

Nadzorne ploče analitike učenja

Ivan Peraić
ivan.peraic@skole.hr

Sažetak – Analitika učenja pruža potencijal za prilagodavanje procesa učenja, poučavanja i testiranja znanja potrebama pojedinca. Jedan od načina korištenja analitike učenja je nadzorna ploča za izvještavanje učenika i nastavnika. U ovom radu napravljen je pregled aktualnih nadzornih ploča korištenih u obrazovanju. U pregled je uključen 61 rad, a predstavljeni rezultati prikazuju korisnike nadzornih ploča analitike učenja, korištene podatke, metode pristupa izradi, ciljeve razvoja te metode i tehnike koje omogućavaju prezentaciju informacija. Najveći naglasak je stavljen na povratnu informaciju koja se koristi u svrhu unaprjeđenja procesa učenja i poučavanja. Na temelju svih povratnih informacija koje se pojavljuju u pregledanim radovima, predstavljen je pedagoški okvir potreban za razvoj nadzorne ploče analitike učenja. Vrednovanje ovakvih sustava predstavlja složen proces, a pokazalo se kako nastavnici i učenici u globalu imaju pozitivan stav prema informacijama koje prime, no utjecaj nadzornih ploča analitike učenja na proces učenja, poučavanja i testiranja znanja još nije dovoljno istražen.

Ključne riječi – analitika učenja, veliki skupovi podataka, nadzorna ploča analitike učenja, povratna informacija, vrednovanje

1. UVOD

U ovom trenutku možemo zaključiti kako su prošli dani uzbudjena zbog online tečajeva, iPada u učionicama, sustava za upravljanjem učenja ili sustava za preporuke koji točno znaju ono što učenik zna i ono što učenik ne zna. Polaganje, ali sigurno, ulazimo u fazu složenosti u kojoj se sustav obrazovanja mijenja neprestano. Naime, korištenjem sustava za poučavanje, trajno ostaju podaci koji zasigurno obećavaju razumijevanje različitih ponašanja učenika [1]. Svi ovi podaci spadaju u velike skupove podataka (eng. Big data), tehnologija nam omogućava da prikupimo podatke, a potom ih iskoristimo na različite načine. Odgovor na pitanje „Na koji način se mogu iskoristiti dobiveni podaci?“ implicira pojavu novog polja nazvanog analitika učenja (eng. Learning analytics). Usvajanjem tehnologija u obrazovne ustanove razvija se više mogućnosti za prikupljanje i analizu podataka, polje analitike učenja predstavlja jedan od najnovijih trendova u obrazovanju, a osim kao trenda obrazovanja, Horizon izvješće [2], 2013. godine opisuje analitiku učenja kao pravi potencijal za poboljšanje iskustava učenika. Povjesno gledano, analitika je korištena u ekonomiji, gdje je imala prediktivnu funkciju, primjenjivala su je razna poduzeća kako bi predvidjeli ponašanje potrošača i na taj način se mogla organizirati kampanja. Ubrzo, nakon toga, obrazovne institucije kreću sa korištenjem analitike, a

krajnji cilj je veća uspješnost učenika. Osnovni cilj i svrha sustava za e-učenje je uspjeh i zadovoljstvo učenika, a na ovaj način je moguće prepoznati faktore koji omogućavaju isto. Elias [3] naglašava kako veće količine podataka već postoje u većini obrazovnih institucija, a tečajevi obrazovanja na daljinu posredovani računalom sve više stvaraju tragove učenikovih podataka. Analizom tih podataka aplikacije za analitiku mogu predvidjeti izazove koji predstoje, kako za ustanovu tako i za učenike. Na ovaj način otvaraju se vrata inovativnom učenju i poučavanju uz pomoć novih tehnologija i otvorenih obrazovnih resursa, jasno je kako pomoću analitike učenja mogu nastati nove metode podučavanja usmjerene više na učenika, jer se napredak učenika koji redovito koriste informacijsko-komunikacijsku tehnologiju može lakše pratiti, nastavnici mogu znati točne rezultate učenja svakog pojedinog učenika te identificirati potrebe za dodatnom pomoći.

2. ANALITIKA UČENJA

Nastava je dinamična aktivnost koju treba stalno nadzirati i prilagođavati promjenama socijalnog konteksta i potrebama učenika kako bi se osigurala visoka kvaliteta [4]. Kako se primjena online učenja i dalje povećava, postoji potreba za učinkovitim strategijama i alatima koji pomažu učenicima postizanje uspjeha u online okruženjima [5]. Tijekom online učenja, učenici ostavljaju digitalni trag, koji otvara vrata analiticu učenja. Analitika učenja koristi potencijal sve većih količina podataka o interakciji, osobnih podataka i podataka postignuća [6]. Prema prvoj međunarodnoj konferenciji Learning Analytics and Knowledge (LAK) analitika učenja 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“ [7]. Suthers i Verbert [8] su polje analitike učenja prepoznali kao "srednji prostor", jer se nalazi na sjecištu između tehnologije i znanosti o učenju. Štoviše, analitiku učenja treba promatrati kao obrazovni pristup vođen pedagogijom, a ne obrnuto [9].

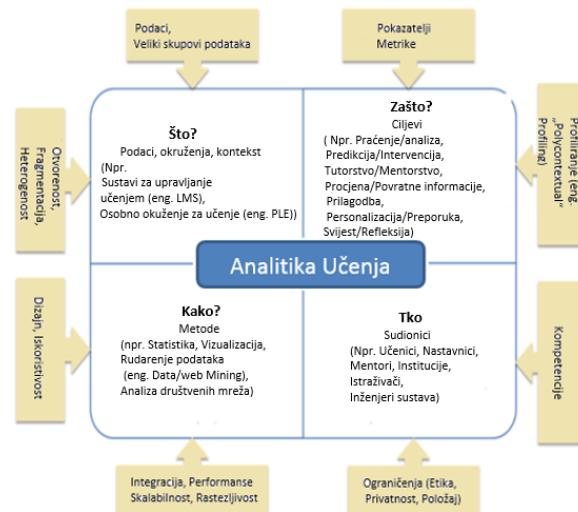
Ideja analitike učenja dolazi od činjenice kako učenik ili student pri komunikaciji sa svojom obrazovnom institucijom uvijek ostavlja digitalni trag (prijava u virtualno okruženje za učenje, odlazak u knjižnicu ili jednostavno pristup forumu) koji u ovom slučaju pripada velikom skupu podataka. U svakom slučaju, sustavi za poučavanje sadrže brojne podatke o aktivnostima učenika,

a svrha analitike učenja je iskoristiti dobivene podatke kako bi što bolje razumjeli proces učenja i poučavanja. Greller i Drachsler [9] zaključuju kako analitika učenja ima potencijal učenicima pružiti uvid u vlastite navike učenja, uz samoprocjenu podataka koji su ključni za stvaranje informacija o svom znanju.

Vrlo je bitno imati na umu kakve podatke možemo prikupiti, a potom definirati strategije na koji način ćemo iskoristiti podatke. Različiti alati i pristupi upotrebljavaju se u analitici učenja kako bi pomogli donošenju odluka o učenju učenika. Četiri područja analitike učenja mogu biti od interesa za obrazovne institucije [10], [11].

- 1) Deskriptivna analitika (eng. Descriptive Analytics) želi odgovoriti na pitanje „Što se dogodilo?“. Obično ima za cilj analizirati podatke o učeniku i izraditi nadzorne ploče koje prikazuju smislene obrasce ili uvide koji dolaze iz tih analiza, vizualizacijama kao što su grafikoni, tablice, mreža i sl. Ova se vrsta analitike može koristiti na različitim razinama unutar obrazovanja :
 - Učenicima da postignu svoj položaj u smislu naučenog, radnog opterećenja ili angažmana u odnosu na druge;
 - Nastavnicima da dobiju ideju o utjecaju svog poučavanja temeljem rezultata testova ili temeljem vremena koje učenici trebaju za realiziranje određene aktivnosti;
 - Instituciji da dobije realnu sliku o odustajanju učenika.
- 2) Dijagnostička analitika (eng. Diagnostic Analytics) želi odgovoriti na pitanje „Zašto se to dogodilo?“, pregledavajući podatke ili sadržaj kako bi bolje razumjeli događaje ili utjecaje koji mogu objasniti trenutnu situaciju. Odgovor na to pitanje pokušava dobiti tehnikom otkrivanja podataka ili koristeći statističke korelacije. Dijagnostička analiza omoguće razumijevanje događaja ili kombinacije događaja koji vode do trenutne situacije. Također, i ova se vrsta analitike može koristiti na različitim razinama unutar obrazovanja:
 - Učenicima ova vrsta analitike može dati odgovore na pitanja zašto su uspješni ili neuspješni u savladavanju nastavnog gradiva;
 - Nastavnicima bi mogla ukazati na bolje načine poučavanja i usporediti s prvobitnom shemom koju su imali na umu za poučavanje;
 - Institucijama, kako bi mjerili učinke pojedinih akcija na postignuća učenika.
- 3) Prediktivna analitika (eng. Predictive Analytics) želi odgovoriti na pitanje „Što će se dogoditi?“. Obično ima za cilj predviđjeti buduće trendove u napretku učenika i obično se koristi za prepoznavanje učenika koji bi mogli postati "rizični" u smislu niskih performansi ili niskih angažmana. Prediktivna analitika je obećavajuće polje, za sve sudionike procesa učenja:

- Učeniku ukazuje radi li u pravom smjeru kako bi postigao svoj cilj učenja;
 - Nastavnik koristi prediktivnu analitiku kako bi utvrdio koji su učenici rizični, a zatim intervenira kad još uvijek ima mogućnosti utjecati na njihov uspjeh.
 - Institucijama ukazuje koji su programi bolji ili lošiji te pomaže donijeti odluke o stvaranju novih programa.
- 4) Propisana analitika (eng. Prescriptive Analytics) želi odgovoriti na pitanje „Kako omogućiti željeno?“. To se može postići generirajući preporuke za proces učenja i poučavanja. Propisana analitika, na temelju pregledanih podataka i digitalnih sadržaja, želi odrediti realne i ispravne radnje za postizanje zadanog cilja. Ovakva vrsta analitike omogućuje:
- Učenicima stvoriti individualne staze učenja;
 - Nastavnicima, da svojim učenicima predloži aktivnosti koje ih vode prema postavljenim ciljevima;
 - Institucijama, da identificira trendove odustajanja i da ih spriječi prije nego se dogode.
- Chatti i sur. [12] predstavljaju referentni model analitike učenja (Slika 1) koji sadrži četiri dimenzije, koje možemo opisati sa sljedeća četiri pitanja:
1. ŠTO - koje vrste podataka moraju biti prikupljene, upravljane i korištene;
 2. TKO – tko će biti obuhvaćen, tko će primiti rezultate
 3. ZAŠTO – koji je cilj analize podataka;
 4. KAKO – koje metode koristiti za analizu podataka?



Slika 1 Referentni model analitike učenja

3. VELIKI SKUPOVI PODATAKA

Analitika učenja je pristup koji se temelji na podacima koji su dobiveni iz okruženja za učenje. Velike količine obrazovnih podataka sada se mogu pohraniti, analizirati i dijeliti. Postoje tjedni, ako ne i dnevni izvještaji o korištenju velikih skupova podataka. Što je još važnije, obrada velikih podataka može pomoći obrazovanju da postigne značajan napredak u poboljšanju procesa učenja i poučavanja. Veliki skupovi podataka predstavljaju područje koje se koristi u mnogim poljima istraživanja, a o važnosti razumijevanja pišu Mayer-Schonberger i Cukier [13] i naglašavaju kako veliki skupovi podataka predstavljaju revoluciju koja će transformirati kako živimo, radimo i mislimo mijenjajući način poslovanja i obrazovanja, ali i upravljanje našim osobnim životima.

Nadalje, kako kaže West [14], "Veliki podaci mogu podupirati klasični obrazovni sustav koji pomaže nastavnicima da analiziraju ono što učenici znaju i koje su tehnike najučinkovitije za svakog učenika". Na taj način i učitelji mogu primjeniti nove tehnike i metode o svom obrazovnom radu. Dakle, osim što novi tipovi podataka mogu omogućiti personalizirano i uspješnije učenje, nove vrste podataka pomažu istraživačima da uče o učenju. Svi ti podaci dolaze iz online tečajeva ili drugih platformi za učenje temeljenih na tehnologiji.

Cope i Kanatzis [15] sugeriraju da su istraživači podijeljeni u pogledu na velike skupove podataka u obrazovanju na one koji ih prihvataju i na one koji ih kritiziraju. S jedne strane, tvrdi se da veliki podaci obećavaju učiteljima i učenicima novu eru personalizirane nastave, aktivnu pedagogiju i suradničko učenje. S druge strane, kritičari se brinu o pitanjima kao što su privatnost učenika ili učinak profiliranja učenika. Bez obzira na to je li orientacija optimistična ili ne, svi se slažu da su promjene značajne.

Velike skupove podataka u obrazovanju čine administrativni podaci i podaci o procesu učenja. Sampson [16] definira profil učenika kao skup atributa i njihovih vrijednosti koje mogu opisati učenika. Upravo ti atributi predstavljaju prethodno spomenute administrativne podatke i podatke o procesu učenja, a klasificira ih na sljedeći način:

- Statički podaci – odnose se na osobne i akademiske osobine učenika koji mogu ostati nepromijenjeni u velikim vremenskim razdobljima (dob, nacionalnost, postignute edukacije, prošlost akademskog uspjeha izvannastavne aktivnosti);
- Dinamičke podatke – odnose se na aktivnosti učenika tijekom procesa učenja i podložni su promjenama (angažiranost učenika u aktivnostima učenja, ponašanje učenika tijekom aktivnosti učenja, izvedba učenika)

Osim ove dvije klasifikacije, grupa autora [15] navodi kako vrlo važnu ulogu imaju podaci postignuća. Naime, sustavi za učenje i poučavanje često sadržavaju bogatu

riznicu podataka o učenikovim postignućima. Najčešće se tu nalaze ocjene koje su učenicima dodijeljene na temelju riješenih ispita ili završenih vježbi. Ova grupa podataka je „rizična“, jer bismo pri promatranju ocjene, također trebali promatrati težinu ispita, inače možemo doći do kontradiktornih rezultata. Veliki podaci mogu uključivati informacije o demografskim podacima, upisima, sustavu upravljanja učenjem, anketama, korištenju knjižnice, izvedbi učenika i vanjske skupove podataka [17].

4. NADZORNA PLOČA ANALITIKE UČENJA

Online okruženja za učenje nemaju istu strukturu podrške kao tradicionalne učionice i nedostaju mnogi motivirajući socijalni aspekti. Jedan od fokusa istraživanja analitike učenja je osnaživanje nastavnika i motivacija učenika kako bi donijeli informirane odluke o procesu učenja, uglavnom vizualizacijom prikupljenih podataka o učenicima putem nadzornih ploča [18]. Few [19] definira nadzornu ploču analitike učenja (NPAU) kao vizualni prikaz najvažnijih informacija potrebnih za postizanje jednog ili više ciljeva koje se nalaze na jednom mjestu. Nastavnici najčešće ne vide na koji način učenici komuniciraju sa sustavom za poučavanje, stoga im je potrebna povratna informacija kako bi poduzeli odgovarajuće akcije. Povratne informacije prezentirane preko NPAU se koriste kao moćan metakognitivni alat za učenike poticanjem na razmišljanje o aktivnostima i rezultatima učenja [20], a nastavnicima omogućuje stvoriti realnu sliku o učenicima i nastavnim materijalima.

U sljedećem poglavlju analizirani su prethodni pregledi literature vezane uz NPAU. U petom poglavlju opisana je metodologija istraživanja i uključivanja radova u pregled, a potom su prikazani rezultati istraživanja. U sedmom poglavlju predstavljen je podagoški okvir za povratne informacije u nadzornim pločama analitike učenja, te, konačno, u zaključku su dana bitna saznanja te smjernice za buduća istraživanje.

4.1. Prethodna istraživanja

Kronološki, prvi pregled nadzornih ploča analitike učenja daju Verbert i dr., 2013. godine [21], predstavljaju konceptualni model koji se sastoji od četiri elementa: samosvijest, refleksija, stvaranje osjećaja i utjecaj (eng. awareness, reflection, sense making, and behavioral change). Nadalje, autori su usporedili 15 nadzornih ploča prema korisnicima (nastavnicima, učenicima ili jednima i drugima), prikupljenim podatcima (potrošeno vrijeme, socijalne interakcije, broj pregledanih i korištenih resursa, rezultati ispita i kvizova) i vrednovanju (upotrebljivost, učinkovitost, korisnost eng. usability, usefulness effectiveness). Ovakva kategorizacija je dala smjernice za daljnja istraživanja. Stoga, 2014. godine Verbert, i dr., [22] nastavljaju prethodni rad i daju novu kategorizaciju nadzornih ploča analitike učenja: nadzorne ploče koje se koriste pri tradicionalnoj nastavi, nadzorne ploče koje se koriste pri grupnom radu i nadzorne ploče koje koriste sustavi za poučavanje na daljinu. Vrednovanje su dodatno proširili sa još jednom dimenzijom efikasnost eng. efficiency, a u obzir su uzeli i nadzorne ploče analitike

učenja korištene na laptopima, mobitelima i tabletima. Prethodno spomenutu kategoriju prikupljanja podataka su proširili koristeći mikrofone i senzore dubine.

Yoo i dr. [12] daju pregled 10 vodećih nadzornih ploča koje se spominju u znanstvenim časopisima i međunarodnim znanstvenim konferencijama. Autori prepoznaju kako trenutno postoji nedovoljno istraživanja o vrednovanju, stoga predstavljaju okvir za vrednovanje obrazovnih nadzornih ploča. Okvir je predstavljen sa četiri kategorije (reakcija, učenje, ponašanje i rezultati), a svaka od tih kategorija ima podkategorije.

Schwendimann i dr. 2017. godine [23] daju prvi sustavni pregled literature. Baze pregledavanja su ACM Digital Library, IEEE Xplore, SpringerLink, Science Direct, Wiley i Google Scholar. Ključne riječi pregleda su bile „dashboard“ i „learning analytics“ ili „educational data mining“ ili „educational datamining“. Pregledano je 55 radova, a rezultat je prikazan temeljem četiri kategorije: vrsta doprinosa (npr. teoretski prijedlog ili implementacija), kontekst učenja (npr. vrsta korisnika, razina obrazovanja ili pedagoški pristup), podaci (npr. svrha, izvori podataka ili vrste platformi) i vrednovanje. Najbitnija saznanja su da nadzorne ploče analitike učenja još uvijek slijede tradicionalnu paradigmu u kojoj nastavnik prati učenike. Autori navode kako postoji tendencija da se analitika učenja najviše koristi na fakultetima, ali da se očekuje porast ovog trenda u srednjoškolskom obrazovanju. Autori također navode kako se dvije trećine istraženih nadzornih ploča oslanja na podatke logiranja kao najbitnije podatke, a osim toga, 21 ploča (40%) se oslanja na nastavnike kao skupinu kojoj se prezentiraju podaci.

2017. godine, Bodily & Verbert [24] daju drugi sustavni pregled literature, a fokus čine sustavi koji nude povratnu informaciju učeniku (nadzorna ploča analitike učenja, sustavi za preporuku ili jednostavno bilo kakva poruka koja se temelji na analitici učenja). Rad se temelji na pregledu 93 rada koji su nastali pretragom sljedećih baza : ERIC, IEEE Xplore, ACM, Google Scholar i konferencija EDM i LAK . Autori su istraživali pet kategorija: funkcionalnost (prednosti sustava), izvore podataka (definirati koji se podaci prikupljaju, analiziraju i prikazuju učenicima, analiza dizajna (dizajn koji bi se trebao napraviti prije testiranja ili provedbe sustava izvješćivanja), percepcije učenika (percepcije učenika na sustave izvješćivanja) i mjereni učinak (učinak koji sustav ostavlja na učenika).

U nastavku je bitno povezati dva rada istih autora [25] i [26]. U prvom radu autori su definirali šest kategorija (kognitivizam, konstruktivizam, humanizam, opisni modeli, nastavni dizajn i psihologija). U drugom radu obrađeno je 53 rada, te su istražili u kojoj su mjeri teorije učenja integrirane u razvoj nadzornih ploča analitike učenja. Definirano je šest razina: metakognitivna, kognitivna, razina ponašanja, emocionalna razina, samoregulacija i upotrebljivost alata.

Posljednji rad koji predstavlja pregled literature je iz 2019. godine. Matcha, Gasevic, Ahmad Uzir, & Pardon [27] navode kako je glavna kritika literature nedostatak teorijskog uporišta pri izgradnji nadzornih ploča analitike

učenja. U radu je definiran model za sustave učenja koji je usmjeren na učenje i na korisnike, a sastoje se od četiri dimenzije: teorija, dizajn, povratna informacija i vrednovanje. Definirana su četiri identifikatora samoreguliranog učenja: identifikacija zadatka (razvijanje percepcije kao riješiti zadatak), postavljanje ciljeva i planiranje (postavljanje strategija učenja i ciljeva), provedba strategija učenja(većina aktivnosti prilikom učenja ovisi o ovoj fazi) i adaptacija (opisuje ponašanje učenika na temelju izvedbe metakognitivnog praćenja i kontrole).

5. METODOLOGIJA ISTRAŽIVANJA

Fokus ovog rada je detaljnije ispitati kako nadzorna ploča utječe na učenike i nastavnike u obrazovnom procesu, a kako bi dobili odgovore na tražena pitanja, napravljen je pregled literature. U ovom dijelu rada prikazat će se postavljena istraživačka pitanja, strategija pretraživanja relevantne literature, kriteriji inkluzije i ekskluzije, analiza odabranih radova te sinteza.

5.1. Istraživačka pitanja

Chatti i sur. [12] predstavljaju referentni model u kojem navode kako analitika učenja ima nekoliko vrsta korisnika (učenike, učitelje, oblikovatelje nastavnih sadržaja, istraživače i znanstvenike). No, u ovom radu ćemo se koncentrirati samo na dva tipa korisnika (učenike i nastavnike). Stoga se postavlja istraživačko pitanje:

„**Kako nadzorna ploča analitike učenja utječe na usvojenost ishoda učenja kod učenika, uvid u usvojenost ishoda učenja kod nastavnika, te koje metode i tehnike omogućavaju prethodno navedeno?**“ Drugo istraživačko pitanje se odnosi na povratne informacije koje podupiru proces učenja i poučavanja i glasi:

„**Kako povratna informacija, koju nastavnici i učenici dobivaju kroz nadzornu ploču analitike učenja, podupire proces učenja, poučavanja i testiranja znanja, te usvojenost ishoda učenja?**“

Slade i Prinsloo [28], Swenson [29] zaključuju kako se primjena analitike učenja događa bržim tempom od razmatranja etičkih pitanja koja se odnose na njihovu upotrebu. Na temelju toga postavlja se treće istraživačko pitanje:

„**Koje su etičke implikacije uvođenja nadzornih ploča analitike učenja u obrazovni proces?**“

5.2. Strategija pretraživanja

U ovom dijelu prikazan je postupak generiranja ključnih riječi za pregled literature, strategija pretraživanja, pregled pretraživanih baza i i dokumentacije pretraživanja. Cilj ovog istraživanja je prikupiti i pretražiti relevantne članke kako bi se identificiralo što se događa u polju analitike učenja s naglaskom na postavljena istraživačka pitanja.

5.2.1 Ključne riječi

Fokus ovog rada je ispitati kako je nadzorna ploča analitike učenja korištena u području obrazovnog procesa. Dashboard je relativno novi pojam, pa se smatra kako znanstvenici umjesto dashboard, često koriste pojam alat, stoga se proširuje pojam pretrage sa „tool“. Ključne riječi pretrage su:

„learning analytics dashboard“
„learning analytics tool“

5.2.2 Pregled literature

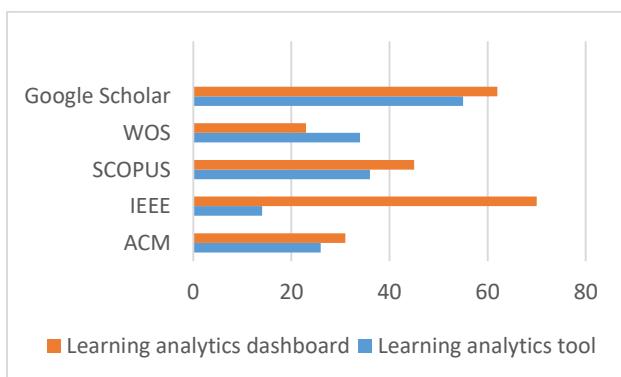
Baze Acm Digital Library, IEEE, Scopus, Google Scholar, Web of Science i konferencije LAK su odabrane za pregled literature. Baze Google Scholar, Scopus i Wos su pregledane koristeći besplatni alat „Publish or perish 7“. Prilikom pretraživanja svih baza, postavljena su vremenska ograničenja. Godina 2011. se uzima kao relevantna godina jer je te godine bila prva konferencija LAK, stoga je vremensko ograničenje bilo od 2011.-2019. godine.

5.3. Postupak odabira

U ovom dijelu rada prikazat ćemo način odabira relevantne literature. Nakon odabira, identifikacija radova bitnih za ovo istraživanje je provedena kroz nekoliko faza.

5.3.1 Postupak odabira relevantne literature

Pretragom ACM baze pronađeno je 57 rezultata, IEEE 84 rezultata, SCOPUS 81 rezultat, WoS 57 rezultata, Google Scholar, 117 rezultata. Slika 3 prikazuje rezultate pretraživanja prema ključnim riječima. Ukupno je identificirano 396 radova.



Slika 2 Broj pregledanih radova po bazama

Pretraživanjem zbornika radova konferencije LAK pregledani su radovi od 2011-2019 godine, a isključili smo Radionice, Panele, Postere i Demos (Tablica 1). Na taj način je identificirano 460 radova.

5.3.2 Kriteriji inkluzije

Fokus istraživanja je nadzorna ploča ili bilo kakav alat koji ima funkciju povratne informacije učenicima ili nastavnicima. Stoga u obzir ulaze svi radovi u kojima je definiran bilo kakav sustav koji nudi povratnu informaciju. Nadalje, želi se provjeriti u kojoj mjeri takvi sustavi pomažu u obrazovne svrhe, stoga u obzir ulaze svi alati u kojima imamo vrednovanje ovakvih sustava od strane učenika ili nastavnika. Budući da ovakvi sustavi koriste brojne podatke koji se mogu klasificirati kao privatni podaci učenika, cilj je ispitati na koji način su poštivana pravila privatnosti pri korištenju ovakvih sustava. U obzir ulaze alati koji su ovim pregledom pronađeni, bez obzira jesu li korišteni u prethodnim pregledima literature, jer se želi ispitati da li ima razlike u korištenju podataka u analitičke svrhe u razdoblju od 2011.-2019. godine.

Tablica 1. Kriteriji inkluzije / ekskluzije

Inkluzija	Ekskluzija
<ul style="list-style-type: none">Radovi koji predstavljaju sustav u kojem je prikazan način korištenja analitike učenja u vidu povratne informacijeRadovi u kojima je prikazano vrednovanje takvih sustava	<ul style="list-style-type: none">Radovi koji nisu na engleskom jezikuRadionice, Paneli, Posteri, DemosRadovi koji se odnose na korištenje analitike učenja osim u svrhu edukacijeKnjige ili dijelovi knjige

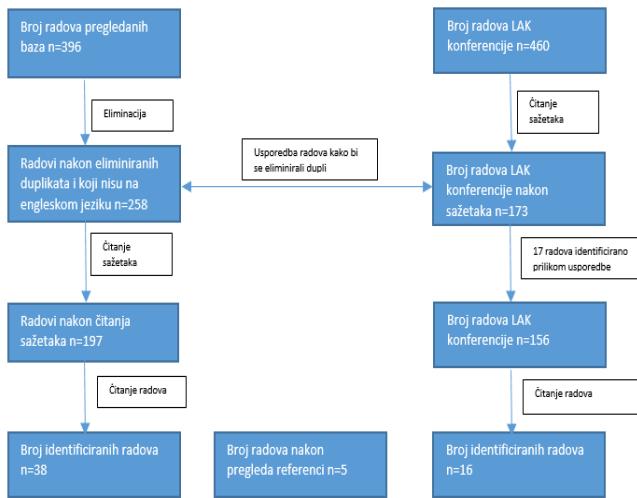
5.3.3. Faza pregledavanja radova

Očekivano je kako imamo istih radova među bazama, stoga je proveden postupak odbacivanja duplih radova, nakon čega je ostalo 264 rada. Šest radova nije bilo na engleskom jeziku pa su i oni odbačeni. Konačno, ostaje 258 radova koji ulaze u uži izbor. Na temelju čitanja sažetaka, odbacili smo radove koje smatramo nepotrebним za ovaj pregled literature, stoga u uži izbor ulazi 197 radova. Svaki od preostalih radova je pročitan i na temelju inkluzije u pregled ulazi 38 radova.

Pročitani su sažeci svih 460 radova s konferencije LAK 2011-2019 i među njima odabранo 173 rada koja će biti pregledana. Prije pregledavanja cijelog rada, popis ćemo usporediti sa popisom radova pregledanih baza kako bi vidjeli ima li radova koji se preklapaju. Identificirano je 17 radova, koje smo također odbacili, stoga ostaje 156 radova. Preostale radove pregledavamo u cijelosti, te na taj način izdvajamo 16 radova.

U idućoj fazi, pregledane su reference identificiranih radova. Na taj način smo pronašli 48 alata koji su navedeni u literaturi. Pregledom radova, pronašli smo 5 alata, [30], [31], [32], [33] i [34] koji odgovaraju postavljenim kriterijima koji su također uključeni u pregled literature. Dva rada [35] i [36] su naknadno dodana u pregled jer predstavljaju alat korišten u nastavi u vidu povratne informacije učenicima ili nastavnicima.

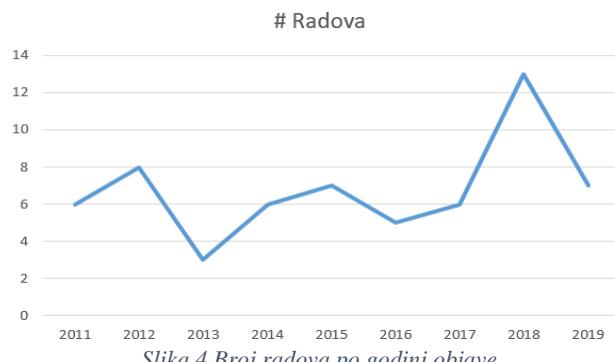
Na sljedećoj slici (Slika 3) prikazan je skraćeni pregled odabira literature koji je proveden kroz sve tri faze.



Slika 3 Pretraga radova

5.4. Pregled odabrane literature

Pregledom traženih baza i zbornika radova s konferencija identificiran je 61 rad. Sljedeći graf prikazuje broj odabranih radova obzirom na godinu objavljivanja rada.



Slika 4 Broj radova po godini objave

Kako bi odgovorili na postavljena istraživačka pitanja, izdvojili smo bitne karakteristike i prikazali ih u tablici (Tablica 2). Željeli smo odgovoriti na 4 pitanja (Što prikupljati? Kako prikupljati? Tko su korisnici? Zašto prikupljati?). Praćene karakteristike odnose se na korištene vrste podataka. Pratili smo sedam vrsta podataka: **statični podaci, podaci logiranja, podatke korištenja nastavnih materijala i postignuća, podatke društvenih mreža, vremenske podatke, psihologische podatke i povijesne podatke**. Statični podaci odnose se na podatke koji su nepromjenjivi u određenom vremenskom razdoblju (npr. ime, id, ...). Podaci logiranja predstavljaju broj logiranja na sustav. Korištenje nastavnih materijala i postignuća odnose se na broj korištenih resursa i uspjeh učenika (npr. koji resursi su najviše korišteni, ocjena na ispit...). Podaci društvenih mreža odnose se na korištenje foruma ili twitera (npr. broj

poruka upućen ostalim korisnicima društvenih mreža, pozitivne/negativne poruke ...). Vremenski podaci se odnose na bilo kakav vremenski period koji je praćen (npr. vrijeme potrošeno za pregled resursa, vrijeme potrošeno na ispit...). Psihologički podaci se odnose na podatke u kojima se prikazuje stanje učenika (npr. emocije). Povijesni podaci se odnose na prethodna postignuća i ponašanja učenika, najčešće kako bi stvorili prediktivni model (npr. uspjeh u prethodnom razredu). Karakteristika Korisnici sustava se odnosi na tipove korisnika (nastavnici ili učenici). Karakteristika Privatnost podataka odnosi se na bilo kakav način u kojem je spomenuto da su korisnici sustava obaviješteni o privatnosti podataka. Vrednovanje sustava se odnosi na vrednovanje od strane nastavnika ili učenika, a osim toga, zanimalo nas je na koji način su vrednovani ovakvi sustavi (npr. upitnik, eksperiment,...). Nadalje, pratili smo povratnu informaciju koja je prezentirana korisnicima sustava. Zanima nas način na koji je prezentirana povratna informacija (Obavijest, Vizualizacija ili Tekst). Unutar karakteristike Vizualizacija pratili smo način prikazivanja podataka različitim grafovima (stupčasti grafikon, linijski grafikon, tortni grafikon, trakasti grafikon, površinski grafikon, raspršeni grafikon, ostali, histogram). Analitika učenja koristi metode rudarenja podataka ili strojnog učenja, stoga nas zanima u kojoj mjeri su korištene metode rudarenja podataka ili strojnog učenja pri analizi podataka.

Tablica 2 Izdvojene karakteristike

Radovi		Pri vat nos t	Podaci						Korisnici sustava			Vrednovanje			Povratna informacija							Tehnike Rudarenje podataka			
Naziv i Id	Godi na		S	L	Pn m	D	V	P s	Po v	N	U	En	Eu	Tip	O b av	S	L	T	T r	P o	R	O	H		
ALAS-KA [37]	2014	-	*	*	*	-	*	-	-	*	*	-	-	-	*	*	*	*	*	*	-	*	-	-	
LATeS [38]	2019	-	*	-	-	*	*	-	-	-	*	-	95555	/	-	-	*	*	*	*	-	-	*	-	
Moodle plugin in [39]	2016	-	-	-	*	*	*	*	-	*	*	-	30		Upitnik	-	-	*	*	-	*	-	*	-	
[40]	2016	-	-	-	-	*	-	-	-	*	-	-	-		-	-	*	-	-	*	-	*	-		
Moodle plugin in [41]	2018	-	*	*	*	-	-	-	-	*	*	-	290		*	-	*	*	-	-	-	-	*	-	
CloudTrail-Tracker [42]	2019	-	-	-	*	-	*	-	-	*	*	-	64		Upitnik	-	*	*	*	-	-	*	-	-	
AMBA [43]	2018	*	-	*	*	*	*	*	-	*	*	-	86		Eksperiment	-	*	-	-	-	-	-	*	-	
SCALA [44]	2014	*	*	-	*	*	-	-	-	*	*				-	-	*	-	-	*	-	*	*	-	
ANALYSE [45]	2016	-	-	*	*	-	*	-	-	*	*	-	-	-	-	*	*	-	*	*	-	*	*	-	
MyScores [46]	2018	*	-	-	*	-	-	-	-	*	*	-	-	1905	/	*	-	-	-	-	-	*	*	-	
Moodle plugin in [47]	2018	*	*	*	*	-	*	-	-	*		-	-	-	*	/	/	/	/	/	/	/	/	*	
TUT Circle [48]	2014	-	-	*	-	*	-	-	-	*	-	-	27	-	upitnik	-	-	-	*	-	-	*	*	-	
LAViEW [49]	2019	*	*	*	*	-	*	-	-	*	*	-	-	-	*	*	-	*	-	*	-	*	*	-	
LOOP [50]	2015	-	-	-	*	*	*	-	-	*	-	-	-	-	-	-	*	*	-	*	-	*	-	-	
SLAR [51]	2015	-	-	-	*	*	*	-	-	*	-	-	-	-	-	-	*	*	-	-	-	*	-	-	
Content recommender Skills recomender [5]	2018	*	-	-	*	-	*	-	-	*					*	*	*	*	*	*	*	*	*	*	-
VISIR [52]	2019	*	-	*	*	-	*	-	-	*	-	-	-	-	-	*	-	-	-	-	*	*	-	-	
Moodle plugin in [53]	2017	-	-	*	*	-	*	-	-	/	/				*	*	-	*	-	-	-	*	-	*	
edIX-MAS [54]	2018	-	*	*	*	*	*	-	-	/	/	-	-	-	-	-	-	-	-	-	-	*	-	*	
QMCU [55]	2013	*	*	-	*	-	*	-	-	*		-	51		upitnik	-	*	-	-	-	-	-	-	-	
PredictCS [56]	2018	-	*	*	*	*	-	*	-	*	*				*	-	-	-	-	-	-	*	-	*	
[57]	2015	-	-	-	*	*	*	*	-	*	-	*	-	-	-	*	*	-	-	*	-	*	-	*	
WPLA [58]	2018	*	/						*	*	3	5		upitnik	-							*	*	*	-
SoftLearn [59]	2014	-	-	*	*	*	*	*	-	*	*	2	72		eksp	-	-	-	-	-	-	*	-	*	-
TEA [60]	2016	-	/						*	*	*	*			upitnik	-	*	-	-	-	-	*	-	*	-
LATUX [61]	2015	-	-	-	-	-	-	*	-	*	-	*			iterativ	-	-	-	*	-	-	*	-	-	-
LISSA [62]	2017	-	*	-	*	-	*	-	*	-	*				upitnik	-	-	*	-	-	-	*	*	-	*
[63]	2019	-	/						*	-	*	-			upitnik	-						*	*	-	*
AAT-Moodle [64]	2011	-	-	*	*	*	*	*	-	*	-					-	-	-	-	-	-	-	*	-	
Grockit [65]	2011	-	-	-	*	-	*	-	-	*	*	-	-	-	*	-	-	-	-	-	-	-	*	-	
SNAPP [66]	2011	-	*	-	-	*	-	*	-	*	-	-	-	-		-	-	-	-	-	-	*	-	-	
Course Signals [67]	2012	-	*	-	*	-	-	-	*	-	*	-	1500		upitnik	*	-	-	-	-	-	-	*	-	*
GLASS [68]	2012	-	-	*	*	-	*	-	*	-	*	-	-	-		-	*	*	-	-	-	-	*	-	
[69]	2012	*	*	*	-	*	*	-	-	*	-	*	-	*	iterativ	upitnik	-	*	*	-	-	*	-	*	-
Learn-B [70]	2012	-	*	*	*	*	*	*	-	*	-	-			upitnik	-	*	*	-	-	-	-	*	-	*
S3 [71]	2012	-	*	*	*	*	*	*	-	*	*	-			upitnik	-	*	-	-	-	-	*	-	*	*
StepUp! [72]	2013	-	*	*	*	*	*	*	-	*	*	-			upitnik	-	*	*	-	-	-	-	*	-	*
GradeCraft [73]	2013	-	*	*	*	*	-	*	-	*	*	*				-	*	*	-	-	*	-	*	-	
EWS [74]	2014	*	*	*	*	-	*	-	-	*	*	-			upitnik	-	*	*	-	-	-	-	*	-	*
RIDT [75]	2016	*	*	*	*	*	*	*	-	*	*	*	-		Upitnik	-	*	-	-	-	-	-	*	-	*
EMODA [76]	2017	-	-	-	-	-	-	*	-	*	-	*	2	-	upitnik	-	*	*	*	-	-	*	-	-	
OUA [77]	2017	-	*	*	*	-	-	-	-	*	-	*			upitnik	-	-	-	-	-	-	*	-	*	
LAPLE – moodle plug in [78]	2017	-	*	*	*	*	-	*	-	*	*	-				-	*	*	-	-	-	*	*	-	
[79]	2018	-	-	*	-	-	-	-	*	*	*	-				-	*	*	-	-	-	*	*	-	
[80]	2019	*	*	*	*	-	*	-	*	-	*	-				-	*	*	-	-	-	*	*	-	
eLAT [81]	2011	*	-	*	*	*	*	*	-	*	-	*	8			intervju	-	*	*	-	-	-	-	*	-
LOCO-Analyst [82]	2012	-	*	*	*	*	*	*	-	*	*	-			upitnik, interview	-	*	*	-	-	-	-	*	-	
TrAVis [30]	2011	-	-	-	*	*	-	-	-	*	*	-			intervju	-	-	-	-	-	-	*	-	*	
SAM [31]	2012	*	*	*	*	*	*	*	-	*	*	*			iterativno	-	*	*	*	-	-	*	*	*	-
Moodle plugin in [32]	2012	-	*	*	*	*	*	*	-	*	-	-				-	-	-	-	-	-	*	*	*	-

Moodle plugin [33]	2011	-	*	*	*	*	*	*	-	*	-	-	-	-	*	-	*	-
VisMOOC [83]	2015	-	*	*	*	*	*	*	-	-	*	-	-	-	-	*	-	-
MoodleMiner [35]	2019	-	*	*	*	*	*	*	-	-	*	-	-	-	-	-	-	*
DDART [84]	2014	-	-	*	*	*	*	*	-	-	*	-	-	-	*	*	-	-
PROTUS [85]	2018	-	-	*	*	*	-	*	-	-	*	*	10	55	Focus group/questionnaire	-	*	-
SST [34]	2015	-	-	*	*	*	*	*	-	-	*	-	-	-	-	*	-	-
SCELE-Moodle [86]	2018	*	*	-	*	-	*	-	-	*	*	*	*	*	upitnik	-	*	-
LADA [87]	2018	*	-	*	*	-	*	-	*	*	*	-	mix	-	User study/questionnaire/think aloud	-	*	-
[88]	2018	*	*	-	-	*	*	*	-	-	*	-	-	-	-	*	-	*
LAPA [89]	2015	*	-	*	*	-	*	-	-	-	*	-	*37 *22	Eksperiment upitnik	-	*	-	-
CM Tutor Dashboard [36]	2017	-	-	*	*	-	*	-	-	*	*	-	*	*	Upitnik	-	*	-

Legenda: Podaci (S-statični podaci, L-log podaci, Pnm-podaci postignuća i korištenja nastavnog materijala, D- podaci društvenih mreža, V-vremenski podaci, Ps-psihologički podaci,Pov – povijesni podaci), Korisnici (N-nastavnici, U-učenici) Vrednovanje (En-evaluacija nastavnika, Eu-evaluacija učenika, Tip-tip evaluacije, Obav – obavijesti sustava, S-stupčasti grafikon, L-Linijski grafikon, T-tortni grafikon, Tr-trakasti grafikon, Po-površinski grafikon, R-raspšreni grafikon, O-ostali , H-histogram), / -nije navedeno

6. REZULTATI

U ovom dijelu rada predstaviti ćemo rezultate istraživanja. Ovaj dio rada možemo podijeliti na sljedeća poglavlja: Korisnici sustava, Podaci, Metode pristupa izradi NPAU Ciljevi razvoja NPAU, Povratna informacija i Privatnost podataka.

6.1. Korisnici sustava

Na samom početku smo definirali kako korisnici ovakvih sustava mogu biti nastavnici i učenici. Tri rada [87], [74], [62] su kao korisnike sustava naveli savjetnike (eng. Advisors), koji su uglavnom profesori, stoga smo i te radove uzeli u obzir. Sljedeća tablica prikazuje korisnike sustava. Dva rada nisu navela korisnike sustava.

Korisnici sustava	Broj radova	Postotak
Nastavnici	26	44%
Nastavnici i učenici	24	41%
Učenici	9	15%

Trenutno ostaje dojam kako NPAU ima za cilj izvijestiti nastavnike o znanju i napretku učenika. Samo 9 (15%) NPAU je orijentirano konkretno učenicima, dok je 26 (44%) NPAU orijentirano isključivo nastavnicima. 24 (41%) NPAU kao korisnike sustava navode i nastavnike i učenike.

6.2. Podaci

Kategorija podaci odnosi se na podatke koji su prikupljani.U ovom pregledu identificirano je nekoliko vrsta podataka koje su praćene: statični podaci, podaci logiranja, podaci korištenja nastavnog materijala i postignuća, podaci društvenih mreža, vremenski podaci, psihologički podaci i povijesni podaci. Tri rada [58], [60] i [63] nisu navela koje podatke su koristili, stoga njih nećemo

uzeti u analizu. Sljedeća tablica (Tablica 3) prikazuje podatke korištene u literaturi.

Vrsta podatka	Broj radova	Postotak
Korištenje nastavnih materijala i postignuća	50	86.2%
Vremenski podaci	46	79.3 %
Log podaci	37	65.5 %
Statični	30	51.7%
Podaci društvenih mreža	28	48.27 %
Povijesni podaci	6	10.3%
Psihološki podaci	3	5.17 %

Tablica 3 Podaci korišteni u literaturi prema broju korištenja

U najvećoj mjeri se koriste podaci korištenja nastavnog materijala i postignuća učenika 50 (**86.2%**), potom vremenski podaci 46 (**79.3 %**), a zatim podaci logiranja 37 (**65.5 %**). S druge strane, autori najmanje koriste psihologičke podatke 3 (5.17 %) i povijesne podatke 6 (10.3%) u analizi ponašanja učenika.

Tablica 4 prikazuje korištenje podataka po godinama objave rada. Korišteni podaci su grupirani u skupine po godinama objavljanja, a potom smo prebrojili korištenje podataka za svaku godinu. Budući da se razlikuje broj radova po godinama, izračunali smo aritmetičku sredinu za svaki podatak kako bi usporedili postoji li razlika u korištenju podataka u kronološkom smjeru..

Godina	Statični	Log	KNM i P	Podataci dr. mreža	Vremenjski	Psih.	Povijesni
2011	0.33	0.5	0.83	0.83	0.67	0.17	0.17
2012	0.88	0.88	0.88	0.63	0.88	0	0.13
2013	1	0.67	1	0.33	1	0	0
2014	0.5	0.83	0.83	0.67	0.67	0	0
2015	0.14	0.43	0.86	0.71	0.86	0.14	
2016	0.25	0.5	0.75	0.75	0.75	0	0
2017	0.5	0.67	0.83	0	0.67	0	0.5
2018	0.5	0.58	0.92	0.25	0.75	0	0.25
2019	0.67	0.67	0.83	0.33	1	0	0.17

Tablica 4 Kronološki pregled korištenja podataka

Iz prethodne tablice, jasno je kako autori impliciraju da učenje najviše ovisi o korištenju nastavnog materijala i postignuća učenika. Zanimljivo je vidjeti kako se u početnim godinama istraživanja, koristilo podatke društvenih mreža u većoj mjeri nego u posljednjim godinama. Godine 2017. niti jedan rad nije koristio podatke društvenih mreža, a u posljednje dvije godine se vidi znatna razlika u korištenju tih podataka. S druge strane, povjesni podaci učenika se koriste u posljednje tri godine u znatno većoj mjeri nego u prethodnim godinama. Budući su povjesni podaci direktno vezani uz predikciju, možemo zaključiti kako se u posljednje vrijeme osim vizualizacije koristi predikcija u sve većem opsegu. Vremenski podaci i podaci logiranja čine zlatnu sredinu.

Siemens [90] kao najveći problem predstavlja poznavanje opsega i kvalitete podataka. Jedno od pitanja analitike učenja je koliko podataka treba prikupiti i koliko različiti ti podaci trebaju biti. Ta pitanja se odnose na opseg podataka. Kvaliteta podataka se odnosi na pouzdanost podataka. Učenje predstavlja složen proces u kojem moramo uzeti u obzir mnoge varijable i stoga možemo zaključiti kako brojenje klika mišem nije dovoljno [91] ili kako brojenje podataka nije dovoljno [92].

Prema u zajednici analitike učenja ne postoji konsenzus o tome koji su podaci o ponašanju i interakcijama korisnika prikladni za mjerjenje, razumijevanje i modeliranje procesa učenja, poučavanja i testiranja znanja kao i njegovog učinka..

Gašević i sur. [93] navode kako modeli analitike učenja ne mogu odgovarati svima jednak i kao takvi ne mogu prikupljati opće podatke. Trebalo bi se usredotočiti na određene opsege visoke kvalitete podataka kako bi bolje razumjeli proces učenja i poučavanja.

6.3. Metode pristupa izradi NPAU

U nastavku ćemo objasniti koje metode pristupa se koriste od strane autora kako bi se NPAU učinili boljima i konkretnijima. Pri izradi NPAU najbitnije je imati na umu tko su korisnici sustava i koje mogućnosti ovakav sustav pruža. Istim se dva pristupa. Prvi, koji analizira postojeće nadzorne ploče, te njihovim pregledom identificira ideje i probleme (16.3%). Npr. [89] daje pregled 15 postojećih nadzornih ploča, i na temelju toga prepoznaje nedostatke i pristupa stvaranju NPAU. U drugom pristupu, dio autora [5], [61], [62], [63], [69], [65], [79], [80], [31], [81], [82], [83], [87], [88] stvara NPAU za učenike i nastavnike uzimajući njihove potrebe u obzir. Taj pristup se zove „dizajn usmjeren na korisnika“ (eng. User-centered design). U obzir uzima potrebe korisnika i prilagođava sustav smjernicama koje dobije kao povratnu informaciju kroz nekoliko provedenih iteracija sustava. Quincey i dr. [80] naglašavaju da bi oblik personalizacije analitike učenja koristeći dizajn usmjeren na korsnika mogao motivirati učenike i utjecati na njihovo učenje. Ključna je poruka da rad sa učenicima na stvaranju sustava analitike učenja, rezultira personaliziranjem i potencijalno privlačnijim oblikom sustava analitike učenja. Potrebno je poboljšati proces upotrebe dizajna usmjeren na korisnike, ne samo u početnim zahtjevima već u svim fazama razvoja alata analitike učenja Ostali autori nisu spomenuli način na koji su pristupali izradi.

6.4. Ciljevi razvoja NPAU

U ovom poglavlju definirat ćemo ciljeve razvoja NPAU. Stoga smo izdvojili dijelove radova u kojima se eksplicitno opisuje cilj razvoja NPAU. Identificirali smo 11 ciljeva, jedan alat može imati više ciljeva ako je navedeno (Tablica 5).

Tablica 5 Ciljevi razvoja nadzorne ploče analitike učenja

Cilj	Radovi	Broj radova	Postotak
Praćenje i podrška	[42], [44], [48], [51], [5], [53], [63], [82], [87], [36], [89], [57], [73], [76], [88], [74], [80], [37]	18	29.5 %
Vizualizacija	[39], [45], [49], [50], [53], [60], [62], [66], [68], [79], [84], [85], [86], [37]	14	22.95 %
Metakognitivno poimanje	[46], [55], [59], [61], [69], [70], [72], [81], [30], [31], [84], [36]	12	19.67 %
Predikcija	[41], [54], [56], [67], [71], [77], [79], [80], [32], [87], [35]	11	18.03 %
Analiza	[38], [39], [49], [64], [65], [66], [83], [84], [52], [35]	10	16.39 %
Personalizacija	[46], [56], [73], [75], [85]	5	8.19 %
Detekcija /identifikacija	[47], [78]	2	3.27 %
Komunikacija i dijalog	[62], [79]	2	3.27 %
Grupiranje	[32], [34],	2	3.27 %
Usporedba	[33]	1	1.64 %
Analitika u radnom okruženju	[58]	1	1.64 %

6.4.1 Praćenje i podrška

U najvećem broju ciljevi razvoja se odnose na Praćenje i podršku. Praćenje je dimenzija koja se odnosi na proces učenja i poučavanja. Kao takva odnosi se direktno na praćenje učenikova angažmana, korištenja sustava, prisutnosti, aktivnosti, emocija, te podataka društvenih mreža. Podrška se odnosi na proces odlučivanja u kojem se u prvom redu nastavnicima, a potom i učenicima olakšava donošenje odluka, potporu učenju i izvedbu učenja.

6.4.2. Vizualizacija

Vizualizacija je drugi cilj koji je najviše naveden. Povratna informacija u vidu vizualizacije djeluje jako dobro na učenike i na nastavnike. S druge strane, statistički podaci u obliku tablica i izvještaja nisu uvijek laki za razumijevanje korisnicima obrazovnog sustava.

Vizualizacije imaju za cilj podržati praćenje aktivnosti učenika i donošenje odluka učenika i nastavnika iz obrazovnog sustava. Svi sudionici imaju različite potrebe i sposobnosti, stoga je jako teško s jednom vizualizacijom

riješiti sve probleme. Izvještavanje o obrazovanju i vizualizacija obrazovnih podataka mogu imati različite oblike i često prikazuju sve, od ocjene, aktivnosti učenika, različitih interakcija učenika, pa sve do emocija.

Ako se učenicima omogući pristup ovim izvješćima, daju im se povratne informacije o njihovim aktivnostima učenja, performansama ili znanju. Također može pomoći učenicima da ispune svoje obrazovne ciljeve podržavajući njihovo promišljanje i odlučivanje

Prepoznavajući snagu vizualnog predstavljanja, tradicionalna izvješća koja se temelje na tablicama podataka sve se više zamjenjuju nadzornim pločama koje grafički prikazuju različite pokazatelje performansi [12].

6.4.3. Metakognitivno poimanje

Iako se većina nadzornih ploča i povratne informacije temelje samo na pokazateljima uspješnosti učenika, istraživanje pokazuje da se djelotvorne povratne informacije moraju temeljiti i na regulatornim mehanizmima na kojima počivaju procesi učenja i na svjesnosti učenika o ciljevima učenja [94]. Nadzorne ploče su instrumenti namijenjeni poboljšanju odlučivanja pojačavanjem ili usmjeravanjem spoznaje i iskorištanjem ljudskih percepcijskih sposobnosti. Učenje je kompleksno, a dozu kompleksnosti proširuju i velike razlike među učenicima. Metakognicija kao cilj u ovom radu ima nekoliko kategorija. Poticanje refleksije učenika o njihovim uspjehu [46], [69], [72], [81], samovijest o napretku i učenikovu stanju [55], [61], [31], samoregulacija kao analiza i procjena vlastitih aktivnosti [59], [70], [30], [31] dok [36] navode kako je cilj njihove NPAU povećanje motivacije, a [84] kao cilj podršku metakognitivnim strategijama.

Ideja korištenja analitike za učenje kao dio ciklusa refleksivne prakse u mnogočemu je slična pojmu samoreguliranog učenja [95]. S reguliranog gledišta učenja, metakognitivno praćenje omogućava učenicima da prilagode ili promijene svoje ciljeve, planove ili strategije za učenje [94]. Analitika učenja ima potencijal pomoći u rješavanju izazova pružanjem podrške učenicima kao i definiranjem što treba nadzirati u obrazovnom procesu. Pored toga, učenici često još uvijek trebaju pomoći u određivanju što promijeniti.

Roll i Winne [96] napominju kako analitika učenja može igrati neizmjerno važnu ulogu za učenike i za teorije učenja. Podaci analitike učenja opisuju značajke i faktore koji utječu na samoregulirano učenje. Na sjecištu analitike učenja i samoreguliranog učenja, pruža se mogućnost istraživanja u svrhu boljeg obrazovanja, no, još uvijek postoje nesigurnosti kada, kako i što uvesti kao analitiku za praćenje učenika radi lakšeg učenja.

6.4.4. Predikcija

Predviđanje uspjeha učenika jedan je od najčešćih ciljeva istraživanja u polju analitike učenja [97]. U ovom pregledu, 11 radova je navelo predikciju kao jedan od ciljeva razvoja NPAU. Prepoznali smo šest kategorija predikcije. Predikcija odustajanja predstavlja jedan od podciljeva izrade NPAU [54]. [56], [71], [77] razvijaju

modele predviđanja rizičnih skupina učenika (učenici koji su skloni odustajanju ili učenici koji imaju malu vjerojatnost uspjeha na ispitu) kako bi intervenirali na vrijeme u svrhu poboljšanja njihova statusa. U nekim zemljama EU između 20% i 54% studenata ne uspije završiti studij, a kod obrazovanja na daljinu postotak studenata koji ne završe tečaj je oko 78%, a u MOOC-ima je više od 93% [77]. Uspjeh učenika je sljedeća kategorija predviđanja [67], [32], [80], [41] predviđaju ocjenu, a [79] predviđaju trajanje studiranja.

Mnogi faktori utječu na učenje stoga se postavlja pitanje, koje varijable uzeti u obzir pri predviđanju nekog od postavljenih podciljeva. Ako uspijemo predvidjeti određeni podcilj, moramo se pitati u kojim uvjetima predikcija ima smisla. Essa i Ayad [71] sugeriraju kako ne možemo jednostavno pretpostaviti da prediktivni model razvijen za određenu grupu učenika i za određenu obrazovnu instituciju ima jednaku vrijednost za drugu grupu učenika u drugoj obrazovnoj instituciji.

6.4.5. Analiza

Analiza je cilj kojeg je navelo 10 radova kao cilj razvoja NPAU. Analiza forum podataka [38], [66], analiza podataka o ponašanju, aktivnosti i uspjehu učenika [64], [65], [84], analiza laboratorijskih vježbi [52] su dimenzije navedene kao ciljevi razvoja. Ispitivanje načina na koji učenici koriste sustav učenja i analiziranje uspjeha učenika mogu pomoći učiteljima u otkrivanju obrazaca i odlučivanju o budućem dizajnu aktivnosti učenja [12].

6.4.6. Personalizacija

Prilagodba nastavnih materijala, stilova učenja pa čak i povratne informacije djeluje različito na učenike. Kako bismo u potpunosti uspjeli u postupku personalizacije, moramo na umu imati potrebe učenika. Dva tipa personalizacije su prepoznata u ovom radu. Prvi tip je personalizacija koja se odnosi na cijeli proces učenja i poučavanja u kojem sustav prilagođava materijale i sadržaj za učenje svakom učeniku, a korisnici mogu poništiti odabir personalizacije [85]. Drugi tip personalizacija se odnosi na povratnu informaciju koja je prezentirana svakom učeniku posebno, na temelju tjednih predikcija [56], te pruža preporuku učeniku kako unaprijediti proces učenja. [75] pruža poseban tip personalizacije u kojem korisnici sustava, u okvirima analitike učenja, sami postavljaju ciljeve, pitanja i sami određuju pokazatelje koji će im pomoći da ostvare svoje ciljeve. GradeCraft [73] pruža učenicima personalizirano iskustvo učenja, temeljeno na igrama. MyScores [46] pruža personalizaciju u obliku adaptacije sustava različitim programima i situacijama. Konkretno, ovaj tip personalizacije se odnosi na rezultate prvog ispita, a autori ističu kako je ključni izazov slijediti personalizirani i ciljano usmjereni model analitike učenja koji se prilagođava potrebama i ciljevima većeg broja učenika.

Personalizirano učenje odnosi se na trud za podučavanjem svakog pojedinog učenika, no s druge strane, personalizacija u smislu analitike učenja, odnosi se na povratnu informaciju prilagođenu svakom učeniku, ispitujući njegove prednosti i nedostatke, te prezentirajući

zaključke. Vesin i sur. [85] navode kako je za dobру personalizaciju učenja potrebno razumjeti analitiku učenja.

6.4.7. Ostali ciljevi

Ostali ciljevi koje smo prepoznali odnose se na detekciju ili identifikaciju neaktivnih učenika ili učenika slabih performansi [47], a [78] za cilj navodi identifikaciju učenika slabih vještina. Dva rada, [62] i [79], navode kao cilj olakšanje komunikacije i praćenje dijaloga. [32] i [34] navode grupiranje kao cilj razvoja NPAU, a željni su grupirati učenike na temelju kognitivnog stila i aktivnosti. Usporedbu kao cilj razvoja NPAU navode [33], a analitiku u radnom okruženju je prepoznat cilj u [58].

6.5. Tehnike rudarenja podataka NPAU

Rudarenje podataka u obrazovne svrhe i analitika učenja mogu se koristiti za predviđanje uspješnosti i mogućeg odustajanja učenika na temelju procjene njihovih postignuća, sudjelovanja, angažmana, ocjena u procesu učenja, poučavanja i testiranja znanja [98]. Rudarenje podataka se koristi za definiranje učenikova ponašanja i stvaranja obrazaca u kojima se događa učenje kako bi stvorili različite profile učenika [99].

Identificirano je 13 radova koji koriste različite tehnike rudarenja podataka. Od tih 13, u prethodnom poglavlju smo prepoznali čak njih 11 gdje je predikcija navedena kao cilj razvoja NPAU, stoga možemo zaključiti kako je zajednički cilj tehnika rudarenja podataka u obrazovne svrhe razvijanje prediktivnih modela.

Od 13 radova navedenih u tablici, dva rada [62], [71] nisu navela algoritme korištene za predikciju, stoga nam ostaje 11 radova u kojima je naveden algoritam.

U nastavku ćemo prikazati korištene tehnike kod svakog od radova kako bi vidjeli koja tehnika se koristi u najvećoj mjeri.

Nguyen i dr. [41] koriste klasifikaciju i metodu klastera kako bi predvidjeli ocjenu učenika. Možemo reći da njihov prediktivni model prolazi kroz dvije faze. Prva, u kojoj se koristi linearna regresija kako bi se predvidjela količina interakcija učenika u određenom vremenu. Druga faza, u kojoj se koristi klaster metoda, kako bi grupirali učenike u tri skupine: rizična skupina učenika, skupina učenika s visokom mogućnosti postizanja dobrih ocjena i srednja skupina. Koristili su K-Means algoritam, Birch i Agglomerative clustering.

[44] predstavljaju korištenje klaster metode i SNA (eng. Social Network Analysis) kako bi prikazali Twitter raspravu te grupirali učenike prema njihovim vezama i sadržaju tvitova.

Hussain i dr. [47] koriste FURIA klasifikaciju kako bi identificirali aktivne i neaktivne učenike. Pokazalo se kako je točnost algoritma na 98.23% kad u obzir uzmu ponašanje učenika. Koriste FURIA klasifikaciju s ciljem predikcije učenika koji su iznad ili ispod prosjeka prema ocjenama. Koristeći K-means grupirali su učenike u tri kategorije: aktivne, neaktivne i slabo aktivne učenike. Konačno, autori su ispitali koji od algoritama FURIA,

Random Forest ili AIRS daje najbolju predikciju neaktivnih i učenika slabog učinka. Pokazalo se kako FURIA klasifikacija daje najbolje rezultate.

U svom radu Lobos i Olmos [54] žele stvoriti prediktivni model koji će prepoznati učenike sklone odustajanju i učenike koji će vjerojatno završiti tečaj. Pokazalo se kako je najbolji prediktivni model koristio Bayesian Generalized Linear Model algoritam. Stochastic Gradient Boosting, Neuronal Network, i Random Forest su se pokazali kao najbolji za predikciju odustajanja. Bayesian Generalized Linear Model, Neuronal Network i Random Forest, koje slijede Stochastic Gradient Boosting i Naïve Bayes se pokazuju kao najbolji za predviđanje završetka tečaja. Osim navedenih, koristili su se Boosted Logistic Regression, Support Vector Machines, k-Nearest Neighbours i Classification i Regression Tree.

[56] koristi klasifikaciju kako bi predvidjeli hoće li učenici proći ili pasti sljedeći ispit, tj. kako bi identificirali rizične skupine učenike. Koristili su Logistic Regression, SVC linear kernel, SVC rbf kernel, Random Forest, Decision Tree i K nearest neighbour. Autori su radili predikciju na tri različita kolegija, pokazalo se kako je u svakom od tri kolegija različiti algoritmi imali najbolji uspjeh. Iz ovog vidimo kako nisu uspjeli napraviti model koji može biti uspjesan za sve kolegije i za sve učenike.

Course Signals [67] koristi Student Success Algorithm kako bi prepoznao rizične skupine i klasificira ih u tri grupe. Crveni, žuti ili zeleni signal prikazuje se na početnoj stranici tečaja. Crveno svjetlo ukazuje na veliku vjerojatnost neuspjeha; žuta označava potencijalni problem uspjeha; a zeleni signal pokazuje veliku vjerojatnost uspjeha na tečaju.

[80] koristi stablo odluke kako bi predvidio ocjenu učenika. Povratna informacija se prikazuje u tjednim intervalima.

[32] koriste klasifikaciju kako bi predvidjeli uspjeh učenika tijekom poučavanja. Koristili su osam različitih algoritama. NeuralNet, AdaBoost i RandomForests se pokazuju kao najbolji algoritmi za predikciju uspjeha. Logistic regression, Naive Bayes, LDA, J4.8 imaju slabiji uspjeh. A s druge strane, najgori uspjeh predviđanja imaju LDA, Logistic regression i Naive bayes.

[35] razvijaju klasifikacijski model s ciljem predviđanja uspješnosti studenata (niska ili visoka) koristeći podatke o interakciji učenika sustava za poučavanje. Alat koristi 12 algoritama za klasifikaciju (LogitBoost, knn, rf, svmRadial, J48, rpart, rpart2, glm, naive_bayes, nnet, svmLinear, gbm). Ovaj alat ima mogućnost klaster metode, a ona nam služi za grupiranje učenika slabih, srednjih i visokih performansi. U ovu svrhu kNN je korišten.

NPAU LADA [87] koristi multilevel klaster metodu. Korišteni algoritam je Fuzzy C-means algoritam. Algoritam grupira prethodne učenike u skladu s dostupnim karakteristikama (njihove dobivene ocjene i broj predmeta koje su odabrali tijekom semestra). Osim predviđanja uspjeha, ovaj alat ima implementiranu komponentu kvalitete predviđanja.

6.6. Povratna informacija (Regulacija učenja)

Ovo poglavlje ima najbitniju ulogu u korištenju NPAU za proces učenja i poučavanja jer analitika učenja nastoji poboljšati procese učenja sustavnim mjerjenjima podataka povezanih s učenjem i pružiti povratne informacije učenicima i nastavnicima [100], [90]. Povratne informacije (PI) koje se daju putem nadzornih ploča analitike učenja mogu pružiti učenicima podatke o njihovoj uspješnosti, kao i njihovu angažmanu u aktivnostima učenja i ocjenjivanju [101]. Davanje povratne informacije je proces u kojima učenici stvaraju svijest o informaciji iz različitih izvora i koriste je kako bi unaprijedili kvalitetu ili strategiju učenja [102] prema [103]. Ova definicija nadilazi ideje da se PI uglavnom odnose na nastavnike koji informiraju učenike o njihovim slabostima i kako te slabosti poboljšati te ističe središnju ulogu učenika u stvaranju svijesti za poboljšanje kasnijeg učenja.

Glavni cilj PI je unaprjeđenje samo-reguliranog učenja, ali s druge strane moramo imati na umu kako su iskustva učenika sa PI individualna i skloni promjenama. Verbert i sur. [21] napominju kako PI mora biti djelotvorna. Zimmerman i Schunk [104] definiraju samoregulirano učenje kao ciljno usmjerenu i metakognitivnu aktivnost u kojoj učenici preuzimaju kontrolu nad svojim postupcima (ponašanje), razmišljanjem (kognicija) i vjerovanjem (motivacija, emocije) s ciljem ispunjavanja zadatka. Istraživanje je pokazalo da uspješni učenici koriste različite strategije za usmjeravanje i unapređivanje svog procesa učenja za ispunjavanje zadatka [104].

4.6.1 Tipovi prezentacije povratne informacije

U ovom radu smo definirali obavijesti, vizualizaciju i tekst kao tipove prezentacije PI. Zanimalo nas je u kojem se omjeru koriste i je li NPAU sadrži više tipova ili se temelji na jednom tipu povratne informacije. Tablica 6 prikazuje broj i postotak korištenja obavijesti, vizualizacija ili teksta u svrhu povratne informacije.

Vrsta PI	Broj radova	Postotak
Vizualizacija	54	88.52%
Text	31	50.81%
Obavijest	12	19.67%

Tablica 6 Vrste povratnih informacija

6.6.1.1. Vizualizacija

Vizualizacija se u najvećoj mjeri koristi kao sredstvo prikazivanja podataka. U ovom radu je identificirano 55 radova koji koriste jednu ili više vrsta vizualizacija, stupčasti grafikon, linijski grafikon, tortni grafikon, trakasti grafikon, površinski grafikon, raspršeni grafikon, histogram i ostali su praćeni. Tablica 7 prikazuje koji tip grafikona se najviše koristi pri vizualizaciji informacija NPAU. [47] nije naveo vrste grafikona, stoga ga nećemo uzeti u obzir.

Tip	Broj radova	Postotak
Linijski	32	53.33%
Stupčasti	29	48.33%
Tortni	16	26.67%
Histogram	10	16.67%
Površinski	7	11.67%
Trakasti	5	8.33%
Raspršeni	3	5%
Ostalo	5	8.33%

Tablica 7 Tip grafikona prema broju korištenja

U najvećoj mjeri se koriste stupčasti i linijski grafikon. Tortni grafikon ga slijedi, a histogram je na četvrtom mjestu po broju korištenja. U najmanjoj mjeri se koriste raspršeni i površinski. U kategoriji Ostalo, u najvećoj mjeri se koristi radar grafikon.

6.6.1.2. Tekst

Tekst kao PI koristi 28 NPAU (45.90%). Prezentacija teksta kao PI je najčešće u tablici [39], [44], [53], [65], [70], [72], [73], [74], [77], [78], [30], [31], [32], [33], [85], [88]. Tekst u tablici npr. prikazuje rezultate testa, vremenske podatke, najviše korištene sadržaje i slično. AAT [64] omogućava nastavnicima da podatke analize preuzimaju u formi CSV/html dokumenta, a [58] osobnu statistiku učenika koristi kao PI u obliku teksta.

6.6.1.3. Obavijesti

Obavijesti se odnose u najvećoj mjeri na slanje poruka kako bi učenici dobili PI o svom napretku [41], [47], [49], [56], [65], [67], [80]. Radi se o personaliziranim porukama o napretku učenika. [56] koristi personalizirane obavijesti temeljene na predikciji uspjeha učenika. S druge strane, obavijesti mogu biti računalno generirane [67]. Smatra se kako većina učenika percipira računalno generirane e-mail poruke i upozorenja kao osobnu komunikaciju između sebe i svog nastavnika, a dobije se dojam kako učenici nisu samo broj. Nakon dobivanja povratnih informacija od NPAU, nastavnik može obavijestiti porukom učenika koji ima slab učinak ili je neaktivan te potaknuti izvrsnog i aktivnog učenika putem e-maila. U tu svrhu možemo podijeliti obavijesti kao pozitivne i negativne. Cilj je potaknuti i upozoriti učenika na razmišljanje o svom uspjehu.

Drugi tip obavijesti čine preporuke sustava [37], [46], [5], [70], [31]. Ovaj tip obavijesti možemo podijeliti na preporuku sardžaja i preporuku strategija kako bi postignuli određene ciljeve uspješnosti. Preporuke sustava se temelje na saznanjima o učenikovom uspjehu i odnose se na preporuku o nastavku učenikova procesa učenja i poučavanja kako bi postigli bolji uspjeh [37]. Content Recommender i Skill recommender [5] predstavljaju dva alata koja sadrže oba tipa preporuka. Content Recommender želi omogućiti poboljšanje strategija kako bi učenici mogli lakše uočiti nedostatke u znanju, te kako bi ih usmjerio na sadržaje s ciljem lakšeg svladavanja traženog. Skill Recommender želi učenicima omogućiti poboljšanje svojih vještina. [70] koristi sustav preporuka puta učenja, a [31] sadrži panel preporuka koji omogućuje

navigaciju korištenih resursa. Verbert i sur. [21] u najranijem pregledu NPAU napominju kako samosvijest o učenikovu uspjehu i sposobnosti pruža pozitivne reakcije, uključujući poticanje uvida, povećanje samokontrole i promicanje dobrog ponašanja.

6.6.2. Vrijeme isporuke PI

Pokazalo se da što prije učenici dobiju povratne informacije o svom radu, to je učinkovitije za njihovo učenje [105]. Konačna ideja NPAU je regulirati proces učenja i poučavanja prezentirajući povratne informacije o saznanjima tokom samog procesa. Taj proces bi trebao obuhvaćati faze planiranja (npr. postavljanje ciljeva), stvarnih trenutaka učenja (npr. dovršetak zadatka), praćenja (npr. provjera napretka prema očekivanim rezultatima) i napora prilagodbe (npr. sudjelovanje u poboljšanju rezultata) [94].

PI u realnom vremenu se smatra najboljim načinom isporuke povratnih informacija. Nekad se povratna informacija ažurira svakih nekoliko dana, a ponekad svakih nekoliko minuta. Jasno je kako moramo biti oprezni da ne zatrpmo učenike sa previše informacija koje mogu smatrati nepotrebima. Učenicima trebamo ponuditi informacije i na kraju ih pustiti da sami odluče kako će napredovati sa učenjem. Vrijeme isporuke povratne informacije kod nastavnika je važno, posebno u segmentu gdje se očekuje da sustav djeluje kao sustav upozorenja u svrhu poboljšanja performansi učenja. Stoga možemo zaključiti da što prije sustav ponudi informaciju, to prije ćemo djelovati na proces učenja i poučavanja.

6.7. Vrednovanje NPAU

NPAU je nedvojbeno zanimljiv alat jer predstavlja velik broj informacija kojima možemo identificirati ključne probleme u procesu učenja i poučavanja. S tehničke strane, NPAU nije nikakva novost, no, ostaje pitanje kako učenici i nastavnici prihvataju ovakve sustave i koliko ovakvi sustavi zaista djeluju na proces učenja i poučavanja. U nastavku ćemo se orijentirati na vrednovanje ovakvih sustava od strane nastavnika i učenika.

Verbert i sur. [21] predstavljaju konceptualni okvir za vrednovanje alata analitike učenja. Predstavljeni okvir ima četiri faze: samosvijest, refleksija, stvaranje osjećaja i utjecaj. Sviest se odnosi na prezentaciju podataka i po definiciji gotovo svaka od NPAU sadrži ovu fazu. Prezentacija podataka nije krajnji cilj. Refleksija se odnosi na stvaranje pitanja o postizanju konačnog cilja učenja. U trećoj fazi se očekuje da učenici stvore percepciju svoga stanja učenja, a Četvrta faza se odnosi na utjecaj, tj. moguće promjene ponašanja s ciljem postizanja boljih rezultata tijekom procesa učenja i poučavanja.

Od ukupnog broja pregledanih radova, 33 rada (54.09%) prikazuju vrednovanje sustava. Metodologija vrednovanja NPAU u pregledanim radovima je najčešće upitnik (18

radova, 54.54%), potom intervju (8 radova, 24.24%), eksperiment (4 rada, 12.12%), fokus grupe (3 rada 9.09%) i vođenje dnevnika (1 rad, 3.03%).

Moramo naglasiti da je vrednovanje nejednako po definiciji cilja. Najčešće navedeni cilj vrednovanja je ispitati upotrebljivost i korisnost ovakvih sustava od strane nastavnika i učenika. Upotrebljivost i korisnost su navedene 9 puta kao cilj ili jedan od ciljeva vrednovanja NPAU. Zanimljivo je kako je svaka od vrednovanja ocijenila pozitivno korisnost sustava u konačnici, dok je skala upotrebljivosti u samo jednom radu bila ispod očekivane razine. Ponekad je cilj naveden kao percepcija od strane učenika ili nastavnika [5], [67], [77] no također, svako od tih vrednovanja je bilo pozitivno ocijenjeno. Stoga možemo zaključiti kako nastavnici i učenici vide svrhu korištenja ovakvih sustava. Refleksija je ispitivana u samo jednom radu [46], no zaključilo se kako refleksija ovisi o uspjehu pojedinca. [72] i [80] između ostalog istražuju kako NPAU utječe na motivaciju učenika. Također se pokazalo da su rezultati uglavnom pozitivni ali bez značajne razlike. Napravljeno je vrednovanje u smjeru preferiranog korištenja NPAU, od strane računala ili putem mobitela [55], pokazalo se kako učenici preferiraju korištenje mobitelom.

Prethodno predstavljena vrednovanja spadaju u prve tri faze prema Verbertovu konceptualnom okviru. No, ostaje pitanje koliki je utjecaj NPAU na učenike i njihovu promjenu ponašanja. U tim okvirima, zanimljivo je predstaviti dva vrednovanja. Oba su provedena putem eksperimenta. [43] provodi eksperiment 60 dana. Eksperimentalna grupa koja je koristila NPAU koristila je sustav za poučavanje u većoj mjeri, koristila je diskusiju u većoj mjeri i postigla bolje rezultate na zadnjoj provjeri. S druge strane, [89] osim eksperimenta, koristi dva upitnika. Prvi upitnik se odnosi na konformnost, jednostavnost korištenja, upotrebljivost, razinu razumijevanja, mišljenja i sugestije. Drugi upitnik se odnosi na zadovoljstvo i promjene ponašanja nakon korištenja NPAU. Ovdje moramo naglasiti kako su rezultati eksperimenta pokazali da nije bilo značajnog utjecaja na ishode učenja.

Prema pregledu provedenih vrednovanja NPAU možemo vidjeti kako su nastavnici i učenici u globalu zadovoljni onim što nude NPAU. Povratne informacije sigurno stvaraju svijest o aktualnom stanju učenika i dopuštaju nastavnicima da prepoznaju prednosti i nedostatke kod učenika. Ostaje pitanje utjecaja. Konačan cilj ovakvih sustava je utjecati na promjene ponašanja. Navedena dva primjera pokazuju kontradiktorne rezultate, stoga ostaje pitanje što ima mogućnost potaknuti učenika da donosi akcije u smjeru promjena ponašanja. [5] navode kako bi trebali analizirati način na koji učenici koriste NPAU, jer se može dogoditi utjecaj, a ako učenik nije koristio NPAU, učinak nije radi sustava. Nadalje, učenike bi trebalo uključiti u istraživanje mogućih problema kod predstavljanja podataka, te uzeti njihove sugestije u obzir. Njihova interpretacija nam može pomoći u stvaranju kvalitetnije slike u vidu preporuke resursa, sadržaja NPAU, motivacije za korištenje određenih značajki NPAU. Na taj način ćemo stvoriti analitičke sustave koje

učenici zaista žele koristiti, a ne sustave za koje se nadamo da će učenici koristiti. Buduća istraživanja vrednovanja NPAU bi trebala sagledati cijelokupnu priču analitike iz perspektive različitih znanstvenih disciplina kako bi saznali koliki i kakav utjecaj NPAU ima na učenike, te koje su sličnosti i razlike po disciplinama.

6.8. Etička načela

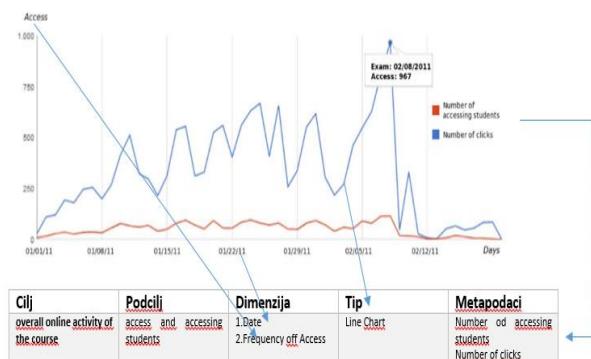
Ključna etička pitanja vezana uz korištenje velikih podataka i analitike učenja su privatnost, suglasnost i način korištenja, pohranjivanja i zaštićenosti podataka [106], [107] stoga smo u ovom pregledu, pratili na koji način i u kojoj mjeri su autori zadovoljili neko od spomenutih etičkih pitanja pri korištenju NPAU. 18 radova (29.5%) je spomenulo privatnost podataka ili etiku. Najčešće su to bile rečenice na kraju rada u kojima se napominje kako su učenici pristali na korištenje njihovih podataka. U nijednom radu nije prikazan obrazac na koji su učenici pristajali. Prema mišljenju eksperata privatnost i etičko korištenje su fundamentalni prvi korak u razvoju analitike učenja, no predstavlja kompleksno pitanje [108]. Moramo otkriti i spriječiti zlouporabu podataka, utvrditi granice analitike, sačuvati povjerljive podatke o korisnicima, zaštititi identitet korisnika u svakom trenutku i razmišljati o našoj obvezi da djelujemo na temelju novo stečenog znanja [12]. Identifikacija učenika je moguća na nekoliko načina, jer je očito da osobni podaci poput imena, matičnog broja i adrese e-pošte moraju biti anonimni [109]. Međutim, studenti se mogu identificirati i po nekom skupu njihovih osobnih podataka, poput dobi, spola, organizacije, godine učenja, vremenske oznake, korištene IP adrese i sl. Pitanja privatnosti i etička pitanja koja se pojavljuju u kontekstu analitike učenja čvrsto su povezana s drugim aspektima kao što su povjerenje, odgovornost i transparentnost [110]. Moramo shvatiti da zaštita podataka nije puki pravni zahtjev, već bi brigu o privatnosti trebalo duboko ugraditi u alate analitike učenja te na taj način povećati povjerenje korisnika ovih sustava [108]. Privatnost ne treba promatrati kao teret, već kao vrijednu uslugu koju možemo ponuditi za izgradnju povjerljivih odnosa. Da bi se izgradio takav odnos, visok stupanj transparentnosti je potreban. Transparentnost se može primijeniti na gotovo svaku fazu analitike učenja. U širem smislu, sve interesne skupine trebale bi imati pristup opisu procesa analitike i trebaju biti informirane o vrsti informacija koje se prikupljaju, uključujući način na koji se prikupljaju, čuvaju i obrađuju. U nijednom radu nije spomenuto u koliko su mjeri učenici obaviješteni i koji podaci će se prikupljati te kako će se koristiti. Ova misao se odnosi na učenikovu kontrolu nad podacima [110]. Kako bi zadovoljili kriterije prava privatnosti i etička načela pri korištenju analitike učenja, moramo odgovoriti na pitanja koji se podaci prikupljaju, tko ima pristup podacima, kako će se podaci identificirati i koliko dugo ostaju dostupni podaci [9]. Stvaranje uglednog okruženja za učenje implicira uključivanje učenika u proces odlučivanja, dok bi učenici trebali imati aktivan glas u određivanju podataka prikupljenih o sebi, načinu korištenja i pohranjivanja, tko će imati pristup podacima i kako će biti zaštićen identitet učenika. Jako je teško ocijeniti koliko dozu transparentnosti i otvorenosti

uključiti u procesu analitike učenja, jer prevelika transparentnost prema učenicima može rezultirati stvaranjem krivog dojma od strane učenika tokom procesa učenja i poučavanja, te se mogu stvoriti lažni obrasci ponašanja.

7. PEDAGOŠKI OKVIR ZA DAVANJE POVRATNE INFORMACIJE U NADZORNIM PLOČAMA ANALITIKE UČENJA

U nastavku smo preuzeли svaku povratnu informaciju kako bi je analizirali u pedagoškom smislu (Dodatak A). Za svaku smo definirali Cilj, Podciljeve, Tip, Dimenziju i Metapodatke. Na sljedećem primjeru, Slika 5, objasnit ćemo kako su podaci evidentirani. Izdvojili smo jednu povratnu informaciju, na kojoj ćemo pojasniti praćene karakteristike.

Cilj svake povratne informacije se odnosi na definiciju pronađenu u radu (ukoliko postoji). Podciljevi su naslovi povratne informacije (npr. access and accessing students). Dimenzija se odnosi na prikazivanje rezultata. U ovom slučaju se koriste dvije dimenzije (Datum i frekvencija pristupa). Tip se odnosi na način kako je povratna informacija prezentirana, u ovom slučaju je Linijski grafikon. Metapodaci se odnose na dodatne pojmove vezane uz informaciju. U ovom primjeru, to su broj prijava učenika i broj klika.



Slika 5 Primjer vizualizacije u svrhu pojašnjena čitanja povratne informacije

Analizom PI koje su korištene ili spomenute u svakom pregledanom radu, stvorili smo pedagoški okvir koji objedinjuje sve NPAU. Na samom početku definirali smo pet kategorija povratnih informacija. PI o interakciji sa sustavom, PI o ponašanju i stanju učenika, PI o nastavnim materijalima, PI o uspjehu i PI o efikasnosti. Za svaki od definiranih kategorija, uvidom u povratne informacije, dali smo pregled svrhe PI, što prikazati, kako prikazati, kada prikazati i karakteristike. Sve napisano je izvedeno analizom PI koje smo prikupili u pregledanim radovima.

7.1. PI o interakciji sa sustavom

Interakcija sa sustavom odnosi se na različite podatke u vremenu dok je učenik logiran na sustav. Prepoznote aktivnosti učenika dok je logiran u sustav su: aktivnosti na društvenim mrežama, ukupno vrijeme korištenja sustava, prosječno vrijeme korištenja sustava. Na temelju tih podataka možemo stvoriti liniju napora (usporediti sa određenim vremenskim razdobljima, kako bi vidjeli

promjene kod učenika), alarmirati učenike i nastavnike ako je primjećen manji napor ili manje korištenje sustava. Bitno je naglasiti da je PI o interakciji prezentirana tijekom procesa učenja i poučavanja, kako bi mogla utjecati na daljnje poučavanje. Rezultati prikazivanja mogu biti usporedba (sa razredom), a mogu biti individualni (prikazujući samo učenikove rezultate). U želji da opišemo karakteristike korištenja sustava u vidu povratne informacije izdvojili smo doba dana, ukupno vrijeme u tjednu, prosječno vrijeme u tjednu, korištenje boja i analiza poruka, threadova, komentara.

7.2. PI o ponašanju i stanju učenika

Ponašanje i stanje učenika je od iznimne važnosti za razumijevanje procesa učenja i poučavanja. Razumijevajući ponašanje i stanje učenika, nastavniku je omogućeno pravovremeno reagirati i donositi odluke. Očekuje se kako PI o ponašanju i stanju učenika može djelovati na motivaciju, što pospješuje personalizirana poruka. Konačan cilj je povećanje svijesti o učenju i samorefleksija. Prikazivanje učenikova stanja može biti u obliku aktivnih/neaktivnih učenika, definirane vještine učenika, kognitivni stil, razina prema Bloomovoj taksonomiji, identificirane poteškoće učenika. Prikazivanje ovakvih podataka je tijekom procesa učenja i poučavanja, jer se očekuje da PI djeluje na donošenje odluka kod učenika. PI o ponašanju može biti prezentirana u vidu motivacijske poruke, prikazujući vještine u određenom vremenskom razdoblju, usporedba sa rezredom ili prikazivanje emocija i stanja učenika prema tipu ili kroz određeni vremenski period.

7.3. PI o nastavnim materijalima

Kako bi nastavnici razvijali strategije učenja kod učenika, primjenjujući određene nastavne materijale, PI o nastavnim materijalima je od iznimne važnosti. Na ovaj način možemo preporučiti učenicima određene materijale ukoliko je potrebno, a sve sa ciljem poboljšanja procesa učenja i poučavanja. Zadaci, video, korištenje materijala u određenom vremenskom intervalu predstavlja sadržaj povratne informacije. Ovakvi podaci su prezentirani tijekom procesa učenja i poučavanja. Broj korištenja prema pristupu, utrošeno vrijeme i minute, pregledane stranice i najviše pregledani resursi, tjedna metrika o sesijama i resursima, grupiranje na temelju sličnih materijala po težini, ukupno vrijeme, prosječno vrijeme, medijan vremena u danu kad učenici koriste materijale ili broj pregledanih resursa predstavljaju sadržaj koji se prati i isporučuje.

7.4. PI o Uspjehu

Procjena postignute razine kod učenika predstavlja informaciju o uspjehu. Uspjeh smatramo konačnim ciljem u procesu učenja i poučavanja. Ostale PI omogućuju donošenje odluka, dok je u ovom slučaju prekasno za djelovanje. Vježbe, domaće zadaće, kviz, ispit, nezavršeni tečajevi, predviđanje uspjeha predstavljaju informacije za isporuku. U ovom slučaju, PI se pruža nakon provedene provjere ili u određenom vremenskom razdoblju. Prikazani rezultati mogu biti individualni ili u usporedbi sa razredom, vrijeme i datum provedbe. Također, možemo prikazati predviđeni uspjeh, usporediti predviđeni uspjeh sa stvarnom ocjenom i odrediti kvalitetu predikcije. Rezultati mogu biti u obliku bodova, postotka, ocjene ili neke unaprijed definirane kategoriskske veličine.

7.5. PI o Efikasnosti

Efikasan učenik je učenik koji prethodi dobrom uspjehu. Kod ove PI prepoznali smo rješavanje problema, pristup rješavanju problema, učinak prema težini i postavljenim ciljevima, razina razumijevanja, broj pogrešaka, točne/netočne odgovore i identifikacija stereotipa kao moguće povratne informacije. Ova PI se javlja tijekom procesa učenja i poučavanja s ciljem procjene razine efikasnosti kod učenika i mogućnosti pravovremenog djelovanja.

Na temelju definiranih klastera, predstavljamo sljedeći pedagoški okvir (**Pogreška! Izvor reference nije pronađen.**):

Tablica 8 Pedagoški okvir za davanje informacija u nadzornim pločama analitike učenja

	PI o interakciji sa sustavom	PI o ponašanju i stanju	PI o nastavnim materijalima	PI o Uspjehu	PI o Efikasnosti
Svrha PI	-usmjerava i poboljšava aktivnost učenja i poučavanja -pruža mogućnost učenicima da razviju svijest o svom učenju -omogućuje nastavnicima donošenje odluka -poboljšava angažman učenika	-Omogućuje pravovremenu intervenciju o stanju učenika -pobuđuje motivaciju -omogućuje personaliziranu poruku -povećava svijest o učenju i samorefleksiju	-Nastavnici će moći regulirati nastavne materijale na temelju korištenja -razumijevanje navika učenika -poboljšava strategije poučavanja -preporuka sadržaja za učenje	-daje informaciju ili procjenu postignute razine učenika -procjenjuje naučeno u odgovarajućoj, krajnjoj točki nastavnog procesa -predviđanje uspjeha	-informacija o efikasnosti učenika prethodi ocjeni -procjenjuje razinu efikasnosti učenika
Što prikazati	Aktivnosti na forumu i twitteru (blogovi, komentari, oznake, poruke, odgovori...) Vrijeme interakcije sa sustavom (dnevna, ukupna, prosječna); Linija napora; Aktivnost na temelju logiranja; Grupni rad;	Usporedba temeljena na pristupu sustavu; Aktivne – neaktivne učenike; Učenikove vještine; performanse učenika prema Bloomu; Najteža/ najviše korištena kategorija; Pitanja o refleksiji; Emocije učenika; identificirane poteškoće učenika; stanje učenika prema trudu na vremenskoj liniji; Kognitivni stil pristupa;	Zadatke i Video kojima je učenik pristupio ili odstupio; korištenje sadržaja za učenje u konkretnom vremenu;	Postotak uspješnosti riješenih vježbi; Rezultate kviza; Domaća zadaća; Rezultati ispita; Trajanje kviza ili zadatka; Broj pokušaja rješavanja; Uspjeh u određenom vremenu; Nezavršene tečajeve; Predviđenu ocjenu/uspjeh;	Vrijeme pristupa problemu; Navika rješavanja problema; Pristup rješavanju problema; Učinak prema težini i postavljenim ciljevima; Razina razumijevanja; efikasnost učenika prema postavljenom cilju; distribucija pogrešaka prema broju i tipu tečaja; točne/netočne odgovore; stereotip kojem pripada učenik;
Kada prikazati	Tijekom procesa učenja i poučavanja; U određenim vremenskim intervalima;	U određenim vremenskim intervalima (tjedno, mjesečno, dnevno);	Tijekom procesa učenja i poučavanja;	Nakon provedene provjere; U određenom vremenskom intervalu;	Tijekom procesa učenja i poučavanja;
Kako prikazati	Individualno; Usporedba (sa prosjekom razreda, sa najboljim rezultatom, sa aktivnim učenicima), Usporedba napora sa prethodnim razdobljem; Korištenje boje kao alarma,	Motivacijska poruka; E-mail; Individualno; Vještine kroz određeni period; vještine potrebne za završetak semestra; Usporedba sa prosjekom razreda prema postotku kognitivnog razumijevanja prema Bloomu; Razina kategorije ; Postaviti pitanje; vremenska crta	Broj korištenja prema pristupu; zadatku; Utrošeno vrijeme i minute; Pregledane stranice; Najviše pregledani resursi; Tjedna metrika o sesijama i resursima; vrijeme od postavljanja materijala do prvog pregleda; Grupiranje na temelju sličnih materijala po težini;	Individualan rezultat; Vrijeme i datum početka i završetka kviza ili zadatka; prosječno vrijeme na kvizu; Usporedba sa prosjekom razreda/ostalim učenicima; korištenje boje kao alarma; Usporedba predviđene i stvarne ocjene; Kvaliteta	Usporedba sa prosjekom razreda; Utrošeno vrijeme i minute, Postavljajući pitanja; linija progresi; broj pogrešaka u određenom vremenu;

		emocije; prosječna duljina emocije u različitim sesijama;	Ukupno vrijeme, prosječno vrijeme, medijan vremena u danu kad učenici rade,	predikcije; broj učenika koji su prošli kolegij;	
Karakteristike	Vrijeme interakcije (jutro, dan, noć), broj poruka; tip poruke(požitivna, negativna, neutralna); Vrste članova u grupnom radu), Boja (crveno loše, zeleno dobro); Ukupno vrijeme u tjednu (sati, minute...), Prosječno vrijeme (sati, minute...)	Tip poruke (pozitivna, negativna); Vještina (online aktivnost, osvještenost o znanju, upravljanje vremenom, Duboko učenje, konzistentnost, perzistentnost); Taksonomija (pamćenje, razumijevanja, analiziranja); 10 unaprijed određenih poruka; Tip kategorije(testiranje, razvoj, dokumentacija, školski rad, sastanak); Pitanje: „Što je teško u određenoj kategoriji za tebe?“; Vrste emocije (12 tipova); poteškoće(odjeljci i vještine, točni odgovori, prosječno vrijeme, točnost); Kognitivni stil (empirijski/intuitivni, introvert/ekstrovert, prosuđujući/opažajući, racionalni ili emocionalni)	Pristup (Nekoliko puta, polovica, većina); Dnevni pregled stranica, tjedni pregled stranica; Trajanje sesije;	Postotak rješenosti; Bodovi; Kategoriski (Zadovoljio, OK, Nije zadovoljio, Nije napravio; Kategoriski ($<30 \geq 30 \& <70 >70$); boja (crveno rizični, žuto-prošli, zeleno-uspješni), Kategorije predviđanja uspjeha(vrlo lako, lako, srednje, teško), kategorije kvalitete predikcije (izvrsna, dobra, srednja, slaba, vrlo slaba)	Vrijeme rada (jutro, dan, noć), Težina (lako, srednje, teško); Postotak rješenosti; Progres prema cilju(zadovoljen, nije zadovoljen, još radi na njemu); Točni/netočni odgovori prema učeniku; vrsta stereotipa

8. ZAKLJUČAK

Ovaj članak predstavlja pregled literature o sustavima za izvještavanje nastavnika i učenika o procesu učenja, poučavanja i testiranja znanja, tzv. nadzornim pločama analitike učenja. U analizi se raspravlja o tipovima podataka koji se prate, ciljevima razvoja alata za izvještavanje, metodama i tehnikama koje omogućavaju navedeno, vrednovanje ovakvih sustava i etičkim načelima koja moraju biti zadovoljena. Pri razvoju nadzornih ploča analitike učenja, bitno je uključiti učenike u proces stvaranja sustava kako bi stvorili sustav koji učenici žele koristiti, a ne se nadati njihovu korištenju. Pokazalo se kako su i dalje nadzorne ploče analitike učenja više orijentirane prema nastavnicima nego učenicima.

Pri odabiru podataka koji se prate, moramo naglasak staviti na kvalitetu podataka, a ne kvantitetu, stoga jedno od budućih istraživačkih pitanja treba biti opseg podataka koji su dovoljni za stvaranje prediktivnih modela. U najvećoj mjeri se koriste podaci korištenja nastavnog materijala i postignuća učenika, a prate ih vremenski podaci i podaci logiranja. Usporedbom kronološkog praćenja podataka, pokazalo se kako su istraživači u početku koristili podatke društvenih mreža u većoj mjeri, dok se u posljednje vrijeme povijesni podaci učenika koriste u znatno većoj mjeri nego u prethodnim godinama. Budući su povijesni podaci direktno vezani uz predikciju, možemo zaključiti kako se u posljednje vrijeme osim same vizualizacije, koristi i predikcija u sve većem opsegu.

Ciljevi razvoja nadzornih ploča analitike učenja su u prvom redu praćenje i podrška tokom procesa učenja i poučavanja, vizualizacija, metakognitivno poimanje, a potom predikcija i analiza. Pokazalo se kako su u najvećoj mjeri korištene tehnike klasifikacije i metoda klastera, te su one usko vezane uz predikciju i grupiranje učenika u određene klastere.

Tijekom izvještavanja učenika, očekuje se kako će učenici na temelju povratnih informacija sami regulirati svoje učenje, prepoznati svoje nedostatke i usmjeriti pažnju na poboljšanje svojih nedostataka. Na temelju svih povratnih informacija koje su korištene u nadzornim pločama analitike učenja, stvorili smo pedagoški okvir u sustavima nadzornih ploča analitike učenja. Predstavljeni okvir ima pet dimenzija: povratna informacija o interakciji sa sustavom, povratna informacija o ponašanju i stanju učenika, povratna informacija o nastavnim materijalima, povratna informacija o uspjehu i povratna informacija o efikasnosti. Tijekom pregleda vrednovanja sustava prepoznali smo kako su korisnici ovakvih sustava zadovoljni predstavljanjem rezultata, no ostaje dojam kako utjecaj sustava nije dovoljno istražen. Dva rada su predstavila utjecaj nadzorne ploče analitike učenja na učenike, no rezultati su kontradiktorni. Stoga jedno od smjernica budućih istraživanja treba biti istraživanje utjecaja povratnih informacija predstavljenih kroz nadzornu ploču analitike učenja na proces učenja. Drugo, trebali bi ispitati postoje li razlike u utjecaju povratnih informacija između različitih znanstvenih disciplina. Treće, sve pregledane nadzorne ploče analitike učenja su

korištene na fakultetima, stoga ostaje dojam kako su ovakvi sustavi najviše korišteni u visokom obrazovanju. pa bi istraživanja trebala pokazati kako učenici nižih razreda (osnovna i srednja škola) reagiraju na povratnu informaciju, te koliko i u kojoj mjeri povratna informacija može utjecati na regulaciju učenja kod učenika nižih razreda. Stvaranje sustava kojem učenici vjeruju se temelji na etičkim načelima. Učenici moraju biti upoznati sa podacima koji se prikupljaju, načinu korištenja, načinu obrade i prezentacije. Sve navedeno predstavlja složen proces, no korištenje analitike učenja zasigurno omogućava bolje razumijevanje procesa učenja i poučavanja, kvalitetnije nastavne sadržaje i pravovremene akcije nadzornu ploču analitike učenja na proces učenja. Drugo, trebali bi ispitati postoji li razlika u utjecaju povratnih informacija između različitih znanstvenih disciplina. Treće, sve pregledane nadzorne ploče analitike učenja su korištene na fakultetima, stoga ostaje dojam kako su ovakvi sustavi najviše korišteni u visokom obrazovanju. pa bi istraživanja trebala pokazati kako učenici nižih razreda (osnovna i srednja škola) reagiraju na povratnu informaciju, te koliko i u kojoj mjeri povratna informacija može utjecati na regulaciju učenja kod učenika nižih razreda.

Stvaranje sustava kojem učenici vjeruju se temelji na etičkim načelima. Učenici moraju biti upoznati sa podacima koji se prikupljaju, načinu korištenja, načinu obrade i prezentacije. Sve navedeno predstavlja složen proces, no korištenje analitike učenja zasigurno omogućava bolje razumijevanje procesa učenja i poučavanja, kvalitetnije nastavne sadržaje i pravovremene akcije.

9. LITERATURA

- [1] P. Long i G. Siemens, »Penetrating the Fog: Analytics in Learning and Education,« *EDUCAUSE Review* 46, p. 31–40., 2011.
- [2] S. B. A. , M. C. V. E. A. F. i. H. L. L. Johnson, »NMC Horizon Report: 2013 Higher Education Edition,« The New Media Consortium, Austin, Texas, 2013.
- [3] T. Elias, »Learning Analytics: Definitions, Processes and Potential,« *Siječanj* 2011..
- [4] A. L. Dyckhoff, V. Lukarov, A. Muslim, M. A. Chatti i U. Schroeder, »Supporting Action Research with Learning Analytics,« u *LAK'13, April 08–12* , Leuven, Belgium, 2013.
- [5] R. Bodily, T. K. Ikahihif, B. Mackley i C. R. Graham, »The design, development, and implementation of student-facing learning analytics dashboards,« *Journal of Computing in Higher Education*, 14 June 2018.
- [6] R. Ferguson, »Learning analytics: drivers, developments and challenges,« *International Journal of Technology Enhanced Learning* 4, 5-6, pp. 304-317, 2012.
- [7] G. Siemens, »Learning Analytics & Knowledge,« u *LAK 2011*, Banff, Alberta, 2011.
- [8] D. Suthers i K. Verbert, »Learning analytics as a middle space,« u *Proceedings of the Third International Conference on Learning Analytics and Knowledge*, 2013.
- [9] W. Greller i H. Drachsler, »Translating Learning into Numbers: A Generic Framework for Learning Analytics,« *Educational Technology & Society* 15 (3), pp. 42-57, 2012.
- [10] Boyer i G. Bonnin, »Higher Education and the Revolution of Learning Analytics«. *INTERNATIONAL COUNCIL FOR OPEN AND DISTANCE EDUCATION, Oslo, Norway..*
- [11] D. G. Sampson, »Learning Analytics: Analyze Your Lesson To Discover More About Your Students,« *EDUCATIONAL TECHNOLOGY*, 22 Listopad 2016.
- [12] M. A. Chatti, A. L. Dyckhoff, U. Schroeder i H. Thüs, »A Reference Model for Learning Analytics,« *International Journal of Technology Enhanced Learning* , 1 February 2013.
- [13] V. S. Mayer i K. Cukier, » Big Data: A Revolution That Will Transform How We Live, Work and Think,« *International Journal of Communication 7 Canada: Eamon Dolan/Houghton Mifflin Harcourt*, p. 242 pp. , 2013.
- [14] D. M. West, »Big Data for Education: Data Mining, Data Analytics, and Web Dashboards,« *Gov. Stud. Brook. US Reuters*, 2012.
- [15] Cope i M. Kalantzis, »Big Data Comes to School: Implications for Learning, Assessment, and Research,« *AERA Open Vol. 2, No. 2, p. pp. 1–19* , Travanj-svibanj 2016..
- [16] G. Sampson, »Learning Analytics: Analyze Your Lesson To Discover More About Your Students,« *EDUCATIONAL TECHNOLOGY*, Listopad 2016.
- [17] S. De Freitas, D. Gibson, C. Du Plessis, P. Halloran, E. Williams, M. Ambrose, I. Dunwell i S. Arnab, »Foundations of dynamic learning analytics: Using university student data to increase retention.« *British Journal of Education Technology; Volume 4*.
- [18] E. Durall i B. Gros, »Learning Analytics as a Metacognitive Tool,« u *6th International Conference on Computer Supported Education*, Barcelona, Spain, 2014.
- [19] S. Few, »Information dashboard design: Displaying data for at-a-glance monitoring,« u *Analytics Press*, Burlingame, CA, 2013.
- [20] S. Charleer, J. Klerkx, E. Duval, T. De Laet i K. Verbert, »Creating Effective Learning Analytics Dashboards: Lessons Learnt,« u *European Conference on Technology Enhanced Learning*, 2016.
- [21] K. Verbert, E. Duval, J. Klerkx, S. Govaerts i J. L. Santos, »Learning Analytics Dashboard Applications,« *American Behavioral Scientist*, p. 1500 –1509, 2013.
- [22] K. Verbert, S. Govaerts, E. Duval, J. L. Santos, V. F. Assche, G. Parra i J. Klerkx, »Learning Dashboards: an Overview and Future Research Opportunities,« pp. pp. 1499-1514, 2014.
- [23] B. A. Schwendimann, M. J. Rodriguez-Triana, A. Vozniuk, L. P. Prieto, M. S. Boroujen, A. Holzer, D. Gillet i P. Dillenbourg, »Perceiving Learning at a Glance: A Systematic Literature Review of Learning Dashboard Research,« *IEEE TRANSACTIONS ON LEARNING TECHNOLOGIES*, VOL. 10, NO. 1, Siječanj-ožujak 2017.
- [24] R. Bodily i K. Verbert, »Review of research on student-facing learning analytics dashboards and educational recommender system,« *IEEE TRANSACTIONS ON LEARNING TECHNOLOGIES*; 03-0046, 2017.
- [25] I. Jivet, H. Drachsler, M. Scheffel i M. Specht, »Awareness Is Not Enough: Pitfalls of Learning Analytics Dashboards in the Educational Practice,« u *Data Driven Approaches in Digital Education*, Tallinn, Estonia, 12th European Conference on Technology Enhanced Learning, EC-TEL , 2017 September 12–15..
- [26] I. Jivet, M. Scheffel, M. Specht i H. Drachsler, »License to evaluate: Preparing learning analytics dashboards for educational practice,« u *Proceedings of International Conference on Learning Analytics and Knowledge*, Sydney, NSW, Australia, March 7–9, 2017.
- [27] W. Matcha, D. Gasevic, N. Ahmad Uzir i A. Pardo, »A Systematic Review of Empirical Studies on Learning Analytics Dashboards: A Self-Regulated Learning Perspective,« *Transactions on Learning Technologies*, Svibanj 2019.

- [28] S. Slade i P. Prinsloo, »ETHICAL ISSUES AND DILEMMAS,« *Am. Behav. Sci.* 57, pp. 1510-1529, 2013.
- [29] J. Swenson , »Establishing an ethical literacy for learning analytics,« *Proceedings of the Fourth International Conference on Learning Analytics And Knowledge*, pp. 246-250, March 2014.
- [30] M. May, S. George i P. Prévôt, »TrAVis to Enhance Students' Self-monitoring in Online Learning Supported by Computer-Mediated Communication Tools,« *International Journal of Computer Information Systems and Industrial Management Applications*, pp. 623-634, 2011.
- [31] S. Govaerts, E. Duval, K. Verbert i . Pardo, »The Student Activity Meter for Awareness and Self-reflection,« *CHI'12*, 5-10 May 2012.
- [32] M. Jovanovic, M. Vukicevic, M. Milovanovic i M. Minovic, »Using data mining on student behavior and cognitive style data for improving e-learning systems: a case study,« *International Journal of Computational Intelligence Systems*, May 2012.
- [33] V. Podgorelec i S. Kuhar , »Taking Advantage of Education Data: Advanced Data Analysis and Reporting in Virtual Learning Environments,« *ELECTRONICS AND ELECTRICAL ENGINEERING ISSN 1392 – 1215; No. 8(14)*, 2011.
- [34] D. A. Gomez-Aquilar, A. Hernandez-Garcia, F. J. Garcia - Penalvo i R. Theron, »Tap into visual analysis of grouping of activities in eLearning,« *Computers in human behaviour*, June 2015.
- [35] G. AKÇAPINAR i A. BAYAZIT, »MoodleMiner: Data Mining Analysis Tool for Moodle Learning Management System,« *Elementary Education Online*, pp. 406-415 , 2019.
- [36] T. Volarić i H. Ljubić, »Learner and Course Dashboards for intelligent,« u *International Conference on Software, Telecommunications and Computer Networks (SoftCOM)*, Split, Croatia, 2017.
- [37] J. A. Ruipérez-Valiente, P. J. M. Merino, D. Leony i C. Delgado-Kloos, »ALAS-KA: A Learning Analytics Extension for Better Understanding the Learning Process in the Khan Academy Platform,« *Computers in Human Behavior*, Srpanj 2014.
- [38] P. M. Moreno-Marcos, C. Alario-Hoyos, P. J. Muñoz-Merino, I. Estévez-Ayres i C. D. Kloos, »A learning analytics methodology for understanding social interactions in MOOCs,« *IEEE TRANSACTIONS ON LEARNING TECHNOLOGIES*, pp. 442 - 455, 2019.
- [39] D. A. Filvà, M. Alier, M. J. Casany i E. Mayol, »A Learning Analytics tool with hybrid graphical and textual interpretation generation,« *TEEM'16*, 2016.
- [40] R. VIVIAN, K. FALKNER, N. FALKNER i H. TARMAZDI, »A Method to Analyze Computer Science Students' Teamwork in Online Collaborative Learning Environments,« *ACM Transactions on Computing Education*, Veljača 2016.
- [41] V. A. Nguyen, Q. B. Nqujen i V. T. Nqujen, »A Model to Forecast Learning Outcomes for Students in Blended Learning Courses Based On Learning Analytics,« *Association for Computing Machinery, ICSET*, 13-15 August 2018.
- [42] D. M. Naranjo, J. R. Prieto, G. Moltó i A. Calatrava, »A Visual Dashboard to Track Learning Analytics for Educational Cloud Computing,« *Advanced Sensors Technology in Education*, 4 July 2019.
- [43] N. R. Aljohani, A. Daud, R. A. Abbasi, J. S. Alowibd, M. Basher i M. A. Aslam, »An Integrated Framework for Course Adapted Student Learning Analytics Dashboard,« *Computers in Human Behaviour*, March 2018.
- [44] A. Rayón, M. Guenaga i A. Nunez, »Integrating and visualizing learner and social data to elicit higher-order indicators in SCALA dashboard,« *i-KNOW*, 16-19 September 2014.
- [45] J. A. Ruiperez-Valiente, P. J. Munoz-Merino, J. A. Gascon-Pinedo i C. D. Kloss, »Scaling to Massiveness With ANALYSE: A Learning Analytics Tool for Open edX,« *IEEE TRANSACTIONS ON HUMAN-MACHINE SYSTEMS*, 22 October 2016.
- [46] T. Broos, K. Verbert, G. Langie, C. V. Soom i T. D. Laet, »Small data as a conversation starter for learning analytics,« *Journal of Research in Innovative Teaching & Learnin*, 25 September 2018.
- [47] M. Hussain, S. Hussain i W. Zhang, »Mining Moodle Data to Detect the Inactive and Low performance Students during the Moodle Course,« *ICBDR*, 27-29 October 2018.
- [48] A. Tervakari, K. Kuosa, J. Koro, J. Paukkeri i M. Kailanto, »Teachers' learning analytics tools in a social media enhanced learning environment,« *International Conference on Interactive Collaborative Learning (ICL)*, 03-06 December 2014.
- [49] R. Majumdar, A. Akçapınar, G. Akçapınar, B. Flanagan i H. Ogata, »Learning Analytics Dashboard Widgets to Author Teaching-Learning Cases for Evidence-based Education,« u *Companion Proceedings of the 9th International Conference on Learning Analytics and Knowledge* , 2019.
- [50] L. Corrin, A. Bakharia, D. Williams, G. Kennedy, L. Lockyer, S. Dawson, P. De Barba, D. Gasevic i S. Copeland, »Loop: A learning analytics tool to provide teachers with useful data visualisations,« u *Asclite*, Perth, Australia, 2015.
- [51] A. Ramos-Soto, M. Lama, B. V'azquez-Barreiros, A. Bugar'in, M. Mucientes i S. Barro, »Towards Textual Reporting in Learning Analytics Dashboards,« u *International Conference on Advanced Learning Technologie*, 2015.
- [52] J. García-Zubí, U. Hernández-Jayo , P. Orduña, J. Cuadros, I. Angulo-Martínez, G. Alves, V. Serrano i A. Villar, »Dashboard for the VISIR remote lab,« *Experiment@ International Conference*, 12-14 June 2019.
- [53] G. Fenu, M. Marras i M. Meles, »A LEARNING ANALYTICS TOOL FOR USABILITY ASSESSMENT IN MOODLE ENVIRONMENTS,« *Journal of e-Learning and Knowledge Society*, 2017.
- [54] R. Cobos i L. Olmos, »A Learning Analytics Tool for Predictive Modeling of Dropout and Certificate Acquisition on MOOCs for Professional Learning,« *IEEE*, 2018.
- [55] N. R. Aljohani i H. C. Davis, »Learning Analytics and Formative Assessment to Provide Immediate Detailed Feedback Using a Student Centered Mobile Dashboard,« *IEEE*, 2013.
- [56] D. Azcona, I.-H. Hsiao i A. F. Smeaton, »Personalizing Computer Science Education by Leveraging Multimodal Learning Analytics,« *IEEE*, 2018.
- [57] M. Guenaga, J. K. Longarte i A. Rayon, »Standardized enriched rubrics to support competency-assessment through the SCALA methodology and dashboard,« u *Global Engineering Education Conference (EDUCON), 2015 IEEE*, 2015.
- [58] E. van der Stappen, »Workplace learning analytics in gigher engineering education,« u *Global Engineering Education Conference*, Santa Cruz de Tenerife, Canary Islands, Spain, 2018.
- [59] A. R. Groba, B. V. Barreiros, M. Lama, A. Gewerc i M. Mucientes, »Using a Learning Analytics Tool for Evaluation in Self-Regulated Learning,« *IEEE*, 2014.
- [60] S. Ruiz, S. Charleer, M. Urretavizcaya, J. Klerkx , I. Fernández-Castro i E. Duval , »Supporting learning by considering emotions: Tracking and Visualization. A case study,« u *LAK*, Edinburgh, United Kingdom, 2016.
- [61] R. Martinez-Maldonado, A. Pardo, N. Mirriahi i K. Yacef, »The LATUX Workflow : Designing and Deploying Awareness Tools in Technology-Enabled Learning Settings,« u *International Conference on Learning Analytics and Knowledge*, At Poughkeepsie, NY, USA, 2015.
- [62] S. Charleer, A. V. Moere, J. Klerkx, K. Verbert i T. De Laet, »Learning Analytics Dashboards to Support Adviser-Student Dialogu,« *IEEE TRANSACTIONS ON LEARNING TECHNOLOGIE*, 2017.
- [63] I. Dabbebi , J.-M. Gilliot i S. Iksal , »User Centered Approach for Learning Analytics Dashboard Generation,« u *International Conference on Computer Supported Education (CSEDU 2019)*, 2019.

- [64] S. Graf, C. Ives, N. Rahman i A. Ferri, »AAT – A Tool for Accessing and Analysing Students' Behaviour Data in Learning Systems,« u LAK, BANFF, 2011.
- [65] A. Bader-Natal i T. Lotze, »Evolving a learning analytics platform,« u LAK, BANFF, 2011.
- [66] A. Bakharia i S. Dawson, »SNAPP: A Bird's-Eye View of Temporal Participant Interaction,« u LAK, BANFF, 2011.
- [67] K. E. Arnold i M. D. Pistilli, »Course Signals at Purdue: Using Learning Analytics to Increase Student Success,« u LAK, Vancouver, 2012.
- [68] D. Leony, A. Pardo i L. d. I. F. Valentín, »A Learning Analytics Visualization Tool,« u LAK, Vancouver, 2012.
- [69] J. L. Santos, S. Govaerts, K. Verbert i E. Duval, »Goal-oriented visualizations of activity tracking: a case study with engineering students,« u LAK, Vancouver, 2012.
- [70] M. Siadaty, D. Gašević, J. Jovanović, N. Milikić, Z. Jeremić, L. Ali, A. Giljanović i M. Hatala, »Learn-B: A Social Analytics-enabled Tool for Self-regulated Workplace Learning,« u LAK, Vancouver, 2012.
- [71] A. Essa i H. Ayad, »Student Success System: Risk Analytics and Data Visualization using Ensembles of Predictive Models,« u LAK, Vancouver, 2012.
- [72] J. L. Santos, K. Verbert, S. Govaerts i E. Duval, »Addressing learner issues with StepUp!: an Evaluation,« u LAK, Leuven, 2013.
- [73] C. Holman, S. Aquilar i B. Fishman, »GradeCraft: What Can We Learn From a Game-Inspired Learning Management System?,« u LAK, Leuven, 2013.
- [74] S. Aguilar, S. Lonn i S. D. Teasley, »Perceptions and Use of an Early Warning System During a Higher Education Transition Program,« u LAK, Indianapolis, 2014.
- [75] A. Muslim, M. A. Chatti, T. Mahapatra i U. Schroeder, »A Rule-Based Indicator Definition Tool for Personalized Learning Analytics,« u LAK, Edinburgh, 2016.
- [76] M. Ez-zaouia i E. Lavoué, »EMODA: a Tutor Oriented Multimodal and Contextual Emotional Dashboard,« u LAK, Vancouver, 2017.
- [77] C. Herodotou, B. Rienties, A. Boroowa, Z. Zdrahal, M. Hlostá i G. Naydenova, »Implementing Predictive Learning Analytics on a Large Scale: The Teacher's Perspective,« u LAK, Vancouver, 2017.
- [78] X. Fu, A. Shimada, H. Ogata , Y. Taniguchi i D. Suehiro, »Real-time Learning Analytics for C Programming Language Courses,« u LAK, Vancouver, 2017.
- [79] M. Millecamp, F. Gutierrez, S. Charleer, K. Verbert i T. De Laet, »A qualitative evaluation of a learning dashboard to support advisor-student dialogue,« u LAK, Sydney, 2018.
- [80] E. Quincey, C. Briggs, T. Kyriacou i R. Waller, »Student Centred Design of a Learning Analytics System,« u LAK, Tempe, 2019.
- [81] A. L. Dyckhoff, D. Zielke, M. Bültmann, M. A. Chatti i U. Schroeder, »Design and Implementation of a Learning Analytics Toolkit for Teachers,« u Proceedings of the 4th International Conference on Educational Data Mining, Eindhoven, 2011.
- [82] L. Ali, M. Hatala, D. Gašević i J. Jovanović, »A Qualitative Evaluation of Evolution of a Learning Analytics Tool,« Computers & Education, January 2012.
- [83] C. Shi, S. Fu, Q. Chen i H. Qu, »VisMOOC: Visualizing Video Clickstream Data from Massive Open Online Courses,« IEEE Pacific Visualization Symposium, 14-17 April 2015.
- [84] M. Ji, C. Michel, E. Lavoué i S. George, »DDART, a Dynamic Dashboard for Collection, Analysis and Visualization of Activity and Reporting Traces,« u 9th European Conference on Technology Enhanced Learning, Graz, Austria, 2014.
- [85] B. Vesin, K. Mangaroska i M. Giannakos, »Learning in small environments: user-centered design and analytics of an adaptive learning system,« Smart Learning Environments volume 5, Article number: 24 (2018), 16 October 2018.
- [86] F. A. Putra,, H. . B. Santoso i R. F. Aji, »Evaluation of learning analytics metrics and dashboard in a software engineering project course,« Global Journal of Engineering Education, Volume 20, Number 3, 2018, 2018.
- [87] F. Gutiérrez, K. Seipp, X. Ochoa, K. Chiluiza, T. De Laet i K. Verbert, »A learning analytics dashboard for academic advising,« Computers in Human Behavior, 2 December 2018.
- [88] A. Gruzd i N. Conroy, »Designing a Learning Analytics Dashboard for Twitterfacilitated Teaching,« u Proceedings of the Fifth Annual ACM Conference on Learning at Scale, 2018.
- [89] Y. Park i I.-H. Jo , »Development of the Learning Analytics Dashboard to Support Students' Learning Performance,« Journal of Universal Computer Science, vol. 21, no. 1, 2015.
- [90] G. Siemens, »Learning Analytics: The Emergence of a Discipline,« American Behavioral Scientist 57(10) , p. 1380–1400, 2013.
- [91] V. Kovanovic, A. Whitelock-Wainwright i S. Joksimovic, »Counting Clicks is Not Enough: Validating a Theorized Model of Engagement in Learning Analytics,« u Proceedings of the 9th International Conference on Learning Analytics & Knowledge, Tempe, AZ, USA, 2019.
- [92] L. P. Macfadyen i S. Dawson, »Numbers Are Not Enough. Why e-Learning Analytics Failed to Inform an Institutional Strategic Plan,« Educational Technology & Society, pp. 149-163, 2012.
- [93] D. Gasevic, S. Dawson, T. Rogers i D. Gasevic, »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 · January 2016 with 2,096 Reads , January 2016.
- [94] G. Sedrakyan, J. Malmberg, K. Verbert, S. Järvelä i P. A. Kirschner, » Linking Learning Behavior Analytics and Learning Science Concepts: Designing a Learning Analytics Dashboard for Feedback to Support Learning Regulation,« Computers in Human Behavior, 2018.
- [95] A. F. Wise, J. M. Vytasek, S. Hausknecht i Y. Zhao, »Developing Learning Analytics Design Knowledge in the "Middle Space": The Student Tuning Model and Align Design Framework for Learning Analytics Use,« Online Learning , Volume 20 Issue 2, June 2016.
- [96] I. Roll i P. H. Winne, »Understanding, evaluating, and supporting self-regulated learning using learning analytics,« Journal of Learning Analytics, 2(1), 7–12., 2015.
- [97] M. Fernández-Delgado, M. Muñientes, B. Vázquez-Barreiros i M. Lama, »Learning analytics for the prediction of the educational objectives achievement,« u 2014 IEEE Frontiers in Education Conference (FIE) Proceedings,, Madrid, 2014.
- [98] H. Aldowah, H. Al-Samarraie i W. Mohamad Fauzy, »Educational data mining and learning analytics for 21st century higher education: A review and synthesis,« Telematics and Informatics, pp. 13-49, 2019.
- [99] S. Parack , Z. Zahid i F. Merchant, »Application of data mining in educational databases for predicting academic trends and patterns,« IEEE International Conference on Technology Enhanced Education (ICTEE), Kerala, 2012, , pp. 1-4, 2012.
- [100] D. T. Tempelaar, B. Rienties i B. Giesbers, »In search for the most informative data for feedback generation: learning analytics in a data-rich context,« Computers in Human Behavior, 47 pp., p. 157–167, 2015.
- [101] L. Corrin i P. de Barba, »Exploring students' interpretation of feedback delivered through learning analytics dashboards,« B. Hegarty, J. McDonald, & S.-K. Loke (Eds.), Rhetoric and Reality: Critical perspectives on educational technology. Proceedings asciite Dunedin 2014 (, pp. 629-633, 2014.
- [102] D. Carless i D. Boud, »The development of student feedback literacy: enabling uptake of feedback,« Assessment & Evaluation in Higher Education, 43:8, pp. 1315-1325.

- [103] D. Boud i E. Molloy, »Rethinking Models of Feedback for Learning: The Challenge of Design,« *Assessment & Evaluation in Higher Education* 38, p. 698–712, 2013.
- [104] B. . J. Zimmerman i D. Schunk, Motivational sources and outcomes of self-regulated learning and performance, New York, : NY: Routledge., 2011.
- [105] A. Irons, Enhancing learning through formative assessment and feedback, London ; New York : Routledge, 2008.
- [106] R. Cumbley i P. Church, »Is “Big Data” creepy?,« *Computer Law & Security Review*, 2013.
- [107] A. Rubel i K. M. Jones, »Student Privacy in Learning Analytics: An Information Ethics Perspective,« *The Information Society*, 32(2), pp. 143-159, 2016.
- [108] H. Drachsler i W. Greller, »Privacy and Analytics – it's a DELICATE Issue A Checklist for Trusted Learning Analytics,« u *Learning Analytics and Knowledge*, Edinburgh, United Kingdom, 2016.
- [109] P. Ihantola, A. Vihavainen, A. Ahadi, M. Butler, J. Börstler, S. H. Edwards, E. Isohanni, A. Korhonen, A. Petersen, K. Rivers, M. Á. Rubio, J. Sheard, B. Skupas, J. Spacco, C. Szabo i D. Toll, »Educational Data Mining and Learning Analytics in Programming: Literature Review and Case Studies,« *ITiCSE WGR'16, 2015, Vilnius, Lithuania*, 4-8 July 2015.
- [110] A. Pardo i G. Siemens, »Ethical and privacy principles for learning analytics,« *British Journal of Educational Technology*, Vol 45 No 3, p. 438–450, 2014.
- [111] Y. Yoo, H. Lee, I.-H. Jo i Y. Park, »Educational Dashboards for Smart Learning: Review of Case Studies,« *Emerging Issues in Smart Learning*, pp. 110-133, 2014.