

Nadzorna ploča analitike učenja

Čelar, Angela

Master's thesis / Diplomski rad

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, University of Split, Faculty of science / Sveučilište u Splitu, Prirodoslovno-matematički fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:166:297202>

Rights / Prava: [Attribution-ShareAlike 4.0 International/Imenovanje-Dijeli pod istim uvjetima 4.0 međunarodna](#)

Download date / Datum preuzimanja: **2024-11-30**

Repository / Repozitorij:

[Repository of Faculty of Science](#)



SVEUČILIŠTE U SPLITU
PRIRODOSLOVNO – MATEMATIČKI FAKULTET

DIPLOMSKI RAD

NADZORNA PLOČA ANALITIKE UČENJA

Angela Čelar

Split,
srpanj 2019.

SVEUČILIŠTE U SPLITU
PRIRODOSLOVNO – MATEMATIČKI FAKULTET
ODJEL ZA INFORMATIKU

DIPLOMSKI RAD
NADZORNA PLOČA ANALITIKE UČENJA

Diplomski studij: FIZIKA I INFORMATIKA

Studentica:
Angela Čelar

Mentorica:
Izv. prof. dr. sc. Ani Grubišić

Split,
srpanj 2019.

Temeljna dokumentacijska kartica

Sveučilište u Splitu
Prirodoslovno-matematički fakultet
Odjel za informatiku
Ruđera Boškovića 33, 21000 Split, Hrvatska

Diplomski rad

NADZORNA PLOČA ANALITIKE UČENJA

Angela Čelar

SAŽETAK

Ovaj diplomski rad opisuje izradu blok dodatka sustavu e-učenja Moodle, koji se najčešće koristi kao podrška mješovitom učenju, naziva Nadzorna ploča analitike učenja koji koristi metodu stabla odlučivanja i ID3 algoritam za predviđanje ocjena te nadzornom pločom vizualizira napredak kroz kolegij i slabe točke kolegija. Poziva sudionike nastavnog procesa da proaktivno djeluju u svrhu unaprijeđivanja istoga te u svrhu poboljšanja vlastitih učinaka u okolini učenja.

Ključne riječi: analitika učenja, sustav e-učenja, Moodle, Moodle blok dodatak, stablo odlučivanja, ID3 algoritam.

Rad je pohranjen u knjižnici Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu.

Rad sadrži: 53 stranice, 19 grafičkih prikaza i 25 literaturnih navoda. Izvornik je na hrvatskom jeziku.

Mentor: **Izv. prof. dr. sc. Ani Grubišić**, *Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu*

Ocjenjivači: **Divna Krpan**, *viši predavač, Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu*

Izv. prof. dr. sc. Branko Žitko, *Prirodoslovno-matematičkog fakulteta, Sveučilišta u Splitu*

Rad prihvaćen: [Srpanj][2019]

Basic documentation card

University of Split
Faculty of Science
Department of Informatics
Ruđera Boškovića 33, 21000 Split, Croatia

Thesis

LEARNING ANALYTICS DASHBOARD

Angela Čelar

ABSTRACT

This thesis describes development of a block plugin for Moodle, most commonly used e-learning system to support blended learning, called Learning analytics dashboard which uses decision tree method and ID3 algorithm to predict students' grades, and visualizes students' progress on course and course weak spots on a dashboard. Invites attendees of the teaching process to proactively work to improve it and to improve its own learning environment.

Key words: learning analytics, e-learning system, Moodle, Moodle block plugin, decision tree, ID3 algorithm.

Thesis deposited in library of Faculty of science, University of Split

Thesis consists of: 53 pages, 19 figures and 25 references. Original language: Croatian

Mentor: **Ani Grubišić**, *Associate Professor, Faculty of Science, University of Split*

Ocjenjivači: **Divna Krpan**, *Lecturer, Faculty of Science, University of Split*

Branko Žitko, *Associate Profesor, Faculty of Science, University of Split*

Thesis accepted: [July][2019]

Sadržaj

Uvod	8
1 Analitika učenja	10
1.1 Strojno učenje	10
1.2 Rudarenje podataka	13
1.3 Definicija analitike učenja	14
1.3.1 <i>Podaci</i>	15
1.3.2 <i>Analiza i djelovanje</i>	16
2 Nadzorna ploča	19
2.1 Djelovanje nakon analize	22
2.2 Predviđanje uspjeha u online edukaciji	23
3 Stablo odlučivanja	25
3.1 Uvod i prikazivanje stabla odlučivanja	25
3.2 ID3 algoritam	26
3.2.1 <i>Generalizirani algoritam</i>	29
3.3 Pretraživanje prostora hipoteza u učenju stabla odlučivanja	30
3.4 Atributi s kontinuiranim vrijednostima	31
4 Sustavi e-učenja	32
4.1 Sustav e-učenja Moodle	35
4.2 Razvoj blok dodatka	37
4.2.1 <i>block_myplugin.php</i>	38
4.2.2 <i>db/access.php</i>	39
4.2.3 <i>lang/hr/block_myplugin.php</i>	40
4.2.4 <i>version.php</i>	41
5 Nadzorna ploča analitike učenja	42
6 Zaključak	49

7 Literatura	50
Sažetak	52
Summary	53

Popis slika

Slika 1. Pojačano strojno učenje (eng. reinforcement learning)	11
Slika 2. Veza među pojmovima strojnog učenja	12
Slika 3. Dijelovi analitike učenja.....	14
Slika 4. Naučeno stablo odlučivanja za igranje tenisa	26
Slika 5. Tehnologije korištene za isporuku nastavnih sadržaja e-učenja (http://cyprusinternetmarketingservices.com/e-learning)	34
Slika 6. Prikaz broja korištenja Moodle sustava e-učenja u svijetu (https://www.lambdasolutions.net/resources/what-is-moodle/)	36
Slika 7. Datoteka <i>block_myplugin.php</i>	38
Slika 8. Datoteka <i>access.php</i>	40
Slika 9. Sadržaj jezične datoteke <i>lang/hr/block_myplugin.php</i>	41
Slika 10. Sadržaj datoteke <i>version.php</i>	41
Slika 11. Dijagram korištenja - učenik.....	43
Slika 12. Dijagram korištenja - nastavnik	43
Slika 13. Prikaz Nadzorne ploče analitike učenja na stranici kolegija	44
Slika 14. Link za predviđanje ocjene studenta	45
Slika 15. Tortni grafikon koji prikazuje udio predviđenih loših i prosječnih ocjena; nisu predviđene dobre ocjene.....	46
Slika 16. Prikaz rezultata predviđanja učeniku	46
Slika 17. Slabe točke kolegija.....	47
Slika 18. Prikaz vremenske crte kolegija	48
Slika 19. Napredak učenika kroz lekcije i testove	48

Uvod

U današnjem svijetu postoje ogromne količine prikupljenih informacija. Prikupljanje informacija je postalo svojevrsan problem jer zahtjeva velika skladišta podataka, a sve više uviđamo njihovu korist.

Razvijaju se razne tehnike obrade podataka u svrhu zaključivanja o okolini u kojoj se nalazimo. Strojno učenje, rudarenje podataka i umjetna inteligencija su neke od novih tehnologija koje se razvijaju ubrzano u posljednjih nekoliko desetljeća.

Razvojem tehnologija za obradu podataka te zaključivanjem na temelju obrade, dolazi do promjena u svim sferama ljudskog življenja od poslovnog svijeta do načina oblikovanja nastavnog procesa.

Iako su računala superiorna nad ljudima u prepoznavanju uzoraka na velikim količinama podataka, konačna vizualizacija analize se oslanja na ljudsku izvanrednu moć percepcije. Čovjek iz prikladne vizualizacije zaključuje i donosi odluke bolje od računala.

U analitici učenja se koriste tehnologije obrade velike količine podataka, iako se radi o manjoj količini prikupljenih podataka o okolini sudionika nastavnog procesa.

Ovaj rad će kroz pet poglavlja opisati primjenu novih tehnologija obrade velikih količina podataka na analitiku učenja, koncept nadzorne ploče i djelovanja nakon analize podataka o sudionicima nastavnog procesa te dodatak sustavu e-učenja Moodle koji je izrađen, a koristi algoritam Interaktivni dihotomizator 3 (eng. Iterative Dichotomiser 3), skraćenog naziva ID3 algoritam, kao metodu stabla odlučivanja za predviđanje ocjena učenika na e-kolegiju.

U prvom poglavlju se nalazi opis strojnog učenja, rudarenja podataka i njihove primjene u analitici učenja te definicija same analitike učenja.

U drugom poglavlju opisan je koncept nadzorne ploče, poticanje djelovanja na temelju rezultata analize te općenito predviđanje uspjeha u online obrazovanju.

U trećem poglavlju su opisane metode stabla odlučivanja, a na primjeru je detaljno opisan ID3 algoritam koji će se koristiti u izrađenom dodatku sustavu e-učenja Moodle.

U četvrtom poglavlju uz opis sustava e-učenja općenito te sustava e-učenja Moodle, prikazan je i način stvaranja jednostavnog blok dodatka.

Na koncu su u petom poglavlju predstavljene značajke izrađenog blok dodatka koji osim nadzorne ploče ima mogućnost i predviđanja ocjena učenika koji su upisani na e-kolegij.

1 Analitika učenja

U današnjem svijetu smo okruženi raznim izvorima ogromne količine podataka. Ljudi su spoznali vrijednost velike količine podataka te tehnikama rudarenja podataka i strojnog učenja donose zaključke. U poslovnom svijetu je od velike važnosti biti informiran prije djelovanja jer se u većini slučajeva radi o velikim svotama novca, pa se svaki postupak koji će dugoročno poboljšati poslovanje uzima u obzir.

1.1 Strojno učenje

Strojno učenje je grana umjetne inteligencije koja se bavi oblikovanjem algoritama koji svoju učinkovitost poboljšavaju na temelju empirijskih podataka. To je znanstvena disciplina koja daje računalima sposobnost učenja bez da su eksplicitno isprogramirana. Strojno učenje je jedno od danas najaktivnijih i najuzbudljivijih područja računarstva, naročito zbog brojnih mogućnosti primjene. Pomoću algoritama strojnog učenja postoji mogućnost prepoznavanja uzoraka, dubinske analize podataka te mogućnost razvijanja robotike, računalnog vida, bioinformatike i računalne lingvistike¹.

Problemi koje rješava strojno učenje se mogu podijeliti na više načina. Jedan od njih je pristup učenju, a s tog stajališta se strojno učenje dijeli na nadzirano učenje (eng. supervised learning) i učenje bez nadzora (eng. unsupervised learning)².


Nadzirano učenje se odvija tako da su računalu dani primjeri ulaza i željeni izlazi, a cilj je naučiti općenito pravilo koje mapira ulaze u izlaze. Proces treniranja modela se ponavlja dok model ne dosegne željenu razinu točnosti na skupu podataka za treniranje. Primjer nadziranog učenja je rješavanje problema klasifikacije slika gdje računalo dobije skup slika za treniranje, od kojih je svaka točno određena. Na primjer, ako je zadatak klasificiranje slika različitih životinja, u podacima za treniranje sve slike mačke će biti označene da pripadaju klasi mačke.

¹ https://en.wikipedia.org/wiki/Machine_learning

² <https://www.geeksforgeeks.org/getting-started-machine-learning/>

Kada se radi o učenju bez nadzora, ulazni podaci nisu označeni nego je zadatak algoritma da prepozna strukturu ulaznih podataka. Koristi se za klasterizaciju populacije u različite grupe. Može biti samo sebi svrha, odnosno cilj učenja bez nadzora može biti prepoznavanje skrivenih uzoraka u podacima.

Osim stroge podjele na nadzirano i učenje bez nadziranja, postoje i polunadzirano učenje (eng. semi-supervised learning) te pojačano učenje (eng. reinforcement learning)³. Polunadzirano učenje se odvija na vrlo velikom skupu ulaznih podataka koji je samo djelomično klasificiran, a zadatak algoritma je prepoznati i klasificirati ostale podatke u ulaznom skupu. U pojačanom učenju računalni program interagira s dinamičkim okruženjem u kojem mora postići određene ciljeve kao što je vožnja automobila. Program dobiva povratne informacije u obliku nagrada i kazni dok prolazi vlastitim prostorom problema. Na Slici 1. je prikazan proces pojačanog učenja, gdje je računalni program agent koji izvršava akcije te iz okruženja dobiva informacije o stanju i nagradi za odrađenu akciju.



Slika 1. Pojačano strojno učenje (eng. reinforcement learning)

Na temelju željenih izlaza strojnog učenja, problemi se dijele na klasifikacijske probleme i regresijske probleme, klasterizaciju, procjenu gustoće i redukciju dimenzionalnosti⁴.


Klasifikacijom je ulazni skup podataka podijeljen u dvije ili više klasa, a obično se radi o nadziranom učenju modela. Filtriranje neželjenih poruka je primjer klasifikacije gdje su ulazni podaci elektroničke poruke, a klase su "neželjena" i "željena" pošta. Klasifikacija se

³ <https://towardsdatascience.com/what-are-the-types-of-machine-learning-e2b9e5d1756f>

⁴ <https://www.geeksforgeeks.org/getting-started-machine-learning/>

može primijeniti u analitici učenja ako je definirani problem klasificiranje uspjeha studenata po ocjenama.

Potrebno je razjasniti neke pojmove strojnog učenja. Model je specifična reprezentacija naučena iz podataka primjenom nekog algoritma strojnog učenja, a naziva se i hipoteza. Atribut je individualno mjerljivo obilježje podataka, skup podataka koji su ulaz u model. Ciljani atribut je varijabla čija se vrijednost predviđa modelom. Izgradnja modela za predviđanje ciljanog atributa se vrši treniranjem, a model će nakon treniranja mapirati nove podatke u jednu od kategorija na kojima je model treniran. Kada je model izgrađen može primiti skup ulaza za koje će predvidjeti ciljani atribut. Na Slici 2. je grafički prikazana veza među pojmovima strojnoga učenja pri treniranju i predviđanju.



Slika 2. Veza među pojmovima strojnog učenja

1.2 Rudarenje podataka

U doslovnom smislu riječi, rudarenje (engl. mining) je proces vađenja nekog vrijednog materijala ispod površine zemlje, kao što je rudarenje ugljena ili dijamanta. U kontekstu računarstva rudarenje podataka (engl. data mining) se odnosi na vađenje korisnih informacija iz velike količine podataka ili skladišta podataka. Međutim, rudarenje u doslovnom smislu i rudarenje podataka u računarstvu se ne može doslovno preslikati. U slučaju rudarenja ugljena, rezultat vađenja je ugljen, ali u slučaju rudarenja podataka rezultat procesa ekstrakcije nisu podaci.

Rezultat procesa rudarenja podataka su uzorci i znanje koje se stječe na kraju procesa ekstrakcije. U tom smislu, rudarenje podataka je također otkrivanje znanja ili ekstrakcija znanja⁵.

Gregory Piatetsky-Shapiro je 1989. godine uveo izraz “otkrivanje znanja u bazama podataka” (eng. Knowledge Discovery in Databases), ali je “rudarenje podataka” (eng. data mining) postao popularniji naziv u poslovnom i medijskom svijetu. Danas se rudarenje podataka koristi skoro svugdje gdje se velike količine podataka pohranjuju i obrađuju. Banke obično koriste rudarenje podataka za pronalazak potencijalnih klijenata koji bi mogli biti zainteresirani za kreditne kartice, osobne zajmove ili osiguranje. S obzirom na to da banke imaju detalje transakcije i detaljne profile svojih klijenata, analiziraju te podatke i pokušavaju pronaći uzorke na temelju kojih će moći predvidjeti jesu li određeni klijenti zainteresirani za druge usluge, kao što je osiguranje.

Tehnički je rudarenje podataka računalni proces analize podataka iz različitih perspektiva, dimenzija, kutova te kategoriziranja podataka u informacije koje imaju značenje.

U području e-učenja postoje dvije povezane discipline istraživanja, rudarenje podataka u obrazovanju (eng. educational data mining, EDM) i analitika učenja (eng. learning analytics, LA). Iako imaju slične ciljeve i interese razlikuju se ideološki, metodološki i tehnološki. Primjena EDM-a je novo interdisciplinarno polje istraživanja koje je usmjereno na razvijanje metoda istraživanja jedinstvenog tipa podataka koji dolaze iz obrazovnih okruženja. EDM se bavi razvojem, istraživanjem i primjenom računalnih metoda za


⁵ <https://www.geeksforgeeks.org/data-mining/>

otkrivanje uzoraka u velikim skupovima podataka u obrazovanju koje bi inače bilo teško ili nemoguće analizirati radi ogromne količine podataka. LA se bavi mjerenjem, prikupljanjem, analizom i izvještavanjem o podacima učenika i njihovog okruženja u svrhu razumijevanja i optimiziranja procesa učenja i okoline u kojoj se odvija. Za otkrivanje uzoraka neuobičajenog ponašanja tijekom aktivnosti e-učenja koristi se EDM.

1.3 Definicija analitike učenja

Analitika učenja se razvija vrlo ubrzano u zadnjih nekoliko godina, pa nema jedinstvenu definiciju. Postoji nekoliko definicija analitike učenja. Najčešće se uzima definicija analitike učenja s međunarodne konferencije o analitici učenja (International Conference on Learning Analytics & Knowledge, LAK 2011.)⁶ koja glasi:

Analitika učenja je mjerenje, prikupljanje, analiziranje i izvještavanje o podacima o učenicima i njihovim okruženjima u svrhu razumijevanja i optimiziranja procesa učenja te okruženja u kojem se odvija.



Slika 3. Dijelovi analitike učenja

Ključni pojmovi u ovoj definiciji su podaci, analiza i djelovanje. Podaci su primarno oruđe analize te sirovina koja se transformira u analitičke uvide. Analiza je proces uključivanja inteligencije u podatke korištenjem algoritama. Najvažniji aspekt definicije analitike učenja je djelovanje, što je ujedno najviši cilj svakog procesa analitike učenja. Rezultati djelovanja na temelju analize odlučuju o uspjehu ili propasti truda uloženog u analitiku. Slika 3.

⁶ <https://tekri.athabascau.ca/analytics/>

ilustrira usku povezanost podataka i analize te djelovanje kao najvažniji aspekt analitike učenja.

1.3.1 Podaci

Podaci za analitiku učenja su informacije o učeniku, obrazovnom okruženju, interakcijama i ishodima učenja. Prikupljaju se tijekom samog procesa učenja, a dolaze iz raznih izvora kao što su Student Information Systems (SIS), Learning Management Systems (LMS) i drugi izvori.

SIS sustavi sadrže demografske i akademske informacije o učenicima, a LMS podatke o aktivnosti i uspjehu učenika. Izvori informacija mogu biti i širi od LMS-a jer drugi izvori podataka kao što su knjižnični sustavi, mogu pružiti bolji uvid u profil učenika i poboljšati analitiku učenja.

Korištenjem analitike učenja se može utjecati na performanse učenika i same institucije. Odgovarajući uvidi u proces učenja omogućuju nastavniku proaktivno poučavanje i pravovremene intervencije. Također se analitika učenja može koristiti za detektiranje slabo razumljivih dijelova nastave, pa se time stvara prilika za poboljšanje kvalitete nastavnog procesa.

Prije svega nekoliko godina veliki skupovi podataka (eng. big data) je postao važan pojam u poslovnom svijetu. U vrlo kratkom razdoblju tvrtke su našle mnogo novih načina za prikupljanje ogromne količine podataka. Količina podataka je bila toliko silovita da tvrtke nisu znale gdje pohraniti podatke niti što učiniti s prikupljenim podacima. LMS sustavi također prikupljaju ogromne količine podataka koji se mogu koristiti za razumijevanje ponašanja učenika, njihovih preferencija, uspjeh učenika. Upravo ovi podaci se koriste u analitici učenja.

Ovisno o dizajnu kolegija, učenici stupaju u interakciju s nastavnicima, sadržajem ili drugim ljudima. Većina nastavnika ulaže puno truda u oblikovanje kolegija kako bi maksimizirali uspjeh u procesu učenja i poučavanja. Tradicionalni pristup oblikovanju kolegija u svrhu maksimiziranja uspjeha učenika uključuje vrednovanje učenika, analizu ocjena i nastavnikove dojmove koji su najčešće prikupljeni na kraju kolegija. Analiza je u prošlosti bila lošija jer su učenici i nastavnici morali izdvojiti vrijeme i biti voljni dati neke

povratne informacije na kraju kolegija. Također se analiza vršila nakon završetka kolegija što nije davalo mogućnost proaktivnog djelovanja za poboljšanje tijekom samog procesa učenja i poučavanja.

Sve više resursa i nastavnih materijala se premješta u virtualni prostor i dostupni su putem interneta. S prelaskom na internet gomilaju se ogromne količine podataka o učeničkim interakcijama na kolegiju, što je potaknulo razvoj analitike učenja.

Učenici sudjelovanjem u nastavnom procesu koriste online resurse kolegija, izvršavaju zadatke i polažu testove. Pri tome LMS prikuplja značajne podatke o njihovoj aktivnosti koji se mogu koristiti za razumijevanje načina na koji učenici najbolje uče i s kojim dijelovima kolegija imaju najviše problema.

Iako se analitika učenja naziva i „big data u obrazovanju“, radi se o manjem skupu podataka na koje možemo primijeniti iste algoritme strojnog učenja i analize kao i na „big data“.

1.3.2 Analiza i djelovanje

Analiza podataka je proces dobivanja uvida u moguće djelovanje iz prikupljenih podataka. Postoje dva tipa analitike učenja: deskriptivna analitika učenja i prediktivna analitika učenja. Deskriptivna je reaktivna - razumijevanje prošlosti i utjecanje na budućnosti na temelju razumijevanja prošlosti. Prediktivna analitika učenja je proaktivna, odnosno utječe na sadašnjost i stoga poboljšava proces učenja tijekom istoga.

Ako nema djelovanja nakon analize, analitika učenja je beskorisna. Djelovanje zahtjeva vođenje jer svaka akcija koja utječe na proces učenja mora biti odobrena od strane institucije ili škole u kojoj se odvija proces. Kulturološki aspekt djelovanja se manifestira kroz potrebu za promjenom ponašanja svih osoba uključenih u nastavni proces unutar institucije.

Prediktivna analitika učenja se koristi za poboljšanje učinkovitosti učenja. Tipični uzroci neučinkovitog učenja uključuju nedostatak primjene novostečenog znanja, nerelevantan sadržaj kolegija i materijal koji nije u skladu s nastavnim ciljevima.

Prediktivna analitika učenja pomaže prepoznati i ukloniti navedene uzroke kako bi online učenje bilo učinkovitije. Podiže analitiku učenja na novu razinu jer omogućuje razumijevanje mogućih ishoda, a ne samo razumijevanje prijašnjih događaja. Predviđa budući uspjeh učenika. Prediktivna analitika učenja se oslanja na skup metoda za prepoznavanje i mjerenje uzoraka u podacima o učenju te zaključuju o budućem ponašanju. Razlikuje se od deskriptivne analitike jer je fokusirana na individualne učenike što omogućuje jedinstvenu pomoć u savladavanju problema neučinkovitog učenja.

Prediktivna analitika učenja ima najveću korisnost kada uključuje sve sudionike nastavnog procesa, od učenika, preko nastavnika do administratora kolegija.

Konkretno se prediktivna analitika učenja može koristiti tako da se upozore učenici koji slabije napreduju od očekivanog. Ako dajemo učenicima informacije o njihovom napretku tijekom procesa učenja, oni mogu prilagoditi svoje učenje u svrhu mijenjanja navika učenja.

Uspješno korištenje prediktivne analitike učenja zahtjeva pomno planiranje i temeljitu pripremu. Potrebno je proučiti potrebe institucije i dostupne informacije te jasno definirati ciljeve. Postoje mnogi alati prediktivne analitike učenja koje je moguće koristiti, ali se mogu razviti vlastita rješenja ili neki kolaborativni sustav koji uključuje druge institucije u obrazovanju.

Ako se razvijaju i koriste vlastiti alati treba osigurati potrebne resurse koji uz novac i infrastrukturu, uključuju i inženjere softvera te stručnjake koji će održavati alat.

Imajući na umu sve mogućnosti koje pruža analitika učenja te stalno razvijanje online učenja, opisano je nekoliko načina za poboljšanje dizajna kolegija koristeći analitiku učenja⁷:

- **Sadržaj kolegija je potrebno organizirati u manje dijelove** za analiziranje koliko temeljito učenici pristupaju određenim segmentima kolegija. Analizirajući vrijeme provedeno na određenom segmentu moguće je spoznati je li potrebno sve manje

⁷ <https://elearningindustry.com/improving-online-course-design-with-learning-analytics-4-tips>

vremena za savladavanje kasnijih segmenata. Također je moguće uvidjeti koji segmenti zahtijevaju više, a koji manje vremena za savladavanje.

- **Povratne informacije prije završetka kolegija** omogućuju intervencije učenika i nastavnika te poboljšanje vlastite organizacije učenja. Učestalim i detaljnim povratnim informacijama jasniji postaju ciljevi, kriteriji i standardi kolegija. Potiču komunikaciju nastavnika i učenika i motivaciju za učenje te daju priliku približavanja trenutnog učinka željenom cilju.
- **Vidljive informacije o ocjenama tijekom kolegija** mogu pomoći učenicima da bolje uče. Vizualizacija napretka kroz testove, lekcije i zadaće kolegija može dati osjećaj samo zadovoljstva kada učenik može vidjeti promjenu nakon rješavanja provjere znanja.

2 Nadzorna ploča

Pojam nadzorne ploče (eng. dashboard) dolazi iz automobilske industrije gdje je nadzorna ploča istaknuti dio u unutrašnjosti automobila te vozaču omogućuje brzi pregled stanja vizualizacijom određenih metrika, kao što su trenutna brzina, prijeđena udaljenost ili temperatura motora. Općenito je metrika skup mjerila kvantitativnih obilježja entiteta kojim je taj entitet opisan u svojoj okolini.

Nadzorne ploče se u računarstvu koriste na relativno sličan način kao u automobilskoj industriji. Razlika je što nadzorna ploča u automobilu prikazuje trenutne podatke kao što je brzina, a nadzorna ploča u računarstvu prikazuje rezultate analize različitih vrsta podataka. Pojednostavljuje podatke u djeliće vizualnih informacija kako bi bilo lakše razumljivo što dobro radimo, a što treba poboljšati. Kada se ispravno koriste, nadzorne ploče mogu pomoći u donošenju informiranih odluka što može pozitivno utjecati na procese koje analiziraju.

Sve nadzorne ploče se mogu kategorizirati u tri osnovne vrste. *Operacijske nadzorne ploče* su najčešći oblik, a podaci na ploči se osvježavaju u realnom vremenu. Prikazuju podatke važne za svakodnevne aktivnosti, a cilj je sveobuhvatni prikaz performansi sustava. *Analitičke nadzorne ploče* koriste podatke iz prošlosti za prepoznavanje uzoraka i trendova te mogu utjecati na donošenje odluka u budućnosti. *Strateške nadzorne ploče* pomažu približavanju djelovanja stvarnim ciljevima procesa koji analizira na temelju najbitnijih aspekata uspjeha⁸.

Informacije koje podaci sadrže su važan izvor znanja, a dobro dizajnirana nadzorna ploča daje pristup svim važnim podacima. Pristup podacima je olakšan jer se sve nalazi na jednome mjestu i vizualizirane informacije su pregledne. Takva jednostavna organizacija sadržaja nadzorne ploče potiče donošenje boljih odluka jer je interpretacija vizualiziranih podataka brža i prirodnija ljudskom umu. Provedba donesenih odluka treba poboljšati proces, a vizualizacijom nedostataka procesa se bolje usmjerava trud i napor sudionika procesa pa i olakšava donošenje odluka. Najbolje nadzorne ploče su interaktivne, a kada

⁸ https://www.perceptualedge.com/articles/ie/dashboard_confusion.pdf

korisnik može filtrirati prikazane podatke povećava se ili smanjuje broj detalja promatrane metrike⁹.

Nadzorna ploča je u analitici učenja vizualni prikaz najvažnijih informacija koje su potrebne za postizanje jednog ili više ciljeva nastavnog procesa. Prikaz je cjelovit i veličine samo jednog zaslona, kako bi se informacije mogle pregledati u jednom pogledu na nadzornu ploču.¹⁰

Nadzorna ploča analitike učenja prikazuje informacije o učenicima. Nadzorne ploče koje prikazuju različite aspekte procesa učenja pojedinih i svih učenika, omogućuju nastavnicima uvid u sumirane informacije o svim učenicima i o učenicima pojedincima.

Ciljevi nadzornih ploča uključuju dostavljanje povratnih informacija o aktivnostima učenja, poticanje samorefleksije i donošenja odluka, povećavanje uključivanja u nastavni proces i motivacije te smanjivanje odustajanje od kolegija. Najviši cilj je poboljšanje procesa učenja.

Nadzorne ploče primjenjuju tehnike vizualizacije informacija kako bi svim sudionicima u nastavnom procesu omogućile istraživanje i razumijevanje relevantnih informacija o sudioniku u raznim okruženjima.

Tehnike vizualizacije se oslanjaju na izvanrednu ljudsku sposobnost percepcije, prvenstveno perceptualnu sposobnost prepoznavanja uzorka. Vizualizacija informacija je korištenje interaktivnih vizualnih prikaza za pospješenje spoznaje (Card, Mackinlay i Shneiderman 1999). Vizualna analitika stavlja naglasak na stvaranje modela i njegove vizualizacije radi boljeg razumijevanja ili poboljšanja modela (Klerkx, Verbert i Duval, 2017).

Neke nadzorne ploče su usmjerene na grafičku reprezentaciju, neke sadrže tablice i podatke, a druge su fokusirane na prikaz stanja. Nadzorne ploče mogu sadržavati sva tri elementa i tako bolje informirati korisnika.

⁹ <https://www.idashboards.com/blog/2016/09/26/what-is-the-purpose-of-a-dashboard-2/>

¹⁰ https://www.perceptualedge.com/articles/ie/dashboard_confusion.pdf

Postoje različite vrste nadzornih ploča, a dijele se prema različitom pristupu analitici učenja ovisno o ciljanim skupinama i razlozima praćenja dijelova nastavnog procesa. Nadzorne ploče koje podržavaju tradicionalno direktno poučavanje u obliku predavanja tako što omogućuju nastavniku prilagođavanje načina poučavanja i poticanje aktivnosti učenika u nastavi. Postoje nadzorne ploče koje podržavaju grupni rad vizualizirajući aktivnosti individualnih učenika i grupa učenika. Osim poučavanja u učionici, nadzorne ploče mogu podržavati i poučavanje na daljinu u obliku online ili mješovitog učenja (eng. blended learning).

Nadzorna ploča može sadržavati informacije o artefaktima koje su stvorili učenici kao što su blogovi, softver i drugim dijelovima učeničkog portfelja. Također može sadržavati informacije o socijalnim interakcijama osoba uključenih u nastavni proces te informacije o upotrebi dostupnih resursa. Korištenjem softverskog praćenja i praćenjem oka se mogu prikupiti detaljne informacije koji dijelovi resursa se koriste i kako. Važne metrike su i utrošeno vrijeme te rezultati testova koje pokazuju napredak učenja i omogućuju nastavniku pravovremene intervencije, a učenicima daju mogućnost uspoređivanja vlastitog napretka s napretkom kolega.

Vizualizacija može na jedinstven način pomoći u oblikovanju procesa učenja i potaknuti razmišljanje o njegovom napretku stvaranjem nadzorne ploče analitike učenja. Nadzorna ploča analitike učenja daje cjelovit prikaz relevantnih podataka te potiče na djelovanje i istraživanje uzoraka.

Nadzorna ploča nije potrebna na svakom e-kolegiju, ali postoji više razloga za korištenje nadzorne ploče u nastavnom procesu. Nadzorna ploča može biti korisna kada nastavnik želi unaprijediti nastavni proces, ali nije siguran kojim segmentima kolegija treba posvetiti pažnju. Praćenje aktivnosti korisnika ne daje uvijek jasne rezultate analize, pa je vizualizacija rezultata ključan međukorak od analize do djelovanja za poboljšanje procesa učenja. Najvažniji aspekt korištenja nadzorne ploče je ušteda vremena, jer pruža uvid u situaciju iz brzog pregleda svih vizualiziranih podataka.

2.1 Djelovanje nakon analize

Traženje zaključaka iz analize podataka zahtjeva kombinaciju automatizirane obrade podataka koristeći statističke metode ili metode strojnog učenja i efektivne vizualizacije u svrhu omogućavanja ljudskog razumijevanja.

Interakcija čovjeka i vizualnih rezultata analize vodi k odlučivanju koje uzrokuje djelovanje što neizbježno mijenja svijet i stvara nove podatke. Mnogi alati vizualizacije analitike učenja su fokusirani na stvaranje mogućnosti da sudionik u nastavnom procesu može uvidjeti smisao u podacima. Proces donošenja odluka uključuje sve sudionike nastavnog procesa.

Nužno je da sudionik prepozna potrebu za djelovanjem. Prepoznavanje potrebe može biti potaknuto analitikom učenja, automatski kada sustav primijeti okidač (na primjer, ako je mali broj učenika pristupilo resursu koji je označen nužnim za određeni segment kolegija) ili ljudskim prepoznavanjem problema na temelju analize (Dix i Leavesley, 2015).

Međutim, potreba za djelovanjem naglašena analitikom učenja neće potaknuti na djelovanje osim ako nije određena dobit ili vrijednost djelovanja. Može se raditi o dobiti određenog učenika ili široj obrazovnoj dobiti poboljšanjem kolegija. Posebno je važno da dobit bude u budućnosti, što možemo ostvariti prediktivnom analitikom učenja.

Za djelovanje je potrebno uspostaviti kanale komunikacije sudionika nastavnog procesa, koji mogu biti email, sustav za poruke u sklopu LMS-a ili razgovor uživo. Također je potrebno određeno vrijeme za djelovanje i komunikaciju. Potreba za djelovanjem se mora moći zabilježiti za kasnije izvršavanje, što pretpostavlja mogućnost asinkrone komunikacije.

Rezultati analize trebaju biti dostupni u kontekstu učenja kao što su ponavljanje gradiva, predavanje u učionici ili stvaranje plana učenja. Mogućnost stvaranja liste obveza (eng. to do list) može pomoći u organizaciji pri učenju, a fleksibilnost stvaranja liste će pogodovati različitosti stilova učenja.

Vrijeme dostupnosti rezultata analize utječe na djelovanje na nekoliko načina. Učenici mogu na temelju analize učenja na kolegiju od prethodne godine unaprijed planirati svoj angažman te vrijeme potrebno za savladavanje kolegija. Nastavnik može na temelju analize podataka prethodne godine prije početka kolegija poboljšati određene segmente i tako povećati kvalitetu nastavnog procesa.

Prediktivna analiza učenja može dati uvid u napredak za vrijeme trajanja kolegija te ubrzati djelovanje sudionika nastavnog procesa.

Analitika učenja orijentirana na djelovanje, sudionike nastavnog procesa nagnaje da analitiku učenja ne shvaćaju samo kao prikupljanje i vizualizaciju podataka, nego kao prikupljanje i vizualizaciju podataka u svrhu djelovanja u određenom kontekstu.

2.2 Predviđanje uspjeha u online obrazovanju

Mješovito učenja spaja jednu ili više strategija poučavanja s tradicionalnim poučavanjem u učionici. Mnogo kolegija iz programiranja se oslanja na Internet za dostavljanje digitalnih materijala za učenje. Prije nekoliko godina je mješovito učenje postala popularna metoda poučavanja radi razvoja analize podataka i računala.

Za visokoobrazovne ustanove analiza uspješnosti studiranja je vrlo važna jer planiranje kolegija ovisi o odluci treba li povećati ili održati postojeću uspješnost studenata. Uspješnost studiranja uglavnom obuhvaća istraživanja s ciljem pronalaženja prosječnih ocjena, duljine studiranja i sličnih pokazatelja, ali čimbenici koji utječu na postizanje uspjeha nisu dovoljno istraženi.

Modeli koji pomažu pri odluci o prihvaćanju kandidata za upis na studij uglavnom uključuju demografske podatke o studentima, no autori modela naglašavaju značaj uključivanja i drugih informacija o kandidatima (Wilson i Hardgrave, 1995).

Udio učenika koji odustaju od kolegija je puno veći za online kolegije nego za klasične kolegije koji se održavaju u učionici. Identificiranje učenika koji će potencijalno odustati od kolegija ili ga neće položiti je prvi korak u djelovanju koje može rezultirati boljim uspjehom učenika.

Za predviđanje uspjeha se mogu koristiti razni podaci, od demografskih karakteristika učenika do uspjeha na kolegijima koji su preduvjeti za upis. Cilj predviđanja je predvidjeti hoće li učenici uspješno završiti kolegij korištenjem podataka te izdvojiti učenike kojima je potrebna intervencija nastavnika.

Nakon što je postavljen cilj identificiranja studenata koji neće završiti kolegij, potrebno je pripremiti podatke. Podaci se klasificiraju u skupove koji predstavljaju attribute studenta kao što su dobna skupina i akademski uspjeh.

Modeliranje se odvija korištenjem odabrane klasifikacije podataka. Važno je odrediti razlog zašto učenik neće uspješno završiti kolegij kako bi postojala motivacija za djelovanje. Predviđanje ne mora uvijek biti binarno. Uspjeh učenika koji bi trebali uspješno završiti kolegij se također može predvidjeti. Neke tehnike za predviđanje koriste stabla odlučivanja.

3 Stablo odlučivanja

Stablo odlučivanja je jedna od najčešće korištenih metoda za modeliranje u strojnom učenju. Primjenjuju se u problemima klasifikacije, predviđanja, klasterizacije i procjene vrijednosti. Radi se o jednostavnoj i razumljivoj metodi koja slijedi pravila po kojima se stabla brzo i jednostavno konstruiraju. Stablo odlučivanja je nastalo na temelju statističkih metoda raspoznavanja uzoraka.

Najšira primjena je za rješavanje prediktivnih problema uz nadzirano učenje, koji uključuju predviđanje vrijednosti ciljanog atributa u budućnosti. Za predviđanje vrijednosti ciljanog atributa koristi se skup ulaznih atributa te se prediktivnim modelom ulazni atributi mapiraju na ciljani¹¹. Jedan od prediktivnih problema je predviđanje uspjeha u online obrazovanju, gdje ciljani atribut može biti ocjena u budućnosti pa je stablo odlučivanja prikladna metoda za stvaranje modela učenja.

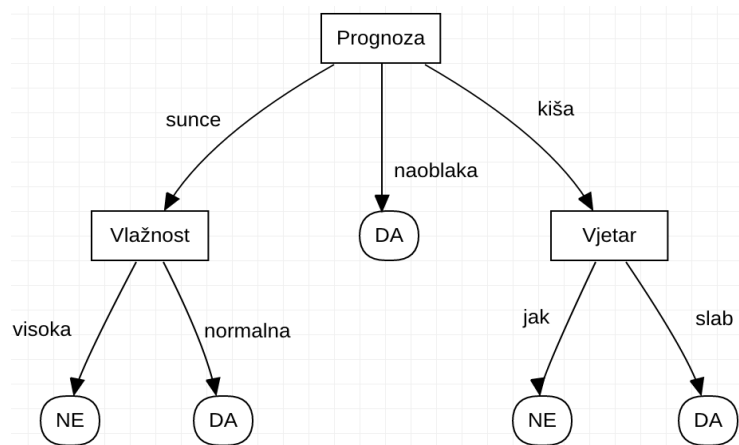
3.1 Prikazivanje stabla odlučivanja

Učenje stablom odlučivanja je metoda aproksimiranja funkcija s diskretnim vrijednostima u kojem je naučena funkcija reprezentirana stablom odluke. Ova metoda je jedna od popularnijih induktivnih algoritama i uspješno se primjenjuje na širokom spektru od učenja dijagnosticiranja medicinskih slučajeva do procjene kreditne sposobnosti osoba koje traže zajam. Problemi u kojima je zadatak klasificirati primjere u jedan od diskretnih skupova mogućih kategorija se često nazivaju problemi klasifikacije (eng. classification problems).

Stabla odluke klasificiraju instance sortirajući ih po stablu od korijena do nekog krajnjeg čvora (lista). Svaki čvor određuje neki atribut instance, a grane koje se granaju iz tog čvora odgovaraju jednoj od mogućih vrijednosti tog atributa.

Instanca se klasificira počinjući u korijenu stabla testiranjem atributa određenog ovim čvorom te kretanjem niz granu koja odgovara vrijednosti atributa. Proces se nastavlja za podstablo u novom čvoru.

¹¹ <http://www.skladistenje.com/stabla-odlucivanja/>



Slika 4. Naučeno stablo odlučivanja za igranje tenisa

Na Slici 4. je prikazano tipično naučeno stablo odlučivanja. Stablo na slici klasificira jesu li subotnja jutra pogodna za igranje tenisa. Na primjer, instanca:

(Prognoza = Sunčano, Temperatura = Vruće, Vlažnost = Visoka, Vjetar = Jak)

će biti sortirana u krajnju lijevu granu stabla odluke te je klasificirana kao negativna instanca. Dakle, stablo će predvidjeti da je IgrajTenis = NE.

Općenito, stabla odlučivanja predstavljaju disjunktiju konjunkcija uvjeta za vrijednosti atributa instance (Mitchell, 1997). Svaki mogući put od korijena do lista odgovara konjunkciji atributa testa, a samo stablo odgovara disjunktiji konjunkcija atributa.

Većina algoritama za metodu strojnog učenja stablom odlučivanja je razvijena iz osnovnog algoritma koji koristi pohlepni algoritam. Stabla odlučivanja su moćne tehnike za klasifikacijske i predikcijske probleme. Modeli su izrađeni u razumljivom obliku pravila koje se poštuju pri klasifikaciji primjera, odnosno predviđanju rezultata.

3.2 ID3 algoritam

Među mnoštvom algoritama strojnog učenja stablom odlučivanja, odabran je Interaktivni dihotomizator 3 (eng. Iterative Dichotomiser 3), skraćenog naziva ID3 algoritam. ID3 algoritam uči stabla odlučivanja konstruirajući ih s vrha prema dnu (eng. top-down) pohlepnom (eng. greedy) pretragom. Sweta Rai, Priyanka Saini i Ajit Kumar Jain (Rai, Saini i Jain, 2014) su proveli opsežno istraživanje gdje su pokazali da se klasifikacijski

algoritam ID3 može koristiti za predviđanje učenika koji su odustali od studiranja. Ovaj algoritam je prikladan za rješavanje problema predviđanja ocjena za vrijeme trajanja kolegija jer ne zahtjeva veliku računalnu moć pri treniranju modela, a u ovom radu će se algoritam izvršavati na poslužitelju i poželjno je da ne zahtjeva posebne resurse. ID3 ne konstruira uvijek točnu klasifikaciju, što je u ovom slučaju manje važno jer se ne radi o konačnim ocjenama učenika, nego predviđanje daje uvid u napredak na kolegiju.

Prvi korak u konstruiranju je odabir atributa koji će se vrednovati u korijenu stabla. Inicijalno, svaki atribut se vrednuje statistički u svrhu određivanja koliko dobro sam klasificira primjere za treniranje modela. Najbolji atribut se odabire i koristi kao provjera za korijen stabla. Dijete čvora korijen se stvara za sve moguće vrijednosti odabranog atributa. Testni primjeri se sortiraju u odgovarajuću djecu korijena. Cijeli proces se ponavlja koristeći testne primjere dodijeljene svakom djetetu kako bi se odabrao najbolji atribut u toj razini stabla odlučivanja.

Opisani postupak formira pohlepnu pretragu u kojoj se algoritam nikada ne vraća da bi ponovno vrednovao prijašnje odluke. Testni primjeri su uzorci za učenje.

Glavna odluka u ID3 algoritmu jest koji će atribut testirati u svakom čvoru stabla. Definiramo statističko obilježje informacijska dobit (eng. information gain) koje mjeri koliko dobro dani atribut razdvaja testne primjere po njihovoj ciljanoj klasifikaciji. ID3 koristi informacijsku dobit za odabir među mogućim atributima u svakom koraku pri izradi stabla odlučivanja.

Za precizniju definiciju informacijske dobiti, također definiramo entropiju koja je mjera za količinu informacije proizvoljnog skupa primjera. U teoriji informacije, poruka je niz simbola odabranih iz abecede, gdje je abeceda konačan skup simbola, a prenosi informacije do prijatelja. U trenutku prije nastanka poruke i na izvoru i na odredištu, postoji neodređenost jer ne znamo koji će simboli biti odabrani. Ta neodređenost je entropija izvora. Kada se radi o klasifikacijskom problemu, entropija određuje najmanji broj bitova informacija koji je potreban za kodiranje klasifikacije proizvoljnog člana skupa S .

Ako skup S sadrži pozitivne (eng. true) i negativne (eng. false) primjere nekog logičkog (eng. boolean) koncepta, entropija od S koja odgovara ovoj klasifikaciji jest:

$$\text{Entropija}(S) = -p_+ \log_2 p_+ - p_- \log_2 p_-$$

gdje je p_+ udio pozitivnih, a p_- udio negativnih primjera u S . U svim proračunima koji uključuju entropiju definiramo $0 \cdot \log(0)$ da je jednako 0.

Na primjer, pretpostavimo da je S skup 14 primjera nekog koncepta, uključujući 9 pozitivnih i 5 negativnih primjera. Tada je entropija skupa S :

$$\text{Entropija}([9+, 5-]) = -(9/14) \log_2(9/14) - (5/14) \log_2(5/14) = 0.940$$

Vrijednost entropije je uvijek između 0 i 1. Ako je podjednako loših, prosječnih i dobrih primjera, entropija je 1, a 0 ako svi članovi skupa S pripadaju istoj klasi.

Na primjer, ako p_+ ima vrijednost 1, primatelj informacija zna da će taj član skupa S biti pozitivan. U tom slučaju nije potrebno obavijestiti prijatelja porukom i entropija je jednaka nuli. U slučaju ako p_+ ima vrijednost 0.5, potreban je jedan bit za određivanje hoće li taj član skupa S biti pozitivan ili negativan. Ako p_+ ima vrijednost 0.8, skup poruka se može kodirati s manje od jednoga bita po poruci dodjeljivanjem kraćih kodova pozitivnim primjerima, a dužih kodova manje vjerojatnim negativnim primjerima.

Općenito, ako ciljani atribut može poprimiti c različitih vrijednosti, entropija skupa S je definirana s:

$$\text{Entropija}(S) = \sum_{i=1}^c -p_i \log_2 p_i$$

gdje je p_i udio skupa S koji pripada klasi i . Logaritam je uvijek s bazom 2 jer je entropija mjera homogenosti primjera, a interpretacija entropije je minimalni broj bitova potreban za kodiranje klasifikacije proizvoljnih članova skupa S .

Informacijska dobit je mjera smanjivanja entropije. Smanjenje entropije uzrokuje razdvajanje testnih primjera po odabranom atributu. Informacijska dobit atributa A u odnosu na skup primjera S je definirana s:

$$Dobit(S, A) = Entropija(S) - \sum_{v \in A} |S_v|/|S| \cdot Entropija(S_v)$$

gdje je S_v podskup od S za koji atribut A ima vrijednost v .

Očekivana vrijednost entropije opisana drugim izrazom u jednadžbi je suma entropija svakog podskupa S_v ponderiranih udjelom primjera (razlomak) koji pripadaju podskupu S_v . Dakle, informacijska dobit je očekivano smanjenje entropije uzrokovano poznavanjem vrijednosti atributa A . Vrijednost informacijske dobiti je broj ušteđenih bitova prilikom kodiranja ciljane vrijednosti proizvoljnog člana skupa S , tako što znamo vrijednost atributa A .

Informacijska dobit je precizno mjera korištena u ID3 algoritmu za odabiranje najboljeg atributa u svakoj razini stabla odlučivanja.

3.2.1 Generalizirani algoritam

Općenit slučaj je kada imamo N primjera razdijeljenih u skupove koji pripadaju klasama c_i . Broj primjera u klasi je N_i . Svaki primjer ima K atributa, a svaki atribut J_k vrijednosti. ID3 postupak za sintezu stabla odluke je:

1. Izračunati početnu vrijednost entropije.

U skupu za učenje, pripadnost klasi je poznata za sve primjere, pa je početna entropija sustava S koji se sastoji od N primjera:

$$Entropija(S) = \sum_{i=1}^c - \left(\frac{N_i}{N} \right) \log_2 \left(\frac{N_i}{N} \right) = \sum_{i=1}^c - p_i \log_2 p_i$$

2. Odabrati atribut koji će biti korijen stabla odluke.

- A. Za svaki atribut A_k , razdijeli originalni skup primjera na skupove prve razine prema vrijednostima a_k od mogućih J vrijednosti atributa A_k . Postoji nk_j primjera u ak_j grani, ali ti uzorci ne moraju nužno biti iz jedne klase.
- B. Za svaki podskup grane nk_j , broj primjera koji pripadaju razredu c_i je $nk_j(i)$. Izračunati entropiju te grane koristeći relaciju:

$$Entropija(S, A_k, j) = \sum_{i=1}^c - \left(\frac{n_{kj}(i)}{n_{kj}} \right) \log_2 \left(\frac{n_{kj}(i)}{n_{kj}} \right)$$

Entropija sustava nakon testiranja atributa A_k je:

$$Entropija(S, A_k) = \sum_{j=1}^J \sum_{i=1}^c \left(\frac{n_{kj}}{\sum_j n_{kj}} \right) \cdot \left[- \left(\frac{n_{kj}(i)}{n_{kj}} \right) \log_2 \left(\frac{n_{kj}(i)}{n_{kj}} \right) \right]$$

C. Informacijska dobit kao rezultat testiranja atributa A_k je:

$$Dobit(k) = Entropija(S) - Entropija(S, A_k)$$

D. Izaberi atribut A_{k_0} za koji imamo najveću informacijsku dobit:

$$Dobit(k_0) > Dobit(k)$$

za svaki k .

E. Atribut A_{k_0} postaje korijen stabla odluke.

3. Izgraditi sljedeću razinu stabla odluke.

Izaberi atribut $A_{k'}$ koji će služiti kao čvor prve razine, takav da nakon testiranja $A_{k'}$ za sve grane dobijemo maksimalnu informacijsku dobit

4. Ponavljati korake 1 do 3.

Nastavljati dok svi podskupovi ne budu iz jedne klase, odnosno entropija sustava ne postane jednaka nuli.

3.3 Pretraživanje prostora hipoteza u učenju stabla odlučivanja

ID3 pretražuje prostor hipoteza za onom koja najbolje odgovara primjerima za učenje. Prostor hipoteza koji pretražuje ID3 je skup svih mogućih stabala odlučivanja. Počinje od praznog stabla prema složenijima koja ispravno klasificiraju primjere za učenje. ID3 možemo promatrati kao pretraživanje prostora hipoteza metodom uspona na vrh (eng. hill-climbing) u kojem je heuristička funkcija informacijska dobit.

Prostor hipoteza ID3 algoritma je kompletan prostor funkcija s konačnim diskretnim vrijednostima atributa. Svaka takva funkcija se može prikazati stablom odlučivanja pa ID3 izbjegava pretraživanje nepotpunog prostora hipoteza koji ne sadrži ciljni koncept.

Odabire uvijek samo jednu hipotezu čime gubi sposobnost određivanja broja alternativnih stabala odlučivanja koji odgovaraju skupu za učenje, a time sposobnost optimiziranja odabira među hipotezama.

3.4 Atributi s kontinuiranim vrijednostima

Početnom definicijom ID3 algoritam je ograničen na korištenje atributa s odgovarajućim skupom diskretnih vrijednosti. Ciljani atribut čija se vrijednost predviđa mora imati diskretne vrijednosti. Također, atributi koji se testiraju u čvorovima odluke u stablu moraju imati diskretne vrijednosti.

Ograničenje vrijednosti atributa koji se testiraju se može lako premostiti podjelom kontinuiranih vrijednosti u diskretni skup intervala vrijednosti.

Za atribut A koji ima kontinuirane vrijednosti se može kreirati novi logički (eng. boolean) atribut A_c koji je istinit ako je $A < c$. Granična vrijednost c se odabire tako da daje najveću informacijsku dobit. Moguće je postavljanje i nekoliko graničnih vrijednosti ako se ne radi o logičkom atributu.

4 Sustavi e-učenja

Prilikom oblikovanja kolegija, nastavnici mogu kombinirati tradicionalnu nastavu s nekim drugim oblikom nastave kao što je online učenje. Za razliku od prikupljanja informacija o učenicima u tradicionalnoj nastavi, online učenje je obično podržano sustavom e-učenja koji prikuplja velike količine podataka o svim sudionicima nastavnog procesa. Na temelju tih podataka se strojnim učenjem može predvidjeti uspjeh učenika na kolegiju.

U nastavku ovog poglavlja će biti opisani sustavi e-učenja, njihova važnost i primjena u obrazovanju te sustav e-učenja Moodle i izrada blok dodatka sustavu Moodle jer je ista vrsta dodatka izrađena za potrebe ovog rada.

Razvoj informacijske i komunikacijske tehnologije, pojava boljih korisničkih sučelja i web 2.0 tehnologija mijenjaju načine na koje se provodi obrazovanje, način života i poslovni svijet općenito. Mijenjaju se ljudske navike komuniciranja, rada i stvaranja te način na koji živimo.

Obrazovanje se mijenja iz tradicionalnih načina poučavanja u moderne načine. Resursi se dijele putem interneta, mijenja se proces učenja i prijenosa znanja nastavnika na učenika. Razvojem pogodnog softvera učenik ne mora nužno biti prisutan na satu kako bi mogao učiti. Danas je učenje na daljinu puno lakše ostvarivo korištenjem sustava e-učenja.

E-učenje je presjek informacijske i komunikacijske tehnologije i svijeta obrazovanja (Zitinski Elias, Baracic, Tomasegovic i Mrvac, 2010). Postoje brojne prednosti e-učenja kada se koristi kao dio dobro planiranog i organiziranog poučavanja, ali nije samo sebi dostatno. Ne zamjenjuje postojeće pedagoške teorije, principe i norme, nego ih nadopunjava.

Postoji više definicija e-učenja, a jednu od najčešće korištenih definira Brandon Hall¹²:

¹² <http://www.brandon-hall.com>

“... nastava koja je isporučena elektronički, u dijelovima ili potpuno putem Web preglednika, putem Interneta ili intraneta, ili putem multimedijских platformi s CD-ROM ili DVD medijem.”


Brandon Hall zagovara upotrebu tehnologija kao faktora poboljšanja e-učenja te pri tom prvenstveno identificira upotrebu Web-a ili intranet Web-a, naglašavajući pri tom vizualno okruženje i interaktivnu prirodu takvog učenja (Stankov, 2010).

U formalnom smislu e-učenje uključuje brojne strategije učenja i poučavanja te elektronička sredstva i uređaje koji podupiru ove aktivnosti. Uključuje mnoge komunikacijske kanale kojima se može obavljati individualna razmjena informacija i stjecanje znanja sudionika takvog procesa. Zasnovano je na elektroničkoj tehnologiji i oblikovano da omogućava stjecanje znanja i vještina kako u formalnom procesu učenja i poučavanja, tako i u neformalnom učenju kao što je prekvalifikacija za nova zanimanja.

Isporuka nastavnih sadržaja za e-učenje se može odvijati asinkrono ili sinkrono. Interakcije nastavnika i učenika se u asinkronom učenju događa povremeno i njihove aktivnosti nisu vremenski sinkronizirane. Sadržaj je dostupan na bilo kojem mjestu, u bilo kojem vremenu i svi učenici napreduju vlastitim tempom. Komunikacija se u sinkronom učenju odvija u realnom vremenu i prema unaprijed dogovorenom scenariju na unaprijed dogovorenom mjestu. Sinkronim e-učenjem se formiraju virtualne učionice gdje nastavnik upravlja aktivnostima u procesu poučavanja.

Tehnologija podržava komunikaciju i interakciju, a nastavne procese i proces učenja čini učinkovitijim. Prezentacija nastavnih sadržaja podržana tehnologijom uklanja vremenske i prostorne prepreke u poučavanju i učenju. Na Slici 5. su prikazane značajke i pripadne vrste sustava za isporuku nastavnih sadržaja u skladu s asinkronim i sinkronim načinima isporuke.

Sustavi e-učenja se oblikuju na različite načine prema različitim isporukama nastavnih sadržaja. Prema tome, sustavi e-učenja se klasificiraju na asinkrone i sinkrone sustave. Na Slici 5. je prikazano koji načini isporuke su pogodni za sinkroni, a koji za asinkroni sustav.



Slika 5. Tehnologije korištene za isporuku nastavnih sadržaja e-učenja
(<http://cyprusinternetmarketingservices.com/e-learning>)

Svaki sustav e-učenja mora uključiti iduće funkcionalnosti koje se temelje na tradicionalnim načelima učenja (Stankov, 2010):

- oblikovanje, spremanje i isporuku nastavnih sadržaja
- testiranje i vrednovanje znanja učenika
- upravljanje ili na višoj razini vođenje procesa učenja i poučavanja
- administriranje sudionika (učenika, nastavnika, stručnjaka područnog znanja).

Temeljni sudionici sustava e-učenja su implicirani ovim funkcionalnostima, a sudionici su učenik, nastavnik, stručnjak područnog znanja i administrator sustava. Potpuni sustav e-učenja u kojem bi bile realizirane sve navedene funkcionalnosti mora imati:

- A. *Autorski alat* (eng. authoring tool) predstavlja okruženje koje omogućuje oblikovanje nastavnih sadržaja, oblikovanje i uređivanje on-line testova i slično.
- B. *Komponentu za ostvarivanje komunikacija posredstvom računala* (eng. computer mediated communication). Komunikacija putem računala se može obavljati kroz diskusijske forume (eng. discussion forums), elektroničkom poštom (eng. e-mail) i razgovornom sobom (eng. chat rooms). Računalno posredovanje omogućava učeniku i nastavniku međusobno komuniciranje i to javno i privatno kao i komunikaciju u prethodno definiranim grupama.
- C. *Navigacijski alat* (eng. navigational tools) je alat za kreiranje unutar definiranog nastavnog sadržaja koji je organiziran na WWW prostoru u vidu sadržajnih modula i lekcija.

- D. *Komponentu za upravljanje kolegijem* (eng. course management) čiju ulogu u tradicionalnom učenju u učionici ima nadzor učenika i njihov učinak što je zadaća nastavnika. U elektroničkom okruženju potrebno je ostvariti podršku različitim vrstama sudionika, a prvenstveno učenicima i učiteljima.
- E. *Komponentu za mjerenje postignuća* (eng. assessment) učenika je najčešće on-line test koji može dati povratnu informaciju o ocjeni neposredno nakon završetka testa.

Potpuni sustav e-učenja će ispuniti sve temeljne funkcionalnosti nastavnog procesa. Funkcionalnosti nastavnog procesa su učenje, poučavanje, testiranje, vrednovanje znanja i administriranje sudionika, što je ispunjeno s ovih pet komponenti potpunog sustava e-učenja.

Nije nužno da svi sustavi e-učenja imaju sve temeljne funkcionalnosti jer su mogući različiti scenariji nastavnog procesa u kojem se kombinira tradicionalna nastava i nastava u okruženju sustava e-učenja (eng. blended learning).

4.1 Sustav e-učenja Moodle


Moodle je sustav e-učenja dizajniran kako bi nastavnicima, administratorima i učenicima omogućio robustan, siguran i integrirani sustav za kreiranje personaliziranih okruženja učenja. Moodle je najčešće korišten sustav za e-učenje u svijetu s desecima tisuća okruženja učenja te više od 90 milijuna akademskih i poslovnih korisnika. Na Slici 6. je prikazan broj slučajeva korištenja Moodle sustava e-učenja u svijetu te je izdvojeno deset zemalja u kojima se Moodle najviše koristi.

Moodle je slobodni softver napisan u PHP programskom jeziku i distribuiran pod GNU (General Public License) licencom. Razvijen je na pedagoškim principima i koristi se za mješovito učenje, učenje na daljinu, obrnutu učionicu (eng. flipped classroom) i druge projekte e-učenja u školama, na sveučilištima, u tvrtkama i drugim sektorima¹³.

Koristi se za kreiranje privatnih web-lokacija s online kolegijima u kojima nastavnici mogu pomoću prilagodljivih upravljačkih značajki postići postavljene obrazovne ciljeve. Moodle (Modular Object-Oriented Dynamic Learning Environment) se može proširivati i oblikovati za različita okruženja za učenje korištenjem dodatka koje razvija Moodle zajednica.

¹³ https://docs.moodle.org/37/en/About_Moodle

Prvu verziju je razvio Martin Dougiamas kako bi pomogao nastavnicima pri stvaranju online kolegija s fokusom na interakciju i kolaboraciju pri izradi sadržaja i njegova kontinuiranog razvijanja, a objavljena je 20. kolovoza 2002. godine. Danas Moodle Project vodi Moodle HQ, tvrtka s 50 programera iz Australije koju financijski podupire mreža od 84 Moodle partner servisnih tvrtki diljem svijeta. Razvitku Moodle sustava e-učenja potpomaže i rad programera slobodnog softvera.



Country	Registrations
United States	9,870
Spain	7,933
Mexico	5,693
Brazil	5,231
United Kingdom	3,301
Germany	3,100
Colombia	2,944
Italy	2,795
India	2,252
France	2,155

Top 10 from registered sites in 228 countries

Slika 6. Prikaz broja korištenja Moodle sustava e-učenja u svijetu
(<https://www.lambdasolutions.net/resources/what-is-moodle/>)

Moodle sadrži širok spektar standardnih i inovativnih dijelova kao što su kalendar ili dnevnik ocjena. Dodaci Moodle sustavu e-učenja su fleksibilan skup alata koji omogućuju korisnicima proširenje značajki stranice.

Korisnici mogu skinuti i instalirati Moodle na web poslužitelju kao što je Apache HTTP Server, a podržani su mnogi sustavi za upravljanje bazama podataka kao što je

PostgreSQL. Moodle se može koristiti na svim operacijskim sustavima koji podržavaju PHP i baze podataka od Windows, preko Linux i Unix do OS X operacijskih sustava.

Pedagoški pristup Moodle sustava e-učenja uključuje konstruktivizam i društveni konstruktivizam u obrazovanju. Naglašava da učenici, a ne samo nastavnici, mogu doprinijeti nastavnom procesu.

Kako je Moodle skup PHP skripti i slobodan softver, korisnik može izrađivati vlastite dodatke sustavu. Dodacima se može poboljšati funkcionalnost sustava te prilagoditi sustav vlastitom sveučilištu.

4.2 Razvoj blok dodatka

Blok je dio sustava e-učenja Moodle koji se može dodati u lijevi, desni ili središnji stupac bilo koje stranice na Moodle-u. Idući opis razvoja blok dodatka Moodle sustavu e-učenja se može primijeniti na verziju Moodle-a 2.0 i svaku noviju inačicu.

Moodle sustav e-učenja ima razvijen stil kodiranja, a sve programere koji izrađuju dodatke sustavu se poziva da poštuju stil čiji zahtjevi se mogu pronaći u dokumentaciji sustava na https://docs.moodle.org/dev/Coding_style. Konzistentan stil kodiranja je važan u bilo kojem projektu, a pogotovo kada je u razvoj softvera uključeno više programera. Standardni stil pomaže osigurati da je kod čitak te razumljiv čime se povećava kvaliteta koda. Praćenje određenog stila kodiranja može smanjiti i mogućnost pogrešaka pri pisanju skripti.

Ime bloka koji će se uzeti za primjer je My Plugin. Dodaci koje posjeduje Moodle sustav se nalaze u direktoriju **moodle** na uređaju na kojem je instaliran sustav. Postoji više vrsta dodataka, a svaka pojedinačna vrsta se nalazi u odgovarajućem poddirektoriju. Blok dodaci se po instalaciji smještaju u poddirektorij **blocks**.

Ako tek razvijamo blok dodatak, potrebno je u poddirektorij **blocks** direktorija **moodle** stvoriti direktorij s nazivom koji odgovara nazivu bloka. U ovom radu naziv direktorija je **myplugin**.

Svaki blok je definiran s četiri PHP datoteke unutar direktorija **myplugin**:

- **block_myplugin.php** - definiranje klase, upravljanje i prikaz blok dodatka
- **db/access.php** - definiranje sposobnosti postavljanja blok dodatka na stranice sustava
- **lang/hr/block_myplugin.php** - jezična datoteka za hrvatski jezik
- **version.php** - informacije o verziji blok dodatka

U nazivu svake od ove četiri datoteke, myplugin odgovara nazivu bloka koji razvijamo.

4.2.1 block_myplugin.php

Ova datoteka sadrži definiciju klase bloka te se koristi za upravljanje blokom i prikaz bloka na zaslonu. Sadržaj datoteke **block_myplugin.php** je prikazan na Slici 7.

```
<?php
class block_myplugin extends block_base{
    public function init(){
        $this->title = get_string('myplugin', 'block_myplugin');
    }

    public function get_content(){

        if ($this->content !== null){
            return $this->content;
        }

        $this->content = new stdClass;
        $this->content->text = 'Sadržaj jednostavnog bloka';
        $this->content->footer = 'Ovdje pišemo zaglavlje...';

        return $this->content;
    }
}
?>
```

Slika 7. Datoteka *block_myplugin.php*

Prva linija koda u definiciji klase bloka koja mora biti imenovana u formatu *block_myplugin*, gdje je *myplugin* naziv bloka koji razvijamo. Klasa sadrži metodu *init()* koja je neophodna za svaki blok, a njezina svrha je dodjeljivanje vrijednosti svim varijablama instanci klase koje treba instancirati.

U ovom jednostavnom primjeru se prikazuje samo naslov u zaglavlju bloka koji je definiran varijablom *\$this->title* u metodi *init()*. *\$this->title* može imati proizvoljnu vrijednost, osim

praznog stringa. Pseudo-varijabla *\$this* je dostupna pri pozivu metoda unutar nekoga objekta. Ovdje je postavljeno čitanje naslova iz jezične datoteke bloka.

Za dodavanje sadržaja bloka koji će se prikazati na zaslonu, potrebno je dodati još jednu metodu klasi. Metoda *get_content()* preko pseudovarijable *\$this* pristupa sadržaju bloka, a definiran je instancom klase *stdClass* koja ima tijelo i zaglavlje.

Tijelu se pristupa s *\$this->content->text*, a zaglavlju s *\$this->content->footer*. Tekst tijela i zaglavlja također može sadržavati HTML, što daje više mogućnosti uređivanja izgleda bloka.

Postoji provjera na početku metode koja vraća trenutnu vrijednost *\$this->content* ako nije jednaka NULL, a ako jest NULL onda stvaramo novi sadržaj. Stvaranje sadržaja bi se pozivalo za svaki blok na Moodle sustavu i može zahtijevati puno vremena, pa je provjera na početku metode *get_content()* mjera štednje vremena.

Ovo nije jedini oblik sadržaja koji blok može prikazivati. Također je moguće stvarati liste i hijerarhijska stabla koji više odgovaraju nekim vrstama sadržaja kao što je kazalo. Vrsta sadržaja koju treba prikazati na bloku određuje hoće li se koristiti lista, tijelo i zaglavlje, stablo ili neki drugi tip konstrukcije.

4.2.2 db/access.php

Datoteka **access.php** je smještena unutar poddirektorija *db* u direktoriju *myplugin*. Sadrži nove sposobnosti koje su stvorene blokom. S Moodle inačicom 2.4 osnovni (eng. core) blokovi imaju sposobnosti *addinstance* i *myaddinstance*.

Ove sposobnosti su dodane kako bi bilo moguće upravljati upotrebom blokova. Sposobnosti *addinstance* i *myaddinstance* bi trebale biti dodane i u nove kastumizirane blokove, a u ovom slučaju u datoteku **blocks/myplugin/db/access.php**. U slučaju da se blok neće koristiti na početnoj stranici korisnika Moodle sustava, tada sposobnost *myaddinstance* ne treba biti dodijeljena niti jednom korisniku, ali svejedno mora biti definirana kako bi se izbjegle greške na nekim stranicama. Na Slici 8. je prikazan sadržaj datoteke **access.php**, a niz *\$capabilities* sadrži obvezne sposobnosti za novi blok.

```

<?php
$capabilities = array(
    'block/myplugin:myaddinstance' => array(
        'captype' => 'write',
        'contextlevel' => CONTEXT_SYSTEM,
        'archetypes' => array(
            'user' => CAP_ALLOW
        ),
        'clonepermissionsfrom' => 'moodle/my:manageblocks'
    ),
    'block/myplugin:addinstance' => array(
        'riskbitmask' => RISK_SPAM | RISK_XSS,
        'captype' => 'write',
        'contextlevel' => CONTEXT_SYSTEM,
        'archetypes' => array(
            'editingteacher' => CAP_ALLOW,
            'manager' => CAP_ALLOW
        ),
        'clonepermissionsfrom' => 'moodle/site:manageblocks'
    ),
);
?>

```

Slika 8. Datoteka *access.php*

4.2.3 lang/hr/block_myplugin.php

Ova datoteka je jezična datoteka za hrvatski jezik bloka. Jezična datoteka može biti i za drugi odgovarajući jezik, a u tom slučaju naziv **hr** direktorija je potrebno preimenovati u odgovarajući jezični kod. Ali svaki blok treba sadržavati i direktorij **lang/en** te su svi jezični direktoriji smješteni u poddirektoriju lang instalacijskog direktorija bloka.

Potrebno je definirati naziv dodatka koji se prikazuje prilikom nadogradnje na novu inačicu dodatka, a njegova vrijednost se postavlja zajedno sa sposobnostima koje su stvorene za dodatak i svim ostalim jezičnim stringovima koji se koriste u bloku. Skripta se ne zatvara završnim tagom “?>” radi problema sa znakovima razmaka koji se mogu pojaviti.

Sadržaj jezične datoteke **block_myplugin.php** je prikazan na Slici 9., a definirani stringovi su redom:

- *pluginname* - naziv blok dodatka koji se prikazuje prilikom nadogradnje na novu inačicu
- *myplugin* - naziv dodatka
- *myplugin:addinstance* - tekst koji se prikazuje prilikom dodavanja bloka

- *myplugin:myaddinstance* - tekst koji se prikazuje prilikom dodavanja bloka na početnu stranicu korisnika

```
<?php
$string['pluginname'] = 'My Plugin';
$string['myplugin'] = 'Jednostavni My Plugin';
$string['myplugin:addinstance'] = 'Dodaj My Plugin';
$string['myplugin:myaddinstance'] = 'Dodaj My Plugin na početnu stranicu';
```

Slika 9. Sadržaj jezične datoteke *lang/hr/block_myplugin.php*

4.2.4 version.php

Datoteka **version.php** sadrži informacije o dodatku, a mogu biti dodani i neki napredni parametri. Sadržaj datoteke je vrlo jednostavan i sadrži definicije samo nekoliko polja koji su potrebni. U ovom dodatku definirana su polja:

- *\$plugin->component*: naziv blok dodatka u formatu **tipdodatka_nazivdodatka**
- *\$plugin->version*: broj inačice dodatka
- *\$plugin->requires*: najniža inačica Moodle sustava koja mora biti instalirana

Pseudovarijabla kojom pristupamo poljima je uvijek *\$plugin* neovisno o vrsti dodatka (eng. plugin). Skripta se ne zatvara završnim tagom “?” radi problema sa znakovima razmaka koji se mogu pojaviti ukoliko je skripta zatvorena u ovoj datoteci. Sadržaj datoteke **version.php** je prikazan na Slici 10.

```
<?php
$plugin->component = 'block_la_dashboard';
$plugin->version = 2019060606;
$plugin->requires = 2017051500;
```

Slika 10. Sadržaj datoteke *version.php*

Brojevi inačica se dogovorno pišu u obliku “YYYYMMDDHH”, a za svaku novu inačicu stavljamo odgovarajući datum i sat.

5 Nadzorna ploča analitike učenja u sustavima e-učenja

Razvojem informacijske tehnologije su danas informacije postale važan resurs. Korištenjem sustava e-učenja prikupljaju se velike količine informacija u obrazovanju, a korištenjem metoda strojnog učenja i rudarenja podataka je moguće iskoristiti potencijal prikupljenih informacija.

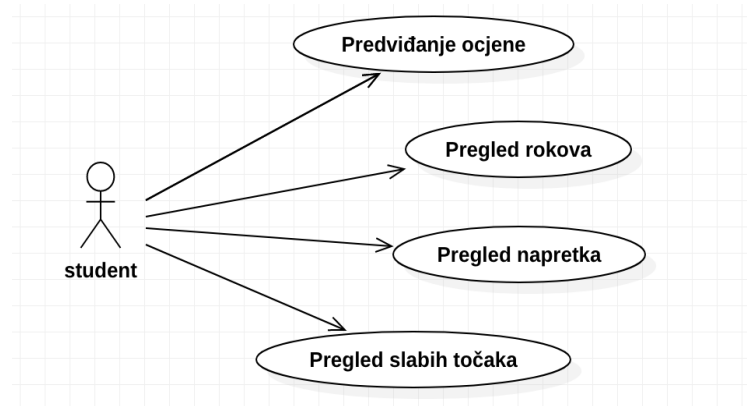
Informacije se analiziraju i na temelju rezultata analize je moguće djelovati u svrhu poboljšanja nastavnog procesa. Sustavi e-učenja naglašavaju ulogu učenika u oblikovanju nastave koji, uz nastavnike, mogu donositi odluke na temelju analitike učenja. Ljudska percepcija je vrlo moćan način poimanja čovjekove okoline, pa rezultati analitike učenja predstavljeni raznim vizualizacijama olakšavaju donošenje odluka i potiču sve sudionike nastavnog procesa na poduzimanje radnji koje će unaprijediti nastavni proces.

Analitika učenja može sadržavati predviđanja o budućim događajima, a u tom slučaju se radi o prediktivnoj analitici učenja. Uspjeh učenika je, kako u tradicionalnom, tako i u online poučavanju jedna od najvažnijih značajki kvalitete nastavnog procesa te se može predvidjeti korištenjem stabla odlučivanja. Stablo odlučivanja je metoda strojnog učenja koja je prikladna za rješavanje problema predviđanja.


Uspjeh učenika se može analizirati predviđanjem ocjena koje će učenici ostvariti na temelju dosadašnjih ocjena na kolegiju. Nije potrebna najveća preciznost prilikom predviđanja, pa se može koristiti algoritam interaktivni dihotomizator 3 (ID3), koji pohlepnom pretragom s vrha prema dnu stvara model strojnog učenja, a ne zahtjeva veliku računalnu moć.

Vizualizacija analitike učenja se može prikazati na nadzornoj ploči koja onda daje brzi pregled uspjeha učenika na kolegiju. Nadzorna ploča može biti dodatak sustavu e-učenja. Ovaj diplomski rad je blok dodatak sustavu e-učenja Moodle koji se može koristiti na e-kolegijima u svrhu vizualizacije analitike učenja. Blok dodatak Nadzorna ploča analitike učenja je koristan kada se doda na stranicu nekog kolegija jer vizualizira rezultate analize podataka relevantnih za kolegij na koji je dodana.

Nadzorna ploča analitike učenja je vizualizirana na dva različita načina, a njezin izgled ovisi o ulozi korisnika na kolegiju. Izgled je drugačiji u svrhu maksimiziranja vrijednosti interakcije korisnika s Nadzornom pločom analitike učenja. Učeniku se prikazuje predviđanje samo njegove ocjene na kolegiju što nosi veći informacijski značaj nego udio ocjena koji se prikazuje nastavniku. Nastavnik ima više koristi od grafičkog prikaza udjela ocjena svih učenika, nego što bi imao od nepregledne tablice s podacima. Također učeniku se uz slabe točke kolegija prikazuje njegov napredak kroz lekcije i testova, a takva vizualizacija može biti sugestivna za djelovanje, odnosno rješavanje testova ili lekcija. Dijagram korištenja koji prikazuje moguće interakcije učenika s nadzornom pločom je prikazan na Slici 11., a interakcije nastavnika s pločom su prikazane na dijagramu na Slici 12.

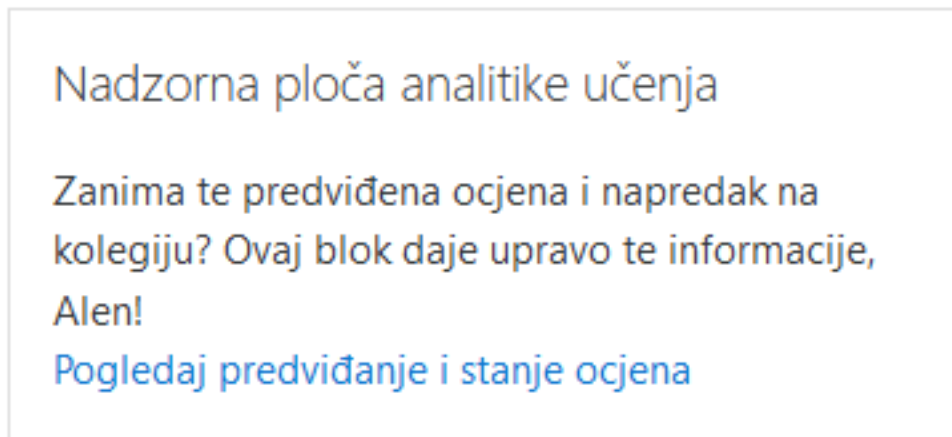


Slika 11. Dijagram korištenja - učenik



Slika 12. Dijagram korištenja - nastavnik

Kada dodamo Nadzornu ploču analitike učenja na kolegij, blok sadrži naziv, pozdrav korisniku koji pregledava kolegij i Moodle link na pregled nadzorne ploče, kao što je prikazano na Slici 13. Korisnikovo ime se dobavlja iz globalne varijable $\$USER$.



Slika 13. Prikaz Nadzorne ploče analitike učenja na stranici kolegija

Moodle link je interni HTML link za navigaciju po dijelovima Moodle web lokacije. Moodle identifikacijski broj je jedinstveni broj koji povezuje element Moodle-a sa zapisom u bazi podataka. Moodle pozove ispravni modul u mod pregledavanja te ga usmjeri na objekt u bazi koji je identificiran s identifikacijskim brojem. Potrebno je navesti lokaciju stranice koju želimo prikazati, a u ovom slučaju lokacija je `'/blocks/la_dashboard/grades_chart.php'`.

Izvor podataka za stvaranje modela i za predviđanje je sustav e-učenja Moodle. Radi se o prediktivnoj analitici učenja jer nadzorna ploča sadrži vizualizacije budućih događaja.

Nadzorna ploča analitike učenja može poboljšati nastavni proces jer ima definirane vrijednosti za sve sudionike kolegija. Učenici mogu spoznati mogućnosti za unaprjeđenje procesa učenja planiranjem i organizacijom, a nastavnici mogu spoznati mogućnost djelovanja za poboljšanje kvalitete sadržaja kolegija te načina vrednovanja znanja.

Klikom na link *"Pogledaj predviđanje i stanje ocjena"* prikazuje se iduća Moodle stranica koja sadrži nadzornu ploču. Nadzorna ploča se sastoji od četiri elementa, link za predviđanje ocjena, vremenska crta kolegija i slabe točke su dostupni svim sudionicima kolegija, a napredak kroz lekcije i ocjene je vidljiv samo studentima.

Svi sudionici kolegija mogu zatražiti predviđanje ocjena klikom na link za predviđanje. U slučaju učenika, predviđanje svoje ocjene može zatražiti klikom na link *"Predvidi moju ocjenu"* koji je prikazan na Slici 14.

Link za predviđanje ocjene/ocjena

Predvidi moju ocjenu

Slika 14. Link za predviđanje ocjene studenta

Nastavniku je prikazan neznatno drugačiji link "*Predvidi ocjene svih studenata*". Razlika u tekstu linka za studenta i nastavnika postoji radi različitosti izgleda iduće stranice Moodlea, što ovisi o ulozi korisnika na kolegiju.


Za rješavanje problema predviđanja ocjena, čije moguće vrijednosti čine diskretan skup mogućnosti, potrebno je odabrati odgovarajuću metodu. U ovom diplomskom radu izabrana je prikladna metoda učenja stablom odlučivanja, a odabrani algoritam je ID3 koji uči stabla odlučivanja konstruirajući ih s vrha prema dnu.

Podatke za učenje, odnosno stvaranje modela, je potrebno uključiti kao datoteku u .csv formatu pri dodavanju bloka na kolegij. Podaci za predviđanje se automatski prikupljaju iz baze podataka moodle prilikom korištenja Nadzorne ploče analitike učenja.

Na temelju podataka o uspjehu učenika na prethodnoj godini održavanja kolegija, korištenjem ID3 algoritma se stvara model strojnog učenja koji se koristi za predviđanje ocjena. Pri predviđanju pojedinačnog i ukupnog uspjeha studenata se uzimaju u obzir podaci o uspjehu na kolegiju u tijeku. Predviđanja se prikazuju na nadzornoj ploči te daju uvid u proces učenja.

Nastavnik može prilagođavati nastavni proces u smislu da identificira moguće odustajanje učenika od kolegija te prilagodi sadržaj učenicima. Predviđene ocjene svih studenata na kolegiju su vizualizirane tortnim grafikonom kao na Slici 15. gdje su prikazani udjeli dobrih, prosječnih i loših predviđenih konačnih ocjena. Učenik može zatražiti predviđanje samo svoje konačne ocjene na kolegiju, čiji rezultat se prikaže u tekstualnom obliku kao na Slici 16.

Raspodjela predviđenih ocjena na kolegiju



Slika 15. Tortni grafikoni koji prikazuju udio predviđenih loših i prosječnih ocjena; nisu predviđene dobre ocjene

Predviđanje ocjena se odvija prema modelu stvorenom ID3 algoritmom stabla odluke. Model se stvara na temelju testnih podataka iz .csv datoteke. Testni podaci su podijeljeni u četiri stupca od koji su tri ocjene iz provjera znanja, a četvrti je konačna ocjena iz kolegija. Stupci ocjena u testnim podacima predstavljaju skup atributa koji se testiraju. Zadnji stupac su ciljane vrijednosti modela, odnosno listovi stabla odluke.

Odabrani atributi su ocjene iz *Lekcija*, *Testova* i *Zadaća* na odabranom kolegiju na Moodle-u. Sva tri atributa imaju kontinuirane vrijednosti jer je vrijednost izražena u kao relativan broj bodova u odnosu na maksimalni broj bodova te aktivnosti.


Using training data to generate Decision tree...
Decision tree using ID3...
Prediction on new data set...

Tvoja predviđena ocjena (mogućnosti: BAD, AVERAGE, GOOD) ---> BAD

Slika 16. Prikaz rezultata predviđanja učeniku

Međutim, moguće je koristiti ID3 algoritam jer se mogu dinamički definirati nove diskretne vrijednosti atributa. Atributima su dodijeljene vrijednosti 0.2, 0.6, 0.9 gdje vrijednost 0.2 imaju sve ocjene manje od 50%, vrijednost 0.9 sve ocjene iznad 80%, a ostalima je dodijeljena vrijednost 0.6. Tim postupkom su razdijeljeni kontinuirani atributi u diskretne skupove intervala.

Osim predviđanja ocjena i vizualizacije predviđenih performansa učenika, sudionici kolegija imaju uvid u slabe točke kolegija. Slabe točke su definirane kao lekcije, zadaće i testovi koji imaju prosječnu prolaznost manju od 50%. Svaka slaba točka je imenovana, kako bi svi sudionici u nastavnom procesu znali kojem dijelu gradiva treba posvetiti više pozornosti. Zadržavanjem pokazivača miša iznad stupca grafikona koji predstavlja određenu slabu točku, pokazuju se dodatne informacije iz kojih je moguće iščitati naziv provjere znanja i stanje atributa *Kritično*, čija vrijednost, kada je jednaka 1, identificira slabe točke.



Slika 17. Slabe točke kolegija

U obzir se uzimaju lekcije, testovi i zadaće jer je na fakultetu najčešća praksa korištenja tih provjera znanja. Primjer vizualizacije slabih točaka je prikazan na Slici 17.

Na temelju identificiranih slabih točaka kolegija, učenik može procijeniti svoju kompetentnost za savladavanje kolegija tako da prepozna koje zahtjevnije segmente kolegija je savladao. Učenik ima mogućnost uspoređivanja vlastitog napretka u procesu učenja u odnosu na napredak njegovih kolega: kompetentniji je ako je riješio slabu točku s dobrom ocjenom, a prosječnih je sposobnosti ako je među studentima koji nisu uspjeli zadovoljiti kriterije identificirane slabe točke.

Nadzorna ploča analitike učenja omogućava svim sudionicima na kolegiju praćenje rokova izvršavanja provjera znanja pomoću vremenske crte. Ako određena zadaća, lekcija ili test ima rok izvršavanja prikazat će se u vremenskoj crti naziv provjere znanja te pripadajući rok izvršavanja kao na Slici 18.

Informacije o rokovima daju mogućnost učenicima da prilagode svoj plan učenja kako bi do roka izvršavanja stekli dovoljno znanja te ostvarili dobar rezultat na provjeri znanja. Također ako se radi o mješovitom učenju, nastavnik može dizajnirati kolegij tako da

neposredno prije provjere znanja u učionici omogućiti ponavljanje gradiva ili razrade nejasnih dijelova nastavnog materijala.


Informacije o nadolazećim testovima i zadaćama koji imaju rok predaje

Naziv provjere ---> Istek roka

probni_test_kolegij ---> 2019-07-15 15:37

Slika 18. Prikaz vremenske crte kolegija

Nadzorna ploča analitike učenja sadrži vizualizaciju učenikovog napretka na kolegiju kao što je prikazano na Slici 19. Stupčastim slaganim grafikonom horizontalne orijentacije je prikazan napredak pojedinačnog učenika kroz lekcije i testove kolegija. Ukupan i broj riješenih lekcija i testova su vizualizirani različitim bojama kako bi učenik percepcijom mogao zaključiti o svom napretku. Plavom bojom je označen ukupan broj lekcija ili testova koje sadrži kolegij, a crvenom broj lekcija ili testova koje je učenik riješio do tog trenutka.



Slika 19. Napredak učenika kroz lekcije i testove

6 Zaključak

Analitika učenja dozvoljava dublje ulaženje u podatke te stvaranje veza koje prosječan ljudski mozak ne može stvoriti, ali je ljudska sposobnost percepcije vrlo moćna tehnika koja se može koristiti za brzo donošenje ispravnih odluka. Traženje smisla u podacima se postiže kombinacijom automatizirane obrade podataka i efektivne vizualizacije.

Tijekom procesa učenja se prikupljaju podaci o učenicima koji dolaze iz sustava e-učenja. Vizualizacija rezultata analize podataka putem nadzorne ploče omogućava proaktivno poučavanje i pravovremeno djelovanje u svrhu poboljšanja nastavnog procesa.

Prediktivna analitika učenja omogućuje razumijevanje budućnosti jer ne daje samo osvrt na prošle događaje i postignute rezultate. Kada se prediktivna analitika učenja koristi za predviđanje ocjena učenika, važno je odrediti razlog zašto učenik neće uspješno završiti kolegij kako bi postojala motivacija za djelovanje.

Djelovanje se potiče automatskim upozorenjem kada sustav primijeti okidač ili ljudskim prepoznavanjem problema na temelju vizualnog prikaza rezultata analitike učenja.

Moodle je najčešće korišten sustav e-učenja, pa je u ovom diplomskom radu razvijen Moodle blok dodatak Nadzorna ploča analitike učenja. Nadzorna ploča nije nužna za svaki kolegij, ali može biti korisna za identificiranje točno određenih dijelova kolegija koje treba unaprijediti kako bi učenici mogli postigli bolji uspjeh u savladavanju kolegija.

7 Literatura

- [1] Mitchell, T. (1997) „*Machine learning*“, McGraw-Hill, 52-78
- [2] Elias, T. (2011) „*Learning Analytics: Definitions, Processes and Potential*“, [https://www.researchgate.net/publication/327220025_Learning_Analytics_Definitions_Processes_and_Potential][26. lipnja 2019.]
- [3] Yupangco, J. (2017) „*4 Ways Predictive Learning Analytics Decreases Ineffective Learning*“ [https://elearningindustry.com/4-ways-predictive-learning-analytics-decreases-ineffective-learning][26. lipnja 2019.]
- [4] Brownlee, J. (2016) „*How To Talk About Data in Machine Learning (Terminology from Statistics and Computer Science)*“ [https://machinelearningmastery.com/data-terminology-in-machine-learning][26. lipnja 2019.]
- [5] Moodle „*Blocks*“ [https://docs.moodle.org/dev/Blocks][26. lipnja 2019.]
- [6] Moodle „*Coding style*“ [https://docs.moodle.org/dev/Coding_style][26. lipnja 2019.]
- [7] Moodle „*About Moodle*“ [https://docs.moodle.org/en/About_Moodle][26. lipnja 2019.]
- [8] Klerkx, J., Verbert, K., Duval, E. (2017) „*Handbook of Learning Analytics*“, Society for Learning Analytics Research, 143-150
- [9] McKown, A. „*What is The Purpose of a Dashboard*“ [https://www.idashboards.com/blog/2016/09/26/what-is-the-purpose-of-a-dashboard-2][26. lipnja 2019.]
- [10] Dix, A., Leavesley, J. (2015) „*Learning Analytics for the Academic: An Action Perspective*“, Journal of Universal Computer Science, 21(1), 48-65
- [11] Miller, J. (2018) „*Predicting Success in Online Education*“ [https://towardsdatascience.com/predicting-success-in-online-education-2b5979fa7016][26. lipnja 2019.]
- [12] Zitinski Elias, P. Y., Baracic M., Tomasegovic, T., Mrvac, N. (2010) „*E-learning and Evaluation in Modern Educational System*“

- [https://www.researchgate.net/publication/268404849_E-LEARNING_AND_EVALUATION_IN_MODERN_EDUCATIONAL_SYSTEM]
[26. lipnja 2019.]
- [13] Stankov, S. (2010) „*Inteligentni tutorski sustavi – teorija i primjena (verzija 2.0)*“, Prirodoslovno-matematički fakultet, Sveučilište u Splitu
- [14] WIKIPEDIA „*Machine Learning*“
[https://en.wikipedia.org/wiki/Machine_learning][26. lipnja 2019.]
- [15] GeeksforGeeks „*Getting started with Machine Learning*“
[<https://www.geeksforgeeks.org/getting-started-machine-learning>][26. lipnja 2019.]
- [16] Heidenreich, H. (2018) „*What are the types of machine learning?*“
[<https://towardsdatascience.com/what-are-the-types-of-machine-learning-e2b9e5d1756f>]
[26. lipnja 2019.]
- [17] GeeksforGeeks „*Data mining*“
[<https://www.geeksforgeeks.org/data-mining>][26. lipnja 2019.]
- [18] Baker, R.S.J., Yacef, K. (2009) „*The State of Educational Data Mining in 2009: A Review and Future Visions*“, Journal of Educational Data Mining, 1(1), 3-17.
- [19] Yupangco, J. (2017) „*4 Tips For Improving Online Course Design With Learning Analytics*“
[<https://elearningindustry.com/improving-online-course-design-with-learning-analytics-4-tips>][26. lipnja 2019.]
- [20] Few, S. (2004) „*Dashboard confusion*“, Intelligent Enterprise, 7(4), 14-15
- [21] Lu, O.H., et al. (2018) „*Applying Learning Analytics for the Early Prediction of Students' Academic Performance in Blended Learning*“ Journal of Educational Technology & Society, 21(2), 220–232
- [22] Brandon Hall Group
[www.brandon-hall.com][26. lipnja 2019.]
- [23] Pandžić, I.S., Bažant, A., Ilić, Ž., Vrdoljak, Z., Kos, M., Sinković V. (2007) „*Uvod u teoriju informacije i kodiranje*“, Element d.o.o., 63-67
- [24] Skladištenje.com (2002) „*Stabla odlučivanja*“
[<http://www.skladistenje.com/stabla-odlucivanja>][26. lipnja 2019.]
- [25] Rai, S., Saini, P. Jain, A. K. (2014). Model for Prediction of Dropout Student Using ID3 Decision Tree Algorithm. International Journal of Advanced Research in Computer Science & Technology, Vol.2, 1(2)), 142-150

Sažetak

Obrazovni sustav se nužno mora mijenjati kako bi uspješno pratio razvoj informacijske i komunikacijske tehnologije, a time i načina na koji ljudi danas percipiraju svoju okolinu i uče. Uvođenjem elemenata online učenja u tradicionalnu nastavu prijenos informacija, učeničkih artefakata i materijala za učenje, obrazovni sustav je ukorak s vremenom globalne mrežne povezanosti.

Ovaj diplomski rad opisuje izradu blok dodatka sustavu e-učenja Moodle, koji se najčešće koristi kao podrška mješovitom učenju, naziva Nadzorna ploča analitike učenja koji koristi metodu stabla odlučivanja i ID3 algoritam za predviđanje ocjena te nadzornom pločom vizualizira napredak kroz kolegij i slabe točke kolegija. Poziva sudionike nastavnog procesa da proaktivno djeluju u svrhu unaprijeđivanja istoga te u svrhu poboljšanja vlastitih učinaka u okolini učenja.

Ključne riječi: analitika učenja, sustavi e-učenja, Moodle, Moodle blok dodatak, stablo odlučivanja, ID3 algoritam.

Summary

Education system must change to successfully stay on top of information and communication technologies development, as ways people perceive their environment and learn have changed. Introducing e-learning elements in traditional classroom with transferring information, students' artefacts and learning materials over the Internet, education system has kept up with global network connectivity era.

This thesis describes development of a block plugin for Moodle, most commonly used e-learning system to support blended learning, called Learning analytics dashboard which uses decision tree method and ID3 algorithm to predict students' grades, and visualizes students' progress on course and course weak spots on a dashboard. Invites attendees of the teaching process to proactively work to improve it and to improve its own learning environment.

Key words: learning analytics, e-learning system, Moodle, Moodle block plugin, decision tree, ID3 algorithm.