



UNIVERZITET U NOVOM SADU  
FAKULTET TEHNIČKIH NAUKA



Vlado Simeunović

**INFORMACIONI MODEL I  
SOFTVERSKA PODRŠKA  
ZA PREDVIĐANJE  
USPJEŠNOSTI STUDIRANJA**

—doktorska disertacija—

Novi Sad 2015.



## SADRŽAJ

<b>1 UVODNA RAZMATRANJA.....</b>	<b>5</b>
1.1 MODEL KORISNIKA.....	12
1.2 OBRAZOVNI INFORMACIONI MODEL.....	16
1.3 ANALITIKA UČENJA .....	25
1.4 PERSONALIZACIJA UČENJA I PAPI I LIP PROFIL STUDENTA.....	26
1.5 EDUPERSON .....	27
1.6 MODELI ZA PREDVIĐANJE USPJEŠNOSTI STUDIRANJA .....	32
1.6.1 Primjena logističke regresije.....	33
1.6.2 Primjena stabala odlučivanja.....	36
1.6.3 Primjena neuronskih mreža .....	37
1.7 CILJ, ZADACI I HIPOTEZA ISTRAŽIVANJA .....	40
<b>2 STANDARDI ZA REPREZENTACIJU PROFILA STUDENATA.....</b>	<b>41</b>
2.1 IEEE LTSC PAPI.....	41
2.1.1 Primjer opisa studenta.....	43
2.2 IMS LIP .....	46
2.2.1 Primjer opisa studenta.....	55
2.3 PRIMJENE STANDARDA ZA REPREZENTACIJU PROFILA UČENIKA.....	63
<b>3 INFORMACIONI MODEL ZA PREDVIĐANJE USPJEŠNOSTI STUDIRANJA .....</b>	<b>64</b>
3.1 MODEL PODATAKA ZA PREDVIĐANJE USPJEŠNOSTI STUDIRANJA .....	64
3.2 METODE ZA PREDVIÐANJE USPJEŠNOSTI STUDIRANJA.....	71
3.2.1 Primjena logističke regresije u predviđanju uspješnosti studenata.....	72
3.3 PRIMJENA STABLA ODLUČIVANJA U PREDVIÐANJU USPJEŠNOSTI STUDENATA U STUDIRANJU.....	76
3.4 PRIMJENA NEURONSKIH MREŽA U PREDVIÐANJU USPJEŠNOSTI STUDENATA U STUDIRANJU.....	77
3.5 ANALIZA DOBIJENIH REZULTATA.....	79
<b>4 SOFTVERSKA PODRŠKA ZA PREDVIÐANJE USPJEŠNOSTI STUDIRANJA .....</b>	<b>81</b>
4.1 PREGLED SISTEMA ZA PODRŠKU UČENJU OTVORENOG KODA .....	81
4.2 SOFTVERSKI ALATI ZA ISTRAŽIVANJE PODATAKA.....	86
4.3 IMPLEMENTACIJA MODELA ZA PREDVIÐANJE USPJEŠNOSTI STUDIRANJA	87
4.3.1 Arhitektura sistema.....	87
4.3.2 Aplikacija za unos profila studenata .....	88
<b>5 ZAKLJUČNA RAZMATRANJA.....</b>	<b>93</b>
<b>A. PRILOG.....</b>	<b>97</b>
<b>LITERATURA .....</b>	<b>102</b>
<b>WEB ADRESE .....</b>	<b>102</b>

<b>BIOGRAFIJA.....</b>	<b>112</b>
<b>KLJUČNA DOKUMENTACIJSKA INFORMACIJA .....</b>	<b>113</b>
<b>KEY WORDS DOCUMENTATION .....</b>	<b>114</b>

# 1 Uvodna razmatranja

Univerziteti danas funkcionišu u veoma složenim i visoko konkurentnom okruženju. Glavni izazov za moderne univerzitete predstavlja dublja analiza sopstvenih performansi, te identifikacija onih posebnosti na kojima će temeljiti sopstvenu strategiju za dalji razvoj i buduće akcije. Menadžmenti univerziteta bi trebali da se više fokusiraju na prikupljanje dovoljne količine relevantnih podataka o upisanim studentima u svrhu definisanja njihovih profila sa akcentom na specifičnosti osobina ličnosti. Baza tih podataka prvenstveno bi omogućila i olakšala modelovanje procesa učenja zasnovanog na jasno definisanim ciljevima i ishodima. Ukoliko se definiše neophodan obim podataka koji će biti dovoljan za kvalitetno donošenje odluka i preduzimanje aktivnosti u cilju poboljšavanja obrazovnog procesa, a koji će se prikupiti prilikom upisa studenata, onda bi se otvorio proces poboljšanja sistema u cjelini. Stoga je ovaj rad i orijentisan na definisanje informacionog modela i softversku podršku predviđanju upješnosti u studiranju.

Jedan od ključnih razloga upravljanja obrazovnim procesom su zahtjevi sve probirljivijeg tržišta rada.

Najvažniji cilj koji se postavlja pred obrazovni sistem svake zemlje jeste da svakom pojedincu treba da bude omogućeno da, kroz sistem obrazovanja, razvije skup znanja, vještina i kompetencija, koje će mu omogućiti učenje, lični razvoj, ispunjenje i permanentno napredovanje kroz život.

Iz društveno-ekonomske perspektive kao najvažniji zadatak obrazovnog sistema nameće se potreba da se pojedincu omogući adekvatno uključivanje na tržište rada, lakše zapošljavanje i sprečavanje socijalne isključenosti. Ispunjavanje ovih ciljeva tiče se ne samo neposredno uključenih u obrazovni sistem, već je naročito značajno i za poslodavce kao korisnike rezultata obrazovanja.

Posmatrano kroz prizmu poslodavca, kao najznačajniji problem obrazovanja, možemo definisati neusklađenost obrazovnog sistema sa potrebama tržišta rada i neadekvatnost sistema da odgovori izazovima koji će se u tom odnosu nesumnjivojavljati u budućnosti.

Neusklađenost ponude i potražnje radne snage se uglavnom ogleda u tome da na tržištu rada postoji potražnja za radnom snagom određenog profila ali obrazovni sistem ne produkuje dovoljan broj takvih profila, velikim dijelom i zbog nezainteresovanosti studenata da se obrazuju po ovim profilima (npr. tehnička zanimanja). Sa druge strane, na tržištu rada često postoji ponuda određenih zanimanja ali ne postoji dovoljna potražnja za radnom snagom tih profila. Drugim riječima, mladi se obrazuju za zanimanja kojima je tržište rada prezasićeno, a gotovo da i nema zainteresovanih za ona koja tržište rada najviše treba.

Naravno, treba biti oprezan u procjenama u pogledu definisanja obrazovnih potreba i upisnih politika samo zbog toga što nema nezaposlenih lica u nekim zanimanjima. S obzirom da se svijet rada mijenja iz dana u dan, pa samim tim i potrebe za određenim zanimanjima podliježu promjenama, tako da trenutne podatke neke zemlje o stanju nezaposlenosti u pojednim zanimanjima treba objektivno sagledati i procijeniti. Primjera radi diplomirani pravnici i diplomirani ekonomisti su najbrojniji na evidenciji nezaposlenih ali se i najbrže zapošljavaju. Buduće tržište rada preferira pokretljivu radnu snagu, odnosno fleksibilnost u odabiru posla i usmjereno prema područjima koja trebaju određene struke i zanimanja. Međutim, ne možemo zapostaviti ni potrebu veće povezanosti tržišta rada i obrazovnog sistema, što će postati imperativ vremena koje je pred nama. Zato je opravdano nastojanje da se društva pripreme za cjeloživotno obrazovanje i svakodnevno sticanje novih znanja i vještina u izabranom zanimanju.

Poseban problem predstavlja činjenica da neusklađenost obrazovnog sistema i potreba poslodavaca postoji i na kvalitativnom nivou. Prema podacima Svjetske banke preduzeća imaju ozbiljne primjedbe u odnosu na kvalifikovanost i obučenost radne snage neposredno po završetku školovanja gdje je posebno istaknut problem srednjeg usmjerjenog obrazovanja koje daje samo usko specijalizovane vještine za potencijalni „prvi posao“ a ne daje dovoljno široko obrazovanje za buduće promjene poslova i zanimanja.

Slično je i u oblasti visokog obrazovanja. U mnogim zemljama širom svijeta vlada mišljenje da postojeći svršeni studenti prvog ciklusa studijane posjeduju potrebne vještine za cjeloživotno učenje niti profesionalne sposobnosti koje su im potrebne kako bi bili uspješni u svojim profesijama (AAGE, 1993; AGR, 995; BHERT, 1992; Candy & Crebert, 1991; Candy, Crebert & O'Leary, 1994; Harvey, 1993; Harvey & Green, 1994; ICAA, 1994; NBETT, 1992). Odnosno, postoji jedan nesklad između onog što poslodavci traže prilikom zapošljavanja i onog što su diplomci stekli.

Postoje brojna istraživanja koja idu u prilog ovom stavu. Na primjer, istraživanja koja su sprovedena u Australiji kako bi se ispitalo

zadovoljstvo poslodavca kvalitetom diplomiranih studenata i njihovim ključnim sposobnostima koje posjeduju na početku svoje karijere, nevezano za profesiju pokazalo je neophodnost veće povezanosti obrazovnog sistema i tržišta rada. Slično je i u našem društvu. Istraživanje sprovedeno 2008. godine (Simeunović, 2008) koje je imalo je za cilj da utvrdi da li postoji korelacija između uspjeha na fakultetu i uspjeha na poslu na uzorku od 102 pripravnika koji su zaposleni na teritoriji filijale Zavoda zapošljavanja u Bijeljini pokazalo je da je savremenih način društvenog života i poslovanja nametnuo potrebu stalnog traganja za najkvalitetnijim ljudskim resursima. Visoki standardi kvaliteta izlaznog proizvoda datog u materijalnoj formi ili kao usluga zahtijevaju stalno odvijanje i usavršavanje radnih procesa bez značajnih odstupanja. Najslabije karike u tom neprekidnom lancu vrlo brzo budu prepoznate i zamijenjene. Ovakav menadžment kvaliteta od rukovodilaca zahtijeva izuzetnu osjetljivost kod odabira kadrova za pojedine radne pozicije. Svaka radna pozicija ima strogo definisane funkcije i kriterijume evaluacije uspjeha, tako da se od zaposlenih traži visoka efektivnost samim stupanjem na radno mjesto. Moguće je da ovdje leži nesklad između formalnog obrazovnog procesa kroz koji prolaze mlade generacije učenika i studenata i visokih zahtjevi u pogledu efikasnosti na radnim mjestima.

Došlo se do zaključka da su nužne promjene u sistemu obrazovanja u smislu veće povezanosti sa svjetom rada i bržeg prilagođavanja društvenim promjenama koje nameće stalni naučno-tehnološki progres.

Razvijene zemlje prepoznaju to da posjedovanje stručne radne snage privlači i investicije u zemlju, ubrzava njen ekonomski rast. Vlade mnogih razvijenih zemalja, poput Australije ili Ujedinjenog Kraljevstva, rade na jačanju uloge institucija visokog obrazovanja i njihovom doprinosu ekonomiji. Australijska Vlada je izradila desetogodišnji plan reformi za sektor visokog obrazovanja i 2009. godine alocirala određenu količinu sredstava za podršku visokom obrazovanju i četvovorgodišnjem istraživanju koje je pokrenuto nakon objavljinjanja *Bradley Review* [Review of Australian higher education: final report, Australian Government, 2008.] dokumenta. Sredstva bi obezbjedila podršku stvaranju visoko kvalitetnog sistema obrazovanja koje bi zadovoljavalo buduće potrebe društva. Finansiranje univerziteta u zavisnosti od pokazanog uspjeha je jedan od načina na koji vlada pokušava obezbjediti da ishodi visokog obrazovanja doprinesu dugoročnoj održivosti koja je potrebna ekonomiji društva. Pomenuti dokument je prepoznao postojanje veze između tercijarnih zanimanja i društveno-ekonomskog napretka.

I pored toga što Australija već nekoliko godina radi na unapređivanju sistema visokog obrazovanja, i dalje postoji potreba da se sistem visokog obrazovanja prilagodi potrebama savremenog društva koje se stalno mijenja usled procesa globalizacije koji su u toku. Postoji i niz nedostataka na kojima se već nekoliko godina radi, poput toga da podjela odgovornosti između Federacije (*Commonwealth-a*) i države još nije najjasnija.

Rezultati istraživanja u Australiji [*Graduate Careers Australia* (GCA), 2015. *Graduate Destinations 2014.*, Melbourne] nisu pokazali ništa novo što i neke druge zemlje već nisu ustanovile, pa je lista osnovnih kriterijuma prilikom zapošljavanja veoma slična kao i u kod nas ili u bilo kojoj državi koja je u procesu prilagođavanja svog obrazovnog sistema novim zahtjevima tržišta rada:

- sposobnost efikasne komunikacije (pisana ili usmena);
- kritičko razmišljanje i analitičke sposobnosti;
- sposobnost rješavanja problema i lateralno razmišljanje;
- želja i motivacija za novim znanjima ;
- posvećenost i stav;
- kulturna tolerancija;

Australija ima veoma dobro razvijen sistema stručnog usavršavanja (*Vocational Education and Training*, VET) koji je razvijen na sekundarnom i tercijarnom nivou. Osim toga, nacionalni sistem kvalifikacija dobro funkcioniše čime je podržan kvalitet i konzistencija prilikom stručnog usavršavanja.

Stanje u našem društvu daleko je nepovoljnije. Poslodavci nerado zapošljavaju mlade ljude bez iskustva zato što je to skupo i ekonomski manje isplativo budući da nisu odmah u potpunosti produktivni. Sa druge strane stručno usavršavanje nije sistemski razvijeno na nivou države. Firme imaju mogućnost da same organizuju edukacije, obuke i dodatna usavršavanja na kojima ljudi stiču konkretna znanja, specifična za tu firmu i oblast rada, ali to košta pa poslodavci nisu dovoljno motivisani da organizuju obuke kojim se usvajaju neke generičke kompetencije, koje bi bile dugoročnije isplative. Između ostalih razloga je i to što često nailaze na prepreke (počev od finansijskih) ili su previše male kako bi pružile efektivnu obuku.

Prepostavke o potrebnim kvalifikacijama su često nepouzdane i ne bi trebale biti osnova za planiranje nego bi ubuduće trebalo više pažnje pridati sistemu koji bi se vodio izbalansiranom odnosu želja studenata i potrebama poslodavaca. Želje studenata i ograničenja samih univerziteta bi određivale broj studenata koji se prima na fakultet. Ovo bi osiguralo to da se obrazovni sektor razvija u skladu sa zahtjevima i potrebama društva.

Kako bi se na tržištu rada osiguralo prisustvo potrebnih profila, odnosno da vještine koje studenti stiču odgovaraju potrebama modernih radnih mesta, poslodavci se podstiču na učestvovanje u razvoju kurikuluma. Posebna pažnja se posvećuje i stručnom usavršavanju i obukama prilikom čega se očekuje da mladi ljudi steknu kako generičke kompetencije tako i posebne kompetencije koje bi zadovoljile konkretne potrebe poslodavca.

Obrazovni sistem koji odgovara potrebama poslodavca treba da više pažnje pridaje razvoju sljedećih sposobnosti kod mladih ljudi:

1. razvijanje kreativnosti i inovativnosti jer će to poslodavcu omogućiti veći uspjeh i konkurentnost firme na tržištu,
2. sposobnost kritičkog i analitičkog razmišljanja, logičkog rezonovanja i donošenja odluka,
3. društvene i interpersonalne vještine i znanja (komunikacije, timski rad, preuzimanje odgovornosti),
4. sposobnost jasnog izražavanja (kako usmenog tako i pisanog),
5. sposobnost primjene znanja u stvarnom životu,
6. sposobnost rješavanja složenih problema (identifikovanje i analiza problema, formulisanje probnih rješenja i njihovo testiranje),
7. sposobnost cjeloživotnog usavršavanja – ekonomski i tehnološki razvoj, posebno razvoj informacionih tehnologija izmjenili su tradicionalne načine rada, zahtjevajući nove i drugačije sposobnosti i vještine – ne samo profesionalno tehničke (*know how*) – prije svega sposobnost produkcije, analize i transformacije informacija i efikasne interakcije i saradnje sa drugima. Učenje postaje doživotna aktivnost.
8. višestruke tehničke vještine i znanja – pošto se zaposleni danas susreću sa većim i raznovrsnijim izazovima, svijet u kome se dešavaju brže promjene u svim njegovim sferama, veliki broj poslodavaca smatra veoma bitnim posjedovanje širokog spektra sposobnosti i znanja pored onog osnovnog, koje je potrebno za određeno radno mjesto koje popunjava.

Promjene u sferi tehnologije i ekonomije su velike, brze, disciplinovane i, prije svega, vođene znanjem. Da bi odgovorilo na te nove zahtjeve, obrazovanje treba da pruži:

- potrebno kognitivno i teorijsko znanje kako bi se omogućilo sticanje stručnih; (profesionalnih) vještina, koje postaju sve više sofisticirane s obzirom na tehnološke promjene u procesu rada;
- široke radne kompetencije koje su potrebne za rad u savremenoj proizvodnji i u sferi usluga i to ne samo za

- trenutnu proizvodnju već za kontinuirano doživotno osposobljavanje i učenje radnika;
- takvo srednje stručno obrazovanje, koje će podržavati samozapošljavanje i jačati produktivnost.

Ovo su sve činjenice koje su odavno poznate i koje potvrđuju neraskidivu veze i zatvoren prirodni ciklus između obrazovnih potreba, sistema školovanja i tržišta rada. Konačno, opredjeljenje za školu ili fakultet, a time i za zanimanje, odnosno posao od koga će se živjeti, na kojem će se graditi društveni status, ugled i karijera – zavisi od realne procjene vlastitih mogućnosti svakog pojedinca, njegovih sposobnosti, interesa, želja, ali i objektivnih okolnosti na koje mladi ljudi veoma malo mogu da utiču. Objektivne okolnosti nameću veliki sistemi te individualne potrebe pojedinaca imaju mali uticaj na njih. Globalno društvo određuje pravce razvoja, male sredine kao što je naša, male države nemaju puno izbora, uspjeće jedino ako pronađu metode da na najbolji način iskoriste svoje prirodne i ljudske resurse.

Ako samo imamo u vidu brzu promjenu obima ljudskog znanja i promjene u sferi rada dolazimo do jednostavne činjenice da je čovjek u svom radnom vijeku primoran barem 6–8 puta da dopunjava, dograđuje svoje prвobitno steчeno znanje za neko zanimanje, a nekada da mijenja čak i zanimanje. Trebamo se oslobođiti iluzije da se školovanjem jednom zauvijek stiče znanje za posao koji je odabran. Očigledno je da se obrazovanje još uvijek razumije kao trošak države, a ne kao investicija u dugoročni i održivi razvoj. Stalne preporuke za obrazovanje u različitim društвima nailaze na različite reakcije nadležnih ali su to obično razvijenija društva ona koja ranije prepoznavaju značaj obrazovanja. Treba imati u vidu da je strukturna neravnотеžа na tržištu rada pojava karakterističна za gotovo sve ekonomije u tranziciji. Ipak, ukoliko je tržište rada spremno za tranzicione procese koji nastaju, utoliko će se brže i efikasnije riješiti problemi obrazovne, kvalifikacione ili lokacijske neusklađenosti ponude i potražnje na tržištu rada.

Kako bi se premostio postojeći jaz između obrazovnog sistema i tržišta rada neophodna je bliža saradnja, partnerstvo i veće uključivanje svih zainteresovanih, poslodavaca, studenata i edukatora.

Neophodno je preduzeti i određene mjere koje će stimulisati poslodavce da ulažu sredstva u unapređivanje znanja zaposlenih radnika kako bi se uključili u procese tehnoloških promjena jer su poslodavci kreatori inovacionih procesa i novih radnih mesta.

Jedan od načina da se ovo postigne jeste formiranje partnerstva sa visokoobrazovnim ustanovama. Osim toga što bi na ovaj način poslodavci mogli neposrednije da budu uključeni u sam obrazovni proces te da utiću na njega tako da se studentima prenose znanja i vještine koje firma traži od kandidata za posao, učenici bi takođe imali

koristi od ovakvog sistema, jer bi ih ovakvo partnerstvo podsticalo da budu uspješniji kada znaju da će samo najbolji imati priliku da se zaposle u jednoj od firmi. Partnerstvo se može ogledati ili u obezbjeđivanju stručne prakse, volontiranja ili pripravničkog staža, ali i stalnog zaposlenja. Ovim će i učenicima biti lakši prelaz sa fakulteta na posao.

Svako uspješno rukovodstvo univerziteta zanima koji su podaci o studentima najbolji prediktori njihovog uspjeha. Ideja da podaci i analize o studentima budu uvijek dostupne u poželjnem formatu, stvorila je potrebu za kreiranjem adekvatnog informacionog sistema sa softverskom podrškom zasnovanom na najnovijim tehnologijama u oblasti softverskog inžinjerstva. Naime, specifični cilj rada usmјeren je na utvrđivanje obrazaca u dostupnim podacima koji bi mogli biti korisni za predviđanje uspješnosti studiranja na univerzitetu na osnovu osobina ličnosti i preduniverzitetskih karakteristika studenata.

Dugoročna predviđanja ostati u biti nepredvidiva, kratkoročna predviđanja složenih sistema nisu samo moguća, ona su bitna. Iz njih se daju izvesti neki tipovi srednjoročnih predviđanja čija tačnost ima visoku vjerovatnoću. Naše sposobnosti prognoziranja izvjesnih aspeka- ta savremenih društava, ekonomija, i tehnologije će se sigurno povećati usprkos posljedicama koje pouzdano predviđanje ima za naše akcije.

Već sada je razvijena tehnologija za prognoziranje mnogih društvenih fenomena, ukoliko ih možemo registrovati u pravom momentu. Theodor Modis, čija knjiga Predictions (Modis, T., 1992.), uspješno sumira slučajeve korisnih i vjerovatnih predviđanja, imenuje tri tipa unutrašnjeg bazičnog reda u raznim vrstama mreža ljudskih interakcija. Svaka od ovih različitih formi može prevladavati u predviđanju u izvjesnom modelu ili u izvjesnom vremenu.

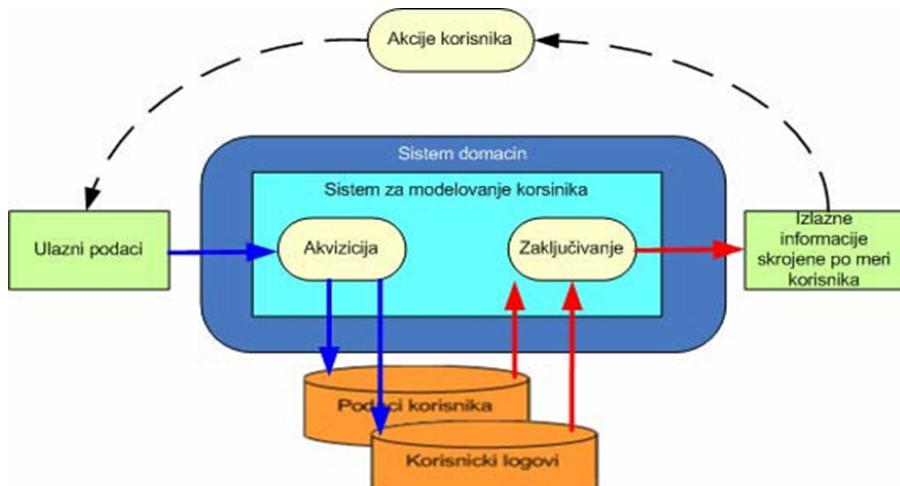
Iako je Modis proveo svoja istraživanja u domenu ekonomije, društvene infrastrukture i tehnologije, rezultati su primjenljivi za većinu sistema. On navodi tri karakteristike svakog sistema i to: unutrašnja varijacija, kriva rasta i ciklične promjene.

Kriva rasta je veoma dobar pokazatelj razvoja nekog sistema. (Modis, T., 1992.) Što neki sistem ima više slojeva, što je vise decentralizovan, to njegov razvoj više sliči organskom razvoju. Svi procesi rasta, bez obzira da li se radi o biološkim, socijalnim ili tehnološkim sistemima dijele neke zajedničke karakteristike. Među njima je tok života koji se može predstaviti krivom S-oblika koja ima spor nastanak, brzi uspon i sporo opadanje. Prediktivna snaga – S-krive je značajna, što pokazuje i njena primjena u neuronskim mrežama kao alatu za predviđanje. Ono što je skriveno pod oblikom S-krivulje je činjenica da prirodni rast slijedi jedan striktni zakon. Ovaj zakon pokazuje da je oblik završetka simetričan obliku početka; zasniva se na empirijskim opažanjima hiljada slučajeva. Teorijska postavka funkcije je poznata te se na osnovu nje može izračunati vrijednost u svakoj tački.

Jedan od najvažnijih ciljeva obrazovanja uopšte, je da zadovolji potrebe studenata u kontekstu opštih ciljeva propisanih u kurikulumu. Kvalitet visokog obrazovanja, posmatran kroz prizmu visokoškolske institucije, podrazumijeva pružanje uslugakojeće zadovoljiti potrebe studenata, akademskog osoblja, i drugih učesnika u obrazovnom sistemu. Učesnici u obrazovnom procesu, ispunjavajući svakodnevne obaveze kroz odgovarajuće aktivnosti, stvaraju ogromnu količinu podataka koji bi trebalo da se na adekvatan način prikupljaju, a zatim integrišu i koriste. Ukoliko se prikupljeni i obrađeni podaci pretvore u znanje onda od njih ima korist cijelokupna akademska zajednica.

## 1.1 Model korisnika

Potreba modelovanja ponašanja korisnika uočena je sedamdesetih godina dvadesetog vijeka. Najranija istraživanja u modelovanju korisnika vršena su u kontekstu istraživanja sistema koji su omogućavali dijalog sa korisnikom upotrebom prirodnog jezika. Kobsa, Koenemann, i Pohl (Kobsa, A., Wahlster, W., 1989) su predstavili teoretski jednu od najpotpunijih specifikacija korisničkog modela. Model daje odgovor na pitanje koje podatke o korisniku sistem treba da prikuplja i da čuva u cilju personalizacije servisa i sadržaja koje sistem nudi.



Slika 1.1. Specifikacija korisničkog modela (Kobsa, Koenemann, i Pohl, 2001.)

Korisnički podaci mogu se grupisati u dvije velike cjeline. Podaci koji opisuju socialno-demografske i psihološke karakteristike korisnika (podaci o korisniku) i podaci o korisnikovim akcijama. Prva grupa podataka ima statičku prirodu (manje su podložni promjenama) i predstavljaju personalne karakteristike korisnika. Ovi podaci su

generalni – njima se opisuje bilo koji tip korisnika u bilo kom tipu sistema. Podaci o korisniku su potpuno nezavisni od sistema i može se slobodno reći da predstavljaju korisnikov portfolio, sastavljen na eksplicitan način (popunjavanjem formulara, upitnika i anketa). Ovi podaci su najčešće i transparentni za različite dijelove sistema koji ih koriste, pa čak i za spoljnje korisnike (druge sisteme).

Tabela 1.1. Model korisnika (Kobsa, Koenemann i Pohl, 2001)

<b>KORISNIČKI MODEL</b>		
Podaci o korisniku	Podaci o korišćenju sistema	
	Posmatranokorišćenje	Regularnost korišćenja
<ul style="list-style-type: none"> <li>• Demografski podaci</li> <li>• Znanje, vještine, navike, ciljevi</li> <li>• Sposobnosti, osobine ličnosti, interesovanja</li> </ul>	<ul style="list-style-type: none"> <li>• Selektivne akcije</li> <li>• Povremeno posmatranje ponašanja</li> <li>• Mjerenje</li> <li>• Ostale konfirmatorne akcije</li> </ul>	<ul style="list-style-type: none"> <li>• Frekvencija korišćenja</li> <li>• Korelacija situacija - akcija</li> <li>• Redoslijed akcija</li> </ul>

Demografski podaci obuhvataju osnovne generalije kao što su ime i prezime, adresa stanovanja, region, država, pol, obrazovanje, porodični status, primanja itd. Znanje, vještine, navike i ciljevi predstavljaju potvrđene kompetencije iz prethodnog perioda neophodne za predstojeće akcije. Kognitivne i konatne karakteristike ličnosti predstavljaju najznačajnije karakteristike svakog pojedinca. One mogu biti jedan od presudnih prediktora za predviđanje uspješnosti u svakom poslu, ali i podatak za druge korisnike sistema.

Ciljevi i planovi korisnika mogu biti vrlo problematični. Korisnik može da koristi sistem bez jasnog plana ili cilja. Ovi podaci su vrlo važni za edukativne sisteme, jer je potrebno da korisnik (student) shvati i usvoji zadate obrazovne ciljeve i planove njihove realizacije. Model takođe podržava podatke koji omogućavaju praćenje ponašanja korisnika u toku eksploatacije sistema. Ti podaci mogu biti direktno posmatrani i zapisani, ili se do njih može doći na osnovu opserviranih podataka. Postoji veliki broj tipova interakcija korisnika sa sistemom.

Selektivne akcije predstavljaju najčešće korišćene akcije, koje mogu poslužiti za prepoznavanje korisnikovih interesovanja. Na primjer, selekcijom linkova korisnik zapravo vrši navigaciju kroz informacioni prostor aplikacije. Sistem na osnovu ostvarenih putanja može da donese zaključak o interesovanjima i motivima korišćenja sistema. Selektivne akcije mogu da omoguće prepoznavanje neznanja koncepata, naročito u tehnološkom smislu (aspekti učenja i korišćenja sistema).

Prepoznavanje preferenci je treća prednost praćenja selektivnih akcija. Izborom proizvoda koji se razlikuju u dizajnu, umjetničkih djela, eksponata, fotografija, specifičnih grafičkih okruženja, sistem može da prepozna estetska mjerila, stil i ukus krajnjeg korisnika.

Povremeno posmatrano ponašanje predstavlja način da sistem na osnovu mjerena vremena korisnikovog zadržavanja na stranici procjeni njegovu zainteresovanost prezentovanim materijalom. Ovo mjerjenje je diskutabilno jer aplikacija koja je serverska nije u mogućnosti da registruje sve mjerodavne akcije korisnika. Iz tog razloga uvodi se klijentska aplikacija (dio sistema koji se izvršava na korisničkom računaru), koja treba da snima ponašanje korisnika i šalje podatke o tome serverskoj aplikaciji. Na primjer, 'Da li prozor aplikacije ima fokus?', 'Da li je minimiziran?', 'Da li je korisnik ispred računara?' i druga slična ponašanja. Vrlo je teško implementirati ovakav način opserviranja korisnika (zahtjeva saglasnost korisnika, sinhronizaciju sa serverskom aplikacijom, intenzivnu interakciju između klijentske i serverske strane, instaliranje komponente na klijentovom računaru i sl.), i najčešće odvraća korisnika od korišćenja sistema (ugrožavanje privatnosti, frustriranost ograničavanjem akcija). Zbog toga podaci prikupljeni na ovaj način imaju vrlo negativnu konotaciju u edukativnim sistemima, izuzev kada su neophodni (na primjer, kontrolisanje ponašanja studenata u toku proveravanja).

Mjerena se koriste u nekim sistemima, radi omogućavanja korisnicima da ocjenjuju sistemske resurse (dokumenta, proizvode, nove articlje i sl.).

Za edukativne sisteme, ovaj mehanizam je vrlo popularan u procesima evaluacije sistema, nastavnih materijala, predavanja, nastavnika.

Pored navedenih (mjerena, ocjenjivanja, potvrda izbora) postoje i druge konfirmatorne akcije (slanje poruka, elektronska pošta, učešće na forumima i diskusionim grupama, upis bilješki, preuzimanje materijala i sl.), koje mogu biti predmet bilježenja i mjerena radi profilisanja korisnika.

Pored direktnih podataka, sistem može da izvede zaključke o korisniku i indirektno, na osnovu statistički obrađenih podataka. Kategorizacija događaja i mjerjenje njihove frekventnosti vjerovatno predstavlja jedan od najčešće korišćenih načina procesiranja. Mjeranjem frekventnosti dobijaju se pouzdani podaci o interesovanjima i preferencama korisnika.

Korelacija situacija-akcija otkriva uzročno-posljedične veze u ponašanju korisnika. Različiti parametri se mogu mjeriti na ovaj način: korisnikov stil rada (učenja), stepen motivacije pri korišćenju sistema, spretnost i vještina u korišćenju sistema, nivo znanja korisnika u oblasti od interesa.

Redosled akcija se najčešće analizira radi preporuka i optimizovanja navigacije u informacionom prostoru, radi predikcije budućih akcija korisnika na osnovu redoslijeda proteklih, i radi preporuka akcija na osnovu redoslijeda akcija drugih korisnika.

Različite grupe korisnika posmatraju obrazovne informacije iz različitih uglova i u skladu sa njihovom sopstvenom misijom, vizijom i ciljevima postavljaju zahtjeve informacionom sistemu. Naprimjer, znanje koje je otkriveno putem *data mining*-a može biti korišteno ne samo da nastavnicima pomogne u organizaciji i planiranju nastave, razumijevanju procesa učenja učenika i poboljšanju ukupne dinamike nastavnog procesa (izbor oblika, metoda, oblika komunikacije, oblika vrednovanja i sl.), nego i kao podrška misaonim aktivnostim studenata u samom procesu učenja (korišćenje informacija, izbor strategije učenja, korišćenje vremena) i da obezbijedi povratnu informaciju za učenike u pogledu njihove uspješnosti.

Informacioni sistem može poslužiti za personalizaciju klasičnog ili e-učenja; može da sugerira učeće aktivnosti, da preporuči dodatne resurse i zadatke studentuma kako bi se njihovo učenje više unaprijedilo; za razmjenu zanimljivih iskustava učenja za studente; da predloži odbacivanje nepotrebnih sadržaja u cilju optimizacije učenja, da skraćuje pretragu ili predlaže linkove, da podsjeća na kurseve, relevantne diskusije, knjige itd.

Informacioni sistemi nastavnicima služe da dobiju objektivne povratne informacije o instrukcijama; da se analizira učenje i ponašanje studenata; da se otkrije kojim studentima je potrebna podrška; da se predvide performanse studenata; da se studenti klasifikuju u grupe; da se otkriju kako pravilni tako i nepravilni obrasci u učenju studentata; da se otkriju najčešće greške; da se utvrde najefektivnije aktivnosti; da se poboljša adaptacija i prilagođavanje kurseva itd.

Kreatorima kurikuluma informacioni sistemi i povratne informacije mogu poslužiti za redefinisanje ciljeva i ishoda učenja, za preispitivanje kompetencija, za procjenu predloženog obima i strukture nastavnih sadržaja, za njegovu evaluaciju u pogledu efikasnosti u dostizanju projektovanih ciljeva učenja, da se automatski sačini model tutora; za nadogradnju informacionog sistema, za predlaganje novih zakonskih rješenja, za razvijawе specifičanog data mining alata za obrazovne svrhe itd.

Rukovodstvu univerziteta koje je najodgovornije za odvijanje obrazovnog procesa, informacioni sistem treba da posluži kao sredstvo za donošenje odluka. Ovdje se misli i na alate za donošenje odluka, kao i na neophodne informacije koje se trebaju skladištiti i čuvati u bazama podataka bez obzira na to koji akter obrazovnog procesa ih kreira. Da bi analitički alati mogli biti od koristi neophodno je da baze podataka budu konfigurisane na način da mogu na svaki upit pružiti adekvatan odgovor. Analitički alati bi trebali automatski generisati vizuelizovane i

kvantitativne pokazatelje pojedinih etapa u približavanju definisanim strateškim i drugim ciljevima univerziteta. Na kraju svake studijske godine informacioni sistem bi trebalo da pruži mogućnost rukovodiocima da adekvatno donose odluke u pogledu upisne politike na pojedine fakultete i studijske grupe.

Svaki sistem osim predmeta svoje aktivnosti, ljudskih resursa koji to treba da realizuju, vremena koje je neophodno za svaki zadatak, podrazumijevaju i materijalno-tehnička sredstva neophodna da se pronađe finansijski najpovoljniji način za poboljšavanje nivoa ostanka na fakultetu i ocjene; za odabir najkvalifikovanijih aplikanata za diplomiranje; da se unaprijedi prijem studenata koji će se dobro pokazati na univerzitetu, itd.

## 1.2 Obrazovni informacioni model

Većina evropskih zemalja je u posljednjih nekoliko decenija doživjelo nagli socio-ekonomski uspon. Razloge treba tražiti u činjenici da skoro sva djeca završavaju srednje škole i da se mijenja struktura zahtjeva u pogledu znanja. Većina univerziteta uvela je složene prijemne ispite i na taj način pokušavala da obezbijedi najbolje kadrove. Prijemni ispit, po pravilu, je osmišljen kako bi pomogao u ostvarivanju ciljeva obrazovnih politika. On bi trebao biti razumljiv, pouzdan, fer, isplativ i legitim. Kvalitet studentskih postignuća direktno se odražava na ekonomiju svake zemlje zbog čega su univerziteti zainteresovani da definišu modele koji bi pomogli u predviđanju akademskog uspjeha uključujući i podatke o prethodnom uspjehu i rezultate prijemnog ispita. Institucionalizovani tokom dugog perioda, prijemni ispiti na univerzitetima, pokazali su da skoro cijelokupan sistem obrazovanja, a posebno struktura srednjeg obrazovanja zavisi od njega. U mnogim zemljama, prijemni ispitina univerzitetima se zasnivaju na testovima znanja i sposobnosti čiji se rezultati kombinuju sa prethodnim uspjehom (u nekim zemljama i sa preporukama). U većini zemalja Evrope univerziteti samostalno biraju svoje studente i ne postoje nacionalni prijemni ispiti. Problemi sadašnjeg sistema su dobro poznati. Konkurenca za pojedina zanimanja je izuzetno jaka jer se na tim fakultetima stiču znanja koja su konkurentna u širem kontekstu i obično dovode do lakog pronalaska posla. Ti fakulteti imaju strogo ograničene prijemne kvote i zahtjevne prijemne ispite. Ukupno, manje od trećine prijava se prihvata.

Na slici 1.2 (Romero and Ventura, 2007, str. 136) predstavljen je uprošćeni model korišćenja informacija u obrazovnom procesu koji obuhvata šeme protoka, obrade i korišćenja informacija u obrazovnom sistemu. Iz obrazovnog sistema je izvučen data mining kao podsistem jer je cilj da se prikaže na koji način obrađene informacije mogu

poslužiti za donošenje odluka. Navedeni sistem se može posmatrati i kao kibernetički sistem u kome su definisani ulazi (cilj učenja) i očekivani izlazi (ishodi učenja), te niz procesa i operacija koje se odvijaju u samom sistemu. Naravno da se sistem može proširiti sa podacima koji se dobijaju iz okruženja (npr. potrebe privrede, potrebe društvene sredine i sl.). U tom slučaju bi se moglo govoriti o složenom sistemu društvenog funkcionisanja u kojem bi bila jasno definisana uloga obrazovnog sistema.



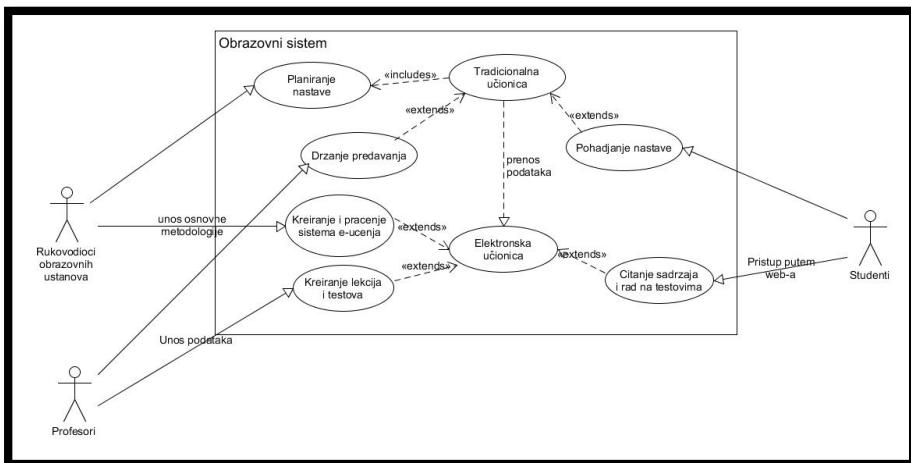
Slika 1.2. Protok, obrada i korišćenje informacija u obrazovnom sistemu (Romero and Ventura, 2007, str. 136)

Obrazovni sistem u svakoje zemlji izuzetno je složen, čine ga veliki broj podsistema (obrazovne institucije) čije su veze i odnosi u uzročno-posljedičnom odnosu. Obrazovni sistem čine ljudi, sredstva i informacije (Romero and Ventura, 2007:9). Da bi se razumjeli informacioni sistemi za podršku predviđanja uspjeha u studiranju nužno je objasniti svaki podsistem.

Pod u informacijama ovom slučaju se podrazumijevaju svi podaci koji je proizvelo društvo (obrazovne i druge institucije) u cilju konstituisanja i funkcionisanja obrazovnog sistema. Ovdje se prije svega misli na Strategiju obrazovanja, Strategiju obrazovnih potreba, zakone o obrazovanju, nastavne planove i programe (kurikulum) i druga dokumenta koja regulišu rad obrazovnih institucija. Navedeni dokumenti su međusobno povezani, naslanjaju se jedan na drugi, odnosno proizilaze jedni iz drugih.

U središtu odvijanja obrazovnog procesa su nastavni planovi i programi (kurikulumi) pojedinih obrazovnih podsistema.

Radi boljeg razumijevanja informacionog sistema na univerzitetu, a posebno sa stanovišta projektovanja obrazovnog softvera predstavili smo moguće slučajeve korišćenja (slika 1.3).



Slika 1.3. Slučajevi korišćenja univerzitskog informacionog sistema o nastavi

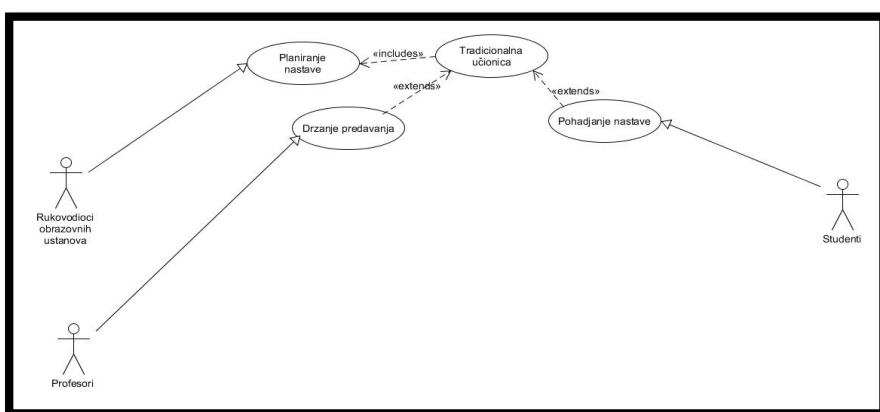
Obrazovni sistem (u užem smislu) odvija se uglavnom na dva načina i to: tradicionalni i sistem koji se zasniva na dostignućima IT. Tradicionalni sistem učenja zasnovan na tri osnovna činioca u procesu nastave koga čine nastavnik, student i sadržaji učenja ima dugu tradiciju i ta paradigma se održava i danas. Orientacija nastavnika uglavnom je takva da se predaju svi sadržaji predviđeni nastavnim planovima i programima sa vrlo slabim povratnim informacijama u toku samog procesa. Sistem je pokazivao svoju efikasnost samo u momentima ispita. U mnogim slučajevima rezultati takvog sistema rada su bili neefikasni jer su studenti učili za ocjenu u ispitnim rokovima. Znanja su, uglavnom, bila teorijskog karaktera koja najčešće nisu pratila potrebe privrede i društva. Jedan od osnovnih problema bio je u dostupnosti sadržaja učenja. Tradicionalni udžbenik, kao osnova za učenje nije bio dovoljan da se steknu šira znanja. Sa stanovišta projektovanja sistema učenja, otežavajuća okolnost su bili podaci o različitim aspektima odvijanja procesa učenja. Većina podataka je bila nedostupna ili su čuvani na različitim mjestima u različitim formatima koji su nepodesni za obradu ili za čiju obradu je trebalo mnogo vremena. Takvi podaci nisu mogli biti sigurna osnova za projektovanja obrazovnog sistema sa stanovišta predviđanja uspjeha. Studenti su studirali kako dugo da se pri tome nisu utvrđivali uzroci. Sva odgovornost se prebacivala na motivisanost studenata, bez suštinske analize funkcionalnosti cjelokupnog sistema.

Pojavom i razvojem informacionih tehnologija ubrzan je tok tehnoloških promjena koji se odrazio na obrazovnim sistemima.

Tehnološke inovacije su uticale na promjenu sadržaja učenja, ali i organizacije procesa učenja.

Nastavnici su u savremenim uslovima na raspolaganju novi mediji za učenje, a studentima su informacije postale dostupne u različitim formama. Sa stanovišta rukovodilaca procesa učenja i planera nova tehnologija pruža mogućnost primjene različitih analitičkih alata sa objektivnom slikom odvijanja procesa. Svi sadržaji određenog kursa su dostupni korisnicima IT, zadaci za učenje se mogu zadavati bez fizičkog prisustva, kao i proces evaluacije.

Velika količina skladištenih podataka može poslužiti kao dobra osnova za planiranje budućih akcija u unapređenju procesa rada na fakultetima.

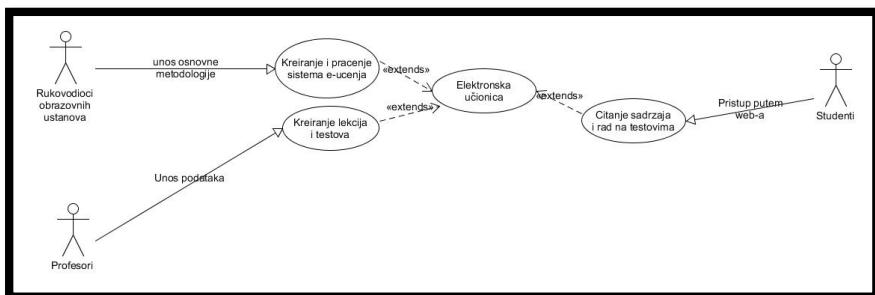


Slika 1.4. Slučajevi korišćenja za tradicionalni sistem učenja

U tradicionalnom sistemu učenja rukovodilac planira strukturu obrazovanja, profesor modelira predavanja, a student pohađa nastavu i služi se ponuđenim sadržajima učenja. Bez obzira na statičnost navedene strukture tradicionalni rad na fakultetima još uvijek je dominantan. Postoje pokušaji uvođenja inovacija u nastavni proces koji se kreće u nekoliko pravaca i to: didaktičko-metodičke inovacije (oblici, metode, nastavna sredstva) i sistemske inovacije (uvođenje novih nastavnih sistema – problemsko učenje, projekt metod, e-learning itd.). Bez obzira na kvalitet inovacija osnovna struktura sistema opstaje. Razloge opstajanja treba tražiti u društvenoj ulozi obrazovanja kao fenomena, jer je obrazovanje i socijalizacijski proces. Neposredna komunikacija koja se odvija u obrazovanju, kako vertikalna nastavnik-student, tako i horizontalna student-student, još uvijek se smatra izuzetno važnom jer je u nastavi važan emocionalni odnos koji stimuliše proces učenja.

U elektronskoj učionici rukovodilac kreira princip učenja i prati njegov razvoj, profesor unosi podatke o nastavnim temama i kreira testove, a student čita sadržaj koji je profesor unio i radi na testovima.

Suštinski nastavnik u skladu sa definisanim ciljevima i ishodima učenja kreira potrebne sadržaje. U tom kontekstu uglavnom su definisane sljedeće aktivnosti.



Slika 1.5. Slučajevi korišćenja za sistem učenja zasnovan na savremenim IT

1. Postavljanje sadržajana sistem, ovaj SK omogućava nastavniku da material sa klijentskog računara, postavi posredstvom mreže na server, predviđen za smještaj sadržaja učenja. Pritome, sistem provjerava na osnovu naziva, vremena kreiranja i veličine fajla da li sadržaj već postoji. Inače originalni nazivi fajlova pohranjuju se u BP, dok se svakom sadržaju dodjeljuje novi (jedinstveni identifikator).

2. Direktno kreiranje sadržaja u sistemu- pored postavljanja (*upload-a*) sistem treba da omogući direktno kreiranje sadržaja, u formi tagovanog teksta (npr.HTML), koji u sebi može da ima ugniježdene i druge resurse.

3. Editovanje sadržaja – ovaj SK omogućava editovanje direktno kreiranog sadržaja i opisa resursa (naziv, domen i ključne riječi, kreator, tip).

4. Pretraživanje sadržaja – pretraživanje sadržaja se vrši na osnovu njihovih metapodataka – naslov, ključne riječi, tip, domen, kreator.

5. Uklanjanje sadržaja – ovaj SK je izvodljiv samo ako se specificiran resurs nije referenciran iz činilaca predmeta.

6. Upravljanje komentarima – ovaj SK odnosi se na dodavanje, pregled, editovanje i uklanjanje komentara vezanih za konkretni sadržaj učenja. Komentarima je predstavljen mehanizam anotacije u sistemu.

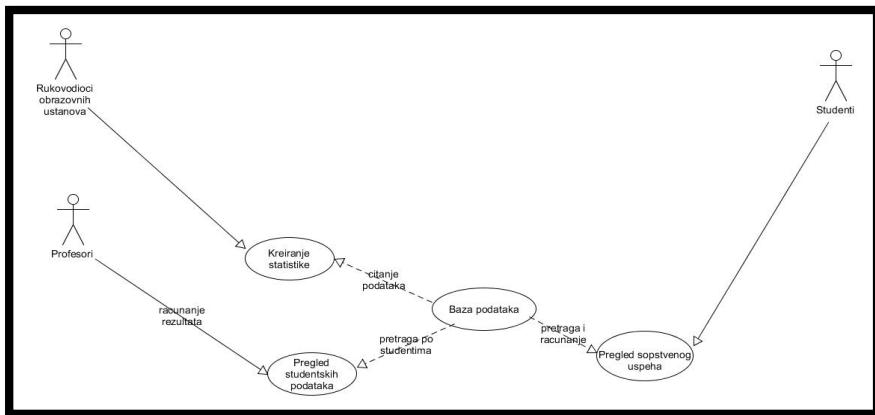
7. Kroz komentare, nastavnik može da studentima sugestije, pomoći, kao i neke dodatne informacije vezane za sadržaj.

8. Opis sadržaja – ovaj SK namijenjen je da se resursu dodaju metapodaci (naslov, ključne riječi, tip, domen, kreator), korisni za pretraživanje repozitorijuma.

9. Provjera veza sadržaja sa činiocima predmeta – treba da zaštititi integritet pripremljenih kurseva (predmeta). U slučaju da nastavnik želi da ukloni sadržaj, sistem mora da provjeri da li se sadržaj već koristi

(da li je povezan začinioce predmeta). Sistem dozvoljava da se sadržaj ukloni samo ako nije uključen u proces učenja (nema vezu ni sa jednim činiocem predmeta).

Sledeći slučaj korišćenja definiše čitanje i korišćenje podataka.



Slika 1.6. Slučaj korišćenja – čitanje i korišćenje podataka

Akademsko planiranje resursa je vrlo složen postupak jer se zasniva najopsežnjoj analizi svih podataka koji se odnose na obrazovni okvir, kao što su nastavni kadar, nastavna sredstva, nivoi školovanja, struktura i priroda nastavnih planova i programa, broj studenata, itd. Odlučivanje na univerzitetima dugo je bila stvar intuicije zasnovane na procjeni i izjavama, a ne duboke analize prikupljenih podataka.

Međutim, pojava naprednih informacijskih tehnologija redefinisala je operativno okruženje univerziteta u svijetu i ponudila im priliku da sistematski i efikasno upravljuju svim najvažnijim procesima koji su vezani za visoko obrazovanje. Precizni računarski modeli, razumljive metodologije, potpune i konzistentne baze podataka i razumljivi izlazni podaci su od najveće važnosti za naprednu podršku odlučivanju. Razvijeni su alati koji omogućavaju efikasnu distribuciju resursa, upravljanje nastavnim kadrom, automatizacija studentskih servisa, praćenje svih aktivnosti studenata, podrška selekciji kandidata za prijem na studije itd.

Prvi pokušaji da se implementiraju simulacioni modeli za upravljanje obrazovnim resursima pojavili su se šezdesetih godina dvadesetog vijeka (<http://eacea.ec.europa.eu/education/eurydice>).

Ukupan napredak i razvoj informacionih tehnologija omogućili su da se devedesetih godina razviju stvarni i dobri sistemi za ovu namjenu. U današnje vrijeme skoro svi univerziteti imaju dovoljan nivo informacione podrške u sistemima za donošenje odluka. Svi korisnici koriste kompleksnu bazu podataka za dobijanje potrebnih informacija. Tako rukovodilac može da kreira statistiku po željenim

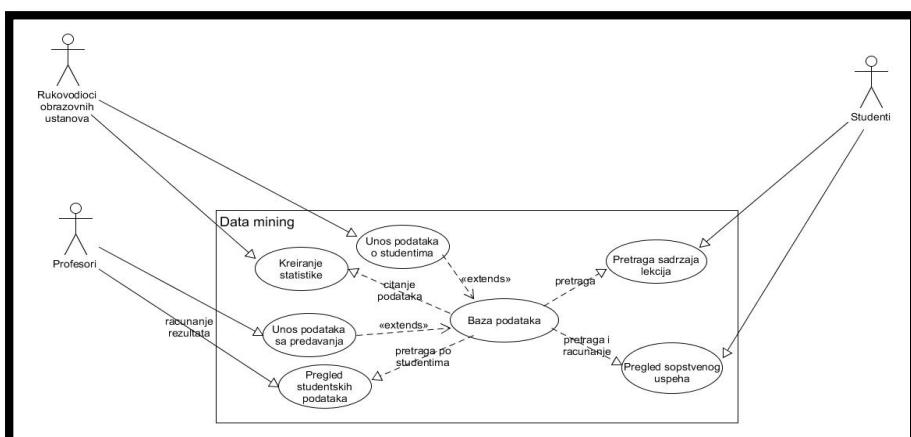
grupama (smjerovima, semestrima, generacijama...), profesor može da prati rezultate izabralih studenata kako bi lakše kreirao ocjene, a student može da vidi sopstveni uspjeh i predstojeće obaveze.

Moderni IT alati omogućuju vođeni interakcijski pristup u pronalaženju adekvatnih odgovora na niz akademskih problema koji se pojavljuju u praksi savremenih univerziteta. Pored poznavanja analitičkih alata korisnici savremenih sistema za donošenje odluka moraju dobropoznavati obrazovni sistem određene zemlje sa stanovišta zakonskih i drugih procesa, osim toga trebaju dobro da poznaju realizaciju procesa nastave i učenja, jer samo u takvom spoju znanja mogu se očekivati adekvatni upiti i tumačenje dodbijenih podataka.

Vođeni interakcijski režim implementiran je kao analitička kutija koja generiše izvještaje za unaprijed definisan skup akademski problemi i sadrži sljedeće korake:

- odabir jednog od predefinisanih zadataka iz liste;
- izbor vrste izvještaja za analizu;
- podešavanje opcija izvještaja (nivo detalja, agregacije, pretpostavke, izvještavanje o pogrešci, ulazni nedosljednost rukovanja, itd);
- podešavanje zadate vrijednosti i ograničenja;
- navođenje zahtjeva i mogućnosti unosa podataka;
- podešavanje ulaznih podatke za mapiranje željenog scenarija;
- pokretanje scenarija i generisanje izvještaja;
- interaktivno istraživanje izlaza (koristeći zumiranje, objedinjavanje, navođenje detalja, i druge tehnike);

Sledeći korak u razvijanju informacionog modela predstavljen je slučajem korišćenja *data mining* (slika 1.7).



Slika 1.7. Slučaj korišćenja *data mining*

Data mining se temelji na istim koracima kao i rad sa osnovnim podacima u drugim tehnikama (Romero et al, 2004). Ti koraci su sledeći.

**1. Priprema podataka** je obično prvi korak u data mining procesu. U ovoj fazi se mogu identifikovati četiri koraka i to:

- Priprema konačnog skupa podataka koji će biti korišćen u narednim fazama iz dobijenih sirovih podataka. Cilj filtriranja podataka je odstranjanje irrelevantnih i suvišnih informacija iz skupa podataka. To podrazumijeva uklanjanje duplih i nepotpunih podataka, njihovu transformaciju i jedinstven sistem podataka, izbor podgrupa podataka, određivanje broja promjenjivih sa kojima je moguće raditi.
- Izbor promjenljivih i njihovih atributa, koje želimo da analiziramo i za koje smatramo da će nam biti od koristi.
- Transformacija određenih promjenljivih ukoliko je to potrebno. Cilj transformacije podataka je promjena izvornog podatka u drugačiji format tipa podataka. Postoje različiti tehnike koje se mogu primijeniti za korak filtriranja i transformaciju podataka, a najčešće korišćene su; transformacija tipova podataka, neprekidna transformacija kolona, grupisanje, rad sa vrijednošću koja nedostaje, brisanje abnormalnih slučajeva itd.
- Prečišćavanje podataka ipriprema za rad sa alatima za modeliranje (Izbor odgovarajuće tehnike za modeliranje, Podešavanje parametara modela, Opciono primjena drugih tehnika (uvijek treba imati na umu da se različite tehnike mogu koristiti za rješavanje istih problema), Ukoliko dodje do problema, vraćanje na fazu pripreme podataka za konkretni algoritam.

**2. Data mining** je centralni korak u cijelokupnom procesu, tokom koga se na pripremljene podatke primjenjuju data mining tehnike koje se mogu svrstati u dvije grupe i to:

- *Discovery data mining* – tehnike za otkrivanje novih znanja (informacija);
- *Predictive data mining* – tehnike za predviđanja.

U ovom koraku se uglavnom sreću sledeće grupe tehnika:

- uparivanje stringova, brute-force uparivanje stringova,
- algoritmi linearnog uređivanja, aparivanje na bazi konačnih automata, Knutt-Morris-Pratt algoritam, aproksimativno uparivanje, Wagner Fischer algoritam za računanje distanci u stringu,
- klasifikacija, klasifikatori na bazi drveća odlučivanja, Bayesian klasifikatori, učitelji na bazi distance, mašine sa vektorskom podrškom,

- fuzzy tehnike odlučivanja,
- clustering, mjere distanci i simbolički objekti, clustering kategorije, skalabilni clustering algoritmi, pristupi na bazi soft računarstva, hijerarhijski simbolički clustering , segmentacija
- asocijativna pravila, generisanje kandidata i metode testa, pravila od interesa, multinivojska pravila, on-line generisanje pravila, generalizovana pravila, temporalna asocijativna pravila,
- filtriranje i transformacija podataka, validacija i vizualizacija rezultata.

**3. Naknadna obrada**je završni korak u kojem se tumače rezultati ili dobijenog modela i koriste se donose odluke o obrazovnom okruženju. *Data mining* je skup svih akcija koje imaju za cilj pregled podataka radi kreiranja statistike postgnutih rezultata, pronalazak željenih podataka. Jedan od važnih izlaznih podataka o kojima želimo da imamo podatke se odnose na procjenu kvaliteta pojedini kurseva (predmeta).

U procjeni kvaliteta kurseva nameću se sljedeća pitanja:

- Da li su ciljevi određenog predmeta dostupni i razumljivi svim činiocima procesa učenja?
- Da li su ostvareni ciljevi određenog predmeta u takvom obimu da se mogu pratiti sljedeći povezani predmeti bez većih problema?
- Da li su ostvareni svi potrebni preduslovi da student mogu uspješno pratiti nastavni predmet (posebno sa stanovišta razumijevanja pojmova)?
- Da li su predviđene metode vrednovanja znanja dovoljno dobro izabrane kako bi mogle da mjere sve aspekte stečenih kompetencija.
- Da li je ravnomjerno raspoređen odnos između teorijskog i praktičnog rada, posebno u domenu samostalnog rada studenata na zadatim projektima?
- Koliko se teškim smatra određeni nastavni predmet, koliko ECTS bodova nosi, koja je prolaznost, koliko prosječno student osvajaju bodova na tom predmetu, kako su ga vrednovali prilikom procesa evaluacije?
- Da li postoji konzistentan povratna informacija o postignutom uspjehu za sve student?
- Da li su jasno definisani izvori znanja (nastavni sadržaji za učenje)?
- Kakva je veza sadržaja učenja sa potrebnim znanjima u praksi?

Da bi se uspješno odgovorilo na navedena pitanja u obzir se moraju uzeti podaci dasvi univerziteti imaju hijerarhijsku strukturu. Osim rukovodstva univerziteta, ovdje se pojavljuje i složena administrativna struktura koja se bavi administrativnim i drugim poslovima u podršci rada rukovodstva univerziteta.

U sljedećem nivou strukturisanja pojavljuju se fakulteti sa rukovodstvom i određenom administrativnom strukturu. Neki fakulteti su jednodisciplinarnog karaktera i uglavnom osposobljavaju jedan obrazovni profil (npr. dipl. inž mašinstva). Drugi su interdisciplinarni sa više studijskih programa koji obrazuju različite obrazovne profile u okviru jednog fakulteta.

Sljedeći problem koji može dodatno otežati prikupljanje podataka i uticati na složenost IT strukture su različita (često udaljena) mesta lociranja pojedinih fakulteta.

Svaki studijski program ima različite korisnike (nastanici, student – različitog nivoa, rukovodstvo). Ovo podrazumijeva i heterogene nastvne programe. Nastavne programe odlikuju ciljevi, sadržaji, dužina trajanja pojedinih kurseva, složenost nastavnog procesa (predavanja, vježbe, seminari, radionice, laboratorije). Svaka od navedenih aktivnosti produkuje veliki broj podataka koji se trebaju skladištiti i čuvati. Podatke je nužno razvrstati u grupe i to: administrativni, nastavni, naučni. Administrativni podaci su od posebne važnosti kako za administrativno osoblje koje donose kratkoročne odluke u smislu procedura i finansiranja, tako i za rukovodstvo fakulteta i univerziteta koji donose operativne i strateške odluke oko upisnih politika i akcija u smislu poboljšanja kurikuluma, promjene obrazovnih standarda i jačanje materijalne osnove obrazovnog procesa.

### 1.3 Analitika učenja

Analitika učenja definiše se kao „mjerjenje, prikupljanje, analiza i priprema izvještaja o učenicima i njihovim kontekstima, svrsi razumijevanja i optimizovanja učenja i sredine u kojoj se to dešava“ (Long i Siemens, 2011, str. 32).

Analitika učenja dobija sve više na značaju naročito iz razloga što predstavlja odlično sredstvo koje obrazovnim ustanovama pomaže da poveća uspjeh i zadovoljstvo učenika. Analitiku su najprije primjenjivala preduzeća kako bi predvidila ponašanje potrošača i na taj način mogla personalizovati marketinšku kampanju. Slično tome, nešto kasnije su obrazovne ustanove počele da koriste analitiku učenja na svojim predavanjima kako bi pružili kvalitetno i personalizovano učenje te time pomogli svojim učenicima da budu uspješniji.

Svrha analitike učenja ne smije da bude cilj sama sebi, ne treba da bude čisto birokratska i deklarativna već analitika treba da služi upravo identifikaciji grešaka i propusta u izvođenju nastave i unapređenju obrazovnog sistema. Primarni zadatak analitike nije da daje izvještaj o prošlosti, nego da pomogne da se pronađe optimalna putanja ka željenoj budućnosti (Shum, 2012).

Postoji veliki broj različitih alata za analitiku koji se koriste putem LMS-a (*learning management system*) a koji mogu pružiti podatke koji nešto znače i koji se mogu obrađivati – u formi koja je iskoristiva i koja nastavnike ohrabruje da u realnom vremenu preduzmu neke aktivnosti. Podatke koji se automatski prikupljaju putem LMS-a obrazovne institucije koriste kako bi poboljšali odnosno prilagodili kvalitet nastave svojim studentima i na taj način osigurali bolju prolaznost. Najčešće prikupljeni podaci se odnose na učestanost prijavljivanja studenata na LMS platformu, broj diskusija koje je student pročitao, broj diskusija koje je sam inicirao ili samo učestvovao. Upravo je učestvovanje studenata u diskusijama na forumima prilično pouzdan prediktor za ocjenu uspješnosti učenika.

Najznačajniji problem vezan za razvoj i implementaciju analitike učenja tiče se zaštite privatnosti učenika. Naime postoji realna opasnost i zabrinutost učenika da se prikupljanjem različitih podataka može utvrditi njihov identitet i ugroziti privatnost. Ovo svakako nepovoljno utiče i na iskrenost i kvalitet prikupljenih podataka i problem je koji se treba riješiti da bi razvoj analitike učenja bio moguć i svrsishodan.

## 1.4 Personalizacija učenja i PAPI i LIP profil studenta

Različiti ljudi imaju različite navike učenja i aspiracije pa je iz tog razloga, u cilju postizanja maksimalnog učinka, potrebno primjenjivati različite pristupe, odnosno potrebno je personalizvati učenje. Personalizacija učenja podrazumijeva prilagođavanje nastavnih sadržaja konkretnim potrebama svakog učenika.

Personalizacija se najlakše postiže ukoliko se koristi tehnologija. Alati za analitiku učenja, takozvani sistemi za upravljanje učenjem (*Learning Management Systems*, LMS), imaju mogućnost personalizacije procesa učenja, s obzirom da se njihovim korištenjem automatski prikupljaju i analiziraju podaci o učenicima. Osim ovih sistema, razvijeni su i fleksibilniji (inteligentni) sistemi koji su bolji izbor za personalizaciju učenja obzirom da se oni dinamički prilagođavaju potrebama svakog učenika.

Ono što je zajedničko za oba sistema jeste posjedovanje baze podataka korisnika (kako onih podataka koje prikuplja tokom korisnikove aktivnosti tako i one podatke koje je korisnik prilikom registracije unio u sistem a koji se tiču prošlosti korisnika). Sistem, na

zahtjev, analizira ove podatke i na osnovu rezultata te analize vrši modelovanje sadržaja za svakog korisnika ponaosob.

Danas je razvijeno više standarda za modelovanje učenika. Iako postoji značajna sličnost među postojećim modelima, većina je fokusirana samo na konkretni problem. Dva najznačajnija i najbolje razvijena standarda (specifikacije) modela studenta su IEEE PAPI model i IMS LIP standard. Oba standarda se bave sa nekoliko kategorija informacija o učeniku.

PAPI (*Public and Private Information*) Learner specifikacija je prvobitno razvijena od strane IEEE LTSC (IEEE Learning Technology Standards Committee) za opisivanje osnovnih informacija o studentima kao i za komunikaciju među operativnim sistemima. Ove informacije se skladište kako bi mogle biti od koristi npr. nastavnicima, studentskoj službi kao i samom studentu. PAPI standard naglašava značaj međuljudskih odnosa.

Skup informacija koji čini studentski profil PAPI modela čine informacije o usvajanju znanja, vještinama, sposobnostima, ličnim kontakt informacijama, odnosima, nivou zaštite tajnosti korisnikovih podataka, radovima i projektima itd.

Posebno korisne karakteristike ovog modela koje doprinose njegovoj fleksibilnosti su njegova modularnost, koja ostavlja prostor za dodatna proširenja i usavršavanja, i interoperabilnost sa drugim sistemima. PAPI model korisnikove informacije predstavlja putem šest kategorija, odnosno informacionih modula koji se mogu nezavisno korisiti u drugim aplikacijama, u skladu sa konkretnim potrebama.

Nasuprot IEEE PAPI standardu, LIP (*Learner Information Package*) standard se zasniva na informacijama kakve se nalaze u CV-u dok se međuljudski odnosi uopšte ne uzimaju u razmatranje. Ova specifikacija je razvijena od strane IMS (Instructional Management Systems) organizacije sa ciljem da se omogući lakša distribucija informacija o učenicima u sve dijelove sistema, ili različite sisteme koji sarađuju. I ovaj standard odlikuje fleksibilnost po pitanju proširenja i korištenja samo pojedinih dijelova sistema. S obzirom da je LIP standard u vrhu bolje razvijenih standarda, suvišno je i napominjati da su mjere zaštite privatnosti i integriteta podataka implementirane.

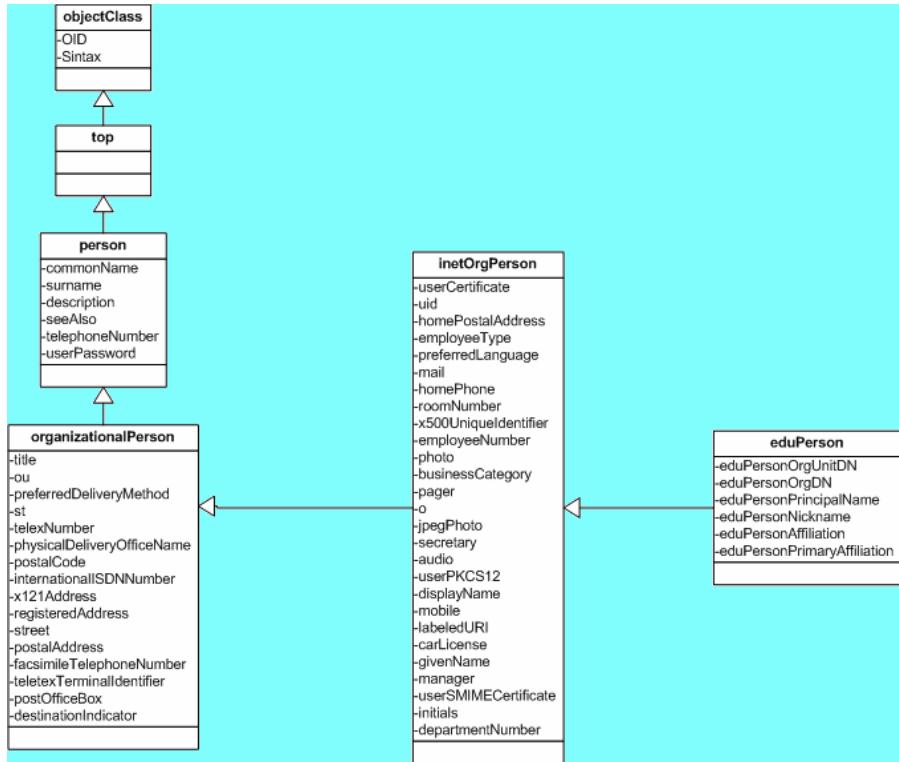
## 1.5 EduPerson

EduPerson studentski model je projektovan za potrebe visokoškolskog obrazovanja u SAD. U momentu prve specifikacije (februar 2001. godine), udruženje istraživačkih institucija Internet2 i EDUCAUSE (<http://www.educause.edu/eduperson/>) su isticale da je glavni motiv ove inicijative stvaranje jedinstvenog obrasca za izgradnju institucionalnih direktorijuma. Pošto sve edukativne institucije u SAD

uglavnom razvijale sopstvene, međusobno nekompatibilne modele, a imale su sve veću potrebu razmjene informacija o studentima, EduPerson je predstavljen kao specifikacija liste atributa koju bi različite visokoškolske institucije trebalo da podrže u studentskim modelima svojih informacionih sistema. Nekoliko univerziteta u SAD-u, među kojima se nalaze Univerzitetu Viskonsinu (engl. University of Wisconsin) i poznati institute za tehnologiju u Masačusetsu (engl. Massachusetts Institute of Technology – MIT), učestvuju u relizaciji ovog zahtjevnog projekta (posljednja verzija standarda objavljena je aprila 2006. godine).

Prema EduPerson specifikaciji, skladišta podataka, bez obzira da li se radi o tabelarnom pohranjivanju u sistemima za upravljanje bazama podataka, ili o čuvanju podataka u fajl sistemima, nazivaju se direktorijumi. EduPerson atributi studenata su dizajnirani da omoguće napredno pretraživanje direktorijuma. Pomenuta specifikacija sadrži skupove elemenata podataka, ili svojstava, o pojedincima unutar visokog obrazovanja, zajedno sa preporukama o sintaksi i značenju podataka koji mogu biti pridružen i pomenutim svojstvima (Lindholm, J., 2002). Informacije koje su sadržane u direktorijumu su organizovane kao objekti klase i atributi. Svaki imenovani atribut sadrži specifični element podataka (npr. adresa, afilacioni podaci i sl.). Jedan objekat klase je definisan kao skup povezanih atributa i predstavlja poseban tip podataka koji je sastavni dio direktorijuma.

EduPerson model se razvija u okviru šireg društvenog konteksta, i ima izraženu hijerarhijsku strukturu (slika 1.8). Dekomponovanje na šest klasa u lancu nasleđivanja. Osnovna klasa je generički objekat (`objectClass`), kojim se definiše jedinstveni objektni identifikator u sistemu i sintaksa koja se koristi radi manipulacije podacima. Ovakvim pristupom omogućeno je da se podaci studenta standardizovano serijalizuju, prenose mrežom, a pristupaim se podjednako preko API-ja i preko Web servisa. Sledeća klasa u lancu nasleđivanja je imenovana kao top klasa i ne sadrži podatke, ali je bitna radi održavanja koncepta direktorijuma. Ona podržava koncept korijena direktorijuma, što je bitno za implementaciju algoritama za pretraživanje podataka. Klasa `person` čuva osnovne identifikacione podatke. Jedan od atributa je `seeAlso` koji omogućava referenciranje na drugi direktorijum preko drugog imena (naziva naloga, korisničkog imena) osobe. Pošto je model predviđen za institucionalizovanu edukaciju, za potrebe čuvanja podataka osoba u kontekstu organizacije, dizajnirana je klasa `organizationalPerson`. Sledeća klasa u hijerarhiji je `inetOrgPerson` u čijem dizajnu je dat akcenat na attribute koji su važni za komunikaciju posredstvom mreže (internet, ili intranet). Iz ove klase je direktno izvedena klasa koja sadrži attribute vezane za obrazovanje – `eduPerson`.



Slika 1.8. EduPerson model studenta

<http://www.nmi-edit.org/eduPerson/internet2-mace-dir-eduperson200406.html>

Pored nasleđenih atributa *eduPerson* sadrži šest atributa od kojih je osnovni *eduPerson OrgDN* (naziv organizacije kojoj osoba pripada). Svi atributi imaju isti prefix *eduPerson*. Sa atributima *cnisn* (na slici *common Name* i *surname*) iz klase *organizationalPerson*, atribut *eduPersonOrgDN* formira osnovu za korišćenje klase *eduPerson* u aplikacijama. Atributi *eduPerson Affiliation* i *eduPersonPrimaryAffiliation* ukazuju na uloge koja osoba ima u edukativnoj instituciji (na primjer student, saradnik, nastavnik i sl.) i oni se moraju razlikovati od atributa *title* nasleđenog iz klase *organizationalPerson*.

EduPerson specifikacija strukturira atribute na sledeće kategorije.

**Postojeći atributi** – standardni komercijalni atributi, nasleđeni od objekata klase *person*, *organizationalPerson* (definisani standardom X.521) i klase *inetOrgPerson* (definisani standardom RFC 2798); (npr. imena, e-mail adrese, bezbednosna podešavanja koji se nalaze u klasi *inetOrgPerson*).

**Novi atributi** – to su zapravo svi atributi klase *eduPerson*. Namena ovih atributa je konkretna–unapređivanje saradnje (razmjene informacija) između obrazovnih institucija. Za svaki od atributa

EduPerson specifikacija detaljno definiše sintaksu, značenje i uputstvo za korišćenje.

Kao kod IMS LIP-a, projektanti EduPerson modela su odlučili da riješe kompleksan problem identifikatora. Za tu svrhu iskorišćen je concept hijerarhijske strukture direktorijuma koji je saglasan sa specifikacijom RFC 3061 (slika 1.9).

```
urn:oid:1.3.6.1
urn:oid:1.3.6.1.4.1
urn:oid:1.3.6.1.2.1.27
URN:OID:0.9.2342.19200300.100.4
```

Slika 1.9. Primjeri identifikatora (RFC 3061) koji se koriste u EduPerson modelu

Identifikatori su zapravo kompoziti naziva (zapravo ID-brojeva, koji se mogu mapirati u nazive i imena radi lakše manipulacije od strane ljudi – korisnika) direktorijuma i ID- brojeva konkretnih podataka (literali-u ovom slučaju to su rastuće cjelobrojne vrijednosti, ili pseudoslučajni nizovi karaktera).

Jedan identifikator je ujedno i jedan element informacije, koji je specijalno dizajniran da razlikuje svaki ulazni podatak od onih koji su mu slični i da ga skladišti u poseban skup. Zajedničko ulaznim podacima je i to da sadrže nekoliko različitih identifikatora, koji se koriste u različitim svrhe ili su generisani od strane različitih izvora informacija. Identifikator ima određeni broj karakteristika koje predstavljaju pomoć kod određivanja načina na koji će biti upotrijebљen. Osnovne osobine identifikatora su sledeći.

**1. Perzistentnost** – predstavlja vremensko trajanje u toku koga je identifikator pouzdano povezan sa osnovnim ulaznim podatkom. Kratkotrajni identifikatori mogu biti povezani samo u toku trajanja jedne sesije, dok su nepromjenljivi identifikatori povezani sa njihovim ulazima u toku cijelog životnog ciklusa.

**2. Privatnost** – neki identifikatori su dizajnirani tako da sačuvaju najviši stepen privatnosti i zabranjuju sposobnost višestrukim nepovezanim primaocima da porede vrijednosti međusobno povezanih osnovnih aktivnosti. Takvi identifikatori, kao što je REQUIRED, mogu biti nerazumljivi i da im uz to nedostaje osnovna povezanost sa ostalim identifikatorima. Ovakav pristup dozvoljava dijeljenje identifikatora između većeg broja povezanih korisnika i to jedino u slučaju ako ih proizvođač atributa smatra ekvivalentnim jedinstvenom identifikatoru po pitanju čuvanja privatnosti.

**3. Jedinstvenost** – jedinstveni identifikatori su oni koji su jedinstveni u okviru prostora imena koji govori i identitetima provajdera servisa koji je kreirao datu vrijednost. Globalno jedinstveni

identifikator je onaj kome je namijenjeno da bude jedinstven posmatrajući sve instance atributa zastupljenih kod svih proizvođača.

**4. Razduživanje** – mnogi identifikatori ne garantuju da vrijednost koja im je pridružena neće biti ponovo korišćena. Ponovno korišćenje podrazumijeva dodjelu vrijednosti jednog identifikatora nekom osnovnom ulazu, a potom dodjeljivanje iste vrijednosti nekom drugom ulaznom podatku u bilo kom trenutku vremena.

Neophodno je postojanje cijelog skupa zahtjeva koji diktiraju politiku koja ne dozvoljava ovakve propuste.

Na identičan način rješavaju se i vrijednosti ostalih atributa studentskog modela. Sledeći primer (slika 1.10) prikazuje način serijalizacije atributa u EduPerson modelu. Predstavljenje fragmenta XML fajla koji omogućava iščitavanje podatka o korisničkom imenu nadređenog (*eduPersonPrincipalName*) posmatranog studenta (prikazano ime je *cantor.2*).

```
<saml:Attribute AttributeNamespace="urn:mace:shibboleth:1.0:attributeNamespace:uri"  
    AttributeName="urn:mace:dir:attribute-def:eduPersonPrincipalName">  
    <saml:AttributeValue Scope="osu.edu">cantor.2</saml:AttributeValue>  
</saml:Attribute>
```

Slika 1.10. Primjer imenovanja u EduPerson modelu

Direktorijumski pristup je predstavljen vrijednošću Scope, što znači da je ovo korisničko ime (*cantor.2*) jednoznačno definisano na mrežnom domenu osu.edu, čime je ograničen doseg imena. Vrijednost *AttributeNamespace* definiše kontekst u kome treba da se tumači predstavljeni podatak (*cantor.2*).

Za razliku od prethodnih modela, EduPerson studentski model je bolje hijerarhijski struktuiran uz izbjegavanje rekurzivnosti. Značaj ovog modela je nastojanje da se postigne potpuna standardizovanost, i time potpuna interoperabilnost u pogledu razmjene konkretnih podataka studenata između institucija u društву. Druga značajna osobina ovog modela je da su podaci vezani za obrazovanje hijerarhijski odvojeni od opštih podataka studenata, važnih za njegovu egzistenciju u široj društvenoj zajednici (npr. na radnom mjestu, na globalnoj mreži, neobrazovnim institucijama i sl.). Hijerarhijska organizovanost pored olakšavanja administriranja podataka (concept identifikatora), pojednostavila je i rješavanje zaštite privatnosti podataka studenata. Hijerarhijski nivoi mogu da se razmatraju kao i nivoi zaštite. Naprimjer, osnovni podaci osobe se čuvaju na nivou klase person, dok podaci važni za poslovnu komunikaciju su na nivou klase organizationalPerson. U tom smislu, ovaj model je razvijan korišćenjem SAML-a (*Security Assertion Markup Language*) (<http://www.oasis-open.org/committees/security/>).

Nažalost, uprkos velikom broju atributa, postoji samo šest koji su definisani radi razmjene u obrazovnom kontekstu – atributi klase

*eduPerson*. Respektujući prethodne modele (*PAPI Learner* i *IMS LIP*) ovi atributi nisu dovoljni da obuhvate sve podatke studenta u procesu učenja. Prema dokumentaciji, proširljivost je moguća, ali je osnovni model sam po sebi već kompleksan (naročito iz aspekta implementacije), tako da u praksi još uvijek nema ekstenzija ove specifikacije. Preporuka kreatora je da se, umjesto proširenja postojećih klasa, definišu nove i dodaju u hijerarhiju *eduPerson* modela.

## 1.6 Modeli za predviđanje uspješnosti studiranja

Predviđanje (prognoza) budućnosti je kruna svake nauke. Obrazovanje ima stratešku važnost za ekonomski i društveni razvoj, tj. za razvijanje društva zasnovanog na znanju. U procesu evropskih integracija neophodno je obrazovani sistem uskladiti sa kriterijumima i preporukama Evropske unije ili drugih evropskih organizacija i procesa, uz posvećivanje posebne pažnje indikatorima uspješnosti obrazovnog sistema koje je EU definisala. Za visokoobrazovne ustanove analiza uspješnosti studiranja vrlo je važna jer strategijsko planiranje studijskih programa pretpostavlja proširivanje ili smanjenja obima ili dubine izučavanih sadržaja, kao i mijenjanje strukture vaspitno-obrazovnog procesa u zavisnosti od uspješnosti studenata. Uspješnost studiranja na fakultetima do sada je uglavnom istraživana u cilju pronalaženja prosječnih ocjena, dužine studiranja i sličnih pokazatelja, dok faktori koji utiču na postizanje uspjeha nisu dovoljno istraženi. Postoje razvijeni modeli za predviđanje uspješnosti koji mogu pomoći pri odluci o prihvatanju kandidata za upis nastudije, koji uglavnom uključuju demografske podatke o studentima, iako se naglašavaju i drugih informacija o aplikantima (Hardgrave i dr, 1994).

Cilj ovog rada je pronalaženje važnih činilaca koji utiču na uspjeh studenata, koji je predstavljen prosječnom ocjenom. Za ovu svrhu smo ispitali tri metode analize podataka pogodne za klasifikaciju: logističku regresiju, stabla odlučivanja i neuronske mreže. Logistička regresija je statistički postupak zasnovan na raspodjeli vjerovatnoće koja se pokazala efikasnom u mnogim područjima predikcije. Njihova tačnost upoređenaje sa stablima odlučivanja kako bi se identifikovao model koji daje tačniju klasifikaciju studenata. Rezultati istraživanja se zasnivaju na anketnom istraživanju provedenom sa studentima Pedagoškog fakulteta u Bijeljini 2009, 2010. i 2011. akademске godine. Prikupljeni podaci razvrstani su u tri grupe i to: prvu grupu čine intelektualne sposobnosti mjerene Ravenovim matricama (Raven, M. S., 1956), motivacija mjerena Velerandovom skalom akademске motivacije (*academic motivation scale*) (Vallerand, R. J., 1992), drugu grupu čine socio-demografski podaci a treću stavovi o organizaciji rada na fakultetu i načinu realizacije nastavnog procesa. Na osnovu tih poda-

taka kreiran je kauzalni model sa demografskimi drugim karakteristikama studenata kao ulaznim varijablama, te prosječnom ocjenom u prethodnoj akademskoj godini kao izlaznom varijablu.

Analiza značajnosti varijabli dobijenih logističkom regresijom, stablom odlučivanja i neuronskim mrežama ukazuju na jačinu uticaja pojedine ulazne varijablena uspjeh studenata, čime je moguće donijeti zaključak o mogućim prediktorima uspješnosti studiranja.

U posljednjih petnaest godina razvijene su mnoge aplikacije u oblasti *data mining*-a koje služe u oblasti obrazovanja. Romero i Ventura (Romero, C., Ventura, S., 2007) su objavili studiju „Istraživanje obrazovnog *data mining*-a iz 1995-2005“ koja obuhvata sva najznačajnija dostignuća u ovoj oblasti. Navedenu studiju su dopunili Baker i Yacef (Baker, R. S. J. D., i Yacef, 2009). Studije obuhvataju skoro sva pitanja u oblasti obrazovanja od upisa u školu (fakultet) pa do veb-baziranog obrazovanja. Istraživanja u području upotrebe inteligentnih metoda za predviđanje uspješnosti studenata uglavnom su orientisana na razvoj modela koji će se koristiti kao pomoć pri odlučivanju o prijemu studenata na studije (Witten i dr. 2000; Romero i dr, 2008). Takvi modeli kao kriterije uzimaju u obzir informacije o kandidatu koje su raspoložive prije upisa, kao npr. završena srednja škola, uspjeh u srednjoj školi, socijalni status i druge informacije prije studija, te uz pomoć statističkih metoda ili metoda vještačke inteligencije nastoje pronaći model koji će produkovati što veću tačnost u predviđanju. Predviđanje uspješnosti u studiranju metodama *data mining*-a umnogome zavisi od kvaliteta prikupljenih podataka. Čini se ipak da nije moguće formirati jedinstven prediktivni model koji bi bio primjenljiv u svim obrazovnim sistemima, ali rezultati dosadašnjih istraživanja ukazuju da određene grupe varijabli treba uvijek uzimati u obzir jer sa visokim stepenom vjerovatnoće učestvuju u predviđanju uspjeha.

U našem radu smo primijenili data mininga za predikciju uspjeha studenata (neuronske mreže, stabla odlučivanja i logističku regresiju).

### 1.6.1 Primjena logističke regresije

Logistička regresija ili logistički model ili logit model se koristi za predviđanje vjerovatnoće događaja putem prilagođavanja podataka logističkoj krivi. Logistička regresija je tip regresione analize u kojoj je zavisna (kriterijumska) promjenljiva dihotomna, odnosno binarna i kodira se sa 0 ili 1 i postoji najmanje jedna nezavisna (prediktorska) promjenljiva. S obzirom da su obrazovne pojave često dihotomne, česta je i primjena logističke regresije u predviđanju tih pojava. Neka prethodna istraživanja nam ukazuju na relativno visok nivo uspješnosti ove metode. Koristeći dvanaest ulaznih varijabli koje opisuju status

studenata (pol, etnička pripdost, način studiranja, način finasiranja, vrsta studija i sl.). Lurens (Loureens, A, 2010) je na Univerzitetu u Južnoj Africi ispitivao predikciju uspeha na prvoj godini visokog obrazovanja koristeći logističku regresiju i dobio rezultat 74.68%. Woodman (Woodman, 2001) je realizovao istraživanje na Open University iz UK uz upotrebu 25 prediktora, te uz pomoć logističke regresije pokušao doći do modela koji bi najbolje predviđao da li će neki student proći na nekom ispit. Autor zaključuje da je logistička regresija pogodna kad se radi sa malim uzorcima. Kod velikog broja varijabli koje se primjenjuju na velikim uzorcima male razlike imaju relativno visok stepen značajnosti što može dovesti do pogrešnog zaključka o značajnosti varijable u ukupnom modelu. Do sličnog rezultata su došli Kotsiantis i dr. (Kotsiantis, Pierrakeas & Pintelas, 2004) primjenom nekoliko metoda (decision trees, artificial neural networks, naive Bayes classifier, instance-based learning, logistic regression and support vector machines) za predviđanje uspjeha studenata uz primjenu većeg broja prediktora.

**Tumačenje modela logističke regresije.** Statističko modelovanje binarnih promjenljivih podrazumijeva mjerjenje izbora koje za svaki subjekat može biti uspješno ili neuspješno. Binarni podaci su vjerovatno najčešći oblik kategorijskih podataka. Jedan od najrasprostranjeniji modela binarnih podataka je logistička regresija.

Za binarni izbor Y i kvantitativnu objašnjavajuću promjenljivu X, neka  $\pi(x)$  predstavlja vjerovatnoću uspjeha kada X ima vrijednost x. Ova vjerovatnoća je parametar za binomnu distribuciju. Model logističke regresije ima linearni oblik za logit ove vjerovatnoće.

$$\text{logit}[\pi(x)] = \log\left(\frac{\pi(x)}{1 - \pi(x)}\right) = \alpha + \beta x$$

Ova formula prikazuje da  $\pi(x)$  raste ili opada sa S-funkcijom od x.

Druga formula za logističku regresiju odnosi se direktno na vjerovatnoću uspjeha. Ova formula koristi eksponencijalnu funkciju  $\exp(x) = e^x$  u obliku

$$\pi(x) = \frac{\exp(\alpha + \beta x)}{1 + \exp(\alpha + \beta x)}$$

**Tumačenje linearne aproksimacije.** Parametar  $\beta$  određuje stopu rasta ili opadanja S-krive. Oznaka  $\beta$  ukazuje na to da li je kriva opadajuća ili rastuća, kao i na stopu rasta promjene kako  $|\beta|$  raste. Kada model ima vrijednost  $\beta = 0$ , desna strana Jednačine 3 pojednostavljuje se u konstantu. Zatim,  $\pi(x)$  je identičan sa svim x, te kriva prelazi u horizontalnu pravu liniju. Binarni izbor Y postaje potom konstanta X.

**Tumačenje racija vjerovatnoće dešavanja.** Naredno tumačenje modela logističke regresije koristi vjerovatnoću dešavanja i raciju vjerovatnoće dešavanja. Kao model vjerovatnoće izbora (to jest, izgledi za uspjehom) koristiti se sljedeća jednačina:

$$\frac{\pi(x)}{1 - \pi(x)} = \exp(\alpha + \beta x) = e^\alpha (e^\beta)^x$$

Eksponencijalni odnos pruža tumačenje za  $\beta$ : Izgledi se povećavaju multiplikativno za  $e^\beta$  za svako povećanje od jedne jedinice po x. Drugim riječima, vjerovatnoća na nivou  $x+1$  jednaka je vjerovatnoći pri x pomnoženo sa  $e^\beta$ . Kada je  $\beta = 0$ ,  $e^\beta = 1$  tada se vjerovatnoća ne mijenja kako se mijenja vrijednost x.

Logaritam vjerovatnoće, što predstavlja logit transformaciju  $\pi(x)$ , ima linearni odnos. Ovde se radi o logit izrazu modela, što govori da se logit povećava uz  $\beta$  jedinicu za svaku jedinicu promjene pri x. Većina ne shvata logit skalu kao nešto prirodno, tako da ona ima ograničenu upotrebu.

**Test značaja.** Kod modela logističke regresije, nulta hipoteza  $H_0 : \beta = 0$  znači da je vjerovatnoća uspjeha nezavisna od X.

Kod većih uzoraka, statistika testa

$$z = \frac{\beta'}{ASE}$$

$\beta$  – koeficijent zakriveljenosti funkcije

ASE – standardna greška

ima standardnu, normalnu distribuciju kada je  $\beta = 0$ . Uz to, z se može pridodati standardnoj tabeli da bismo dobili jednostranu ili dvostranu P-vrednost. Isto tako, za dvostranu alternativu  $\beta \neq 0$ ,  $(\beta' / ASE)^2$  važi Valdova statistika kod koje važiksi-kvadratna distribucija velikog uzorka sa  $df = 1$ .

Iako Valdov test dobro funkcioniše kod velikih uzoraka, test racija vjerodostojnosti je efektniji i pouzdaniji za veličine uzorka koje koristimo u praksi. Statistika testa poredi maksimalni  $L_0$  log-funkcije vjerodostojnosti kada je  $\beta = 0$  (to jest, kada  $\pi(x)$  mora da bude identična sa svim vrijednostima x) do maksimalnog  $L_1$  log-funkcije vjerodostojnosti za nerestriktivnu  $\beta$ . Statistika testa,  $-2(L_0 - L_1)$ , takođe ima ksi-kvadratnu distribuciju velikog uzorka sa  $df = 1$ . Većina softvera za logističku regresiju daje podatke za maksimalnu log-vjerodostojnost  $L_0$  i  $L_1$ , a statistika racija vjerodostojnosti dobija se iz ovih maksima.

**Distribucija proračuna vjerovatnoće.** Procjenjena vjerovatnoća da je  $Y = 1$  pri fiksnom skupu  $x$  od  $X$  iznosi

$$\pi(x) = \frac{\exp(\alpha + \beta x)}{1 + \exp(\alpha + \beta x)}$$

Većina softvera za logističku regresiju može da prikaže procjene kao i intervale pouzdanosti za prave vjerovatnoće.

### 1.6.2 Primjena stabala odlučivanja

U cilju izgradnje što uspješnijeg modela, na posmatranom uzorku testirana je jedna od neparametrijskih metoda rudarenja podataka: stablo odlučivanja, tačnije njihova podvrsta klasifikaciona i regresiona stabla (*Classification and Regression Trees*, CART). Ovom metodom dobiva se grafički prikaz modela uticaja ulaznih varijabli na izlaznu, koja je izražena u obliku klasa ili kategorija. Svaki čvor u grafičkom stablu predstavlja jednu ulaznu varijablu, na čijim su rubovima označena „djeca čvorovi“ za svaku moguću vrijednost neke ulazne varijable. Svaki list u stablu predstavlja vrijednost ciljne (izlazne) varijable ako su date vrijednosti ulaznih varijabli predstavljene putem od korijena stabla do tog lista. Stablo se dobija „učenjem“ na podacima, na način da se vrši grananje (*splitting*) izvornog skupa podataka u podskupove na osnovu testiranja vrijednosti varijabli. Proces se ponavlja na svakom izvedenom podskupu na rekurzivni način (*recursive partitioning*). Rekurzija je završena kada podskup određenog čvora ima sve iste vrijednosti izlazne varijable, ili kada dalje grananje više ne pridonosi poboljšanju rezultata (Witten, Frank, 2000).

Za izgradnju stabla korištenje CART algoritam (Breiman et al, 1984), koji na osnovu raspoloživih podataka o ulaznim i izlaznim varijablama kreira binarno stablo grananjem slogova u svakom čvoru prema funkciji određenoj za svaku ulaznu varijablu. Evaluaciona funkcija korišćena za prelom je Gini indeks (IG), definisan prema formuli:

$$I_G(t) = 1 - \sum_{i=1}^m p_i^2$$

gdje je  $t$  trenutni čvor,  $p_i$  je vjerovatnoća klase  $i$  u čvoru  $t$ , a  $m$  je broj klasa umodelu (u našem slučaju  $m=2$ ).

Stablo u ovom radu kreirano je na osnovu 16 ulaznih kategorijalnih varijabli definisanih u trećem poglavlju. Stabla odlučivanja su čest alat u predviđanju uspjeha studenata u studiranju sa stepenom uspješnosti većim od 65% (Romero, 2008). Stepen uspješnosti zavisi od

uzorka, izabranih varijabli i kriterijuma procjenjivanja. U jednom istraživanju u Indoneziji (Sembiring i dr., 2011) korišćene su četiri grupe varijabli kao prediktori i to: *Interest*, *Study Behavior*, *Engage Time* and *Family Support*. Kategorijalne varijable su bile: *excellent*, *very good* and *good*. Stablo odlučivanja je u prosjeku 69,33% uspješno predviđalo sve slučajeve. Istraživanje sprovedeno na Novom Zelandu (Kovačić J. Z., 2009) upotrebom CART algoritma pokazuje da se uspjeh studenata može uspješno predvidjeti u 62,3% slučajeva. Navedeni rezultat potvrdio je koristeći stablo odlučivanja.

Neka istraživanja pokazuju i nešto slabije rezultate u predviđanju uspjeha pomoću data mining. U radu (Vandamme, Meskens & Superby, 2007) korišćena su stabla odlučivanja, neuronske mreže i linearnu analizu diskriminanti za ranu identifikaciju tri kategorije studenata: *low risk*, *medium risk* i *high risk*. Neki od podataka o studentima prve godine (demografski podaci i prethodni akademski uspeh) na frankofonim belgijskim univerzitetima su značajno korelirani sa akademskim uspehom. U pitanju su bili sljedeći podaci: prethodno obrazovanje, broj časova matematike, finansijska nezavisnost i uzrast. Sa druge strane, pol, obrazovanje i profesija roditelja i bračni status nisu značajno uslovjavali akademski uspeh. Međutim, sve tri metode korišćene za predikciju nisu se pokazale dovoljno dobro. Ukupno gledano, korektno klasifikovanih slučajeva je bilo 40.63% pomoću stabala odlučivanja, 51.88% pomoću neuronskih mreža i 57.35% pomoću linearne analize diskriminanti.

### 1.6.3 Primjena neuronskih mreža

Neuronske mreže simuliraju način rada ljudskog mozga pri obavljanju datog zadatka ili neke funkcije. Neuronska mreža je masovno paralelizovan distribuirani procesor sa prirodnom sposobnošću memorisanja iskustvenog znanja i obezbeđivanja njegovog korišćenja. Vještačke neuronske mreže podsjećaju na ljudski mozak u dva pogleda:

- neuronska mreža zahvata znanje kroz proces obučavanja,
- težine međuneuronskih veza (jačina sinaptičkih veza) služe za memoriranje znanja (Milosavljević, 2005).

Vještačke neuronske mreže spadaju u inteligentne metode *data mining-a*, čiji je cilj da pronađe skrivene veze među podacima. Vještačka neuronska mreža je međusobno povezana grupa jednostavnih elemenata obrade, jedinica ili čvorova, čiji se rad zasniva na načinu djelovanja neurona kod živih bića. Sposobnost obrade mreže je posljedica jačine veza među tim jedinicama, a postiže se kroz proces adaptacije ili učenjem iz skupa primjera za učenje (Russell, 2002).

Drugim riječima, neuronske mreže su programi ili hardverski sklopovi koji, najčešće iterativnim postupkom iz prošlih podataka nastoje pronaći vezu između ulaznih i izlaznih varijabli modela, kako bi se za nove ulazne varijable dobila vrijednost izlaza. Vještački neuron je jedinica za obradu podataka (varijabli) koja prima ponderisane ulazne vrijednosti od drugih varijabli, prema nekoj formuli transformiše primljenu vrijednost te šalje izlaz drugim varijablama. Učenje se odvija promjenom vrijednosti „težina“ među varijablama (težine su ponderi kojima se množe ulazne vrijednosti u neki „neuron“). S obzirom na broj slojeva, tip učenja, tip veze između neurona, veza između ulaznih i izlaznih podataka, ulazne i prenosne funkcije, namjenu, razlikuju se brojni algoritmi neuronskih mreža. Zbog njegove opšte namjene (budući da je pogodan i za probleme predviđanja i klasifikacije), te učestale upotrebe u istraživanjima, za modelovanje je korišten algoritam višeslojni perceptron. Višeslojni perceptron pripada u nadgledane algoritme sa vezom unaprijed (*feed forward*), u kojoj se slojevi mreže povezuju na način da signali putuju samo u jednom smjeru, od ulaza ka izlazima mreže. Najpoznatiji i najčešće upotrebljavani algoritam primijenjen za učenje i treniranje višeslojnih perceptron mreža je tzv. mreža „širenje unatrag“ (*backpropagation*). Algoritam mreže „širenje unatrag“ bio je presudan za široku komercijalnu upotrebu ove metodologije, te je neuronske mreže učinio široko upotrebljavanom i popularnom metodom u različitim područjima. Standardni algoritam mreže „širenje unatrag“ uključuje optimizaciju greške koristeći deterministički algoritam gradijentnog opadanja (*gradient descent*) (Milosavljević, 2005). Glavni nedostatak ovog algoritma je problem čestog pronalaženja lokalnog umjesto globalnog minimuma greške, te stoga novija istraživanja uključuju njegovo unapređivanje nekim drugim determinističkim (npr. metode drugoga reda) ili stohastičkim metodama (npr. simulirano kaljenje). Strukturu mreže čine ulazni sloj, izlazni sloj i najmanje jedan skriveni sloj sa vezom unaprijed.

Jedni od prvih autora u tom području koji koriste neuronske mreže su (Hardgrave i dr., 1994) koji upoređuju neuronske mreže i tradicionalne statističke tehnike u predviđanju uspješnosti studenata na diplomskom studiju. Dalji rad istih autora naglašava kako se odluka o tome da li primiti nekog studenta na studije zasniva na brojnim faktorima, te je nužno razviti prediktivne modele koji će omogućiti nekom fakultetu upisivanje onih studenata za koje je postoji visoka vjerovatnoća da će studirati uspješno. Njihovo istraživanje pokazuje sljedeće: (a) klasifikacione tehnike su pogodnije za predviđanje uspjeha studenata od prediktivnih metoda, (b) predviđanje uspjeha ili neuspjeha studenata na diplomskom studiju nije dovoljno tačno ako se koriste samo tipični podaci koji opisuju studenta, i (c) neparametrijske procedure, kao što su neuronske mreže, produkuju barem jednako

tačan rezultat kao i tradicionalne metode i vrijedan su potencijal za dalja istraživanja u tom području.

Istim problemom odlučivanja o prijemu kandidata na studije bavili su se i Naik i Regotman (Naik i Ragothaman, 2004), koji su istraživali uspješnost na MBA studiju. Koristili su neuronske mreže, logit i probit modele za predviđanje uspješnosti studenata koji se upisu na MBA studije. Neuronske mreže su klasifikovale studente u uspješne i neuspješne na osnovu njihovog prosjeka ocjena na preddiplomskom studiju, rezultatima GMAT testa, smjera na preddiplomskom studiju, starosti i drugih varijabli. Rezultati pokazuju da su neuronske mreže jednako uspješne kao i ostale tehnike, ali ih zbog brojnih prednosti preporučuju za upotrebu u tom području.

Istraživanje (Sulaimana i Mohezara, 2006), bavi se istom tematikom, ali ide korak dalje u identifikovanju ključnih faktora uspješnosti. Njihov model pokazao je da je dosadašnji prosjek ocjena studenta najznačajniji prediktor njegove daljnje uspješnosti, dok variable poput starosti, etničke pripadnosti, pola, te godina radnog iskustva nisu značajne za uspješnost studiranja.

Autori iz Malezije (Zaidah i Daliela, 2008) su uporedili neuronske mreže, stabla odlučivanja i linearnu regresionu analizu u predviđanju uspješnosti studenata. Uspjeh su mjerili kumulativnim prosjekom ocjena tokom studija, a kao ulazne varijable koristili su demografski profil studenata i prosjek ocjena na prvom semestru preddiplomskog studija. Rezultati pokazuju da su sve tri metode proizvele tačnost veću od 80%, dok neuronske mreže daju veću tačnost od ostalih dviju metoda.

Autori sa fakulteta organizacionih nauka u Beogradu (Vukićević i dr., 2010), su koristili neuronske mreže za predviđanje uspjeha studenata koristeći podatke o studentima, koji obuhvataju lične podatke i podatke o uspjehu na prvoj godini studija, ukupno 14 različitih varijabli. Kao izlaz iz neuronske mreže, za svakog studenta neuronska mreža je kreirala promenljivu koja predstavlja predviđenju prosječnu ocjenu na kraju studija. Testirano je ukupno šest algoritama za obučavanja od kojih se najbolji algoritam po svim kriterijumima izdvojio *Exhaustive Prune*. Karamouzis i dr. (Karamouzis i dr. 2008) su koristili dvanaest ulaznih parametara za predviđanje uspjeha 307 studenata. Uspješnost predviđanja bila je na nivou 70.27% za uspješne i 66.29% za neuspješne.

## **1.7 Cilj, zadaci i hipoteza istraživanja**

Na osnovu definisanog predmeta istraživanja izdvajaju se ciljevi koji bi se mogli svrstati u dvije grupe i to:

- analiza postojećih informacionih modela koji su u upotrebi u sistemima obrazovanja sa stanovišta mogućnosti unapređivanja njihovih performansi;
- definisanje informacionog modela koji bi uz adekvatnu softversku podršku mogao pružiti dovoljnu količinu informacija za predikciju ponašanja pojedinih dijelova obrazovnog sistema, a posebno uspješnosti studenta u studiranju.

Postavljeni ciljevi rada nameću potrebu definisanja osnovnih hipoteza kao pretpostavki o mogućem rješavanju problema. Osnovne hipoteze ovog rada su:

1. Moguće je definisati model podataka za evidenciju uspjeha studenata koji će biti u skladu sa potrebama predikcije i obrazovnom praksom u visokoškolskim ustanovama, čija reprezentacija je data u formalnom i mašinski čitljivom obliku.
2. Moguće je odabrati i definisati tehnike za predikciju uspješnosti studiranja koje će biti bazirane na prethodno definisanom modelu.
3. Moguće je realizovati informacioni sistem za podršku predviđanju uspjeha studenata koji će omogućiti da predviđanje uspješnosti studiranja postane integralni deo informacionog sistema za podršku učenju koji se može koristiti u praksi.

## 2 Standardi za reprezentaciju profila studenata

Danas još ne postoji univerzalno prihvaćen standard za reprezentaciju podataka o studentima (profila studenta). Postoji više inicijativa za standardizaciju modela učenika. Dvije najvažnije specifikacije u ovoj oblasti su IEEE LTSC PAPI (PAPI, 2002) i IMS LIP (IMS LIP, 2005). Ovi standardi definišu, prije svega, apstraktne modele profila učenika, ali definišu i mapiranje takvih modela na konkretnu sintaksu nekog od više jezika, npr. XML. Cilj ovih standarda je definisanje standardnog formata za razmjenu podataka o profilima učenika na takav način da se omoguće efikasno skladištenje, pristup, obrada i pretraživanje. Postoje značajne razlike između ova dva standarda. Fokus PAPI standarda je da definiše minimalan skup informacija koji će omogućiti praćenje uspješnosti učenika tokom učenja. On obuhvata koncepte kao što su performanse učenika, portfolio i veze sa drugim učenicima. Sa druge strane, LIP standard definiše bogatije strukture podataka koje obuhvataju i ciljeve učenika, interesovanja i osobine učenika iz aspekta personalizacije sadržaja.

### 2.1 IEEE LTSC PAPI

*Public and Private Information (PAPI) for Learners (PAPI Learner)* (PAPI, 2002) standard je specifikacija koja opisuje učenika za potrebe razmjene podataka između sistema za podršku učenju. Pri tome, komunikacija se može oslanjati isključivo na *PAPI Learner* standard ali i na druge specifikacije. PAPI je propisao komitet IEEE LTSC (*Institute of Electrical and Electronic Engineers, Learning Technology Standards Committee*). Razmjena podataka može se odvijati na različite načine:

1. Na nivou usvojenog formata poruka: koristi se samo *PAPI Learner* kodiranje podataka, dok se metod za komunikaciju ugovara između strana koje razmjenjuju podatke.
2. Na nivou usvojenog programskog interfejsa (API): koristi se PAPI specifikacija programskog interfejsa.
3. Na nivou komunikacionog protokola: koristi se PAPI specifikacija protokola za razmjenu podataka.

Važna osobina *PAPI Learner* standarda je logička podjela, odvojena bezbjednost i razdvojena administracija više različitih tipova informacija o učeniku (tzv. zapisa o učeniku, *learner records*). Ovi tipovi informacija su poznati kao profili učenika (*learner profiles*). Standard se sastoji iz sljedećih dijelova:

1. IEEE 1484.2.1 – *Core Features*: zajednički elementi svih dijelova standarda, kao što su zajednički model podataka i reference na druge standarde.
2. IEEE 1484.2.2 – *Rationale*: objašnjenja odluka donošenih tokom razvoja ovog standarda.
3. IEEE 1484.2.3 – *Learner Information Security Issues*: informacije i preporuke za pitanja bezbjednosti informacija u implementaciji ovog standarda.
4. IEEE 1484.2.4 – *Examples and Illustrations*: informacije koje su od pomoći u implementaciji standarda.
5. IEEE 1484.2.5 – *Registration Authority Process*: definiše način registracije i održavanja podataka iz kontrolisanih skupova (šifarnika), načina za kodiranje podataka, skupova validnih podataka i slično.
6. IEEE 1484.2.6 – *Data Element Registry*: registar postojećih elemenata podataka, skupova validnih podataka, načina za kodiranje podataka i slično.
7. IEEE 1484.2.21 – *Learner Contact Information*: lični podaci o učeniku.
8. IEEE 1484.2.22 – *Learner Relations Information*: podaci o osobama sa kojima je učenik sarađivao u toku učenja (učenici iz iste učionice/razreda/klase, članovi timova, mentori) i vezama između njih.
9. IEEE 1484.2.23 – *Learner Security Information*: podaci o privatnim i javnim ključevima učenika, biometrijski podaci, akreditivi i slično.
10. IEEE 1484.2.24 – *Learner Preference Information*: podaci o upotrebljivim i neupotrebljivim ulazno-izlaznim uređajima za posmatranog učenika, fizička ograničenja, stilovi učenja.
11. IEEE 1484.2.25 – *Learner Performance Information*: informacije o uspjehu učenika, kao što su ocjene, periodični izveštaji i dnevničci.
12. IEEE 1484.2.26 – *Learner Portfolio Information*: informacije o postignućima učenika, realizovanim radovima i slično.

*PAPI Learner* standard definiše strukture podataka o učenicima pomoću ISO/IEC 11404 tipova podataka opšte namene (*general purpose datatypes*, GPD) sa ciljem da definicija strukture ovih podataka bude upotrebljiva u različitim kontekstima i tehnologijama za implementa-

ciju softvera. Pored toga, standard obuhvata i kodiranje ovako definisanih struktura podataka na XML i DNVP sintaksu.

### 2.1.1 Primjer opisa studenta

U listingu 2.1 dat je primjer XML reprezentacije *PAPI Learner* ličnih podataka o studentu. Primjer iz listinga ilustruje širok opseg podataka o učeniku koji je predviđen ovim standardom. Pravilna implementacija standarda mora voditi računa o zaštiti privatnosti, odnosno dostupnosti ovih informacija u skladu sa preporukama iz sekcije IEEE 1484.2.3. Za identifikaciju učenika koristi se ISO/IEC 21484-13 *Simple Human Identifiers* standard.

```
<my_contact_identifier_list>
  <contact_identifier>
    <identifier_kind>pointer</identifier_kind>
    <identifier_value>0x12345678</identifier_value>
  </contact_identifier>
</my_contact_identifier_list>
<my_contact_hid_list>
  <learner_hid>
    <identifier_kind>ISO_IEC_21484_13</identifier_kind>
    <identifier_value>00112233</identifier_value>
  </learner_hid>
</my_contact_hid_list>
<name_list>
  <name>
    <official_name>
      <primary>Public</primary>
      <secondary>Joseph Q.</secondary>
    </official_name>
    <sort_name locale="en-US">Public, Joseph Q.</sort_name>
    <short_informal_name locale="en-US">Joe</short_informal_name>
  </name>
</name_list>
<telephone_list>
  <telephone>
    <context_label>home</context_label>
    <identifier_kind>voice</identifier_kind>
    <phone_number>+12125551212</phone_number>
  </telephone>
  <telephone>
    <context_label>work</context_label>
    <identifier_kind>fax</identifier_kind>
    <phone_number>+12125551414</phone_number>
  </telephone>
</telephone_list>
<email_contact_list>
  <email_contact>
    <context_label>home</context_label>
    <email_address_type>rfc822</email_address_type>
    <email_address>foobar@mail.com</email_address>
```

```

        </email_contact>
    </email_contact_list>
<postal_address_list>
    <postal_address>
        <context_label>school</context_label>
        <addressee>
            <name>
                <given>Joseph Q.</given>
                <family>Public</family>
            </name>
        </addressee>
        <delivery>
            <street>
                <number>123</number>
                <name>Main</name>
                <street_type>Street</street_type>
            </street>
            <city>New York</city>
            <territory>NY</territory>
            <routing>10001</routing>
            <country>USA</country>
        </delivery>
    </postal_address>
</postal_address_list>
<contact_bucket>
    <bucket>
        <name>us_social_security_number</name>
        <value>123-45-6789</value>
    </bucket>
    <bucket>
        <name>payment_method</name>
        <value>371234567890123/200212/John Q. Public</value>
    </bucket>
</contact_bucket>

```

Listing 2.1 *PAPI Learner* – primjer ličnih podataka o učeniku (PAPI, 2002)

Posebno interesantan dio *PAPI Learner* specifikacije jeste mogućnost opisa informacija o vezama učenika sa drugim osobama u mašinski čitljivom obliku koji omogućava kasniju analizu. Listing 2.2 predstavlja primjer podataka o vezama učenika sa drugim osobama. U primjeru je prikazana veza između posmatranog učenika i drugog učenika iz istog odjeljenja. Referenciranje na druge osobe oslanja se na ISO/IEC 21484-13 *Simple Human Identifiers* standard. Listing 2.3 predstavlja primjer podataka o lozinkama za autentikaciju i akreditivima učenika.

```

<my_relations_identifier_list>
    <relations_identifier>
        <identifier_kind>pointer</identifier_kind>
        <identifier_value>0x12345678</identifier_value>
    </relations_identifier>
</my_relations_identifier_list>
<my_relations_hid_list>

```

```

<learner_hid>
    <identifier_kind>ISO_IEC_21484_13</identifier_kind>
    <identifier_value>44556677</identifier_value>
</learner_hid>
</my_relations_hid_list>
<relationship_list>
    <relationship>
        <others_identifier_list>
            <others_identifier>
                <identifier_kind>ISO_IEC_21484_13</identifier_kind>
                <identifier_value>44556688</identifier_value>
            </others_identifier>
            <others_identifier>
                <identifier_kind>ISO_IEC_21484_13</identifier_kind>
                <identifier_value>44556699</identifier_value>
            </others_identifier>
        </others_identifier_list>
        <relationship_label_list>
            <relationship_label LANG="en-US">
                history_101_section_3
            </relationship_label>
        </relationship_label_list>
        <relationship_to_them>classmate</relationship_to_them>
    </relationship>
</relationship_list>
</my_relations_identifier_list>

```

Listing 2.2 *PAPI Learner* – primjer opisa veze između učenika (PAPI, 2002)

```

<my_security_identifier_list>
    <security_identifier>
        <identifier_kind>pointer</identifier_kind>
        <identifier_value>0x12345678</identifier_value>
    </security_identifier>
</my_security_identifier_list>
<my_security_hid_list>
    <learner_hid>
        <identifier_kind>ISO_IEC_21484_13</identifier_kind>
        <identifier_value>88990011</identifier_value>
    </learner_hid>
</my_security_hid_list>
<credential_list>
    <credential>
        <context_label>home</context_label>
        <credential_kind>password</credential_kind>
        <credential_value>swordfish</credential_value>
    </credential>
    <credential>
        <context_label>work</context_label>
        <credential_kind>biometric_type_1</credential_kind>
        <credential_value>120398123b10931203123</credential_value>
    </credential>
</credential_list>

```

Listing 2.3. *PAPI Learner* – primjer podataka o akreditivima i autentikaciji (PAPI, 2002)

## 2.2 IMS LIP

IMS LIP (*Learner Information Profile*) standard (IMS LIP, 2005) definiše strukture podataka, XML reprezentaciju i primjere dobre prakse za strukturiranje, skladištenje i razmjenu podataka o učeniku. IMS LIP je propisao IMS *Global Learning Consortium* [IMSGlobal]. Ova specifikacija omogućava razmjenu informacija između sistema za podršku učenju, sistema za podršku upravljanju ljudskim resursima, informacionih sistema obrazovnih ustanova, korporacijskih sistema za e-učenje, sistema za upravljanje znanjem, repozitorijuma biografija i drugih informacionih sistema koji učestvuju u procesu učenja. Svi ovakvi sistemi se iz perspektive LIP standarda posmatraju kao sistemi koji čuvaju podatke o učeniku bez obzira na njihove ostale funkcije. LIP definiše strukture podataka za opis profila učenika pomoću XML Schema jezika. Protokol za razmenu podataka nije obuhvaćen ovim standardom.

Vrste informacija koje se modeluju ovim standardom su sljedeće:

1. **Identifikacioni podaci:** biografski i demografski podaci (npr. ime, adresa, kontakt). Data je detaljnija specifikacija u odnosu na istu kod *PAPI Learner* modela.
2. **Ciljevi:** sadrže opise ciljeva konkretnog studenta i to prvenstveno u domenu obrazovanja i karijere. Ovi opisi mogu sadržati i informacije relevantne za praćenje napredovanja studenta u ostvarivanju postavljenih ciljeva.
3. **QCL paket** (*Qualifications, Certifications And Licenses*): informacije o studentovim kvalifikacijama, sertifikatima i licencama.
4. **Aktivnosti:** bilježi sve aktivnosti studenta koje se odnose na obrazovanje (npr. pohađani kursevi) i rezultatima koje je ostvario na procenama znanja nakon svakog od tih kurseva.
5. **Kompetencije:** informacije o vještinama, znanjima i sposobnostima studenta koje je on stekao u kognitivnom, afektivnom i/ili psihomotornom domenu.
6. **Transkript** (prepis): sumarni pregled akademskih ostvarenja učenika.
7. **Dostupnost:** opisuje generalno pristupačnost učenikovim podacima i kognitivnim, fizičkim i tehnološkim mogućnostima učenika, kao i o postojanju nekih nedostataka zbog kojih je potreban poseban pristup.
8. **Interesovanja:** informacije o hobijima i drugim rekreativnim aktivnostima studenta.

9. **Pripadnost:** pripadnost studenta različitim profesionalnim, obrazovnim i drugim organizacijama.
10. **Bezbjednosni podaci:** ključevi, lozinke ili drugi podaci kojise dodjeljuju učeniku za potrebe pristupa sistemu.
11. **Veze:** daje opis veza između pojedinih tipova informacija o studentu.

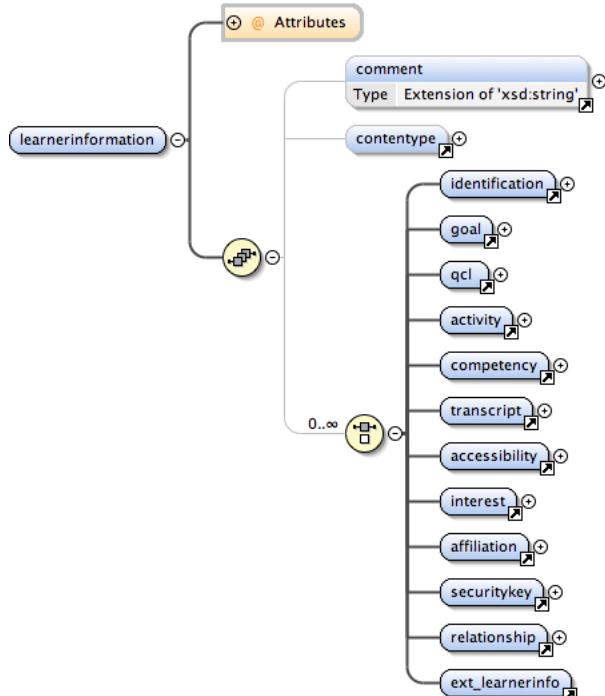
Ključna osobina ovog standarda je podrška za proširenja. Proširenja se mogu uvoditi na tri načina.

1. **Proširenja definicija:** predstavljaju proširenja LIP specifikacije u skladu sa dogovorom sistema koji učestvuju u razmjeni podataka. Interna organizacija ovakvih proširenja nije obuhvaćena standardom, ali način na koji se strukturiraju i koriste je precizno definisan.
2. **Proširenja rečnika:** predstavljaju proširenja osnovnih rečnika podataka korišćenih u specifikaciji. Mnogi elementi u strukturi podataka imaju dodeljene rečnike koje održava IMS konzorcijum. Proširenja se mogu referencirati pomoću URI reference.
3. **Funkcionalna proširenja:** predstavljaju proširenja koja omogućavaju korisnicima standarda da uvode funkcionalnost koja nije inicijalno predviđena standardom.

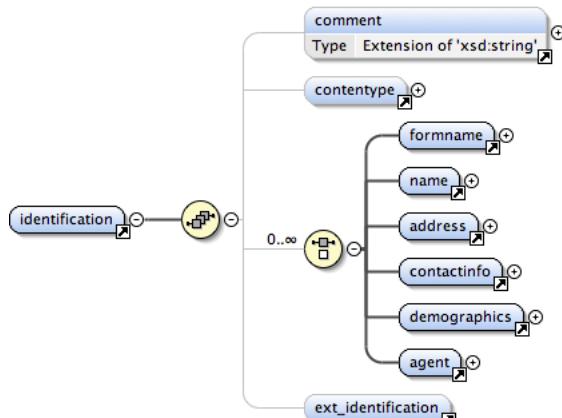
IMS LIP je formalno definisan kao XML Schema dokument. Slika 2.1 predstavlja learnerinformation kao korijenski element ove šeme. Element learnerinformation predstavljen kao sekvenca podelemenata koji predstavljaju prethodno predstavljene osnovne komponente profila učenika. U daljem tekstu biće prikazani najvažniji elementi ove strukture radi analize primjene LIP standarda za ciljeve koje definiše ova disertacija. Ovi elementi će biti prikazani kroz niz dijagrama. Cjelovit prikaz strukture definisane LIP standardom izostavljen je iz tehničkih razloga – dobijeni dijagram je prevelik za reprodukciju u štampanom dokumentu, ali se može dobiti primenom nekog od softverskih paketa za analizu XML šema.

U skoro svim delovima šeme pojavljuju se odrijeđeni elementi koji imaju generičko značenje – element comment predstavlja komentar o posmatranom elementu čitljiv za čoveka, element contenttype predstavlja tehnički opis vrste podataka kojima se rukuje u datom elementu, dok elementi čiji naziv počinje sa ext\_ predstavljaju standardno mjesto za uvođenje proširenja u ovaj model podataka.

Identifikacioni podaci o učeniku predstavljeni su na slici 2.2. U poređenju sa PAPI Learner standardom, LIP obuhvata više vrsta podataka, pre svega demografske podatke koji su relevantni za proces učenja.

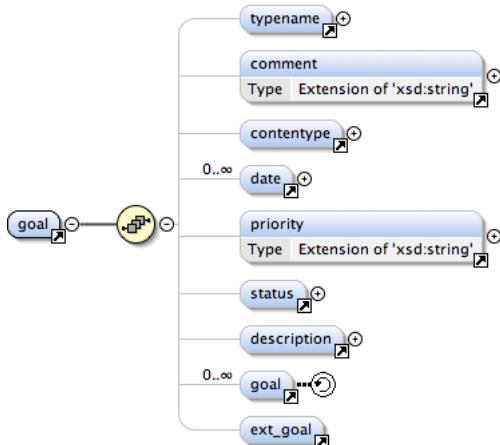


Slika 2.1 IMS LIP – element learnerinformation



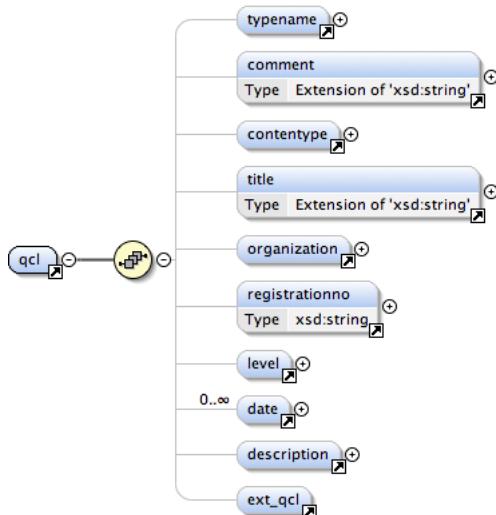
Slika 2.2 IMS LIP – element identification

Podaci o ciljevima učenika predstavljeni su na slici 2.3. Element typename predstavlja vrstu cilja i uzima vrijednost iz rječnika. Cilj je iskazan verbalnim opisom (description), prioritetom (priority), stanjima (status) i datumima relevantnim za stanje cilja (date). Element goal predstavlja podciljeve i omogućava izgradnju hijerarhije ciljeva pri čemu su podciljevi opisani identičnom strukturu.



Slika 2.3 IMS LIP – element goal

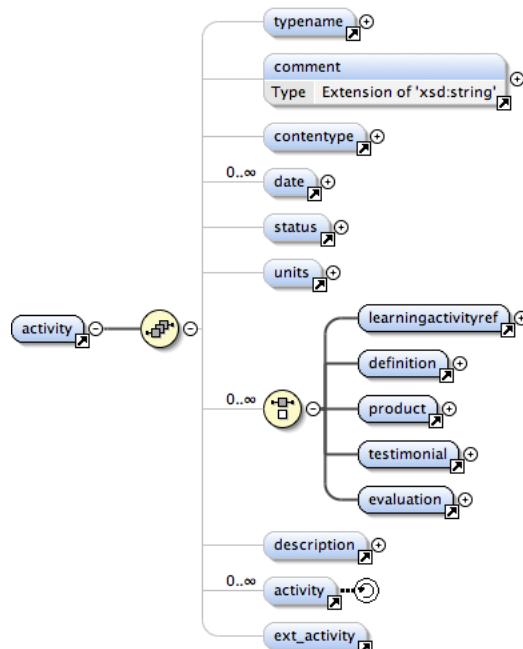
Podaci o kvalifikacijama, sertifikatima i licencama su predstavljeni elementom qcl sa slike 2.4. Elementom typename (vrijednost iz rječnika) predstavljena je vrsta kvalifikacije, sertifikata ili licence. Naziv je dat elementom title, organizacija koja je izdala dokument je data elementom organization, dok je identifikator te organizacije predstavljen elementom registrationno. Nivo kvalifikacije, sertifikata ili licence je predstavljen elementom level, a njen tekstualni sadržaj elementom text. Verbalni opis je dat elementom description. Datum sticanja je predstavljen elementom date.



Slika 2.4 IMS LIP – element qcl

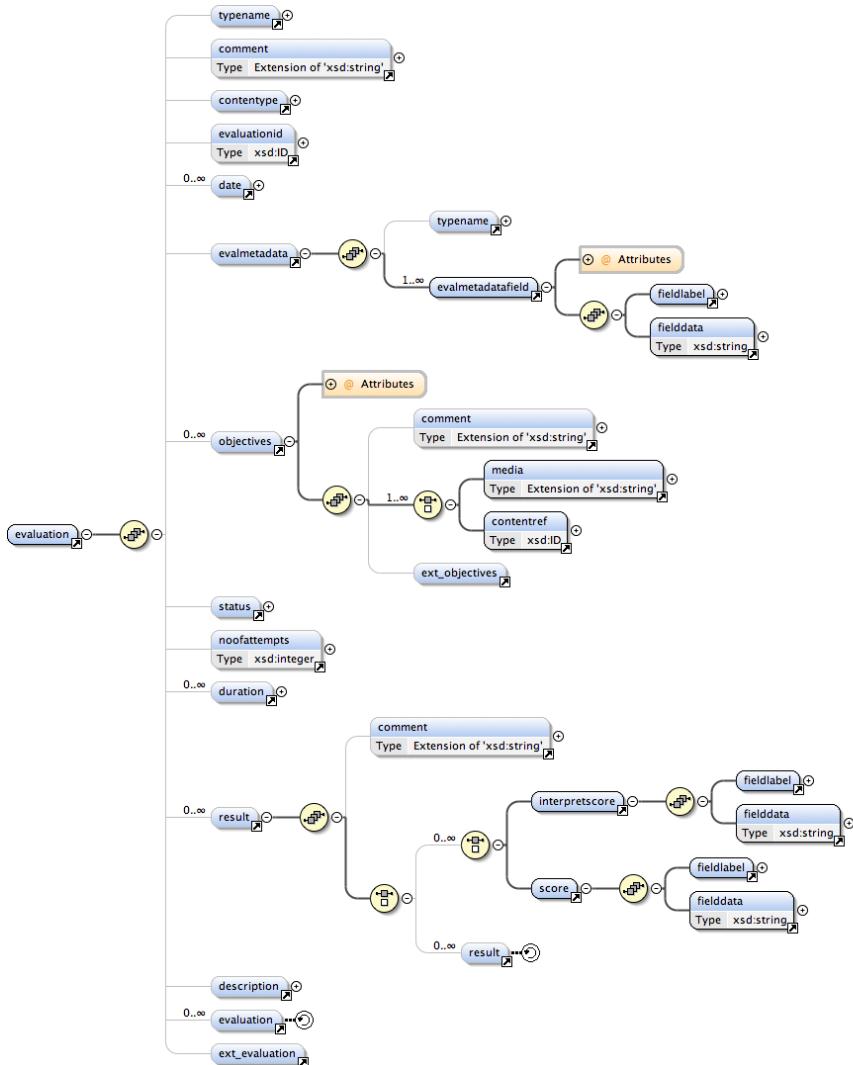
Aktivnosti učenika predstavljene su strukturu sa slike 2.5. Vrsta aktivnosti (vrednost iz rečnika) je predstavljena elementom typename. Stanja aktivnosti data su elementom status, dok su datumi vezani za ta stanja dati elementom date. Elementom units omogućeno je strukturi-

ranje materijala izučavanog u okviru ove aktivnosti. Opis izučavanog materijala moguće je formalno iskazati pomoću reference na opis u nekom drugom sistemu (`learningactivityref`) ili njegovom definicijom u okviru ovog dokumenta (`definition`) ili opisom proizvoda nastalog sprovođenjem aktivnosti (`product`), svedočanstvom druge osobe koja je učestvovala u aktivnosti (`testimonial`) ili vrednovanjem postignuća uaktivnosti kroz proveru znanja ili na neki drugi način (`evaluation`). Verbalni opis aktivnosti dat je elementom `description`. Hjерархијско uređenje aktivnosti omogućено je elementом `activity` koji ima identičnu strukturu.



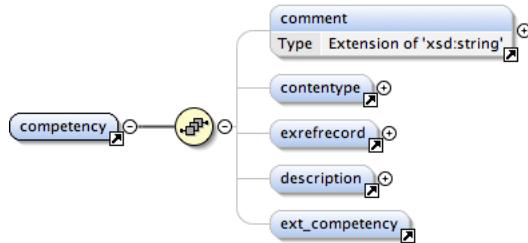
Slika 2.5 IMS LIP – element `activity`

Rezultati provjere znanja, u okviru prethodno prikazane strukture, predstavljeni su podstrukturom sa slike 2.6. Metapodaci vezani za evaluaciju prikazani su elementom `evalmetadata`. Pojedinačni obrazovni ciljevi vezani za materijale za evaluaciju definisani su elementom `objectives`. Broj pokušaja načinjen prilikom evaluacije je prikazan elementom `noofattempts`. Vrijeme trajanja evaluacije prikazano je elementom `duration`. Rezultati evaluacije prikazani su elementom `results`. Informacije potrebne za interpretaciju rezultata (npr. maksimalan broj bodova) nalaze se u elementu `interpretscore`, dok se konkretni rezultati evaluacije nalaze u elementu `score`. Hjерархијско uređivanje rezultata omogućeno je podelementom `results` sa identičnom strukturu.



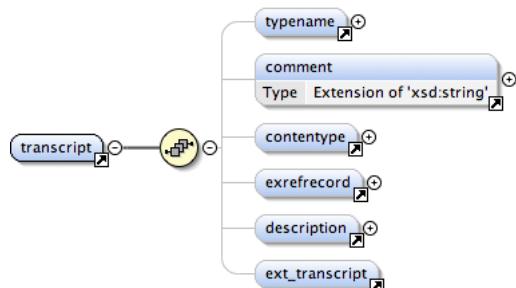
Slika 2.6 IMS LIP – element evaluation

Stečene kompetencije su prikazane struktrom sa slike 2.7. Elementom `exrefrecord` predstavljena je referenca na formalni opis kompetencije u nekoj eksternoj strukturi podataka odnosno sistemu. Verbalni opis kompetencije predstavljen je elementom `description`. Formalno definisanje kompetencija je izvan opsega ovog standarda.



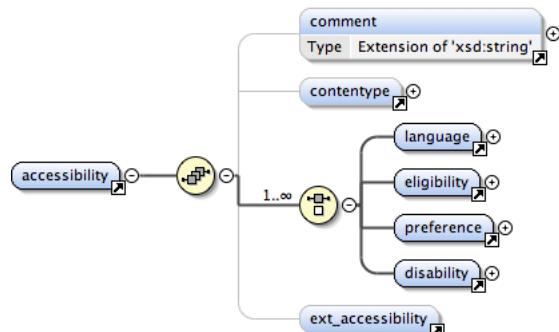
Slika 2.7 IMS LIP – element competency

Prepis akademskih ostvarenja učenika predstavljen je struktrom sa slike 2.8. Referenca na eksterni formalni opis ostvarenja dat je elementom exrefrecord. Verbalni opis dat je elementom description, a tipizacija pomoću vrijednosti iz rječnika elementom typename.



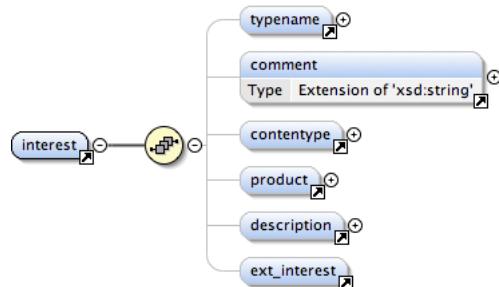
Slika 2.8 IMS LIP – element transcript

Informacije o dostupnosti definisane su strukturom sa slike 2.9. Jezik kojim se služi učenik za čitanje, pisanje i govor predstavljen je elementom language. Nivoi vještine u korišćenju jezika i poželjni jezik su definisani u odgovarajućim podelementima (izostavljeni sa slike). Element eligibility predstavlja ocjene podobnosti učenika i trenutno je ostavljen za razvoj u budućoj verziji standarda. Elementom preference predstavljene su poželjne opcije u procesu učenja za datog učenika. Elementom disability predstavljene su posebne potrebe posmatranog učenika koje utiču na proces učenja.



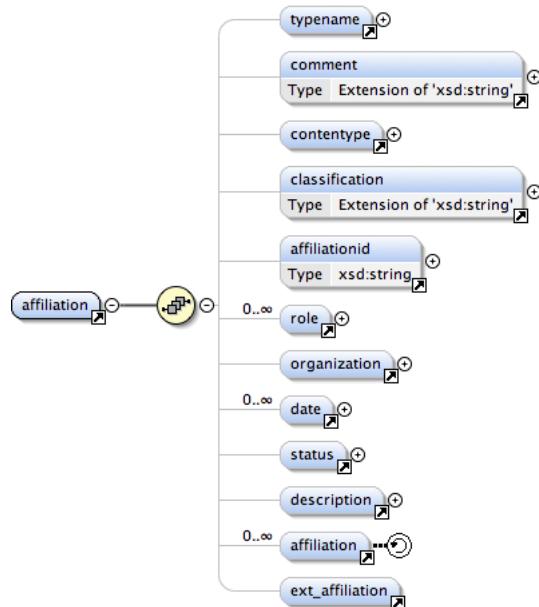
Slika 2.9 IMS LIP – element accessibility

Interesovanja učenika su predstavljena struktrom sa slike 2.10. Tipizacija interesovanja pomoću vrijednosti iz rječnika data je elementom typename. Opis proizvoda koji je nastao kao deo bavljenja aktivnostima iz oblasti interesovanja učenika dat je elementom product. Verbalni opis interesovanja je predstavljen elementom description.



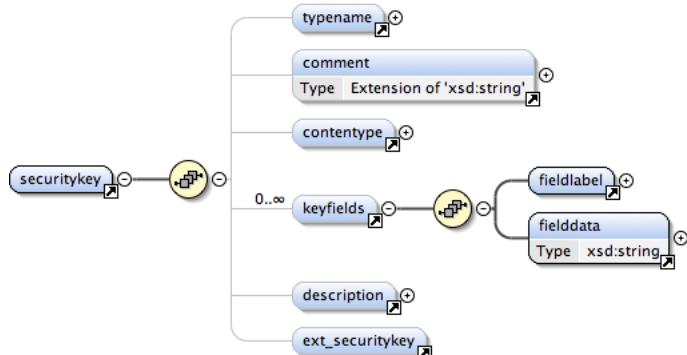
Slika 2.10 IMS LIP – element interest

Pripadnost učenika obrazovnim ili drugim institucijama je definisana strukturom sa slike 2.11. Tipizacija pripadnosti vrijednošću iz rječnika (npr. *professional*) omogućena je elementom typename. Vrsta pripadnosti u konkretnoj organizaciji predstavljena je elementom classification (npr. *member* ili *fellow*). Identifikator članstva (npr. članski broj) prikazan je elementom affiliationid. Uloge koje je učenik uzimao u organizaciji predstavljene su elementom role. Podaci o organizaciji predstavljeni su elementom organization, a status i njegovi datumi promjene elementima status i date. Pojam pripadnosti je moguće urediti u hijerarhijsku strukturu (podelement affiliation).



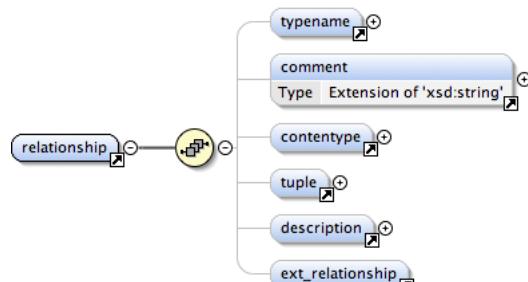
Slika 2.11 IMS LIP – element affiliation

Bezbednosni podaci opisani su struktrom sa slike 2.12. Svaki pojedinačni podatak opisan je struktrom keyfields, sa podelementima fieldlabel (klasifikacija podatka, npr. lozinka, javni ključ, itd) i fielddata (vrednost podatka). Tipizacija je omogućena elementom typename sa vrednošću iz rečnika.

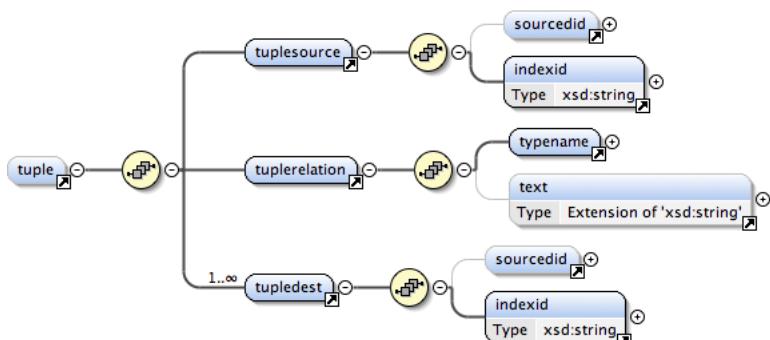


Slika 2.12 IMS LIP – element securitykey

Veze između pojedinih elemenata profila učenika definisane su struktrom sa slike 2.13. U vezi mogu da učestvuju različiti elementi, na primjer, aktivnosti i QCL opisi. Veza je formalno opisana elementom tuple (slika 2.14) koja ima izvořite (element tuplesource), odredište (element tupledest) i opis vrste veze (element tuplerelation).



Slika 2.13 IMS LIP – element relationship



Slika 2.14 IMS LIP - element tuple

### 2.2.1 Primjer opisa studenta

Na listingu 2.4 dat je primjer minimalnog zapisa učeničkog profila po IMS LIP standardu. Zapis sadrži osnovni identifikator **IMS\_LIP\_V1p0\_Example:basic\_1001**, definiše njemački jezik i nivoe vještine učenika u korišćenju nemačkog jezika. Poznavanje još jednog jezika bi se prikazalo dodavanjem još jednog elementa *language* u prikazanu strukturu.

```
<learnerinformation>
    <comment>An example of LIP Accessibility information.</comment>
    <contenttype>
        <referential>
            <sourcedid>
                <source>IMS_LIP_V1p0_Example</source>
                <id>basic_1001</id>
            </sourcedid>
        </referential>
    </contenttype>
    <accessibility>
        <contenttype>
            <referential>
                <indexid>accessibility_01</indexid>
            </referential>
        </contenttype>
        <language>
            <typename>
                <tysource sourcetype="imsdefault"/>
                <tyvalue>German</tyvalue>
            </typename>
            <contenttype>
                <referential>
                    <indexid>language_01</indexid>
                </referential>
            </contenttype>
            <proficiency profmode="OralSpeak">Excellent</proficiency>
            <proficiency profmode="OralComp">Excellent</proficiency>
            <proficiency profmode="Read">Good</proficiency>
            <proficiency profmode="Write">Poor</proficiency>
        </language>
    </accessibility>
</learnerinformation>
```

Listing 2.4. Minimalni profil učenika po (IMS LIP, 2005)

Za datog učenika moguće je dodati informacije o posebnim potrebama kroz element *accessibility*. U primjeru sa listinga 2.5 navedeno jedna posmatrani učenik koristi uređaje sa krupnim fontom i navedena je kognitivna karakteristika učenika.

```
<accessibility>
    <contenttype>
        <referential>
```

```

        <indexid>accessibility_01</indexid>
    </referential>
</contentype>
<preference>
    <typename>
        <tysource sourcetype="imsdefault"/>
        <tyvalue>InputTech</tyvalue>
    </typename>
<contentype>
    <referential>
        <indexid>preference_01</indexid>
    </referential>
</contentype>
    <prefcode>Large Font Display Devices</prefcode>
</preference>
<preference>
    <typename>
        <tysource sourcetype="imsdefault"/>
        <tyvalue>Cognitive</tyvalue>
    </typename>
<contentype>
    <referential>
        <indexid>preference_02</indexid>
    </referential>
</contentype>
    <prefcode>Exploratory</prefcode>
</preference>
</accessibility>

```

Listing 2.5. Primjer informacija o posebnim potrebama (IMS LIP, 2005)

Primjer opisa jedne obrazovne aktivnosti dat je na listingu 2.6. U ovom primjeru, naveden je datum aktivnosti (element `datetime`), broj kredita koji je dodijeljen aktivnosti i referenca na eksternu definiciju aktivnosti (`learningactivityref`).

```

<activity>
    <typename>
        <tysource sourcetype="imsdefault"/>
        <tyvalue>Education</tyvalue>
    </typename>
<contentype>
    <referential>
        <indexid>activity_1</indexid>
    </referential>
</contentype>
<date>
    <typename>
        <tysource sourcetype="imsdefault"/>
        <tyvalue>Award</tyvalue>
    </typename>
    <datetime>1980:7</datetime>
</date>
<units>
    <unitsfield>

```

```

<fieldlabel>
    <typename>
        <tyvalue>CreditNumber</tyvalue>
    </tynname>
</fieldlabel>
<fielddata>10</fielddata>
</unitsfield>
</units>
<learningactivityref>
    <text>HNC in Mathematics</text>
</learningactivityref>
</activity>

```

Listing 2.6. Primjer opisa eksterno definisane aktivnosti (IMS LIP, 2005)

Primjer opisa aktivnosti koji sadrži i definiciju kursa dat je na listingu 2.7. U ovom primjeru prikazan je deo kurikuluma koji u prvoj godini ima dva predmeta (sa identifikatorima *Electronics\_101* i *Maths\_101*), svaki sa po dvije nastavne jedinice.

```

<activity>
    <tynname>
        <tysource sourcetype="imsdefault"/>
        <tyvalue>Education</tyvalue>
    </tynname>
    <contentype>
        <referential>
            <indexid>activity_1</indexid>
        </referential>
    </contentype>
    <definition>
        <tynname>
            <tysource sourcetype="imsdefault"/>
            <tyvalue>Course</tyvalue>
        </tynname>
        <contentype>
            <referential>
                <indexid>DegreeCourse</indexid>
            </referential>
        </contentype>
        <definition>
            <tynname>
                <tysource sourcetype="imsdefault"/>
                <tyvalue>Curriculum</tyvalue>
            </tynname>
            <contentype>
                <referential>
                    <indexid>Year1</indexid>
                </referential>
            </contentype>
            <definition>
                <tynname>
                    <tysource sourcetype="imsdefault"/>
                    <tyvalue>Module</tyvalue>
                </tynname>
            </definition>
        </definition>
    </definition>

```

```

<contentype>
  <referential>
    <indexid>Electronics_101</indexid>
  </referential>
</contentype>
<definitionfield>
  <fieldlabel>
    <typename>
      <tyvalue>Lecture1</tyvalue>
    </typename>
  </fieldlabel>
  <fielddata>BooleanLogic</fielddata>
</definitionfield>
<definitionfield>
  <fieldlabel>
    <typename>
      <tyvalue>Lecture2</tyvalue>
    </typename>
  </fieldlabel>
  <fielddata>Transistors</fielddata>
</definitionfield>
</definition>
<definition>
  <typename>
    <tysource sourcetype="imsdefault"/>
    <tyvalue>Module</tyvalue>
  </typename>
<contentype>
  <referential>
    <indexid>Maths_101</indexid>
  </referential>
</contentype>
<definitionfield>
  <fieldlabel>
    <typename>
      <tyvalue>Lecture1</tyvalue>
    </typename>
  </fieldlabel>
  <fielddata>BooleanLogic1</fielddata>
</definitionfield>
<definitionfield>
  <fieldlabel>
    <typename>
      <tyvalue>Lecture2</tyvalue>
    </typename>
  </fieldlabel>
  <fielddata>BooleanLogic2</fielddata>
</definitionfield>
</definition>
</definition>
</definition>
</activity>

```

Listing 2.7. Primjer opisa aktivnosti koji sadrži  
i definiciju kursa (IMS LIP, 2005)

Primjer obrazovne aktivnosti koja je rezultovala odrijeđenim proizvodom – u ovom slučaju, završnim radom koji je dostupan u digitalnom obliku – prikazan je na listingu 2.8. Na sličan način, upotrebom elementa *testimonial*, umjesto elementa *product*, može se prikazati izvještaj sa obavljene stručne prakse.

```
<activity>
  <typename>
    <tysource sourcetype="imsdefault"/>
    <tyvalue>Education</tyvalue>
  </typename>
  <contentype>
    <referential>
      <indexid>activity_1</indexid>
    </referential>
  </contentype>
  <date>
    <typename>
      <tysource sourcetype="imsdefault"/>
      <tyvalue>Create</tyvalue>
    </typename>
    <datetime>1980:7</datetime>
  </date>
  <product>
    <typename>
      <tysource sourcetype="imsdefault"/>
      <tyvalue>Coursework</tyvalue>
    </typename>
    <contentype>
      <referential>
        <indexid>activity_product_01</indexid>
      </referential>
    </contentype>
    <description>
      <short>Thesis</short>
      <full>
        <media mediemode="Text"
          mimetype="text/word"
          contentreftype="uri">
          http://document.storage.edu/myfile/thesis.doc
        </media>
      </full>
    </description>
  </product>
</activity>
```

Listing 2.8. Primjer obrazovne aktivnosti koja rezultuje pisanim radom u digitalnom obliku(IMS LIP, 2005)

Primjer rezultata evaluacije prikazan je na listingu 2.9. Aktivnost sa identifikatorom *activity\_1* nosi 20 kredita, ispitno telo sa identifikatorom 12345 je izvršilo ispitivanje i kao rezultat dalo 30 bodova od mogućih minimalno 0 i maksimalno 100.

```

<activity>
    <typename>
        <tysource sourcetype="imsdefault"/>
        <tyvalue>Education</tyvalue>
    </typename>
    <contentype>
        <referential>
            <indexid>activity_1</indexid>
        </referential>
    </contentype>
    <units>
        <unitsfield>
            <fieldlabel>
                <typename>
                    <tyvalue>CreditNumber</tyvalue>
                </typename>
            </fieldlabel>
            <fielddata>20</fielddata>
        </unitsfield>
    </units>
    <evaluation>
        <contentype>
            <referential>
                <sourcedid>
                    <source>ExamBoard</source>
                    <id>12345</id>
                </sourcedid>
            </referential>
        </contentype>
        <result>
            <interpretscore>
                <fieldlabel>
                    <typename>
                        <tyvalue>MinimumScore</tyvalue>
                    </typename>
                </fieldlabel>
                <fielddata>0</fielddata>
            </interpretscore>
            <interpretscore>
                <fieldlabel>
                    <typename>
                        <tyvalue>MaximumScore</tyvalue>
                    </typename>
                </fieldlabel>
                <fielddata>100</fielddata>
            </interpretscore>
            <score>
                <fieldlabel>
                    <typename>
                        <tyvalue>Score</tyvalue>
                    </typename>
                </fieldlabel>
                <fielddata>30</fielddata>
            </score>
        </result>
    </evaluation>
</activity>

```

Listing 2.9. Primjer unijetog rezultata ocjenjivanja u aktivnost (IMS LIP, 2005)

Primjer referenciranja na eksterno definisane kompetencije dat je na listingu 2.10. U ovom primjeru učenik je 1998. godine osvojio nagradu za uspjeh u sticanju kompetencija koje su opisane u eksternim resursima (dokumentima) na koje upućuje odgovarajuća URL adresa.

```
<competency>
  <contentype>
    <referential>
      <indexid>competency_01</indexid>
    </referential>
  </contentype>
  <exrefrecord>
    <reformat uri="compformats/vocabulary.doc"/>
    <reldata uri="learner1/competency.doc"/>
    <date>
      <typename>
        <tysource sourcetype="imsdefault"/>
        <tyvalue>Award</tyvalue>
      </typename>
      <datetime>1998</datetime>
    </date>
  </exrefrecord>
  <description>
    <short>IT Competencies</short>
  </description>
</competency>
```

Listing 2.10. Primjer referenciranja na eksterno definisane kompetencije

Izražavanje ciljeva omogućeno je kroz strukturirane podatke (vrijemenske odrednice, opise stanja i procesa) i nestrukturirane podatke koji se nalaze u eksternim resursima na koje ukazuju URL adrese. Na listingu 2.11. dat je primjer jednog opisa cilja.

```
<goal>
  <typename>
    <tysource sourcetype="imsdefault"/>
    <tyvalue>Work</tyvalue>
  </typename>
  <contentype>
    <referential>
      <indexid>goal_01</indexid>
    </referential>
  </contentype>
  <date>
    <typename>
      <tysource sourcetype="imsdefault"/>
      <tyvalue>Start</tyvalue>
    </typename>
    <datetime>2000:11:06</datetime>
  </date>
  <priority>Primary Objective</priority>
  <status>
    <typename>
```

```

<tysource sourcetype="imsdefault"/>
<tyvalue>Active</tyvalue>
</typename>
<date>
    <typename>
        <tysource sourcetype="imsdefault"/>
        <tyvalue>Effective</tyvalue>
    </typename>
    <datetime>2000:11:06</datetime>
</date>
</status>
<description>
    <short>Career Plan</short>
    <full>
        <media
            mediemode="Text"
            mimetype="text/word"
            contentreftype="uri">
            learner1/careerplan.doc
        </media>
    </full>
</description>
</goal>
```

Listing 2.11. Primjer reprezentacije cilja (IMS LIP, 2005)

Primjer reprezentacije licence dat je na listingu 2.12. U ovom primjeru učenik je stekao licencu za obavljanje taksi usluga koju je izdala savezna država Njujork i koja ima odgovarajući period važenja.

```

<qcl>
    <typename>
        <tysource sourcetype="imsdefault"/>
        <tyvalue>Licence</tyvalue>
    </typename>
    <contentype>
        <referential>
            <indexid>qcl_01</indexid>
        </referential>
    </contentype>
    <title>Taxi Driver Licence</title>
    <organization>
        <typename>
            <tysource sourcetype="imsdefault"/>
            <tyvalue>Government</tyvalue>
        </typename>
        <description>
            <short>New York State</short>
        </description>
    </organization>
    <registrationno>24785NY</registrationno>
    <date>
        <typename>
            <tysource sourcetype="imsdefault"/>
            <tyvalue>Start</tyvalue>
        </typename>
    </date>
```

```

</typename>
<datetime>1996:09:01</datetime>
</date>
<date>
  <typename>
    <tysource sourcetype="imsdefault"/>
    <tyvalue>Expiry</tyvalue>
  </typename>
  <datetime>2001:08:31</datetime>
</date>
</qcl>

```

Listing 2.12. Primjer reprezentacije stečene licence (IMS LIP, 2005)

## 2.3 Primjene standarda za reprezentaciju profila učenika

Analiza međusobnog odnosa između *PAPI Learneri* IMS LIP standarda data je u radu (Chatti i dr, 2005). U njemu je predstavljeno rješenje za opisivanje, upoređivanje i transformaciju različitih profila učenika. Cilj ovog istraživanja je formulisanje zajedničkog meta-modela koji će omogućiti razmjenu i korišćenje različitih modela učenika između različitih tehnoloških platformi. Na osnovu tih rezultata mapiranje profila između *PAPI Learneri* IMS LIP standarda implementirano je pomoću XSLT transformacija. Skladištenje podataka zasniva se na upotrebi XML baze podataka Apache Xindice.

Primjena više standarda u oblasti tehnološki podržanog učenja (IMS LIP, IMS LD, IMS CP, IEEE LOM, IMS QTI) uz mogućnost adaptacije prema pojedinačnim učenicima je rezultat aLFanet projekta [aLFanet]. aLFanet projekt je pokrenut sa ciljem da se realizuje adaptivna platforma za podršku učenju koja omogućava interaktivno i personalizovano učenje putem Interneta. Na taj način učenici su u mogućnosti da na optimalan način pristupaju i savladavaju onu materiju koja je od značaja za njihov rad. Projekat je fokusiran na učenik-centrične pedagoške metode uz naglasak na aktivnosti, saradnji i značaju instrukcionog dizajna. Kao spona između komercijalno dostupnih sistema za podršku učenju, koji ne posjeduju osobine adaptivnosti, i istraživačkih prototipova koji su usmjereni upravo u tom pravcu, razvijen je novi sistem za podršku učenju koji se oslanja na IMS LIP (Boticario i dr, 2006; Boticario i dr, 2007).

### **3 Informacioni model za predviđanje uspješnosti studiranja**

U ovom poglavlju prikazan je model podataka za predviđanje uspješnosti studiranja koji se može implementirati u okviru postojećeg IMS LIP standarda za reprezentaciju profila učenika. Potom su analizirane metode za predviđanje koje koriste podatke definisane ovim modelom. Rezultati navedeni u ovom poglavlju su nastali kao rezultat istraživanja objavljenog u (Simeunović i Preradović, 2014).

#### **3.1 Model podataka za predviđanje uspješnosti studiranja**

Model podataka razvijen za potrebe predviđanja uspješnosti studiranja formalno je definisan kao skup podataka o studentima i predstavljen pomoću postojećih elemenata IMS LIP standarda tamo gde je to bilo moguće, odnosno pomoću proširenja ovog standarda u suprotnom slučaju.

U definisanju seta varijabli koje su ušle u prediktivni model za predviđanje uspjeha u studiranja pošlo se od osnovne teorijske prepostavke zasnovane na Blumovoj teoriji ličnosti (Bloom, 1956; Anderson, L.W i dr. 2001). Autor navodi tri domena koja utiču na uspjeh u procesu učenja i to: kognitivni, afektivni i psihomotorni. Isto tako, autor navodi da su tri faktora odlučujuća za postizanje uspjeha u nastavi i to: kognitivne sposobnosti, emocionalne karakteristike i kvalitet instrukcije.

**Kognitivni domen** uključuje znanje i razvoj intelektualnih sposobnosti na osnovu čega su definisani ciljevi u okviru područja. Kognicija se odnosi na svjesne mentalne aktivnosti: opažanje, mišljenje, zaključivanje, pamćenje, mišljenje, učenje. Kognicija obuhvata sve procese saznanja i sticanja znanja.

**Afektivni domen** (Krathwohl i dr, 1973) uključuje način na koji se bavimo stvarima emotivno, kao što su osjećanja, vrijednosti, uvažavanje, entuzijazam, motivacija, i stavovi.

**Psihomotorni domen** (Simpson, 1972) uključuje fizički pokret, koordinaciju i korištenje motornih vještina u područjima učenja. Razvoj

ovih vještina zahtijeva praksu i mjeri se u pogledu brzine, preciznosti, procjene udaljenosti, procedure, ili tehnika u izvršenju.

S obzirom da ovakve teorijske pretpostavke govore o osnovnim faktorima koji utiču na uspjeh definisali smo bateriju instrumenata koja bi obuhvatila svaki od njih. Za ispitivanje intelektualnih sposobnosti koristili smo Ravenove progresivne matrice.

Ovaj test uključuju mjerjenje edukativne, neverbalne sposobnosti, odnosno sposobnosti razumijevanja kompleksnih situacija, sposobnosti pronalaženja značenja u događajima, sposobnosti percepcije i mišljenja. Test ima šezdeset pitanja koji se rade ukupno četrdeset minuta.

Motivaciju studenata za učenje u ovom istraživanju mjerili smo Velerandovom Skalom akademske motivacije (*Academic Motivation Scale*), konstruisane 1992. godine. Ovaj instrument mjeri unutrašnju motivaciju, identifikovanu i internalizovanu regulaciju, vanjsku regulaciju i amotivaciju. Instrument se sastoji od dvadeset tvrdnji na koje ispitanici odgovaraju petostepenom skalom Likertovog tipa. Na primjer, unutrašnju motivisanost za pohađanje škole tretira pitanje: *U školu idem zato što moje iskustvo govori da će doživjeti zadovoljstvo i radost pri učenju novih stvari*. Na sličan način su formulisana i druga pitanja.

Motivacija za učenje najsnažnije povezana sa akademskim samopoimanjem te samoefikasnošću za učenje, sa kojima ima umjerenou visoke pozitivne korelacije. Pozitivno je, ali slabije povezana i sa samopoimanjem verbalnih sposobnosti te sa sposobnošću rješavanja problema. Vrijednost učenja kao indikator motivacije za učenje pozitivno je povezana i sa intrinskičnom te identifikacijskom motivacijom za poučavanje. Dakle, studenti učiteljskih studija koji su motivisani za učenje imaju pozitivnije akademsko samopoimanje, bolje procjenjuju vlastitu samoefikasnost u učenju, a iskazuju i više intrinskične motivisanosti za poučavanje učenika. Studenti koji imaju veće akademsko i opšte samo-poštovanje u većoj mjeri procjenjuju da su na studiju zadovoljene njihove potrebe za autonomijom i povezanošću sa drugima.

U istraživanju koje su proveli Jakšić i Vizek Vidović (2007) se pokazalo da je percepcija vlastite kompetentnosti za učenje povezana sa kvalitetnijim korištenjem strategija učenja ( $r= 0,22$ ), kao i varijabla "cilj ovladavanja zadatkom putem uključivanja" ( $r= 0,379$ ). Na osnovu dobijenih rezultata može pretpostaviti kako je zadovoljstvo vlastitim akademskim sposobnostima povezano sa kvalitetnijim procesima učenja koji potom rezultiraju boljim uspjehom na studiju.

Vodeći se IMS LIP standardom konstruisali smo upitnik koji sadrži petnaest pitanja koja su u visokoj mjeri kopatibilna sa pitanjima iz „studentske ankete“ Univerziteta u Istočnom Sarajevu. Odgovori na sva pitanja uzimaju vrijednosti iz konačnog skupa. U nastavku su, prilikom definisanja pitanja, dati i ponuđeni mogući odgovori.

U prvu kategoriju *Identifikacija* svrstali smo podatke o studiranju i to:

- **Studiram:** (1) u mjestu rođenja, (2) svakodnevno putujem na fakultet, (3) došao sam iz drugog mjesta zbog studiranja.
- **Podaci o stipendiranju:** (1) primam stipendiju, (2) povremeno primam stipendiju, (3) ne primam stipendiju.
- **Pol:** (1) muško, (2) žensko.

U kategoriju *Ciljevi* mogu se svrstati sljedeći podaci:

- **Važno mi je koju ču ocjenu dobiti na ispitu:** (1) slažem se, (2) neodlučan sam, (3) ne slažem se.

U kategoriju *Aktivnosti* smo uvrstili sve aktivnosti vezane za učenje studenta, a koje se nalaze i u studentskoj anketi UIS i to:

- **U toku dana učenju posvećujem:** (1) do jedan sat, (2) dva do tri sata, (3) tri do pet sati, (4) više od pet sati.
- **Za učenje najviše koristim:** (1) knjigu profesora, (2) skripte drugih sudenata, (3) bilješke sa predavanja, (4) sve dostupne izvore.
- **Na predavanju prisustvujem:** (1) redovno, (2) uglavnom redovno, (3) povremeno, (4) rijetko, (5) nikad.
- **Izlazim na kolokvijume:** (1) uvijek, (2) uglavnom, (3) ne izlazim na kolokvijume.
- **Prisustvo vježbama:** (1) redovno, (2) uglavnom redovno, (3) povremeno, (4) rijetko, (5) nikad.

Posebna kategorija pitanja kojima bi se mogao dopuniti IMS LIP se odnose na organizaciju procesa učenja i sistemu rada na fakultetima koji neposredno utiču na uspjeh u studiranju. Nju čine sljedeća pitanja:

- **Predavanja na mom studiju su:** (1) kvalitetna i korisna, mogu sve saznati o predmetu, (2) uglavnom su dobro pripremljena i korisna, (3) mala je korist od predavanja, (4) nepotrebna su i nekorisna, uglavnom učim samostalno.
- **Vježbe su:** (1) najbolji način da bolje razumijem nastavni predmet, (2) produžetak predavanja, (3) gubljenje vremena, bolje je samostalno učiti, (4) zastarjela i potpuno prevaziđena.
- **Programi na ovom studiju su:** (1) dobri i korisni za moju buduću profesiju, (2) dobri su ali ima i nepotrebnih predmeta, (3) programi su uglavnom zastarjeli, ne idu u korak sa praksom, (4) programi su uglavnom teorija, ne vjerujem da će mi koristiti u radu.

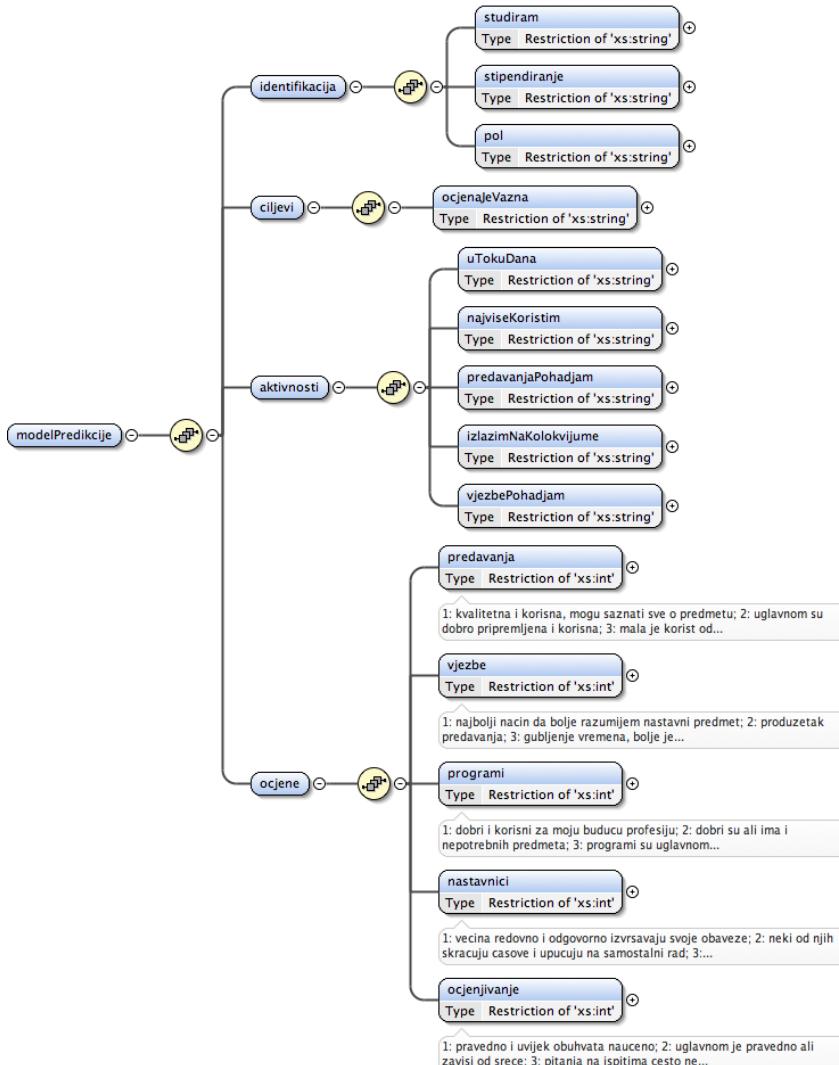
- **Nastavnici na fakultetu su:** (1) većina redovno i odgovorno izvršavaju obaveze, (2) neki od njih skraćuju časove i upućuju na samostalni rad, (3) neki nastavnici uopšte ne drže nastavu, samo organizuju povremene konsultacije, (4) većina nastavnika ne drži nastavu.
- **Ocjenvivanje je:** (1) pravedno i uvijek obuhvata naučeno, (2) uglavnom pravedno ali zavisi od sreće, (3) pitanja na ispitima često ne prate program, (4) potpuno je nepravedno i zasnovano na dobrom raspoloženju.

Navedeni stav se može potkrepiti i stavom Tjuning projekta EU (*Tuning project – Tuning educational structures in Europe*) [Tuning] u kome se definišu ishodi učenja i u kome se traži kvalitativna veza između nivoa studija, ishoda učenja, ECTS kredita, metoda učenja i poučavanja, vrednovanja postignuća i ocjenjivanja.

Na slici 3.1 prikazana je XML šema ovog modela za predikciju uspješnosti studiranja. Puni listing ove XML šeme dat je u prilogu A.

Prikazani elementi modela za predviđanje uspješnosti studiranja mogu se dodati u postojeći IMS LIP model podataka u okviru standardom predviđenih mesta za proširenje novim podacima. Pri tome je potrebno koristiti IMS LIP preporuku za reprezentovanje novih podataka pomoću elemenata `fieldlabel` i `fielddata` u okviru elementa namijenjenog za navođenje proširenja za datu sekciju IMS LIP specifikacije. Ukoliko podatak uzima vrijednost iz konačnog skupa – što je slučaj kod nas – sadržaj elementa `fielddata` mora uzimati vrijednost iz odgovarajućeg rječnika.

Na primjer, podatak o mjestu stanovanja studenta u odnosu na mjesto studiranja trebalo bi da bude prikazan u okviru elementa `ext_identification` u `identification` sekciji IMS LIP šeme. Ukoliko je potrebno smjestiti više podataka u elementu `ext_identification`, oni se mogu smjestiti tako da svaki par elemenata `fieldlabel` i `fielddata` ima svog zasebnog roditelja koji je dijete `ext_identification` elementa. U našem slučaju, sekcija za identifikaciju studenta bi trebalo da sadrži: (1) podatak o prebivalištu studenta u odnosu na lokaciju fakulteta, (2) podatak o stipendiranju i (3) pol studenta. Podatak o polu studenta je već predviđen IMS LIP specifikacijom, dok se prva dva podatka smještaju u element namenjen za proširenja. Na listingu 3.1 je dat primjer sekcije za identifikaciju koja sadrži ova tri podatka (ostali podaci su izostavljeni radi bolje preglednosti). Na ovom listingu je prikazan primjer osobe ženskog pola (element `gender`), koja svakodnevno putuje na fakultet iz mesta stanovanja (element `location`), i redovno prima stipendiju (element `scholarship`).



Slika 3.1. XML šema modela za predikciju uspješnosti studiranja

```

<identification>
    ...
<demographics>
    ...
    <gender gender="F"/>
    ...
</demographics>
...
<ext_identification>
    <location>
        <fieldlabel>
            <typename>
                <tyvalue>StudyLocation</tyvalue>
            </typename>
        </fieldlabel>
    </location>

```

```

</fieldlabel>
<fielddata>TravelEveryDay</fielddata>
</location>
<scolarship>
<fieldlabel>
<typename>
<tyvalue>Scolarship</tyvalue>
</typename>
</fieldlabel>
<fielddata>RegularScholarship</fielddata>
</scolarship>
</ext_identification>
</identification>

```

Listing 3.1. Primjer dodatih podataka u identifikacionu sekciju  
IMS LIP profila studenta

Na sličan način se podatak o studentovoj procjeni važnosti postignute ocjene može predstaviti u IMS LIP sekciji o ciljevima. Na listingu 3.2 predstavljen je primjer sekcije o ciljevima koja sadrži ovaj podatak sa vrijednošću *slažem se*. Novi podatak je predstavljen u okviru dela za proširenja, tj. kao podelement `grade_importance`elementa `ext_goal`.

```

<goal>
...
<ext_goal>
<grade_importance>
<fieldlabel>
<typename>
<tyvalue>GradeImportance</tyvalue>
</typename>
</fieldlabel>
<fielddata>IAgree</fielddata>
</grade_importance>
</ext_goal>
</goal>

```

Listing 3.2. Primjer dodatih podataka u sekciji o ciljevima

Sekcija aktivnosti dopunjava se sa pet novih podataka, svih smještenih u okviru elementa `ext_activity`. Na listingu 3.3 predstavljen je primjer sekcije o aktivnostima koja sadrži sljedeće podatke: (1) student u toku dana posvjećuje učenju dva do tri sata, (2) za učenje najviše koristi knjigu profesora, (3) predavanjima prisustvuje redovno, (4) uvijek izlazi na kolokvijume i (5) redovno prisustvuje vježbama.

```

<activity>
...
<ext_activity>
<daily_hours>
<fieldlabel>
<typename>
<tyvalue>DailyHoursSpentOnLearning</tyvalue>

```

```

        </typename>
    </fieldlabel>
    <fielddata>TwoToThree</fielddata>
</dailyhours>
<learning_resource>
    <fieldlabel>
        <typename>
            <tyvalue>MainLearningResource</tyvalue>
        </typename>
    </fieldlabel>
    <fielddata>Textbook</fielddata>
</learning_resource>
<lecture_attendance>
    <fieldlabel>
        <typename>
            <tyvalue>LectureAttendance</tyvalue>
        </typename>
    </fieldlabel>
    <fielddata>Regular</fielddata>
</lecture_attendance>
<colloquium_attendance>
    <fieldlabel>
        <typename>
            <tyvalue>ColloquiumAttendance</tyvalue>
        </typename>
    </fieldlabel>
    <fielddata>Always</fielddata>
</colloquium_attendance>
<workshop_attendance>
    <fieldlabel>
        <typename>
            <tyvalue>WorkshopAttendance</tyvalue>
        </typename>
    </fieldlabel>
    <fielddata>Regular</fielddata>
</workshop_attendance>
</ext_activity>
</activity>

```

Listing 3.3. Primjer dodatih podataka u sekciju o aktivnostima

Elementi našeg modela za predikciju koji se ne mogu svrstati u neku od sekcija predviđenih IMS LIP specifikacijom mogu se smjestiti u element `ext_learnerinfo` namijenjen upravo ovakvim slučajevima. Primjer ovih elemenata dat je na listingu 3.4.

```

<learnerinformation>
    ...
    <ext_learnerinfo>
        <lecture_assessment>
            <fieldlabel>
                <typename>
                    <tyvalue>LectureAssessment</tyvalue>
                </typename>
            </fieldlabel>

```

```

        <fielddata>Useful</fielddata>
    </lecture_assessment>
    <workshop_assessment>
        <fieldlabel>
            <typename>
                <tyvalue>WorkshopAssessment</tyvalue>
            </typename>
        </fieldlabel>
        <fielddata>Best</fielddata>
    </workshop_assessment>
    <program_assessment>
        <fieldlabel>
            <typename>
                <tyvalue>ProgramAssessment</tyvalue>
            </typename>
        </fieldlabel>
        <fielddata>GoodAndUseful</fielddata>
    </program_assessment>
    <teacher_assessment>
        <fieldlabel>
            <typename>
                <tyvalue>TeacherAssessment</tyvalue>
            </typename>
        </fieldlabel>
        <fielddata>Regular</fielddata>
    </teacher_assessment>
    <grading_assessment>
        <fieldlabel>
            <typename>
                <tyvalue>GradingAssessment</tyvalue>
            </typename>
        </fieldlabel>
        <fielddata>AlwaysFair</fielddata>
    </grading_assessment>
</ext_learnerinfo>
</learnerinformation>

```

Listing 3.4. Primjer reprezentacije ostalih podataka iz modela

### 3.2 Metode za predviđanje uspješnosti studiranja

Cilj ovog odeljka je pronalaženje važnih činilaca koji utiču na uspjeh studenata, koji je predstavljen prosječnom ocjenom. Za ovu svrhu smo upotrijebili tri metode za analizu podataka pogodne za klasifikaciju: logističku regresiju, stabla odlučivanja i neuronske mreže, te smo imali namjeru testirati kvalitet svake od njih.

### 3.2.1 Primjena logističke regresije u predviđanju uspješnosti studenata

Postoji nekoliko metoda procjene u logističkoj regresiji ali najčešći, možda i najmanje rizičan u smislu potvrđivanja hipoteze je BSTEP(LR), za *stepwise* analizu unazad. Metod se zasniva na mogućnosti testiranja *log-likelihood-a* (vjerovatnoće) sa datom promjenljivom ispuštenom iz jednačine. U tabeli 3.1 prikazana je ukupna statistika testiranih slučajeva. Uzorak čine 234 studenta Pedagoškog fakulteta u Bijeljini.

Ukupan test modela dat je u tabeli 3.2. U našoj logističkoj regresiji BSTEP(LR) na početku sve promjenljive su ušle u jednačinu, a zatim je model testiran u deset koraka. Kao što se vidi na početku su sve vrijednosti date kao „korak“, „model“ i „blokiranje“ jednake sa nivoom značajnosti ,000. U početnom koraku sve varijable su u modelu. U drugom koraku došlo je do eliminacije jedne varijable koja nije statistički značajna (.946). U trećem koraku još jedna varijabla je eliminisana iz modela sa stepenom značajnosti (.859), u četvrtom koraku je eliminisana varijabla sa stepenom značajnosti (.816), u petom koraku varijabla sa stepenom značajnosti (.565), a u šestom koraku varijabla sa stepenom značajnosti (.487), u sedmom koraku varijabla sa stepenom značajnosti (.272) i u osmom koraku varijabla sa stepenom značajnosti (.117). Kroz postupak od deset koraka (v. tabelu 3.2) hi-kvadrat test se postepeno smanjivao, što je i imperativ modela, tako da je da smo od početne vrijednosti 68,789 dobili umanjenu vrijednost koja iznosi 64,223.

Tabela 3.1. Sumarni prikaz obrađenih rezultata

Neponderisani slučajevi	N	Postotak
Ukupan broj slučajeva	234	100.0
Izgubljeni slučajevi	0	.0
Ukupno	234	100.0
Neklasifikovani slučajevi	0	.0
Ukupno	234	100.0

Iz tabele 3.2 nismo mogli zaključiti koje su varijable bile eleminisane iz modela. Tek se uvidom u tabelu 3.3 mogu uočiti pravilnosti u eliminaciji pojedinih varijabli iz jednačine. Prva varijabla koja je eleminisana iz modela je *pol*. U sljedećem koraku eleminisana je varijabla *kvalitet vježbi*. U trećem koraku eleminisana je varijabla *prisustvo predavanju*. U četvrtom koraku učešće varijable *kvalitet predavanja* nije značajno učestvovalo u poboljšanju vjerovatnoće ukupnog modela. U sljedećim koracima su eleminisane varijable

sljedećim redoslijedom: kvalitet programa, način učenja i mjesto studiranja.

Tabela 3.2. Omnibus test modela

		$\chi^2$	df	Sig.
Korak 1	Korak	69.696	16	.000
	Rezultat	69.696	16	.000
	Model	69.696	16	.000
Korak	.....	.....	....	.....
Korak 10	Korak	-2.456	1	.117
	Rezultat	64.223	6	.000
	Model	64.223	6	.000

U konačnom modelu procjene vjerovatnoće učestvuju sljedeće varijable: važnost ocjene (0,000), prisustvovanje kolokvijumima (0,003), intelektualne sposobnosti (0,012), stipendija (0,039), prisustvo vježbama (0,049), dužina učenja (0,089). U narednoj tabeli prikazani su pseudo R – kvadратi. Cox & Snell indeks imaju vrijednost od 0 do ,75, tek se sa Nagelkerke indeksom vrši korekcija i dovodi nivo u opseg od 0 do 1. Naravno da se ovdje se R ne može posmatrati kao koeficijent determinacije u linearnej regresiji, jer je ovdje riječ o proporcionalnom učešću pojedinih varijabli u ukupnoj vjerovatnoći. Regresijom korak po korak u svakoj novoj etapi ukupan rezultat objasnjenje varijanse se povećavao. U finalnom modelu Cox & Snell iznose (0,24), a korekcijom Nagelkerke indeksom dobija se vrijednost (0,324) što se može smatrati zadovoljavajućim ishodom (Nagelkerke, N. J. D., 1991).

Tabela 3.3. Varijable koje ne ulaze u jednačinu

			Wald	Stepen slobode	Stepen značajnosti
<b>Korak 2</b>	Variable	Kvalitet vježbi	.003	1	.956
		Ukupna statistika	.003	1	.956
<b>Korak</b>	.....	.....	.....	.....	.....
<b>Korak11</b>	Variable	Pol	.050	1	.823
		Mjesto studiranja	2.453	1	.117
		Način učenja	.579	1	.447
		Prisustvo predavanju	.139	1	.709
		Kvalitet predavanja	.027	1	.869
		Kvalitet vježbi	.003	1	.955
		Kvalitet programa	.437	1	.509
		Kvalitet nastavnika	.137	1	.711
		Ocjenvivanje	.827	1	.363

	Motivacija	.897	1	.221
Ukupna statistika		6.229	10	.804

U tabeli 3.5 prikazane su predviđene vrijednosti zavisnih promjenljivih baziranih na modelu cijele logističke regresije. Ova tabela pokazuje koliko je slučajeva tačno prognozirano, a koliko nije. Cilj regresije u deset koraka bio je da se poveća procenat uspješnog predviđanja. U prvom koraku smo imali 50 slučajeva koji su trebali imati vrijednost 1, a dobili su vrijednost 2, i 42 slučaja koji su u ukupnom broju od 170 slučajeva koji su trebali dobiti vrijednost 2, dobili vrijednost 1. Dakle, ukupna tačnog predviđanja iznosi 74,8%. U konačnom modelu od ukupno 184 slučaja koji su trebali imati vrijednost 1, samo 49 slučajeva dobilo je vrijednost 2, a od 170 slučajeva koji su trebali uzeti vrijednost 2, 40 slučajeva je uzelo vrijednost 1.

Tabela 3.4. Koeficijent determinacije

Korak	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	247.118	.258	.347
2	247.121	.258	.347
3	247.127	.258	.347
4	247.195	.257	.347
5	247.259	.257	.347
6	247.617	.256	.345
7	247.916	.255	.344
8	248.930	.252	.339
9	250.134	.248	.334
10	252.591	.240	.324

Tabela 3.5. Procentualna tačnost uspješnog predviđanja

	Posmatrano	Predviđanje			
		uspjeh		Procenat tačnosti	
		1.00	2.00		
<b>Korak 1</b>	uspjeh	1.00	134	50	72.8
		2.00	42	128	75.3
	Ukupna tačnost				74.02
<b>Korak 2</b>	uspjeh	1.00	133	51	72.2
		2.00	41	129	75.8
	Ukupna tačnost				74.0

<b>Korak 3</b>	uspjeh	1.00	133	41	72.2
		2.00	41	129	75.8
	Ukupna tačnost				74.0
<b>Korak 4</b>	uspjeh	1.00	133	51	72.2
		2.00	41	129	75.8
	Ukupna tačnost				74.0
<b>Korak 5</b>	uspjeh	1.00	133	51	69.8
		2.00	40	130	76.4
	Ukupna tačnost				73.1
<b>Korak 6</b>	uspjeh	1.00	132	52	71.7
		2.00	39	131	77.0
	Ukupna tačnost				74.3
<b>Korak 7</b>	uspjeh	1.00	131	53	71.1
		2.00	38	132	77.6
	Ukupna tačnost				74.3
<b>Korak 8</b>	uspjeh	1.00	135	49	73.3
		2.00	40	130	76.4
	Ukupna tačnost				74.8
<b>Korak 9</b>	uspjeh	1.00	136	48	73.9
		2.00	41	129	75.8
	Ukupna tačnost				74.8
<b>Korak 10</b>	uspjeh	1.00	135	49	73.3
		2.00	40	130	76.4
	Ukupna tačnost				74.8

Da ne bismo ostali na površini kvantitativnih podataka izvršili smo detaljniju statističko-matematičku analizu svakog podatka. Pomoću jednačine  $P(x) = \frac{e^{b_0+b_1*x}}{1+e^{b_0+b_1*x}}$  izračunali smo vjerovatnoću svake promjenljive koja značajno utiče na stepen uspješnosti na studijama.

U desetom koraku dobili smo vrijednost konstante  $b_0 = -3.685$ . Konstanta ulazi u eksponencijalnu funkciju kao prvi član. Izračunali smo vjerovatnoću svake varijable koja je ušla u jednačinu. Najveću vjerovatnoću  $P(x)=0.88$  ima prediktor – važnost ocjene, čiji je b koeficijent 0.943, zatim slijedi prisustvo kolokvijumu ( $P(x)=0.85$ ;  $b_1=0.999$ ); intelektualne sposobnosti imaju sljedeću vjerovatnoću ( $P(x)=0.81$ ;  $b_1=0.929$ ); stipendija je po težini na četvrtom mjestu u jednačini ( $P(x)=0.70$   $b_1=0.488$ ), zatim prisustvo vježbama ( $P(x)=0.61$   $b_1=0.631$ ) i na kraju dužina učenja ( $P(x)=0.59$   $b_1=-0.378$ ).

Ukoliko pogledamo učešće pojedinih varijabli u ukupnom nivou vjerovatnoće predviđanja može se konstatovati sljedeće: da redovno prisustvo kolokvijuma pet puta povećava vjerovatnoću uspjeha na studijama (Exp. B 5.280), ukoliko im je ocjena koju će dobiti važna onda se stepen uspješnosti povećava četiri puta (Exp. B 4.218), visok nivo intelektualnih sposobnosti četiri puta povećava vjerovatnoću uspjeha (Exp. B 4.118), redovno prisustvo vježbama tri i po puta povećava

stepen uspješnosti (Exp. B 3.250), ako primaju stipendiju onda se uspješnost studenata povećava dva i po puta (Exp. B 2.590) i ako uče bar dva sata dnevno biće uspješniji jedanput (Exp. B 1.059).

Radi potkrepljenja rezultata dobijenih regresionom analizom može se konstatovati da 85% uspješnih studenata redovno prisustvuje kolokvijumima u odnosu na 53% prisustva manje uspješnih studenata. Uspješni studenti u 88% slučajeva prisustvuju vježbama u odnosu na 63% studenata iz druge grupe, 79% njih se izjasnilo da im je vrlo važno koju će ocjenu dobiti u odnosu na 45% studenata iz grupe manje uspješnih, 85% njih uči u prosjeku od dva do pet sati dnevno u odnosu na 60% studenata druge grupe i na kraju 27% njih prima stipendiju u odnosu na 11% iz druge grupe.

Rezultati dobijeni logističkom regresijom u našem istraživanju pokazuju 74,8% uspješnog predviđanja uspješnosti studenata u studiranju na Pedagoškom fakultetu. Varijable koje najviše doprinose ukupnoj vjerovatnoći predviđanja se mogu svrstati u dvije grupe i to: didaktičku (prisustvo kolokvijumima, prisustvo vježbama, dužina učenja i važnost ocjene), osobine ličnosti (intelektualna sposbnost) i socijalna grupa (primanje stipendije).

### **3.3 Primjena stabla odlučivanja u predviđanju uspješnosti studenata u studiranju**

Za istraživanje uspješnosti studenata u studiranju na Pedagoškom fakultetu u Bijeljini koristili smo CART stablo odlučivanja, koje se u nekim od prethodnih istraživanja pokazalo kao efikasno u predviđanju uspjeha studenata(Kovačić J. Z., 2009;Zaidah, I. and Daliela, R., 2007). Na listingu 3.5 prikazani su rezultati primjene ove metode.

```
*****
CART Decision Tree
važnost ocjene < 1.5
| kolokvijum < 1.5: 1(87.0/38.0)
| kolokvijum >= 1.5: 2(31.0/14.0)
važnost ocjene >= 1.5: 2(134.0/50.0)
Number of Leaf Nodes: 3
Size of the Tree: 5
== Stratified cross-validation ==
== Summary ==
Correctly Classified Instances      252      71.2502 %
Incorrectly Classified Instances    102      28.7598 %
Kappa statistic                      0.4014
Mean absolute error                  0.3873
Root mean squared error              0.4601
Relative absolute error              79.9955 %
Root relative squared error         93.5313 %
Total Number of Instances           354
== Detailed Accuracy By Class ==
```

```

TP Rate    FP Rate    Precision    Recall    F-Measure    ROC Area    Class
  0.684      0.254      0.64       0.656      0.649       0.683     1
  0.741      0.344      0.757      0.746      0.752       0.683     2
==== Confusion Matrix ====
   a      b  <- classified as
 126    58 |  a = 1
  44   126 |  b = 2
*****

```

Listing 3.5. Rezultati primjene CART stabla odlučivanja

Iz datog pregleda vidljivo je da je prosječna stopa klasifikacije koju daje stablo odlučivanja 71,2% što je manje od prosječne stope klasifikacije dobijene pomoću logističke regresije (74,8%). Stablo je posebno tačno pri prepoznavanju „lošijih“ studenata sa nižim prosjekom ocjena od 7,5, gdje stopa ispravne klasifikacije iznosi 74,1%. Dobijena je nešto niža stopa klasifikacije za klasu 1 - „boljih“ studenata(68,4%).

Rezultat klasifikacije studenata od strane stabla odlučivanja na poduzorku za testiranje (30% od ukupnog broja podataka), može se ilustrovati i pomoću matrice konfuzije, koja u kolonama prikazuje stvarni broj studenata koji pripadaju kategoriju sa nižim (2) ili višim (1) prosjekom, dok je u redovima prikazan broj studenata koje je model stabla odlučivanja svrstao u kategoriju 2 ili 1. Na dijagonali matrice konfuzije moguće je vidjeti broj studenata koje je model ispravno klasifikovan. Iz tabele je vidljivo da od ukupno 44 studenata sa nižim prosjekom (kategorija 2), stablo odlučivanja ne uspijeva svrstati u ispravnukategoriju, dok 126 je uspješno klasifikованo. Sa kategorijom 1 situacija je drugačija, 126 studenta je pravilno klasifikованo, dok je njih 58 svrstano u pogrešnu kategoriju. Cijeli model je ukupno pravilno svrstao 252 studenata od ukupno 354. Stablo je nešto preciznije od regresione analize i izdvaja samo dvije variable koje utiču na ukupnu vjerovatnoću i to: prisustvo kolokvijumima i važnost ocjene.

### 3.4 Primjena neuronskih mreža u predviđanju uspješnosti studenata u studiranju

Arhitektura testirane neuronske mreže u našem radu sastojala se od tri sloja. Broj jedinica (neurona) u skrivenom sloju i dužina učenja dobijeni su postupkom unakrsne validacije. Izgradnja modela provedena je kroz tri faze: (a) priprema podataka i modelovanje, (b) treniranje i testiranje neuronskih mreža, (c) tumačenje rezultata neuronskih mreže i izbor najboljeg modela. Treniranje mreže odvijalo se na uzorku za treniranje (70% ukupnog uzorka), dužina učenja mreže dobijena je postupkom unakrsne validacije, pri čemu mreža u iterativnom postupku uči na uzorku za treniranje koristeći različite parametre (npr. različit broj skrivenih neurona), a svaka kombinacija se testira na uzorku za

validaciju (30% ukupnog uzorka). Cilj je pronaći onu dužinu učenja i strukturu mreže koji daju najbolji rezultat na uzorku za validaciju. Na kraju se tako dobijena mreža testira na uzorku za testiranje (30% ukupnog uzorka), a dobijeni rezultat nakon faze testiranja korišten je kao mjerilo uspješnosti mreže. Od izlaznih funkcija testirana je sigmoidna funkcija, dok je kao pravilo učenja korišćeno delta pravilo sa momentumom 0.7 i dinamičkim koeficijentom učenja od 0.1 do 0.9 (Milosavljević, 2005. str 21). Za izračunavanje greške neuronske mreže u fazi treniranja najčešće se koriste srednja kvadratna greška (eng. mean square error – MSE) ili korijen srednje kvadratne greške (RMSE).

Budući da je u našem radu posmatran problem klasifikacije, nakon faze testiranja neuronske mreže izračunava se stopa klasifikacije za svaku klasu pojedinačno, te prosječna stopa klasifikacije, koja se uzima kao mjerilo ocjenjivanja uspješnosti modela neuronske mreže. Stopa klasifikacije za pojedinu klasu je postotak slučajeva koji je mreža ispravno stavila u tu klasu.

U našem radu je trenirana višeslojna neuronska mreža. Za rješavanje navedenog problema u neuronskoj mreži korištena su 33 skrivena neurona, logistička prenosna funkcija, delta-bar-delta pravilo učenja, a mreža je učila na najviše 1000 epoha. Broj skrivenih neurona koji daje najmanju grešku u fazi unakrsne validacije bio je 33. Za navedenu arhitekturu dobijena je stopa ispravne klasifikacije za svaku klasu na uzorku za treniranje i testiranje. Kao mjerilo uspješnosti modela korišćena je prosječna stopa klasifikacije na prethodno opisanom uzorku za testiranje.

Tabela 3.6: Kvalifikaciona tabela predviđanja pomoću neuronskih mreža

UZORAK	ATRIBUT	PREDVIĐANjE		
		2	1	Procenat
TRENING	2	98	21	82,8%
	1	99	27	78,3 %
	UKUPNO	56,8%	43,2%	80,9%
TESTIRANjE	2	43	7	84,4%
	1	36	22	63,0%
	UKUPNO	66,7%	33,3%	76,4%

Dobijeni rezultat znači da je u uzorku za testiranje 76,4% slučajeva bilo ispravno klasifikovano, dok je 23,6% slučajeva stavljen u pogrešnu klasu. Ako se pogledaju posebne stope klasifikacije za svaku klasu pojedinačno, tada je vidljivo da stopa klasifikacije za klasu 2 („lošije“ studente), iznosi 84,4%, dok je stopa klasifikacije za klasu 1, tj. Za „bolje“ studente 63,0%. Veća tačnost klasifikacije za „lošije“ studente ukazuje na to da studenti koji imaju prosjek niži od 7,5 imaju zajedničke karakteristike koje model neuronske mreže uspijeva prepoznati i

povezati uspješnije nego što je to slučaj kod studenata s prosjekom višim od 7,5. Za tumačenje rezultata dobijenih neuronskim mrežama nužno je objašnjenje učešća pojedinih varijabli u postupku predviđanja uspješnosti. U tabeli 3.7 su prikazane vjerovatnoće svake nezavisne varijable u ukupnom definisanom modelu. Slično modelu dobijenom logističkom regresijom varijabla *važnost ocjene* sa stoprocentnom vjerovatnoćom ulazi u model predviđanja. Varijable *dužina učenja*, *prisustvo kolokvijumima* i intelektualna sposobnost, sa vjerovatnoćom iznad 80% su značajni elementi modela. Ostale varijable manje utiču na model predviđanja. Bez obzira na veličinu uzorka, treba konstatovati da dobijeni rezultati ukazuju na slabosti sistema vaspitno-obrazovnog procesa jer varijable *kvalitet nastavnika*, *prisustvo predavanju*, *kvalitet vježbi* i *kvalitet programa* imaju veoma nisku prediktivnu vrijednost u predviđanju uspjeha studenata.

Tabela 3.7. Učešće pojedinih varijabli u modelu predviđanja uspjeha

Naziv varijable	Značaj (težina iz NM)	Normalizovan značaj
važnost ocjene	.152	100%
dužina učenja	.133	87,3%
prisustvo kolokvijumima	.122	80,3%
Intelektualna sposobnost	.121	80,1%
prisustvo vježbama	.080	52,9%
motivacija	.080	52,9%
kvalitet predavanja	.080	52,9%
način učenja	.071	46,5%
stipendija	.069	45,6%
način ocjenjivanja	.066	43,4%
mjesto studiranja	.063	41,2%
pol	.048	31,5%
kvalitet nastavnika	.033	21,8%
prisustvo predavanju	.030	19,6%
kvalitet vježbi	.030	19,5%
kvalitet programa	.024	15,5%

### 3.5 Analiza dobijenih rezultata

Sva tri modela *data mining*-a pružaju mogućnost uspješnog predviđanja uspjeha studenata. Rezultati koje smo dobili odslikavaju stanje našeg obrazovnog sistema u oblasti visokoškolskog obrazovanja. Potpuno je jasno da je reforma sistema izazvala promjene ponašanja kod studenata. Ono što se može smatrati zabrinjavajućim je činjenica da velikom broju studenata nije stalo koju će ocjenu dobiti na ispitu, da im nije važno da li će prisustvovati na predavanjima, jer očigledno nemaju

visoko mišljenje o mogućnostima učenja u toku samog vaspitno-obrazovnog procesa.

Pokazuje se da uspješni studenti više pažnje posvećuju učenju, učestvuju na kolokvijumima, posjećuju vježbe (što govori o aplikativnosti studija) i da im je stalo koju će ocjenu dobiti. Ovdje leže moguće intervencije u procesu modelovanja rada na fakultetu. Naravno da ove faktore treba povezati sa mogućnošću dobijanja stipendije.

Potrebno je izvršiti analizu svih dobijenih rezultata, sistem predviđanja obogatiti novim varijablama i onda izvršiti korekcije u realizaciji vaspitno-obrazovnog procesa. Neke od preporuka za poboljšanje vaspitno obrazovnog procesa koje su proizašle iz ovog istraživanja bi se mogle svrstati u sljedeće grupe:

- intenzivirati nastavni proces,
- češće organizovati rad u manjim grupama,
- bolje povezivanje teorijskih sa praktičnim sadržajima,
- redovno praćenje napretka studenata kroz kolokvije i druge oblike provjere znanja,
- pružiti podršku studentima pri prilagođavanju na studije,
- obimom i sadržajem osavremeniti literaturu koja će biti prilagođena ciljevima i načinu provjere znanja,
- motivisati nastavnike u cilju podizanja nivoa posvećenosti nastavi i studentima,
- podići nivo i kvalitet znanje nastavnika o metodici nastavnog rada i vrednovanju uspjeha,
- unaprijediti komunikacione vještina i posvećenost nastavnika nastavnom radu,
- osavremeniti sistem evaluacije nastave i nastavnika kao jednog od načina praćenje kvaliteta i podrške promjenama.

Kako poboljšati model predviđanja uspješnosti studenata na studiju?

- Uvođenjem novih varijabli, npr. ishoda učenja,
- povećanjem uzorka,
- u uzorak uključiti i druge učiteljske i pedagoške fakultete,
- kreiranjem informatičke podrške sistemu obrazovanja na visokoškolskim ustanovama.

## 4 Softverska podrška za predviđanje uspješnosti studiranja

Softverska podrška za prethodno definisani model predviđanja uspješnosti studiranja bi trebalo da se osloni na postojeća rješenja u oblasti tehnološki podržanog učenja. Pri tome se, s obzirom na broj dostupnih postojećih rješenja, ova studija ograničava na sisteme koji su dostupni u obliku otvorenog koda i omogućavaju njihovo prilagođavanje specifičnim primjenama. Pored ovakvih sistema, postoje i sistemi koji su dostupni isključivo uz komercijalnu licencu. Njihovo izostavljanje ne umanjuje opštost ove analize. Njihovo prilagođavanje specifičnim potrebama mora se obaviti od strane ili u saradnji sa proizvođačem datog softverskog paketa.

### 4.1 Pregled sistema za podršku učenju otvorenog koda

U ovom odjeljku dat je pregled osnovnih karakteristika sistema za podršku učenju koji su dostupni u obliku otvorenog koda. Među karakteristikama ovih sistema sa stanovišta ovog rada najznačajnije su one vezane za model studenata, njegovu kompatibilnost sa IMS LIP standardom i mogućnost njegovog proširivanja. Prilikom izbora odgovarajućeg sistema za realnu eksploraciju potrebno je uzeti u obzir i druge karakteristike kako bi sistem ispunio sve funkcionalne i nefunkcionalne zahtjeve.

**aTutor** [aTutor] je sistem koji je prije svega namijenjen upravljanju nastavnim sadržajima (*learning content management system*, LCMS). Njegova osnovna karakteristika je jednostavna i razvijena dostupnost nastavnih materijala. aTutor u potpunosti ispunjava W3C WCAG standard za dostupnost veb sadržaja na AA+ nivou [aTutor]. Pored toga, sistem omogućava nastavnicima da prate putanje u navigaciji i načine na koje studenti koriste nastavne sadržaje. Sa druge strane, nije namijenjen čuvanju podataka o učenicima.

**Canvas** [Canvas] je sistem koji sveobuhvatno implementira funkcije sistema za podršku učenju, sa posebnim verzijama koje pokrivaju funkcije visokog i nižih nivoa obrazovanja. Omogućava i

čuvanje podataka o studentima tokom cijelog procesa školovanja u okviru visokog obrazovanja. Dostupan je i kao rješenje koje funkcioniše u *cloud* arhitekturi sa posebnim mogućnostima vezanim za dostupnost nastavnih sadržaja i sistema u cjelini u periodima intenzivnog saobraćaja (npr. pred kraj roka za predaju radova ili neposredno pred termin ispita).

**Chamilo** [Chamilo] je projekat proistekao iz Claroline [Claroline] i Dokeos [Dokeos] projekata a predstavlja i sastavni deo OLPC (*one laptop per child*) inicijative. Ima razvijene funkcije za upravljanje dokumentima i kolaborativni razvoj nastavnih sadržaja. Podrška za čuvanje profila studenata nije razvijena u jednakoj mjeri.

**eFront** [eFront] je sistem započet kao istraživački projekat a kasnije je zaživio i kao softverski proizvod na tržištu. Predstavlja jedan od najkompletnijih sistema za podršku učenju, obuhvatajući upravljanje podacima o studentima, nastavnim sadržajima, kurikulumom, alate za međusobnu komunikaciju studenata i/ili nastavnika, izvještavanje, integraciju sa društvenim mrežama i sistemima za elektronsko plaćanje, kao i upravljanje podacima o organizacionoj strukturi institucije i nastavnim kadrom.

**Fedena** [Fedena] je sistem za podršku administrativnim poslovima u obrazovnim institucijama. Posebno je raširen u Indiji. Posjeduje i mogućnost integracije sa Moodle sistemom za potrebe rukovanja nastavnim sadržajima.

**ILIAS** [Ilias] je njemački projekat koji, obuhvatajući i repozitorijum nastavnih sadržaja, promoviše koncept ličnog radnog prostora (*personal desktop*) namijenjenog samostalnom radu studenata koji u velikoj mjeri pokriva funkcije kompletne računarske radne stanice za potrebe obrazovanja.

**LAMS** [LAMS] je sistem koji omogućava kolaborativni dizajn, upravljanje i distribuciju nastavnih sadržaja. Ističe se grafičkim alatima za kreiranje sadržaja koji omogućavaju vizuelno uređivanje sekvenci aktivnosti učenja. Zasniva se na IMS LD (*Learning Design*) standardu za modelovanje procesa učenja. Omogućava kreiranje „digitalnih planova učenja“ (*digital lesson plans*) koje studenti mogu koristiti putem računarske mreže. Postoji i centralni repozitorijum ovakvih planova koji je na raspolaganju svim nastavnicima koji koriste LAMS.

**.LRN** [LRN] je originalno nastao na univerzitetu MIT i koristi se u obrazovnim institucijama, organima javne uprave i neprofitnim organizacijama. U osnovi ovog sistema leži pojam „zajednice“ koju čine učenici okupljeni oko iste teme. Sistem posjeduje mogućnosti za upravljanje kurikulumom, nastavnim sadržajima, profilima učenika i saradnju online korisnika. Ove funkcije nisu razvijene u istoj mjeri kao u sistemima Moodle, Canvas ili eFront.

**Moodle** [Moodle] je danas najrašireniji sistem za podršku učenju. Odlikuje se velikom fleksibilnošću i mogućnošću prilagođavanja

konkretnim potrebama putem programskih dodataka (*plugins*) koji su vrlo brojni. Tradicionalno ovaj projekat kasni sa uvođenjem podrške za informatičke standarde u ovoj oblasti kao što je SCORM, ali se sistem može prilagoditi zahtjevima putem *plugin-ova*. Velika zajednica korisnika predstavlja značajan resurs u proširivanju mogućnosti ovog sistema.

**OLAT**[OLAT] je započet kao projekat Univerziteta u Cirihi namijenjen upravljanju nastavnim sadržajima. U današnjoj verziji posjeduje i alate za komunikaciju učenika i nastavnika kao podršku za mješoviti koncept učenja (*blended learning*) i evidentiranje ocjena.

**Sakai** [Sakai] predstavlja zajednicu akademskih institucija, profitnih organizacija i pojedinaca koji sarađuju na razvoju zajedničkog sistema za saradnju i učenje. Koristi se za obrazovanje, istraživanje i saradnju učesnika. Razvijeni sistem posjeduje funkcije za distribuciju sadržaja, evidentiranje ocjena, diskusije, komunikaciju uživo (*chat*), kreiranje i slanje realizovanih zadataka i *online* testiranje. Pored toga, posjeduje i funkcije za suradnju grupa korisnika i istraživačkih timova. Podrška za upravljanje učeničkim profilima nije razvijena na nivou sistema kao što je Canvas, eFront ili Moodle.

**SWAD** [SWAD] je projekat koji je inicijalno zaživio na Univerzitetu u Granadi. Ima razvijene funkcije za upravljanje organizacionom strukturu i korisnicima, kontrolu pristupa, čuvanje i distribuciju nastavnih sadržaja i statistike korišćenja sistema.

Podrška za standarde u ovoj oblasti kao što su *PAPI Learner* i IMS LIP među navedenim sistemima za podršku učenju nije na visokom nivou. Prevashodno su sistemi fokusirani na podršku nekoj od verzija SCORM standarda koji omogućava prenosivost nastavnih sadržaja između različitih sistema. Neposredna podrška za IMS LIP standard nije prisutna ni kod jednog od navedenih sistema. Sa stanovišta razvijenosti funkcija za upravljanje profilima učenika, među ovim sistemima izdvajaju se Canvas, eFront i Moodle.

eFront ne posjeduje mogućnost proširivanja putem programskih dodataka, već je dostupan u dvije verzije – besplatnoj i komercijalnoj. Komercijalna verzija je orijentisana na korporativne korisnike i podršku za cjeloživotno učenje. Podaci o učeničkim profilima ne mogu se proširivati.

Moodle inicijalno ne posjeduje bogat skup informacija o profilu učenika. Uz odgovarajuće programske dodatke ovaj skup se može proširiti potrebnim podacima. Međutim, potrebni programski dodaci često nisu međusobno usklađeni ili nisu prilagođeni za istu verziju osnovnog Moodle sistema, što komplikuje njegovo održavanje. Trenutno postoji mogućnost dodavanja pojedinačnih polja u profil učenika, pri čemu polja mogu uzimati i vrijednosti iz rječnika, ali

razvijenost tih funkcija nije zadovoljavajuća imajući u vidu složenost struktura koje propisuje IMS LIP standard.

Canvas sistem u ovom trenutku ne implementira podršku za IMS LIP standard, ali je razvoj ove podrške u planu. S obzirom na najbolje razvijenu podršku za rukovanje studentskim profilima, Canvas je u ovom trenutku najbolje rješenje za razvoj softverske podrške za sistem za predviđanje uspješnosti studenata. Komunikacija dodatnih softverskih modula koji čine prototipsku implementaciju sistema za predviđanje uspješnosti studiranja odvija se putem otvorenog programskog interfejsa (API) koji definiše Canvas.

Canvas sistem se posebno ističe još jednom svojom osobinom – omogućava čuvanje dodatnih atributa vezanih za profil studenata bez potrebe za izmjenom programskog koda sistema i bez potrebe za definicijom strukture pridodatih podataka.

Canvas-ov API zasniva se na REST (*Representational State Transfer*) principu (Fielding, 2000) i JSON (*JavaScript Object Notation*) [JSON] formatu podataka. Na primjer, podaci o korisniku sistema (studentu) sa internim Canvas identifikatorom `id` mogu se dobiti slanjem sljedećeg HTTP GET zahtjeva:

```
GET /api/v1/users/<id> HTTP/1.1
Authorization: Bearer <token>
Accept: application/json
```

Svaki zahtjev koji se upućuje Canvas serveru mora uključiti i odgovarajuće podatke za autentikaciju u skladu sa OAuth 2.0 protokolom [OAuth], pa je `Authorization` zaglavje u zahtjevu obavezno. Odgovor Canvas servera, u slučaju da je traženi korisnik pronađen u bazi, dat je kao uspješan rezultat HTTP operacije uz podatke u JSON formatu:

```
HTTP/1.1 200 OK
Content-Type: application/json
Content-Length: nnn

{
    // identifikator korisnika
    "id": 2,
    // ime i prezime korisnika
    "name": "Petar Petrović",
    // ime korisnika pogodno za sortiranje
    "sortable_name": "Petrović, Petar",
    // kratko ime korisnika, pogodno za neformalnu komunikaciju
    "short_name": "Petar",
    // identifikator iz studentske službe (broj indeksa)
    "sis_user_id": "SW12/2015",
    // interni identifikator iz sistema studentske službe
    "sis_import_id": 18,
    // korisničko ime za prijavljivanje na Canvas
    "login_id": "petar.petrovic@uns.ac.rs",
    // putanja do korisnikovog avatara
```

```

    "avatar_url":  

    "https://en.gravatar.com/avatar/d8cb8c8cd40ddf0cd05241443a591868?s=80&r=g",  

    // lista predmeta koje sluša korisnik  

    "enrollments": "",  

    // glavna email adresa korisnika  

    "email": "petar.petrovic@gmail.com",  

    // lokacija korisnika  

    "locale": "tlh",  

    // trenutak posljednje posjete sistemu  

    "last_login": "2012-05-30T17:45:25Z",  

    // vrijemenska zona  

    "time_zone": "Europe/Belgrade",  

    // biografija korisnika  

    "bio": "..."  

}

```

Iako Canvas API podrazumijeva korišćenje isključivo JSON formata, ovi podaci se na jednostavan način mogu konvertovati u XML format prema IMS LIP šemi. Kako IMS LIP podrazumijeva znatno širi skup podataka o studentu u odnosu na osnovni skup koji koristi Canvas, može se iskoristiti Canvas-ova funkcija za smještanje dodatnih podataka o korisniku sistema u JSON formatu. Na primjer, slanjem HTTP komande PUT može se poslati dodatni skup podataka o korisniku:

```

PUT /api/v1/users/<id>/custom_data HTTP/1.1
Authorization: Bearer <token>
Content-Type: application/json

```

```

{
  "ns": "rs.ac.uns.canvas"
  "data": {
    "interest": {
      "description": {
        "short": "...",
        "long": "..."
      }
    }
  }
}

```

Dva obavezna atributa u ovom dokumentu su ns, koji predstavlja identifikator prostora imena za podatke – čime se omogućava da više različitih aplikacija može da smješta svoje dodatne podatke na ovaj način – i data, koji predstavlja objekat sa podacima koji se smiještaju u Canvas-ovu bazu podataka. Nakon skladištenja podataka, pristup ovim podacima može se odnositi na cijeli uskladišteni JSON objekat, ali i na njegove pojedine dijelove. Na primjer, HTTP zahtjev

```
GET /api/v1/users/<id>/custom_data
```

vratice kompletan uskladišteni JSON objekat sa dopunskim podacima, dok će HTTP zahtjev

```
GET /api/v1/users/<id>/custom_data/interest/description/short
```

vratiti samo sadržaj atributa short u okviru JSON objekta koji je prethodno uskladišten.

Ovakvim pristupom je, u sklopu profila korisnika, omogućen jednak tretman atributa koje je unaprijed predvidio Canvas sistem i dopunskih atributa koje dodaju zasebne aplikacije. Kompletan IMS LIP profil studenata se može smjestiti u Canvas na ovaj način. Na osnovu ove karakteristike, Canvas sistem posredno podržava kompletan IMS LIP profil i elemente našeg modela za predviđanje uspješnosti studiranja.

## 4.2 Softverski alati za istraživanje podataka

Prilikom izbora softverskih alata za *data mining* za potrebe ovog rada ograničili smo se samo na alate dostupne u obliku otvorenog koda. Među takvim alatima posebno se ističu RapidMiner [RapidMiner] i Weka [Weka]. Kako svi razmatrani alati podržavaju metode koje smo koristili u ovom radu – logističku regresiju, stabla odlučivanja i neuronske mreže – izbor bilo kog od ovih alata bi zadovoljio potrebe rada. Stoga je izabran RapidMiner kao najrasprostranjeniji alat sa širokom zajednicom korisnika.

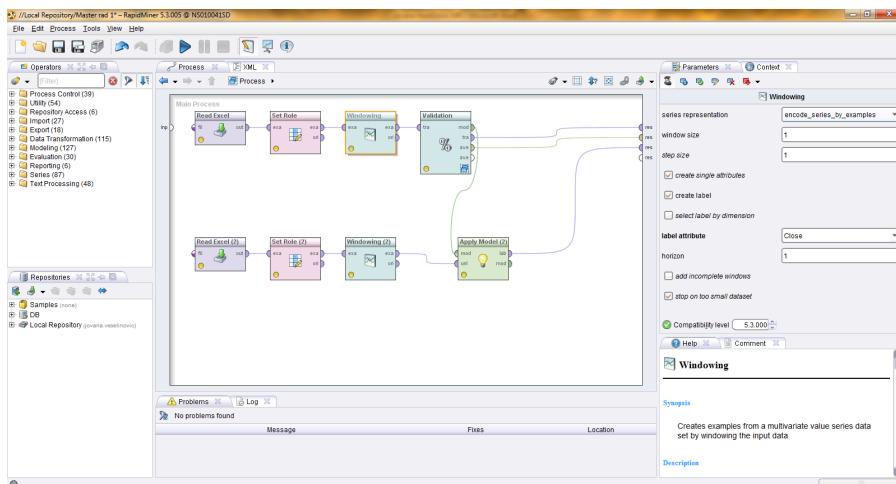
RapidMiner je programsko okruženje za mašinsko učenje, istraživanje podataka, analizu teksta, predviđanje i biznis analize. Koristi se za brzu izradu prototipova na osnovu prikupljenih informacija i razvoj kako industrijskih tako i drugih vrsta aplikacija.

Grafički interfejs je jednostavan i prijatan za korisnika (slika 4.1). Pogodan je za jednostavno kreiranje procesa uvezivanjem pojedinačnih operatora u lanac koraka. Takođe generiše XML fajl koji definiše analitičke procese koji se odnose na podatke. Alternativno, može se pozvati od strane drugih programa ili koristiti kao API [RapidMiner]. Omogućeno je i pokretanje kreiranog procesa iz komandne linije.

Još jedna prednost ovog alata je njegova mogućnost analize podataka koji su generisani od instrumenata sa stalnim i brzim protokom podataka (upotreba kod genotipizacije, proteomike i masene spektrometrije). U mogućnosti ovog alata koje su vezane za istraživanje podataka i procedure mašinskog učenja spadaju: učitavanje i transformacija podataka (ETL – Extract, Transform, Load), predobrada, vizuelizacija, modelovanje, evaluacija i primjena kreiranih modela nad nepoznatim skupom podataka [RapidMiner].

Program je napisan u Java programskom jeziku. Ima opcije za prikazivanje rezultata u grafičkom obliku. Moguće je proširiti funkcionalnost raznim dodacima. Posjeduje veliki broj sopstvenih

operatora, ali nudi i mogućnost korišćenja Weka i R operatora instalacijom odgovarajućih dodataka [RapidMiner]. Dokumentacija je uključena u program i posjeduje dobro uputstvo za upotrebu.

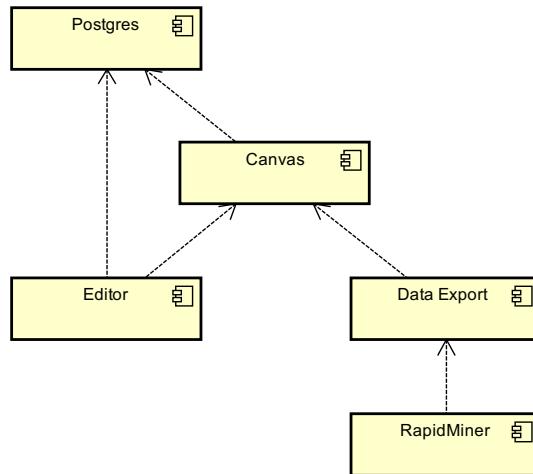


Slika 4.1. Grafički interfejs alata RapidMiner

## 4.3 Implementacija modela za predviđanje uspješnosti studiranja

### 4.3.1 Arhitektura sistema

Prototipska implementacija sistema za predviđanje uspješnosti sastoji se iz nekoliko osnovnih komponenti, prikazanih na UML dijagramu komponenti sa slike 4.2. Skladištenje podataka iz učeničkih profila obavlja Canvas kao sistem za podršku učenju. Canvas za svoje potrebe interno koristi Postgres sistem za upravljanje relacionim bazama podataka ali ostatak sistema ne zavisi od Postgres-a. Kako upravljanje IMS LIP podacima koje Canvas ne obuhvata direktno, nego u obliku dopunskih JSON struktura nije omogućeno kroz korisnički interfejs Canvasa, razvijena je zasebna veb aplikacija – na dijagramu komponenti sa slike 4.2 prikazana kao *Editor* – za unos ovih podataka. Za potrebe skladištenja podataka ova veb aplikacija se u potpunosti oslanja na Canvas-ov API zasnovan na JSON formatu. Za rukovanje internim podacima, kao što su podaci za autentifikaciju korisnika i konfiguracija aplikacije, *Editor* se takođe oslanja na sistem za upravljanje relacionim bazama podataka. Prilagođavanje podataka iz studentskih profila za potrebe analize u *RapidMiner* alatu je zadatak posebne komponente *Data Export*.



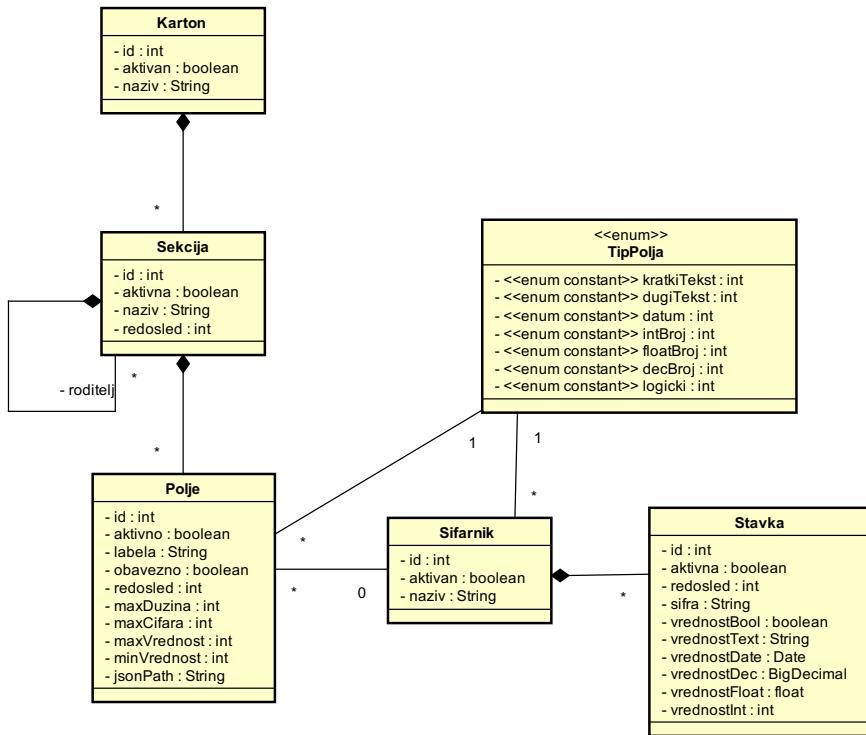
Slika 4.2. Osnovne komponente prototipske implementacije sistema

### 4.3.2 Aplikacija za unos profila studenata

Veb aplikacija za unos podataka iz profila učenika bi trebalo da obezbijedi korisnički interfejs za unos svih podataka predviđenih IMS LIP standardom i dodatnih elemenata našeg modela za predikciju. Podaci koji se unose kroz ovu aplikaciju skladište se u okviru Canvas sistema za podršku učenju.

Kako je IMS LIP standard vrlo obiman, jedna ekranska forma za unos svih podataka predviđenih standardom bi bila vrlo nepregledna. Pored toga, održavanje ovakve aplikacije, u kontekstu izmjena koje se mogu pojaviti u narednim verzijama standarda, može biti mukotrpno. Zbog toga je veb aplikacija realizovana kao aplikacija za popunjavanje formulara (studentskog profila) koja je u potpunosti vođena podacima. Ova osobina omogućava da se formular kao struktura podataka koji se unose kroz aplikaciju opiše podacima, i da se potom korisnički interfejs aplikacije namijenjen unosu podataka dinamički prilagodi datom opisu strukture formulara. Dijagram klasi koji predstavlja model podataka za opis strukture formulara (studentskog profila) dat je na slici 4.3.

Model podataka omogućava rad sa više formulara istovremeno. Svaki pojedinačni formular za popunjavanje podataka predstavljen je klasom *Karton*. Formulari se, za potrebe preglednosti i organizacije elemenata korisničkog interfejsa, sastoje iz hijerarhijski uređenih sekcija (klasa *Sekcija*). Sekcije mogu da sadrže druge sekcije i konkretna polja sa podacima (klasa *Polje*). Svako polje ima svoj tip podatka predstavljen enumeracijom *TipPolja*. Tip polja utiče na način na koji će polje biti prikazano u korisničkom interfejsu i na koji način će ograničavati unos dozvoljenih vrednosti.



Slika 4.3. Model podataka za opis strukture formulara za unos podataka iz profila studenata

Ograničenja u pogledu sadržaja pojedinačnog polja, zavisno od njegovog tipa, navedena su atributima *maxDuzina* (za tekstualna polja) i *maxCifara*, *maxVrednost*, *minVrednost* (za numerička polja). Mapiranje polja u formularu na element JSON dokumenta koji će biti skladišten u Canvas sistemu predstavljeno je atributom *jsonPath*.

Klasa *Sifarnik* predstavlja konačan skup dozvoljenih vrijednosti za neko polje. Jedan šifarnik može biti korišćen u više različitih polja. Ukoliko polje uzima vrijednost iz šifarnika, veza između objekta klase *Polje* i objekta klase *Sifarnik* će biti uspostavljena. Podaci obuhvaćeni šifarnikom takođe imaju svoj tip, predstavljen vezom klase *Sifarnik* sa enumeracijom *TipPolja*. Pojedinačni elementi šifarnika predstavljeni su klasom *Stavka*. Zavisno od tipa podatka koji se predstavlja šifarnikom, jedan od atributa ove klase *vrednostBool*, *vrednostText*, *vrednostDate*, *vrednostDec*, *vrednostFloat*, *vrednostInt* biće korišćen za skladištenje konkretne vrednosti.

Radi fleksibilnije organizacije korisničkog interfejsa, svaki njegov element (sekcija, polje, stavka šifarnika) ima svoj redni broj u okviru konteksta u kome se prikazuje, predstavljen atributom *redosled* u odgovarajućim klasama. Pored toga, mogućnost da se pojedini elementi

korisničkog interfejsa privremeno uklone predstavljena je atributom *aktivran*.

Ilustracija implementirane aplikacije, konfigurisane podacima koji predstavljaju formular za evidenciju učeničkih profila, data je na slici 4.4.

The screenshot shows a web-based application for managing student profiles. The main title is "Evidencija učeničkih profila". On the left, there's a sidebar with navigation links: Početna, Novi učenik (highlighted in orange), Moji učenici, Pretraga, Izvještaji, and Administracija. The main content area is titled "Novi učenik" with the sub-instruction "Unesite podatke za novog učenika". Below this, there are several tabs: Identifikacija, Ciljevi, Kvalifikacije, Aktivnosti, Kompetencije, Prepis, Dostupnost, Pripadnost, Vele, and Uspješnost. The "Identifikacija" tab is active. Inside this tab, there are two sections: "Ime" (Name) containing fields for "ime" and "prezime", and "Adresa" (Address) containing fields for "ulica", "broj", "mjesto", "poštanski kod", "region", and "država". In the bottom right corner of the form area, there is a green "Sačuvaj" (Save) button.

Slika 4.4. Ekranska forma za unos profila učenika

Aplikacija prikazana na slici 4.4 prikazuje formular za unos učeničkih profila segmentiran u sekcije date na dva nivoa. Sekcije prvog nivoa predstavljaju osnovne sekcije IMS LIP standarda. Njima je dodata još jedna sekcija *Uspješnost* koja sadrži podatke definisane našim modelom predikcije kojih nema u IMS LIP standardu. Sekcije prvog nivoa predstavljene su u korisničkom interfejsu kao kartice (*tabs*) osnovnog formulara.

Sekcije drugog nivoa prikazane su kao podnaslovi u okviru jedne kartice formulara. Pojedinačna polja za unos podataka predstavljena su odgovarajućim komponentama korisničkog interfejsa (jednolinijsko tekstualno polje, višelinjsko polje, numeričko polje, datumsko polje, itd.) u okviru tih podnaslova.

Popunjeni formular se klikom na dugme *Sačuvaj* konvertuje u JSON dokument koji se upućuje Canvas sistemu na skladištenje. Pojedini elementi formulara se razvrstavaju u strukturi JSON dokumenta prema svom atributu *jsonPath* predstavljenom na dijagramu klasa sa slike 4.3.

Podaci unijeti na ovaj način postaju sastavni dio Canvas sistema. Upotrebori Canvas sistema u svakodnevnom radu – na primjer, za evidentiranje ocjena, prisustva studenata nastavi i slično – obezbjeđuju se i podaci koji se mogu koristiti za predviđanje uspješnosti studiranja.

Prikazano rješenje oslanja se na Canvas sistem za potrebe skladištenja podataka. Bez umanjenja opštosti ovog rješenja, moguće je

prilagoditi ga saradnji sa drugim sistemima za podršku učenju (LMS), s tim što bi se ova komponenta sistema morala dopuniti mogućnošću samostalnog skladištenja podataka koji nisu podržani izabranim LMS-om.

Zahvaljujući ovakvoj implementaciji sistema, predviđanje uspješnosti studiranja može da postane integralni deo informacionog sistema za podršku učenju koji se zaista koristi u praksi, i time koristi uvijek aktuelne i ažurne podatke. Prikazana prototipska implementacija definiše tehološku platformu koja omogućava korišćenje kvalitetnog LMS-a koji odgovara potrebama visokoškolskih ustanova, a pritom pruža mogućnost predikcije uspješnosti studiranja kao sastavni dio funkcionalnosti sistema.



## 5 Zaključna razmatranja

Obrazovne aktivnosti možemo podijeliti u dvije grupe: one koje se odnose na organizaciju nastave, i one koje se tiču izvođenja nastave. Organizacija nastave podrazumjeva planiranje i kreiranje nastave na makro i mikro nivou. Makro nivo se odnosi na definisanje studijskih programa, kurseva i njihovih kurikuluma, vertikalno i horizontalno usklađivanje pojedinačnih kurikuluma, i organizaciju učesnika u nastavi (broj i struktura učenika i nastavnika i njihov raspored po studijskim programima i kursevima). Mikro nivo je vezan za planiranje konkretnih nastavnih aktivnosti u okviru jednog kursa, razvoj i izbor nastavnih materijala, vremensku artikulaciju nastavnih aktivnosti i definisanje instruksijskog dizajna.

Predmet istraživanja u ovoj disertaciji je podrška upravljanju obrazovnim procesom u visokom obrazovanju na osnovu predikcije postignuća studenata. Pri tome, istraživanje se bavi aspektima upravljanja obrazovnim procesom i na makro i na mikro nivou.

U posljednjih petnaest godina razvijene su različite aplikacije koje primjenjuju tehnike istraživanja i analize podataka. Do sada objavljene studije obuhvataju skoro sva pitanja u oblasti obrazovanja od upisa u školu (fakultet) pa do veb-baziranog obrazovanja. Istraživanja u području upotrebe inteligentnih metoda za predviđanje uspješnosti studenata uglavnom su orijentisana na razvoj modela koji će se koristiti kao pomoć pri odlučivanju o prijemu studenata na studije. Takvi modeli kao kriterije uzimaju u obzir informacije o kandidatu koje su raspoložive prije upisa, kao npr. završena srednja škola, uspjeh u srednjoj školi, socijalni status i druge informacije prije studija, te uz pomoć statističkih metoda ili metoda vještačke inteligencije nastoje pronaći model koji će produkovati što veću tačnost u predviđanju. Predviđanje uspješnosti u studiranju *data mining* metodama umnogome zavisi od kvaliteta prikupljenih podataka. Rezultati dosadašnjih istraživanja ukazuju da određene grupe varijabli treba uvijek uzimati u obzir jer sa visokim stepenom vjerovatnoće učestvuju u predviđanju uspjeha.

Trenutna organizacija obrazovnog procesa najčešće se ne oslanja na formalne modele predikcije studentskog postignuća. Ovo za posljedicu ima sljedeće probleme.

*Loša iskorišćenost resursa obrazovnih institucija.* S obzirom da su uobičajene metode predviđanja veličine i strukture populacije u određenoj obrazovnoj prilici neprecizne, pravilo je da alocirani resursi obrazovne institucije ne odražavaju realne potrebe. To rezultuje potrebom za dinamičkom realokacijom resursa, koja unosi dodatne poteškoće.

*Neodgovarajući izbor individualne obrazovne putanje.* Student bira obrazovnu putanju bez prethodnog znanja o svom potencijalnom uspjehu u toj putanji. Usljed neadekvatnog izbora obrazovnih prilika studenti se suočavaju sa poteškoćama u studiranju, kao što su smanjenje motivacije, neuspješno realizovanje obaveza na studijama, nemogućnost realizacije obrazovnih ishoda.

*Izostanak poboljšanja kurikuluma.* Informacije koje su potrebne za poboljšanje kurikuluma dostupne su prekasno. Problemi u kurikulumu se uočavaju tek prilikom same realizacije kurikuluma, što ima za posljedicu da kurikulum nije prilagođen populaciji studenata

*Neadekvatna obrazovna iskustva.* Nastavni materijal i obrazovna iskustva generalno nisu prilagođena potrebama, sklonostima i obrazovnom nivou studenata.

*Tipska nastava za sve studente.* Pošto informacije o potencijalnom postignuću studenata nisu dostupne tokom planiranja obrazovnih prilika, prilikom realizacije nastave zanemaruju se individualne razlike među studentima po sposobnostima, sklonostima i stilu učenja.

Predviđanje uspješnosti studenata na osnovu prethodnog postignuća može doprinjeti rješavanju pomenutih problema. Naime, ukoliko su informacije o potencijalnom postignuću pravovremeno dostupne, moguće je unaprijediti planiranje obrazovnog procesa tako da se negativne posljedice pomenutih problema izbjegnu ili ublaže.

U prvom poglavlju rada, najprije su objašnjeni osnovni pojmovi vezani za upravljanje obrazovnim procesom. Razmatran je značaj upravljanja obrazovnim procesom iz perspektive studenta, nastavnika i poslodavca. Dat je pregled postojeće literature u ovoj oblasti, a posebno u domenu predikcije uspješnosti studenata i tehnika koje su korišćene za predikciju.

U drugom poglavlju analizirani su postojeći informatički standardi za reprezentaciju profila studenata – PAPI Learner i IMS LIP. IMS LIP standard je identifikovan kao pogodan za upotrebu za potrebe ove disertacije jer obuhvata znatno širi skup podataka o studentima, poseduje standardom predviđena mesta i načine za proširenja profila studenata novim elementima, a podrška za njega u raspoloživim softverskim sistemima za upravljanje učenjem je, iako nekompletna, daleko bolja nego za *PAPI Learner*.

Treće poglavlje disertacije predstavlja centralni deo rada. U njemu su predstavljeni model podataka i tehnike za predviđanje

uspješnosti studenata. Tehnike za predviđanje su primjenjene na uzorku sačinjenom na Pedagoškom fakultetu u Bijeljini i predstavljaju kvantitativnu verifikaciju predloženog rješenja. Na osnovu rezultata analize formulisani su zaključci koji mogu doprinijeti unapređenju nastavnog procesa u visokom obrazovanju.

U četvrtom poglavlju prikazana je prototipska implementacija softverskog sistema za podršku učenju koja omogućava predikciju uspješnosti studenata na osnovu prethodno definisanog modela i tehnika predikcije. Implementacija je zasnovana na IMS LIP standardu i odgovarajućim proširenjima i Canvas sistemu koji omogućava skladištenje svih elemenata studentskog profila u skladu sa IMS LIP. Razvijena je aplikacija za unos podataka prema prikazanom modelu i njihovo skladištenje u Canvas. Data aplikacija komunicira sa Canvas sistemom putem standardnog programskog interfejsa zasnovanog na savremenim veb tehnologijama – HTTP protokolu, REST servisima i JSON formatu podataka.

Osnovni rezultat disertacije predstavlja formalni model predikcije uspješnosti studiranja. Model predikcije sadrži dvije osnovne komponente:

- 1. Model podataka** koga čine podaci koji se evidentiraju o studentu i obrazovnim prilikama. Model podataka je formiran u skladu sa potrebama predikcije i obrazovnom praksom u visokoškolskim institucijama, a reprezentacija modela podataka je data u formalnom i mašinski čitljivom obliku. U tu svrhu iskorišćen je međunarodni standard IMS LIP koji je proširen pojedinim elementima modela podataka. Proširenje standardnog modela je učinjeno u skladu sa pravilima proširivanja koje propisuje sam standard. Na ovaj način je omogućena potpuna saradnja i razmjena podataka između različitih informacionih sistema koji evidentiraju podatke o studentima.
- 2. Tehnike predikcije** koje predstavljaju formalne matematičke metode pomoću kojih se iz modela podataka vrši predviđanje postignuća studenata. U radu su analizirane tri metode za analizu podataka: logistička regresija, stabla odlučivanja i neuronske mreže. Sve tri primjenjene metode su pokazale uspjeh u primjeni, uz neuronske mreže kao najuspješniju metodu. Uzorak korišćen prilikom ovog istraživanja prikupljen je na Pedagoškom fakultetu u Bijeljini.

Dodatni rezultat disertacije predstavlja prototipska implementacija informacionog sistema za podršku predviđanju uspjeha studenata. Prikazano rješenje oslanja se na Canvas sistem za podršku učenju (LMS) kao osnovu koja se koristi za potrebe skladištenja podataka. Bez

umanjenja opštosti ovog rješenja, moguće je prilagoditi ga suradnji sa drugim LMS, s tim što bi se ova komponenta sistema morala dopuniti mogućnošću samostalnog skladištenja podataka koji nisu podržani izabranim LMS-om.

Ovakva implementacija sistema omogućava da predviđanje uspješnosti studiranja postane integralni deo informacionog sistema za podršku učenju koji se zaista koristi u praksi, i time koristi uvijek aktuelne i ažurne podatke. Prikazana prototipska implementacija definiše tehološku platformu koja omogućava korišćenje kvalitetnog LMS-a koji odgovara potrebama visokoškolskih ustanova, a pritom pruža mogućnost predikcije uspješnosti studiranja kao sastavni deo funkcionalnosti sistema.

Prikazani informacioni model za predviđanje uspješnosti studiranja mogao bi se dalje poboljšati putem (1) uvođenja novih varijabli u model, npr. ishoda učenja, (2) povećanjem uzorka, (3) uključivanjem drugih visokoškolskih institucija u analizu i (4) daljim unapređenjem prototipske implementacije sistema u cilju formiranja softverskog proizvoda koji može u cijelosti zadovoljiti potrebe visokoškolskih institucija u domenu upravljanja obrazovnim procesom.

## A. Prilog

U ovom prilogu dat je listing XML šeme koja predstavlja formalnu specifikaciju modela za predikciju uspješnosti studiranja.

```
<?xml version="1.0" encoding="UTF-8"?>
<xss:schema xmlns:xss="http://www.w3.org/2001/XMLSchema"
elementFormDefault="qualified">

<xss:element name="modelPredikcije">
  <xss:complexType>
    <xss:sequence>
      <xss:element name="identifikacija">
        <xss:complexType>
          <xss:sequence>
            <xss:element name="studiram">
              <xss:simpleType>
                <xss:restriction base="xss:string">
                  <xss:enumeration value="uMjestuRodjenja"/>
                  <xss:enumeration value="svakodnevnoPutujem"/>
                  <xss:enumeration value="doselio"/>
                </xss:restriction>
              </xss:simpleType>
            </xss:element>
            <xss:element name="stipendiranje">
              <xss:simpleType>
                <xss:restriction base="xss:string">
                  <xss:enumeration value="redovno"/>
                  <xss:enumeration value="povremeno"/>
                  <xss:enumeration value="nePrimam"/>
                </xss:restriction>
              </xss:simpleType>
            </xss:element>
            <xss:element name="pol">
              <xss:simpleType>
                <xss:restriction base="xss:string">
                  <xss:enumeration value="muski"/>
                  <xss:enumeration value="zenski"/>
                </xss:restriction>
              </xss:simpleType>
            </xss:element>
          </xss:sequence>
        </xss:complexType>
      </xss:element>
    </xss:sequence>
  </xss:complexType>
</xss:element>
```

```

    </xs:element>
<xs:element name="ciljevi">
    <xs:complexType>
        <xs:sequence>
            <xs:element name="ocjenaJeVazna">
                <xs:simpleType>
                    <xs:restriction base="xs:string">
                        <xs:enumeration value="slazemSe"/>
                        <xs:enumeration value="neodlucan"/>
                        <xs:enumeration value="neSlazemSe"/>
                    </xs:restriction>
                </xs:simpleType>
            </xs:element>
        </xs:sequence>
    </xs:complexType>
</xs:element>
<xs:element name="aktivnosti">
    <xs:complexType>
        <xs:sequence>
            <xs:element name="uTokuDana">
                <xs:simpleType>
                    <xs:restriction base="xs:string">
                        <xs:enumeration value="do1sat"/>
                        <xs:enumeration value="od2do3sata"/>
                        <xs:enumeration value="od3do5sati"/>
                        <xs:enumeration value="viseod5sati"/>
                    </xs:restriction>
                </xs:simpleType>
            </xs:element>
        </xs:sequence>
    </xs:complexType>
</xs:element>
<xs:element name="najviseKoristim">
    <xs:simpleType>
        <xs:restriction base="xs:string">
            <xs:enumeration value="knjiguProfesora"/>
            <xs:enumeration value="skripteDrugih"/>
            <xs:enumeration value="biljeske"/>
            <xs:enumeration value="sveIzvore"/>
        </xs:restriction>
    </xs:simpleType>
</xs:element>
<xs:element name="predavanjaPohadjam">
    <xs:simpleType>
        <xs:restriction base="xs:string">
            <xs:enumeration value="redovno"/>
            <xs:enumeration value="uglavnomRedovno"/>
            <xs:enumeration value="povremeno"/>
            <xs:enumeration value="rijetko"/>
            <xs:enumeration value="nikad"/>
        </xs:restriction>
    </xs:simpleType>
</xs:element>
<xs:element name="izlazimNaKolokvijume">
    <xs:simpleType>
        <xs:restriction base="xs:string">
            <xs:enumeration value="uvijek"/>
            <xs:enumeration value="uglavnom"/>

```

```

            <xs:enumeration value="neIzlazim"/>
        </xs:restriction>
    </xs:simpleType>
</xs:element>
<xs:element name="vjezbePohadjam">
    <xs:simpleType>
        <xs:restriction base="xs:string">
            <xs:enumeration value="redovno"/>
            <xs:enumeration value="uglavnomRedovno"/>
            <xs:enumeration value="povremeno"/>
            <xs:enumeration value="rijetko"/>
            <xs:enumeration value="nikad"/>
        </xs:restriction>
    </xs:simpleType>
</xs:element>
</xs:sequence>
</xs:complexType>
</xs:element>
<xs:element name="ocjene">
    <xs:complexType>
        <xs:sequence>
            <xs:element name="predavanja">
                <xs:annotation>
                    <xs:documentation>1: kvalitetna i korisna, mogu  
saznati sve o predmetu; 2: uglavnom su dobro  
pripremljena i korisna; 3: mala je korist od  
predavanja; 4: nepotrebna su i nekorisna,  
uglavnom ucim samostalno.razumijem nastavni predmet; 2: produzetak  
predavanja; 3: gubljenje vremena, bolje je  
samostalno učiti; 4: zastarjela i potpuno  
prevazidjena.

```

```

<xs:documentation>1: dobri i korisni za moju  

    buducu profesiju; 2: dobri su ali ima i  

    nepotrebnih predmeta; 3: programi su uglavnom  

    zastarjeli, ne idu u korak sa praksom; 4:  

    programi su uglavnom teorija, ne vjerujem da ce  

    mi koristiti u radu.  

</xs:documentation>  

</xs:annotation>  

<xs:simpleType>  

    <xs:restriction base="xs:int">  

        <xs:minInclusive value="1"/>  

        <xs:maxInclusive value="4"/>  

    </xs:restriction>  

</xs:simpleType>  

</xs:element>  

<xs:element name="nastavnici">  

    <xs:annotation>  

        <xs:documentation>1: vecina redovno i odgovorno  

            izvrsavaju svoje obaveze; 2: neki od njih  

            skracuju casove i upucuju na samostalni rad; 3:  

            neki nastavnici uopste ne drze nastavu, samo  

            organizuju povremene konsultacije; 4: vecina  

            nastavnika ne drzi nastavu.  

        </xs:documentation>  

    </xs:annotation>  

    <xs:simpleType>  

        <xs:restriction base="xs:int">  

            <xs:minInclusive value="1"/>  

            <xs:maxInclusive value="4"/>  

        </xs:restriction>  

    </xs:simpleType>  

</xs:element>  

<xs:element name="ocjenjivanje">  

    <xs:annotation>  

        <xs:documentation>1: pravedno i uvijek obuhvata  

            nauceno; 2: uglavnom je pravedno ali zavisi od  

            sreće; 3: pitanja na ispitima cesto ne prate  

            program; 4: potpuno je nepravedno i zasnovano  

            na dobrom raspolozenju.  

        </xs:documentation>  

    </xs:annotation>  

    <xs:simpleType>  

        <xs:restriction base="xs:int">  

            <xs:maxInclusive value="4"/>  

            <xs:minInclusive value="1"/>  

        </xs:restriction>  

    </xs:simpleType>  

</xs:element>  

</xs:sequence>  

</xs:complexType>  

</xs:element>  

</xs:sequence>  

</xs:complexType>  

</xs:element>  

</xs:schema>

```



## Literatura

- Apple, M. W. (1997). *Postmodernizam, obrazovanje, moć i ekonomija*. London.
- Apté, C., & Weiss, S. (1997). Data Mining with Decision Trees and Decision Rules. *Future Generation Computer Systems*, 13, 197-210. Elsevier, Amsterdam.
- Australian Association of Graduate Employers (AAGE) (1993). *National Survey of Graduate Employers*. Sydney, Australia: AAGE.
- Association of Graduate Recruiters (AGR) (1995). *Skills for Graduates in the 21st Century*. Cambridge: AGR.
- Baker, R. S. J. d., & 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.
- Biesta, G.J.J. (2009). Good education in an age of measurement: On the need to reconnect with the question of purpose in education. *Educational Assessment, Evaluation and Accountability*, 21(1), 33-46.
- Biesta, G.J.J. (2010). Learner, student, speaker. Why it matters how we call those we teach. *Educational Philosophy and Theory*, 42(4), 540-552.
- Biesta, G.J.J. (2011). The ignorant citizen: Mouffe, Rancière, and the subject of democratic education. *Studies in Philosophy and Education*, 30(2), 141-153.
- Boticario, J. G. and Santos, O. C. Issues in Developing Adaptive Learning Management Systems for Higher Education Institutions. Proceedings of Adaptive Hypermedia. Dublin, Ireland, 2006.  
<http://hdl.handle.net/1820/750>
- Boticario, Jesus G., and Olga C. Santos. An Open IMS-Based User Modelling Approach for Developing Adaptive Learning Management Systems. *Journal of Interactive Media in Education* 2007(1).  
<http://doi.org/10.5334/2007-2>
- Branković, D. (2009). *Definisanje kompetencija nastavnika razredno-predmetne nastave*. Nova škola, br. 7.
- Breiman, L., Friedman, J.H., Olshen, R.A., & Stone, C.J. (1984). *Classification and Regression Trees*. Chapman & Hall, New York.
- Business/Higher Education Round Table (BHERT) (1992). Educating for Excellence. Commissioned Report No. 2 Camberwell: BHERT.
- Bussing, A. (2002). *Motivation and satisfaction*. In A, Sorge (ed). Organization. Thomson Learning, London.

- Candy, P., Crebert, G. and O'Leary, J. (1994). *Developing lifelong learners through undergraduate education*. NBEET. AGPS, Canberra.
- Chati, Mohamed Amine, Klamma, Ralf, Quix, Christoph, Kensche, David. LM-DTM: An Environment for XML-Based, LIP/PAPI-Compliant Deployment, Transformation and Matching of Learner Models. *Fifth IEEE International Conference on Advanced Learning Technologies (ICALT)*, 2005. pp. 567-569.
- Commission Of The European Communities (2008). *Improving competences for the 21st Century: An Agenda for European Cooperation on Schools*. [http://ec.europa.eu/education/school21/sec2177\\_en.pdf](http://ec.europa.eu/education/school21/sec2177_en.pdf).
- Ćućilović, M. (2006). Znanje kao privredni resurs. *Zbornik radova Tehnološko obrazovanje u Srbiji*. Čačak, Srbija.
- Deakin Crick, R., i Yu, G. (2008). The Effective Lifelong Learning Inventory (ELLl): is it valid and reliable as a measurement tool? *Education Research*, 50(4), 387–402.
- Dewey, J. (1907). The School and the Life of the Child, Chapter 2 in *The School and Society*. University of Chicago Press, Chicago, str. 51.
- Dixit, A. K. (1996). *The making of economic policy: A transaction-cost politics perspective*. MIT Press, Cambridge, MA, USA.
- Dunham, M. (2003). *Data Mining: Introductory and Advanced Topics*. Prentice Hall, New York.
- EduPerson Object Klass Specification* (200604), Internet2 Middleware Architecture Committee for Education, Directory Working Group (MACE-Dir), 2006, Specifikacija dostupna na <http://www.nmi-edit.org/eduPerson/internet2-mace-dir-eduperson-200406.html>.
- Ehrlenspiel, K. (1997). *Knowledge - Explosion and its consequences*. Proceedings of ICED 97, Tampera.
- ETUCE (European Trade Union Committee for Education) (2008). *Teacher Education in Europe*. An ETUCE Policy Paper. Brussels.
- European Commission (2007). *Communication from the Commission to the European Parliament and Council: Improving the Quality of Teacher Education*. COM (2007) 392 final. Brussels.
- European Commission (2010). *Developing coherent and system-wide induction programmes for beginning teachers: a handbook for policymakers*. European Commission Staff Working Document 538 final. Brussels.
- European Commission (2011a). Literature review: *Teachers' core competences: requirements and development*. Author: Francesca Caena. Brussels.
- European Commission (2011b). Lirerature review: *Quality in teachers' continuing professional development*. Author: Francesca Caena. Brussels.
- European Commission (2012a). *Rethinking Education: Investing in skills for better socio-economic outcomes*. COM (2012) 669/3. Brussels.
- European Commission (2012b). *Assessment of Key Competences in initial education and training: Policy Guidance*. Strasbourg, 20.11.2012. SWD (2012) 371 final.
- European Commission (2012c). *Supporting the Teaching Professions for Better Learning Outcomes*. Strasbourg, 20.11.2012. SWD (2012) 374 final.

- European Commission: Education and Culture (2005). *Common European Principles for Teacher Competences and Qualifications*.  
[http://ec.europa.eu/education/policies/2010/doc/principles\\_en.pdf](http://ec.europa.eu/education/policies/2010/doc/principles_en.pdf).
- European Commission: Education and Culture (2008), *The European Qualifications Framework for Lifelong Learning (EQF)*.  
[http://ec.europa.eu/dgs/education\\_culture/publ/pdf/eqf/broch\\_en.pdf](http://ec.europa.eu/dgs/education_culture/publ/pdf/eqf/broch_en.pdf).
- European Trade Union Committee For Education (2008). *Teacher Education in Europe: An ETUCE Policy Paper*.  
[http://etuce.homestead.com/Publications2008/ETUCE\\_PolicyPaper\\_en\\_web.pdf](http://etuce.homestead.com/Publications2008/ETUCE_PolicyPaper_en_web.pdf) 1
- European Union (2006), *Key Competences for Lifelong Learning: A European Reference Framework*. Brussels.
- European Union (2009). *Council Conclusions of 26 November 2009 on the professional development of teachers and school leaders*. Official Journal 2009/C 302/04, 12.12.2009.
- Europska Komisija/EACEA/Eurydice, 2012. Developing Key Competences at School in Europe: Challenges and Opportunities for Policy. Eurydice Report. Luksemburg: Ured za publikacije Europske unije.
- Feiman-Nemser, S. (2008). Teacher Learning. How do Teachers learn to teach? In Cochran-Smith, M, Feiman-Nemser, S., McIntyre, D. (Eds.). *Handbook of research on Teacher Education. Enduring Questions in Changing Contexts*. Routledge/Taylor & Francis, New York/Abingdon.
- Fielding, R.T. (2000). *Architectural Styles and the Design of Network-Based Software Architectures*. Doctoral dissertation, University of California, Irvine.
- Furlong, J., Barton, L., Miles, S., Whiting, C. i Whitty, G. (2000). *Teacher Education in Transition*. Open University Press, Buckingham.
- Giddens, A. (2003). *Sociologija*. Ekonomski fakultet, Beograd.
- Glasser, W. (1984). *Control Theory*. Harper & Row, New York.
- Gonzalez, J. i Wagenaar, R. (Eds.) (2005). *Tuning Educational Structures in Europe II. Universities' contribution to the Bologna Process*. University of Deusto & University of Groningen.  
<http://tuning.unideusto.org/tuningeu/>
- Hafner, P. (2002). Obrazovanje u funkciji ekonomske efikasnosti preduzeća. Ekonomski teme, XL(3):81-86. Ekonomski fakultet u Nišu.
- Hagger, H. i McIntyre, D. (2006). *Learning teaching from teachers. Realizing the potential of school-based teacher education*. Open University Press, Maidenhead.
- Han, J., & Kamber, M. (2001). *Data Mining – Concepts and Techniques*, Morgan Kaufman Press.
- Hardgrave, B.C., Wilson, R.L., & Kent, K.A. (1994). Predicting Graduate Student Success: A Comparison of Neural Networks and Traditional Techniques. *Computers & Operations Research*, 21, 249-263.
- Hargreaves, A., Earl, L., Moore, S. i Maning, S. (2001). *Learning to Change: Teaching Beyond Subjects and Standards*. Jossey Bass, San Francisco.

- Harvey , L.(1993). Assessment & Evaluation in Higher Education Volume 18, Issue 1
- Hattie, John A. (2008). *Visible Learning: A Synthesis of Over 800 Meta-Analyses Relating to Achievement*. ISBN 0-415-47618-6. Routledge, London.
- Hattie, John A. (2011). *Visible Learning for Teachers: Maximizing Impact on Learning*. ISBN 0-415-69015-3. Routledge, London.
- IMS LIP (2005). *Learner Information Package*. IMS Global Learning Consortium.
- Ingvarson, L. (1998). Professional standards: a challenge for the AATE? *English in Australia*, 122: 31-44.
- Institute of Chartered Accountants in Australia (ICAA), (1994). Chartered Accountants in the 21st Century. Sydney, Australia: ICAA.
- Johnson, L., Adams Becker, S., Estrada, V., and Freeman, A. (2014). *NMC Horizon Report: 2014 K-12 Edition*. The New Media Consortium, Austin, TX, USA.
- Karamouzis, S.T., & Vrettos, A. (2008). An Artificial Neural Network for Predicting Student Graduation Outcomes, *Proceedings of the World Congress on Engineering and Computer Science*. San Francisco, USA.
- Kirkby, R. (2002). *WEKA Explorer User Guide for Version 3-3-4*, University of Waikato.
- Knežević-Florić, O. (2005). *Pedagogija razvoja*. Filozofski fakultet, Novi Sad.
- Kobsa, A., Wahlster, W. (1989). *User Models in Dialog Systems*, Springer-Verlag.
- Kobsa, A., Koenemann, J. i Pohl, W., (2001). Personalized Hypermedia Presentation techniques for Improving Online Customer Relationships. *The Knowledge Engineering Review*, 16(2), str. 111-155.
- Koster, B. and Dengerink, J. J.(2008). Professional standards for teacher educators: how to deal with complexity, ownership and function. Experiences from the Netherlands. *European Journal of Teacher Education*, 31:2, 135-149.
- Kotsiantis, S., Pierrakeas, C., & Pintelas, P. (2004). Predicting students' performance in distance learning using machine learning techniques. *Applied Artificial Intelligence*, 18, 411-426.
- Kovačić, J. Z. (2010). Early Prediction of Student Success: Mining Students Enrolment Data. *Proceedings of Informing Science & IT Education Conference (InSITE)*. Cassino, Italy.
- Lin, J. J., Imbrie, P. K., & Reid, K. J., (2009). Student Retention Modelling: An Evaluation of Different Methods and their Impact on Prediction Results, *Proceedings of the Research in Engineering Education Symposium*. Palm Cove, Australia.
- Lindholm, J., (2002). *Metadata resources – Metadata standards and specifications for describing people and their interests*. Dostupno na <http://www.ukoln.ac.uk>

- Lisbon European Council (2000). *Lisbon European Council 23 and 24 March, Presidency conclusions*.  
[http://www.europarl.eu.int/summits/lis1\\_en.htm](http://www.europarl.eu.int/summits/lis1_en.htm).
- Lončarić, D. i Pejić, P. (2009). Profiliranje učiteljskih kompetencija. *Odgovne znanosti*, 11(2):479-497.
- Long P. & Siemens G. (2011). Penetrating the Fog: Analytics in Learning and Education. *EDUCAUSE Review* 46, 31-40.  
<http://net.educause.edu/ir/library/pdf/ERM1151.pdf>
- Lourens, A., & Smit I.P.J. (2003). Retention: predicting first-year success. *South African Journal of Higher Education*. 17(2), 169-170.
- Maler, E. et al. *Assertions and Protocols for the OASIS Security Assertion Markup Language (SAML)*. OASIS, Septembar 2003. ID dokumenta oasis-sstcsaml-core-1.1. Specifikacija dostupna na <http://www.oasis-open.org/committees/security/>.
- Masters, T. (1995). *Advanced Algorithms for Neural Networks: A C++ Sourcebook*. John Wiley & Sons, New York.
- Milosavljević, M. (2005). *Neural networks*. Faculty of Electrical Engineering, Belgrade.
- Modis, T. (1992). *Predictions - Society's Telltale Signature Reveals the Past and Forecasts the Future*, Simon & Schuster, New York.
- Nagelkerke, N. J. D. (1991). "A Note on a General Definition of the Coefficient of Determination". *Biometrika* 78 (3): 691-2.
- Naik, B., & Ragotthaman, S. (2004). Using Neural Networks to Predict MBA Student Success, *College Student Journal*. 38(1), 143-150.
- National Board of Employment, Education and Training (NBEET), (1992). *Skills Required for Graduates: One test of quality in Australian higher education*. Higher Education Council Commissioned Report No. 20. Canberra, Australia: Australian Government Publishing Service.
- Njavoro, Đ. (2006). *Obrazovanje i tržište rada u procesu globalizacije*. ZSEM, Zagreb.
- OECD (2000), *OECD Science Technology and Industry Outlook 2000*. OECD, Paris, France.
- OECD (2005). *Teachers Matter: Attracting, Developing and Retaining Effective Teachers*. OECD Publications, Paris, France.  
<http://www.oecd.org/edu/teacherpolicy>
- OECD (2009). *Creating Effective Teaching and Learning Environments. First Results from TALIS*. OECD Publications, Paris, France.  
<http://www.oecd.org/dataoecd/17/51/43023606.pdf>
- OECD (2011). *Preparing Teachers and Developing School Leaders for 21st Century - Lessons from around the world (Background Report for the International Summit on the Teaching Profession)*. OECD Publications, Paris France.
- Oladokun, V.O., Adebanjo, A. T., & Charles-Owaba, O.E. (2008). Predicting Students' Academic Performance using Artificial Neural Network, A Case

- Study of an Engineering Course, *The Pacific Journal of Science and Technology*. 9 (1), 72-79.
- Olson, M. (1982). *The rise and decline of nations*, Yale University Pres, New Haven.
- Olsson, T., Ryegård, Å., Apelgren, K. (2010). A Swedish perspective on pedagogical competence, Upsala University.
- Ounnas, A., Liccardi, I., Davis, H.C., Millard, D.E. and White, S.A. (2006). Towards a Semantic Modeling of Learners for Social Networks. *International Workshop on Applications of Semantic Web Technologies for E-Learning (SW-EL)* at the AH2006 Conference, Dublin, Ireland, 2006. <http://eprints.soton.ac.uk/id/eprint/262774>
- Pantić, N. (Ed.). (2008). *Tuning Teacher Education Curricula in the Western Balkans*. Centre for Education Policy, Belgrade, Serbia.  
[http://www.cep.edu.rs/sites/default/files/izdanja/Tuning\\_Teacher\\_Education\\_Western\\_Balkans.pdf](http://www.cep.edu.rs/sites/default/files/izdanja/Tuning_Teacher_Education_Western_Balkans.pdf)
- PAPI (2002). *IEEE P1484.2.1/D8 – PAPI Learner*. Information Technology for Learning, Education, and Training: ISO/IEC JTC1 SC36.
- Piaget, J. (1937). *La construction du reel chez l'enfant*. Delachaux et Niestle, Neuchatel, Switzerland.
- Prokopijević, M. (2005). *Evropska unija: Uvod*. Službeni glasnik, Beograd.
- Radas, S., Mervar A., Švaljek S., Budak J., i Rajh, E. (2002). *Institucije, mehanizmi, mjere i instrumenti financijskih i fiskalnih poticaja znanstvenoistraživačkoj i razvojnoj djelatnosti u funkciji tehnologiskog razvoja s posebnim naglaskom na suradnji znanstvenog i gospodarskog sektora*. Studija Ekonomskog instituta, Zagreb.
- Rado, P. (2001). *Transition in Education*. Open Society Institute, Budapest.
- Ramaswami, M., & R. Bhaskaran, (2010). A CHAID based performance prediction model in educational data mining, *IJCSI International Journal of Computer Science Issues*, 7(1), 10-18.
- Raven, M. S. (1956). Uputstvo za korišćenje Progresivnih matrica u boji. Beograd, Centar za primenjenu psihologiju.
- Reason, R. D. (2003). Student variables that predict retention: Recent research and new developments. *NASPA Journal*, 40(4), 172-191.
- Rodić, N. (2000). Latent structure of success of students graduated at the Faculty of Teacher Education in Sombor, Norma, 6(3), 25-44, *Nastava i vaspitanje*, 50(1), 98-113.
- Romero, C., & Ventura, S. (2007). Educational data mining: A survey from 1995 to 2005. *Expert Systems with Applications*, 33(1), 135-146, doi:10.1016/j.eswa.2006.04.005.
- Romero, C., & Ventura, S. (2011). Educational data mining: a review of the state-of-the-art, *IEEE Trans. Syst. Man Cybernet. C Appl. Rev.*, 40(6), 601-618.
- Romero, C., Ventura, S., Espejo, P. G., & Hervás, C. (2008). Educational Data Mining 2008, *The 1st International Conference on Educational Data Mining*.

- Russell, S.J. & Norvig, P. (2002). *Artificial Intelligence: A Modern Approach*. Prentice Hall, New York.
- Savić, G. (2013). *Upravljanje elektronskim nastavnim kursevima zasnovano na komponentnom modelu i formalnoj reprezentaciji instrukcijskog dizajna*. Doktorska disertacija, Univerzitet u Novom Sadu.
- Scheerens, J. (2007). *Conceptual framework for the development of the PISA 2009 context questionnaires and thematic reports*.
- Sembiring, S., Zarlis, M., Hartama, D., Ramliana, S., & Elvi, W. (2011). Prediction of student academic performance by an application of data mining techniques, *International Conference on Management and Artificial Intelligence IPEDR vol.6*, IACSIT Press. Bali, Indonesia.
- Sengi, M. P., (2003). *Peta Disciplina: Umeće i praksa organizacije koja uči*. Adižes MC, Novi Sad.
- Sergiovanni, T.J. (2000). *The Lifeworld of Leadership: Creating Culture, Community, and Personal Meaning in Our Schools*, San Francisco, Jossey Bass.
- Shulruf, B., Hattie, J., & Tumen, S. (2008). The Predictability of Enrolment and First-Year University Results from Secondary School Performance: The New Zealand National Certificate of Educational Achievement, *Studies in Higher Education*, 33(6), 685-698.
- Shum, S.B. (2012). Our Learning Analytics Are Our Pedagogy. Keynote Presentation at *Expanding Horizons 2012*, Macquarie University.
- Simeunović, V. (2005). *Informatika, Metodologija, Statistika*. Visoka škola unutrašnjih poslova, Banja Luka.
- Simeunović, V.(2009). Obrazovanje u funkciji privrednog razvoja u Republici Srpskoj, Zbornik sa prvog kongresa pedagoga Republike Srpske, Jahorina, 25-27. jun. Naša škola, br. 3-4, str.235-266.
- Simeunović, V. and Preradović, Lj. (2014). Using Data Mining to Predict Success in Studying. *Croatian Journal of Education*, 16(2):491-523.
- Šipka, P. (1981). *A collection of papers from the area of criteria*. Department for Psychology of Military Medical Academy, Belgrade.
- Službeni glasnik BiH, broj 031.
- Službeni glasnik BiH, broj 24/8. *Strateški pravci razvoja obrazovanja u Bosni i Hercegovini sa planom implementacije 2008–2015*.
- Stiglitz, J. E. (1999). *Public policy for a knowledge economy*. Center for Economic Policy Research, London.
- Sulaiman, A., & Mohezar, S. (2006). Student Success Factors: Identifying Key Predictors, *Journal of Education for Business*, 81(6), 328-333.
- Suzić, N. (2005). *Pedagogija za 21. vijek*. TT Centar, Banja Luka.
- The European Parliament And The Council Of The European Union (2006), *Key Competences for Lifelong Learning — A European Reference Framework*.
- TUNING Educational Structures In Europe Workgroup: Education (TUNING 2; 2005), *Tuning educational structures in Europe: Summary of Outcomes – Education*.

- [http://tuning.unideusto.org/tuningeu/images/stories/template/  
Template\\_Education.pdf](http://tuning.unideusto.org/tuningeu/images/stories/template/Template_Education.pdf).
- United Kingdom Government, Department for Education and Skills (2002). *Qualifying to Teach: Professional Standards for Qualified Teacher Status and Requirements for Initial Teacher Training*. Teacher Training Agency, London.
- <http://www.tda.gov.uk/upload/resources/pdf/q/qts-standards-final.pdf>.
- Vallerand, R. J., Pelletier, L. G., Blais, M. R., Briere, N. M., Senecal, C., & Vallieres, E. F. (1992). The Academic Motivation Scale: A measure of intrinsic, extrinsic, and motivation in education. *Educational and Psychological Measurement*, 52, 1003-1017.
- Vandamme, J.-P., Meskens, N., & Superby, J.-F. (2007). Predicting academic performance by data mining methods. *Education Economics*, 15(4), 405-419.
- Vlada RH, Povjerenstvo za izradu Hrvatskoga kvalifikacijskog okvira (2007). *Polazne osnove Hrvatskoga kvalifikacijskog okvira*. [http://www.vlada.hr/hr/content/download/22392/287176/file/  
243-12.pdf](http://www.vlada.hr/hr/content/download/22392/287176/file/243-12.pdf).
- Vlada RS (2009). *Strategija razvoja obrazovanja RS za period 2010-2014*.
- Vukicevic, M., Isljamovic, S., Jovanovic, M., Delibasic, B., & Suknovic, M. (2011). *Application of neural networks for prediction of success*. Faculty of Organisational Sciences, Belgrade.
- Weule, H. (1997). *Die Bedeutung der Produktenentwicklung für den Industriestandort Deutschland*. VDI-EKV-Jahrbuch '97, Düsseldorf.
- Witten, I.H., & Frank, E. (2000). *Data Mining: Practical Machine Learning Tools and Techniques with Java Implementation*. Morgan Kaufmann, San Francisco.
- Woodman, R. (2001). *Investigation of factors that influence student retention and success rate on Open University courses in the East Anglia region*. M.Sc. Dissertation, Sheffield Hallam University, UK.
- World Bank (1998). *Knowledge for development*. WDR, Oxford University Press, New York.
- Zaidah, I., & Daliela, R. (2007). Predicting students' academic performance, comparing artificial neural network, decision tree and linear regression. 21st Annual SAS Malaysia Forum, Kuala Lumpur, Malaysia, pp. 1-6.
- Zavod za školstvo Crne Gore (2008). *Standardi za nastavnička zvanja*.
- ZUOV (2011). *Standardi kompetencija za profesiju nastavnika i njihovog profesionalnog razvoja*. Beograd.

## Web adrese

[aLFanet]	Active Learning for Adaptive Internet. <a href="http://adenu.ia.uned.es/alfanet/">http://adenu.ia.uned.es/alfanet/</a>
[aTutor]	ATutor Learning Management System <a href="http://www.atutor.ca">http://www.atutor.ca</a>
[Canvas]	Canvas Learning Management System <a href="http://www.canvaslms.com">http://www.canvaslms.com</a>
[Chamilo]	Chamilo E-Learning and Collaboration Software <a href="https://chamilo.org/chamilo-lms/">https://chamilo.org/chamilo-lms/</a>
[Claroline]	Claroline Learning Management System <a href="http://claroline.fsm.ac.in">http://claroline.fsm.ac.in</a>
[Dokeos]	Dokeos E-Learning Suite <a href="http://www.dokeos.com">http://www.dokeos.com</a>
[eFront]	Enterprise Learning Management Software <a href="http://www.efrontlearning.net">http://www.efrontlearning.net</a>
[Fedena]	Fedena Pro – School Management Information System <a href="http://www.fedena.com">http://www.fedena.com</a>
[ILIAS]	ILIAS E-Learning <a href="http://www.ilias.de">http://www.ilias.de</a>
[IMSGlobal]	IMS Global Learning Consortium, <a href="http://www.imsglobal.com">http://www.imsglobal.com</a>
[JSON]	JavaScript Object Notation <a href="http://www.json.org">http://www.json.org</a>
[LAMS]	Learning Activity Management System <a href="http://lamsfoundation.org">http://lamsfoundation.org</a>
[LRN]	.LRN <a href="http://dotlrn.org">http://dotlrn.org</a>
[Moodle]	Moodle – Open Source Learning Platform <a href="https://moodle.org">https://moodle.org</a>
[OAuth]	An open protocol to allow secure authorization in a simple and standard method from web, mobile and desktop applications

	<a href="http://oauth.net">http://oauth.net</a>
[OLAT]	Online Learning and Training <a href="http://www.olat.org">http://www.olat.org</a>
[RapidMiner]	RapidMiner 5.0 Manual, Rapid-I GmbH, <a href="http://rapidminer.com">http://rapidminer.com</a>
[Sakai]	Sakai Course Learning Environment <a href="https://sakaiproject.org">https://sakaiproject.org</a>
[SWAD]	Shared Workspace At a Distance <a href="https://openswad.org">https://openswad.org</a>
[Tuning]	Tuning Educational Structures in Europe <a href="http://www.unideusto.org/tuningeu/">http://www.unideusto.org/tuningeu/</a>
[Weka]	Weka 3: Data Mining Software in Java, <a href="http://www.cs.waikato.ac.nz/ml/weka/">http://www.cs.waikato.ac.nz/ml/weka/</a>

## **Biografija**

Vlado Simeunović rođen je 06.02.1962. u Tuzli, Republika Srpska, Bosna i Hercegovina. Diplomirao je 27.07.1985. godine na Vojnoj akademiji kopnene vojske u Beogradu i stekao stručni naziv diplomiranog oficira veze. Magistarsku tezu pod nazivom „Uticaj psihološkog faktora na uspeh u obuci teleprinterista“ odbranio je 27.07.1995. godine na Vojnoj akademiji kopnene vojske u Beogradu, u okviru naučne oblasti Vojna andragogija.

Stalno je zaposlen u Gradskoj upravi Grada Bijeljine. U okviru tog angažmana rukovodio je ili učestvovao u realizaciji većeg broja projekata nacionalnog ili međunarodnog značaja.

U svom istraživačkom radu objavio je preko 30 radova. Među njima ima 7 radova koji neposredno pripadaju oblasti kojom se bavi ova doktorska disertacija, a od toga jedan rad je objavljen u međunarodnom časopisu sa impakt faktorom.

## Ključna dokumentacijska informacija

Redni broj, <b>RBR:</b>	
Identifikacioni broj, <b>IBR:</b>	
Tip dokumentacije, <b>TD:</b>	monografska publikacija
Tip zapisa, <b>TZ:</b>	tekstualni štampani dokument
Vrsta rada, <b>VR:</b>	doktorska disertacija
Autor, <b>AU:</b>	Vlado Simeunović
Mentor, <b>MN:</b>	Branko Milosavljević
Naslov rada, <b>NR:</b>	Informacioni model i softverska podrška za predviđanje uspješnosti studiranja
Jezik publikacije, <b>JP:</b>	srpski
Jezik izvoda, <b>JI:</b>	srpski / engleski
Zemlja publikovanja, <b>ZP:</b>	Srbija
Uže geografsko područje, <b>UGP:</b>	Vojvodina
Godina, <b>GO:</b>	2015
Izdavač, <b>IZ:</b>	autorski reprint
Mesto i adresa, <b>MA:</b>	Novi Sad, Fakultet tehničkih nauka, Trg Dositeja Obradovića 6
Fizički opis rada, <b>FO:</b>	5 / 114 / 153 / 8 / 28 / 0 / 1
Naučna oblast, <b>NO:</b>	Elektrotehničko i računarsko inženjerstvo
Naučna disciplina, <b>ND:</b>	Primenjene računarske nauke i informatika
Predmetna odrednica / ključne reči, <b>PO:</b>	tehnološki podržano učenje, istraživanje podataka, predikcija uspešnosti studiranja
<b>UDK</b>	
Čuva se, <b>ČU:</b>	Biblioteka Fakulteta tehničkih nauka, Trg Dositeja Obradovića 6, Novi Sad
Važna napomena, <b>VN:</b>	
Izvod, <b>IZ:</b>	U radu je prikazan model podataka koji omogućava predviđanje uspješnosti studiranja na visokoškolskim ustanovama, kao i analizu više tehnika predikcije. Pored toga, prikazuje i prototipsku implementaciju informacionog sistema za upravljanje obrazovnim procesom koji omogućava korišćenje predikcije u realnim informacionim sistemima.
Datum prihvatanja teme, <b>DP:</b>	
Datum odbrane, <b>DO:</b>	
Članovi komisije, <b>KO:</b>	
predsednik	dr Mirjana Segedinac, red. prof, PMF Novi Sad
član	dr Milan Milosavljević, red. prof, ETF Beograd
član	dr Milan Segedinac, assist. prof, FTN Novi Sad
član	dr Goran Savić, docent, FTN Novi Sad
mentor	dr Branko Milosavljević, red. prof, FTN Novi Sad
	Potpis mentora

## Key Words Documentation

Accession number, ANO:	
Identification number, INO:	
Document type, DT:	monographic publication
Type of record, TR:	textual material
Contents code, CC:	PhD thesis
Author, AU:	Vlado Simeunović
Mentor, MN:	Branko Milosavljević
Title, TI:	An Information Model and Software Support for Prediction of Student Success in Studying
Language of text, LT:	serbian
Language of abstract, LA:	serbian / english
Country of publication, CP:	Serbia
Locality of publication, LP:	Vojvodina
Publication year, PY:	2015
Publisher, PB:	author's reprint
Publication place, PP:	Novi Sad, Faculty of Technical Sciences, Trg Dositeja Obradovića 6
Physical description, PD:	5 / 114 / 153 / 8 / 28 / 0 / 1
Scientific field, SF:	Electrical Engineering and Computer Science
Scientific discipline, ND:	Applied Computer Science and Informatics
Subject / Keywords, S/KW:	technology enhanced learning, data mining, studying success prediction
UDC	
Holding data, HD:	Library of the Faculty of Technical Sciences, Trg Dositeja Obradovića 6, Novi Sad
Note, N:	
Abstract, AB:	The paper presents a data model that facilitates prediction of students success in studying, as well as a review of prediction techniques. It also presents a prototype implementation of a learning management information system that enables the use of prediction of success in studying and represents a real-world use case.
Accepted by sci. board on, ASB:	
Defended on, DE:	
Defense board, DB:	
president	Mirjana Segedinac, PhD, full prof., PMF Novi Sad
member	Milan Milosavljević, PhD, full prof., ETF Belgrade
member	Milan Segedinac, PhD, assist. prof., FTN Novi Sad
member	Goran Savić, PhD, assist. prof., FTN Novi Sad
mentor	Branko Milosavljević, PhD, full prof., FTN Novi Sad
	Mentor's signature