašeno, boje se koriste za vizualnu reprezentaciju predviđenog uspjeha: zelenom bojom označava se dobar uspjeh, žutom prosječan uspjeh, a crvenom loš uspjeh. Budući da komponenta predviđanja prikazuje isključivo ovu povratnu informaciju, nije potrebno uključivati je u skupni prikaz, kao što je bio slučaj s prethodnim komponentama.




Slika 24 Povratna informacija o predviđenom uspjehu učenika

4.3. LAD-T

LAD-t omogućava praćenje napredovanja učenika, uvid u postignute ishode učenja, te pruža nastavnicima mogućnost za prilagodbu metoda poučavanja prema specifičnim potrebama učenika, unutar jednog predmeta. Uključivanje prediktivne analitike (PA), omogućuje prepoznavanje učenika koji su u većem riziku od poteškoća te pravovremenu reakciju. Na taj način, kombinacijom vizualizacije stupnja postignutosti ishoda učenja i prediktivne analitike, nastavnicima se pruža uvid u trenutne učinke nastavnih strategija, kao i smjernice za optimizaciju nastavnog procesa.

LAD-t sastoji se od tri glavne komponente: *komponenta aktivnosti i uspjeha*, *komponenta ishodi učenja* i *komponenta predviđanja*. Arhitekturu LAD-t prikazuje Slika 25.



Slika 25 Arhitektura LAD-t

LAD-t je implementiran kao plugin za Moodle LMS. Nastavnik interakcijom s predmetom unosi i uređuje sadržaje, a svi podaci o aktivnostima i uspjehu studenata pohranjuju se u bazu podataka. LAD-t komponente (aktivnosti i uspjeh, ishodi učenja, predviđanje) dohvaćaju podatke iz baze i nastavniku pružaju povratne informacije. Jednosmjerna strelica između nastavnika i predmeta označava unos i upravljanje sadržajem, dok jednosmjerne strelice između baze i komponenti predstavljaju dohvat podataka.


4.3.1. KOMPONENTA AKTIVNOSTI I USPJEHA

Komponenta aktivnosti i uspjeha obuhvaća sljedeće povratne informacije: *Opće informacije* (broj prijava na predmet, uspjeh učenika na predmetu, broj nastavnih materijala, broj ishoda učenja), *Popis učenika*, *Broj pregleda nastavnih materijala*, *Oblike sudjelovanja na predmetu* te *Pregled aktivnosti po tjednima*.

Opće informacije predstavljaju osnovne podatke o učenicima i predmetu (Slika 26). *Opće informacije* uključuju sljedeće povratne informacije:

1. Broj aktivnosti na predmetu – Ovaj podatak prikazuje ukupan broj aktivnosti učenika u okviru predmeta, počevši od datuma početka predmeta definiranog u Moodle LMS-u.
2. Uspjeh učenika na predmetu – Uspjeh učenika mjeri se kroz rezultate postignute na različitim provjerama unutar predmeta.

3. Broj nastavnih materijala – Ovaj podatak uključuje broj različitih materijala koji su dostupni učenicima unutar predmeta, poput predavanja, bilješki, uputa, videozapisa i drugih obrazovnih sadržaja.
4. Broj ishoda učenja – Ovaj podatak prikazuje broj definiranih ishoda učenja u okviru predmeta.



Slika 26 Opće informacije

Svi ovi podaci zajedno čine opće informacije koje omogućuju nastavnicima da prate ukupnu dinamiku predmeta i angažman učenika na razini grupe. Prikazane vrijednosti ne uključuju optimalne vrijednosti uspjeha, budući da broj bodova može varirati ovisno o pojedinom ispitu.

Povratna informacija *Popis učenika* omogućuje nastavnicima uvid u sve učenike koji sudjeluju u predmetu (Slika 27, lijevo). Također, omogućava nastavnicima brzo prepoznavanje učeničkog angažmana i napretka unutar predmeta. Kada nastavnik klikne na *Detalji* na određenog učenika u popisu, otvara se skočni prozor koji pruža detaljnije informacije o aktivnostima i uspjehu tog učenika (Slika 27, desno). Ovaj prozor uključuje sljedeće podatke:

- *Broj aktivnosti* – prikazuje ukupan broj aktivnosti u kojima je učenik sudjelovao unutar predmeta.
- *Uspjeh učenika* – prikazuje postignuti uspjeh učenika na provjerama. Za ove potrebe je iskorištena funkcija koja prikuplja podatke o svim provjerama kojima je učenik pristupio unutar predmeta.
- *Rezultati provjera* – detaljno prikazuje rezultate svih provjera kojima je učenik pristupio, uključujući bodove koje je osvojio na svakoj provjeri, kao i maksimalni mogući ostvaren broj bodova na provjeri.
- *Broj pregledanih resursa* – ovaj podatak pokazuje koliko je puta učenik pregledao nastavne materijale.

Popis učenika daje jasniji uvid u angažman svakog učenika. Ova povratna informacija služi nastavnicima kao alat za praćenje napretka učenika i olakšava donošenje odluka u vezi s daljnjim obrazovnim strategijama.

POPIS UČENIKA

Search...

Br.	Ime	Prezime	Detalji
1	anonfirstname1	anonlastname1	Detalji
2	anonfirstname5	anonlastname5	Detalji
3	anonfirstname9	anonlastname9	Detalji
4	anonfirstname2	anonlastname2	Detalji
5	anonfirstname4	anonlastname4	Detalji
6	anonfirstname6	anonlastname6	Detalji
7	anonfirstname20	anonlastname20	Detalji
8	anonfirstname7	anonlastname7	Detalji

anonfirstname20 anonlastname20

Aktivnosti: 2130
Uspeh učenika: 132.14

Rezultati provjere:
Naziv provjere/Postignuta ocjena/Maksimalna ocjena:
Test 1 - Uvodju SQL / 11 / 12
Test 2 - Osnovne naredbe u SQL / 7 / 10
Test 3 - SQL upiti nad Moodle bazom / 10 / 10
Test 4 - PHP / 9 / 9
Test 5 - PHP / 13 / 13
Test 6 - PHP / 13 / 13
Test 7 - PHP / 10 / 10
Kolokvij / 51 / 53

Pregledani resursi:
Izrada osnovnog Moodle bloka
Izrada bloka za prikaz HTML-a
Izrada osnovnog report dodatka
Izrada Emailovi dodatka tipa report
Sto su to baze podataka
Kratka povijest SQL-a
Sto je to zaprava SQL-a i cemu nam on služi
Vrste podataka, relacije, atributi
SQL naredba SELECT

Slika 27 Popis učenika


Povratna informacija *Broj pregleda nastavnih materijala* pruža pregled nastavnih materijala po broju pregleda (Slika 28). Nastavni materijali u Moodle LMS-u mogu biti različiti resursi koje nastavnici dodaju kako bi podržali proces učenja. To uključuje: datoteke, stranice, url poveznice, forume i slično.

Iz sljedećeg primjera jasno je da je nastavni materijal *Moodle baza* najčešće korišten prema broju pregleda (1 510 pregleda). Na temelju ovih podataka može se zaključiti da učenici ovom materijalu pridaju posebnu pažnju, što može ukazivati na njegovu važnost ili potencijalne poteškoće u razumijevanju. Stoga bi nastavnici mogli dodatno analizirati ovaj sadržaj, prema potrebi, pružiti dodatna objašnjenja ili resurse kako bi učenicima olakšali usvajanje gradiva.

Naziv	#
Moodle baza	1510
Složeniji upiti nad Moodle bazom	1198
Izrada osnovnog Moodle bloka	1142
Komuniciranje s bazom podataka	985
Sto su to baze podataka	814
Kratka povijest SQL-a	742
Funkcije	703
Vrste podataka, relacije, atributi	700
SQL naredba SELECT	700
Polja	695


Slika 28 Povratna informacija o broju pregleda nastavnih materijala

Za Prikaz sudjelovanja učenika na predmetu korišten je sljedeći prikaz Slika 29. Ovaj grafikon prikazuje broj predanih materijala, broj pregleda lekcija te broj završenih kvizova.




Slika 29 Oblici sudjelovanja na predmetu

Povratna informacija o aktivnostima učenika omogućuje nastavnicima uvid u obrasce sudjelovanja na predmetu po tjednima (Slika 30), počevši od datuma početka predmeta definiranog u Moodle LMS-u. Ovakav vizualni prikaz omogućava nastavnicima da uoče obrasce sudjelovanja tijekom vremena, identificiraju razdoblja povećane ili smanjene aktivnosti te pravovremeno reagiraju ako uoče nedostatak angažmana.



Slika 30 Pregled aktivnosti po tjednima

Slika 31 prikazuje *Komponentu aktivnosti i uspjeha* iz perspektive nastavnika, uključujući sve prethodno navedene povratne informacije.



Slika 31 Komponenta aktivnosti i uspjeha

4.3.2. KOMPONENTA ISHODI UČENJA

Moodle LMS omogućuje povezivanje ishoda učenja s različitim nastavnim elementima, čime se omogućuje sustavno praćenje i vrednovanje postignuća učenika. Cilj predloženog pristupa je prikazati ostvarene ishode učenja za svakog učenika kroz različite oblike rada u predmetu, omogućujući preciznu vizualizaciju napretka. Inovativnost ovog pristupa ogleda se u jedinstvenom prikazu: **za svakog učenika se prikazuje postotak stupnja postignutosti ishoda učenja, dok se za svaki pojedini ishod dodatno prikazuje postotak stupnja postignutosti ishoda učenja među svim učenicima**, što nismo pronašli pregledom literature. Samo u jednom radu (Buvari i ostali, 2023) koristi se vizualizacija stupnja postignutosti ishoda učenja, no njihova vizualizacija ne omogućava ovako detaljan pristup. Na ovaj način nastavnicima se pruža brz i jasan uvid u individualni napredak te identifikacija specifičnih područja koja zahtijevaju dodatnu intervenciju.

Pregledom literature utvrđeno je da se deskriptivna analitika usmjeravala na povratne informacije o uspjehu učenika i aktivnostima, što je pokriveno u komponentama aktivnosti i uspjeha. S druge strane, naš inovativni prikaz ishoda učenja, koji integrira prikaz postotka ostvarenih ishoda u interakciji s komponentom predviđanja, predstavlja jedinstven alat za nastavnike, omogućujući im konkretno praćenje i usmjeravanje daljnjih pedagoških intervencija.

Skup postavljenih ishoda učenja na kolegiju *Programiranje I* sadrži deset definiranih ishoda učenja. Svaki od tih ishoda povezan je s nekoliko nastavnih elemenata, kao što su lekcije, testovi i ispitivanja. Na primjer, ishod učenja „Usporedba osnovnih algoritama za sortiranje“ povezan je s devet elemenata, uključujući Provjera na temu nizova, te lekcije i testove vezane uz različite algoritme sortiranja: Bubble sort (Lekcija), Bubble sort (Test), Selection sort (Lekcija), Selection sort (Test), Insertion sort (Lekcija), Quick sort (Lekcija), Insertion sort (Test), i Quick sort (Test). Detaljniji podaci o postavkama kolegija *Programiranje I* prikazani su u potpoglavlju 5.2.1.

U ovoj komponenti, također koristimo boje. Crvena boja označava ishode učenja kod kojih postotak ostvarenja iznosi između 0-33%, žuta označava postotke u rasponu od 34-66%, dok zelena boja označava ishode s postotkom ostvarenja većim od 66%. *Komponenta ishodi učenja* obuhvaća dvije vrste povratnih informacija. Prva vrsta, *Postignuti ishodi*, odnosi se na individualni prikaz svakog učenika i prikaz stupnja postignutosti ishoda učenja, dok se druga vrsta, *Ishodi učenja po postotku*, odnosi na grupni prikaz stupnja postignutosti ishoda učenja. U nastavku ćemo detaljno opisati obje vrste povratnih informacija. Povratna informacija o postignutim ishodima učenja prikazuje individualne rezultate učenika na predmetu u kontekstu uspješnosti ostvarenja definiranih ishoda učenja (Slika 32). Za svakog učenika i svaki ishod učenja prikazan je postotak stupanja postignutosti ishoda učenja, temeljen na povezanim nastavnim elementima, kako je prethodno opisano.

Ime	Prezime	Klasificirati osnovne algoritamske strukture	Klasificirati osnovne tipove grešaka	Identificirati greške u programskom rješenju	Napraviti dijagram toka i pseudokod algoritma	Usporediti osnovne algoritme sortiranja	Napisati programe u programskom jeziku Python	Procijeniti ispravnost programskog rješenja	Vrednovati gotova programska rješenja	Definirati temeljne pojmove programiranja	Definirati osnovne tipove podataka
anonfirstname11	anonlastname11	38%	50%	40%	77%	100%	25%	35%	9%	19%	64%
anonfirstname5	anonlastname5	71%	50%	75%	41%	0%	100%	35%	83%	48%	64%
anonfirstname19	anonlastname19	57%	0%	65%	95%	67%	48%	52%	61%	52%	91%
anonfirstname12	anonlastname12	95%	0%	85%	27%	89%	83%	70%	9%	14%	41%
anonfirstname14	anonlastname14	38%	100%	50%	95%	78%	52%	13%	4%	81%	55%
anonfirstname6	anonlastname6	90%	100%	50%	68%	89%	95%	22%	48%	52%	23%
anonfirstname20	anonlastname20	5%	0%	90%	73%	11%	78%	43%	70%	52%	73%
anonfirstname7	anonlastname7	67%	100%	70%	86%	78%	87%	100%	48%	29%	73%

Slika 32 Prikaz stupnja postignutosti ishoda učenja - individualno

Na primjer, za ishod učenja *Usporediti osnovne algoritme sortiranja*, učenik *anonfirstname14* *anonlastname14* ostvario je stupanj postignutosti ishoda učenja od 78% , temeljen na izvršenim aktivnostima vezanima uz taj ishod. Klikom na *Prikazani postotak* otvara se skočni prozor koji detaljno prikazuje ostvarene i neostvarene nastavne elemente za taj ishod (Slika 33).

Ishod učenja povezan sa sljedećim nastavnim elementima	
Nastavni elementi na kojima je ishod postignut	
Isplit - nizovi	
Bubble sort (Lekcija)	
Bubble sort (Test)	
Selection sort (Lekcija),	
Selection sort (Test)	
Insertion sort (Lekcija)	
Quick sort (Lekcija)	
Nastavni elementi na kojima ishod nije postignut	
Insertion sort (Test)	
Quick sort (Test).	

Slika 33 Prikaz stupnja postignutosti ishoda učenja vezanog za nastavne elemente

Povratna informacija o postotku stupnja postignutih ishoda učenja prikazuje uspješnost cijelog razreda za pojedini ishod (Slika 34). Ovaj grafikon pruža jasan i sažet prikaz postignutih rezultata u odnosu na ukupni uspjeh. Iz grafikona je vidljivo da je najniža razina ostvarenosti postignuta u ishodu Procijeniti ispravnost programskog rješenja (oko 50%), dok je najviša razina uspješnosti zabilježena u ishodu Klasificirati osnovne tipove grešaka (oko 90%). Ova povratna informacija omogućuje nastavnicima uvid u područja predmeta u kojima su učenici

najuspješniji te istovremeno identificira segmente koji zahtijevaju dodatnu analizu i unaprjeđenje.



Slika 34 Ishodi učenja po postotku

Budući da komponenta ishodi učenja prikazuje samo ove dvije povratne informacije, nema potrebe da se prikazuje u sklopu skupnog prikaza, kao što je to bio slučaj s prethodnom komponentom.

4.3.3. KOMPONENTA PREDVIĐANJA

Primarni cilj komponente predviđanja jest pružiti nastavnicima povratnu informaciju o predviđenom uspjehu svih učenika. Iako se komponente predviđanja u LAD-s i LAD-t temelje na istim podacima, komponenta predviđanja za nastavnike koristi tri modela, jer veći broj modela omogućuje dodatnu sigurnost u točnost predviđanja, čime nastavnici mogu imati veće povjerenje u rezultate usporedbom rezultata različitih modela. Detaljan opis ulaznih podataka, procesa treniranja i vrednovanja te izlaznih rezultata modela predviđanja prikazan je u potpoglavlju 5.3.

Kada nastavnik otvori komponentu predviđanja u LAD-t, alat koristi Python skriptu koja učitava sva tri prethodno trenirana modela (model1.pkl, model2.pkl, model3.pkl) pomoću biblioteke joblib. Za svakog učenika sustav prikuplja najnovije vrijednosti značajki korištenih pri treniranju modela te konstruira odgovarajuće ulazne vektore. Svaki model neovisno poziva metodu predict() i generira vlastitu procjenu klase uspjeha. Dobiveni rezultati prikazuju se

nastavniku, omogućujući usporedbu modela i uvid u potencijalne rizike ili potrebe za dodatnom podrškom učenicima.

Komponenta koristi boje za prikaz predviđenog uspjeha svakog učenika. Slika 35 prikazuje povratnu informaciju o predviđenom uspjehu svih učenika, pri čemu su korištene različite boje koje označavaju uspjeh (zelena, žuta, crvena).

The image displays three side-by-side panels, each representing a different model's predictions. Each panel has a title 'Predikcija na temelju obradenih podataka' followed by a model number (MODEL 1, MODEL 2, MODEL 3). Below each title is a table with three columns: 'Ime' (Name), 'Prezime' (Surname), and 'Uspjeh studenta' (Student Success). The success is indicated by a colored word: green for 'Dobar' (Good), yellow for 'Prosječan' (Average), and red for 'Loš' (Poor). In MODEL 2, the student 'anonfirstnamel2' is marked as 'Prosječan' (yellow), while all other students in all three models are marked as 'Dobar' (green).

Ime	Prezime	Uspjeh studenta
anonfirstnamel1	anonlastname11	Dobar
anonfirstname5	anonlastname5	Dobar
anonfirstname19	anonlastname19	Dobar
anonfirstname12	anonlastname12	Dobar
anonfirstname14	anonlastname14	Dobar
anonfirstname6	anonlastname6	Dobar
anonfirstname20	anonlastname20	Dobar
anonfirstname7	anonlastname7	Dobar
anonfirstname9	anonlastname9	Dobar

Ime	Prezime	Uspjeh studenta
anonfirstnamel1	anonlastname11	Dobar
anonfirstname5	anonlastname5	Dobar
anonfirstname19	anonlastname19	Dobar
anonfirstname12	anonlastname12	Prosječan
anonfirstname14	anonlastname14	Dobar
anonfirstname6	anonlastname6	Dobar
anonfirstname20	anonlastname20	Dobar
anonfirstname7	anonlastname7	Dobar
anonfirstname9	anonlastname9	Dobar

Ime	Prezime	Uspjeh studenta
anonfirstnamel1	anonlastname11	Dobar
anonfirstname5	anonlastname5	Dobar
anonfirstname19	anonlastname19	Dobar
anonfirstname12	anonlastname12	Dobar
anonfirstname14	anonlastname14	Dobar
anonfirstname6	anonlastname6	Dobar
anonfirstname20	anonlastname20	Dobar
anonfirstname7	anonlastname7	Dobar
anonfirstname9	anonlastname9	Dobar

Slika 35 Komponenta predviđanja

5. METODOLOGIJA ISTRAŽIVANJA

U ovome poglavlju opisujemo odabranu metodologiju istraživanja te objašnjavamo zašto je upravo ona najprimjerenija za problematiku kojom se bavimo. Budući da su istraživanja provedena na sveučilišnoj razini, u nastavku, dosljedno koristimo termine *student* i *kolegij*. Na samom početku, razjasnimo razliku između metodologije i metode. Prema L. Cohen i ostali (2000) definiraju metodu kao „raspon pristupa koji se koriste u obrazovnom istraživanju za prikupljanje podataka koji će poslužiti kao osnova za zaključivanje i interpretaciju, za objašnjenje i predviđanje” (str. 44), dok je „cilj metodologije pomoći nam da shvatimo, u najširem mogućem smislu, ne proizvode znanstvenog istraživanja, već sam proces” (str. 45). U ovoj disertaciji, metodologija se odnosi na sveukupni istraživački pristup i logiku istraživačkog procesa koji omogućuje razumijevanje samog fenomena. Metode se, s druge strane, odnose na konkretne tehnike i pristupe koji se koriste za prikupljanje, analizu i interpretaciju podataka.

Dizajn studije slučaja (engl. case study design), prema L. Cohen i ostali (2017) specifičan je primjer koji se često koristi za ilustraciju šireg načela; studija slučaja pruža jedinstven uvid u stvarne ljude i situacije, čime omogućuje primjenu i provjeru teorijskih koncepata u praksi. Studija slučaja podrazumijeva istraživanje „omeđenog sustava (npr. slučaj, dijete, skupina, razred, škola, zajednica i dr.) kroz vrijeme, putem detaljnog i dubinskog prikupljanja podataka” (Creswell, 1994, str. 12). Yin (2018) ističe kako granica između fenomena i njegovog konteksta često nije jasno definirana, te da se slučaj odvija u stvarnom (engl. real world) kontekstu.

S obzirom da su prethodna istraživanja o integraciji LAD-ova u obrazovne procese kategorizirana kao studije slučaja (Ademi i ostali, 2019; Ihantola i ostali, 2015; Santos i ostali, 2012; Yoo i ostali, 2015), i da se ovo istraživanje bavi tom temom, primjena dizajna studije slučaja smatra se najprikladnijim pristupom za odgovaranje na istraživačka pitanja.

Još preciznije, u ovom istraživanju korišten je dizajn studije jednog slučaja (engl. single case study design) (Yin, 2018; Kasapović, 2013). Slučaj definiramo kao korištenje LAD-ova u hibridnom (mješovitom) obliku učenja. Sukladno definiciji Creswella, u ovom slučaju „omeđeni sustav” predstavlja uvođenje LAD-ova u proces učenja i poučavanja. Nadalje, kako (Yin, 2018) naglašava, granica između fenomena (uvođenje tehnologije, odnosno korištenje LAD-ova) i konteksta (obrazovni sustav) često ostaje nejasna, što predstavlja ključnu karakteristiku svakog istraživanja unutar ovog okvira. Također, Yin (2018) sugerira da se unutar dizajna jedne studije slučaja mogu uključiti pojedinačne analize čime se razvija

ugniježđeni (engl. embedded) dizajn, a takav pristup se naziva ugniježđena studija jednog slučaja (engl. embedded single-case design). U ovom istraživanju pojedinačne analize se odnose na model predviđanja i vrednovanje LAD-s kod studenata, te vrednovanje LAD-t kod nastavnika.

Yin (2018) također ukazuje na mogućnost integriranja studije slučaja s drugim istraživačkim metodama, ističući porast interesa za kombiniranje kvalitativnih i kvantitativnih metoda. Kad se u hrvatskom jeziku govori o „mješovitoj“ ili „kombiniranoj“ metodologiji to se odnosi na pristup koji uključuje upravo kombinaciju ovih metoda (Tkalac Verčić i ostali, 2010). Međutim, kako bismo izbjegli konfuziju s pojmom metodologije kao cjelokupnim pristupom, ovdje se koristi termin „istraživanje pomoću kombiniranih metoda“ (eng. mixed-method research). Da je istraživanje pomoću kombiniranih metoda prikladno za studiju slučaja dodatno potvrđuju (Clark i ostali, 2018; Yin, 2018).

Istraživanje pomoću kombiniranih metoda, uključuje „prikupljanje (kvantitativnih i kvalitativnih) podataka, njihovu analizu i interpretaciju u studijama koje, pojedinačno ili zajedno, obrađuju određeni fenomen“ (Leech & Onwuegbuzie, 2004, str. 265). Takav pristup smatra se „istraživanjem koje provodi jedan ili više istraživača, a obuhvaća kombiniranje različitih elemenata kvantitativnih i kvalitativnih pristupa (npr. s obzirom na perspektive, prikupljanje i analizu podataka), zajedno s prirodom zaključaka proizašlih iz istraživanja“ (Creswell & Plano Clark, 2011, str. 4). Svrha toga jest pružiti bogatije i pouzdanije (šire i dublje) razumijevanje nekog fenomena nego što bi to omogućio samo jedan pristup (L. Cohen i ostali, 2017).

Iako se u posljednje vrijeme sve češće susrećemo s novim terminima koji kombiniraju studiju slučaja i istraživanje pomoću kombiniranih metoda, poput „mixed methods case studies“ (Cook & Kamalodeen, 2023), u ovoj disertaciji koristi se dizajn ugniježđene studije jednog slučaja (engl. embedded single-case design). Takav pristup se smatra najprikladnijim za ispunjavanje ciljeva ovog istraživanja.

O pouzdanosti i valjanosti studije slučaja, L. Cohen i ostali (2017) smatraju da studije slučaja nemaju uvijek vanjske provjere i mehanizme ravnoteže (engl. checks and balances) karakteristične za neke druge oblike istraživanja, no i dalje mogu udovoljavati načelima valjanosti i pouzdanosti ako se pomno planiraju i provode. (L. Cohen i ostali, 2017, str. 381–382) pritom ističu nekoliko ključnih vrsta valjanosti:

- valjanost konstrukata istraživanja (eng. construct validity) - postiže se dosljednom primjenom prihvaćenih definicija i konstrukata za pojmove i fenomene koji se istražuju. Uključuje preciznu operacionalizaciju istraživanja i mjernih instrumenata, čime se osigurava da korištene mjere uistinu obuhvaćaju koncepte od interesa.
- interna valjanost istraživanja (eng. internal validity) - odnosi se na usklađenost različitih dijelova podataka i obrasce rezultata, tako da interpretacije i zaključci jasno proizlaze iz prikupljenih podataka.
- eksterna valjanost istraživanja (engl. external validity) - povezana je s razinom na kojoj se nalazište i teorijski okvir istraživanja mogu generalizirati na druge kontekste. Uključuje precizno opisivanje konteksta i uvjeta istraživanja te obrazloženje kako i zašto se određeni rezultati mogu (ili ne mogu) prenijeti u druge slične situacije.

pouzdanost (engl. reliability) - obuhvaća ponovljivost i dosljednost istraživanja, kako u pogledu unutarnje tako i vanjske pouzdanosti. U studijama slučaja posebno je važna dosljedna primjena metodologije, transparentnost postupaka i detaljno dokumentiranje svih koraka. Uključivanje kvantitativnih i kvalitativnih podataka može pružiti veću pouzdanost (L. Cohen i ostali, 2017).

5.1. PREDMET I PROBLEM ISTRAŽIVANJA

Obrazovni proces je sustavno organizirana zajednička aktivnost nastavnika i studenata na ostvarenju zadataka odgoja i obrazovanja (Bognar & Matijević, 2002). U skladu s time, predmet ovog istraživanja je **razvoj i vrednovanje nadzornih ploča analitike učenja s naglaskom na integraciju prediktivne i deskriptivne analitike, usmjerenih na dvije ciljane skupine: studente i nastavnike.**

Zbog izazovnog vremena u kojem živimo podložnog promjenama kod studenata, nastavnika i samog obrazovnog procesa, smatramo da je LAD važan alat za podršku procesu učenja i poučavanja u mješovitom (hibridnom) i online okruženju, a posebno u kolegijima u kojima je izražena veća vjerojatnost odustajanja. Složenost programiranja, osobito u uvodnim kolegijima programiranja, često rezultira visokom stopom odustajanja studenata, što dodatno naglašava potrebu za implementacijom digitalnih alata za podršku učenju. Razvoj LAD-ova usmjerenih studentima omogućuje im da u svakom trenutku budu svjesni situacije u kojoj se nalaze, dok LAD usmjeren nastavnicima pruža mogućnost pravovremene intervencije.

Kako bi se spriječile eventualne nejasnoće, nadzornu ploču analitike učenja koja sadrži prediktivnu analitiku potrebno je promatrati iz dva gledišta, što potvrđuju (R. G. Bodily, 2018; Ramaswami, 2022). Prvo, potrebno je istražiti točnost modela predviđanja, a potom vrednovati alat koji se koristi za kontinuirano unapređenje nastavnih praksi.

U skladu s iznijetim predmetom, problem istraživanja definira se kao **istraživanje o točnosti modela predviđanja uspjeha studenata na kolegiju *Programiranje 1* te vrednovanje modela nadzornih ploča analitike učenja** sa stvarnim korisnicima.

5.2. KONTEKST ISTRAŽIVANJA

Učenje i poučavanje programiranja može biti izazovno, a početnici često brzo gube motivaciju i odustaju. Upravo je to razlog uvođenja **nadzornih ploča analitike učenja (LAD) u kolegije** povezane s poučavanjem programiranja, konkretno kolegij *Programiranje 1* na Sveučilištu u Splitu, na Prirodoslovno-matematičkom fakultetu (u daljnjem tekstu PMFST). Studenti prve godine suočavaju se s uobičajenim poteškoćama jer većina njih nema prethodno iskustvo u pisanju koda. Oni se razlikuju prema studijima matematika (M), fizika (F), informatika (I), inženjerska fizika (iF), matematika i informatika (MI) te informatika i tehnika (IT). Za većinu studenata prvi susret s programiranjem događa se u kolegiju *Programiranje 1*, koji uvodi osnovne koncepte proceduralnog programiranja u jeziku Python (Krpan, 2020).

ISHODI UČENJA

Kolegij je namijenjen studentima preddiplomskog studija i organiziran je u hibridnom obliku, s dijelom nastave koja se održava uživo te dijelom online korištenjem Moodle LMS-a. Tijekom 15 tjedana, nastava se sastoji od dva sata predavanja i dva sata vježbi tjedno. Nastavni materijali, uključujući video sadržaje, dostupni su studentima neograničeno, a tjedne kratke provjere omogućuju primjenu naučenih koncepata. Konačna ocjena temelji se na bodovima iz tjednih provjera i završnoj provjeri (ispitu). Studenti koji ne polože na ovaj način, upućuju se na ispitni rok. Radi postizanja nastavnih ciljeva, definirano je deset ishoda učenja, pri čemu je svaki usko povezan s više nastavnih elemenata. Ovakva struktura omogućava detaljno praćenje napretka studenata, identificiranje područja gdje su potrebne intervencije te pruža nastavnicima sveobuhvatan uvid u ostvarivanje ishoda učenja.

1. I1. Klasificirati osnovne algoritamske strukture
2. I2. Klasificirati osnovne tipove grešaka
3. I3. Identificirati greške u programskom rješenju
4. I4. Napraviti dijagram toka i pseudokod algoritma
5. I5. Usporediti osnovne algoritme sortiranja
6. I6. Napisati programe u programskom jeziku Python
7. I7. Procijeniti ispravnost programskog rješenja
8. I8. Vrednovati gotova programska rješenja
9. I9. Definirati temeljne pojmove programiranja
10. I10. Definirati osnovne tipove podataka

U kolegiju se obrađuje 35 nastavnih tema. Svaka nastavna tema ima i element provjere kojim se prati napredak, razumijevanje i uspješnost studenata. Primjerice, nastavna tema „Algoritam, svojstva algoritma, načini zapisivanja algoritma“ obuhvaća nastavni element „Algoritam (Lekcija)“ te provjeru „Algoritam, svojstva algoritma, načini zapisivanja algoritma (Provjera)“, koja je dio procesa vrednovanja znanja.

Tablica 9 prikazuje povezanost ishoda učenja s pripadajućim nastavnim elementima, čime se omogućuje jasniji uvid u pedagoški okvir kolegija.

Tablica 9 Povezanost ishoda učenja i nastavnih elemenata na kolegiju *Programiranje 1*

Nastavna tema	Nastavni elementi vezani za ishode	očekivani ishodi učenja									
		I1	I2	I3	I4	I5	I6	I7	I8	I9	I10
Materijali	Blic-varijable i razgranata struktura						*	*			
	Blic-petlje						*	*			
	Blic-funkcije						*	*			
	Blic nizovi					*	*	*			
	Blic datoteke						*	*			
1. Temeljni pojmovi iz programiranja	Temeljni pojmovi iz programiranja (Lekcija)									*	
	Temeljni pojmovi iz programiranja (Provjera)									*	
2. Elementi programskog jezika Python	Elementi programskog jezika Python (Lekcija)									*	
	Elementi programskog jezika Python language (Provjera)									*	
	Test Rad u Python IDLE okruženju - otvaranje datoteke, spremanje datoteke, testiranje programa (Provjera)									*	
3. Brojčani tip podataka	Brojčani tip podataka (Lekcija)										*
	Brojčani tip podataka (Provjera)										*
4. Tekstualni tip podataka	Tekstualni tip podataka (Lekcija)										*
	Tekstualni tip podataka (Provjera)										*
	Logički tip podataka (Lekcija)										*

5. Logički tip podataka	Logički tip podataka (Provjera)										*
6. Operatori i izrazi - aritmetički, logički, relacijski, za stringove	Operatori i izrazi - aritmetički, logički, relacijski, za stringove (Lekcija)										*
	Operatori i izrazi - aritmetički (Provjera)										*
	Operatori i izrazi - logički (Provjera)										*
	Operatori i izrazi - relacijski (Provjera)										*
	Operatori i izrazi - stringovi (Provjera)										*
7. Infiksna i prefiksna notacija, prioritet i asocijativnost operatora, ekvivalentnost logičkih izraza	Infiksna i prefiksna notacija (Lekcija)										*
	Prioritet i asocijativnost operatora (Lekcija)										*
	Ekvivalentnost logičkih izraza (Lekcija)										*
	Infiksna i prefiksna notacija, prioritet i asocijativnost operatora, ekvivalentnost logičkih izraza (Provjera)										*
8. Varijable	Varijable (Lekcija)									*	*
	Varijable (Provjera)									*	*
	Naredba za ispis - print (Provjera)									*	*
	Naredba za unos - input (Provjera)									*	*
9. Algoritam, svojstva algoritma, načini zapisivanja algoritma	Algoritam (Lekcija)	*			*						
	Algoritam, svojstva algoritma, načini zapisivanja algoritma (Provjera)	*			*						
10. Primjer izrade algoritma	Primjer izrade algoritma (Lekcija)	*			*						
	Primjer izrade algoritma (Provjera)	*			*						
11. Jednostavne algoritamske strukture	Jednostavne algoritamske strukture (Lekcija)	*			*						
	Linijaska struktura (Provjera)	*			*						
	Razgranata struktura - jednostrana selekcija (Provjera)	*			*						
	Razgranata struktura - dvostrana selekcija (Provjera)	*			*						
	Razgranata struktura - višestruka selekcija (Provjera)	*			*						
12. Ciklička struktura	Pojam cikličke strukture i vrste osnovnih struktura (Lekcija)	*			*						
	Tipični primjeri povezivanja osnovnih cikličkih struktura u složenije (Lekcija)	*			*						
	Ciklička struktura - petlja s poznatim brojem ponavljanja (Provjera)	*			*						
	Ciklička struktura - petlja s Ispitivanjem uvjeta (Provjera)	*			*						
13. Osnovni algoritmi - problemi sa znamenkama	Osnovni algoritmi - problemi sa znamenkama (Lekcija)	*			*						
	Osnovni algoritmi - problemi sa znamenkama (broj znamenki, ispis znamenki, suma znamenki, umnožak znamenki) (Provjera)	*			*						
	Osnovni algoritmi - problemi sa znamenkama (brojač određenih znamenki, najveća znamenka, najmanja znamenka, obrnuti ispis broja) (Provjera)	*			*						
14. Osnovni algoritmi - problemi s djeliteljima broja	Osnovni algoritmi - problemi s djeliteljima broja (Lekcija)	*			*						
	Osnovni algoritmi - problemi s djeliteljima broja (najveći zajednički djelitelj, najmanji zajednički	*			*						

	višekratnik, broj djelitelja, suma djelitelja) (Provjera)											
	Osnovni algoritmi - problemi s djeliteljima broja (produkt djelitelja, aritmetička sredina djelitelja, skraćivanje razlomka, prosti brojevi) (Provjera)	*			*							
15. Osnovni algoritmi - problemi sa stringovima	Osnovni algoritmi - problemi sa stringovima (Lekcija)	*			*							
	Osnovni algoritmi - problemi sa stringovima (brojanje slova u stringu, brojanje riječi u rečenici, palindrom) (Provjera)	*			*							
16. Procedure	Procedure (Lekcija)									*		
	Procedure (Provjera)									*		
17. Napredan rad sa stringovima	Napredan rad sa stringovima (Lekcija)										*	
	Napredan rad sa stringovima - indeksiranje znakova stringa (Provjera)										*	
	Napredan rad sa stringovima - selektiranje znakova stringa (Provjera)										*	
18. Ugrađene funkcije	Ugrađene funkcije (Lekcija)									*		
	Ugrađene funkcije (Provjera)									*		
19. Zadaci sa znamenkama	Zadaci sa znamenkama (Lekcija)			*			*	*	*			
	Zadaci sa znamenkama - korištenje ugrađenih funkcija (Provjera)			*			*	*	*			
20. Zadaci s djeliteljima broja	Zadaci s djeliteljima broja (Lekcija)			*			*	*	*			
	Zadaci s djeliteljima broja (Provjera)			*			*	*	*			
21. Zadaci sa stringovima	Zadaci sa stringovima (Lekcija)			*			*	*	*			
	Zadaci sa stringovima - korištenje ugrađenih funkcija (Provjera)			*			*	*	*			
22. Liste - statički i dinamički unos, osnovni algoritmi	Liste - statički i dinamički unos, osnovni algoritmi (Lekcija)									*		
	Liste - statički i dinamički unos, osnovni algoritmi (Provjera)									*		
23. Funkcije i metode, konstruiranje listi (list comprehension)	Funkcije i metode, konstruiranje listi (Lekcija)									*		
	Funkcije i metode, konstruiranje listi (Provjera)									*		
24. Bubble Sort	Bubble sort (Lekcija)					*						
	Bubble sort (Provjera)					*						
25. Selection sort	Selection sort (Lekcija)					*						
	Selection sort (Provjera)					*						
26. Insertion sort	Insertion sort (Lekcija)					*						
	Insertion sort (Provjera)					*						
27. Quick sort	Quick sort (Lekcija)					*						
	Quick sort (Provjera)					*						
28. Zadaci s nizovima brojeva - problemi sa znamenkama	Zadaci s nizovima brojeva - problemi sa znamenkama (Lekcija)			*			*	*	*			
	Zadaci s listama - problemi sa znamenkama (Provjera)			*			*	*	*			
29. Zadaci s nizovima brojeva - problemi s djeliteljima broja	Zadaci s nizovima brojeva - problemi s djeliteljima broja (Lekcija)			*			*	*	*			
	Zadaci s listama - problemi s djeliteljima broja (Provjera)			*			*	*	*			
30. Zadaci s nizovima stringova - problemi sa stringovima	Zadaci s nizovima stringova - problemi sa stringovima (Lekcija)			*			*	*	*			
	Zadaci s listama - problemi sa stringovima (Provjera)			*			*	*	*			
31. Podatkovne datoteke - osnovni algoritam za unos i čitanje podataka	Podatkovne datoteke (Lekcija)									*		
	Podatkovne datoteke - osnovni algoritam za unos i čitanje podataka (Provjera)									*		

32. Zadaci s datotekama - Problemi sa znamenkama	Zadaci s datotekama - Problemi sa znamenkama (Lekcija)			*			*	*	*		
	Zadaci s datotekama - Problemi sa znamenkama (Provjera)			*			*	*	*		
33. Zadaci s datotekama - problemi sa djeljiteljima broja	Zadaci s datotekama - problemi sa djeljiteljima broja (Lekcija)			*			*	*	*		
	Zadaci s datotekama - problemi sa djeljiteljima broja (Provjera)			*			*	*	*		
34. Zadaci s datotekama - problemi sa stringovima	Zadaci s datotekama - problemi sa stringovima (Lekcija)			*			*	*	*		
	Zadaci s datotekama - problemi sa stringovima (Provjera)			*			*	*	*		
35. Rekurzija	Rekurzija (Lekcija)									*	
	Rekurzija (Provjera)									*	

Budući da je izrada nadzornih ploča analitike učenja LAD-s i LAD-t detaljno opisana u poglavlju 4, faza 2 istraživanja izostavljena je u ovom poglavlju, a pažnja je usmjerena na analizu i prikaz faze 1 i faze 3.

5.3. OBLIKOVANJE I VREDNOVANJE MODELA PREDVIĐANJA USPJEHA STUDENATA

Ovo potpoglavlje predstavlja prvo istraživanje u sklopu disertacije, usmjereno na odgovor na prvo istraživačko pitanje (IP 1):

Koji ključni pokazatelji uspješnosti učenja programiranja, identificirani analizom podataka generiranih kroz nastavne aktivnosti, imaju najveći prediktivni značaj za uspjeh studenata?

Kako bi se odgovorilo na ovo istraživačko pitanje, koriste se koraci za izgradnju modela predviđanja prema Brooks & Thompson (2022), koji obuhvaćaju: identifikacija problema (engl. problem identification), prikupljanje podataka (engl. data collection), inženjering značajki (engl. feature engineering), odabir značajki (engl. feature selection), izgradnja modela (engl. model building) i vrednovanje modela (engl. model evaluation).

IDENTIFIKACIJA PROBLEMA

Problem ovog istraživanja jest izraditi model predviđanja uspjeha studenata na kolegiju *Programiranje I* na temelju podataka prikupljenih putem Moodle LMS-a. Posebna pozornost posvećuje se identifikaciji ključnih pokazatelja uspješnosti učenja programiranja putem analize podataka generiranih kroz nastavne aktivnosti, što doprinosi boljem razumijevanju interakcija studenata s Moodle LMS-om i čimbenika koji utječu na njihovu uspješnost.

Jasno definiran ishod (predviđanje uspjeha studenata) i mjerljive značajke o interakciji studenata s LMS-om omogućili su formiranje odgovarajućeg skupa podataka.

PRIKUPLJANJE PODATAKA

Podaci korišteni u ovom istraživanju prikupljeni su iz Moodle LMS-a, koji se na PMFST-u koristi kao platforma za distribuciju nastavnih materijala i praćenje studentskih aktivnosti na kolegiju. Uzorak za ovo istraživanje obuhvaća tri uzastopne akademske godine (2019./2020., 2020./2021. i 2021./2022.), tijekom kojih je zabilježeno ukupno 457 studenata (134 u prvoj, 145 u drugoj te 178 u trećoj godini). Moodle LMS evidentira širok raspon interakcija, uključujući prijave u LMS, preuzimanje i pregledavanje materijala, rješavanje zadataka i kvizova, bilježene tijekom petnaest tjedana svakog semestra. Za potrebe testiranja modela predviđanja napravljena je sigurnosna kopija kolegija *Programiranje 1* za sve tri akademske godine, a podaci su zatim lokalno preuzeti iz baze postavljanjem upita.

Tri različite vrste podataka uključuju (1) podatke povezane s aktivnostima LMS-a, (2) podatke povezane s korištenjem materijala i (3) podatke vezane uz ispitni postupak.

INŽENJERING ZNAČAJKI

Kako bi se sirovi podaci mogli koristiti u modelima predviđanja, bilo je potrebno provesti transformaciju podataka i definiranje značajki koje kvantificiraju interakciju studenata s Moodle LMS-om. Ovaj proces uključivao je kategorizaciju ciljne značajke, konstruiranje novih značajki i rješavanje problema nedostajućih podataka. Kategorijalna završna ocjena, koja odražava uspješnost studenata, dodana je ručno i predstavlja ciljnu značajku (loš uspjeh, prosječan uspjeh, dobar uspjeh) koja se nastoji predvidjeti. Budući da su ocjene studenata na kraju semestra zabilježene kao numerička vrijednost od 1 do 100, ocjene su kategorizirane na način da se raspon 0–49 odnosi na loš uspjeh, 50–74 na prosječan uspjeh, a 75–100 na dobar uspjeh.

Na temelju prikupljenih podataka definirani su potencijalni pokazatelji uspjeha studenata pri korištenju LMS-a. Nerealno je očekivati savršeni skup podataka. Stvarne primjene prepoznavanja obrazaca ili algoritama strojnog učenja često uključuju situacije u kojima su podaci djelomično nedostadni, oštećeni ili na neki drugi način nepotpuni (Aste i ostali, 2015). Prema Ren i ostali (2023), brisanje (engl. delete missing values) i umetanje (engl. missing values imputation) predstavljaju najčešće korištene tehnike za upravljanje nedostatnim

podacima. Ipak, postoji širok raspon stavova o njihovoj učinkovitosti i primjeni u različitom kontekstu. Dok brisanje omogućuje rad samo s potpunim podacima, umetanje nastoji nadomjestiti izgubljene vrijednosti.

Trideset studenata imalo je visok postotak nepotpunih podataka u nekoliko značajki, što je moglo narušiti pouzdanost modela. Kako bi se osigurala kvaliteta analize, odlučeno je da se ti zapisi eliminiraju iz skupa podataka. Za preostale zapise, ako kod pojedinog studenta nedostaje samo jedna vrijednost u jednoj značajki, primijenjeno je umetanje nedostajućih vrijednosti medijanom.

Konačna struktura podataka uključuje značajke vezane uz prijave na kolegij, interakciju sa sadržajima i kvizovima te ispitne parametre. Angažman studenata sa sadržajima izražen je pomoću značajki *Ang1* (broj preuzetih nastavnik materijala), *Ang2* (broj pregledanih materijala) i *Ang3* (broj riješenih kvizova), pri čemu je *UkupnoAng* definiran kao zbroj svih ovih mjera. Značajka *Akt* definira ukupan broj prijava na kolegij, dok *TjedneAkt* i *VikendAkt* kvantificiraju broj prijava u određenim vremenskim intervalima.

Podaci vezani uz ispitni postupak uključuju značajke *VrijemeNaIspitu* (vrijeme provedeno na ispitu, izraženo kao postotak ukupno dopuštenog vremena), te *PrviIspitUspjeh* (uspjeh na prvom ispitu u postocima). Završna ocjena studenata predstavljena je značajkom *Uspjeh*. Nakon ovog koraka, konačni skup podataka sadrži 427 zapisa studenata. Prikaz svih značajki nalazi se u Tablica 10.

Tablica 10 Opis značajki skupa podataka korištenog za predviđanje uspjeha studenata

ZNAČAJKA	OPIS
<i>Ang1</i>	broj preuzetih nastavnik materijala
<i>Ang2</i>	broj pregledanih materijala
<i>Ang3</i>	broj riješenih kvizova
<i>UkupnoAng</i>	ukupan angažman ($Ang1 + Ang2 + Ang3$)
<i>Akt</i>	ukupan broj prijava na kolegij
<i>TjedneAkt</i>	broj prijava tijekom radnog tjedna (ponedjeljak - petak)
<i>VikendAkt</i>	broj prijava tijekom vikenda
<i>VrijemeNaIspitu</i>	vrijeme provedeno na ispitu, izračunato kao postotak ukupnog vremena u odnosu na dopušteno vrijeme

<i>PrviIsplitUspjeh</i>	uspjeh na prvom ispitu izražen u postotku
<i>Uspjeh</i>	završna ocjena

Slika 36 prikazuje isječak skupa podataka korišten za modele predviđanja uspjeha studenata.

Ang1	Ang2	Ang3	UkupnoAng	Akt	TjedneAkt	VikendAkt	VrijemeNaIsplitu	PrviIsplitUspjeh	Uspjeh
10	9	5	24	58	58	0	98,42	100	1
18	16	11	45	164	152	12	67,23	40	2
13	19	7	39	106	91	15	97,43	86,67	1
21	27	11	59	136	113	23	86,9	46,67	1
18	17	10	45	86	79	7	72,79	90	1
17	21	10	48	61	59	2	57,04	100	3
16	23	10	49	135	120	15	86,87	50	3
18	21	9	48	100	86	14	80,11	70	3
16	23	9	48	132	110	22	87,01	60	1
21	24	14	59	149	109	40	52,1	80	1
16	10	9	35	40	39	1	78,68	70	3
22	22	14	58	161	145	16	44,97	50	2
18	23	9	50	93	80	13	106,38	50	3
12	7	6	25	49	45	4	80,46	80	1
22	18	16	56	174	109	65	45,01	90	3
16	7	9	32	53	49	4	81,67	90	3
18	13	10	41	87	82	5	88,92	20	1
20	27	14	61	114	95	19	53,58	50	2
17	7	10	34	47	46	1	80,65	40	1
16	17	9	42	73	67	6	77,05	80	3
17	14	9	40	50	48	2	82,04	70	3
15	10	9	34	83	80	3	77,56	50	1
21	25	15	61	95	84	11	49,53	70	3
16	8	10	34	91	75	16	77,71	80	3
17	22	9	48	85	66	19	89,58	50	2

Slika 36 Isječak skupa podataka korištenog za predviđanje uspjeha studenata

DESKRIPTIVNA STATISTIKA SKUPA PODATAKA

Deskriptivna statistika ukazuje na značajne varijacije u interakciji studenata s LMS-om, što se vidi kroz širok raspon vrijednosti i visoke standardne devijacije određenih značajki (Tablica 11). Na primjer, ukupne aktivnosti na kolegiju (*Akt*) kreću se od samo 7 do čak 686 prijava, uz aritmetičku sredinu od 140,06 i standardnu devijaciju od 92,45. Broj preuzetih nastavnih materijala (*Ang1*), pregledanih sadržaja (*Ang2*) i riješenih kvizova (*Ang3*) također pokazuje velike oscilacije među studentima, pri čemu najveće vrijednosti dosežu do 208 (*Ang1*), 292 (*Ang2*) i 133 (*Ang3*). Ukupni angažman (*UkupnoAng*), kao zbroj tih triju aktivnosti, varira od 3 do 623.

Značajke *TjedneAkt* i *VikendAkt* ilustriraju učestalost prijava tijekom radnog tjedna, odnosno vikenda. Vrijednosti ukazuju na to da su studenti češće pristupali sustavu radnim danima, ali i tijekom vikenda, što sugerira fleksibilne navike učenja. Vrijeme provedeno na ispitu (*VrijemeNaIsplitu*) prikazano je kao postotak u odnosu na ukupno dopušteno vrijeme rješavanja. Vrijednosti koje prelaze 100% (maksimalno 119,02%) mogu se objasniti višestrukim pokušajima rješavanja ispita od strane pojedinih studenata, s obzirom na to da se uzima ukupno zabilježeno vrijeme iz LMS-a. Vrijednosti značajke *PrviIsplitUspjeh*, koja mjeri postotak uspješnosti na prvom pokušaju ispita, također pokazuju razlike u uspješnosti, s prosjekom od 57%, ali i minimumom od 0%. Ove razlike ukazuju na heterogenost ponašanja studenata. Važno je naglasiti da dio podataka dolazi iz perioda online nastave tijekom pandemije COVID-19, što može dodatno objasniti ekstremne vrijednosti u pojedinim značajkama, osobito u pogledu angažmana i učestalosti interakcije sa sustavom.


Tablica 11 Deskriptivna statistika skupa podataka

ZNAČAJKA	M	SD	Min	25%	50%	75%	Max
<i>Ang1</i>	69,68	75,76	1,0	14,0	22,0	159,0	208,0
<i>Ang2</i>	89,81	79,62	1,0	21,0	62,0	172,5	292,0
<i>Ang3</i>	43,31	46,85	1,0	8,0	15,0	96,5	133,0
<i>UkupnoAng</i>	202,8	199,38	3,0	45,0	97,0	423,0	623,0
<i>Akt</i>	140,06	92,45	7,0	74,5	118,0	189,0	686,0
<i>TjedneAkt</i>	103,27	69,96	3,0	55,0	86,0	133,0	548,0
<i>VikendAkt</i>	36,78	37,5	0,0	9,0	23,0	53,5	247,0
<i>VrijemeNaIsplitu</i>	60,0	21,48	16,32	42,7	56,29	76,56	119,02
<i>PrviIsplitUspjeh</i>	57,0	21,39	0,0	40,0	60,0	73,81	100,0

Legenda: M označava aritmetičku sredinu, SD standardnu devijaciju, Min minimalnu vrijednost, 25% donji kvartil, 50% medijan, 75% gornji kvartil, a Max maksimalnu vrijednost

Kako bi se dodatno ilustrirale razlike u ponašanju i angažmanu studenata, Slika 37 prikazuje distribuciju svih značajki. Histogrami jasno pokazuju da većina značajki nije ravnomjerno raspoređena, što upućuje na asimetrične distribucije podataka i prisutnost ekstremnih vrijednosti. Na primjer, distribucije značajki *Ang1*, *Ang2*, *Ang3* i *UkupnoAng* pokazuju asimetričan oblik što znači da većina studenata ostvaruje niži angažman, dok manji broj

pokazuje iznimno visoku aktivnost. Sličan obrazac prisutan je i kod značajki *Akt*, *TjedneAkt* i *VikendAkt*, koje se odnose na broj prijava na kolegij u različitim vremenskim intervalima.



Slika 37 Distribucija svih značajki skupa podataka

Deskriptivna statistika pokazala je značajnu raznolikost u načinu na koji su studenti koristili Moodle LMS. Prikazani rezultati temelje se na izvornom skupu podataka (nenormalizirane vrijednosti) kako bi se osigurao vjerodostojan uvid u stvarne obrasce ponašanja studenata i njihovu interakciju sa Moodle LMS-om.

Kako bi se osigurala optimalna izvedba algoritama strojnog učenja, nužno je primijeniti skaliranje značajki ili normalizaciju (engl. Feature scaling or normalization), čime se postiže ujednačavanje njihovih skala i smanjuje utjecaj značajki s većim apsolutnim vrijednostima na modele predviđanja (A. Zheng & Casari, 2018). Pojam *skaliranje značajki* koristi se za različite pristupe transformacije podataka, uključujući kontekstualno skaliranje po tjednima, Z-score standardizaciju i Min-Max skaliranje. Skaliranje značajki osobito je važno kod algoritama koji su osjetljivi na razlike u skali ulaznih podataka. Primjeri takvih modela uključuju linearne modele (linearna i logistička regresija), metode temeljene na udaljenosti (SVM) te neuronske mreže (Hastie i ostali, 2004). Ako se skaliranje ne provede, značajke s većim numeričkim rasponima mogu dominirati nad onima s manjim vrijednostima, što smanjuje mogućnost interpretacije modela i njegovu sposobnost otkrivanja uzoraka.

Suprotno tome, algoritmi temeljeni na stablima odlučivanja, poput RF, Boosting algoritama i klasičnih stabala odluka (DT), nisu osjetljivi na skaliranje (Han & Kamber, 2000). Ovi modeli rade s hijerarhijskim podjelama podataka, što znači da apsolutne vrijednosti značajki nemaju izravan utjecaj na odluke modela. Zbog toga skaliranje nije nužno za ove algoritme, ali može biti korisno kada se podaci koriste u kombinaciji s modelima koji zahtijevaju standardizaciju.

S obzirom na to da se nastava u ovom istraživanju odvijala tijekom 15 tjedana, značajke koje kvantificiraju aktivnosti studenata u LMS-u (*Ang1*, *Ang2*, *Ang3*, *UkupnoAng*, *Akt*, *TjedneAkt*, *VikendAkt*) skalirane su tako da je svaka vrijednost podijeljena s brojem nastavnih tjedana. Time su transformirane u prosječne tjedne vrijednosti, što omogućuje usklađivanje modela s ritmom nastavnog procesa. Značajke *VrijemeNaIsplitu* i *PrviIsplitUspjeh* nisu obuhvaćene ovom vrstom skaliranja jer su već izražene kao postotne vrijednosti, neovisne o vremenskom okviru.

Ovakav pristup osigurava konzistentnost u primjeni modela predviđanja u alatima LAD-s i LAD-t, koji koriste realno prikupljene tjedne podatke tijekom trajanja nastave. Skalirane vrijednosti korištene su isključivo za treniranje i vrednovanje modela predviđanja. Radi provjere robusnosti razvijenih modela, na deset najboljih kombinacija značajki dodatno su primijenjene dvije klasične metode skaliranja (A. Zheng & Casari, 2018):

1. Z-score standardizacija transformira podatke tako da imaju srednju vrijednost 0 i standardnu devijaciju 1, čime se eliminiraju razlike u veličini značajki (A. Zheng & Casari, 2018).
2. Min-Max skaliranje transformira podatke u raspon [0,1], čime se osigurava da minimalna vrijednost postane 0, a maksimalna 1 (A. Zheng & Casari, 2018). Ova metoda je korisna za značajke koje su ograničene unutar unaprijed definiranog raspona. Za razliku od Z-score standardizacije, Min-Max skaliranje omogućuje zadržavanje interpretabilnosti podataka, čime se osigurava da, primjerice, student s *PrviIsplitUspjeh* koji ima 100% i dalje zadrži svoju maksimalnu vrijednost u skaliranom obliku.

Ove metode nisu korištene u glavnoj analizi, već su primijenjene naknadno na deset najboljih modela radi dodatne provjere utjecaja različitih metoda skaliranja na performanse modela. Konačan skup podataka, s vrijednostima značajki skaliranim po tjednima, korišten za treniranje i vrednovanje modela, prikazan je u Prilogu B1.

ODABIR ZNAČAJKI

Odabir značajki je važna i često korištena tehnika u predobradi podataka za rudarenje podataka. Ova tehnika smanjuje broj značajki, uklanja nebitne, redundantne ili šumom opterećene podatke, čime poboljšava performanse modela, uključujući vrijeme odziva, točnost predviđanja i razumljivost rezultata (Harb & Moustafa, 2012).

Kako bi se izgradio i primijenio model predviđanja, nužno je odabrati prediktivne značajke koje su povezane s ciljnom značajkom, tj. vrijednošću koja se predviđa (Brooks & Thompson, 2022). Odabir značajki podrazumijeva izbor najvažnijih značajki iz većeg skupa, koji može sadržavati i irelevantne ili nepotrebne podatke (Shrestha & Pokharel, 2021). Za izgradnju modela predviđanja uspjeha studenata, važno je pravilno odabrati značajke koje najbolje predstavljaju odnos između ulaznih podataka i uspjeha studenata (Zaffar i ostali, 2018). Najprikladnije značajke mogu se odabrati primjenom algoritama za odabir značajki (Harb & Moustafa, 2012). Postoje tri glavne vrste algoritama za odabir značajki: filter metode, *wrapper* metode i hibridne metode (Zaffar i ostali, 2018). Filter metode provode se tijekom preprocesiranja podataka i nisu ovisne o bilo kojem algoritmu za učenje, već se oslanjaju na sveukupne značajke podataka za obuku. Wrapper metode koriste algoritme za učenje kako bi procijenile značajke, dok hibridne metode kombiniraju svojstva obje metode (filter i wrapper) (Zaffar i ostali, 2018).

Iako su algoritmi za odabir značajki uobičajeni u mnogim istraživanjima, u ovoj disertaciji se ne istražuju. Cilj je pronalaženje najboljeg modela predviđanja za implementaciju u LAD-s i LAD-t u smislu točnosti. Umjesto da se primijene standardni algoritmi za odabir značajki, izabran je pristup koji uključuje ispitivanje svake moguće kombinacije značajki.

Skup podataka sastoji se od 9 značajki, što rezultira s ukupno 502 moguće kombinacije značajki. Pristup odabira značajki specifičan je za ovo istraživanje jer se, u mnogim prethodnim radovima odabir značajki ne spominje kao ključna faza već konačna predviđanja i metrike vrednovanja. Ukupno je ispitano 502 različitih kombinacija značajki za treniranje modela. Taj broj proizlazi iz ukupnog broja podskupova devet značajki ($2^9 = 512$), pri čemu su izostavljene kombinacije s nula i s jednom značajkom ($512 - 1 - 9 = 502$).

IZGRADNJA MODELA

Za **izgradnju modela predviđanja uspjeha studenata**, korišteno je šest klasifikacijskih algoritama strojnog učenja: logistička regresija (engl. Logistic Regression, LogR) (Kleinbaum David G. and Klein, 2010), stroj potpornih vektora (engl. Support Vector Machines, SVM) (Cortes & Vapnik, 2009), stablo odlučivanja (engl. Decision Tree, DT) (Rokach & Maimon, 2008), slučajne šume (engl. Random Forests, RF) (Svetnik i ostali, 2003), umjetna neuronska mreža (engl. Artificial Neural Network, ANN), konkretno tip višeslojnog perceptrona (engl. Multilayer perceptron, MLP) (McClean, 2000) i Naivni Bayesov algoritam (engl. Naïve Bayes, NB) (Webb, 2016).

Razlog za odabir ovih algoritama temelji se na njihovoj uspješnosti u prethodnim istraživanjima vezanim za predviđanje uspjeha, posebno u kontekstu obrazovnih podataka. Osim toga, spomenuti algoritmi imaju mogućnost predviđanja više od dvije klase, što je zadatak klasifikacije u ovom radu. Algoritmi su implementirani korištenjem biblioteke scikit-learn (Pedregosa i ostali, 2012). Vrednovanje svakog modela provedeno je korištenjem metode unakrsne validacije primjenom k -fold pristupa (s $k = 10$), što omogućuje pouzdanu procjenu sposobnosti modela predviđanja. Za klasifikacijske algoritme koji podržavaju balansiranje klasa, korišten je parametar `class_weight=„balanced“` kako bi se umanjio utjecaj neravnoteže u distribuciji ciljnih klasa. Za analizu je implementirano ukupno 3012 modela predviđanja, što je rezultat 502 kombinacije značajki pomnoženih sa 6 različitih algoritama. Ovaj pristup omogućio je temeljitu analizu utjecaja različitih kombinacija značajki na predviđanje uspjeha studenata.

VREDNOVANJE MODELA

Nakon izgradnje modela klasifikacije, sljedeći korak je procjena učinkovitosti kako bi se utvrdila njegova točnost i pouzdanost u predviđanju. Za **vrednovanje modela** uspoređena je izvedba klasifikacije korištenjem četiri metrike: točnost (engl. accuracy), preciznost (engl. precision), odziv (engl. recall) i F1 mjeru (engl. F1 score). Točnost je najčešće korištena metrika za procjenu učinkovitosti modela predviđanja (Namoun & Alshantqi, 2020).

Budući da je riječ o predviđanju uspjeha studenata, postoje četiri moguće situacije:

- Stvarno pozitivni (engl. True Positive, TP): broj uspješnih studenata koji su ispravno klasificirani kao „uspješni“.
- Lažno pozitivni (engl. False Positive, FP): broj neuspješnih studenata koji su pogrešno klasificirani kao „uspješni“.
- Stvarno negativni (engl. True Negative, TN): broj neuspješnih studenata koji su ispravno klasificirani kao „neuspješni“.
- Lažno negativni (engl. False Negative, FN): broj uspješnih studenata koji su pogrešno klasificirani kao „neuspješni“.

Slijede definicije korištenih mjera i načini izračuna:

- Točnost (engl. accuracy) je omjer ispravno predviđenih rezultata u odnosu na ukupan broj predviđanja (Sokolova & Lapalme, 2009). Izračunava se prema jednadžbi:

$$\text{točnost} = \frac{TP + TN}{TP + TN + FP + FN}$$

- Preciznost (engl. precision) je ključna mjera točnosti klasifikatora, izražavajući omjer stvarno pozitivnih primjera (TP) u odnosu na ukupan broj pozitivnih predviđanja (TP + FP) (Sokolova & Lapalme, 2009). Izračunava se prema jednadžbi:

$$\text{preciznost} = \frac{TP}{TP + FP}$$

- Odziv (engl. recall), poznat i kao osjetljivost (engl. sensitivity), pokazuje koliko je model uspješan u prepoznavanju svih stvarnih pozitivnih primjera (Sokolova & Lapalme, 2009). . Izračunava se prema jednadžbi:

$$\text{odziv} = \frac{TP}{TP + FN}$$

Kombinacija ovih metrika omogućila je analizu učinkovitosti modela, čime se olakšao odabir optimalnog modela. Za sveobuhvatnu procjenu učinkovitosti modela često se koristi F1 mjera (engl. F1 score), koja predstavlja harmonijsku sredinu preciznosti (engl. Precision) i odziva (engl. Recall) (Sokolova & Lapalme, 2009). Osim toga, dodatne metrike poput specifičnosti (engl. Specificity) i AUC-ROC (engl. Area Under the Receiver Operating Characteristic Curve) također se često primjenjuju kako bi se dobio dublji uvid u performanse modela predviđanja (Powers & Ailab, 2011; Sokolova & Lapalme, 2009). U ovoj disertaciji korištene mjere su točnost, preciznost, odziv i F1 mjera. Primjer koda implementiran u Jupyter notebooku, koji prikazuje izračun metrika učinkovitosti za broj kombinacija $N=3$, dostupan je u Prilogu B2.

VALJANOST I POUZDANOST ISTRAŽIVANJA

Konstruktna valjanost u nadziranom strojnom učenju postiže se jasnim definiranjem i operacionalizacijom značajki (Anglin, 2024). Ciljna značajka koju istraživači nastoje izmjeriti treba biti precizno definirana i označena, a model treba odražavati taj konstrukt. U ovom radu, ciljna značajka je uspjeh studenata na kolegiju *Programiranje I*, a model temeljito odražava taj konstrukt kroz odabrane značajke.

Vanjska valjanost odnosi se na mogućnost generalizacije modela na nove, neviđene podatke. Minimalni standard za rigorozno nadzirano učenje uključuje podjelu podataka na skup za treniranje i skup za testiranje, čime se osigurava preciznija procjena izvedbe modela na neovisnim podacima (Anglin, 2024). U ovom istraživanju primijenjena je desetostruka unakrsna validacija (engl. 10-fold cross-validation), postupak u kojem se skup podataka dijeli na 10 jednakih dijelova, pri čemu se u svakoj iteraciji jedan dio koristi za testiranje, a preostalih devet za treniranje modela. Ovaj pristup omogućuje generalizaciju sposobnosti modela predviđanja na nove skupove podataka.

Unutarnja valjanost ispituje u kojoj mjeri su odnosi između ishoda, prediktora i/ili tretmana uzročno povezani, odnosno postoje li mješoviti čimbenici u opaženoj korelaciji (Anglin, 2024). Smatramo da su eliminirani mješoviti čimbenici ispitivanjem svih mogućih kombinacija skupa podataka, čime je osigurano da odnos između značajki odražava stvarnu uzročnost. Statistička valjanost postiže se prezentiranjem više mjernih pokazatelja, kao što su točnost, preciznost i odziv (Anglin, 2024), čime se osigurava da je izvedba modela reprezentativna i pouzdana.

Pouzdanost se postiže dosljednom primjenom mjernih instrumenata i osiguravanjem neovisnosti skupova podataka za treniranje i testiranje, što omogućava replikaciju rezultata (Anglin, 2024). Transparentno dokumentiranje procesa modeliranja, od pripreme podataka do vrednovanja modela, dodatno doprinosi povećanju pouzdanosti. Ovim pristupom osigurano je da model predviđanja uspjeha studenata na kolegiju *Programiranje 1* zadovoljava sve ključne aspekte valjanosti i pouzdanosti, čime se povećava povjerenje u njegove rezultate.

REZULTATI

Rezultati svih generiranih modela predviđanja evidentirani su u excel datoteci, zajedno s nazivom korištenog algoritma, točnošću, preciznošću, odzivom, F1 mjerom i korištenim značajkama. Ukupno je generirano 3012 modela predviđanja, a u Tablica 12 prikazani su rezultati deset najboljih modela predviđanja prema točnosti.

Tablica 12 Rezultati deset najboljih modela predviđanja prema mjerama i korištenim značajkama

Algoritam	Točnost	Preciznost	Odziv	F1	Korištene značajke
RF	72,83%	69,44%	72,83%	68,06%	<i>Ang1, Ang2, Ang3, VikendAkt, PrviIsplitUspjeh, VrijemeNaIsplitu</i>
RF	72,37%	68,20%	72,37%	67,19%	<i>Ang1, Ang3, Akt, VikendAkt, VrijemeNaIsplitu</i>
RF	72,13%	67,67%	72,13%	66,94%	<i>Ang1, Ang2, Ang3, UkupnoAng, VikendAkt, PrviIsplitUspjeh, VrijemeNaIsplitu</i>
RF	72,13%	66,77%	72,13%	65,58%	<i>Ang1, Ang2, Ang3, UkupnoAng, Akt, VikendAkt, PrviIsplitUspjeh, VrijemeNaIsplitu</i>
RF	71,66%	66,64%	71,66%	66,57%	<i>Ang1, Ang3, VikendAkt, VrijemeNaIsplitu</i>
RF	71,43%	67,06%	71,43%	68,05%	<i>Ang1, Ang2, PrviIsplitUspjeh</i>
MLP	71,43%	65,45%	71,43%	65,34%	<i>Ang1, Ang2, Ang3, UkupnoAng, Akt, TjedneAkt, PrviIsplitUspjeh</i>
RF	71,43%	65,58%	71,43%	65,30%	<i>Ang1, Ang3, UkupnoAng, Akt, VikendAkt, VrijemeNaIsplitu</i>
RF	71,43%	65,24%	71,43%	65,16%	<i>Ang1, Ang2, Ang3, UkupnoAng, TjedneAkt, VikendAkt, PrviIsplitUspjeh, VrijemeNaIsplitu</i>

Deset najbolje rangiranih modela predviđanja izvedeni su korištenjem algoritma RF, osim jednog modela koji koristi umjetnu neuronsku mrežu (MLP). Najbolji model postigao je točnost od 72,83%, preciznost od 69,44%, odziv od 72,83% te F1 mjeru od 68,06%. Ovaj model temelji se na sljedećim značajkama: *Ang1*, *Ang2*, *Ang3*, *VikendAkt*, *PrviIsplitUspjeh* i *VrijemeNaIsplitu*.

Drugi model predviđanja, također temeljen na algoritmu RF, koristi značajke *Ang1*, *Ang3*, *Akt*, *VikendAkt* i *VrijemeNaIsplitu*, uz postignute vrijednosti: točnost 72,37%, preciznost 68,20%, odziv 72,37% i F1 mjera 67,19%. Treći model predviđanja uključuje značajke *Ang1*, *Ang2*, *Ang3*, *UkupnoAng*, *VikendAkt*, *PrviIsplitUspjeh* i *VrijemeNaIsplitu*, te je ostvario točnost od 72,13%, preciznost 67,67%, odziv 72,13% i F1 mjeru 66,94%. Ostali modeli u skupu deset najbolje rangiranih, uključujući i jedini model temeljen na umjetnoj neuronskoj mreži (MLP), pokazali su vrlo slične performanse. Ovo ukazuje na to da povećanje broja značajki ne dovodi nužno do boljih rezultata. Unatoč razlikama u korištenim značajkama, metrike vrednovanja ostaju unutar relativno uskog raspona: razlika između najboljeg i desetog modela iznosi 1,40% u točnosti, 4,20% u preciznosti, 1,40% u odzivu te 1,41% u F1 mjeri.

DODATNA ANALIZA SKALIRANJA ZNAČAJKI

Radi dodatne provjere modela, na deset najboljih kombinacija značajki dodatno su primijenjene klasične metode skaliranja značajki: Z-score standardizacija i Min-Max skaliranje. Z-score standardizacija primijenjena je na značajke koje imaju veći raspon i standardnu devijaciju *Ang1*, *Ang2*, *Ang3*, *UkupnoAng*, *Akt*, *TjedneAkt*, *VikendAkt*, *VrijemeNaIsplitu* dok je Min-Max skaliranje primijenjeno na značajku *PrviIsplitUspjeh*, budući da ima prirodno ograničen raspon od 0 do 100.

Rezultate skaliranih modela prikazuje Tablica 13. Modeli su trenirani na isti način kao i u prethodnoj analizi, uz korištenje istih algoritama (RF i MLP) i istih kombinacija značajki.

Tablica 13 Rezultati skaliranih modela

Algoritam	Točnost	Preciznost	Odziv	F1	Korištene značajke
RF	71,19%	64,66%	71,19%	66,1%	<i>Ang1, Ang2, Ang3, VikendAkt, PrviIspitUspjeh, VrijemeNaIspitu</i>
RF	70,73%	65,69%	70,73%	65,95%	<i>Ang1, Ang3, Akt, VikendAkt, VrijemeNaIspitu</i>
RF	70,96%	64,92%	70,96%	65,87%	<i>Ang1, Ang2, Ang3, UkupnoAng, VikendAkt, PrviIspitUspjeh, VrijemeNaIspitu</i>
RF	71,19%	64,47%	71,19%	65,0%	<i>Ang1, Ang2, Ang3, UkupnoAng, Akt, VikendAkt, PrviIspitUspjeh, VrijemeNaIspitu</i>
RF	69,09%	62,59%	69,09%	63,87%	<i>Ang1, Ang3, VikendAkt, VrijemeNaIspitu</i>
RF	70,02%	65,81%	70,02%	66,95%	<i>Ang1, Ang2, PrviIspitUspjeh</i>
MLP	69,56%	62,27%	69,56%	62,96%	<i>Ang1, Ang2, Ang3, UkupnoAng, Akt, TjedneAkt, PrviIspitUspjeh</i>
RF	70,02%	61,57%	70,02%	63,83%	<i>Ang1, Ang3, UkupnoAng, Akt, VikendAkt, VrijemeNaIspitu</i>
RF	69,32%	61,98%	69,32%	63,61%	<i>Ang1, Ang2, Ang3, UkupnoAng, TjedneAkt, VikendAkt, PrviIspitUspjeh, VrijemeNaIspitu</i>

Rezultati analize pokazali su da modeli trenirani na podacima skaliranim po tjednima postižu bolje rezultate u usporedbi s modelima treniranim na podacima skaliranim Z-score ili Min-Max metodom. Usporedba točnosti, preciznosti, odziva i F1 mjere pokazuje blagi pad performansi kod svih modela koristeći klasične metode skaliranja. Ovi nalazi potvrđuju opravdanost odabrane metode skaliranja, temeljene na kontekstu nastavnog procesa, jer takva metoda zadržava realne odnose među podacima u skladu s tjednim ritmom aktivnosti studenata.

RASPRAVA

Istraživanje je pokazalo da ključne značajke koje imaju najveći prediktivni značaj za uspjeh studenata u učenju programiranja uključuju broj prenesenih materijala (*Ang1*), broj pregledanih materijala (*Ang2*), broj riješenih kvizova (*Ang3*), vrijeme provedeno na ispitu (*VrijemeNaIspitu*), broj aktivnosti tijekom vikenda (*VikendAkt*) i rezultat na prvom ispitu (*PrviIspitUspjeh*).

Značajke koje su direktno povezane sa materijalima i zadacima dodijeljenim studentima: broj materijala koje je student prenio (*Ang1*), broj pregledanih materijala (*Ang2*) i broj riješenih kvizova (*Ang3*) jasno reflektiraju interakciju i angažiranost studenata te pružaju uvid u njihove kompetencije u specifičnim domenama stoga ne iznenađuje činjenica kako imaju najveći prediktivni značaj.

Vrijeme provedeno na ispitu (*VrijemeNaIsplitu*) pokazalo se važnim prediktorom koji, u kombinaciji s drugim značajkama, može ukazivati na razinu razumijevanja gradiva ili na moguće poteškoće u njegovom usvajanju. Kontinuirana i dosljedna aktivnost studenata na LMS-u, kao što su aktivnosti tijekom vikenda (*VikendAkt*) također ima veliki prediktivni značaj jer ukazuje na sustavan pristup učenju. Ovakvo ponašanje može upućivati na višu razinu motivacije, samostalnosti i odgovornosti u učenju, što pozitivno utječe na njihov uspjeh.

Rezultat na prvom ispitu (*PrviIsplitUspjeh*) također je važna značajka jer daje uvid u početnu razinu znanja studenta. Visok rezultat može ukazivati na dobro razumijevanje gradiva od samog početka, što često vodi većoj uspješnosti u nastavku kolegija. Njegova prisutnost u većini najboljih modela potvrđuje njegov prediktivni značaj.

Time je odgovoreno na prvo istraživačko pitanje (IP 1), a ujedno je ostvaren Podcilj 1.1, koji se odnosio na identifikaciju ključnih pokazatelja uspješnosti putem analize obrazovnih podataka generiranih tijekom nastavnog procesa.

Najuspješniji model temeljen na algoritmu RF postigao je točnost od 72,83%, preciznost 69,44%, odziv 72,83% i F1 mjeru 68,06%, koristeći značajke *Ang1*, *Ang2*, *Ang3*, *VikendAkt*, *PrviIsplitUspjeh* i *VrijemeNaIsplitu*. Ovaj model je implementiran u LAD-s za predviđanje uspjeha studenata na kolegiju *Programiranje 1*. U proučenoj literaturi, analiza vrednovanja LAD-ova pokazuje da nastavnici ponekad iskazuju skepsu prema modelima predviđanja. Kako bi se omogućila usporedba i bolje razumijevanje rezultata, odlučeno je implementirati najbolja tri modela predviđanja u alat LAD-t. Nastavnicima je omogućena transparentnost pri odabiru modela, uz isticanje da različite kombinacije značajki mogu rezultirati vrlo sličnim performansama. Na taj je način ostvaren Podcilj 1.2, koji se odnosio na izgradnju i vrednovanje modela predviđanja uspjeha studenata.

U ovom istraživanju korišten je skup podataka od 427 studenata. Iako na prvi pogled broj studenata može izgledati malen, važno je napomenuti da je kontekst predviđanja uspjeha

specifičan za kolegij *Programiranje I*. Prema Essa & Ayad (2012) različiti modeli predviđanja daju različite rezultate na različitim kolegijima, stoga je ovaj rad usmjeren na izgradnju modela u ovom specifičnom kontekstu. Također, uzeti su u obzir isključivo podatci koje su studenti generirali tijekom korištenja Moodle LMS-a, bez dodatnih demografskih podataka studenata, a predviđanje ocjene u tri kategorije dodatno otežava zadatak u usporedbi s predviđanjem na binarnoj ljestvici. Usporedba s prethodnim istraživanjima dodatno podržava naš pristup: Bernacki i ostali (2020) sa skupom podataka od 337 studenata postižu točnost od 63,2%, Altabrawee i ostali (2019) sa 161 studentom postižu točnost od 66,5%, dok Francis & Sasidhar Babu (2019) bilježe točnost od 64,2%. Rezultati našeg modela (najbolji model: 72,83% točnosti) nadmašuju rezultate prethodnih istraživanja, potvrđujući njegovu opravdanost i učinkovitost u specifičnom obrazovnom okruženju.

5.4. VREDNOVANJE

U ovoj fazi prikazujemo rezultate vrednovanja alata LAD-s i LAD-t.

5.4.1. VREDNOVANJE LAD-S

Ovo potpoglavlje predstavlja drugo istraživanje u sklopu disertacije, usmjereno na odgovor na drugo istraživačko pitanje (IP 2): **Kakva je percepcija studenata o učinkovitosti nadzorne ploče analitike učenja?**

R. Bodily & Verbert (2017) su istaknuli kako istraživanja o nadzornim pločama analitike učenja imaju ograničenja u procjeni promjena ponašanja studenata, kao i u dokazivanju ukupne učinkovitosti alata. Pitanje povjerenja studenata u alate analitike učenja pokazalo se kao važan aspekt za njihovu uspješnu implementaciju (Greller & Drachsler, 2012).

U skladu s navedenim, cilj ovog istraživanja je ispitati subjektivne percepcije studenata o učinkovitosti alata LAD-s: razina zadovoljstva korištenim alatom, percepcija promjene u ponašanju, razumijevanje prikazanih podataka, učinak na učenje te razvoj samosvijesti i refleksije nakon jednog semestra korištenja alata u nastavi. Iako je istraživanje primarno usmjereno na ispitivanje percepcije studenata kolegija *Programiranje 1*, također je provedeno i sa studentima kolegija *Sustavi e-učenja*, s obzirom na to da se alat LAD-s može primijeniti u različitim obrazovnim kontekstima i kolegijima.

U istraživanju su obuhvaćeni studenti sa PMFST-a tijekom zimskog semestra akademske godine 2021/2022 na kolegiju *Programiranje 1* i *Sustavi e-učenja*. U toj je akademskoj godini upisano 175 studenata na kolegij *Programiranje 1*. Iako je na kolegiju bilo 175 studenata, ispunjavanju upitnika je pristupilo 19 studenata. U istoj je akademskoj godini upisano 53 studenta na kolegij *Sustavi e-učenja*, a ispunjavanju upitnika je pristupilo 14 studenata.

INSTRUMENTI

Kako bi odgovorili na postavljeno istraživačko pitanje primijenjeni su sljedeći instrumenti: upitnik A1, upitnik A2, upitnik A3 i dva pitanja otvorenog tipa. Odgovori na tvrdnje u upitnicima ocjenjivani su Likertovom skalom od 1 do 5 (1 – u potpunosti se ne slažem, 5 – u potpunosti se slažem), pri čemu su ispitanici izražavali stupanj slaganja s tvrdnjama.

- A1 - Za procjenu percepcije razumijevanja podataka, samosvijesti i refleksije te učinka na učenje nakon korištenja alata u obrazovnom okruženju LAD-s korišten je upitnik *Okvir za vrednovanje analitike učenja* (engl. Evaluation Framework for Learning Analytics, EFLA) (Scheffel, 2017). Ovaj instrument se može koristiti u različitim kontekstima za implementaciju, vrednovanje i unaprjeđenje LA alata. Upitnik ima tri dimenzije. Dimenzija „Samosvijest i refleksija“ odnosi se na sposobnost studenata da pomoću nadzorne ploče analitike učenja prepoznaju vlastite snage i slabosti te razmišljaju o svom procesu učenja. Dimenzija „Učinak na učenje“ mjeri percepciju studenata o tome koliko nadzorna ploča analitike učenja doprinosi njihovoj efikasnosti u učenju i općem uspjehu. Dimenzija „Razumijevanje podataka“ odnosi se na sposobnost studenata da interpretiraju prikazane podatke i izvuku zaključke korisne za svoj akademski napredak. Prilog upitnika korištenog u ovom istraživanju nalazi se u Prilogu C1.
- A2 - Za procjenu promjena u ponašanju tijekom korištenja LAD-a korišten je upitnik (Park & Jo, 2015), koji mjeri promjene u ponašanju nastale korištenjem LAD-s. Upitnik se sastoji od šest izjava, a nalazi se u Prilogu C2.
- A3 - Standardizirani upitnik, System Usability Scale (SUS), koji se sastoji od deset tvrdnji ocijenjenih na Likertovoj ljestvici s pet stupnjeva (Brooke, 1996) za mjerenje zadovoljstva studenata sa LAD-s. SUS rezultat se računa kao postotak, dok se pojedina pitanja ne analiziraju zasebno. Iako autor SUS upitnika nije dao jasna tumačenja rezultata, u ovom istraživanju koristi se kompletna skala ocjena za interpretaciju rezultata prema Bangor i ostali (2008). Primjer upitnika korištenog u ovom istraživanju nalazi se u Prilogu C3.

Dodatno su osmišljena dva pitanja otvorenog tipa kako bi se prikupile informacije o subjektivnom iskustvu studenata. *Prvo pitanje* usmjereno je na analizu ključnih komponenti LAD-s alata. U okviru ovog pitanja, „Podaci o aktivnostima“ predstavljaju komponentu aktivnosti, „Podaci o uspjehu“ odražavaju komponentu uspjeha, dok „Predvidi svoj uspjeh“ odražava komponentu predviđanja. Pitanje glasi: „Nadzorna ploča analitike učenja ima tri komponente: „Podaci o aktivnostima“, „Podaci o uspjehu“ i „Predvidi svoj uspjeh“. Koji je od ovih pogleda najvažniji te molimo obrazložite svoj odabir?“ *Drugo pitanje* potiče studente da kritički sagledaju trenutnu verziju nadzorne ploče analitike učenja, tražeći od njih da navedu koje bi elemente dodali: „Što biste dodali, a ne nalazi se na trenutnoj nadzornoj ploči analitike učenja?“. Ovim pitanjem

cilj je identificirati aspekte za poboljšanje koji nisu bili obuhvaćeni prethodno opisanim upitnicima.

METODE OBRADE PODATAKA ISTRAŽIVANJA

Za izračun SUS rezultata korišten je online kalkulator⁴ koji primjenjuje standardnu metodu bodovanja. Ostali prikupljeni podaci analizirani su deskriptivnim statističkim metodama; izračunati su prosječni rezultati (M) i standardna devijacija (SD), te je provjerena interna pouzdanost mjernih instrumenata izračunom Cronbachova alfa koeficijenta. U ovom se radu koristi ljestvica prema George & Mallery (2003), u kojoj se vrijednosti Cronbachova alfa koeficijenta iznad 0,9 smatraju izvrsnima, iznad 0,8 dobrima, iznad 0,7 prihvatljivima, iznad 0,6 upitnima, iznad 0,5 slabima, dok se vrijednosti ispod 0,5 smatraju neprihvatljivima (str. 231).

Kako bismo osigurali točnost interpretacije kompozitnih rezultata dobivenih Likertovom skalom, primijenjena je klasifikacija intervala od pet stupnjeva prema Alkharusi (2022) koja omogućuje jasnije tumačenje srednjih vrijednosti odgovora u istraživanjima u području obrazovanja i psihologije. Tablica 14 prikazuje korištenu klasifikaciju.

Tablica 14 Skala za interpretaciju srednjih vrijednosti stavova izraženih na Likertovoj skali [pripremljeno prema (Alkharusi, 2022)]

Raspon intervala	Srednja vrijednost intervala	Tumačenje
1,00 – 1,80	1,40	Vrlo niska razina slaganja
1,81 – 2,61	2,21	Niska razina slaganja
2,62 – 3,42	3,02	Umjerena razina slaganja
3,43 – 4,23	3,83	Visoka razina slaganja
4,24 – 5,00	4,64	Vrlo visoka razina slaganja


TIJEK ISTRAŽIVANJA

LAD-s je implementiran u okviru kolegija *Programiranje I i Sustavi e-učenja*, koji su se realizirali u obliku mješovite (hibridne) nastave na PMFST-u, na preddiplomskom studiju tijekom zimskog semestra akademske godine 2021./2022. kako bi studenti tijekom semestra mogli pratiti informacije o svom napretku.

⁴ System Usability Scale (SUS) kalkulator: <https://blucado.com/sus-calculator/>

U fazi planiranja pripremljene su video upute. Njihova svrha bila je pomoći studentima da razumiju način korištenja i funkcionalnosti alata. U tim uputama prikazane su sve tri komponente LAD-s alata (komponenta aktivnosti, komponenta uspjeha i komponenta predviđanja), uz jasno ilustrirane primjere gdje i kako se pojedine funkcionalnosti primjenjuju. Važno je napomenuti da studenti nisu poticani na korištenje LAD-s tijekom semestra, osim u uvodnom dijelu, kada su im predstavljeni svrha i način uporabe alata.

U akademskoj godini 2021/2022, semestar je započeo u rujnu 2021. godine, a LAD-s je implementiran u listopadu 2021. godine. Nastavu provode profesor i dva asistenta, dok je istraživač angažiran radi rješavanja eventualnih problema te ručnog bilježenja ispunjavanja zadanih ishoda vezanih uz nastavni sadržaj u sustavu Moodle. Alat je integriran u Moodle LMS kao plugin (u .rar formatu) te je povezan s kolegijem kako bi bio vidljiv i dostupan studentima. Završetak semestra smatra se krajem korištenja alata, nakon čega slijedi faza prikupljanja podataka. “Nakon višemjesečne upotrebe LAD-s u navedenom kolegiju, prikupljeni su podaci o iskustvu studenata putem anketnog upitnika, dobrovoljno i anonimno. Studentima je putem Google Forms omogućen pristup pripremljenim upitnicima. Slika 38 prikazuje vremenski slijed provedbe istraživanja.



Slika 38 Vremenski slijed provedbe istraživanja o percepciji učinkovitosti alata LAD-s

REZULTATI

Rezultati prikupljeni anketnim upitnikom za potrebe preciznije interpretacije prikazani su odvojeno za kolegij *Programiranje 1* i *Sustavi e-učenja*.

Za kolegij programiranje 1, Izračun Cronbachova alfa koeficijenta za upitnik A1 ($n = 19$) ukazuje na visoku internu konzistentnost instrumenta (Cronbach $\alpha = 0,91$), čime je potvrđena njegova pouzdanost. Tablica 15 prikazuje prosječne rezultate (M) i standardne devijacije (SD) za sve tri dimenzije upitnika.

Tablica 15 Deskriptivna statistika anketnih odgovora – upitnik A1

Dimenzija upitnika A1	M	SD
Samosvijest i refleksija	2,67	1,31
Učinak na učenje	2,79	1,40
Razumijevanja podataka	3,16	1,31

Analiza rezultata upitnika A1 pokazuje da su sve tri ispitivane dimenzije ocijenjene s umjerenom razinom slaganja, prema Tablica 14. Najnižu prosječnu ocjenu zabilježila je dimenzija „Samosvijest i refleksija“ ($M = 2,67$; $SD = 1,31$), dok su „Učinak na učenje“ ($M = 2,79$; $SD = 1,40$) i „Razumijevanje podataka“ ($M = 3,16$; $SD = 1,31$) ostvarile nešto više, ali i dalje unutar istog interpretacijskog raspona. Standardne devijacije kretale su se od 1,31 do 1,40, što ukazuje na umjerenu do veću varijabilnost odgovora i razlike u iskustvima među studentima.

Izračun Cronbachova alfa koeficijenta za upitnik A2 ($n = 19$) ukazuje na visoku internu konzistentnost instrumenta (Cronbach $\alpha = 0,90$), čime je potvrđena njegova pouzdanost. U Tablica 16 izračunati su prosjek (M) i standardna devijacija (SD), što daje uvid u prosječne vrijednosti i odstupanja među odgovorima.

Tablica 16 Deskriptivna statistika anketnih odgovora – upitnik A2

Dimenzija upitnika A2	M	SD
Promjena u ponašanju	2,76	1,21

Dimenzija „Promjena u ponašanju“ ocijenjena je s $M = 2,76$ ($SD = 1,21$), što se također klasificira kao umjerena razina slaganja, ali bliže donjoj granici. Rezultati upitnika A3 (SUS) iznosili su 56,97. Ova vrijednost je između „U redu“ (engl. OK) i „dobro“ (engl. good) prema (Bangor i ostali, 2008), no bliža „U redu“, što je prilično niska razina zadovoljstva.

Analiza odgovora na pitanje „Koji je po vašem mišljenju najvažniji pogled na nadzornu ploču i zašto?“ (na temelju 14 odgovora, ostali studenti nisu napisali odgovor)

- Najveći broj ispitanika (8 od 14, tj. 57%) preferira komponentu 'uspjeh' koja je u više odgovora prepoznata kao ključna za vrednovanje vlastitog napretka, jer studentima omogućuje pregled vlastitih rezultata. Jedan od ispitanika obrazložio je to ovako: „*Podaci o uspjehu jer tako vidimo koliko smo imali znanja u nečemu.*“
- Tri ispitanika (3 od 14, tj. 21%) odabrala su komponentu 'predviđanje', a u svojim odgovorima ističu da predviđanje buduće ocjene može poslužiti kao poticaj za motivaciju, samoregulaciju i planiranje učenja. Primjer odgovora: „*Predvidi svoj uspjeh jer na kraju kolegija dobro prikaže.*“ ; „*Predvidi svoj uspjeh. Svatko više-manje zna koliko vremena ulaže u koji kolegij i kako „ga ide“. Međutim predviđanje buduće ocjene može ih osvijestiti - ako se moraju trgnuti, ili ako se mogu opustiti i posvetiti drugim kolegijima.*“
- Jedan ispitanik (1 od 14, tj. 7%) istaknuo je komponentu aktivnosti kao najvažniji pogled bez obrazloženja.

Analiza odgovora na pitanje „Što biste dodali, a ne nalazi se na trenutnoj nadzornoj ploči analitike učenja?“ pokazuje sljedeći raspored (na temelju 6 odgovora, ostali studenti nisu napisali odgovor):

- Većina ispitanika (5 od 6, tj. 83 %) navela je da ne bi dodavala ništa, s komentarima poput „Ništa“, „Ništa. Ima sve potrebno“.
- Jedan ispitanik (1 od 6, tj. 17 %) dao je detaljniji odgovor u kojem je predložio mogućnost dodavanja funkcionalnosti za samostalan upis sati posvećenih kolegiju. Primjer odgovora: „*Možda nekakav dio za samostalan upis npr. sati posvećenih kolegiju (sa strane e-learninga, memory-ja itd.); tako da se i to uračuna u količinu truda, jer ja osobno više učim samostalno pomoću materijala nego li online s kvizovima.*“

Za kolegij sustavi e-učenja, izračun Cronbachova alfa koeficijenta za upitnik A1 ($n = 14$) ukazuje na visoku internu konzistentnost instrumenta (Cronbach $\alpha = 0,91$), čime je potvrđena njegova pouzdanost. U Tablica 17 za svaku dimenziju izračunati su prosjek (M) i standardna devijacija (SD), što daje uvid u prosječne vrijednosti i odstupanja među odgovorima.

Tablica 17 Deskriptivna statistika anketnih odgovora – upitnik A1

Dimenzija upitnika	M	SD
A1		
Samosvijest i refleksija	4,05	0,90
Učinak na učenje	3,86	1,04
Razumijevanja podataka	4,21	1,07

Analiza rezultata upitnika A1 pokazuje da su sve tri ispitivane dimenzije ocijenjene s visokom razinom slaganja, prema Tablica 14. Najvišu prosječnu ocjenu ostvarila je dimenzija „Razumijevanje podataka“ ($M = 4,21$; $SD = 1,07$). Dimenzije „Samosvijest i refleksija“ ($M = 4,05$; $SD = 0,90$) te „Učinak na učenje“ ($M = 3,86$; $SD = 1,04$) također su visoko ocijenjene. Standardne devijacije kretale su se od 0,90 do 1,07, što upućuje na umjerenu varijabilnost odgovora i općenito ujednačenije iskustvo među studentima.

Izračun Cronbachova alfa koeficijenta za upitnik A2 ($n = 14$) ukazuje na visoku internu konzistentnost instrumenta (Cronbach $\alpha = 0,91$), čime je potvrđena njegova pouzdanost. U Tablica 18 izračunati su prosjek (M) i standardna devijacija (SD), što daje uvid u prosječne vrijednosti i odstupanja među odgovorima.

Tablica 18 Deskriptivna statistika anketnih odgovora – upitnik A2

Dimenzija upitnika A2	M	SD
Promjena u ponašanju	3,50	1,28

Dimenzija „Promjena u ponašanju“ ocijenjena je s $M = 3,50$ ($SD = 1,28$), što se također klasificira kao visoka razina slaganja, ali bliže donjoj granici. Rezultati upitnika SUS iznosili su 69,20, što prema (Bangor i ostali, 2008), odgovara kategoriji „dobro“, ali se nalazi na donjoj granici te kategorije.

Analiza odgovora na pitanje „Koji je po vašem mišljenju najvažniji pogled na nadzornu ploču i zašto?“ (na temelju 13 odgovora, dok jedan sudionik nije napisao odgovor) pokazuje nekoliko jasno izraženih preferencija.

- Najveći broj ispitanika (8 od 13, tj. 61,53%) naveo je da su podaci o uspjehu najvažniji pogled na nadzornoj ploči. Ova komponenta najčešće se opisivala kao ključna za praćenje napretka, vrednovanje vlastitih postignuća i usporedbu s kolegama. U nekim odgovorima dodatno se ističe njezin utjecaj na motivaciju i samopouzdanje, ali i mogući pritisak koji proizlazi iz uspoređivanja. Primjeri uključuju: „Podaci o uspjehu jer tako vidimo koliko smo imali znanja u nečemu.“; „Na jednom mjestu imam rezultate svih provjera koje smo rješavali, mogu usporediti svoje rezultate s rezultatima kolega.“; „Iako najvažniji, opet smo forsirani da se uspoređujemo s ostalim kolegama u grupi.“
- Tri ispitanika (3 od 13, tj. 23,07%) istaknula su komponentu aktivnosti kao najvažniji pogled. U tim odgovorima naglašava se vrijednost praćenja angažmana, otkrivanja zaostataka i uvida u organiziranost vlastitog rada. Ova komponenta percipira se kao koristan alat za upravljanje vremenom i odgovornostima. Primjer uključuje: „Zato što mogu na jednom mjestu vidjeti jesam li u nekom zaostatku i što je ostalo nedovršeno.“
- Dva odgovora (2 od 13, tj. 15,38%) odnosila su se na komponentu predviđanja, jednu samostalno, a jednu u kombinaciji s podacima o uspjehu. Primjeri uključuju: „Predvidi svoj uspjeh jer na kraju kolegija dobro prikaže.“; „Podaci o uspjehu i predvidi svoj uspjeh, jer je direktan uvid kako stojimo s kolegijem.“

Analiza odgovora na pitanje „Što biste dodali, a ne nalazi se na trenutnoj nadzornoj ploči analitike učenja?“ (na temelju 6 odgovora, dok ostali studenti nisu naveli prijedloge) pokazuje relativno nizak broj konkretnih sugestija, ali i nekoliko korisnih smjernica za moguće unaprjeđenje sučelja LAD-s alata:

- Većina ispitanika (4 od 6, tj. 67%) navela je da ne bi dodavala ništa ili nije imala konkretan prijedlog. Odgovori poput „Ništa“, „Ne znam“, te „Ne bih ništa dodavao, ali bi dobro bilo da sučelje nije grafički jednostavno nego da je malo grafički zanimljivije za oko“.
- Jedan ispitanik (1 od 6, tj. 17%) predložio je uvođenje naprednih opcija i filtriranja, uključujući stranicu s postavkama gdje bi korisnici mogli *uključiti ili isključiti usporedbu vlastitih rezultata s drugima*, te *filtrirati koje podatke žele prikazati (npr. samo prvi test ili ukupni rezultat)*.
- Jedan odgovor (1 od 6, tj. 17%) osvrće se na postojeći pogled prikaza aktivnosti, uz komentar: „Neki studenti su učili kroz sustav pa imaju više logiranja u odnosu na druge koji su preuzeli materijale na računalo“.

RASPRAVA

Rezultati provedenog istraživanja ukazuju na razlike u percepciji učinkovitosti alata LAD-s, ovisno o kontekstu implementacije, odnosno o kolegiju u okviru kojeg je alat korišten.

U kolegiju *Programiranje I*, sve dimenzije ocijenjene su umjerenom razinom slaganja. Najniže je ocijenjena dimenzija „Samosvijest i refleksija“ ($M = 2,67$), što sugerira umjeren doprinos alata u poticanju metakognitivnih procesa. Nešto viši, ali i dalje unutar istog raspona, zabilježeni su rezultati za dimenziju „Učinak na učenje“ ($M = 2,79$), „Razumijevanje podataka“ ($M = 3,16$) te „Promjena u ponašanju“ ($M = 2,76$). SUS rezultat od 56,97 dodatno ukazuje na djelomično zadovoljstvo studenata LAD-s alatom. Kvalitativni nalazi pokazuju kako studenti najviše cijene komponentu uspjeha, a potom komponentu predviđanja, dok studenti većinom komentiraju kako ne bi ništa dodavali, osim jednog studenta koji sugerira samostalan upis korištenja.

Ovakvi rezultati mogu se objasniti prirodom kolegija, koji je zahtjevan i uvodi studente u kompleksne koncepte programiranja. Studenti početnici često se suočavaju s nesigurnošću, stresom i visokim kognitivnim opterećenjem, što može utjecati na njihovu sposobnost

interpretacije podataka iz LAD-s alata ili motivaciju za korištenje istog kao alata za samoregulaciju. LAD-s je u tom kontekstu vjerojatno percipiran više kao pasivni informacijski resurs, a manje kao aktivni alat za podršku učenju. Dodatno, istraživanje (R. Bodily i ostali, 2018) pokazuje da deskriptivna analitika iako korisna, često nije dovoljna za poticanje konkretnih obrazovnih promjena, te da je za stvarno unapređenje učenja nužna preskriptivna analitika, koja studentima pruža jasne i personalizirane preporuke za daljnje korake, poput prilagodbe tempa učenja ili sudjelovanja u specifičnim nastavnim aktivnostima. S obzirom na prirodu kolegija kao što je *Programiranje 1*, potrebno je implementirati preskriptivne elemente u LAD-s, kako bi se studentima omogućila konkretnija podrška u učenju

Studenti kolegija *Sustavi e-učenja* pokazali su visoku razinu slaganja u svim ispitivanim dimenzijama upitnika A1 i A2. Najviši rezultat ostvaren je u dimenziji „Razumijevanje podataka“ ($M = 4,21$), zatim slijede „Samosvijest i refleksija“ ($M = 4,05$), „Učinak na učenje“ ($M = 3,86$) i „Promjena u ponašanju“ ($M = 3,50$). Dodatno, SUS rezultat 69,20 potvrđuje da je LAD-s u ovom kontekstu percipiran kao funkcionalan i informativan alat koji pomaže u praćenju napretka ali ima prostora za unapređenje. Ovakvi rezultati mogu biti povezani s karakteristikama studenata i samog kolegija, koji je više orijentiran na tehnologije u obrazovanju, gdje su studenti digitalno kompetentniji i skloniji korištenju alata poput LAD-s. Dodatno, istraživanje Kaur & Chahal (2024) pokazuje da dosljedna i smisleno integrirana upotreba LAD alata dovodi do pozitivnih promjena u ponašanju, što je i u ovom istraživanju vidljivo kroz visoke rezultate u dimenziji promjene ponašanja ($M = 3,50$).

Na temelju provedenog istraživanja i prikupljenih podataka, oblikovana je slika o percepciji učinkovitosti LAD-s alata iz studentske perspektive, uz izražene razlike među kolegijima. Ove razlike ne proizlaze nužno samo iz sadržaja i konteksta pojedinog kolegija, već su povezane i s karakteristikama samih studenata. Studenti su pripadali različitim godinama studija, čime se razlikuju u dobi i zrelosti, a zasigurno postoje i razlike u motivaciji za studij, što je moglo utjecati na način korištenja alata i njegovu percipiranu učinkovitost.

Rezultati pokazuju da je alat percipiran kao umjereno učinkovit u kolegiju *Programiranje 1*, dok je u kolegiju *Sustavi e-učenja* ocijenjen kao vrlo učinkovit. Na taj je način istraživanje dalo konkretan odgovor na drugo istraživačko pitanje (IP 2) te otvorilo prostor za ciljana poboljšanja alata.

Ovakvi nalazi, u kojima su razlike među studentima u načinu uporabe alata jasno izražene, podudaraju se s rezultatima prethodnih istraživanja Broos i ostali (2017) te Duan i ostali (2022). Također, nalazi ovog istraživanja potvrđuju zaključke De Quincey i ostali (2019) o potrebi za prilagodbom LAD sučelja i funkcionalnosti prema specifičnim potrebama pojedinog kolegija i profila studenata. U tom smislu, preporučuje se:

- Uključivanje preskriptivne analitike u LAD-s, koje bi studentima nudile konkretne preporuke za daljnje korake;
- Veća vidljivost i integracija LAD-a u svakodnevni nastavni proces;
- Povećanje fleksibilnosti prikaza podataka, omogućavanjem studentima da samostalno odaberu koje povratne informacije žele vidjeti kako bi LAD-s bio prilagođen njihovim individualnim preferencijama i potrebama za učenjem.

Pri interpretaciji rezultata potrebno je uzeti u obzir valjanost i pouzdanost provedenog istraživanja. Pouzdanost mjernih instrumenata potvrđena je izračunom Cronbachova alfa koeficijenta. Svi korišteni instrumenti pokazali su zadovoljavajuću internu konzistentnost. Time je smanjena vjerojatnost da su rezultati puki artefakt nesigurnog mjerenja ili nepouzdanih upitnih izjava.

Što se tiče valjanosti samih zaključaka istraživanja, potrebno je sagledati ograničenja i biti svjesni konteksta svrhe u kojem je istraživanje provedeno. Iako su studenti na kraju semestra nekoliko puta bili zamoljeni da ispune upitnike, istraživanje je provedeno na relativno malom uzorku ($n = 19$ za kolegij *Programiranje I* i $n = 14$ za kolegij *Sustavi e-učenja*). Izračuni margine pogreške dodatno pojašnjavaju razinu preciznosti rezultata. Za kolegij *Programiranje I* SUS iznosi 57,0 ($SD = 10,5$), uz 95 %-tni interval pouzdanosti od 52,3 do 61,7 ($ME = \pm 4,7$). Za kolegij *Sustavi e-učenja* SUS iznosi 69,2 ($SD = 13,8$), s intervalom od 62,1 do 76,5 ($ME = \pm 7,2$). Slično tome, za upitnike A1 i A2 margine pogreške kretale su se između $\pm 0,54$ i $\pm 0,63$ u slučaju kolegija *Programiranje I*, dok su kod kolegija *Sustavi e-učenja* bile u rasponu od $\pm 0,47$ do $\pm 0,67$. Nadalje, Tullis & Stetson (2006) pokazali su da se pri korištenju SUS upitnika već s podskupom od 12–14 slučajno odabranih ispitanika mogu dobiti rezultati jednako pouzdani kao i s punim uzorkom, te zaključuju da je takav broj dovoljan za valjanu procjenu zadovoljstva korisnika. Unatoč tim ograničenjima, ovo istraživanje pruža valjane početne pokazatelje LAD-s alata. Korišteni upitnici su ranije provjereni u sličnim kontekstima, što pridonosi konstruktnoj valjanosti. Ove rezultate treba promatrati kao eksplorativne nalaze koji potiču daljnja istraživanja, a ne kao konačne dokaze o korištenju LAD-s alata. Za pouzdanije utvrđivanje

trebalo bi pratiti studente kroz dulje razdoblje (longitudinalno).

Buduća istraživanja s većim brojem sudionika mogla bi pružiti robusnije uvide i dodatno potvrditi ove nalaze. Nadalje, podaci su prikupljeni isključivo putem samoprocjene studenata u anketi. Takva percepcijska mjerenja mogu sadržavati određene pristranosti zbog efekta društvene poželjnosti, koje smo smanjili jer studenti nisu poznavali istraživača, a ispunjavanje upitnika je bilo anonimno. Također, broj aktivnosti i vrijeme provedeno u sustavu često se koriste kao pokazatelji angažmana, no njihova pouzdanost može biti upitna. Dok neki ostavljaju sustav otvoren bez aktivne uporabe, drugi brzo prolaze kroz sadržaje bez duljeg zadržavanja, dok treći istovremeno obavljaju druge aktivnosti. Takva ponašanja mogu utjecati na točnost prikupljenih podataka. Pored toga, jedan od komentara studenata ukazuje i na preferenciju samostalnog učenja pomoću nastavnih materijala u odnosu na korištenje kvizova. Ovakvi uvidi potvrđuju raznolikost pristupa učenju i sugeriraju da alat ne može jednako odgovarati svim stilovima učenja. U ovom su istraživanju ti pokazatelji analizirani u svrhu identifikacije obrazaca ponašanja, no njihovo dublje tumačenje, kao i prilagodba alata različitim profilima studenata, izlazi iz okvira ovog rada i predstavlja smjer za buduće nadogradnje alata i daljnja istraživanja. Dodatno, korištenje LAD-s alata bilo je vremenski ograničeno na trajanje nastavnog semestra, čime nisu obuhvaćeni studenti koji se aktivnije uključuju tek uoči ispitnih rokova. Iako zanimljivo, ovo nije bila primarna svrha istraživanja.

Važno je naglasiti da primjena analitike učenja, uz svoje potencijale, nosi i određena ograničenja. Posebno se ističu etički i pravni aspekti, poput zaštite privatnosti studenata i transparentnosti u korištenju njihovih podataka (Greller & Drachsler, 2012). U ovom istraživanju korišteni su isključivo anonimizirani podaci iz Moodle LMS-a, čime je osigurana zaštita identiteta studenata. Ipak, svaka buduća primjena razvijenih modela i alata u stvarnom obrazovnom okruženju mora uzeti u obzir etičke standarde i osigurati da studenti budu informirani i da daju pristanak na korištenje podataka.

5.4.2. VREDNOVANJE LAD-T

Svrha ovog istraživanja je odgovoriti na treće istraživačko pitanje (IP 3) u okviru disertacije: **Kakva je upotrebljivost nadzorne ploče analitike učenja za nastavnike, te koji su mogući problemi u primjeni i smjernice za eventualna poboljšanja?**

Ovim istraživanjem nastoje se prepoznati i otkloniti eventualne prepreke u korištenju, čime se povećava vjerojatnost uspješne primjene LAD-t alata u praksi. To je važno jer upotrebljivost predstavlja preduvjet da nastavnici doista prihvate alat i učinkovito ga uključe u svoj rad.

Pojam upotrebljivost definiran je na različite načine od strane različitih standarda i istraživača. Nielsen (1994), pionir u području upotrebljivosti softvera, definira pet atributa dobre upotrebljivosti softvera kao, lakoća učenja (engl. learnability), učinkovitost (engl. efficiency), pamtljivost (engl. memorability), mali broj grešaka (engl. errors) i zadovoljstvo (engl. satisfaction). Definicija upotrebljivosti prema standardu ISO 9241-11 (ISO 9241-11:2018(en) Ergonomics of human-system interaction — Part 11: Usability: Definitions and concepts) najčešće se koristi u HCI praksi. Prema tom standardu, upotrebljivost je opseg u kojem određeni korisnik može uspješno (engl. effectively), učinkovito (engl. efficiently) i sa zadovoljstvom (engl. satisfaction) koristiti određeni proizvod da bi postigao specifične ciljeve u danom kontekstu. Objektivne mjere predstavljaju uspješnost (engl. effectiveness), učinkovitost (engl. efficiency), lakoća učenja (engl. learnability), pamtljivosti (engl. memorability) i mali broj grešaka (engl. errors), a subjektivna mjera je zadovoljstvo (engl. satisfaction).

Objektivne mjere uključuju kvantitativna mjerenja kao što su vrijeme potrebno za izvršavanje zadatka, broj pogrešaka koje korisnik napravi i učinkovitost korisnika, a subjektivne mjere dobivaju se kroz upitnike i ankete, gdje korisnici izražavaju svoje osobno mišljenje o upotrebljivosti i predstavljaju zadovoljstvo korisnika i njegovo prihvaćanje sustava (Nielsen, 2018). Općenito, mjere upotrebljivosti koje se koriste kod testiranja upotrebljivosti dijele se na (Dumas & Redish, 1999, str. 84; Rubin, 2008, str. 166) : mjere performansi (eng. performance measures) – objektivne mjere i mjere percepcije (eng. perception measures) – subjektivne mjere. Za vrednovanje LAD-t korištene su empirijske metode, konkretno metoda testiranja i metoda ispitivanja prema taksonomiji (Ivory & Hearst, 2001):

- Metoda testiranja uključuje promatranje korisnika dok obavljaju definirane zadatke, pri čemu se bilježe objektivne mjere kao što su vrijeme izvršenja zadataka i stopa uspješnosti (Ivory & Hearst, 2001). Prema Nielsen (1994) metode testiranja daju nam direktan uvid u to kako korisnici upotrebljavaju sučelje te na koje probleme nailaze pri interakciji sa sučeljem. Prema Nielsen & Landauer (1993), broj korisnika ovisi o broju problema koje želimo otkriti tijekom testiranja. Ako naginjemo manje formalnom testiranju, navodi se da je dovoljno testirati s barem 8 korisnika, a idealno 10-12 (Rubin, 2008). Jedna od metoda testiranja koja daje objektivne podatke o interakciji korisnika i sustava te problemima upotrebljivosti je metoda mjerenja performansi (eng. performance measurement) koja je korištena u ovom istraživanju.
- Metoda ispitivanja oslanja se na prikupljanje subjektivnih povratnih informacija putem upitnika, uz dodatne intervju i otvorena pitanja (Ivory & Hearst, 2001). Korisničko zadovoljstvo je subjektivna kategorija koja se najlakše ispituje upitnicima i mjeri pomoću Likertove ljestvice stavova.

FAZA PLANIRANJA

Kako bismo osigurali sve elemente potrebne za provođenje istraživanja, u fazi planiranja obratili smo pozornost na sljedeće aspekte:

OKRUŽENJE ZA TESTIRANJE

U ovom istraživanju koristi se testiranje od kuće odnosno iz uobičajenog okruženja u kojem nastavnici koriste LAD-s (tzv. field study). Imajući na umu da povratna informacija ne mora biti preslika stvarnog stanja, već se temelji na ozbiljnosti i iskrenosti ispitanika koji sudjeluje u istraživanju, korišteno je testiranje na daljinu (eng. remote testing), bez prisutnosti voditelja (moderatora), gdje se od korisnika tražilo da se drže protokola istraživanja koji im je poslan i između ostalog pripreme okruženje za snimanje prema uputama.

Za potrebe istraživanja kreiran je račun na platformi Digital Ocean⁵, na kojem je postavljen Moodle LMS, a zatim je rekonstruiran kolegij identičan kolegiju *Programiranje 1*. Umjesto kupnje vlastite domene, korišten je URL: <http://164.92.240.5/moodle/>, koji je trenutno deaktiviran a bio je dostupan isključivo za potrebe istraživanja. Ovo kreirano okruženje služilo

⁵ DigitalOcean | Cloud Infrastructure for Developers

je nastavnicima za vrednovanje LAD-t. Na sustavu Moodle za nastavnike su izrađeni korisnički računi te su dodani na kolegij kako bi mogli pristupiti alatu i sudjelovati u istraživanju.

SCENARIJI I ZADACI

Posebna pozornost pri izradi uputa posvećena je definiranju scenarija temeljenih na zadatku (eng. task scenarios). Scenariji mogu biti temeljeni na zadacima, pitanjima ili pričama s različitim razinama detaljnosti (Plantak Vukovac, 2012). Scenarij temeljen na zadacima odnosi se na kratke opise zadataka koje korisnik treba napraviti da bi postigao određeni cilj, npr. u komponenti predviđanja LAD-t pronaći informacije o zadovoljenju ishoda. Konkretno, zanimali su nas zadaci koji su usmjereni na funkcionalnosti LAD-t, stoga naši zadaci služe identificiranju povratnih informacija na LAD-t u svrhu prepoznavanja studenata kojima je potrebna pomoć.

MJERENJE VREMENA IZVRŠENJA ZADATKA

Budući da se tražilo snimanje ekrana tijekom obavljanja zadataka, sudionici su pratili zadatke napisane u word dokumentu pod nazivom „Zadaci“, pri čemu im je predloženo korištenje *Xbox Game Bar*-a, no mogli su koristiti i drugu alternativu za snimanje. S obzirom da LAD-t ima tri komponente, nastavnicima je precizno određeno koju komponentu koristiti (to je postavljeno kao zadatak, kako bi se ispitala mogućnost navigacije), a potom su im postavljeni zadaci unutar svake komponente. Nastavnik treba moći odrediti funkcionalnost LAD-t i ispravno je upotrijebiti kako bi riješio zadatak. Nije važno zna li nastavnik što spada u koju komponentu, već zna li koristiti funkcionalnosti na određenim komponentama. Zadaci se nalaze u Prilogu D1.

Neki zadaci su se samo pratili izvršavanjem, a na neke su sudionici trebali napisati odgovore. Za prvi zadatak, vrijeme se mjeri od trenutka kada nastavnik otvori word dokument pod nazivom „Zadaci“, a zatim se prati izvršenje zadatka, tek kada nastavnik prijeđe na idući zadatak, počinje se pratiti vrijeme za drugi zadatak.

PILOT TESTIRANJE

U svrhu dobre pripreme za istraživanje s nastavnicima provedeno je (pred)pilot istraživanje s dva nastavnika kako bi se provjerilo je li sve funkcionira, te da se uklone greške u koracima i prilagodi procedura, slijedeći smjernice (Sauro, 2010) o vremenu trajanja sesije, broju zadataka i slično. Za ispunjavanje upitnika korišten je Google Forms. Također, naglašeni su etički aspekti

istraživanja te činjenica da se ispitanik može povući iz istraživanja bez posljedica.

MJERE UPOTREBLJIVOSTI

Za vrednovanje LAD-t alata korištene su sljedeće kvantitativne mjere:

- Mjere uspješnosti (engl. effectiveness): Točnost obavljanja zadataka (engl. Accuracy of task completion) pokazuje koliko su točno i uspješno korisnici dovršili zadatke. Prema (Sauro, 2010) poželjno je da stopa uspješno dovršenih zadataka bude iznad 78%.
- Mjere učinkovitosti (engl. efficiency): Objektivna mjera učinkovitosti korištenja sustava predstavlja vrijeme dovršetka zadataka (engl. Task completion time).
- Mjera pamtljivosti (engl. memorability): Mjeri se koliko je sustav lako zapamtiti, što se određuje kroz test pamtljivosti (engl. memo-test) – metodom kojom se nakon izvođenja zadataka ispituje broj uspješno zapamćenih funkcija alata (Nielsen, 1994). Novi korisnici bi trebali zapamtiti barem polovicu funkcionalnosti sustava (npr. ocjena iznad 6 za nastavnike) (Kellner i ostali, 2008) prema (Granić & Cukusic, 2011).
- Mjera zadovoljstva (eng. satisfaction): Standardizirani upitnik, konkretno System Usability Scale (SUS).

PODACI O UZORKU

Za testiranje je bilo vrlo važno odabrati tipične korisnike i to iz različitih kategorija korisnika s obzirom na njihovo prethodno iskustvo u korištenju računala, korištenju alata i poznavanju domene (Nielsen, 1994). Budući da su nastavu izvodili profesor i asistenti, a bili su upoznati s alatom, njih nismo uključili kako bismo osigurali što objektivnije rezultate. S obzirom na to da je teško pronaći nastavnike koji izravno izvode nastavu na kolegiju *Programiranje 1*, težili smo nastavnicima koji sudjeluju u provedbi vježbi i predavanja u bliskim kolegijima s različitim iskustvom.

U ovom istraživanju korišten je uzorak odabran metodom namjernog uzorkovanja (engl. purposive sampling) te metodom uzorkovanja prema pogodnosti (engl. convenience sampling), s obzirom na to da su sudionici odabrani na temelju osobnog poznanstva i njihove dostupnosti. Uzorak se sastoji od osam nastavnika, od kojih je šest sa Sveučilišta u Zadru, jedan sa Sveučilišta u Splitu te jedan sa Sveučilišta u Osijeku, što se prema ranije navedenim kriterijima smatra dovoljnim za potrebe istraživanja.

INSTRUMENTI

Što se tiče načina dobivanja kvantitativnih i kvalitativnih mjera, korišteno je nekoliko instrumenata, uključujući:

1. Pred-eksperimentalni upitnik usmjeren na prikupljanje demografskih podataka korisnika, njihovog prethodnog iskustva i stručnosti (Prilog D2),
2. Test pamtljivosti (ili memo-test) za određivanje broja uspješno zapamćenih funkcija LAD-t. Test pamtljivosti jedan je od načina mjerenja atributa pamtljivosti. Pomoću njega se na jednostavan način, nakon testiranja korisnika, može utvrditi koliko je elemenata sučelja korisnik zapamtio (Prilog D3),
3. Standardizirani upitnik SUS opisan u potpoglavlju 5.4.1. (Prilog D4).
4. Strukturirani intervju, koji je usmjeren na identifikaciju aspekata koji su korisnicima najviše i najmanje privlačni, na neočekivane elemente te na eventualne frustracije tijekom korištenja (Prilog D5).

TIJEK ISTRAŽIVANJA


Testiranje na daljinu provedeno je tijekom sedmodnevnog razdoblja, 04-11/07, 2022. zbog smanjenog opterećenja nastavnika, budući da se tada ne održava nastava. Nastavnicima je poslana elektronička pošta s uputama i pristupnim podacima. U ovom istraživanju sudionici su prošli kroz niz sljedećih koraka. Istraživanje je započelo ispunjavanjem online upitnika (pred-eksperimentalni upitnik) putem Google Forms platforme, čime su prikupljeni osnovni podaci o demografskim karakteristikama, prethodnom iskustvu i stručnosti sudionika. Nakon toga, sudionici su postavili okruženje za snimanje ekrana korištenjem Xbox Game Bar⁶ (ili alternativnog alata), čime su osigurani tehnički uvjeti za snimanje tijekom izvođenja zadataka.

Slijedilo je izvođenje zadataka unutar LAD-t. Tijekom ovog koraka, sudionici su snimali postupak izvršavanja zadataka, pri čemu je bilo ključno da se, od početka do kraja, zabilježe svi traženi podaci koji se upisuju u predviđenu tablicu unutar word dokumenta "Zadaci". Odgovori su ocijenjeni koristeći binarnu klasifikaciju (Točno, Netočno). Ukoliko sudionici nisu u potpunosti odgovorili na pitanje (npr. ako je postojalo pod-pitanje), odgovor se smatrao netočnim. Po završetku ovog dijela, sudionici su zatvorili LAD-t jer im alat više nije bio potreban, a onda su rješavali test pamtljivosti, koristeći vlastitu sposobnost pamćenja kako bi

⁶ <https://www.microsoft.com/en-us/windows/tips/game-bar>

odgovorili na postavljena pitanja. Odgovori su procijenjeni prema sljedećoj ljestvici: 0 bodova za netočne odgovore (kada odgovor nije bio upisan), 1 bod za potpuno točne odgovore (kada su svi dijelovi odgovora bili točno navedeni), a 0,5 bodova za polovično točne odgovore (kada je samo jedan od dijelova odgovora bio ispravan). Primjer polovično točnog odgovora najbolje je ilustrirati na primjeru pitanja br. 4: „Koje informacije se prikazuju na drugom pogledu „Ishodi učenja“ na nadzornoj ploči (navedite sve)?“ Točan odgovor obuhvaća dvije informacije: zadovoljenje ishoda učenja po studentu i zadovoljenje ishoda učenja po postotku. Ako je sudionik naveo oba odgovora, dodijeljeno mu je 1 bod; ako je naveo samo jedan od odgovora, dobio je 0,5 bodova, dok je za izostavljanje oba odgovora dodijeljeno 0 bodova.

U sljedećem koraku, sudionici su ispunili SUS upitnik. Posljednji korak istraživanja odnosi se na kratak intervju. Sudionici su zamoljeni da snime odgovore na zadanih pet pitanja te ih dostave u svrhu analize. Slika 39 prikazuje vremenski slijed provedbe istraživanja, od planiranja i pripreme, preko prikupljanja podataka, do završetka istraživanja.



Slika 39 Vremenski slijed provedbe istraživanja

VALJANOST I POUZDANOST ISTRAŽIVANJA

Pri analiziranju **valjanosti i pouzdanosti provedenog istraživanja upotrebljivosti**, potrebno je razmotriti nekoliko ključnih aspekata. U ovom istraživanju pomno su odabrane metode i instrumenti kako bi se mjerila upravo upotrebljivost, čime se osigurava sadržajna valjanost. Time je osigurano da korišteni instrumenti doista mjere ono što bi trebali (tj. aspekte

upotrebljivosti), što pozitivno pridonosi valjanosti istraživanja. Uzorak korisnika obuhvaćen istraživanjem bio je relativno malen ali ciljan. U idealnom slučaju, veći i raznovrsniji uzorak pružio bi još čvršće zaključke, no za vrednovanje u ranoj fazi razvoja, u kojoj je LAD-t, korištena veličina uzorka smatra se prihvatljivom, kako je ranije objašnjeno u ovom potpoglavlju. Smatramo da je odabir sudionika reprezentativan za buduće realne korisnike. To doprinosi vanjskoj valjanosti nalaza, jer se rezultati dobiveni na tom uzorku mogu poopćiti na širu populaciju sličnih korisnika.

U ovom istraživanju nastojalo se da mjerenja budu što objektivnija kako bi se smanjio utjecaj subjektivnih procjena istraživača. Time je smanjen rizik da bi pristranost istraživača utjecala na rezultate. Tijekom provedbe testiranja definirani su jasni zadaci koje su korisnici trebali obaviti koristeći LAD-t, a sva mjerenja su unaprijed definirana. Kao i u svakom istraživanju, i ovdje postoje određene pristranosti i ograničenja koje mogu utjecati na tumačenje rezultata. Jedno moguće ograničenje je pristranost uzorka budući da su sudionici poznanici istraživača. Pristranost se pokušala smanjiti testiranjem od kuće, u uvjetima koji su njima prirodni i bez prisustva istraživača. Neutralan stav ispitivača i poticanje sudionika da iskreno iznesu kritike dodatne su mjere za smanjenje pristranosti.

Pouzdanost rezultata odnosi se na konzistentnost i stabilnost mjerenja, tj. bi li ponovljeno provođenje istraživanja pod sličnim uvjetima dalo slične nalaze. U ovom istraživanju pouzdanost je osigurana kroz nekoliko mehanizama. Između ostalog, transparentno dokumentiranje postupka istraživanja i kriterija ocjenjivanja doprinosi mogućnosti ponavljanja istraživanja: drugi istraživači potencijalno mogu ponoviti sličan test na LAD-t alatu i provjeriti podudaraju li se njihovi rezultati s ovdje dobivenima. Sve navedeno sugerira da su dobiveni rezultati vjerodostojni te da se može imati visoko povjerenje u zaključke o upotrebljivosti LAD-t alata, u okviru prepoznatih ograničenja.

REZULTATI

DEMOGRAFSKA OBILJEŽJA NASTAVNIKA

Ukupno 8 nastavnika s tri sveučilišta u Hrvatskoj ispunilo je prvi upitnik. Od toga broja, bilo je 4 ženskih ispitanika (50,0%), a 4 muških ispitanika (50,0%). Raspon godina ispitanika od 29 do 52. Struktura ispitanika prema znanstveno/nastavnom zvanju bila je raznolika: asistenti (2 ili 25,0%), poslijedoktorandi (2 ili 50,0%), docenti (3 ili 37,5%), te jedan izvanredni profesor (12,5%).

Samoprocjene stručnosti ispitanika ukazuju na sljedeće: kada se ocjenjuje poznavanje sustava za e-učenje (npr. Moodle LMS), 2 ispitanika sebe ocjenjuju kao „expert“, 2 kao „napredni korisnik“, dok 4 ispitanika sebe ocjenjuju kao „prosječni korisnik“. U pogledu iskustva u korištenju alata analitike učenja za praćenje učenja, 4 ispitanika su se ocijenili kao „napredni korisnik“, a 4 kao „početnici“. Vezano za interpretaciju podataka s nadzorne ploče, 3 ispitanika su se izjasnili kao „napredni korisnik“, 2 kao „prosječni korisnik“, dok su 3 sebe ocijenili kao „početnici“. Također, kada se radi o vještinama za rad na računalu, 4 ispitanika sebe su ocijenila kao „expert“, a 4 kao „napredni korisnik“.


USPJEŠNOST I UČINKOVITOST

U istraživanju je korišteno 14 zadataka, čiji je cjelovit opis naveden u Prilogu D1. Tablica 19 prikazuje vrijeme potrebno za završetak svakog zadatka, izraženo u sekundama. Zadaci koji nisu riješeni prikazani su bez vremena, označeni znakom „-“.

Tablica 19 Vrijeme završetka zadataka za sve sudionike


Sudionici	Zadaci													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	15	35	32	34	31	48	14	40	37	37	10	34	33	18
2	16	38	42	37	33	47	15	44	58	47	22	49	48	23
3	14	48	38	40	28	50	14	45	50	44	13	44	38	22
4	18	46	37	41	35	-	15	39	44	39	17	37	44	21
5	14	40	35	32	30	48	14	35	52	48	14	41	47	15
6	17	39	38	35	30	52	16	48	44	39	15	37	37	19
7	15	42	39	44	35	51	18	51	52	-	19	50	39	25
8	12	43	27	42	30	44	15	38	50	41	15	39	42	15

Rezultati pokazuju da je 6 od 8 ispitanika dovršilo sve zadatke, dok preostala 2 ispitanika nisu dovršila po jedan zadatak. Konkretno, sudionik 4 je na zadatku 6 unio ukupni uspjeh studenta umjesto uspjeha s pojedine provjere, dok je sudionik 7 na zadatku 10 netočno napisao očekivanje ishoda koji su bili najviše zadovoljeni. Ukupna stopa uspješnosti iznosi 12 od 14 zadataka (85,7%), što prema (Sauro, 2010) zadovoljava minimalni prag od 78%. Slika 40 prikazuje prosječno vrijeme završetka svih zadataka.



Slika 40 Prosječno vrijeme završetka zadataka

S obzirom na iskustvo ispitanika u korištenju alata analitike učenja, ispitanici su podijeljeni u dvije kategorije, napredni korisnici prikazani plavom bojom i početnici narančastom bojom, prema njihovom odgovoru na pred-eksperimentalnom upitniku o razini iskustva u korištenju alata analitike učenja za praćenje učenja. Omjer naprednih korisnika i početnika je jednak (N=4). Prosječno vrijeme dovršetka zadataka za obje skupine prikazano je na sljedećoj slici (Slika 41).



Slika 41 Usporedba prosječnog vremena dovršetka zadataka između naprednih korisnika i početnika

Slika ukazuje da se zadaci razlikuju po težini. Zadaci 1, 7, 11, i 14 predstavljaju jednostavne zadatke, u kojima je bilo potrebno samo kliknuti ili se prebaciti na drugu komponentu. Ostali zadaci zahtijevaju nešto više vremena za dovršetak, što ukazuje na njihovu složenost. Rezultati

sugeriraju da LAD-t učinkovito podržava zadatke različitih razina složenosti te da je vrijeme dovršetka zadataka kod naprednih korisnika i početnika vrlo slično, čime se potvrđuje učinkovitost alata LAD-t.

PAMTLJIVOST

Distribucija rezultata za mjeru pamtljivosti (broj točnih odgovora; od 0 do 10 bodova za 10 pitanja) kreće se od 3,5 do 7,5 bodova. Svi sudionici u ovom istraživanju okarakterizirani su kao novi korisnici, budući da su se prvi put susreli s alatom. Na testu pamtljivosti, nastavnici su u prosjeku postigli 6,19 bodova (standardna devijacija 1,25), što je u skladu sa sugeriranim intervalom – ciljana vrijednost iznad 6 bodova za nastavnike (Kellner i ostali, 2008) prema (Granić & Cukusic, 2011).

SUBJEKTIVNO ZADOVOLJSTVO

Rezultati upitnika System Usability Scale (SUS) iznosili su 70,94, što prema kategorizaciji Bangor i ostali (2008) predstavlja vrijednost između „u redu“ (engl. OK) i „dobro“ (engl. good), ali bliže je kategoriji „dobro“.

KVALITATIVNA ANALIZA

Analiza rezultata intervjua pokazuje da su svi ispitanici stekli pozitivan dojam o LAD-t. Sudionici su opisali sučelje kao pregledno, jednostavno i informativno, naglašavajući jasnu organizaciju podataka. Nekolicina ispitanika istaknula je vrijednost vizualizacija te mogućnost uvida u ostvarene ishode učenja, dok su drugi naveli mogućnost predviđanja uspjeha kao ključnu prednost alata.

Tijekom intervjua, ispitanici su ukazali na nekoliko problema upotrebljivosti. Ti problemi se odnose na nejasnoću modela predviđanja i nejasnoću čitanja ishoda učenja. Problem nejasnoće se ne odnosi na sučelje, no, zbog svrhe samog LAD-t, treba se uzeti u obzir. Svi problemi, zajedno s problemima identificiranim tijekom izvođenja zadataka (npr. slučajevi u kojima je nastavnik unio netočan podatak ili kliknuo na pogrešno mjesto unutar sučelja), prikazani su u Tablica 20. Na temelju tih komentara provedene su dodatne analize, a u skladu s njima izneseni su odgovarajući argumenti i preporuke za unapređenje alata. Tablica prikazuje evidentirane probleme zajedno sa ocjenom ozbiljnosti problema (u tablici navedena kao OP), prema tome je

li problem manji ili značajan (problemi su ocjenjeni prema procjeni autora), identificirani problem i preporuka za poboljšanje.

Tablica 20 Problemi upotrebljivosti LAD-t

OP	Identificirani problemi	Preporuke za poboljšanje
Manji	Tijekom izrade zadataka, najčešći problem bio je prelazak na drugu komponentu. Na primjer, komponenta aktivnosti i uspjeha prikazuje samo broj postavljenih ishoda, pa su sudionici često kliknuli na taj broj umjesto na link koji vodi na komponentu ishodi učenja. Iako su se, primijetivši da to nije link, vratili natrag i završili zadatak, problem narušava jasnu navigaciju.	Implementirati linkove na svim prikazima koji izravno vode na odgovarajuće komponente (npr. s komponente aktivnosti i uspjeha osigurati link koji vodi na komponentu ishodi učenja).
Manji	Jedan sudionik nije izvršio zadatak čitanja postotka ishoda učenja. Analizom intervjua ustanovljeno je da je upravo taj sudionik naveo da mu radar chart stvara problem: „težak za iščitati, teško je vidjeti koji je postotak zadovoljen“. Ovo otežava pravilno interpretiranje podataka što može otežati procjenu ostvarenosti očekivanih ishoda.	Prilagoditi prikaz radar charta, eventualno ga zamijeniti tortnim grafikonom ili ponuditi dodatne tekstualne prikaze kako bi se olakšalo praćenje i interpretacija ishoda učenja.
Manji	Jedan sudionik nije izvršio zadatak čitanja rezultata provjere za studenta – umjesto toga, upisao je ukupni uspjeh. Ova greška, koja može biti posljedica brzine izvođenja zadatka, zahtijeva poseban oprez u daljnjem vrednovanju.	Preporučuje se jasno označiti i prikazati rezultate provjere (koristeći podebljani tekst) kako bi se osigurala ispravna interpretacija podataka.
Značajan	Dva sudionika su istaknula problem s predviđanjem: „Ne razumijem kako se dobivaju podaci u modelu predviđanja.“ Ova nejasnoća ukazuje na to da je model predviđanja percipiran kao „black box“ te nije dovoljno transparentan, što može umanjiti povjerenje korisnika u njegovu pouzdanost.	Povećati transparentnost modela predviđanja, te pri prikazu rezultata jasno navesti koje značajke se koriste, koji je algoritam implementiran i koja je njegova prediktivna snaga, kako bi se korisnicima olakšalo razumijevanje.
Značajan	Jedan sudionik je izrazio da je LAD-t pretrpan s podacima, sugerirajući da nije jasno koji su podaci bitni, što može dovesti do preopterećenja informacija.	Omogućiti korisnicima personalizirani prikaz podataka putem padajućeg izbornika, gdje bi mogli sami odabrati koje informacije žele vidjeti, čime se osigurava prilagođenost individualnim potrebama.

RASPRAVA

Rezultati istraživanja pokazuju da je 6 od 8 sudionika uspjelo dovršiti sve zadatke, pri čemu je ukupna stopa rješavanja zadataka iznosila 85,7 %. Ovim se potvrđuje uspješnost LAD-t alata. Analiza vremena potrebnog za dovršetak pojedinih zadataka ukazuje na učinkovitost alata, budući da su vremena izvršenja zadataka među ispitanicima s različitim razinama iskustva bila usporediva. Stopa zadovoljstva, izmjerena putem SUS upitnika, iznosila je 70,94 %, što se smatra dobrim, a prosječna ocjena testa pamtljivosti iznosila je 6,19, što također ukazuje na prihvatljivu pamtljivost sustava. Prema navedenim rezultatima, smatramo da je LAD-t upotrebljiv s aspekta uspješnosti, učinkovitosti, zadovoljstva i pamtljivosti.

Tijekom istraživanja primijećeni su problemi upotrebljivosti koji će se pokušati otkloniti u redizajnu sučelja. U situaciji kad nastavnici žele provjeriti informaciju na LAD-t, podaci trebaju biti točni kako bi alat mogao ponuditi upravo ono što nastavnik želi. LAD-t je početna točka za pedagoški i tehnološki dizajn usmjeren prema procesu učenja i poučavanja kolegija koji su teži za poučavanje, u mješovitom ili online obliku učenja. Na ovaj način je odgovoreno na treće istraživačko pitanje (IP 3) te su prepoznate smjernice za unaprjeđenje budućih verzija alata. Provedenim istraživanjima sa stvarnim korisnicima ostvareno je vrednovanje LAD-s i LAD-t, čime je ostvaren Podcilj 2.3.

5.5. PREPORUKE ZA UNAPRIJEĐENJE PRAKSE U NASTAVI PROGRAMIRANJA

Integracijom rezultata sve tri faze, formulirane su konkretne preporuke za integraciju analitike učenja u postojeće prakse poučavanja u svrhu unaprjeđenja nastave programiranja:

- Fokusiranje nastave i potpore na identificirane pokazatelje uspješnosti učenja programiranja (preporuka temeljena na rezultatima faze 1): Izrada prilagođenih notifikacija i upozorenja unutar LAD-s alata za studente kod kojih se uoči pad u identificiranim pokazateljima uspješnosti učenja programiranja, primjerice, nedovoljan broj pregledanih materijala, riješenih kvizova ili slabija aktivnost studenata; Usmjeravanje pedagoške intervencije nastavnika na temelju modela – npr. ciljane podrška studentima čije predviđanje ukazuje na visok rizik od neuspjeha. Time se stvara funkcionalni sustav ranog upozoravanja, temeljen na objektivnim podacima.

Uključivanje preskriptivne analitike (na temelju vrednovanja LAD-s): Vrednovanje LAD-s alata pokazalo je umjerenu razinu učinkovitosti kod studenata na kolegiju *Programiranje 1*. Stoga je preporuka integrirati elemente preskriptivne analitike, koji studentima automatski nude jasne smjernice za poboljšanje, temeljene na njihovim obrascima ponašanja. Na primjer: „*Riješi dodatni kviz kako bi ojačao domenu „petlje i uvjeti“*“.

- Personalizacija i fleksibilnost prikaza podataka (na temelju vrednovanja LAD-s): Kvalitativni nalazi jasno pokazuju da studenti različito vrednuju pojedine komponente nadzorne ploče analitike učenja. Dok neki studenti preferiraju komponentu uspjeha, drugi naglašavaju važnost komponente predviđanja, a treći komponentu aktivnosti. Premda neki ispitanici navode da usporedbe mogu stvoriti pritisak, većina ih vidi kao motivacijski faktor. U tom smislu, alat bi trebao omogućiti personalizaciju korisničkog sučelja, gdje bi studenti mogli odabrati informacije koje žele da su istaknute ili izostavljene, te način kako su prikazane (tekstualno, vizualno, usporedno, kroz vremensku liniju i sl.), čime se omogućuje fleksibilnost u prikazu podataka, koja zadovoljava različite stilove učenja i razine digitalne pismenosti.
- Veća integracija LAD-a u svakodnevni nastavni proces: LAD-s bi trebao postati dio nastave, a ne dodatna opcija. Stoga se potiče primjena nadzornih ploča analitike učenja kako bi se osnažilo studente u praćenju vlastitog napretka i motiviralo ih na kontinuirani rad. Primjerice, nastavnik može pokazati kolektivne uvide iz LAD-a u učionici usmjerene na zadovoljavanje ishoda učenja, a studenti mogu tjedno pratiti vlastiti napredak i reflektirati se na temelju podataka.

6. ZAKLJUČAK

Provedeno istraživanje obuhvatilo je tri međusobno povezane faze kojima su ostvareni ciljevi i izvorni znanstveni doprinosi.

U prvoj fazi istraživanja, analizom podataka, identificirani su ključni pokazatelji uspjeha u učenju programiranja generirani kroz nastavne aktivnosti. Rezultati analize pokazali su da značajke povezane s angažmanom studenata, aktivnosti studenata tijekom vikenda, vrijeme provedeno na ispitu i uspjeh na prvom ispitu, najviše doprinose predviđanju uspjeha studenta. Na temelju tih značajki, razvijen je model predviđanja uspjeha studenata, temeljen na algoritmu RF, koji je postigao točnost od 72,83 %, preciznost od 69,44 %, odziv od 72,83 % i F1 mjeru od 68,06 %. Time je uspješno odgovoreno na prvo **Istraživačko pitanje (IP 1: Koji ključni pokazatelji uspješnosti učenja programiranja, identificirani analizom podataka generiranih kroz nastavne aktivnosti, imaju najveći prediktivni značaj za uspjeh studenata?)** te su ostvareni **Cilj 1 (Identificirati ključne pokazatelje uspješnosti učenja programiranja putem analize podataka generiranih kroz nastavne aktivnosti i razviti model predviđanja uspjeha studenata)** i pripadajući **podciljevi: 1.1. (Analizirati podatke generirane tijekom nastavnih aktivnosti kako bi se identificirali ključni pokazatelji uspješnosti učenja programiranja), i 1.2. (Izgraditi modele predviđanja uspjeha studenata primjenom algoritama strojnog učenja, nad svim mogućim kombinacijama značajki usporediti performanse modela koristeći standardne mjere (točnost, preciznost, odziv i F1 mjeru) kako bi se najbolji model mogao integrirati u nadzorne ploče analitike učenja).**

U drugoj fazi razvijene su i implementirane nadzorne ploče analitike učenja za studente (LAD-s) i nastavnike (LAD-t), čime su ostvareni **Podcilj 2.1. (Razviti i implementirati nadzornu ploču analitike učenja za studente koja omogućuje studentima kontinuirano praćenje vlastitog napretka i pruža podršku njihovoj samoregulaciji učenja), te Podcilj 2.2. (Razviti i implementirati nadzornu ploču analitike učenja za nastavnike koja omogućuje praćenje ostvarenosti ishoda učenja studenata).** LAD-s omogućuje studentima kontinuirano praćenje aktivnosti, uspjeha i predviđanja, čime se potiče njihova samoregulacija učenja. LAD-t nastavnicima omogućuje praćenje ostvarenosti ishoda učenja studenata i analizu obrazovnog procesa, uključujući mogućnost pravovremene intervencije. Obje nadzorne ploče analitike učenja uključuju deskriptivne i prediktivne elemente.

U trećoj fazi, provedeno istraživanje sa stvarnim korisnicima omogućilo je vrednovanje alata LAD-s i LAD-t, čime je ostvaren **Podcilj 2.3. (Vrednovati razvijene nadzorne ploče analitike učenja sa stvarnim korisnicima kako bi se ispitala njihova učinkovitost i upotrebljivost).** U okviru toga, drugo **Istraživačko pitanje (IP 2: Kakva je percepcija studenata o učinkovitosti nadzorne ploče analitike učenja?)** ispituje percepcije učinkovitosti LAD-s. Rezultati su pokazali različite razine percepcije učinkovitosti studenata. Studenti kolegija *Programiranje I* iskazali su umjerenu razinu učinkovitosti LAD-s alata, što se može objasniti prirodom kolegija, koji je zahtjevan i uvodi studente u kompleksne koncepte programiranja, a zasigurno postoje i razlike u motivaciji za studij, što je moglo utjecati na način korištenja alata i njegovu percipiranu učinkovitost. Studenti početnici često se suočavaju s nesigurnošću, stresom i visokim kognitivnim opterećenjem, što može utjecati na njihovu sposobnost interpretacije podataka iz LAD-s alata ili motivaciju za korištenje istog kao alata za samoregulaciju. Ovi nalazi sugeriraju potrebu za prilagodbom alata specifičnim karakteristikama studenata i kolegija. Nasuprot tome, studenti kolegija *Sustavi e-učenja* izrazili su visoku razinu učinkovitosti LAD-s alata što se može povezati s njihovom višom razinom digitalnih kompetencija i boljom pripremljenošću za korištenje takvih alata.

Treće istraživačko pitanje (IP 3: Kakva je upotrebljivost nadzorne ploče analitike učenja za nastavnike, te koji su mogući problemi u primjeni i smjernice za eventualna poboljšanja?) usmjereno je na ispitivanje upotrebljivosti nadzorne ploče LAD-t iz perspektive nastavnika. Prema dobivenim rezultatima, LAD-t je upotrebljiv s aspekta uspješnosti, učinkovitosti, zadovoljstva i pamtljivosti. Ipak, zabilježeni su određeni problemi koji se odnose na jasnoću informacija i lakoću korištenja, otvarajući prostor za daljnji razvoj i poboljšanu verziju alata. Unatoč tome, LAD-t se pokazao kao vrijedna polazna točka u osmišljavanju alata koji može podržati nastavnike u praćenju napretka studenata u realnom vremenu i donošenju odluka.

Četvrto istraživačko pitanje (IP 4: Koje su preporuke za učinkovitu primjenu nadzornih ploča analitike učenja u svrhu poboljšanja nastavne prakse u području programiranja?) je usmjereno na formuliranje konkretnih preporuka za integraciju analitike učenja u postojeće prakse poučavanja u svrhu unaprjeđenja nastave programiranja. Integracijom rezultata sve tri faze, disertacija je omogućila formuliranje konkretnih preporuka za unaprjeđenje prakse u nastavi programiranja. Implementacija ovih preporuka može doprinijeti poboljšanju ishoda učenja i cjelokupne kvalitete nastave programiranja. Ovim preporukama odgovoreno je i na

završno **Istraživačko pitanje (IP 4)**, čime je ostvaren **Podcilj 2.4. (Formulirati konkretne preporuke za integraciju analitike učenja u postojeće prakse poučavanja u svrhu unaprjeđenja nastave programiranja)**, a posredno i **Cilj 2 (Razviti novi pristup vrednovanju ostvarenosti ishoda učenja u nastavi programiranja korištenjem alata temeljenih na analitici učenja)**.

Sveukupno, rezultati ove disertacije pokazuju da primjena analitike učenja ima potencijal za unapređenje procesa učenja i poučavanja. Iako su studenti na kolegiju *Programiranje I* iskazali umjeren stupanj slaganja s percepcijom učinkovitosti alata, provedeno istraživanje ispunilo je sve zadane ciljeve: identificiralo je kritične čimbenike uspjeha u učenju programiranja, uvelo inovativne alate za praćenje i vrednovanje učenja te ponudilo smjernice za poboljšanje prakse. Time rad doprinosi širem području primjene analitike učenja pokazujući kako se podacima potpomognuto poučavanje može iskoristiti za podršku studentima i nastavnicima u postizanju zadanih ishoda učenja.

Znanstveni doprinosi ovog rada su:

1. Identifikacija ključnih pokazatelja uspješnosti učenja programiranja putem analize obrazovnih podataka. Ovaj doprinos je inovativan jer pruža empirijski utemeljene uvide koji aspekti ponašanja studenata i rada najviše utječu na uspjeh u programiranju. Inovativnost se očituje u primjeni prediktivnog modeliranja na prikupljene podatke, što je omogućilo ne samo opisivanje, već i predviđanje buduće uspješnosti studenata. Praktična vrijednost ovog doprinosa ogleda se u mogućnosti da obrazovne institucije iskoriste identificirane pokazatelje za rano prepoznavanje studenata kojima je potrebna dodatna podrška. Nastavnici mogu, na temelju ovih rezultata, usmjeriti pažnju na one aktivnosti koje su se pokazale kritičnima za uspjeh, čime se povećava vjerojatnost poboljšanja ishoda učenja.

2. Razvoj novog pristupa vrednovanju ostvarenosti ishoda učenja kroz integraciju analitike učenja. Drugi doprinos donosi novi konceptualni i tehnološki okvir za praćenje i vrednovanje ishoda učenja u realnom vremenu. Inovativnost se ogleda u integraciji nadzorne ploče analitike učenja u svakodnevnu nastavu programiranja, čime se tradicionalno periodično ocjenjivanje nadopunjuje kontinuiranim prikupljanjem i interpretacijom podataka o učenju. Povezivanje aktivnosti na kolegiju s ishodima učenja ključno je, jer upravo to mapiranje omogućuje sustavno praćenje napretka studenata i osigurava da povratne informacije budu usmjerene na ostvarivanje ishoda učenja. Predloženim pristupom studenti putem LAD-s

dobivaju neposrednu povratnu informaciju o svom napretku, dok nastavnici putem LAD-t prate ostvarenje ishoda učenja na razini cijelog kolegija. Takav pristup vrednovanju ishoda učenja dosad nije bio uobičajen u nastavi programiranja, a njegova praktična vrijednost sastoji se u tome da nastavnici dobivaju učinkovito sredstvo za identificiranje problema u učenju dok se oni još mogu ispraviti, umjesto da tek na kraju kolegija uoče nedostatno ostvarene ishode učenja. Istovremeno, studenti su osnaženi jasnim pokazateljima svog napretka, što ih može motivirati i usmjeriti u njihovom radu. Ovaj pristup može poslužiti kao model i za druge kolegije ili obrazovne kontekste gdje je praćenje ostvarenosti ishoda učenja ključno.

3. Razvoj preporuka za unaprjeđenje prakse u nastavi programiranja integracijom analitike učenja. Treći doprinos konsolidira spoznaje iz provedenih istraživanja u obliku preporuka koje imaju i znanstvenu utemeljenost i praktičnu upotrebljivost. Inovativnost ovog doprinosa je u činjenici da se preporuke temelje na konkretnim rezultatima eksperimentalne primjene analitike učenja u nastavi, a ne samo na teorijskim razmatranjima. Posebno je značajno što su preporuke usmjerene na nastavu programiranja, područje u kojem studenti često nailaze na poteškoće, te stoga imaju potencijal za neposredan utjecaj na poboljšanje uspjeha studenata. Praktična vrijednost ovih smjernica očituje se u njihovoj primjenjivosti: visokoškolske ustanove i nastavnici mogu ih iskoristiti prilikom dizajniranja ili revizije kolegija programiranja. Na taj način, treći doprinos povezuje znanstvena otkrića s praktičnim koracima koje akademska zajednica može poduzeti.

Smjernice za buduća istraživanja uključuju nadogradnje modela predviđanja budući da predviđanje uspjeha studenata zahtijeva kontinuirano prilagođavanje modela s obzirom na promjene u obrazovnim procesima i ponašanju studenata. Buduća istraživanjima također uključuju primijenu drugih algoritama, Boosting metode (npr. AdaBoost, Gradient Boosting), kako bi se usporedila njihova sposobnost predviđanja. Nadalje, težiti će se razvoju generičkog modela predviđanja uspjeha studenata, koji će biti prilagodljiv različitim obrazovnim okruženjima i potrebama.

Trenutno istraživanje vrednovanja sa studentima provedeno je unutar jednog semestra. Za dublje razumijevanje trajnih obrazovnih učinaka, potrebno je provesti longitudinalna istraživanja koja bi pratila korištenje LAD alata kroz više semestara. Osim toga, preporučuje se uključivanje većih i reprezentativnijih uzoraka, kao i primjena naprednijih statističkih metoda kako bi se dublje razumjele međusobne veze između stavova, ponašanja i obrazovnog konteksta. Također, potrebna su dodatna istraživanja o načinu na koji nastavnici interpretiraju

podatke iz LAD-t alata te kako ih koriste za donošenje pedagoških odluka.

LITERATURA

- Abu Saa, A., Al-Emran, M., & Shaalan, K. (2019). Factors Affecting Students' Performance in Higher Education: A Systematic Review of Predictive Data Mining Techniques. *Technology, Knowledge and Learning*, 24. <https://doi.org/10.1007/s10758-019-09408-7>
- Ademi, N., Loskovska, S., & Kalajdziski, S. (2019). *Prediction of Student Success Through Analysis of Moodle Logs: Case Study* (str. 27–40). https://doi.org/10.1007/978-3-030-33110-8_3
- Afzaal, M., Nouri, J., Zia, A., Papapetrou, P., Fors, U., Weegar, R., Wu, Y., & Li, X. (2021). Explainable AI for Data-Driven Feedback and Intelligent Action Recommendations to Support Students Self-Regulation. *Frontiers in Artificial Intelligence*. <https://doi.org/10.3389/frai.2021.723447>
- Aguilar, S., Lonn, S., & Teasley, S. (2014). *Perceptions and use of an early warning system during a higher education transition program*. 113–117. <https://doi.org/10.1145/2567574.2567625>
- Akçapınar, G., & Bayazit, A. (2019). MoodleMiner: Data Mining Analysis Tool for Moodle Learning Management System. *İlköğretim Online*, 18, 406–415. <https://doi.org/10.17051/ilkonline.2019.527645>
- Akinsola, J. E. T. (2017). Supervised Machine Learning Algorithms: Classification and Comparison. *International Journal of Computer Trends and Technology (IJCTT)*, 48, 128–138. <https://doi.org/10.14445/22312803/IJCTT-V48P126>
- Akuji, I., Eletu, I. I., & Olasunkanmi, Y. (2024). *ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING IN MODERN TECHNOLOGY: A COMPREHENSIVE REVIEW*. 4, 156–162.
- Albert, S. (1977). Temporal comparison theory. *Psychological Review*, 84, 485–503. <https://doi.org/10.1037/0033-295X.84.6.485>
- Al-Dhief, F., Nasser, A., Tharikh, S., Nasser, H., Almuslih, A., Albadr, M., & Mohamed, M. (2024). Review of learning management systems: history, types, advantages, and challenges. *Indonesian Journal of Electrical Engineering and Computer Science*, 33. <https://doi.org/10.11591/ijeecs.v33.i1.pp350-360>
- Aldrich, C. (2003). *Simulations and the Future of Learning*. John Wiley & Sons.
- Alfredo, R., Echeverria, V., Zhao, L., Lawrence, L., Fan, J. X., Yan, L., Li, X., Swiecki, Z., Gasevic, D., & Martinez-Maldonado, R. (2024). Designing a Human-centred Learning Analytics Dashboard In-use. *Journal of Learning Analytics*, 1–20. <https://doi.org/10.18608/jla.2024.8487>
- Ali, L., Asadi, M., Gasevic, D., Jovanovic, J., & Hatala, M. (2013). Factors influencing beliefs for adoption of a learning analytics tool: An empirical study. *Computers & Education*, 62, 130–148. <https://doi.org/10.1016/j.compedu.2012.10.023>
- Ali, L., Hatala, M., Gasevic, D., & Jovanovic, J. (2012). A qualitative evaluation of evolution of a learning analytics tool. *Computers & Education*, 58, 470–489. <https://doi.org/10.1016/j.compedu.2011.08.030>
- Alkharusi, H. (2022). *A descriptive analysis and interpretation of data from Likert scales in educational and psychological research*. 12, 13–16.
- Altabrawee, H., Ali, O., & Qaisar, S. (2019). Predicting Students' Performance Using Machine Learning Techniques. *JOURNAL OF UNIVERSITY OF BABYLON for pure and applied sciences*, 27, 194–205. <https://doi.org/10.29196/jubpas.v27i1.2108>
- Altınpulluk, H., & Kesim, M. (2021). A SYSTEMATIC REVIEW OF THE TENDENCIES IN THE USE OF LEARNING MANAGEMENT SYSTEMS.

- Turkish Online Journal of Distance Education*, 22, 40–54.
<https://doi.org/10.17718/tojde.961812>
- Alyahyan, E., & Dustegor, D. (2020). Predicting Academic Success in Higher Education Literature Review and Best Practices. *International Journal of Educational Technology in Higher Education*, 17. <https://doi.org/10.1186/s41239-020-0177-7>
- AlZoubi, D., Baran, E., Karabulut-Ilgu, A., Morales, A. S., & Gilbert, S. B. (2024). From concept to classroom: Developing instructor dashboards through human centered design. *Computers and Education Open*, 7, 100234. <https://doi.org/https://doi.org/10.1016/j.caeo.2024.100234>
- Aljohani, N., Daud, A., Abbasi, R., Alowibdi, J., Basher, M., & Aslam, M. (2018). An Integrated Framework for Course Adapted Student Learning Analytics Dashboard. *Computers in Human Behavior*, 92. <https://doi.org/10.1016/j.chb.2018.03.035>
- Aljohani, N., & Davis, H. (2013, siječanj). Learning Analytics and Formative Assessment to Provide Immediate Detailed Feedback Using a Student Centered Mobile Dashboard. *International Conference on Next Generation Mobile Applications, Services, and Technologies*. <https://doi.org/10.1109/NGMAST.2013.54>
- Anderson, L. W., Krathwohl, D. R., & Bloom, B. S. (2001). *A Taxonomy for Learning, Teaching, and Assessing: A Revision of Bloom's Taxonomy of Educational Objectives*. <https://api.semanticscholar.org/CorpusID:61966728>
- Anglin, K. (2024). Addressing Threats to Validity in Supervised Machine Learning: A Framework and Best Practices for Education Researchers. *AERA Open*, 10. <https://doi.org/10.1177/23328584241303495>
- Anh, N., Nguyen, Q., & Nguyen, V. (2018, siječanj). *A Model to Forecast Learning Outcomes for Students in Blended Learning Courses Based On Learning Analytics*. <https://doi.org/10.1145/3268808.3268827>
- Arnold, K., & Pistilli, M. (2012). Course signals at Purdue: Using learning analytics to increase student success. *ACM International Conference Proceeding Series*. <https://doi.org/10.1145/2330601.2330666>
- Aste, M., Boninsegna, M., Freno, A., & Trentin, E. (2015). Techniques for dealing with incomplete data: a tutorial and survey. *Pattern Analysis and Applications*, 18(1), 1–29. <https://doi.org/10.1007/s10044-014-0411-9>
- Avila-Garzon, C., Baldiris, S., Fabregat, R., & Graf, S. (2020). Evaluation of a learning analytics tool for supporting teachers in the creation and evaluation of accessible and quality open educational resources. *British Journal of Educational Technology*, 51. <https://doi.org/10.1111/bjet.12940>
- Awang, N. B., & Darus, M. Y. B. (2012). Evaluation of an Open Source Learning Management System: Claroline. *Procedia - Social and Behavioral Sciences*, 67, 416–426. <https://doi.org/10.1016/j.sbspro.2012.11.346>
- Azcona, D., Hsiao, I.-H., & Smeaton, A. (2018). *Personalizing Computer Science Education by Leveraging Multimodal Learning Analytics*. 1–9. <https://doi.org/10.1109/FIE.2018.8658596>
- Bader-Natal, A., & Lotze, T. (2011). *Evolving a learning analytics platform*. 180–185. <https://doi.org/10.1145/2090116.2090146>
- Baek, C., & Doleck, T. (2021). Educational Data Mining versus Learning Analytics: A Review of Publications From 2015 to 2019. *Interactive Learning Environments*, 31, 1–23. <https://doi.org/10.1080/10494820.2021.1943689>
- Baker, R., & Inventado, P. S. (2014). Educational Data Mining and Learning Analytics. U J. A. Larusson & B. White (Ur.), *Learning Analytics: From Research to Practice* (str. 61–75). Springer New York. https://doi.org/10.1007/978-1-4614-3305-7_4

- Baker, R., & Siemens, G. (2014). *Educational data mining and learning analytics* (str. 253–272). <https://doi.org/10.1017/CBO9781139519526.016>
- Bakharia, A., & Dawson, S. (2011). SNAPP: A bird's-eye view of temporal participant interaction. *ACM International Conference Proceeding Series*, 168–173. <https://doi.org/10.1145/2090116.2090144>
- Balkovich, E., Lerman, S., & Parmelee, R. (1985). Computing in Higher Education: The Athena Experience. *Computer*, 18, 112–125. <https://doi.org/10.1109/MC.1985.1662749>
- Ball, T., & Zorn, B. (2015). Teach foundational language principles. *Commun. ACM*, 58(5), 30–31. <https://doi.org/10.1145/2663342>
- Bandura, A. (2001). The Changing Face of Psychology at the Dawning of a Globalization Era. *Canadian Psychology/Psychologie canadienne*, 42, 12–24. <https://doi.org/10.1037/h0086876>
- Bangor, Aaron, Kortum, P., T., P., Miller, & T., J. (2008). The System Usability Scale (SUS): an Empirical evaluation. *International Journal of Human-Computer Interaction*, 24, 574. <https://doi.org/10.1080/10447310802205776>
- Bao, H., Li, Y., Su, Y., Xing, S., Chen, N.-S., & Rosé, C. (2021). The effects of a learning analytics dashboard on teachers' diagnosis and intervention in computer-supported collaborative learning. *Technology, Pedagogy and Education*, 30, 1–17. <https://doi.org/10.1080/1475939X.2021.1902383>
- Başaran, S., & Mohammed, R. K. H. (2020). Usability evaluation of open source learning management systems. *International Journal of Advanced Computer Science and Applications*, 11(6), 400–410. <https://doi.org/10.14569/IJACSA.2020.0110652>
- Bayer, V., Mulholland, P., Hlosta, M., Farrell, T., Herodotou, C., & Fernandez, M. (2024). Co-creating an equality diversity and inclusion learning analytics dashboard for addressing awarding gaps in higher education. *British Journal of Educational Technology*, 55, n/a-n/a. <https://doi.org/10.1111/bjet.13509>
- Berking, P., & Gallagher, S. (2016). *Choosing a Learning Management System Advanced Distributed Learning (ADL) Initiative*. <http://creativecommons.org/licenses/by-nc-sa/4.0/>
- Bernacki, M., Chavez, M., & Uesbeck, P. (2020). Predicting Achievement and Providing Support before STEM Majors Begin to Fail. *Computers & Education*, 158, 103999. <https://doi.org/10.1016/j.compedu.2020.103999>
- Bhuasiri, W., Xaymoungkhoun, O., Zo, H., Rho, J., & Ciganek, A. (2012). Critical success factors for e-learning in developing countries: A comparative analysis between ICT experts and faculty. *Computers & Education*, 58, 843–855. <https://doi.org/10.1016/j.compedu.2011.10.010>
- Bloom, B., Engelhart, M., Furst, E., Hill, W., & Krathwohl, D. (1956). *Taxonomy of Educational Objectives: Cognitive Domain*.
- Bodily, R. G. (2018). *Designing, Developing, and Implementing Real-Time Learning Analytics Student Dashboards" (2018). Theses and Dissertations*. <https://scholarsarchive.byu.edu/etd/7360>
- Bodily, R., Ikahihifo, T., Mackley, B., & Graham, C. (2018). The design, development, and implementation of student-facing learning analytics dashboards. *Journal of Computing in Higher Education*, 30. <https://doi.org/10.1007/s12528-018-9186-0>
- Bodily, R., & Verbert, K. (2017). Review of Research on Student-Facing Learning Analytics Dashboards and Educational Recommender Systems. *IEEE Transactions on Learning Technologies*, 10(4), 405–418. <https://doi.org/10.1109/TLT.2017.2740172>
- Bognar, L., & Matijević, M. (2002). *Didaktika*. Školska knjiga.

- Boud, D., & Molloy, E. (2012). Rethinking models of feedback for learning: The challenge of design. *Assessment & Evaluation in Higher Education - ASSESS EVAL HIGH EDUC*, 38, 1–15. <https://doi.org/10.1080/02602938.2012.691462>
- Brooke, J. (1996). *SUS: A quick and dirty usability scale*. <https://www.researchgate.net/publication/228593520>
- Brooks, C., & Thompson, C. (2022). *Predictive Modelling in Teaching and Learning* (str. 29–37). <https://doi.org/10.18608/hla22.003>
- Broos, T., Verbert, K., Langie, G., Soom, C., & De Laet, T. (2017). Small data as a conversation starter for learning analytics: Exam results dashboard for first-year students in higher education. *Journal of Research in Innovative Teaching & Learning*, 10, 94–106. <https://doi.org/10.1108/JRIT-05-2017-0010>
- Brown, M. (2012). *Learning Analytics: Moving from Concept to Practice*. <https://api.semanticscholar.org/CorpusID:53136880>
- Brush, T., Glazewski, K., & Hew, K. (2008). Development of an Instrument to Measure Preservice Teachers' Technology Skills, Technology Beliefs, and Technology Barriers. *Computers in The Schools*, 25, 112–125. <https://doi.org/10.1080/07380560802157972>
- Buhamad, A. (2024). The Application of Behavioral and Constructivist Theories in Educational Technology. *Journal of Education and Learning*, 13, 52. <https://doi.org/10.5539/jel.v13n3p52>
- Buvari, S., Viberg, O., Iop, A., & Romero, M. (2023). A Student-Centered Learning Analytics Dashboard Towards Course Goal Achievement in STEM Education. *European Conference on Technology Enhanced Learning*. <https://api.semanticscholar.org/CorpusID:261559284>
- Calvet Liñán, L., & Juan Pérez, A. A. (2015). Educational Data Mining and Learning Analytics: differences, similarities, and time evolution. *International Journal of Educational Technology in Higher Education*, 12(3), 98–112. <https://doi.org/10.7238/rusc.v12i3.2515>
- Campbell, J., DeBlois, P., & Oblinger, D. (2007). Academic Analytics: A New Tool for a New Era. *EDUCAUSE Review*, 42.
- Cappel, J. J., & Hayen, R. L. (2004). Evaluating E-Learning: A Case Study. *Journal of Computer Information Systems*, 44, 49–56. <https://api.semanticscholar.org/CorpusID:63108622>
- Carless, D., & Boud, D. (2018). The development of student feedback literacy: enabling uptake of feedback. *Assessment & Evaluation in Higher Education*, 43, 1315–1325. <https://doi.org/10.1080/02602938.2018.1463354>
- Cassidy, S. (2016). Virtual Learning Environments as Mediating Factors in Student Satisfaction with Teaching and Learning in Higher Education. *Journal of Curriculum and Teaching*, 5. <https://doi.org/10.5430/jct.v5n1p113>
- Castells, M. (2001). *The Internet Galaxy: Reflections on the Internet, Business, and Society*. Oxford University Press, Inc.
- Castro Sánchez, J., & Alemán, E. (2011). Teachers' opinion survey on the use of ICT tools to support attendance-based teaching. *Computers & Education*, 56, 911–915. <https://doi.org/10.1016/j.compedu.2010.11.005>
- Cechinel, C., Freitas, M., Santos, Barrozo, C., Schardosim, J., Vila, E., Ramos, V., Primo, T., Munoz, R., & Queiroga, E. (2021, prosinac). *A Learning Analytics Dashboard for Moodle: Implementing Machine Learning Techniques to Early Detect Students at Risk of Failure*. <https://doi.org/10.1109/LACLO54177.2021.00019>

- Cerezo, R., Lara, J.-A., Azevedo, R., & Romero, C. (2024). Reviewing the differences between learning analytics and educational data mining: Towards educational data science. *Comput. Hum. Behav.*, 154(C). <https://doi.org/10.1016/j.chb.2024.108155>
- Chai, C., Koh, J., & Tsai, C.-C. (2010). Facilitating Preservice Teachers' Development of Technological, Pedagogical, and Content Knowledge (TPACK). *Educational Technology & Society*, 13, 63–73.
- Charleer, S., Vande Moere, A., Klerkx, J., Verbert, K., & De Laet, T. (2017). Learning Analytics Dashboards to Support Adviser-Student Dialogue. *IEEE Transactions on Learning Technologies*, PP, 1. <https://doi.org/10.1109/TLT.2017.2720670>
- Chatti, M., Dyckhoff, A., Schroeder, U., & Thüs, H. (2012). A Reference Model for Learning Analytics. *International Journal of Technology Enhanced Learning*, 4, 318–331. <https://doi.org/10.1504/IJTEL.2012.051815>
- Chaubey, A., & Bhattacharya, B. (2015). Learning Management System in Higher Education. U *IJSTE-International Journal of Science Technology & Engineering* | (Sv. 2, Izdanje 3). www.ispringsolutions.com
- Choi, H., Borrella, I., & Ponce-Cueto, E. (2023). *Meta-LAD: Developing a Learning Analytics Dashboard with a Theoretically Grounded and Context-Specific Approach*. 1–6. <https://doi.org/10.1109/LWMOOCS58322.2023.10306139>
- Choi, N. (2005). Self-efficacy and self-concept as predictors of college students' academic performance. *Psychology in the Schools*, 42, 197–205. <https://doi.org/10.1002/pits.20048>
- Choi, W. C., Lam, C., & Mendes, A. (2023). *A Systematic Literature Review on Performance Prediction in Learning Programming Using Educational Data Mining*. 1–9. <https://doi.org/10.1109/FIE58773.2023.10343346>
- Clark, V., Foote, L., & Walton, J. (2018). Intersecting Mixed Methods and Case Study Research: Design Possibilities and Challenges. *INTERNATIONAL JOURNAL OF MULTIPLE RESEARCH APPROACHES*, 10, 14–29. <https://doi.org/10.29034/ijmra.v10n1a1>
- Cleary, T. (2009). Monitoring trends and accuracy of self-efficacy beliefs during interventions: Advantages and potential applications to school-based settings. *Psychology in the Schools*, 46, 154–171. <https://doi.org/10.1002/pits.20360>
- Cobos, R., & Olmos Camarena, L. (2018). *A Learning Analytics Tool for Predictive Modeling of Dropout and Certificate Acquisition on MOOCs for Professional Learning*. 1533–1537. <https://doi.org/10.1109/IEEM.2018.8607541>
- Cohen, A., & Singh, D. (2020). Effective student feedback as a marker for student success. *South African Journal of Higher Education*, 35. <https://doi.org/10.20853/34-5-4259>
- Cohen, L., Manion, L., & Morrison, K. (2000). Research Methods in Education. [http://lst-iiep.iiep-unesco.org/cgi-bin/wwwi32.exe/\[in=epidoc1.in\]/?t2000=011160/\(100\)](http://lst-iiep.iiep-unesco.org/cgi-bin/wwwi32.exe/[in=epidoc1.in]/?t2000=011160/(100)).
- Cohen, L., Manion, L., & Morrison, K. (2017). *Research Methods in Education* (8. izd.). Taylor & Francis.
- Collins, C., Dennehy, D., Conboy, K., & Mikalef, P. (2021). Artificial intelligence in information systems research: A systematic literature review and research agenda. *International Journal of Information Management*, 60, 102383. <https://doi.org/10.1016/j.ijinfomgt.2021.102383>
- Commission of the European Communities. (2001, ožujak 28). [https://www.europarl.europa.eu/meetdocs/committees/cult/20020122/com\(2001\)678_en.pdf](https://www.europarl.europa.eu/meetdocs/committees/cult/20020122/com(2001)678_en.pdf)
- Cook, L., & Kamalodeen, V. (2023). *Intersection of Mixed Methods and Case Study Research (MM+CSR): Two Design Options in Educational Research* (str. 267–277). <https://doi.org/10.4135/9781529614572.n27>

- Corrin, L., & de Barba, P. (2014). Exploring students' interpretation of feedback delivered through learning analytics dashboards. *ASCILITE Publications*, 629–633. <https://doi.org/10.14742/apubs.2014.1300>
- Corrin, L., Kennedy, G., de Barba, P., Bakharia, A., Lockyer, L., Gasevic, D., Williams, D., Dawson, S., & Copeland, S. (2015, siječanj). *Loop: A learning analytics tool to provide teachers with useful data visualisations*.
- Cortes, C., & Vapnik, V. (2009). Support-vector networks. *Chem. Biol. Drug Des.*, 297, 273–297. <https://doi.org/10.1007/%2FBF00994018>
- Creswell, J. W. (1994). *Research design: Qualitative & quantitative approaches*. Sage Publications, Inc.
- Creswell, J. W., & Plano Clark, V. L. (2011). *Designing and Conducting Mixed Methods Research* (Second). SAGE Publications, Inc.
- Dabbebi, I., Gilliot, J.-M., & Iksal, S. (2019). *User Centered Approach for Learning Analytics Dashboard Generation*. 260–267. <https://doi.org/10.5220/0007693102600267>
- Davis, B., Carmean, C., & Wagner, E. D. (2009). The evolution of the LMS: From management to learning. *Santa Rosa, CA: e-Learning Guild*, 24.
- Dawson, S., Macfadyen, L., & Lockyer, L. (2009). Learning or performance: Predicting drivers of student motivation. *Faculty of Education - Papers*.
- De Laet, T., Millecamp, M., Ortiz, M., Jimenez-Macias, A., Maya, R., & Verbert, K. (2020). Adoption and impact of a learning analytics dashboard supporting the advisor—Student dialogue in a higher education institute in Latin America. *British Journal of Educational Technology*, 51. <https://doi.org/10.1111/bjet.12962>
- De Quincey, E., Kyriacou, T., Briggs, C., & Waller, R. (2019). Student centred design of a learning analytics system. *ACM International Conference Proceeding Series*, 353–362. <https://doi.org/10.1145/3303772.3303793>
- Demiray, U. (2010). *e-Learning Practices: Cases on challenges facing e-learning and national development*. <https://api.semanticscholar.org/CorpusID:107948059>
- Dhankhar, A., Solanki, K., Dalal, S., & Omdev. (2021). Predicting Students Performance Using Educational Data Mining and Learning Analytics: A Systematic Literature Review. *Innovative Data Communication Technologies and Application*. <https://api.semanticscholar.org/CorpusID:234336318>
- Distante, D., Villa, M., Sansone, N., & Faralli, S. (2020, ožujak). *MILA: A SCORM-Compliant Interactive Learning Analytics Tool for Moodle*. <https://doi.org/10.1109/ICALT49669.2020.00056>
- Dormezil, S., Khoshgoftaar, T. M., & Robinson-Bryant, F. (2019). Differentiating between Educational Data Mining and Learning Analytics: A Bibliometric Approach. *Educational Data Mining*. <https://api.semanticscholar.org/CorpusID:216107026>
- Dougiamas, M., & Taylor, P. (2003, studeni). Moodle: Using Learning Communities to Create an Open Source Course Management System. *Proceedings of World Conference on Educational Multimedia, Hypermedia and Telecommunications*.
- Dourado, R., Rodrigues, R., Ferreira, N., Ferreira, R., Gomes, A., & Verbert, K. (2021). *A Teacher-facing Learning Analytics Dashboard for Process-oriented Feedback in Online Learning*. 482–489. <https://doi.org/10.1145/3448139.3448187>
- Duan, X., Wang, C., & Rouamba, G. (2022). *Designing a Learning Analytics Dashboard to Provide Students with Actionable Feedback and Evaluating Its Impacts*. 117–127. <https://doi.org/10.5220/0011116400003182>
- Dumas, J. S., & Redish, J. C. (1999). *A Practical Guide to Usability Testing* (1st izd.). Intellect Books.

- Dyckhoff, A., Zielke, D., Bültmann, M., Chatti, M., & Schroeder, U. (2012). Design and Implementation of a Learning Analytics Toolkit for Teachers. *Educational Technology and Society*, 15.
- Eickholt, J., Weible, J. L., & Teasley, S. D. (2022). Student-facing Learning Analytics Dashboard: Profiles of Student Use. *2022 IEEE Frontiers in Education Conference (FIE)*, 1–9. <https://doi.org/10.1109/FIE56618.2022.9962531>
- El Morr Christo and Ali-Hassan, H. (2019). Descriptive, Predictive, and Prescriptive Analytics. U *Analytics in Healthcare: A Practical Introduction* (str. 31–55). Springer International Publishing. https://doi.org/10.1007/978-3-030-04506-7_3
- Elias, T. (2011). *Learning Analytics: Definitions, Processes and Potential*.
- Essa, A., & Ayad, H. (2012). *Student success system: risk analytics and data visualization using ensembles of predictive models*. <https://doi.org/10.1145/2330601.2330641>
- Ez-zaouia, M., & Lavoué, E. (2017). *EMODA: a tutor oriented multimodal and contextual emotional dashboard*. 429–438. <https://doi.org/10.1145/3027385.3027434>
- Ez-zaouia, M., Tabard, A., & Lavoué, E. (2020). Emodash: A dashboard supporting retrospective awareness of emotions in online learning. *International Journal of Human-Computer Studies*, 139, 102411. <https://doi.org/https://doi.org/10.1016/j.ijhcs.2020.102411>
- Fenu, G., Marras, M., & Meles, M. (2017). A Learning Analytics Tool for Usability Assessment in Moodle Environments. *Journal of E-Learning and Knowledge Society*, 13, 23–34. <https://doi.org/10.20368/1971-8829/1388>
- Ferguson, R. (2012). Learning analytics: Drivers, developments and challenges. *International Journal of Technology Enhanced Learning*, 4, 304–317. <https://doi.org/10.1504/IJTEL.2012.051816>
- Fernandez Nieto, G. M., Kitto, K., Buckingham Shum, S., & Martinez-Maldonado, R. (2022). Beyond the Learning Analytics Dashboard: Alternative Ways to Communicate Student Data Insights Combining Visualisation, Narrative and Storytelling. *LAK22: 12th International Learning Analytics and Knowledge Conference*, 219–229. <https://doi.org/10.1145/3506860.3506895>
- Festinger, L. (1954). A theory of social comparison processes. *Human Relations*, 7, 117–140. <https://doi.org/10.1177/001872675400700202>
- Few, S. (2013). *Information dashboard design: displaying data for at-a-glance monitoring*.
- Filvá, D. A., Alier, M., Casany, M. J., & Mayol, E. (2016). A learning analytics tool with hybrid graphical and textual interpretation generation. *ACM International Conference Proceeding Series*, 02-04-November-2016, 326–333. <https://doi.org/10.1145/3012430.3012536>
- Fincham, E., Whitelock-Wainwright, A., Kovanovic, V., Joksimovic, S., Staaldin, J.-P., & Gasevic, D. (2019). *Counting Clicks is Not Enough: Validating a Theorized Model of Engagement in Learning Analytics*. 501–510. <https://doi.org/10.1145/3303772.3303775>
- Fleur, D., van den Bos, W., & Bredeweg, B. (2023). Social Comparison in Learning Analytics Dashboard supporting Motivation and Academic Achievement. *Computers and Education Open*, 4, 100130. <https://doi.org/10.1016/j.cao.2023.100130>
- Francis, B., & Sasidhar Babu, D. (2019). Predicting Academic Performance of Students Using a Hybrid Data Mining Approach. *Journal of Medical Systems*, 43, 162. <https://doi.org/10.1007/s10916-019-1295-4>
- Franco, D. C. (2022). 6 - Gamification as an engagement, learning and interaction strategy for distance education in Mozambique. U U. G. Singh, C. S. Nair, C. Blewett, & T.

- Shea (Ur.), *Academic Voices* (str. 71–81). Chandos Publishing.
<https://doi.org/https://doi.org/10.1016/B978-0-323-91185-6.00010-0>
- Frazzetto, D., Nielsen, T., Pedersen, T., & Siksnys, L. (2019). Prescriptive analytics: a survey of emerging trends and technologies. *The VLDB Journal*, 28. <https://doi.org/10.1007/s00778-019-00539-y>
- Fu, J. S. (2013). ICT in education: A critical literature review and its implications. *International Journal of Education and Development Using Information and Communication Technology (IJEDICT)*, 9, 112–125.
- Fu, Q., Bai, X., Zheng, Y., Du, R., Wang, D., & Zhang, T. (2023). VisOJ: real-time visual learning analytics dashboard for online programming judge. *The Visual Computer*, 39(6), 2393–2405. <https://doi.org/10.1007/s00371-022-02586-z>
- Fu, X., Shimada, A., Ogata, H., Taniguchi, Y., & Suehiro, D. (2017). *Real-time learning analytics for C programming language courses*. 280–288. <https://doi.org/10.1145/3027385.3027407>
- Garcia-Zubia, J., Cuadros, J., Molinero, V., Hernandez, U., Angulo, I., Villar-Martínez, A., Orduña, P., & Alves, G. (2019). *Dashboard for the VISIR remote lab*. 42–46. <https://doi.org/10.1109/EXPAT.2019.8876527>
- Gasevic, D., Dawson, S., Rogers, T., & Gasevic, D. (2016). Learning analytics should not promote one size fits all: The effects of instructional conditions in predicting academic success. *The Internet and Higher Education*, 28, 68–84. <https://doi.org/10.1016/j.iheduc.2015.10.002>
- Gasevic, D., Dawson, S., & Siemens, G. (2015). Let's not forget: Learning analytics are about learning. *TechTrends*, 59. <https://doi.org/10.1007/s11528-014-0822-x>
- George, D., & Mallery, P. (2003). *SPSS for Windows Step-by-Step: A Simple Guide and Reference*, 14.0 update (7th Edition). [http://lst-iiep.iiep-unesco.org/cgi-bin/wwwi32.exe/\[in=epidoc1.in\]/?t2000=026564/\(100\)](http://lst-iiep.iiep-unesco.org/cgi-bin/wwwi32.exe/[in=epidoc1.in]/?t2000=026564/(100)).
- Goar, V. (2022). The Impact and Transformation of Artificial Intelligence. *International Journal on Recent and Innovation Trends in Computing and Communication*, 10, 67–75. <https://doi.org/10.17762/ijritcc.v10i8.5677>
- Gómez Aguilar, D., García-Peñalvo, F., & Therón, R. (2013). Tap into Visual Analysis of the customization of grouping of activities in eLearning. *ACM International Conference Proceeding Series*, 253–259. <https://doi.org/10.1145/2536536.2536575>
- Govaerts, S., Verbert, K., duval, erik, & Pardo, A. (2012). *The student activity meter for awareness and self-reflection*. <https://doi.org/10.1145/2212776.2212860>
- Graf, S., Ives, C., Rahman, N., & Ferri, A. (2011). AAT - A tool for accessing and analysing students' behaviour data in learning systems. *ACM International Conference Proceeding Series*, 174–179. <https://doi.org/10.1145/2090116.2090145>
- Granić, A., & Cukusic, M. (2011). Usability Testing and Expert Inspections Complemented by Educational Evaluation: A Case Study of an e-Learning Platform. *Educational Technology & Society*, 14, 107–123.
- Greller, W., & Drachsler, H. (2012). Turning Learning into Numbers - A Learning Analytics Framework. *Educational Technology & Society*.
- Gruzd, A., & Conroy, N. (2018). *Designing a learning analytics dashboard for twitter-facilitated teaching*. 1–4. <https://doi.org/10.1145/3231644.3231704>
- Guenaga, M., Longarte, J., & Rayon, A. (2015, siječanj). *Standardized enriched rubrics to support competency-assessment through the SCALA methodology and dashboard*. <https://doi.org/10.1109/EDUCON.2015.7095994>
- Guerra, J., Hosseini, R., Somyürek, S., & Brusilovsky, P. (2016, studeni). *An Intelligent Interface for Learning Content: Combining an Open Learner Model and Social*

- Comparison to Support Self-Regulated Learning and Engagement.* <https://doi.org/10.1145/2856767.2856784>
- Gutierrez, F., Seipp, K., Ochoa, X., Chiluita, K., De Laet, T., & Verbert, K. (2018). LADA: A learning analytics dashboard for academic advising. *Computers in Human Behavior*, 107. <https://doi.org/10.1016/j.chb.2018.12.004>
- Han, J., & Kamber, M. (2000). *Data Mining: Concepts and Techniques*. U San Francisco: Morgan kaufmann;
- Harb, H. M., & Moustafa, M. A. (2012). *Selecting Optimal Subset of Features for Student Performance Model*. <https://api.semanticscholar.org/CorpusID:18756945>
- Hardaker, G., & Singh, G. (2011). The adoption and diffusion of eLearning in UK universities: A comparative case study using Giddens's Theory of Structuration. *Campus-Wide Information Systems*, 28, 221–233. <https://doi.org/10.1108/10650741111162707>
- Hasnine, M., Nguyen Tan, H., Tran, T., Bui, T., Akçapınar, G., & Ueda, H. (2023). A Real-Time Learning Analytics Dashboard for Automatic Detection of Online Learners' Affective States. *Sensors (Basel, Switzerland)*, 23. <https://doi.org/10.3390/s23094243>
- Hastie, T., Tibshirani, R., Friedman, J., & Franklin, J. (2004). The Elements of Statistical Learning: Data Mining, Inference, and Prediction. *Math. Intell.*, 27, 83–85. <https://doi.org/10.1007/BF02985802>
- Haynes-Magyar, C. (2020). *The Role of Self-Regulated Learning in the Design, Implementation, and Evaluation of Learning Analytics Dashboards*. 297–300. <https://doi.org/10.1145/3386527.3406732>
- He, W. (2013). Examining Students' Online Interaction in a Live Video Streaming Environment Using Data Mining and Text Mining. *Computers in Human Behavior*, 29, 90–102. <https://doi.org/10.1016/j.chb.2012.07.020>
- Herodotou, C., Rienties, B., Borooa, A., Zdráhal, Z., Hlosta, M., & Naydenova, G. (2017). *Implementing predictive learning analytics on a large scale: the teacher's perspective*. 267–271. <https://doi.org/10.1145/3027385.3027397>
- Holman, C., Aguilar, S., & Fishman, B. (2013). *GradeCraft: What can we learn from a game-inspired learning management system?* 260–264. <https://doi.org/10.1145/2460296.2460350>
- Hrvatski kvalifikacijski okvir. (2009). https://www.azvo.hr/images/stories/HKO_Prirucnik.pdf
- Hu, X., Ng, J., & Lei, C.-U. (2021). *Evaluation of a Lightweight Learning Analytics Tool in Moodle and edX: Preliminary Results*. 157–159. <https://doi.org/10.1109/ICALT52272.2021.00054>
- Hussain, M., Hussain, S., Zhang, wu, Zhu, W., Theodorou, P., & Abidi, R. (2018, siječanj). *Mining Moodle Data to Detect the Inactive and Lowperformance Students during the Moodle Course*. <https://doi.org/10.1145/3291801.3291828>
- Hutinski, Ž., & Aurer, B. (2009). Informacijska i komunikacijska tehnologija u obrazovanju: stanje i perspektive. *Informatologia*, 4, 265–272.
- Ihantola, P., Hellas, A., Butler, M., Börstler, J., Edwards, S., Isohanni, E., Korhonen, A., Petersen, A., Rivers, K., Rubio, M., Sheard, J., Skupas, B., Spacco, J., Szabo, C., & Toll, D. (2015, studeni). *Educational Data Mining and Learning Analytics in Programming: Literature Review and Case Studies*. <https://doi.org/10.1145/2858796.2858798>
- Irons, A., & Elkington, S. (2021). *Enhancing Learning through Formative Assessment and Feedback*. <https://doi.org/10.4324/9781138610514>

- ISO 9241-11:2018(en) *Ergonomics of human-system interaction — Part 11: Usability: Definitions and concepts*. (bez dat.).
- Ivory, M. Y., & Hearst, M. A. (2001). The state of the art in automating usability evaluation of user interfaces. *ACM Computing Surveys*, 33(4). <https://doi.org/10.1145/503112.503114>
- Jain, N., & Kumar, R. (2022). A Review on Machine Learning & It's Algorithms. *International Journal of Soft Computing and Engineering*, 12, 1–5. <https://doi.org/10.35940/ijsc.E3583.1112522>
- Jaramillo-Morillo, D., Ruipérez-Valiente, J. A., Burbano Astaiza, C., Solarte, M., Ramirez-Gonzalez, G., & Alexandron, G. (2022). Evaluating a learning analytics dashboard to detect dishonest behaviours: A case study in small private online courses with academic recognition. *Journal of Computer Assisted Learning*, 38. <https://doi.org/10.1111/jcal.12734>
- Jayashanka, R., Hettiarachchi, E., & Hewagamage, K. (2022). Technology Enhanced Learning Analytics Dashboard in Higher Education. *Electronic Journal of e-Learning*, 20, pp151-170. <https://doi.org/10.34190/ejel.20.2.2189>
- Ji, M., Michel, C., Lavoué, E., & George, S. (2014, siječanj). *DDART, a Dynamic Dashboard for Collection, Analysis and Visualization of Activity and Reporting Traces*. https://doi.org/10.1007/978-3-319-11200-8_39
- Jivet, I., Scheffel, M., Drachsler, H., & Specht, M. (2017, siječanj). *Awareness Is Not Enough: Pitfalls of Learning Analytics Dashboards in the Educational Practice*. https://doi.org/10.1007/978-3-319-66610-5_7
- Jivet, I., Scheffel, M., Specht, M., & Drachsler, H. (2018). *License to evaluate: preparing learning analytics dashboards for educational practice*. 31–40. <https://doi.org/10.1145/3170358.3170421>
- Jovanovic, M., Vukicevic, M., Milovanović, M., & Minović, M. (2012). Using data mining on student behavior and cognitive style data for improving e-learning systems: A case study. *International Journal of Computational Intelligence Systems*, 5, 597–610. <https://doi.org/10.1080/18756891.2012.696923>
- Kahiigi, E., Ekenberg, L., Hansson, H., Tusubira, F., & Danielson, M. (2008). Exploring the e-Learning State of art. *The Electronic Journal of e-Learning*, 6.
- Kaliisa, R., & Dolonen, J. (2022). CADA: a teacher-facing learning analytics dashboard to foster teachers' awareness of students' participation and discourse patterns in online discussions. *Technology, Knowledge and Learning*, 28. <https://doi.org/10.1007/s10758-022-09598-7>
- Kaliisa, R., Misiejuk, K., López-Pernas, S., Khalil, M., & Saqr, M. (2024). *Have Learning Analytics Dashboards Lived Up to the Hype? A Systematic Review of Impact on Students' Achievement, Motivation, Participation and Attitude*. 295–304. <https://doi.org/10.1145/3636555.3636884>
- Kats, Y. (2010). *Learning Management System Technologies and Software Solutions for Online Teaching: Tools and Applications*. <https://doi.org/10.4018/978-1-61520-853-1>
- Kasapović, M. (2013). Englesko-hrvatski politološki rječnik: komparativna politika (I). . *Političke analize*, 4 (15), 4(15), 60–64.
- Kasim, N. N. M., & Khalid, F. (2016). Choosing the right learning management system (LMS) for the higher education institution context: A systematic review. *International Journal of Emerging Technologies in Learning*, 11(6), 55–61. <https://doi.org/10.3991/ijet.v11i06.5644>
- Kaur, A., & Chahal, K. K. (2024). A learning analytics dashboard for data-driven recommendations on influences of non-cognitive factors in introductory

- programming. *Education and Information Technologies*, 29(8), 9221–9256. <https://doi.org/10.1007/s10639-023-12125-5>
- Kaya Keleş, M., & Özel, S. (2016). *A Review of Distance Learning and Learning Management Systems*. <https://doi.org/10.5772/65222>
- Kellner, A., Teichert, V., Čukušić, M., Granić, A., Pagden, A., & Rikure, T. (2008). *D7.2: Report of validation results. FP6-IST UNITE project-report*.
- Kennedy, D., Hyland, Á., & Ryan, N. (2007). *Writing and Using Learning Outcomes: A Practical Guide*.
- Khalil, M., & Belokry, G. (2020, ožujak). *OXALIC: an Open edX Advanced Learning Analytics Tool*. <https://doi.org/10.1109/LWMOOCS50143.2020.9234322>
- Khan, B. (2001). A framework for Web-based learning. U *Web-Based Training* (str. 75–98). Educational Technology Publications.
- Khan, R., & Hassan, Q.-U. (2021). Learning Management Systems. U *Adoption of LMS in Higher Educational Institutions of the Middle East* (str. 13–17). Springer International Publishing. https://doi.org/10.1007/978-3-030-50112-9_3
- Kia, F., Teasley, S., Hatala, M., Karabenick, S., & Kay, M. (2020). *How patterns of students dashboard use are related to their achievement and self-regulatory engagement*. 340–349. <https://doi.org/10.1145/3375462.3375472>
- Kleinbaum David G. and Klein, M. (2010). Introduction to Logistic Regression. U *Logistic Regression: A Self-Learning Text* (str. 1–39). Springer New York. https://doi.org/10.1007/978-1-4419-1742-3_1
- Konert, J., Bohr, C., Bellhäuser, H., & Rensing, C. (2016). *PeerLA - Assistant for Individual Learning Goals and Self-Regulation Competency Improvement in Online Learning Scenarios*. 52–56. <https://doi.org/10.1109/ICALT.2016.100>
- Krathwohl, D. (2002). A Revision of Bloom's Taxonomy: An Overview. *Theory Into Practice - THEORY PRACT*, 41, 212–218. https://doi.org/10.1207/s15430421tip4104_2
- Krpan, D. (2020). *Poučavanje objektno orijentiranog programiranja metodom didaktičkog skrivanja* [Sveučilište u Splitu, Prirodoslovno-matematički fakultet]. <https://urn.nsk.hr/urn:nbn:hr:166:718989>
- Kuh, G., Kinzie, J., Buckley, J., Bridges, B., & Hayek, J. (2006). *What Matters to Student Success: A Review of the Literature*.
- Lang, S. (2023). Learning Management Systems (LMSs). U C. and A. C. M. and B. K. and C. E. and D. A. and S. A. Kruse Otto and Rapp (Ur.), *Digital Writing Technologies in Higher Education : Theory, Research, and Practice* (str. 173–182). Springer International Publishing. https://doi.org/10.1007/978-3-031-36033-6_11
- Laurillard, D. (2006). E-learning in higher education. *Changing Higher Education Routledge*, 71–84.
- Leech, N., & Onwuegbuzie, A. (2004). A Proposed Fourth Measure of Significance: The Role of Economic Significance in Educational Research. *Evaluation & Research in Education*, 18, 179–198. <https://doi.org/10.1080/09500790408668317>
- Leitner, P., Khalil, M., & Ebner, M. (2017). Learning Analytics in Higher Education—A Literature Review. U *Studies in Systems, Decision and Control* (Sv. 94, str. 1–23). https://doi.org/10.1007/978-3-319-52977-6_1
- Lemay, D., Baek, C., & Doleck, T. (2021). Comparison of Learning Analytics and Educational Data Mining: A Topic Modeling Approach. *Computers and Education: Artificial Intelligence*, 2, 100016. <https://doi.org/10.1016/j.caeai.2021.100016>
- Leony, D., Pardo, A., de la Fuente Valentín, L., Castro, D., & Delgado-Kloos, C. (2012). *GLASS: a learning analytics visualization tool*.

- Levin, T., & Wadmany, R. (2006). Teachers' Beliefs and Practices in Technology-based Classrooms. *Journal of Research on Technology in Education*, 39, 157–181. <https://doi.org/10.1080/15391523.2006.10782478>
- Lim, S. L., & Atkinson, D. (2013). Improving assessment processes in Higher Education: Student and teacher perceptions of the effectiveness of a rubric embedded in a LMS. *Australasian Journal of Educational Technology*, 29. <https://doi.org/10.14742/ajet.526>
- Liu, & Bing. (2007). *Web Data Mining*.
- Lowther, D., Inan, F., Strahl, J., & Ross, S. (2008). Does technology integration “work” when key barriers are removed? *Educational Media International*, 45, 195–213. <https://doi.org/10.1080/09523980802284317>
- Lu, Z., Hou, L., & Huang, X. (2010). A research on a student-centred teaching model in an ICT-based English audio-video speaking class. *International Journal of Education and Development using ICT*, 6, 101–123. <https://api.semanticscholar.org/CorpusID:54590980>
- Lust, G., Elen, J., & Clarebout, G. (2013). Students' tool-use within a web enhanced course: Explanatory mechanisms of students' tool-use pattern. *Computers in Human Behavior*, 29, 2013–2021. <https://doi.org/10.1016/j.chb.2013.03.014>
- Ma, L., & Sun, B. (2020). Machine learning and AI in marketing – Connecting computing power to human insights. *International Journal of Research in Marketing*, 37. <https://doi.org/10.1016/j.ijresmar.2020.04.005>
- Macayan, J. (2017). Implementing Outcome-Based Education (OBE) Framework: Implications for Assessment of Students' Performance. *Educational Measurement and Evaluation Review*, 8, 1–10.
- Macfadyen, L., & Dawson, S. (2010). Mining LMS data to develop an “early warning system” for educators: A proof of concept. *Computers & Education*, 54, 588–599. <https://doi.org/10.1016/j.compedu.2009.09.008>
- Macharia PhD, J., & Pelsner, T. (2012). Key factors that influence the diffusion and infusion of information and communication technologies in Kenyan higher education. *Studies in Higher Education*, 39, 695–709. <https://doi.org/10.1080/03075079.2012.729033>
- Mahesh, B. (2019). Machine Learning Algorithms -A Review. *U International Journal of Science and Research (IJSR)* (Sv. 9). <https://doi.org/10.21275/ART20203995>
- Majumdar, R., Akçapınar, A., Akçapınar, G., Flanagan, B., & Ogata, H. (2019, siječanj). *Learning Analytics Dashboard Widgets to Author Teaching-Learning Cases for Evidence-based Education*.
- Martinez-Maldonado, R., Pardo, A., Mirriahi, N., Yacef, K., Kay, J., & Clayphan, A. (2015, siječanj). *The LATUX Workflow : Designing and Deploying Awareness Tools in Technology-Enabled Learning Settings*. <https://doi.org/10.1145/2723576.2723583>
- Matcha, W., Ahmad Uzir, N., Gasevic, D., & Pardo, A. (2019). A Systematic Review of Empirical Studies on Learning Analytics Dashboards: A Self-Regulated Learning Perspective. *IEEE Transactions on Learning Technologies*, PP, 1. <https://doi.org/10.1109/TLT.2019.2916802>
- May, M., George, S., & Prévôt, P. (2011). TrAVis to enhance online tutoring and learning activities: Real-time visualization of students tracking data. *Interactive Technology and Smart Education*, 8(1), 52–69. <https://doi.org/10.1108/17415651111125513>
- Mazza, R., & Dimitrova, V. (2004). Visualising student tracking data to support instructors in web-based distance education. *Proceedings of the 13th International World Wide Web Conference on Alternate Track Papers & Posters*, 154–161. <https://doi.org/10.1145/1013367.1013393>

- Mazza, R., & Dimitrova, V. (2007). CourseVis: A graphical student monitoring tool for supporting instructors in web-based distance courses. *International Journal of Human-Computer Studies*, 65(2), 125–139. <https://doi.org/https://doi.org/10.1016/j.ijhcs.2006.08.008>
- Mclean, D. (2000). Kevin Gurney, An Introduction to Neural Networks, University College London (UCL) Press, 1997. ISBN 1-85728-673-1 HB. £14.95. xi+234 pages. *Natural Language Engineering*, 6, 203–204. <https://api.semanticscholar.org/CorpusID:10362019>
- Millecamp, M., Gutierrez, F., Charleer, S., Verbert, K., & De Laet, T. (2018). *A qualitative evaluation of a learning dashboard to support advisor-student dialogues*. 56–60. <https://doi.org/10.1145/3170358.3170417>
- Mladenovic, S., Krpan, D., & Mladenović, M. (2016). Using Games to Help Novices Embrace Programming: From Elementary to Higher Education. *International Journal of Engineering Education*, 32, 521–531.
- Moore, M., & Diehl, W. (2018). *Handbook of Distance Education* (4th Edition). Routledge.
- Moos, D., & Azevedo, R. (2009). Learning With Computer-Based Learning Environments: A Literature Review of Computer Self-Efficacy. *Review of Educational Research - REV EDUC RES*, 79, 576–600. <https://doi.org/10.3102/0034654308326083>
- Moreno-Marcos, P., Alario-Hoyos, C., Merino, P., Estévez-Ayres, I., & Delgado-Kloos, C. (2018). A Learning Analytics Methodology for Understanding Social Interactions in MOOCs. *IEEE Transactions on Learning Technologies*, 12, 1. <https://doi.org/10.1109/TLT.2018.2883419>
- Muslim, A., Chatti, M., Mahapatra, T., & Schroeder, U. (2016). *A rule-based indicator definition tool for personalized learning analytics*. 264–273. <https://doi.org/10.1145/2883851.2883921>
- Mustafa, K. O. Ç. (2005). Implications of Learning Theories for Effective Technology Integration and Pre-service Teacher Training: A Critical Literature Review. *Journal of Turkish Science Education*.
- Namoun, A., & Alshanqiti, A. (2020). Predicting Student Performance Using Data Mining and Learning Analytics Techniques: A Systematic Literature Review. *Applied Sciences*, 11, 1–28. <https://doi.org/10.3390/app11010237>
- Naranjo Delgado, D. M., Prieto, J., Moltó, G., & Calatrava, A. (2019). A Visual Dashboard to Track Learning Analytics for Educational Cloud Computing. *Sensors*, 19. <https://doi.org/10.3390/s19132952>
- National Commission for Academic Accreditation & Assessment. (2015, listopad). <https://m.mu.edu.sa/sites/default/files/content/2017/02/ETMAD3.pdf>
- Ng, J., Wang, Z., & Hu, X. (2022). *Needs Analysis and Prototype Evaluation of Student-facing LA Dashboard for Virtual Reality Content Creation*. 444–450. <https://doi.org/10.1145/3506860.3506880>
- Nielsen, J. (1994). *Usability Engineering*. Morgan Kaufmann Publishers Inc.
- Nielsen, J. (2018). User satisfaction vs. performance metrics. U Nielsen Norman Group. <https://www.nngroup.com/articles/satisfaction-vs-performance-metrics/>
- Nielsen, J., & Landauer, T. K. (1993). A mathematical model of the finding of usability problems. *Proceedings of the INTERACT '93 and CHI '93 Conference on Human Factors in Computing Systems*, 206–213. <https://doi.org/10.1145/169059.169166>
- Owatari, T., Shimada, A., Minematsu, T., Hori, M., & Taniguchi, R. (2020). *Real-Time Learning Analytics Dashboard for Students in Online Classes*. 523–529. <https://doi.org/10.1109/TALE48869.2020.9368340>

- Papamitsiou, Z., & Economides, A. (2014). Learning Analytics and Educational Data Mining in Practice: A Systematic Literature Review of Empirical Evidence. *Educational Technology & Society*, 17, 49–64.
- Park, Y., & Jo, I.-H. (2015). Development of the Learning Analytics Dashboard to Support Students' Learning Performance. *JOURNAL OF UNIVERSAL COMPUTER SCIENCE*, 21, 110–133.
- Patel, Mrs. H., Raut, V., Dhok, A., Sagwadiya, J., More, S., Mahale, S., & Student. (2022). *ADVANCEMENT IN AGRICULTURE WITH AI, ML AND IOT: AN OVERVIEW*. <https://api.semanticscholar.org/CorpusID:254688426>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, E., & Louppe, G. (2012). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12.
- Plantak Vukovac, D. (2012). *Metoda vrednovanja tehničke i pedagoške upotrebljivosti sustava e-učenja kod akademskog mješovitog oblika učenja (Disertacija)*. [Disertacija, Sveučilište u Zagrebu, Fakultet organizacije i informatike]. <https://urn.nsk.hr/urn:nbn:hr:211:462656>
- Podgorelec, V., & Kuhar, S. (2011). Taking Advantage of Education Data: Advanced Data Analysis and Reporting in Virtual Learning Environments. *Elektronika ir Elektrotehnika*, 114, 111–116. <https://doi.org/10.5755/j01.eee.114.8.708>
- Powers, D., & Ailab. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness & correlation. *J. Mach. Learn. Technol*, 2, 2229–3981. <https://doi.org/10.9735/2229-3981>
- Pozdniakov, S., Martinez-Maldonado, R., Tsai, Y.-S., Cukurova, M., Bartindale, T., Chen, P., Marshall, H., Richardson, D., & Gasevic, D. (2022). *The Question-driven Dashboard: How Can We Design Analytics Interfaces Aligned to Teachers' Inquiry?* 175–185. <https://doi.org/10.1145/3506860.3506885>
- Premalatha, K. (2019). Course and Program Outcomes Assessment Methods in Outcome-Based Education: A Review. *Journal of Education*, 199, 002205741985435. <https://doi.org/10.1177/0022057419854351>
- Priručnik za izradu ishoda učenja.* (2018). https://www.unizd.hr/Portals/0/kvaliteta/Prirucnik_za_izradu_ishoda_ucenja.pdf?ve r=2019-03-07-133532-253
- Putra, F. A. T., Santoso, H. B., & Aji, R. F. (2018). Evaluation of learning analytics metrics and dashboard in a software engineering project course. *Australasian. Journal of Engineering Education*, 20, 171–180. <https://api.semanticscholar.org/CorpusID:202773570>
- Radović, S., Seidel, N., Menze, D., & Kasakowskij, R. (2024). Investigating the effects of different levels of students' regulation support on learning process and outcome: In search of the optimal level of support for self-regulated learning. *Computers & Education*. <https://doi.org/10.1016/j.compedu.2024.105041>
- Ramaswami, G. (2022). Learning Analytics: On Effectiveness of Dashboarding for Enhancing Student Learning. *U Journal of Learning Analytics* (Sv. 10). <https://mro.massey.ac.nz/items/c5e65326-b189-4cdb-8603-38e1af051d2a>
- Ramaswami, G., Susnjak, T., & Mathrani, A. (2023). Effectiveness of a Learning Analytics Dashboard for Increasing Student Engagement Levels. *Journal of Learning Analytics*, 10, 1–20. <https://doi.org/10.18608/jla.2023.7935>
- Ramaswami, G., Susnjak, T., Mathrani, A., & Umer, R. (2022). Use of Predictive Analytics within Learning Analytics Dashboards: A Review of Case Studies.

- Technology, Knowledge and Learning*, 28, 1–22. <https://doi.org/10.1007/s10758-022-09613-x>
- Ramos, C., & Yudko, E. (2008). “Hits” (not “Discussion Posts”) predict student success in online courses: A double cross-validation study. *Computers & Education*, 50, 1174–1182. <https://doi.org/10.1016/j.compedu.2006.11.003>
- Ramos Soto, A., Lama, M., Barreiros, B., Bugarín-Diz, A., Mucientes, M., & Barro, S. (2015, siječanj). *Towards Textual Reporting in Learning Analytics Dashboards*. <https://doi.org/10.1109/ICALT.2015.96>
- Ranjeeth, S., Latchoumi, T. P., & Paul, P. V. (2020). A Survey on Predictive Models of Learning Analytics. *Procedia Computer Science*, 167, 37–46. <https://doi.org/https://doi.org/10.1016/j.procs.2020.03.180>
- Rayon, A., Guenaga, M., & Núñez, A. (2014). *Integrating and visualizing learner and social data to elicit higher-order indicators in SCALA dashboard*. 1–4. <https://doi.org/10.1145/2637748.2638435>
- Ren, L., Wang, T., Sekhari Seklouli, A., Zhang, H., & Bouras, A. (2023). A review on missing values for main challenges and methods. *Information Systems*, 119, 102268. <https://doi.org/https://doi.org/10.1016/j.is.2023.102268>
- Rienties, B., Tempelaar, D., & Giesbers, B. (2015). In search for the most informative data for feedback generation: Learning Analytics in a data-rich context. *Computers in Human Behavior*, 47, 157–167. <https://doi.org/10.1016/j.chb.2014.05.038>
- Rodríguez Groba, A., Barreirosy, B., Lama, M., Barujel, A., & Mucientes, M. (2014, siječanj). *Using a Learning Analytics Tool for Evaluation in Self-Regulated Learning*. <https://doi.org/10.1109/FIE.2014.7044400>
- Rokach, L., & Maimon, O. (2008). Data mining with decision trees. Theory and applications. *U Mach Percept Artif Intell* (Sv. 69). https://doi.org/10.1142/9789812771728_0001
- Romero, C., & Ventura, S. (2007). Educational data mining: A survey from 1995 to 2005. *Expert Systems with Applications*, 33, 135–146. <https://doi.org/10.1016/j.eswa.2006.04.005>
- Romero, C., & Ventura, S. (2010). Educational Data Mining: A Review of the State of the Art. *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on*, 40, 601–618. <https://doi.org/10.1109/TSMCC.2010.2053532>
- Romero, C., & Ventura, S. (2013). Data Mining in Education. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 3. <https://doi.org/10.1002/widm.1075>
- Romero, C., & Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 10. <https://api.semanticscholar.org/CorpusID:213930151>
- Roslan, H., & Chen, C. J. (2022). Educational Data Mining for Student Performance Prediction: A Systematic Literature Review (2015–2021). *International Journal of Emerging Technologies in Learning (iJET)*, 17, 147–179. <https://doi.org/10.3991/ijet.v17i05.27685>
- Rubin, J. (2008). *Handbook of Usability Testing: How to Plan, Design and Conduct Effective Tests*.
- Ruble, D., & Flett, G. (1988). Conflicting Goals in Self-Evaluative Information Seeking: Developmental and Ability Level Analyses. *Child development*, 59, 97–106. <https://doi.org/10.2307/1130392>
- Ruipérez-Valiente, J. A., Merino, P., Gascon-Pinedo, J., & Delgado-Kloos, C. (2016). Scaling to Massiveness With ANALYSE: A Learning Analytics Tool for Open edX.

- IEEE Transactions on Human-Machine Systems*, 47, 909–914. <https://doi.org/10.1109/THMS.2016.2630420>
- Ruipérez-Valiente, J. A., Muñoz-Merino, P. J., Leony, D., & Delgado Kloos, C. (2015). ALAS-KA: A learning analytics extension for better understanding the learning process in the Khan Academy platform. *Computers in Human Behavior*, 47, 139–148. <https://doi.org/10.1016/j.chb.2014.07.002>
- Ruiz, S., Charleer, S., Maite, U., Klerkx, J., de Castro, I., & duval, erik. (2016). Supporting learning by considering emotions: Tracking and Visualization. A case study. *LAK '16: Proceedings of the Sixth International Conference on Learning Analytics & Knowledge*, 254–263. <https://doi.org/10.1145/2883851.2883888>
- Safsouf, Y., Mansouri, K., & Poirier, F. (2022, ožujak). *Understand the influence of learning analytics dashboards on learner self-regulation and academic success*. <https://doi.org/10.1109/EDUCON52537.2022.9766741>
- Sánchez, R., Nozal, C., Ji, Y. P., Pardo-Aguilar, C., & Arnaiz-González, Á. (2022). UBUMonitor: An Open-Source Desktop Application for Visual E-Learning Analysis with Moodle. *Electronics*, 11, 954. <https://doi.org/10.3390/electronics11060954>
- Santos, J., Govaerts, S., Verbert, K., & duval, erik. (2012). Goal-oriented visualizations of activity tracking: A case study with engineering students. *ACM International Conference Proceeding Series*, 143–152. <https://doi.org/10.1145/2330601.2330639>
- Santos, J., Verbert, K., Govaerts, S., & duval, erik. (2013). Addressing learner issues with StepUp!: An evaluation. *ACM International Conference Proceeding Series*, 14–22. <https://doi.org/10.1145/2460296.2460301>
- Saqr, M. (2018). *Using Learning Analytics to Understand and Support Collaborative Learning*. <https://doi.org/10.13140/RG.2.2.29579.44321>
- Sauro, Jeff. (2010). *A practical guide to measuring usability: 72 answers to the most common questions about quantifying the usability of websites and software*. Measuring Usability LCC.
- Scheffel, M. (2017). *The Evaluation Framework for Learning Analytics*. <https://api.semanticscholar.org/CorpusID:67283315>
- Schwendimann, B., Rodríguez-Triana, M., Vozniuk, A., Prieto, L., Shirvani Boroujeni, M., Holzer, A., Gillet, D., & Dillenbourg, P. (2016). Perceiving Learning at a Glance: A Systematic Literature Review of Learning Dashboard Research. *IEEE Transactions on Learning Technologies*, 10, 1. <https://doi.org/10.1109/TLT.2016.2599522>
- Sedrakyan, G., Malmberg, J., Verbert, K., Järvelä, S., & Kirschner, P. (2018). Linking Learning Behavior Analytics and Learning Science Concepts: Designing a Learning Analytics Dashboard for Feedback to Support Learning Regulation. *Computers in Human Behavior*, 107. <https://doi.org/10.1016/j.chb.2018.05.004>
- Seidel, N., Meyer, V., & Radović, S. (2024). Co-Design of an Adaptive Personalized Learner Dashboard. *2024 IEEE International Conference on Advanced Learning Technologies (ICALT)*, 26–28. <https://doi.org/10.1109/ICALT61570.2024.00014>
- Sekhar, D., Kumar, K., Saketh, K., Rao, K., & Babu, K. (2024). Secure E-Learning Activity Tracking using Federated Learning. *International Journal of Advanced Research in Science, Communication and Technology*, 403–414. <https://doi.org/10.48175/IJARSCT-17470>
- Shi, C., Fu, S., Chen, Q., & Qu, H. (2015). VisMOOC: Visualizing video clickstream data from Massive Open Online Courses. 159–166. <https://doi.org/10.1109/PACIFICVIS.2015.7156373>

- Shrestha, S., & Pokharel, M. (2021). Educational data mining in moodle data. *International Journal of Informatics and Communication Technology (IJ-ICT)*, 10, 9. <https://doi.org/10.11591/ijict.v10i1.pp9-18>
- Siadat, M., Gasevic, D., Jovanovic, J., Milikic, N., Jeremic, Z., Ali, L., Giljanović, A., & Hatala, M. (2012). *Learn-B: A Social Analytics-enabled Tool for Self-regulated Workplace Learning*. <https://doi.org/10.1145/2330601.2330632>
- Siemens, G. (2013). Learning Analytics The Emergence of a Discipline. *American Behavioral Scientist*, 57, 1380–1400. <https://doi.org/10.1177/0002764213498851>
- Siemens, G., & Baker, R. (2012). Learning analytics and educational data mining: Towards communication and collaboration. *ACM International Conference Proceeding Series*. <https://doi.org/10.1145/2330601.2330661>
- Siemens, G., Gaević, D., Haythornthwaite, C., Dawson, S., Shum, S. B., Ferguson, R., Duval, E., Verbert, K., & Baker, R. (2011). *Open Learning Analytics: an integrated modularized platform*. <https://api.semanticscholar.org/CorpusID:220865528>
- Siemens, G., & Long, P. (2011). Penetrating the Fog: Analytics in Learning and Education. *EDUCAUSE Review*, 5, 30–32. <https://doi.org/10.17471/2499-4324/195>
- Simon, P., Jiang, J., Fryer, L., King, R., & Frondozo, C. (2024). An Assessment of Learning Management System Use in Higher Education: Perspectives from a Comprehensive Sample of Teachers and Students. *Technology, Knowledge and Learning*. <https://doi.org/10.1007/s10758-024-09734-5>
- Simonson, M., Schlosser, C., & Orellana, A. (2011). Distance education research: A review of the literature. *J. Computing in Higher Education*, 23, 124–142. <https://doi.org/10.1007/s12528-011-9045-8>
- Simpson, M., & Anderson, B. (2012). History and heritage in open, flexible and distance education. *Journal of Open, Flexible and Distance Learning*, 16, 1–10. <https://doi.org/10.61468/jofdl.v16i2.56>
- Slade, S., & Prinsloo, P. (2013). Learning Analytics Ethical Issues and Dilemmas. *American Behavioral Scientist*, 57, 1510–1529. <https://doi.org/10.1177/0002764213479366>
- Smjernice za vrednovanje procesa učenja i ostvarenosti ishoda u osnovnoškolske i srednjoškolske odgoju i obrazovanju . (2020, veljača). <https://mzom.gov.hr/UserDocsImages/dokumenti/Obrazovanje/NacionalniKurikulum/Smjernice/Smjernice%20za%20vrednovanje%20procesa%20ucenja%20i%20ostvarenosti%20ishoda%20u%20osnovnoskolske%20i%20srednjoskolske%20odgoju%20i%20obrazovanju.pdf>
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45, 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Sorić, I. (2014). *Samoregulacija učenja: možemo li naučiti učiti Jastrebarsko: Naklada Slap, 2014., 665 str.*
- Soykan, F., & Şimşek, B. (2017). Examining studies on learning management systems in SSCI database: A content analysis study. *Procedia Computer Science*, 120, 871–876. <https://doi.org/10.1016/j.procs.2017.11.320>
- Strategija e-učenja 2007.–2010. (2007, svibanj). https://www.unizd.hr/Portals/0/kvaliteta/Prirucnik_za_izradu_ishoda_ucenja.pdf?ver=2019-03-07-133532-253
- Strategija e-učenja FOI-a. (2007). <https://repozitorij.foi.unizg.hr/islandora/object/foi%3A350/datastream/PDF/view>
- Susnjak, T., Ramaswami, G., & Mathrani, A. (2022). Learning analytics dashboard: a tool for providing actionable insights to learners. *International Journal of Educational*

Technology in Higher Education, 19, 12. <https://doi.org/10.1186/s41239-021-00313-7>

- Suthers, D., & Rosen, D. (2011). A unified framework for multi-level analysis of distributed learning. *ACM International Conference Proceeding Series*, 64–74. <https://doi.org/10.1145/2090116.2090124>
- Svetnik, V., Liaw, A., Tong, C., Culberson, J., Sheridan, R., & Feuston, B. (2003). Random Forest: A Classification and Regression Tool for Compound Classification and QSAR Modeling. *Journal of chemical information and computer sciences*, 43, 1947–1958. <https://doi.org/10.1021/ci034160g>
- Swenson, J. (2014). *Establishing an ethical literacy for learning analytics*. 246–250. <https://doi.org/10.1145/2567574.2567613>
- Tabassum, S., Pereira, F., Fernandes, S., & Gama, J. (2018). Social network analysis: An overview. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8, e1256. <https://doi.org/10.1002/widm.1256>
- Tervakari, A., Kuosa, K., Koro, J., Paukkeri, J., & Kailanto, M. (2014, siječanj). Teachers' learning analytics tools in a social media enhanced learning environment. *Proceedings of 2014 International Conference on Interactive Collaborative Learning, ICL 2014*. <https://doi.org/10.1109/ICL.2014.7017798>
- Tkalac Verčić, A., Čorić, D. S., & Vokić, N. P. (2010). *Priručnik za metodologiju istraživačkog rada - Kako osmisliti, provesti i opisati znanstveno i stručno istraživanje*. <https://api.semanticscholar.org/CorpusID:149715738>
- Topalli, D., & Cagiltay, N. (2018). Improving programming skills in engineering education through problem-based game projects with Scratch. *Computers & Education*, 120. <https://doi.org/10.1016/j.compedu.2018.01.011>
- Tretow-Fish, T., & Khalid, Md. S. (2024). Applying Kano's two-factor theory to prioritize learning analytics dashboard features for learning technology designers. *Contemporary Educational Technology*, 16, ep496. <https://doi.org/10.30935/cedtech/14286>
- Tullis, T., & Stetson, J. (2006). *A Comparison of Questionnaires for Assessing Website Usability*.
- Turnbull, D., Chugh, R., & Luck, J. (2020). *Learning Management Systems, An Overview* (str. 1052–1058). https://doi.org/10.1007/978-3-030-10576-1_248
- USDLA. (2011). *Instructional Media Selection Guide for Distance Learning: Implications for Blended Learning* (2nd izd.). https://www.usdla.org/wp-content/uploads/2015/05/AIMSGDL_2nd_Ed_styled_010311.pdf
- Valle, N., Antonenko, P., Pasha, Valle, D., Sommer, M., Huggins-Manley, A., Dawson, K., Kim, D., & Baiser, B. (2021). Predict or describe? How learning analytics dashboard design influences motivation and statistics anxiety in an online statistics course. *Educational Technology Research and Development*, 69. <https://doi.org/10.1007/s11423-021-09998-z>
- Valsamidis, S., Kontogiannis, S., Kazanidis, I., & Karakos, A. (2011). E-Learning Platform Usage Analysis. *Interdisciplinary Journal of E-Learning and Learning Objects*, 7, 185–204. <https://doi.org/10.28945/1511>
- van der Stappen, E. (2018, siječanj). *Workplace Learning Analytics in Higher Engineering Education*. <https://doi.org/10.1109/EDUCON.2018.8363102>
- van Leeuwen, A., & Rummel, N. (2020). Comparing teachers' use of mirroring and advising dashboards. 26–34. <https://doi.org/10.1145/3375462.3375471>
- Verbert, K., Duval, E., Klerkx, J., Govaerts, S., & Santos, J. L. (2013). Learning Analytics Dashboard Applications. *American Behavioral Scientist*, 57, 1500–1509. <https://api.semanticscholar.org/CorpusID:62736299>

- Verbert, K., Govaerts, S., duval, erik, Santos, J., Van Assche, F., Parra, G., & Klerkx, J. (2013). Learning dashboards: An overview and future research opportunities. *Personal and Ubiquitous Computing*, 18. <https://doi.org/10.1007/s00779-013-0751-2>
- Verbraeken, J., Wolting, M., Katzy, J., Kloppenburg, J., Verbelen, T., & Rellermeyer, J. (2020). A Survey on Distributed Machine Learning. *ACM Computing Surveys*, 53, 1–33. <https://doi.org/10.1145/3377454>
- Vesin, B., Mangaroska, K., & Giannakos, M. (2018). Learning in smart environments: user-centered design and analytics of an adaptive learning system. *Smart Learning Environments*, 5. <https://doi.org/10.1186/s40561-018-0071-0>
- Vieira, C., Parsons, P., & Byrd, V. (2018). Visual learning analytics of educational data: A systematic literature review and research agenda. *Computers & Education*, 122. <https://doi.org/10.1016/j.compedu.2018.03.018>
- Vivian, R., Falkner, K., Falkner, N., & Tarmazdi, H. (2016). A Method to Analyze Computer Science Students' Teamwork in Online Collaborative Learning Environments. *ACM Transactions on Computing Education*, 16, 1–28. <https://doi.org/10.1145/2793507>
- Vizek-Vidović, V. (2009). *Planiranje kurikulumu usmjerenog na kompetencije u obrazovanju učitelja i nastavnika: priručnik za visokoškolske nastavnike - ISRZ Repository*. <http://idiprints.knjiznica.idi.hr/297/>
- Volaric, T., & Ljubić, H. (2017). *Learner and course dashboards for intelligent learning management systems*. 1–6. <https://doi.org/10.23919/SOFTCOM.2017.8115555>
- Vreugd, L., van Leeuwen, A., Jansen, R., & Schaaf, M. F. (2024). Learning Analytics Dashboard Design and Evaluation to Support Student Self-Regulation of Study Behaviour. *Journal of Learning Analytics*, 1–14. <https://doi.org/10.18608/jla.2024.8529>
- Wang, A., & Newlin, M. (2000). Characteristics of Students Who Enroll and Succeed in Psychology Web-Based Classes. *Journal of Educational Psychology*, 92, 137–143. <https://doi.org/10.1037/0022-0663.92.1.137>
- Wang, A., & Newlin, M. H. (2002). Predictors of Performance in the Virtual Classroom: Identifying and Helping At-Risk Cyber-Students. *T.H.E. Journal Technological Horizons in Education*, 29, 21. <https://api.semanticscholar.org/CorpusID:60187105>
- Wang, C., Ng, J., Hernández López, N., & Hu, X. (2024, ožujak). *Preliminary Evaluation of Learning Analytics Dashboard for College Teachers' Online Professional Learning*. <https://doi.org/10.1109/ICALT61570.2024.00030>
- Wasserman, S., & Faust, K. (1994). Social Network Analysis Methods and Applications. *U Journal of the American Statistical Association* (Sv. 91). <https://doi.org/10.2307/2077235>
- Watson, W., & Watson, S. (2007). An Argument for Clarity: What are Learning Management Systems, What are They Not, and What Should They Become? *TechTrends*, 51, 28–34. <https://doi.org/10.1007/s11528-007-0023-y>
- Watts-Taffe, S., Gwinn, C. B., Johnson, J. R., & Horn, M. L. (2003). Preparing preservice teachers to integrate technology with the elementary literacy program. *The Reading Teacher*, 57, 130–138.
- Webb, G. (2016). *Naïve Bayes* (str. 1–2). https://doi.org/10.1007/978-1-4899-7502-7_581-1
- Webster, J., & Watson, R. (2002). Analyzing the Past to Prepare for the Future: Writing a Literature Review. *MIS Quarterly*, 26. <https://doi.org/10.2307/4132319>
- Weert, T., & Tatnall, A. (2005). *Information and communication technologies and real-life learning: New education for the knowledge society*. 182.

- Wiggins, G. (2012). Seven Keys to Effective Feedback. *Educational Leadership*, 70, 10–16. <https://api.semanticscholar.org/CorpusID:142607307>
- Williamson, K. C., & Kizilcec, R. F. (2022). A Review of Learning Analytics Dashboard Research in Higher Education: Implications for Justice, Equity, Diversity, and Inclusion. *LAK22: 12th International Learning Analytics and Knowledge Conference*. <https://api.semanticscholar.org/CorpusID:247222381>
- Wolf, G. (2009). Know thyself: Tracking every facet of life, from sleep to mood to pain 24/7/365. *Wired*, 92–95.
- Wu, W., & Hwang, L.-Y. (2010). The effectiveness of e-learning for blended courses in colleges: A multi-level empirical study. *International Journal of Electronic Business Management*, 8.
- Yadav, A. (2024). Enhancing E-Learning Platform for Higher Education. *INTERANTIONAL JOURNAL OF SCIENTIFIC RESEARCH IN ENGINEERING AND MANAGEMENT*, 08, 1–5. <https://doi.org/10.55041/IJSREM30948>
- Yagci, M. (2022). Educational data mining: prediction of students' academic performance using machine learning algorithms. *Smart Learning Environments*, 9. <https://doi.org/10.1186/s40561-022-00192-z>
- Yin, R. K. (2018). *Case Study Research and Applications: Design and Methods* (Sixth). CA: Sage.
- Yoo, Y., Lee, H., Jo, I.-H., & Park, Y. (2015). Educational Dashboards for Smart Learning: Review of Case Studies. U *Lecture Notes in Educational Technology* (str. 145–155). https://doi.org/10.1007/978-3-662-44188-6_21
- York, T., Gibson III, C., & Rankin, S. (2015). Defining and Measuring Academic Success. *Practice Assessment, Research & Evaluation*, 20.
- Yousaf, F., Shehzadi, K., & Haider Aali, A. (2021). Learning Management System (LMS): The Perspectives of Teachers. *Global Social Sciences Review*, VI, 183–196. [https://doi.org/10.31703/gssr.2021\(VI-I\).18](https://doi.org/10.31703/gssr.2021(VI-I).18)
- Zaffar, M., Ahmed, M., Savita, K. S., & Sajjad, S. (2018). A Study of Feature Selection Algorithms for Predicting Students Academic Performance. *International Journal of Advanced Computer Science and Applications*, 9. <https://doi.org/10.14569/IJACSA.2018.090569>
- Zheng, A., & Casari, A. (2018). *Feature Engineering for Machine Learning: Principles and Techniques for Data Scientists* (1st izd.). O'Reilly Media, Inc.
- Zheng, J., Huang, L., Li, S., Lajoie, S., Chen, Y., & Hmelo-Silver, C. (2021). Self-regulation and emotion matter: A case study of instructor interactions with a learning analytics dashboard. *Computers & Education*, 161, 104061. <https://doi.org/10.1016/j.compedu.2020.104061>
- Zmuda, A., Curtis, G., Ullman, D., & Jacobs, H. H. (2015). *Learning Personalized: The Evolution of the Contemporary Classroom*. <https://api.semanticscholar.org/CorpusID:156972444>

PRILOZI

S obzirom na kompleksnost područja obuhvaćenog ovom doktorskom disertacijom, veliki dio detaljnih objašnjenja, opisa i analiza nalazi se u prilogima. Prilozi ovoj doktorskoj disertaciji obuhvaćaju sljedeće:

- Prikaz i detaljan popis analiziranih publikacija koje opisuju LAD-ove i njihove

karakteristike, u svrhu utvrđivanja trenutnog stanja istraženosti LAD-ova (Prilog A).

- Skup podataka korišten za modele predviđanja i primjer koda (Prilog B)
- Prikaz korištenih instrumenata za vrednovanje LAD-s (Prilog C)
- Prikaz korištenih instrumenata za vrednovanje LAD-t (Prilog D)

PRILOG A – ANALIZA PUBLIKACIJA UKLJUČENIH U SUSTAVNI PREGLED LITERATURE

U ovom potpoglavlju prikazujemo rezultate sustavnog pregleda literature. Prilog A1 prikazuje pregled praćenih karakteristika svih publikacija uključenih u sustavni pregled. Prilog A2 prikazuje ciljeve razvoja LAD-ova. Prilog A3 prikazuje analizu korištenja prediktivne analitike, izdvajajući relevantne publikacije te razmatrajući ciljeve korištenja, tehnike primjene i korištene algoritme. Prilog A4 prikazuje rezultate vrednovanja LAD-ova, pri čemu se usmjeravamo na publikacije koje opisuju ciljne skupine, korištene metode vrednovanja i ključne nalaze.

PRILOGA A1 – PREGLED PUBLIKACIJA I NJIHOVIH KARAKTERISTIKA

U ovom dijelu prikazujemo sve publikacije uključene u sustavni pregled literature, zajedno s praćenim karakteristikama.

	Korišteni podaci							Korisnici sustava		Vrednovanje	Povratna informacija			Prediktivna analitika
	S	L	P n m	D	V	P s	P o v	N	U		O b a v	Vizu aliza cija	Tek st	
(Ruipérez-Valiente i ostali, 2015)	*	*	*	-	*	-	-	*	*	-	*	*	-	-
(Moreno-Marcos i ostali, 2018)	*	-	-	*	*	-	-	-	*	*	-	*	-	-
(Filvá i ostali, 2016)	-	-	*	*	*	-	-	*	-	*	-	*	*	-
(Vivian i ostali, 2016)	-	-	-	*	-	-	-	*	-	-	-	*	-	-

(Anh i ostali, 2018)	*	*	*	-	-	-	*	*	*	-	*	*	-	*
(Naranjo Delgado i ostali, 2019)	-	-	*	-	*	-	-	*	*	*	-	*	-	-
(Aljohani i ostali, 2018)	-	*	*	*	*	-	-	*	*	*	-	*	*	-
(Rayon i ostali, 2014)	*	-	*	*	-	-	-	*	*	-	-	*	*	-
(Ruipérez-Valiente i ostali, 2016)	-	*	*	-	*	-	-	*	*	-	-	*	*	-
(Broos i ostali, 2017)	-	-	*	-	-	-	*	*	-	*	*	*	*	-
(Hussain i ostali, 2018)	*	*	*	-	*	-	*	*		-	*	-	-	*
(Tervakari i ostali, 2014)	-	*	-	*	-	-	-	*	-	*	-	*	-	-
(Majumdar i ostali, 2019)	*	*	*	-	*	-	-	*	*	-	*	*	*	-
(Corrin i ostali, 2015)	-	-	*	*	*	-	-	*	-	-	-	*	-	-
(Ramos Soto i ostali, 2015)	-	-	*	*	*	-	-	*	-	-	-	*	*	-
(R. Bodily i ostali, 2018)	-	-	*	-	*	-	-	-	*	*	*	*	*	-
(Garcia-Zubia i ostali, 2019)	-	*	*	-	*	-	-	*	-	-	-	*	-	-
(Fenu i ostali, 2017)	-	*	*	-	*	-	-	/	/	*	-	*	*	-
(Cobos & Olmos Camarena, 2018)	*	*	*	*	*	-	*	/	/	-	-	*	-	*
(Aljohani & Davis, 2013)	*	-	*	-	*	-	-	-	*	*	-	-	-	-
(Azcona i ostali, 2018)	*	*	*	-	*	-	*	*	*		*	-	*	*
(Guenaga i ostali, 2015)	-	-	*	*	*	-	-	*	-	*	-	*	-	-
(van der Stappen, 2018)	/							*	*	*	-	*	*	-
(Rodríguez Groba i ostali, 2014)	-	*	*	*	*	-	-	*	*	*	-	*	*	-
(Ruiz i ostali, 2016)	/							*	*	*	-	*	*	-
(Martínez-Maldonado i ostali, 2015)	-	-	-	-	-	*	-	*	-	*	-	*	-	-

(Charleer i ostali, 2017)	*	-	*	-	*	-	*	-	*	*	-	*	-	*
(Dabbebi i ostali, 2019)	/							*	-	*	-	*	*	-
(Graf i ostali, 2011)	-	*	*	*	*	-	-	*	-	-	-	-	*	-
(Bader-Natal & Lotze, 2011)	-	-	*	-	*	-	-	*	*	-	*	-	*	-
(Bakharia & Dawson, 2011)	*	-	-	*	-	*	-	*	-	-	-	*	-	-
Arnold & Pistilli (2012)	*	-	*	-	-	-	*	-	*	*	*	-	*	*
(Leony i ostali, 2012)	-	*	*	-	*	-	-	*	*	-	-	*	-	-
(Santos i ostali, 2012)	*	*	-	-	*	-	-	-	*	*	-	*	-	-
(Siadaty i ostali, 2012)	*	*	*	*	*	-	-	-	*	-	*	*	*	-
(Essa & Ayad, 2012)	*	*	*	*	*	-	*	*	*	-	-	*	-	*
(Santos i ostali, 2013)	*	*	*	*	*	-	-	*	*	*	-	*	*	-
(Holman i ostali, 2013)	*	*	*	-	*	-	-	*	*	-	-	*	*	-
(Aguilar i ostali, 2014)	*	*	*	-	*	-	-	*	-	-	-	*	*	-
(Muslim i ostali, 2016)	*	*	*	*	*	-	-	*	*	*	-	*	-	-
(Ez-zaouia & Lavoué, 2017)	-	-	-	-	-	*	-	*	-	*	-	*	-	-
(Herodotou i ostali, 2017)	*	*	*	-	-	-	-	*	-	*	-	*	*	-
(Fu i ostali, 2017)	*	*	*	-	*	-	-	*	*	-	-	*	*	-
(Millecamp i ostali, 2018)	-	-	*	-	-	-	-	*	*	*	-	*	*	-
(De Quincey i ostali, 2019)	*	*	*	-	*	-	*	-	*	*	*	*	-	*
(Dyckhoff i ostali, 2012)	-	*	*	*	*	-	-	*	-	*	-	*	-	-
(Ali i ostali, 2012)	*	*	*	*	*	-	-	*	-	*	-	*	-	-
(May i ostali, 2011)	-	-	*	*	-	-	-	*	*	*	-	*	*	-
(Govaerts i ostali, 2012)	*	*	*	*	*	-	-	*	*	*	*	*	*	-
(Jovanovic i ostali, 2012)	*	*	*	*	*	-	*	*	-	-	-	-	*	*
(Podgorelec & Kuhar, 2011)	*	*	*	*	*	-	-	*	-	-	-	*	*	-

(Shi i ostali, 2015)	*	*	*	*	*	-	-	*	-	-	-	*	-	-
(Akçapınar & Bayazit, 2019)	*	*	*	*	*	-	*	*	-	-	-	*	-	*
(Ji i ostali, 2014)	-	*	*	*	*	-	-	*	-	-	-	*	-	-
(Vesin i ostali, 2018)	-	*	*	-	*	-	-	*	*	*	-	*	*	-
(Gómez Aguilar i ostali, 2013)	-	*	*	*	*	-	-	*	-	-	-	*	-	-
(Putra i ostali, 2018)	*	-	*	-	*	-	-	*	*	*	-	*	-	-
(Gutierrez i ostali, 2018)	-	*	*	-	*	-	*	*	-	*	-	*	-	*
(Gruzd & Conroy, 2018)	*	-	-	*	*	-	-	*	-	-	-	*	*	-
(Park & Jo, 2015)	-	*	*	-	*	-	-	-	*	*	-	*	-	-
(Volaric & Ljubić, 2017)	-	*	*	-	*	-	-	*	*	*	-	*	*	-
(Kaur & Chahal, 2024)	*	*	*	-	-	*	*	*	*	*	*	-	*	*
(Cechinel i ostali, 2021)	*	*	*	-	*	-	*	*	-	-	-	*	*	*
(Hasnine i ostali, 2023)	*	*	*	-	*	*	*	*	-	-	*	*	*	*
(Buvari i ostali, 2023)	*	*	*	-	*	-	-	-	*	*	-	*	*	-
(Dourado i ostali, 2021)	*	*	*	-	*	-	-	*	-	*	-	*	*	-
(De Laet i ostali, 2020)	*	*	*	*	-	-	*	*	-	*	*	*	-	*
(Tretow-Fish & Khalid, 2024)	/							-	*	*	*	-	*	-
(Fernandez Nieto i ostali, 2022)	*	*	-	-	*	*	-	-	*	*	*	*	-	-
(Kaliisa & Dolonen, 2022)	-	*	-	*	*	-	-	*	-	*	-	-	*	-
(Bayer i ostali, 2024)	*	*	*	*	*	-	-	*	-	*	*	*	*	-
(Alfredo i ostali, 2024)	*	*	*	-	-	-	-	*	-	*	*	*	*	-
(Duan i ostali, 2022)	*	*	*	-	*	-	*	-	*	*	*	*	-	*
(Avila-Garzon i ostali, 2020)	*	-	-	-	*	-	-	*	-	*	*	*	*	-
(Bao i ostali, 2021)	-	-	-	*	*	-	-	*	-	*	-	*	*	-
(H. Choi i ostali, 2023)	*	*	*	-	-	-	-	-	*	*	*	*	*	-

(Vreugd i ostali, 2024)	*	*	*	*	*	-	-	-	*	*	*	*	*	-
(Distante i ostali, 2020)	*	*	*	-	-	-	-	*	-	-	-	*	*	-
(Ez-zaouia i ostali, 2020)	*	*	-	-	*	*	-	*	-	*	*	*	*	-
(Q. Fu i ostali, 2023)	*	*	*	*	*	-	-	*	*	*	*	*	*	-
(Haynes-Magyar, 2020)	*	*	*	*	*	-	-	-	*	*	*	*	*	-
(Hu i ostali, 2021)	*	*	*	*	-	-	-	*	*	*	-	*	*	-
(Jaramillo-Morillo i ostali, 2022)	*	*	*	*	*	-	-	*	-	*	-	*	*	-
(Jayashanka i ostali, 2022)	*	*	*	*	*	-	-	-	*	*	*	*	*	-
(Khalil & Belokrys, 2020)	*	*	*	*	*	-	-	*	*	-	-	*	-	-
(Sánchez i ostali, 2022)	*	*	*	*	*	-	-	*	*	*	*	*	*	-
(Owatari i ostali, 2020)	*	*	*	-	*	-	-	-	*	*	*	*	*	-
(Radović i ostali, 2024)	*	*	*	-	*	-	-	-	*	*	*	-	*	-
(Ramaswami i ostali, 2023)	*	*	*	*	*	-	*	-	*	*	*	*	*	*
(Susnjak i ostali, 2022)	*	*	*	*	*	-	*	-	*	-	*	*	*	*
(Valle i ostali, 2021)	*	*	*	-	*	-	-	-	*	*	*	*	*	-
(C. Wang i ostali, 2024)	*	*	*	-	*	-	-	*	-	*	*	*	*	-
(J. Zheng i ostali, 2021)	*	*	*	*	*	-	-	*	*	*	*	*	*	-
(Safsouf i ostali, 2022)	*	*	*	-	*	-	*	*	*	*	*	*	*	*
(Seidel i ostali, 2024)	*	*	*	-	*	-	-	-	*	*	*	*	*	-
(AlZoubi i ostali, 2024)	*	*	*	-	*	-	-	*	-	*	-	*	*	-
(Eickholt i ostali, 2022)	*	*	*	-	*	-	-	-	*	*	-	*	-	-
(van Leeuwen & Rummel, 2020)	*	*	*	-	*	-	-	*	-	*	*	*	*	-
(Kia i ostali, 2020)	*	*	*	-	*	-	-	-	*	*	-	*	*	-
(Pozdniakov i ostali, 2022)	*	*	*	-	*	-	-	*	-	*	*	*	-	-

(Ng i ostali, 2022)	*	*	*	-	*	-	-	-	*	*	*	*	*	-
---------------------	---	---	---	---	---	---	---	---	---	---	---	---	---	---

Legenda:

Simboli u tablici označavaju prisutnost ili odsutnost specifičnih vrsta podataka za svaku publikaciju. Za svaki redak, simbol „*” označava da su određeni podaci prisutni, dok simbol „-“ označava da podaci nisu prisutni. Također, simbol „/“ znači da podaci nisu navedeni u izvoru. Unutar kategorije „Korišteni podaci”: S - statični podaci, L - podaci logiranja, Pnm - korištenje nastavnih materijala i postignuća, D - podaci društvenih mreža, V - vremenski podaci, Ps - psihološki podaci, Pov - povijesni podaci.

PRILOG A2 – CILJEVI RAZVOJA LAD-A

Cilj	Publikacija	Broj radova	Postotak
Praćenje i podrška	(Naranjo Delgado i ostali, 2019), (Rayon i ostali, 2014), (Ramos Soto i ostali, 2015), (Tervakari i ostali, 2014), (R. Bodily i ostali, 2018), (Fenu i ostali, 2017), (Dabbebi i ostali, 2019), (Ali i ostali, 2012), (Gutierrez i ostali, 2018), (Volaric & Ljubić, 2017), (Park & Jo, 2015), (Guenaga i ostali, 2015), (Holman i ostali, 2013), (Ez-zaouia & Lavoué, 2017), (Gruzd & Conroy, 2018), (Aguilar i ostali, 2014), (De Quincey i ostali, 2019), (Ruipérez-Valiente i ostali, 2016), (Kaur & Chahal, 2024), (Hasnine i ostali, 2023), (De Laet i ostali, 2020), (Fernandez Nieto i ostali, 2022), (Bayer i ostali, 2024), (Alfredo i ostali, 2024), (Avila-Garzon i ostali, 2020), (Ez-zaouia i ostali, 2020), (Hu i ostali, 2021), (Jayashanka i ostali, 2022), (Khalil & Belokrys, 2020), (Sánchez i ostali, 2022), (Owatari i ostali, 2020), (Radović i ostali, 2024), (Ramaswami i ostali, 2023), (Susnjak i ostali, 2022), (C. Wang i ostali, 2024), (J. Zheng i ostali, 2021), (AlZoubi i ostali, 2024), (van Leeuwen & Rummel, 2020), (Pozdniakov i ostali, 2022)	39	38,61%
Vizualizacija	(Filvá i ostali, 2016), (Ruipérez-Valiente i ostali, 2016), (Majumdar i ostali, 2019), (Corrin i ostali, 2015), (Fenu i ostali, 2017), (Ruiz i ostali, 2016), (Charleer i ostali, 2017), (Bakharia & Dawson, 2011), (Leony i ostali, 2012), (Millecamp i ostali, 2018), (Ji i ostali, 2014), (Vesin i ostali, 2018), (Putra i ostali, 2018), (Ruipérez-Valiente i ostali, 2015), (Buvvari i ostali, 2023), (Fernandez Nieto i ostali, 2022), (Kaliisa & Dolonen, 2022), (Bao i ostali, 2021), (Q. Fu i ostali, 2023), (Kia i ostali, 2020)	20	19,80%

Metakognitivno poimanje	(Aljohani & Davis, 2013), (Broos i ostali, 2017), (Dyckhoff i ostali, 2012), (Govaerts i ostali, 2012), (Rodríguez Groba i ostali, 2014), (Ji i ostali, 2014), (Martinez-Maldonado i ostali, 2015), (May i ostali, 2011), (Santos i ostali, 2012), (Santos i ostali, 2012), (Siadaty i ostali, 2012), (Volaric & Ljubić, 2017), (Duan i ostali, 2022), (H. Choi i ostali, 2023), (Vreugd i ostali, 2024), (Ez-zaouia i ostali, 2020), (Haynes-Magyar, 2020), (Valle i ostali, 2021), (Ng i ostali, 2022), (Seidel i ostali, 2024)	20	19,80%
Predviđanje	(Akçapınar & Bayazit, 2019), (Arnold & Pistilli, 2012), (Azcona i ostali, 2018), (Cobos & Olmos Camarena, 2018), , (Gutierrez i ostali, 2018), (Herodotou i ostali, 2017), (Jovanovic i ostali, 2012), (Millecamp i ostali, 2018), (Anh i ostali, 2018), (De Quincey i ostali, 2019), (Ramaswami i ostali, 2023), (Susnjak i ostali, 2022), (Kaur & Chahal, 2024), (Cechinel i ostali, 2021), (Hasnine i ostali, 2023)	15	14,85%
Analiza	(Akçapınar & Bayazit, 2019), (Bader-Natal & Lotze, 2011), , (Filv i ostali, 2016), (Garcia-Zubia i ostali, 2019), (Graf i ostali, 2011), (Ji i ostali, 2014), (Majumdar i ostali, 2019), (Moreno-Marcos i ostali, 2018), (Shi i ostali, 2015), (Bakharia & Dawson, 2011), (Eickholt i ostali, 2022), (Dourado i ostali, 2021), (Tretow-Fish & Khalid, 2024), (Distante i ostali, 2020), (van Leeuwen & Rummel, 2020)	15	14,85%
Personalizacija	(Azcona i ostali, 2018), (Broos i ostali, 2017), (Holman i ostali, 2013), (Muslim i ostali, 2016), (Vesin i ostali, 2018), (Eickholt i ostali, 2022), (Kia i ostali, 2020)	7	6,93%
Detekcija/ identifikacija	(Fu i ostali, 2017), (Hussain i ostali, 2018), (Q. Fu i ostali, 2023), (Hu i ostali, 2021), (Jaramillo-Morillo i ostali, 2022), (van Leeuwen & Rummel, 2020)	6	5,94%
Usporedba	(Podgorelec & Kuhar, 2011), (Pozdniakov i ostali, 2022), (Bao i ostali, 2021)	3	2,97%
Komunikacija i dijalog	(Charleer i ostali, 2017), (Millecamp i ostali, 2018)	2	1,98%
Grupiranje	(Gomez Aguilar i ostali, 2013), (Jovanovic i ostali, 2012)	2	1,98%

Analitika u radnom okruženju	(van der Stappen, 2018)	1	0,99%
-------------------------------------	-------------------------	---	-------

PRILOG A3 – KORIŠTENJE PREDIKTIVNE ANALITIKE U LAD-OVIMA

Ovdje ćemo analizirati kako se PA koristi u LAD-ovima, razmatrajući relevantne publikacije, ciljeve korištenja prediktivne analitike, primijenjene tehnike i korištene algoritme.

Referenca	Tehnika	Korišteni algoritam	Cilj predviđanja
(Anh i ostali, 2018)	Regresija	LR	Uspjeh učenika
(Hussain i ostali, 2018)	Klasifikacija	FURIA	Predviđanje aktivnih i neaktivnih učenika
(Cobos & Olmos Camarena, 2018)	Klasifikacija	BGLM(Bayesian Generalized Linear Model), Boosting, NB	Predviđanje učenika sklonih odustajanju i predviđanje završetka predmeta
(Azcona i ostali, 2018)	Klasifikacija	LR, , SVM, RF,DT	Predviđanje uspjeha učenika na različitim predmetima
Arnold & Pistilli (2012)	Nije evidentirano	Razvili svoj algoritam	Predviđanje rizičnih skupina učenika
(De Quincey i ostali, 2019)	Klasifikacija	DT	Predviđanje uspjeha učenika
(Jovanovic i ostali, 2012)	Klasifikacija	ANN, Boosting algoritmi	Predviđanje uspjeha učenika
(Akçapınar & Bayazit, 2019)	Klasifikacija	Nije evidentirano	Predviđanje uspjeha učenika
(Kaur & Chahal, 2024)	Klasifikacija	XGBoost Random Forest, SVM, KNN, Boosting, DT	Predviđanje uspjeha učenika
(Cechinel i ostali, 2021)	Klasifikacija	Boosting	Predviđanje uspjeha učenika (u riziku od odustajanja)
(Hasnine i ostali, 2023)	Klasifikacija	Perspective-n-Point (PnP) algoritam	Predviđanje angažmana učenika

(Ramaswami i ostali, 2023)	Klasifikacija	Boosting, KNN; Naive Bayes, Logistic regression, Random forest	Predviđanje uspjeha učenika (u riziku od odustajanja)
(Susnjak i ostali, 2022)	Klasifikacija	Boosting	Predviđanje uspjeha učenika (u riziku od odustajanja)

PRILOG A4 – VREDNOVANJE LAD-OVA: CILJANA SKUPINA, METODA I KLJUČNI NALAZI

Ovdje ćemo analizirati vrednovanje LAD-ova, usmjeravajući pažnju na ciljne skupine, korištene metode vrednovanja i ključne nalaze iz relevantnih publikacija.

Referenca	Ciljana skupina	Metoda	Ključni nalazi
(Moreno-Marcos i ostali, 2018)	Učenici	Upitnik + Analiza interakcija	Učenici su zadovoljni sa LAD-om. Aktivnost učenika je generalno prihvatljiva, no, aktivnost učenika za korištenje LAD-a opada s vremenom.
(Filvá i ostali, 2016)	Nastavnici	Upitnik	Većina nastavnika smatra da su zaključci o interakciji učenika korisni. Neki bi radije koristili drugačiji format prikaza podataka.
(Naranjo Delgado i ostali, 2019)	Učenici	Upitnik	Učenici su percipirali visoku razinu korisnosti LAD-ova.
(Aljohani i ostali, 2018)	Učenici	Ispitivanje utjecaja	Učenici koji su koristili LAD pokazali su statistički značajnu razliku u angažmanu u usporedbi s kontrolnom skupinom.
(Broos i ostali, 2017)	Učenici	Upitnik + Analiza interakcija učenika	Učenici pozitivno ocjenjuju korisnost i jasnoću LAD-a, ali percepcija njenog utjecaja na zadovoljstvo rezultatima varira. Rezultati nisu jedinstveni, tj. slabiji učenici manje koriste LAD.
(Tervakari i ostali, 2014)	Nastavnici	Fokus grupa	Nastavnici smatraju LAD alate korisnima za praćenje napretka učenika, identificiranje rizičnih učenika i usporedbu aktivnosti učenika.
(R. Bodily i ostali, 2018)	Učenici	Fokus grupa i upitnik	79 % učenika smatra LAD-ove intuitivnima, zanimljivima i korisnima.

		(Verbert i Yoo)	
(Fenu i ostali, 2017)	Učenici	Analiza interakcija	Nova metoda analize upotrebljivosti u Moodle LMS-u omogućuje pasivno prikupljanje podataka bez potrebe za aktivnim angažmanom korisnika.
(Aljohani & Davis, 2013)	Učenici	Upitnik	84 % učenika smatra LAD korisnim.
(Guenaga i ostali, 2015)	Učenici	Upitnik + Analiza interakcija	Učenici su općenito zadovoljni sa LAD-om i smatraju da je koristan u procesu učenja i poučavanja.
(van der Stappen, 2018)	Nastavnici	Intervju	Rezultati pokazuju da LAD omogućuje pravovremene uvide u proces učenja učenika na, što može poboljšati njihovu podršku i praćenje napretka.
(Rodríguez Groba i ostali, 2014)	Nastavnici	Upitnik - CSUQ	Nastavnici preporučuju korištenje alata.
(Ruiz i ostali, 2016)	Učenici	Upitnik i intervju + Analiza interakcija	55 % učenika smatra da LAD može pozitivno utjecati na ponašanje. Nakon duljeg korištenja LAD-a ovaj postotak raste na 73 %.
(Martínez-Maldonado i ostali, 2015)	Nastavnici	Upitnik i intervju	Nastavnici smatraju da je LAD koristan za donošenje odluka. Pokazalo se koje vizualizacije su najbitnije iz perspektive nastavnika.
(Charleer i ostali, 2017)	Učenici i nastavnici	Upitnik	Korisnici rado koriste LAD. Napominju da, „izgleda odlično“, pruža im pouzdane podatke i dodatnu vrijednost.
(Dabbebi i ostali, 2019)	Nastavnici	Fokus grupa	Nastavnici su zadovoljni strukturom LAD-a.
Arnold & Pistilli (2012)	Učenici i nastavnici	Upitnik	89 % učenika smatra korištenje LAD-a pozitivnim iskustvom; 58 % bi ga koristilo u svakom predmetu. Nastavnici su oprezni u njegovom korištenju.
	Učenici	Analiza interakcija	Usporedbom postignuća učenika prije i nakon uvođenja LAD-a, korištena je deskriptivna statistika za određivanje njegovog utjecaja na postignuće učenika. Nastava s LAD-om (u usporedbi s istim predmetom prije uvođenja) zabilježila je povećan broj boljih ocjena te smanjen broj lošijih ocjena.
(Santos i ostali, 2012)	Učenici	Upitnik - SUS i pitanja otvorenog tipa	Učenici smatraju LAD korisnim, ali nisu motivirani za korištenje. Prosječna ocjena SUS upitnika 72.

	Nastavnici	Razmišljanje naglas	Primijenjen je protokol glasnog razmišljanja. Rezultati pokazuju kako nastavnicima, općenito, nedostaje informacija o tome što vizualizacije prikazuju.
(Santos i ostali, 2013)	Učenici	Upitnik - SUS	Svi Učenici ocijenili su LAD između prihvatljivog i dobrog. Prema rezultatima SUS upitnika, prosječna ocjena iznosi 67.9 za učenike prvog programa, 67.5 za učenike drugog programa te 72.1 za učenike koji rade na završnom radu. Ukupno gledano, upotrebljivost alata smanjena je u odnosu na prethodnu verziju.
(Muslim i ostali, 2016)	Učenici i nastavnici	Upitnik - SUS + upitnik	Korisnicima se sviđa fleksibilnost vizualizacije, ali žele jednostavnije korisničko sučelje. Prosječna ocjena SUS upitnika iznosi 53.
(Ez-zaouia & Lavoué, 2017)	Nastavnici	Upitnik	LAD se percipira kao jednostavan za korištenje, ali ima problema s vizualizacijom vremenskih podataka. Unatoč tome, ukupna percepcija LAD-a je prilično pozitivna.
(Herodotou i ostali, 2017)	Nastavnici	Intervju + Analiza interakcija	Nastavnici su zainteresirani za korištenje LAD-a kako bi prepoznali rizične učenike. Od 70 nastavnika, 60 ih je koristilo LAD. U nekim predmetima pristup je bio znatno rjeđi, što ukazuje na nedosljednu upotrebu LAD-a.
(Millecamp i ostali, 2018)	Učenici	Upitnik	Rezultati pokazuju da se učenici slažu kako je LAD jasan, pouzdan, omogućuje uvid u njihovu trenutnu situaciju i budući obrazovni put te ih osvještava o njihovom učenju.
(De Quincey i ostali, 2019)	Učenici	Upitnik - UEQ i intervju + Analiza interakcija	Učenici su imali uglavnom pozitivne dojmove, iako su rezultati na UEQ upitniku bili tek nešto iznad prosjeka ili ocijenjeni kao „dobri“. Angažiranost učenika poboljšana je u odnosu na prethodne generacije, no korištenje LAD-a i dalje je bilo nisko u nekim predmetima.
(Dyckhoff i ostali, 2012)	Nastavnici	Razmišljanje naglas	Testiran LAD alat na četiri predmeta. Korisnici su dobili zadatke usmjerene na praćenje napretka u učenju prikazane u LAD-u. Nastavnici smatraju da je LAD koristan ali su potrebna daljnja ispitivanja s različitim predmetima kako bi se bolje razumjela njegova pedagoška korisnost.
(Ali i ostali, 2012)	Nastavnici	Upitnik	Nakon rezultata istraživanja iz 2006. godine, alat je unaprijeđen primjenom tehnika vizualizacije podataka za predstavljanje povratnih informacija koje alat generira, uz poboljšanje grafičkog korisničkog sučelja. Rezultati su pokazali da korisnici smatraju korisnim ovakav alat.

(May i ostali, 2011)	Učenici	Upitnik	Učenici smatraju da LAD pomaže u stjecanju pregleda vremena koje učenici provode na učenju, kao i boljem uvidu u cijeli predmet. Ova povratna informacija ukazuje na to da alat pruža korisne informacije koje olakšavaju praćenje napredovanja i omogućuju bolje upravljanje tijekom procesa učenja i poučavanja.
(Govaerts i ostali, 2012)	Nastavnici	Upitnik - SUS Upitnik	LAD pomaže u praćenju angažmana učenika i daje bolji pregled predmeta. Nastavnici smatraju da LAD pomaže u stjecanju pregleda vremena koje učenici provode na učenju, kao i boljem uvidu u cijeli predmet. Ova povratna informacija ukazuje na to da alat pruža korisne informacije koje olakšavaju praćenje napredovanja učenika tijekom procesa učenja i poučavanja. SUS rezultat iznosi 73.33.
(Vesin i ostali, 2018)	Nastavnici i Učenici	Upitnik - SUS i pitanja otvorenog tipa	Učenici žele više različitih vizualizacija. Traže mogućnost praćenja napretka kroz vrijeme. SUS rezultat kod nastavnika iznosio je 56.3, a kod učenika 67.2.
(Putra i ostali, 2018)	Nastavnici i Učenici	Upitnik - SUS i A/B testiranje	Od devet ispitanika koji su sudjelovali u testiranju, svi su ocijenili sustav kao dobar i prikladan za korištenje, uz nekoliko prijedloga za poboljšanje. Prosječna ocjena SUS upitnika kod nastavnika iznosi 70.75. Učenici su generalno zadovoljni, ali izražavaju sumnju u konzistentnost sustava. Prosječna ocjena SUS upitnika kod učenika iznosi 69.5.
(Park & Jo, 2015)	Učenici	Upitnik	Učenici imaju umjereno zadovoljstvo LAD-om.
		Ispitivanje utjecaja	Istraživanje je obuhvatilo 36 učenika u eksperimentalnoj skupini i 37 u kontrolnoj skupini. Iako je eksperimentalna skupina ostvarila nešto bolje rezultate u odnosu na kontrolnu, razlike nisu bile statistički značajne.
(Volaric & Ljubić, 2017)	Učenici	Upitnik	Učenici pozitivno ocjenjuju vizualni prikaz LAD-a i smatraju da im pomaže u praćenju napretka.
(Gutierrez i ostali, 2018)	Nastavnici i Učenici	Upitnik - SUS i Razmišljanje naglas	Istraživanje je pokazalo da je LAD pozitivno ocijenjena na dva sveučilišta. Sudionici su istaknuli da im je LAD pomogla u usporedbi svojih rezultata s drugim učenicima i boljem planiranju studija, što bi moglo smanjiti stopu neuspjeha. Unatoč dobrim rezultatima, postoje izazovi u pogledu transparentnosti

			modela predviđanja, ali dodatne funkcionalnosti mogu poboljšati povjerenje u sustav. Rezultati SUS-a pokazali su dobru upotrebljivost alata, s prosječnim rezultatom od 70,75 na Sveučilištu A, dok je na Sveučilištu B bio nešto niži (56,25 za nastavnike, 71,25 za učenike), što ukazuje na potrebu za daljnjim poboljšanjima, osobito za nastavnike.
(Kaur & Chahal, 2024)	Nastavnici i Učenici	Upitnik – SUS i EFLA	Vrednovanje LAD-a, od strane nastavnika i učenika, ukazale su da je LAD jasan, jednostavan za korištenje te pruža lako razumljive informacije. Prema EFLA upitnicima, dobiveni su visoki rezultati za dimenzije: podaci, samosvijest i utjecaj. Prosječna SUS ocjena kod učenika iznosila je 75.6.
(Buvari i ostali, 2023)	Učenici	Nije navedeno	Autori su naveli samo smjernice poboljšanja LAD-a, bez objašnjenja provedbe vrednovanja.
(Dourado i ostali, 2021)	Nastavnici	Fokus grupa	Identificirani problemi sa ekspertima, u nastavku žele vrednovati novi dizajn kako bi ocijenili njegovu upotrebljivost, korisnost i utjecaj na njihovu praksu.
(De Laet i ostali, 2020)	Nastavnici i Učenici	Analiza interakcija učenika, upitnik i intervju	Rezultati pokazuju da su novi moduli dashboarda uspješno usvojeni. Iako su nastavnici izvijestili o značajno povećanoj percipiranoj razini potpore, nije zabilježen značajan učinak na akademsko postignuće učenika, što ukazuje na potrebu dodatnih intervencija za dugoročni utjecaj.
(Tretow-Fish & Khalid, 2024)	Učenici	upitnik	Učenici općenito nisu smatrali LAD važnim, budući da je prosječni raspon ocjena svih učenika bio između 4,12 i 5,47 na Likertovoj ljesvici od 9 stupnjeva.
(Fernandez Nieto i ostali, 2022)	Nastavnici	Intervju	Nastavnici su prepoznali vrijednost ovih sučelja za poticanje refleksije i unapređenje obrazovnih praksi, iako je potrebno dodatno istraživanje kako bi se optimizirala interpretacija kompleksnih podataka.
(Kaliisa & Dolonen, 2022)	Nastavnici	Intervju	Nastavnici su pozitivno ocijenili LAD, ističući njegovu sposobnost omogućavanja u prilagodbi nastave. Međutim, ukazano je na potrebu za dodatnim personaliziranim i orijentiranim preporukama kako bi se u potpunosti zadovoljile njihove pedagoške potrebe.
(Bayer i ostali, 2024)	Nastavnici	Upitnik i ekspert	Istraživanje pokazalo značajne potrebe u transparentnosti podataka, kao i etičkim i tehničkim izazovima integracije LAD-ova u

		ealthrough	poticanju jednakosti, raznolikosti i inkluzije u visokom obrazovanju.
(Alfredo i ostali, 2024)	Nastavnici	Opažanja i intervju	Prema intervjuima, nastavnici su naglasili važnost trajnih i privremenih prilagodbi LAD-a, što može poboljšati integraciju ovakvih alata u obrazovni proces. Ističu potrebu za fleksibilnim LAD-ovima, kako bi se kontinuirano unaprijedio obrazovni proces.
(Duan i ostali, 2022)	Učenici	Intervju, Upitnik, Analiza interakcija	Vrednovanje LAD-a otkrila je da vizualizacije pružaju korisne informacije, a statistički značajna korelacija između učestalosti korištenja LAD-a i poboljšanog ponašanja (ranija predaja zadataka) potvrđuje njegov pozitivan utjecaj. Pokazalo se i kako se razlikuju rezultati individualno, prema učenicima.
(Avila-Garzon i ostali, 2020)	Nastavnici	Opažanje i upitnik (LAAM)	Rezultati odgovora nastavnika (N = 19) na obje sekcije završnog upitnika (LAAM instrument i otvorena pitanja) otkrili su pozitivne percepcije nastavnika prema upotrebi LAD alata.
(Bao i ostali, 2021)	Nastavnici	Ispitivanje utjecaja	Rezultati pokazuju da je LAD omogućio nastavnicima učinkovitije dijagnosticiranje performansi učenika, naročito kroz upotrebu strategija usporedbe između grupa. Također, nastavnici iz eksperimentalne skupine pokazali su značajno veći fokus na kognitivne intervencije, pozitivne povratne informacije i individualni pristup, što ukazuje na poboljšanu sposobnost pravovremenog pružanja podrške učenju.
(H. Choi i ostali, 2023)	Učenici	SUS upitnik, intervju	Učenici su pozitivno ocijenili LAD na temelju SUS upitnika, gdje je prosječna ocjena iznosila 87.81. LAD ima potencijal motivirati učenike da aktivno sudjeluju u učenju i koriste strategije samoreguliranog učenja.
(Vreugd i ostali, 2024)		SUS upitnik, intervju, fokus grupa, testiranje upotrebljivosti	Istraživanje je pokazalo da aktivno uključivanje sudionika tijekom svih faza dizajna LAD-a doprinosi stvaranju sustava koji bolje podržava samoregulaciju učenika. Ipak, u finalnoj fazi, pokazalo se kako ima mogućnosti za unapređenje upotrebljivosti kako bi se povećavala učinkovitost LAD alata u obrazovnom procesu. Rezultati SUS upitnika iznosili su 78.25.
(Ez-zaouia i ostali, 2020)	Nastavnici	upitnici (SUS), intervju i te	Upotreba LAD-a povećava svjesnost nastavnika o emocijama učenika, što rezultira povećanjem i boljom prilagodbom povratnih

		kvantitativne statističke analize	informacija. Iako detaljne vizualizacije mogu biti zahtjevne za interpretaciju, sažeti prikazi emocionalnih trendova omogućuju nastavnicima prilagodbu nastavnih praksi i potiču kontinuiranu refleksiju. Rezultati SUS upitnika su iznosili 80.
(Q. Fu i ostali, 2023)	Nastavnici i Učenici	Upitnik (SUS) i intervju	Rezultati SUS upitnika su iznosili 77, a intervju je proveden sa 4 eksperta radi vrednovanja vizualizacija. Eksperti su dali pozitivne povratne informacije, ističući vrijednost različitih vizualizacijskih tehnika, dok su istaknuti prijedlozi za daljnje poboljšanje alata usmjereni na integraciju naprednih interakcijskih mogućnosti i proširenje prikaza na više grupa istovremeno.
(Haynes-Magyar, 2020)	Učenici	pre- i post-upitnik, te analiza interakcija, pitanja otvorenog tipa	Glavni nalazi istraživanja pokazuju da većina učenika nakon korištenja LAD-a nije smatrala da im je alat promijenio način planiranja aktivnosti. Nadalje, učenici su ocijenili da su vizualni prikazi LAD-a znatno složeniji nego što su očekivali, a većina komentara odnosila se na potrebu za poboljšanjem prikaza.
(Hu i ostali, 2021)	Učenici i nastavnici	Upitnik i intervju	Glavni nalazi pokazuju da je većina učenika koristila LA alat, a korisnici su imali značajno pozitivnije stavove u odnosu na one koji ga nisu koristili, smatrajući ga korisnim za praćenje napretka u učenju i refleksiju o vlastitom ponašanju. Također, učenici su ocijenili vizualizacije motivirajućima. Što se tiče nastavnika, svi su prepoznali da LA alat olakšava identifikaciju učenika u riziku, premda su istaknuli potrebu za dodatnim podacima o kvaliteti napora učenika i integracijom alata u širi pedagoški kontekst.
(Jaramillo-Morillo i ostali, 2022)	Nastavnici	Intervju	Nastavnici smatraju da su metrički pokazatelji (npr. sličnost odgovora i vremenska odstupanja) te vizualizacije u LAD-u adekvatni i lako razumljivi, što im omogućuje detekciju sumnjivih obrazaca učenika.
(Jayashanka i ostali, 2022)	Učenici	Ispitivanje utjecaja	Zaključci vrednovanja pokazuju da je LAD alat značajno poboljšao interakciju učenika i akademske rezultate. Učenici u eksperimentalnoj grupi su znatno češće pristupali online resursima i ostvarili veće ocjene na završnom testu. Više od 94% učenika ocijenilo je ključne vizualizacije—usporedbu vlastitih bodova s prosjekom i najboljim rezultatom klase te prikaz

			trenutnog statusa—kao izrazito korisne za identifikaciju slabih područja, motivaciju i praćenje napretka, potvrđujući učinkovitost ovog modula u poticanju samoreguliranog učenja i kontinuiranog unaprjeđenja akademskih postignuća.
(Sánchez i ostali, 2022)	Nastavnici i Učenici	Upitnik (UEQ)	Glavni zaključci vrednovanja LAD-a su da je alat postigao iznadprosječne rezultate u većini UEQ aspekata. Međutim, faktor jasnoće je ostao prosječan i zahtijeva dodatna poboljšanja. Unatoč tehničkim prednostima poput jednostavne implementacije, osiguranosti podataka i otvorenog izvornog koda, izazovi ostaju u institucionalnoj integraciji i dodatnom prilagođavanju funkcionalnosti, što uključuje i unaprjeđenje interpretabilnosti podataka kroz alat.
(Owatari i ostali, 2020)	Učenici	Upitnik, Analiza interakcija	Rani prototip LAD-a pokazao je da, iako može poboljšati sinkronizaciju s nastavnikom te potaknuti određene interakcije, opisna priroda povratnih informacija i kašnjenje u ažuriranju ograničili su njegovu ukupnu korisnost. Budući razvoj treba uzeti u obzir brže alate (kao što su obavijesti u stvarnom vremenu i personalizirane preporuke) kako bi se bolje podržale raznolike potrebe učenika i poboljšali rezultati učenja u stvarnom vremenu.
(Radović i ostali, 2024)	Učenici	Upitnik(LI ST-K skala, Izjave TAM-(percipirana korisnost i percipirana jednostavnost korištenja), Analiza interakcija	Povećana podrška za samoregulirano učenje može potaknuti veći angažman i bolju akademsku izvedbu, ali ne poboljšava sve aspekte procesa učenja (npr. samoprocjenu). Studija naglašava važnost integracije više strategija kako bi se pružila sveobuhvatna podrška kroz sve faze ciklusa samoregulacije. Potrebna su daljnja istraživanja kako bi se utvrdila optimalna razina podrške, razvili objektivni instrumenti za mjerenje te ispitali specifični čimbenici koji utječu na zadovoljstvo i učinkovitost alata u online obrazovnim okruženjima.
(Ramaswami i ostali, 2023)	Učenici	Upitnik (SUS) i Analiza interakcija	Interakcija s LAD-om značajno povećava angažman učenika s LMS-om na kratkoročnoj razini (povećani angažman evidentan je samo tijekom prvih 15 dana nakon interakcije. Nakon dodatnih 15 dana, razlika nije bila značajna). LAD potiče

			učenike na usporedbu sa svojim kolegama, što ih motivira da prilagode svoje obrazovne strategije i postave realističnije ciljeve. Daljnja usavršavanja su potrebna kako bi se poboljšala transparentnost modela predviđanja i smanjilo kognitivno opterećenje. Osjena SUS upitnika iznosila je 70.5.
(Valle i ostali, 2021)	Učenici	Ispitivanje utjecaja	Nije bilo statistički značajnih razlika između grupa u pogledu konačnih rezultata na ispitima i kvizovima. Nalazi ukazuju na to da su učenici doživjeli LAD kao korisne alate za samoregulaciju i refleksiju o vlastitom napretku, no njihova iskustva su bila miješana.
(C. Wang i ostali, 2024)	Nastavnici	Upitnik i pitanja otvorenog tipa	Nastavnici su ocijenili LAD visoko na svih pet kriterija (perceived usefulness, ease of use, behavioral change, satisfaction i intention to use), što ukazuje na snažnu prihvaćenost i korisnost alata. Iako su opće ocjene bile visoke, sudionici su dali povratne informacije o potrebi jasnijim preporukama za akciju — što će poslužiti kao temelj za daljnje poboljšanje dizajna alata.
(J. Zheng i ostali, 2021)	Nastavnici	Razmišljanje naglas	Rezultati su pokazali da postoji velika varijabilnost među nastavnicima u načinu na koji pristupaju i reagiraju na prikazane podatke. Nastavnici s boljim vještinama samoregulacije su lakše identificirali ključne informacije i prilagođavali svoje nastavne strategije u skladu s tim. Učinkovita upotreba ovakvih alata ovisi o sposobnosti nastavnika da reflektiraju o prikazanim podacima i da poduzmu konkretne nastavne intervencije.
(Safsouf i ostali, 2022)	Nastavnici i Učenici	Opažanja (nisu detaljno napisali)	Primjena alata poboljšala je akademski uspjeh i autonomiju učenika u online obliku učenja. Autori sugeriraju da je ovaj alat učinkovit za poticanje samoregulacije i da je koristan za ranije prepoznavanje i poboljšanje uspjeha učenika.
(Seidel i ostali, 2024)	Učenici	Analiza interakcija	Učenici su najviše koristili alate za praćenje (npr. grafikoni napretka), dok su alati za planiranje i refleksiju bili manje korišteni. Iako je LAD bila učestalo korištena, sofisticiranije značajke za samoregulirano učenje poput postavljanja ciljeva i samoprocjene bili su manje zastupljeni. Postojala je sumnja u oslanjanje isključivo na podatke o interakciji iz Moodlea za adaptivnu povratnu informaciju

(AlZoubi i ostali, 2024)	Nastavnici	Intervju	Prema nastavnicima, nisu sve vizualizacije i metrike percipirane kao jednako važne. Nastavnici su izjavili da bi preporučili ovu nadzornu ploču te su naglasili da bi informacije koje ona pruža bile izuzetno korisne ako bi se podijelile s kolegama.
(Eickholt i ostali, 2022)	Učenici	Analiza interakcija	Otpriblike trećina učenika redovito je koristila LAD. Analize su pokazale da su učenici koji su koristili nadzornu ploču ostvarili značajno više prosječne ocjene u usporedbi s onima koji je nisu koristili. Najčešće korištena funkcija bila je pregled distribucije ocjena, što sugerira da učenici najviše cijene mogućnost usporedbe vlastitih rezultata s prosjekom predmeta.
(van Leeuwen & Rummel, 2020)	Nastavnici	Upitnik za kognitivno opterećenje, analiza interakcija	Rezultati ukazuju na to da LAD, koji nudi dodatne vizualne i tekstualne povratne informacije, značajno poboljšava točnost detekcije problematičnih grupa, smanjuje kognitivno opterećenje i povećava samopouzdanje nastavnika pri donošenju odluka.
(Kia i ostali, 2020)	Učenici	Upitnik , Analiza interakcija	Nisko uspješni učenici češće pregledavaju Files Accessed (više puta u jednoj sesiji) i Grade Distribution, a rjeđe koriste Assignment Planning, što ukazuje na fokus na metakognitivni nadzor i trenutni status učenja. Visoko samoregulirani učenici kombiniraju Files Accessed i Assignment Planning, sugerirajući aktivnije planiranje i praćenje napretka. Ne postoji direktna veza između samoprocijenjene razine samoregulacije i ocjene, pa učenici različitih uspjeha mogu imati slične obrasce ponašanja. Ključna implikacija je da LAD-ovi moraju biti prilagodljivi različitim profilima učenika, jer „jedan dizajn ne odgovara svima“.
(Pozdniakov i ostali, 2022)	Nastavnici i učenici	Intervju	LAD je u trojednoj primjeni vrednovan putem intervju s četiri nastavnika i četiri učenika. Svi nastavnici su potvrdili da vizualizacije pomažu brzo uočiti neaktivne ili zapostavljene grupe, iako su istaknuli nejasne pragove za označavanje i zabrinutost oko privatnosti. Učenici su predložili manje prilagodbe kako bi preciznije odražavala njihove aktivnosti
(Ng i ostali, 2022)	Učenici	Upitnik	Sudionici su potvrdili korisnost ključnih funkcionalnosti za bolje upravljanje vremenom, praćenje vlastitog napretka i poboljšanje kvalitete sadržaja.

PRILOG B

PRILOG B1 – SKUP PODATAKA

Konačan skup podataka, s vrijednostima značajki skaliranim po tjednima, korišten za treniranje i vrednovanje modela

Ang1	Ang2	Ang 3	Ukupno Ang	Akt	Tjedne Akt	Vikend Akt	PrviIspit Uspjeh	VrijemeNa Ispitu	Uspjeh
0.07	0.27	0.07	0.4	1.53	1.33	0.2	60.0	100.0	1.0
0.87	0.73	0.6	2.2	4.93	4.73	0.2	40.0	83.96	1.0
0.87	2.13	0.47	3.47	6.27	5.0	1.27	20.0	97.71	3.0
1.47	1.6	0.93	4.0	9.13	8.07	1.07	50.0	62.22	1.0
1.27	1.87	0.67	3.8	5.13	4.4	0.73	60.0	86.73	1.0
1.47	1.8	0.87	4.13	7.8	5.73	2.07	60.0	62.4	1.0
1.07	1.33	0.6	3.0	7.0	6.13	0.87	40.0	74.46	1.0
1.13	1.2	0.67	3.0	5.6	5.27	0.33	60.0	94.69	1.0
1.07	1.6	0.6	3.27	7.8	5.4	2.4	80.0	81.32	1.0
0.93	1.07	0.27	2.27	5.87	4.73	1.13	20.0	119.02	1.0
1.0	1.0	0.47	2.47	3.73	2.67	1.07	40.0	84.9	1.0
1.47	1.87	1.0	4.33	15.4	13.93	1.47	50.0	42.71	1.0
0.8	0.47	0.53	1.8	4.4	4.13	0.27	30.0	70.29	1.0
1.2	1.6	0.6	3.4	6.93	5.67	1.27	20.0	98.7	1.0
1.2	1.2	0.67	3.07	6.07	5.53	0.53	20.0	96.4	1.0
0.87	1.0	0.53	2.4	3.33	2.87	0.47	80.0	82.33	1.0
0.93	1.47	0.53	2.93	3.73	3.2	0.53	20.0	94.69	1.0
0.73	1.27	0.47	2.47	3.8	3.2	0.6	60.0	96.19	1.0
0.87	1.2	0.6	2.67	6.93	6.67	0.27	60.0	70.35	1.0
0.93	0.6	0.67	2.2	6.33	5.8	0.53	70.0	76.06	1.0
1.13	1.13	0.67	2.93	3.87	3.27	0.6	50.0	73.3	1.0
1.2	0.27	0.67	2.13	5.6	5.47	0.13	60.0	70.62	1.0
1.13	0.67	0.67	2.47	3.6	3.53	0.07	20.0	67.68	1.0
1.07	0.8	0.67	2.53	4.53	4.27	0.27	20.0	84.76	1.0
0.53	0.53	0.53	1.6	1.8	1.53	0.27	40.0	78.65	1.0
0.93	1.53	0.6	3.07	4.93	4.53	0.4	90.0	75.46	1.0
1.2	0.6	0.67	2.47	4.8	4.07	0.73	50.0	78.4	1.0
0.8	1.67	0.4	2.87	6.47	5.2	1.27	60.0	86.29	1.0
1.07	0.4	0.6	2.07	3.13	2.8	0.33	40.0	78.37	1.0
0.33	1.13	0.13	1.6	6.0	5.33	0.67	70.0	48.07	1.0
1.2	0.87	0.67	2.73	5.2	4.87	0.33	60.0	87.24	1.0
0.07	0.07	0.07	0.2	0.47	0.27	0.2	70.0	100.0	1.0

1.13	0.67	0.6	2.4	5.0	4.8	0.2	50.0	74.39	1.0
0.93	0.87	0.6	2.4	3.4	3.0	0.4	40.0	78.12	1.0
1.07	0.6	0.67	2.33	3.2	3.0	0.2	80.0	72.68	1.0
0.67	0.6	0.33	1.6	3.87	3.87	0.0	100.0	98.42	1.0
1.2	1.07	0.73	3.0	10.93	10.13	0.8	40.0	67.23	2.0
0.87	1.27	0.47	2.6	7.07	6.07	1.0	86.67	97.43	1.0
1.4	1.8	0.73	3.93	9.07	7.53	1.53	46.67	86.9	1.0
1.2	1.13	0.67	3.0	5.73	5.27	0.47	90.0	72.79	1.0
1.13	1.4	0.67	3.2	4.07	3.93	0.13	100.0	57.04	3.0
1.07	1.53	0.67	3.27	9.0	8.0	1.0	50.0	86.87	3.0
1.2	1.4	0.6	3.2	6.67	5.73	0.93	70.0	80.11	3.0
1.07	1.53	0.6	3.2	8.8	7.33	1.47	60.0	87.01	1.0
1.4	1.6	0.93	3.93	9.93	7.27	2.67	80.0	52.1	1.0
1.07	0.67	0.6	2.33	2.67	2.6	0.07	70.0	78.68	3.0
1.47	1.47	0.93	3.87	10.73	9.67	1.07	50.0	44.97	2.0
1.2	1.53	0.6	3.33	6.2	5.33	0.87	50.0	106.38	3.0
0.8	0.47	0.4	1.67	3.27	3.0	0.27	80.0	80.46	1.0
1.47	1.2	1.07	3.73	11.6	7.27	4.33	90.0	45.01	3.0
1.07	0.47	0.6	2.13	3.53	3.27	0.27	90.0	81.67	3.0
1.2	0.87	0.67	2.73	5.8	5.47	0.33	20.0	88.92	1.0
1.33	1.8	0.93	4.07	7.6	6.33	1.27	50.0	53.58	2.0
1.13	0.47	0.67	2.27	3.13	3.07	0.07	40.0	80.65	1.0
1.07	1.13	0.6	2.8	4.87	4.47	0.4	80.0	77.05	3.0
1.13	0.93	0.6	2.67	3.33	3.2	0.13	70.0	82.04	3.0
1.0	0.67	0.6	2.27	5.53	5.33	0.2	50.0	77.56	1.0
1.4	1.67	1.0	4.07	6.33	5.6	0.73	70.0	49.53	3.0
1.07	0.53	0.67	2.27	6.07	5.0	1.07	80.0	77.71	3.0
1.13	1.47	0.6	3.2	5.67	4.4	1.27	50.0	89.58	2.0
0.87	1.0	0.47	2.33	4.2	3.8	0.4	80.0	98.18	1.0
0.67	0.53	0.33	1.53	1.87	1.8	0.07	70.0	77.15	1.0
1.2	0.67	0.67	2.53	4.47	4.27	0.2	60.0	84.43	2.0
1.33	1.8	0.73	3.87	7.13	6.73	0.4	40.0	69.44	1.0
1.0	0.93	0.6	2.53	10.0	8.87	1.13	70.0	72.53	3.0
1.33	1.67	0.87	3.87	7.87	6.07	1.8	70.0	64.38	3.0
1.2	1.13	0.6	2.93	6.07	5.27	0.8	90.0	73.18	3.0
0.8	0.07	0.47	1.33	1.53	1.53	0.0	40.0	55.81	1.0
1.13	0.87	0.67	2.67	3.53	3.2	0.33	70.0	88.14	3.0
1.33	1.47	0.67	3.47	8.53	7.93	0.6	40.0	93.72	2.0
1.47	2.13	0.87	4.47	15.2	10.87	4.33	90.0	75.02	2.0
1.33	1.27	0.67	3.27	4.8	4.27	0.53	40.0	95.45	2.0
1.2	0.8	0.67	2.67	5.0	4.93	0.07	60.0	91.65	1.0
1.2	1.8	0.67	3.67	5.73	5.47	0.27	80.0	53.18	2.0
1.13	2.27	0.67	4.07	9.07	8.07	1.0	60.0	52.75	2.0
0.93	1.4	0.6	2.93	6.33	5.73	0.6	70.0	83.12	3.0
0.8	0.4	0.4	1.6	2.07	2.0	0.07	70.0	87.03	1.0
0.93	1.8	0.6	3.33	7.27	6.0	1.27	90.0	81.54	3.0
0.87	0.87	0.53	2.27	7.13	6.4	0.73	53.33	71.9	2.0
1.0	0.87	0.53	2.4	5.73	5.27	0.47	100.0	67.65	2.0
0.53	0.4	0.27	1.2	2.13	2.07	0.07	40.0	70.08	1.0
0.93	1.27	0.6	2.8	4.2	3.07	1.13	50.0	79.35	3.0
1.0	1.2	0.53	2.73	6.0	5.4	0.6	80.0	64.49	1.0
1.07	0.93	0.67	2.67	4.47	3.27	1.2	60.0	71.27	1.0
1.0	1.87	0.6	3.47	8.2	6.67	1.53	70.0	93.67	3.0
1.0	1.0	0.6	2.6	5.07	4.53	0.53	50.0	97.81	3.0
1.53	2.0	0.93	4.47	8.67	7.07	1.6	30.0	53.3	3.0
1.07	0.53	0.53	2.13	2.93	2.4	0.53	86.67	73.37	2.0
1.0	0.53	0.6	2.13	4.07	3.8	0.27	70.0	79.68	1.0
1.2	1.87	0.53	3.6	4.93	4.6	0.33	80.0	104.56	2.0

1.33	1.27	0.67	3.27	7.2	6.07	1.13	50.0	90.59	2.0
1.2	1.6	0.67	3.47	4.67	3.93	0.73	90.0	76.0	3.0
1.07	0.93	0.6	2.6	3.27	3.2	0.07	70.0	95.07	1.0
1.13	0.6	0.53	2.27	3.67	3.4	0.27	90.0	91.96	1.0
0.93	1.07	0.6	2.6	3.87	3.4	0.47	60.0	74.93	3.0
1.0	1.4	0.6	3.0	5.13	4.53	0.6	60.0	89.86	1.0
0.53	0.13	0.27	0.93	1.4	1.2	0.2	40.0	88.54	1.0
1.07	0.47	0.53	2.07	4.2	3.4	0.8	30.0	87.41	1.0
0.73	0.2	0.4	1.33	2.27	2.2	0.07	20.0	87.0	1.0
0.93	1.0	0.53	2.47	6.07	4.2	1.87	60.0	88.18	3.0
0.67	0.73	0.4	1.8	4.0	3.6	0.4	40.0	89.52	1.0
1.07	1.2	0.6	2.87	5.93	4.8	1.13	60.0	85.86	3.0
1.13	1.2	0.6	2.93	5.2	5.0	0.2	80.0	77.0	1.0
1.27	1.27	0.67	3.2	7.13	6.8	0.33	50.0	95.05	2.0
0.87	1.0	0.47	2.33	3.93	3.73	0.2	50.0	73.76	1.0
1.2	1.33	0.67	3.2	4.73	4.33	0.4	90.0	89.67	3.0
0.87	0.87	0.53	2.27	2.67	2.33	0.33	40.0	87.25	1.0
1.0	0.8	0.6	2.4	4.47	3.8	0.67	80.0	76.28	3.0
1.0	0.33	0.53	1.87	2.6	2.27	0.33	30.0	79.41	1.0
1.33	1.53	0.67	3.53	6.8	5.53	1.27	20.0	90.27	3.0
1.27	1.73	0.67	3.67	7.33	5.87	1.47	80.0	107.65	2.0
1.07	0.73	0.53	2.33	3.0	2.6	0.4	70.0	105.62	2.0
1.2	1.4	0.67	3.27	4.4	4.2	0.2	10.0	83.17	2.0
1.0	1.2	0.53	2.73	4.0	3.87	0.13	60.0	92.29	1.0
1.0	1.67	0.6	3.27	7.33	6.6	0.73	50.0	70.86	1.0
1.07	1.0	0.6	2.67	4.8	4.33	0.47	80.0	105.73	3.0
1.53	2.4	1.13	5.07	13.33	9.2	4.13	80.0	37.56	3.0
1.07	0.87	0.67	2.6	3.8	3.2	0.6	80.0	90.17	1.0
1.07	1.6	0.6	3.27	3.93	3.27	0.67	50.0	92.76	1.0
1.13	1.67	0.73	3.53	5.4	5.27	0.13	60.0	72.63	2.0
1.0	0.8	0.53	2.33	3.13	2.67	0.47	60.0	93.57	1.0
1.13	0.6	0.73	2.47	3.47	2.73	0.73	70.0	57.19	3.0
0.93	1.33	0.4	2.67	3.8	3.47	0.33	40.0	86.8	1.0
0.6	0.53	0.27	1.4	1.93	1.93	0.0	80.0	92.13	1.0
0.6	0.6	0.4	1.6	2.33	2.33	0.0	11.11	55.14	1.0
0.8	1.2	0.4	2.4	6.8	6.13	0.67	26.67	86.38	3.0
0.33	0.67	0.2	1.2	1.6	1.4	0.2	60.0	55.56	1.0
10.87	13.6	6.53	31.0	7.67	6.67	1.0	41.67	43.32	1.0
13.07	13.53	8.27	34.87	11.2	6.33	4.87	73.81	53.43	2.0
13.2	19.47	8.2	40.87	17.53	14.93	2.6	76.19	74.65	1.0
13.2	13.8	8.2	35.2	16.07	13.0	3.07	50.0	42.76	1.0
13.2	14.47	8.2	35.87	12.4	6.33	6.07	88.1	54.05	2.0
12.53	14.13	7.53	34.2	15.0	9.73	5.27	85.71	45.69	3.0
13.53	13.47	8.53	35.53	15.53	13.33	2.2	66.67	42.84	1.0
13.53	13.13	8.53	35.2	11.67	8.8	2.87	85.71	59.85	2.0
12.87	16.8	7.87	37.53	25.67	19.0	6.67	85.71	55.88	3.0
12.4	13.93	7.6	33.93	15.53	9.93	5.6	76.19	35.04	1.0
3.93	3.33	2.6	9.87	2.67	1.87	0.8	40.0	61.94	1.0
13.07	13.27	8.27	34.6	11.67	9.53	2.13	85.71	50.35	2.0
13.53	13.47	8.53	35.53	3.8	3.33	0.47	78.57	48.2	1.0
7.27	12.93	4.33	24.53	6.67	6.07	0.6	10.0	66.56	1.0
12.33	11.8	7.87	32.0	12.93	5.47	7.47	76.19	72.61	1.0
13.2	13.13	8.2	34.53	16.8	10.8	6.0	80.95	53.49	2.0
13.2	13.07	8.33	34.6	22.8	20.07	2.73	83.33	59.49	1.0
8.93	9.87	5.53	24.33	10.67	6.8	3.87	80.95	55.99	1.0
13.53	13.8	8.53	35.87	8.27	5.6	2.67	57.14	38.11	1.0
2.93	6.27	2.4	11.6	3.2	0.53	2.67	0.0	37.47	1.0
12.87	15.13	7.87	35.87	17.87	13.2	4.67	76.19	57.64	1.0

7.93	7.73	4.8	20.47	5.07	1.87	3.2	33.33	38.95	1.0
10.87	11.2	7.07	29.13	8.13	4.13	4.0	47.62	84.47	1.0
6.4	7.13	3.73	17.27	3.13	2.93	0.2	79.44	39.71	1.0
13.07	13.93	8.27	35.27	15.87	6.33	9.53	83.33	46.54	1.0
12.2	15.6	7.73	35.53	12.93	9.13	3.8	59.52	39.69	1.0
13.07	11.93	8.27	33.27	3.0	2.0	1.0	78.57	64.81	1.0
13.2	14.13	8.2	35.53	22.73	17.67	5.07	80.95	54.61	2.0
1.6	1.93	0.8	4.33	2.0	1.73	0.27	59.74	25.75	1.0
13.07	12.27	8.27	33.6	10.6	5.53	5.07	73.81	68.55	2.0
12.73	12.27	7.93	32.93	11.2	8.73	2.47	85.71	42.71	2.0
13.53	14.13	8.53	36.2	14.4	11.2	3.2	78.57	46.45	3.0
12.87	19.47	7.87	40.2	9.73	6.53	3.2	85.71	46.19	3.0
13.2	14.8	8.13	36.13	8.27	5.4	2.87	66.67	29.47	1.0
13.53	16.47	8.53	38.53	12.73	9.0	3.73	83.33	31.61	3.0
12.87	13.8	7.87	34.53	17.4	11.73	5.67	71.43	26.69	1.0
12.53	12.8	7.53	32.87	9.27	7.33	1.93	69.05	50.25	1.0
13.53	13.13	8.53	35.2	11.2	10.53	0.67	80.95	36.25	3.0
10.6	9.87	6.53	27.0	2.6	1.93	0.67	64.29	28.69	1.0
13.53	13.8	8.53	35.87	16.67	12.0	4.67	69.05	39.26	3.0
12.6	12.07	8.27	32.93	9.2	3.0	6.2	78.57	43.2	2.0
12.93	12.87	8.07	33.87	14.93	8.73	6.2	73.81	55.16	1.0
13.13	19.47	8.13	40.73	17.47	10.27	7.2	69.05	38.94	1.0
13.53	14.13	8.53	36.2	18.07	11.93	6.13	78.57	62.4	3.0
4.33	2.67	2.93	9.93	1.27	0.73	0.53	20.0	56.75	1.0
13.13	13.8	8.13	35.07	7.33	5.73	1.6	73.81	39.74	2.0
9.6	10.6	5.8	26.0	4.8	2.33	2.47	71.43	38.02	1.0
12.8	12.67	8.13	33.6	16.13	11.07	5.07	78.57	60.37	1.0
13.2	13.13	8.2	34.53	5.6	4.2	1.4	57.14	47.24	1.0
13.53	13.8	8.53	35.87	10.53	7.8	2.73	69.05	43.39	1.0
13.07	13.27	8.2	34.53	5.47	4.27	1.2	54.76	30.31	1.0
13.53	13.47	8.53	35.53	7.8	5.73	2.07	76.19	45.89	1.0
12.73	15.93	7.93	36.6	16.53	8.47	8.07	69.05	53.3	1.0
12.4	13.27	7.53	33.2	15.07	7.07	8.0	71.43	32.55	3.0
13.2	16.4	8.33	37.93	11.87	6.67	5.2	71.43	43.76	1.0
3.73	5.07	1.87	10.67	3.27	2.93	0.33	97.78	31.03	1.0
13.2	19.47	8.2	40.87	8.53	5.47	3.07	83.33	37.18	1.0
12.87	13.47	7.87	34.2	14.27	6.0	8.27	76.19	33.59	1.0
11.33	11.87	6.8	30.0	5.87	4.93	0.93	61.9	50.0	1.0
12.67	12.27	7.93	32.87	11.4	2.73	8.67	52.38	33.67	1.0
11.53	11.0	6.8	29.33	6.93	3.27	3.67	73.81	32.6	1.0
7.0	4.8	5.4	17.2	4.87	1.8	3.07	83.33	29.03	1.0
5.8	11.87	3.27	20.93	5.67	3.4	2.27	47.33	51.35	1.0
12.53	13.8	7.53	33.87	10.4	3.07	7.33	50.0	39.03	1.0
13.07	12.27	8.27	33.6	13.47	9.6	3.87	69.05	37.63	1.0
12.53	17.13	7.4	37.07	22.6	14.4	8.2	61.9	42.34	1.0
10.6	10.4	6.33	27.33	9.07	1.13	7.93	57.14	24.82	1.0
11.67	10.47	7.47	29.6	7.53	5.47	2.07	76.19	44.78	2.0
12.53	12.47	7.6	32.6	13.6	5.67	7.93	85.71	33.78	2.0
11.87	14.0	7.47	33.33	10.2	3.33	6.87	61.9	50.78	1.0
11.4	12.27	6.6	30.27	12.6	2.67	9.93	83.52	33.39	1.0
11.8	12.13	6.8	30.73	5.33	4.33	1.0	60.0	21.78	1.0
11.0	12.33	6.6	29.93	10.4	2.73	7.67	93.33	32.47	1.0
11.93	11.8	7.33	31.07	8.13	2.47	5.67	60.0	32.34	1.0
13.2	13.47	8.2	34.87	14.93	6.93	8.0	9.52	40.56	1.0
9.53	11.27	5.53	26.33	1.07	0.93	0.13	93.33	36.27	1.0
13.53	16.8	8.53	38.87	8.6	4.6	4.0	73.81	63.91	1.0
12.73	12.27	7.93	32.93	10.47	5.93	4.53	59.52	40.24	1.0
13.53	14.13	8.53	36.2	10.8	5.07	5.73	66.67	49.86	1.0

9.4	10.07	5.67	25.13	9.4	7.53	1.87	50.0	37.11	1.0
10.93	11.13	6.6	28.67	6.13	4.13	2.0	80.0	47.9	1.0
13.2	15.13	8.2	36.53	20.2	16.33	3.87	61.9	34.03	2.0
8.6	7.73	5.8	22.13	4.47	2.27	2.2	35.0	40.21	1.0
10.0	12.2	6.33	28.53	5.8	4.07	1.73	80.95	51.14	1.0
13.53	15.13	8.53	37.2	17.47	17.07	0.4	85.71	68.44	2.0
13.53	15.8	8.53	37.87	17.87	12.0	5.87	64.29	43.65	1.0
11.27	13.73	7.0	32.0	8.33	5.33	3.0	66.67	58.47	1.0
7.53	9.87	4.33	21.73	4.13	1.2	2.93	41.67	48.61	1.0
13.53	16.13	8.53	38.2	17.53	12.87	4.67	71.43	62.33	2.0
10.4	13.53	5.73	29.67	11.13	8.4	2.73	96.11	47.35	1.0
13.87	15.13	8.87	37.87	19.07	10.27	8.8	83.33	33.45	1.0
8.07	5.87	6.2	20.13	6.73	4.93	1.8	71.43	43.56	1.0
11.87	14.13	6.87	32.87	14.07	9.07	5.0	84.44	25.3	1.0
0.27	0.53	0.27	1.07	0.67	0.2	0.47	56.78	69.29	1.0
13.2	15.47	7.93	36.6	20.33	10.4	9.93	20.0	24.97	1.0
12.87	15.27	8.0	36.13	11.27	7.8	3.47	50.0	50.73	1.0
9.0	9.4	5.13	23.53	5.73	3.27	2.47	61.9	53.57	1.0
0.93	1.87	0.6	3.4	1.07	0.53	0.53	14.29	85.67	1.0
13.53	16.13	8.53	38.2	20.2	8.4	11.8	73.81	51.46	1.0
12.73	12.27	7.93	32.93	4.07	3.2	0.87	40.48	37.61	1.0
12.33	12.2	7.73	32.27	9.8	2.73	7.07	76.19	60.05	1.0
2.47	2.33	1.93	6.73	1.67	1.4	0.27	50.0	77.93	1.0
12.87	14.13	7.87	34.87	13.47	9.33	4.13	71.43	43.11	1.0
11.2	13.33	6.87	31.4	5.53	1.87	3.67	33.33	43.13	1.0
11.13	13.07	6.27	30.47	13.13	9.93	3.2	45.56	46.9	1.0
8.73	14.2	5.33	28.27	13.4	5.73	7.67	82.22	24.45	1.0
10.33	9.33	6.53	26.2	4.47	2.0	2.47	85.71	38.44	2.0
7.73	9.47	4.47	21.67	6.13	3.73	2.4	59.52	64.6	1.0
11.07	10.2	6.6	27.87	8.07	7.0	1.07	76.19	41.93	2.0
12.8	13.13	7.8	33.73	12.07	6.67	5.4	76.19	51.77	1.0
11.33	10.0	6.8	28.13	6.93	2.73	4.2	85.71	45.8	3.0
13.2	13.8	8.2	35.2	21.2	11.27	9.93	59.52	26.64	1.0
11.73	12.27	6.67	30.67	7.93	0.53	7.4	28.57	39.39	1.0
12.87	14.13	7.73	34.73	9.13	5.87	3.27	70.0	49.69	1.0
12.87	12.47	7.87	33.2	6.53	1.67	4.87	41.67	36.74	1.0
12.73	12.93	7.93	33.6	6.73	3.93	2.8	69.05	32.35	1.0
13.47	13.8	8.47	35.73	12.13	9.87	2.27	80.95	41.93	2.0
13.53	18.13	8.47	40.13	22.6	15.73	6.87	73.81	39.98	3.0
13.2	15.47	8.2	36.87	15.07	13.8	1.27	61.9	26.68	1.0
13.53	19.13	8.53	41.2	30.0	15.87	14.13	71.43	43.63	1.0
13.53	13.47	8.53	35.53	26.33	9.87	16.47	64.29	36.41	1.0
12.2	13.13	7.07	32.4	7.47	5.93	1.53	71.43	64.74	1.0
9.33	12.13	5.8	27.27	12.13	7.67	4.47	30.0	50.51	1.0
11.4	13.47	6.87	31.73	14.4	9.27	5.13	64.29	52.13	1.0
10.67	10.87	6.53	28.07	13.6	6.93	6.67	76.19	61.44	1.0
12.73	13.6	7.93	34.27	13.0	7.8	5.2	69.05	47.85	2.0
13.53	13.47	8.53	35.53	13.4	10.13	3.27	85.71	51.73	3.0
12.47	14.33	7.8	34.6	9.2	6.07	3.13	64.29	53.39	1.0
10.47	14.4	6.33	31.2	12.87	6.73	6.13	71.43	65.07	1.0
13.2	15.47	8.2	36.87	17.0	12.13	4.87	80.95	44.93	3.0
13.53	19.47	8.53	41.53	8.8	5.53	3.27	64.29	26.81	1.0
11.4	13.6	6.6	31.6	10.8	4.6	6.2	82.96	50.11	1.0
9.93	11.73	5.87	27.53	20.47	14.73	5.73	33.33	58.7	1.0
11.4	13.27	6.6	31.27	7.87	1.33	6.53	60.56	39.45	1.0
13.2	16.13	8.13	37.47	6.47	3.47	3.0	64.29	39.24	1.0
9.0	8.13	5.47	22.6	5.47	3.87	1.6	58.33	56.29	1.0
7.27	11.07	5.67	24.0	1.53	1.2	0.33	91.11	35.45	1.0

13.13	12.13	8.0	33.27	13.0	12.33	0.67	76.19	49.41	1.0
12.27	12.47	7.53	32.27	8.47	5.33	3.13	50.0	49.93	1.0
3.53	6.07	2.2	11.8	14.2	7.4	6.8	40.0	71.09	1.0
3.53	4.47	2.13	10.13	12.6	11.53	1.07	70.0	39.6	2.0
0.4	4.07	0.4	4.87	6.47	5.4	1.07	20.0	37.93	1.0
0.47	4.47	0.4	5.33	8.8	8.4	0.4	40.0	63.21	1.0
0.6	5.13	0.4	6.13	22.87	21.73	1.13	30.0	75.9	3.0
2.93	8.07	1.8	12.8	17.27	14.27	3.0	100.0	38.99	1.0
1.93	3.33	1.27	6.53	7.33	7.13	0.2	73.68	67.97	1.0
0.07	0.33	0.07	0.47	0.6	0.6	0.0	80.0	99.5	1.0
3.4	4.73	2.07	10.2	12.13	9.93	2.2	40.0	25.72	1.0
2.93	4.8	1.87	9.6	27.73	20.73	7.0	60.0	23.68	1.0
1.27	3.93	0.8	6.0	5.73	5.67	0.07	60.0	21.55	1.0
0.33	1.67	0.2	2.2	4.93	4.27	0.67	50.0	40.94	1.0
0.4	4.2	0.27	4.87	7.87	6.93	0.93	86.84	63.33	2.0
3.33	5.33	2.0	10.67	10.27	8.67	1.6	81.58	30.69	3.0
0.73	5.53	0.4	6.67	8.73	7.33	1.4	60.0	30.22	1.0
0.13	1.2	0.07	1.4	3.13	2.67	0.47	58.33	72.67	1.0
0.4	1.0	0.13	1.53	5.07	3.93	1.13	50.0	112.21	1.0
0.47	5.53	0.27	6.27	6.8	5.47	1.33	50.0	86.6	2.0
3.27	4.93	1.87	10.07	12.6	10.8	1.8	20.0	40.14	1.0
1.47	4.27	0.87	6.6	6.0	5.87	0.13	70.0	45.4	1.0
0.27	1.07	0.2	1.53	1.8	1.67	0.13	50.0	84.83	1.0
3.67	5.53	2.27	11.47	20.67	17.47	3.2	60.0	26.95	1.0
0.53	4.07	0.4	5.0	13.27	11.33	1.93	30.0	61.61	2.0
1.0	2.73	0.73	4.47	9.6	8.6	1.0	50.0	43.48	1.0
0.27	1.27	0.13	1.67	3.0	2.8	0.2	76.32	54.06	1.0
3.6	6.0	2.2	11.8	25.2	19.6	5.6	10.0	20.64	1.0
0.4	4.33	0.33	5.07	5.93	4.67	1.27	65.79	52.48	1.0
3.47	3.87	2.2	9.53	8.73	6.07	2.67	40.0	48.12	1.0
0.13	3.2	0.13	3.47	3.0	2.93	0.07	50.0	94.85	1.0
2.6	4.0	1.6	8.2	11.73	9.4	2.33	65.79	54.71	2.0
2.73	3.4	1.6	7.73	9.13	7.93	1.2	40.0	37.12	2.0
0.4	2.8	0.27	3.47	5.4	4.4	1.0	30.0	95.84	1.0
0.47	5.0	0.33	5.8	8.87	7.47	1.4	30.0	71.74	1.0
0.4	3.47	0.2	4.07	5.47	3.4	2.07	29.17	46.71	1.0
0.53	4.47	0.33	5.33	5.8	4.93	0.87	71.05	60.87	1.0
2.93	5.67	1.8	10.4	10.4	8.93	1.47	84.21	43.92	1.0
0.6	4.6	0.47	5.67	9.93	7.47	2.47	78.95	38.82	2.0
5.0	7.27	2.93	15.2	22.8	19.8	3.0	40.0	17.24	2.0
3.27	5.73	1.87	10.87	9.67	6.0	3.67	41.67	35.23	1.0
0.13	1.8	0.13	2.07	2.87	2.2	0.67	60.0	100.0	1.0
2.53	3.53	1.6	7.67	11.87	11.47	0.4	50.0	30.98	1.0
0.4	4.13	0.13	4.67	5.2	4.73	0.47	20.0	88.42	1.0
2.53	4.53	1.6	8.67	14.4	11.27	3.13	30.0	64.28	1.0
4.4	6.07	3.07	13.53	13.0	12.33	0.67	60.0	16.32	1.0
0.2	0.33	0.13	0.67	1.53	1.53	0.0	57.89	90.89	1.0
2.87	8.0	1.8	12.67	45.73	36.53	9.2	60.0	70.69	1.0
1.0	5.47	0.67	7.13	7.4	3.8	3.6	50.0	43.74	1.0
2.6	5.73	1.53	9.87	8.4	7.53	0.87	40.0	22.4	1.0
0.47	4.0	0.4	4.87	5.13	4.8	0.33	40.0	59.65	1.0
1.27	4.0	0.87	6.13	5.0	3.6	1.4	70.0	47.9	3.0
0.6	4.33	0.27	5.2	9.07	7.93	1.13	80.0	98.66	3.0
1.0	6.4	0.8	8.2	12.8	10.0	2.8	50.0	59.51	3.0
0.67	6.07	0.4	7.13	9.2	7.67	1.53	40.0	98.8	3.0
0.47	3.53	0.4	4.4	10.87	8.33	2.53	30.0	65.9	1.0
1.8	7.07	1.2	10.07	19.2	14.87	4.33	40.0	39.73	3.0
3.27	6.47	2.07	11.8	14.67	12.27	2.4	80.0	42.21	1.0

1.93	7.07	1.4	10.4	18.47	16.13	2.33	60.0	31.07	3.0
2.0	2.27	1.33	5.6	6.93	5.13	1.8	10.0	40.2	1.0
1.93	2.2	1.93	6.07	6.13	5.73	0.4	80.0	43.37	1.0
3.07	7.53	1.87	12.47	18.13	14.8	3.33	30.0	44.21	2.0
2.27	2.53	1.4	6.2	2.13	1.73	0.4	50.0	26.41	1.0
3.67	7.6	2.27	13.53	22.8	20.33	2.47	50.0	42.7	2.0
3.8	5.33	2.27	11.4	12.73	7.67	5.07	30.0	74.22	2.0
0.2	0.4	0.13	0.73	1.27	1.27	0.0	80.0	78.83	1.0
3.47	3.93	2.2	9.6	13.93	13.33	0.6	50.0	46.59	1.0
5.2	8.0	3.13	16.33	17.2	12.93	4.27	40.0	40.53	2.0
0.4	2.73	0.4	3.53	3.87	3.13	0.73	60.0	63.8	1.0
0.53	1.13	0.47	2.13	8.0	6.93	1.07	70.0	84.69	1.0
1.0	6.07	0.93	8.0	12.73	10.33	2.4	40.0	40.59	1.0
3.4	5.47	2.13	11.0	12.47	11.6	0.87	50.0	41.55	1.0
0.6	4.33	0.47	5.4	22.47	18.8	3.67	40.0	73.22	1.0
0.27	3.67	0.27	4.2	4.27	2.27	2.0	30.0	80.16	1.0
1.53	6.53	1.0	9.07	17.2	13.33	3.87	60.0	36.03	3.0
0.6	5.33	0.4	6.33	9.73	8.47	1.27	60.0	72.87	2.0
2.53	2.93	1.67	7.13	8.6	7.6	1.0	30.0	43.88	1.0
1.07	2.13	1.0	4.2	7.73	5.47	2.27	40.0	44.42	1.0
0.47	1.73	0.4	2.6	7.33	6.67	0.67	30.0	71.67	1.0
0.53	3.87	0.4	4.8	12.67	9.47	3.2	40.0	73.31	1.0
0.47	5.07	0.33	5.87	10.33	7.67	2.67	30.0	82.63	2.0
2.93	4.53	1.87	9.33	8.87	7.13	1.73	20.0	29.71	1.0
3.53	5.33	2.07	10.93	16.27	13.73	2.53	30.0	55.72	2.0
0.8	3.73	0.53	5.07	8.87	7.33	1.53	60.0	70.65	2.0
0.13	1.33	0.07	1.53	5.73	5.0	0.73	60.53	31.92	1.0
2.13	3.93	1.8	7.87	12.47	9.0	3.47	60.0	60.36	1.0
2.73	7.13	1.6	11.47	9.13	8.2	0.93	70.0	32.86	3.0
2.53	2.93	1.67	7.13	6.2	4.67	1.53	40.0	66.16	1.0
3.6	4.07	2.27	9.93	9.4	6.4	3.0	50.0	38.96	1.0
3.8	6.6	2.4	12.8	25.0	15.2	9.8	30.0	36.5	3.0
1.87	2.67	1.53	6.07	7.07	6.07	1.0	60.0	57.22	1.0
1.0	1.4	0.8	3.2	6.2	5.87	0.33	30.0	53.21	1.0
2.33	8.6	1.27	12.2	38.2	29.47	8.73	40.0	68.77	1.0
0.6	5.33	0.53	6.47	12.93	9.4	3.53	40.0	73.71	1.0
3.47	5.93	2.27	11.67	25.67	21.47	4.2	10.0	33.23	1.0
4.4	7.13	2.8	14.33	28.6	23.53	5.07	80.0	39.48	3.0
3.4	4.07	2.13	9.6	10.93	8.6	2.33	70.0	38.07	1.0
2.8	3.47	1.8	8.07	20.6	14.73	5.87	30.0	41.21	1.0
0.4	1.13	0.33	1.87	3.27	2.27	1.0	30.0	75.18	1.0
0.33	1.27	0.2	1.8	6.73	5.13	1.6	83.33	51.54	1.0
0.27	0.4	0.2	0.87	3.27	2.8	0.47	50.0	69.26	1.0
0.73	3.6	0.6	4.93	17.47	13.2	4.27	30.0	53.33	3.0
0.53	2.27	0.47	3.27	4.6	3.6	1.0	30.0	61.74	1.0
0.93	3.0	0.93	4.87	9.2	7.2	2.0	50.0	40.36	1.0
3.53	5.27	2.2	11.0	32.07	25.67	6.4	60.0	47.51	2.0
2.93	3.93	1.73	8.6	8.53	4.87	3.67	40.0	45.5	1.0
0.6	2.13	0.47	3.2	7.8	6.47	1.33	40.0	73.48	2.0
2.13	4.6	1.4	8.13	11.47	8.87	2.6	60.0	50.09	1.0
0.73	1.07	0.67	2.47	3.73	2.93	0.8	70.0	49.38	1.0
2.67	4.73	1.6	9.0	15.8	10.27	5.53	70.0	44.99	1.0
2.33	7.93	1.27	11.53	17.0	11.2	5.8	60.0	71.85	2.0
0.67	3.8	0.53	5.0	11.27	7.73	3.53	40.0	77.24	1.0
2.13	5.13	1.33	8.6	10.47	9.07	1.4	30.0	46.92	1.0
0.53	5.2	0.47	6.2	7.53	7.4	0.13	10.0	74.43	1.0
0.33	3.07	0.33	3.73	5.53	2.87	2.67	40.0	74.75	1.0
0.6	0.67	0.4	1.67	4.27	3.87	0.4	90.0	68.23	1.0

0.6	6.47	0.47	7.53	14.07	10.93	3.13	30.0	57.67	3.0
0.53	3.87	0.47	4.87	7.47	5.47	2.0	30.0	45.95	1.0
0.6	1.87	0.4	2.87	3.87	3.13	0.73	30.0	54.56	1.0
0.13	2.0	0.13	2.27	4.0	2.87	1.13	20.0	100.0	1.0
1.73	1.07	1.07	3.87	5.27	4.6	0.67	20.0	46.56	1.0
2.33	3.33	1.6	7.27	11.4	6.87	4.53	50.0	34.17	2.0
3.6	5.07	2.27	10.93	17.2	12.73	4.47	60.0	39.63	1.0
0.67	5.27	0.53	6.47	17.87	13.4	4.47	60.0	86.84	1.0
3.53	5.2	2.27	11.0	13.53	8.13	5.4	20.0	33.73	1.0
3.6	6.47	2.27	12.33	17.47	14.6	2.87	40.0	66.76	1.0
2.27	2.53	1.53	6.33	10.53	7.33	3.2	70.0	29.28	3.0
0.6	4.47	0.47	5.53	8.2	6.27	1.93	10.0	70.89	1.0
3.53	5.4	2.27	11.2	18.6	10.47	8.13	40.0	37.17	1.0
0.53	4.67	0.4	5.6	7.87	4.13	3.73	20.0	76.56	1.0
0.2	2.6	0.2	3.0	4.73	3.47	1.27	73.68	80.67	1.0
0.67	5.0	0.6	6.27	12.47	10.27	2.2	50.0	66.8	1.0
3.27	5.4	2.13	10.8	18.87	12.2	6.67	10.0	45.58	1.0
0.73	5.4	0.6	6.73	15.07	11.67	3.4	70.0	71.46	3.0
0.4	2.67	0.4	3.47	6.53	4.93	1.6	40.0	80.42	1.0
0.67	4.67	0.53	5.87	9.13	6.6	2.53	40.0	69.96	1.0
2.4	3.67	1.53	7.6	10.07	7.0	3.07	30.0	48.48	1.0
3.6	5.93	2.33	11.87	19.67	15.4	4.27	30.0	44.11	1.0
0.8	5.67	0.47	6.93	14.6	11.93	2.67	40.0	91.48	2.0
0.87	1.73	0.67	3.27	6.13	4.4	1.73	50.0	51.84	1.0
1.87	1.53	1.4	4.8	5.4	4.0	1.4	30.0	38.12	1.0
0.8	4.8	0.53	6.13	7.0	5.67	1.33	30.0	75.03	1.0
0.6	4.93	0.53	6.07	9.67	7.47	2.2	20.0	52.89	1.0
0.6	1.13	0.47	2.2	4.73	4.73	0.0	60.0	71.68	2.0
1.0	6.53	0.67	8.2	19.53	13.13	6.4	30.0	70.43	2.0
0.67	0.53	0.47	1.67	2.4	2.13	0.27	30.0	57.72	1.0
2.0	4.0	1.6	7.6	5.0	4.73	0.27	20.0	53.26	1.0
3.6	6.07	2.13	11.8	14.0	12.07	1.93	40.0	40.68	1.0
0.6	5.87	0.53	7.0	17.93	10.87	7.07	20.0	68.65	1.0
0.13	1.73	0.13	2.0	2.0	1.13	0.87	60.0	82.67	1.0
2.33	2.93	1.27	6.53	6.87	3.07	3.8	50.0	35.38	1.0
0.47	4.47	0.47	5.4	8.13	6.73	1.4	40.0	70.94	1.0
1.87	2.07	1.6	5.53	8.87	7.87	1.0	68.42	34.77	1.0
1.4	3.93	0.73	6.07	10.27	7.07	3.2	60.0	63.23	1.0
0.47	3.27	0.27	4.0	8.53	7.2	1.33	78.95	79.39	2.0
0.87	2.33	0.67	3.87	8.73	7.53	1.2	60.0	63.53	1.0
0.6	5.0	0.53	6.13	12.47	8.27	4.2	70.0	76.56	1.0
2.67	3.27	1.67	7.6	12.07	11.53	0.53	50.0	48.97	1.0
2.73	3.73	1.8	8.27	13.87	10.2	3.67	40.0	53.7	1.0
0.2	0.6	0.2	1.0	0.87	0.53	0.33	40.0	44.25	1.0
1.87	6.2	1.8	9.87	17.6	13.67	3.93	20.0	46.74	1.0
1.6	4.67	0.87	7.13	14.8	12.6	2.2	65.79	73.12	1.0
2.33	2.87	1.87	7.07	6.93	4.93	2.0	68.42	52.15	1.0

PRILOG B2 – PRIMJER KODA ZA N=3

```
import pandas as pd
import numpy as np
import itertools
import os
from sklearn.model_selection import cross_val_predict, StratifiedKFold
from sklearn.metrics import accuracy_score, precision_score, recall_score, f1_score
from sklearn.linear_model import LogisticRegression
from sklearn.svm import SVC
from sklearn.tree import DecisionTreeClassifier
from sklearn.ensemble import RandomForestClassifier
from sklearn.naive_bayes import GaussianNB
from sklearn.neural_network import MLPClassifier

file_path = r'C:\Users\Admin\Desktop\Skup podataka\Normirano\Sve.xlsx'
df = pd.read_excel(file_path)

target_col = 'Uspjeh'
feature_cols = [col for col in df.columns if col != target_col]

models = {
    'Logistic Regression': LogisticRegression(max_iter=1000, class_weight='balanced',
random_state=42),
    'SVM': SVC(kernel='rbf', class_weight='balanced', random_state=42),
    'Decision Tree': DecisionTreeClassifier(class_weight='balanced', random_state=42),
    'Random Forest': RandomForestClassifier(class_weight='balanced', random_state=42),
    'Naïve Bayes': GaussianNB(), # nema class_weight parametar
    'Neural Network (MLP)': MLPClassifier(max_iter=1000, random_state=42)
}

csv_path = r'C:\Users\Admin\Desktop\Skup podataka\Treniranje
modela\Treniranje_3_znacajke\rezultati3.csv'

if not os.path.exists(csv_path):
    with open(csv_path, 'w', encoding='utf-8') as f:
        f.write("Znacajke,Model,Točnost,Preciznost,Odziv,F1 Score\n")
```

```

cv = StratifiedKFold(n_splits=10, shuffle=True, random_state=42)

for features in itertools.combinations(feature_cols, 3):
    X = df[list(features)]
    y = df[target_col]

    for model_name, model in models.items():
        y_pred = cross_val_predict(model, X, y, cv=cv)

        acc = accuracy_score(y, y_pred)
        prec = precision_score(y, y_pred, average='weighted', zero_division=0)
        rec = recall_score(y, y_pred, average='weighted')
        f1 = f1_score(y, y_pred, average='weighted')

        with open(csv_path, 'a', encoding='utf-8') as f:
            line = f'{', '.join(features)}, {model_name}, {acc:.4f}, {prec:.4f}, {rec:.4f}, {f1:.4f}\n'
            f.write(line)

    print(f'Značajke: {features} | Model: {model_name}')
    print(f' Točnost    : {acc:.4f}')
    print(f' Preciznost  : {prec:.4f}')
    print(f' Odziv       : {rec:.4f}')
    print(f' F1 Score    : {f1:.4f}')
    print("-" * 50)

```

PRILOG C

PRILOG C1 – Upitnik A1

1. Nadzorna ploča analitike učenja mi pomaže da stvorim svijest o svojoj trenutnoj situaciji učenja.
2. Pomoću nadzorne ploče analitike učenja predviđam svoju moguću situaciju sa učenjem.
3. Nadzorna ploča analitike učenja potiče me na razmišljanje o svom ponašanju u učenju.
4. Nadzorna ploča analitike učenja stimulira me da promijenim ponašanje u učenju ili način proučavanja.
5. Nadzorna ploča analitike učenja potiče me na učinkovitije učenje (kao npr.: pobrinite se da radite na pravi način).
6. Nadzorna ploča analitike učenja potiče me na učinkovitije učenje (kao npr.: osiguravanje postizanja cilja, na bilo koji način).
7. Jasno mi je koji se podaci prikupljaju za sastavljanje i prikazivanje nadzorne ploče analitike učenja.
8. Jasno mi je zašto se prikupljaju podaci prikazani na nadzornoj ploči analitike učenja.

PRILOG C2 – Upitnik A2

1. Nadzorna ploča analitike učenja pozitivno utječe na motivaciju za učenje.
2. Redovito sam pratio/la informacije prikazane na nadzornoj ploči analitike učenja.
3. Praćenje informacija na nadzornoj ploči analitike učenja potaknulo me na razmišljanje o svom ponašanju i uspjehu.
4. Nadzorna ploča analitike učenja je utjecala na moju strategiju upravljanja vremenom.
5. Nadzorna ploča analitike učenja mi je omogućila da lakše napravim plan učenja.
6. Samopouzdanje je poraslo nakon pregleda mog ponašanja na nadzornoj ploči analitike učenja.

PRILOG C3 – Upitnik A3 (SUS)

1. Mislim da bih često volio/la koristiti nadzornu ploču analitike učenja.
2. Mislim da je nadzorna ploča analitike učenja nepotrebno kompleksna.
3. Mislim da je nadzorna ploča analitike učenja jednostavna za korištenje.
4. Mislim da će mi biti potrebna pomoć osobe iz tehničke podrške za korištenje nadzorne ploče analitike učenja.
5. Razne funkcije na nadzornoj ploči analitike učenja su jako dobro integrirane.
6. Mislim da postoji previše nekonzistentnosti u nadzornoj ploči analitike učenja.
7. Pretpostavljam da bi većina korisnika mogla brzo naučiti raditi s nadzornom pločom analitike učenja.
8. Mislim da je nadzorna ploča analitike učenja nezgrapna za korištenje.
9. Osjećao/la sam se sigurnim pri korištenju nadzorne ploče analitike učenja.
10. Bilo mi je potrebno naučiti dosta stvari prije nego sam mogao/la početi koristiti nadzornu ploču analitike učenja.

PRILOG D

PRILOG D1 – Zadaci za testiranje

Zadatak 1: Prijavite se na nadzornu ploču analitike učenja i odaberite komponentu aktivnosti i uspjeha.

Zadatak 2: Provjerite ukupan broj logiranja studenata prikazan po medijanu, prosjeku, minimumu i maksimumu (zapišite odgovore u tablicu ispod, u Zadatku 2).

Zadatak 3: Provjerite ukupan uspjeh studenata na kolegiju prikazan po medijanu, prosjeku, minimumu i maksimumu (zapišite odgovore u tablicu ispod, u Zadatku 3).

Zadatak 4: Izdvojite prva tri nastavna materijala po broju pregleda dostupnih na nadzornoj ploči (zapišite odgovore u tablicu ispod, u Zadatku 4).

Zadatak 5: Provjerite u kojem tjednu je bilo najviše logiranja (zapišite odgovore u tablicu ispod, u Zadatku 5).

Zadatak 6: Odaberite jednog studenta s popisa, a potom Zapišite broj logiranja i uspjeh studenta s jedne od prikazanih provjera (zapišite odgovore u tablicu ispod, u Zadatku 6).

	Odgovori
Zadatak 2.	
Zadatak 3:	
Zadatak 4:	
Zadatak 5:	
Zadatak 6:	

Zadatak 7: Odaberite komponentu ishodi učenja.

Zadatak 8: Odaberite jednog studenta s popisa (zapišite ime i prezime u tablicu ispod, pod Zadatkom 8), a zatim odaberite postavljene ishod učenja (zapišite naziv ishoda učenja u tablicu ispod, također pod Zadatkom 8).

Zadatak 9. Provjerite je li odabrani student iz prethodnog zadatka izvršio obaveze prema odabranom ishodu učenja i rezultat zapišite u tablicu ispod, pod Zadatkom 9.

Zadatak 10: Provjerite ukupan postotak zadovoljenih ishoda učenja za cijeli predmet putem radar charta i u tablicu ispod, pod Zadatkom 10, zapišite koji je ishod učenja zadovoljen u najvećem postotku, a koji u najmanjem.

	Odgovori:
Zadatak 8:	
Zadatak 9:	
Zadatak 10:	

Zadatak 11: Odaberite komponentu predviđanja.

Zadatak 12: Odaberite jednog studenta (zapišite ime i prezime u tablicu ispod, pod Zadatkom 12), a potom provjerite daju li svi tri algoritma strojnog učenja iste rezultate. Rezultat (Da/Ne) zapišite ispod, pod Zadatkom 12.

Zadatak 13: Napišite imena dva studenta koji postižu isti uspjeh u sva tri modela predviđanja (odgovor zapišite u tablicu ispod, pod Zadatkom 13).

Zadatak 14: Odjavite se sa nadzorne ploče analitike učenja.

	Odgovori:
Zadatak 12:	
Zadatak 13:	

PRILOG D2 – Pre-eksperimentalni upitnik

Upitnik prije eksperimenta ima za cilj prikupiti demografske informacije, prethodno iskustvo i stručnost korisnika.

Spol (odaberi odgovor):

M

Ž

Godine

Vaš odgovor:

Koje je vaše trenutno zvanje/uloga na fakultetu? Molimo vas da odaberete jedan od sljedećih odgovora:

Asistent

Poslijedoktorand

Docent

Izvanredni profesor

Redoviti profesor

Ostalo

Kako biste ocijenili svoje poznavanje sustava za e-učenje (npr. Moodle LMS)? Molimo vas da odaberete jedan od sljedećih odgovora:

Nemam iskustva

Početak

Prosječni korisnik

Napredni korisnik

Expert

Kako biste opisali svoje iskustvo u korištenju analitičkih alata za praćenje učenja ili napretka studenata? Molimo vas da odaberete jedan od sljedećih odgovora:

Nemam iskustva

Početak

Prosječni korisnik

Napredni korisnik

Expert

Kako biste ocijenili svoju razinu vještina u interpretaciji podataka s nadzorne ploče analitike učenja?

Nemam iskustva

Početak

Prosječni korisnik
 Napredni korisnik
 Expert
 Kako biste ocijenili svoje vještine za rad na računalu?
 Nemam iskustva
 Početnik
 Prosječni korisnik
 Napredni korisnik
 Expert

PRILOG D3 – Test pamtljivosti (memo-test)


1. Koja je dominantna boja sučelja na nadzornoj ploči analitike učenja?

Vaš odgovor

2. Koje informacije se prikazuju na prvom pogledu „Podaci o aktivnostima sa sustavom“ na nadzornoj ploči?

Vaš odgovor

3. Objasnite svrhu sljedećeg grafa:



Vaš odgovor

4. Koje informacije se prikazuju na drugom pogledu „Ishodi učenja“ na nadzornoj ploči (navedite sve)?

Vaš odgovor

5. Kako možete provjeriti je li student izvršio obaveze prema postavljenom ishodu u drugom pogledu „Ishodi učenja“ na nadzornoj ploči?

Vaš odgovor


6. Koliko prediktivnih modela je implementirano na nadzornoj ploči analitike učenja za nastavnike?

Vaš odgovor

7. Gdje se nalaze podaci o uspjehu studenata?

Vaš odgovor

8. Koje informacije o analitici učenja nedostaju u žutom pravokutniku na sljedećoj slici:



Vaš odgovor

9. Nabroji dvije vrste analitike koje sadrži nadzorna ploča analitike učenja, a da nisu prethodno opisani u zadacima?

Vaš odgovor

10. Koje informacije o studentu sadrži kartica Detalji u pogledu „Podaci o aktivnostima sa sustavom“?

PRILOG D4 – Upitnik (SUS)

1. Mislim da bih često volio/la koristiti nadzornu ploču analitike učenja.
2. Mislim da je nadzorna ploča analitike učenja nepotrebno kompleksna.
3. Mislim da je nadzorna ploča analitike učenja jednostavna za korištenje.
4. Mislim da će mi biti potrebna pomoć osobe iz tehničke podrške za korištenje nadzorne ploče analitike učenja.
5. Razne funkcije na nadzornoj ploči analitike učenja su jako dobro integrirane.
6. Mislim da postoji previše nekonzistentnosti u nadzornoj ploči analitike učenja.
7. Pretpostavljam da bi većina korisnika mogla brzo naučiti raditi s nadzornom pločom analitike učenja.
8. Mislim da je nadzorna ploča analitike učenja nezgrapna za korištenje.
9. Osjećao/la sam se sigurnim pri korištenju nadzorne ploče analitike učenja.
10. Bilo mi je potrebno naučiti dosta stvari prije nego sam mogao/la početi koristiti nadzornu ploču analitike učenja.

PRILOG D5 – Strukturirani upitnik

1. Kako biste opisali svoje cjelokupno iskustvo sa nadzornom pločom analitike učenja za nastavnike – LAD-t?
2. Što vam se najviše svidjelo u korištenju nadzorne ploče analitike učenja za nastavnike – LAD-t?
3. Što vam se najmanje svidjelo u korištenju nadzorne ploče analitike učenja za nastavnike – LAD-t?
4. Što vas je, ako išta, iznenadilo u tom iskustvu?
5. Što je, ako je išta, izazvalo frustraciju?

ŽIVOTOPIS I POPIS JAVNO OBJAVLJENIH RADOVA

Ivan Peraić rođen je 11. kolovoza 1986. godine u Zadru. Opću gimnaziju završio je u Biogradu na Moru. Diplomirao je 2012. godine na Prirodoslovno-matematičkom fakultetu Sveučilišta u Splitu i stekao zvanje magistra matematike i informatike.

Od 2011. do 2020. radio je kao nastavnik matematike i informatike u Srednjoj školi Biograd na Moru. Od početka školske godine 2020. radio je kao učitelj matematike i informatike u Osnovnoj školi „Bartula Kašića“ u Zadru, gdje je ostao zaposlen do travnja 2022. U razdoblju od 2021. do 2022. bio je i vanjski suradnik u naslovnom zvanju asistenta na Sveučilištu u Zadru, na Stručnom studiju informacijske tehnologije.

Od svibnja 2022. zaposlen je na Odjelu za informacijske znanosti i tehnologije Sveučilišta u Zadru na radnom mjestu asistenta, za potrebe stručnog studija informacijske tehnologije.

ZNANSTVENI RADOVI

Grubišić, A., Stankov, S., & Peraić, I. (2013). Ontology based approach to Bayesian student model design. *Expert Systems with Applications*, 40(13), 5363–5371. <https://doi.org/10.1016/j.eswa.2013.03.041>

Peraić, I., & Grubišić, A. (2018). Nadzorna ploča analitike učenja: upotreba podataka i analitike za podršku procesu učenja i poučavanja. *MIPRO 2018*.

Vasić, D., Žitko, B., Grubišić, A., Stankov, S., Gašpar, A., Šarić-Grgić, I., Tomaš, S., Peraić, I., & Markić-Vučić, M. (2021). Croatian POS Tagger as a Prerequisite for Knowledge Extraction in Intelligent Tutoring Systems. U *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*: Sv. 12792 LNCS. https://doi.org/10.1007/978-3-030-77857-6_23

Peraić, I., & Grubišić, A. (2023). Exploring Student Engagement in Online Programming Courses: A Two-Level K-means Analysis. *2023 31st International Conference on Software, Telecommunications and Computer Networks, SoftCOM 2023*. <https://doi.org/10.23919/SoftCOM58365.2023.10271619>

Peraić, I., & Grubišić, A. (2022). Development and Evaluation of a Learning Analytics Dashboard for Moodle Learning Management System. U *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*: Sv. 13517 LNCS. https://doi.org/10.1007/978-3-031-22131-6_30

Peraić, I., & Grubišić, A. (2023). Predicting Academic Performance of Students in a Computer Programming Course using Data Mining. *International Journal of Engineering Education*, 39(4), 836–844.

Peraić, I., Grubišić, A., & Pintarić, N. (2025). Machine Learning in Learning Analytics Dashboards: A Systematic Literature Review. *2025 IEEE 23rd World Symposium on Applied Machine Intelligence and Informatics (SAMI)*, 47–52.