

Ontologija analitika učenja u visokom obrazovanju

Medenjak, Karla

Master's thesis / Diplomski rad

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Organization and Informatics / Sveučilište u Zagrebu, Fakultet organizacije i informatike**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:211:675655>

Rights / Prava: [Attribution 3.0 Unported](#)/[Imenovanje 3.0](#)

Download date / Datum preuzimanja: **2024-07-23**



Repository / Repozitorij:

[Faculty of Organization and Informatics - Digital Repository](#)



**SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN**

Karla Medenjak

**ONTOLOGIJA ANALITIKA UČENJA U
VISOKOM OBRAZOVANJU**

DIPLOMSKI RAD

Varaždin, 2023.

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ž D I N

Karla Medenjak

Matični broj: 49560/21–R

Studij: *Baze podataka i baze znanja*

ONTOLOGIJA ANALITIKA UČENJA U VISOKOM OBRAZOVANJU

DIPLOMSKI RAD

Mentor/Mentorica:

Prof. dr. sc. Sandra Lovrenčić

Varaždin, rujan 2023.

Karla Medenjak

Izjava o izvornosti

Izjavljujem da je moj završni/diplomski rad izvorni rezultat mojeg rada te da se u izradi istoga nisam koristio drugim izvorima osim onima koji su u njemu navedeni. Za izradu rada su korištene etički prikladne i prihvatljive metode i tehnike rada.

Autor/Autorica potvrdio/potvrdila prihvaćanjem odredbi u sustavu FOI-radovi

Sažetak

Tema ovog diplomskog rada je *Ontologija analitika učenja u visokom obrazovanju*. Kao što sam naziv govori, fokus diplomskog rada je pojam *analitike učenja* i ontologija kojom će analitika učenja biti prikazana kako bi se razradila terminologija i kako bi se bolje shvatilo područje. Cilj je istražiti i proanalizirati metode, svrhu, korisnike, alat i pokazatelje analitike učenja kao mjere kolekcije analize i izvještavanja o podacima o onima koji uče, odnosno studentima u ovom primjeru, i njihovim kontekstima s ciljem razumijevanja i optimizacije učenja unutar okruženja u kojima se učenje odvija. Potrebno je upotrijebiti neke metode da bi se mogli razumjeti i evaluirati podaci tijekom nekog vremena. Teorijsko-metodološka polazišta vezana su uz mjerenja i analizu određenih pokazatelja o studentima koji su vezani uz procese učenja sa svrhom da se taj proces bolje razumije te da se može poboljšati. Nakon obrade teorijskog dijela napravljena je ontologija koja povezuje sve navedene pojmove u jednu cjelinu. Ontologijom se želi postići da se elementi analitike učenja prikupe te stave na jedno mjesto kako bi bilo kreirano općenito znanje vezano uz taj pojam.

Ključne riječi: *analitika učenja, ontologija, visoko obrazovanje, metode analitike učenja, alati analitike učenja, sudionici*

Sadržaj

Sadržaj.....	iii
1. Uvod.....	1
2. Metode i tehnike rada	2
3. Analitika učenja.....	3
4. Metode analitika učenja	4
4.1. Deskriptivna analitika	4
4.1.1. Poslovna inteligencija.....	5
4.2. Dijagnostička analitika.....	5
4.3. Prediktivna analitika	6
4.3.1. Stablo odlučivanja	7
4.3.2. Regresijske tehnike	8
4.3.3. Neuronske mreže.....	9
4.3.4. Rudarenje podataka.....	9
4.4. Preskriptivna analitika	10
4.4.1. Umjetna inteligencija	10
5. Analitika učenja u visokom obrazovanju.....	13
5.1. Svrha analitike učenja u visokom obrazovanju	13
5.1.1. Funkcionalna taksonomija analitike učenja.....	13
5.1.1.1. Pristup ponašanja pri učenju	13
5.1.1.2. Ocjena socijalnog učenja.....	14
5.1.1.3. Pобоljšanje materijala i alata za učenje.....	14
5.1.1.4. Individualizirano učenje	15
5.1.1.5. Predikcija učinka studenta.....	15
5.1.1.6. Vizualizacija aktivnosti učenja	16
5.2. Koraci procesa unapređenja	18
5.2.1. Priprema	18

5.2.1.1. Organiziranje zajedničkog rada	18
5.2.1.2. Izgradanja pismenosti za procjenu	19
5.2.2. Proučavanje	19
5.2.2.1. Izrada pregleda podataka.....	19
5.2.2.2. Kopanje po studentskim podacima	19
5.2.2.3. Uputa za ispitivanje	20
5.2.3. Djelovanje	20
5.2.3.1. Izrada akcijskog plana.....	20
5.2.3.2. Planiranje za procjenu napretka	20
5.2.3.3. Akcija i procjena	20
6. Korisnici analitike učenja u visokom obrazovanju.....	21
7. Alati i pokazatelji za analitiku učenja u visokom obrazovanju	22
8. Ontologija	23
8.1. Povijest ontologije	23
8.2. Ontologije za potporu u učenju i poučavanju.....	24
8.3. Alat <i>Protégé</i>	24
9. Izrada ontologije	25
9.1. Entiteti.....	25
9.1.1. Klase.....	25
9.1.1.1. Hijerarhija klasa.....	25
9.1.2. Opisi klasa	28
9.2. Objektna svojstva.....	32
9.2.1. Hijerarhija objektnih svojstava	32
9.2.2. Opisi objektnih svojstava.....	33
9.2.3. Karakteristike objektnih svojstava.....	35
9.3. Podatkovna svojstva	36
9.4. Instance	38
9.5. Upiti	41
10. Zaključak	49

Popis literature	50
Popis slika	53
Popis tablica	54

1. Uvod

Pojam ontologije odnosi se na znanje, spoznaje i definiranje nečega onakvim kakvo to nešto i jest. [19] Za svako biće, pojam, objekt, može se napraviti ontologija, pa se isto tako može napraviti i za analitiku učenja u visokom obrazovanju. Analitika učenja, je sama po sebi, dosta široki pojam. Ona se odnosi na razne metode, taksonomije, korake unapređenja i to sve s ciljem poboljšanja i unapređenja učenja i poučavanja.

Ontologija, kao takva, koristi se u ovom radu kako bi se analitika učenja, na pregledan način mogla prikazati i povezati. Unutar rada, definirani su glavni pojmovi, poput ontologije, analitike učenja, metoda koje se koriste kod primjene analitike učenja, taksonomije, koraci i tako dalje. No, da bi se sve te metode mogle koristiti, potrebno je imati sudionike i alate koji će moći stvarati i obrađivati podatke. Korisnici su studenti, na koje je stavljen dosta veliki fokus, jer studenti su, sami po sebi ključni za vlastiti uspjeh pa se tako mjerenjem njihove aktivnosti, interakcija, ponašanja, ostvarenih bodova, i tako dalje, može dobiti dobar uvid u to koliko student kao individua pridonosi svom uspjehu te koliko studenti općenito imaju utjecaj na prolaznost nekog kolegija. Osim studenata, nastavnici isto tako pridonose prolaznosti. Oni mogu imati utjecaj na prolaznost, ovisno o kvaliteti materijala koje daju, kvaliteti poučavanja, voljnosti pružanja potpore i dodatnih informacija.

Prema tome, analitika učenja, zapravo služi, za detektiranje rizika, nedostataka i problema kod učenja i poučavanja, kako bi se oni mogli sanirati prije ili nakon što se jave unutar obrazovanja. Nakon prikupljenih podataka i informacija, napravljena je ontologija analitike učenja u visokom obrazovanju. Unutar ontologije definirane su metode, taksonomija, koraci unapređenja, sudionici, alati, podaci i problemi. Isto tako, definirana su objektna i podatkovna svojstva te individue kako bi se svaki aspekt ontologije jasnije definirao.

2. Metode i tehnike rada

Za svrhu izrade ovog diplomskog rada, korišten je standardni tekstualni editor, odnosno *Word* i alat iza izradu ontologije, odnosno *Protege*. Način, odnosno metode na koji su prikupljane informacije je putem internetskog preglednika te dio putem alata *Protege*. Korišteni su razni znanstveni članci kako bi tema bila što detaljnije razrađena i opisana. Isto tako, razvijena je ontologija analitike učenja unutar alata kako bi se cijeli rad mogao sumirati i iz njega izvući ono najbitnije. Nakon razvijene ontologije postavljeni su upiti koji su vezani uz metode i kvalitetu učenja u viskom obrazovanu, kako bi se pokazala mogućnost njezine uporabe.

3. Analitika učenja

Analitika učenja (engl. Learning Analytics), kao proces, odnosi se na prikupljanje podataka te njihovu analizu u svrhu praćenja učenika i studenta unutar organizacije u kojoj se obrazuju. U užem smislu, svrha analitike učenja je pomaganje u razumijevanju učenja i poučavanja i samog okruženja učenja te otkrivanje načina kojima se mogu poboljšati ishodi učenja. U širem smislu, pojam analitike učenja iznimno je opsežan, te kako bi se mogao shvatiti svaki aspekt tog pojma potrebno je proučiti sam njegov nastanak, odnosno kada se on počeo koristiti i iz kojeg razloga. [1]

Od početaka učenja, javlja se potreba za određenom evaluacijom učenja kako bi učitelji, odnosno nastavnici, mogli poboljšati svoje metode učenja te materijale koje daju svojim učenicima/studentima. 1930. godine dolazi do selekcije određenih individua, odnosno studenata koji su bili izloženi naprednom testiranju kako bi se mogli definirati i postići određeni zaključci vezani uz kompetencije i nedostatke u učenju za svakog individualnog učitelja. Također, postojale su određene tradicionalne metode evaluacije učinka učenja i to tako da su prikupljeni kvantitativni podaci studenata, to jest, njihova postignuća i izvedbe kod određenih predmeta kako bi, po potrebi, došlo do određenih promjena. S vremenom, osim kvantitativnih podataka, počeli su se koristiti podaci koji su se odnosili na učestalosti ponašanja studenta, što bi moglo dovesti do zaključka da ocjene ili neki drugi kvantitativni parametri nisu bili dovoljni da bi se mogla dobiti ispravna slika, odnosno analitika nekog učenja. [2]

Godine 2011. došlo je do uspostave prvog društva za istraživanje analitike učenja, *The Society for Learning Analytics Research (SoLAR)* koja se sastoji od međunarodne mreže istraživača koji su se posvetili unapređivanju učenja pomoću analize. Unazad nekoliko godina svrha istraživanja analitike učenja temelji se na povratnim informacijama studenata, kako bi se pomoću njih moglo predvidjeti ponašanje studenata, unaprijediti njihovo samostalno učenje, poticati određene strategije učenja te donositi ispravne odluke vezane za procese učenja. S obzirom na sve više istraživača koji su se posvetili analitici učenja u obrazovanju, dolazi do sve pozitivnijih rezultata kod učenja, odnosno počele su se prihvaćati i primjenjivati metode analitike učenja. No, bez obzira na to, javljaju se i određeni problemi koji su vezani uz etičko ponašanje. [2]

4. Metode analitika učenja

Unutar područja analitike učenja postoje ukupno četiri metode koje se bave prikupljanjem i analizom podataka od učenika. Dakle, nazivi tih metoda su deskriptivna analitika, dijagnostička analitika, prediktivna analitika i preskriptivna analitika. [1] Svaka od tih metoda bit će detaljnije razrađena.

4.1. Deskriptivna analitika

Deskriptivna se analitika temelji na poslovnoj inteligenciji, odnosno poslovnim metrikama i pričama te je podloga za razne analitičke strategije, odnosno temelji se na pretraživanju i sumiranju prikupljenih podataka kako bi se mogla identificirati određena značenja ili određeni uzorci [1].

Može se postaviti pitanje, zašto je deskriptivna analitika važna za analitiku učenja. Odgovor na to pitanje iznimno je jednostavan. Zato što se deskriptivna analitika može tretirati kao reflektivna analiza podataka koji pružaju pregled u ponašanja i performanse učenika koji koriste određene materijale za učenje te se nalaze u nekoj okolini učenja. Isto tako, važnost tih podataka može se očitati kod mogućeg unapređenja daljnjeg učenja od strane učenika i učitelja. [3]

Da bi se podaci mogli prikupiti i obraditi, potrebno je koristiti tehniku agregacije podataka i rudarenja podataka. Agregacija podataka ima svrhu pohranjivanja podataka te zatim njihovog sortiranja kako bi se mogli kreirati skupovi podataka koji bi mogli poslužiti za detaljniju analizu pomoću tehnike rudarenja podataka. Shodno tome, nakon agregacije podataka dolazi do rudarenja novog skupa podataka koje se temelji na pretraživanju s ciljem identifikacije značenja istih te kreiranja uzoraka. Nakon toga, dolazi do analize identificiranih uzoraka kako bi se mogli otkriti specifični načini kako učenici imaju interakciju sa sadržajem učenja te s okolinom učenja. [3]

Osim što se prikupljaju podaci o ponašanju i uspješnosti učenika, dolazi i do prikupljanja i analize podataka vezanih uz performanse kvalitete učenja i uspjeha od strane nastavnika. Analizom i uvidom u navedene podatke može se doći do određenih informacija o tome kako neki nastavnik može unaprijediti svoje poučavanje. Bitno je naglasiti da kod deskriptivne analitike ne dolazi do predikcija za performanse učitelja u budućnosti, to jest, mogu se dati određeni savjeti što se može poboljšati, ali ne i koliko će to biti uspješno. [3]

Načini na koje se, unutar analitike učenja, deskriptivna analitika može koristiti je kao praćenje zadataka i njihova validacija, broj upisa na određeni predmet ili kolegij te stopa pohađanja istog, praćenje broja pristupanja određenim materijalima i resursima na kolegiju,

usporedba rezultata ankete vezane uz kolegij, analiza vremenskog opterećenja s kako bi se navedeni kolegij završio i tako dalje. [3]

Postoje brojne prednosti deskriptivne analitike, a neke od njih se očituju u lakim i brzim izvješćima koja pokazuju performanse i željene ciljeve, identifikacija mogućih nedostataka prije nego što oni postaju problemi, identifikacija učenika koji možda zahtijevaju više podrške od strane učitelja te identificiranje uspješnih učenika kako bi se dobile pozitivne povratne informacije ili određeni dodatni resursi. [3]

4.1.1. Poslovna inteligencija

Unutar područja deskriptivne analitike javlja se i pojam poslovne inteligencije koja je u isto vrijeme spoj poslovne analitike, rudarenja podataka, vizualizacije podataka i alata koji omogućavaju raznim organizacijama donošenje odluka koje su vođene podacima. Upravo je iz tog razloga pojam poslovne inteligencije relevantan za analitiku učenja, jer i ona, kao i organizacije, donosi odluke temeljene na podacima. [1]

Ako postoji pregled podataka koji obuhvaća sve glavne aspekte koje koristi određena organizacija, u ovom primjeru školstvo, i ako se ti podaci koriste za poticanje određenih korisnih poboljšanja i uklanjanje neučinkovitosti te se stvara težnja za konstantnim promjenama i napretkom, onda se može zaključiti da se poslovna inteligencija ispravno koristi i u dobre svrhe. [4]

4.2. Dijagnostička analitika

Druga metoda koja se koristi kod analitike učenja naziva se dijagnostička analitika. Kao što i sam naziv govori, dijagnostička se analitika ne temelji na onome što se dogodilo u prošlosti, nego se temelji na razlozima zašto je do nečega došlo, odnosno radi se dijagnoza. Svrha navedene analitike je da identificira neku neučinkovitost i da odredi problem zbog kojeg je došlo do nepoželjnog rezultata kako bi se moglo dalje posvetiti napretku tog specifičnog dijela. [1]

Može se dogoditi da je veliki broj studenata pao kolegij, pa se shodno tome, mora otkriti koji je bio uzrok tom padu. Ako je bio uzrok to što većina studenata nije dobro organizirala učenje, onda je potrebno to identificirati i težiti ka poboljšanju i pronalasku rješenja za navedeni problem.

Načini na koje se može napraviti dijagnostička analitika jesu manualno, odnosno ručno, pomoću raznih algoritama ili uz korištenje programskih alata. Ovdje postoje dodatna dva pojma, a to su korelacija i uzročnost. Pojam korelacije se koristi kod dva ili više parametara čija su kretanja povezana. Može se govoriti o pozitivnoj korelaciji, koja djeluje tako da ako se

jedan parametar kreće pozitivno, tada se i drugi isto tako kreće u pozitivnom smjeru. Primjer toga je ako nastavnik neki kolegij dobro objasni i daje dobre nastavne materijale, tada će biti i veća uspješnost studenata, odnosno bit će veća prolaznost tog kolegija. Ovdje se vidi da ako se parametar kvalitete sadržaja kolegija povećava, da se tada povećava i parametar prolaznosti istog kolegija. [5]

Nadalje, može se definirati i negativna korelacija kod koje ako se jedan parametar kreće u pozitivnom smjeru, tada će se drugi parametar kretati u negativnom smjeru. Primjer toga može biti, da ako nastavnik daje previše materijala za učiti, tada može doći do zbunjenosti kod studenata jer neće znati koje materijale točno koristiti. Na taj način može doći do smanjene prolaznosti kolegija. Bitno je napomenuti da ako su dva parametra korelacijska da to ne mora značiti da je jedan parametar uzrok drugom. [5]

Da bi se uzročnost među dva parametra mogla točno odrediti, potrebno je provesti određene eksperimente unutar kontroliranog okruženja radi dobivanja najtočnijih informacija. Dobivanje uzročnosti smatra se idealnim slučajem za uvid u problem, ali ako organizacija nema mogućnost točnog određivanja uzročnosti, tada i korelacija parametara može biti dovoljno dobra da bi se zaključilo zašto je došlo do nekog ishoda. [5]

Kod varijabla, odnosno parametara nekad postoje odnosi koji se lako otkrivaju, ali nekad dođe do problema te je potrebna detaljnija analiza odnosa među njima. Takva detaljnija analiza naziva se dijagnostička regresijska analiza. Ako se radi regresijska analiza između dviju varijabli, tada ona naziva jednostruka linearna regresija, a ako se radi na tri ili više, onda se naziva višestruka linearna regresija. [5]

4.3. Prediktivna analitika

Prediktivna analitika, treća je metoda koja se koristi kod analitike učenja. Ona je zapravo statistička metoda koja objedinjuje algoritme i strojno učenje kako bi se mogli odrediti trendovi kod podataka i kako bi se predvidjela buduća ponašanja. U odnosu na prethodne dvije metode, vidljivo je da se prediktivna analitika fokusira na ono što bi moglo biti, odnosno njome se pokušava predvidjeti mogući ishod u budućnosti. [1]

Dakle, prediktivna analitika može koristiti prošle i sadašnje podatke kako bi pružila uvid u ono što bi se moglo dogoditi u budućnosti. Samim time, dolazi do predviđanja mogućih prilika i rizika koji se mogu pojaviti kod uvođenja određenih promjena te se prema tome mogu dodatno unaprijediti budućni koraci u novim inicijativama kod analitike učenja. [6]

Postoje brojne prednosti kod korištenja prediktivne analitike. Prva je da se mogu napraviti personalizirani sadržaji prema potrebama pojedinaca ovisno o tome kolike su razlike i sposobnosti među njima. Prema tome, mogu se ponuditi određeni resursi ili materijali da se podupiru potrebe individua. Na primjer, ako student želi znati nešto više o nekoj temi, nastavnik

ga može uputiti na dodatne materijale i znanja kako bi mogao unaprijediti svoje sposobnosti. [6]

Druga prednost je da se može zadržati određeni talent kod individua, tako da se prati razumijevanje i napredak te osobe te da se predviđa što bi bilo potrebno, odnosno koji su resursi potrebni da bi ta osoba mogla još više napredovati. Spoznavanjem vještina studenata može se predvidjeti buduća obuka istih. [6]

Treći aspekt je da treba podržavati one studente koji možda zaostaju s gradivom tako dugo dok ne postignu svoj potencijal. Način na koji se to može učiniti je da im se pruži podrška u obliku dodatnih pojašnjenja i materijala i sve to prije nego ih njihov učinak izloži nekom riziku. Primjer toga može biti da student zatraži konzultacije na kojima nastavnik može dodatno pojasniti određeni dio gradiva ili dati neke savjete, ali to je potrebno učiniti prije negoli student padne kolegij, a s ciljem da ga uspješno položi. Posljednja prednost je ta da se može povremeno javiti pojednostavljeno izvješćivanje kojim se daju neke povratne informacije je li i dalje potreban neki oblik prediktivnog predviđanja. [6]

Prediktivna analitika složenija je od prethodne dvije i to zato što ona ne koristi prikupljanje, sortiranje i razvrstavanje podataka nego se odnosi na modele koji se temelje na donošenju odluka, to jest, zaključaka na temelju podataka. Upravo iz tog razloga javlja se potreba za algoritmima i strojnim učenjem koji će na temelju prošlih i sadašnjih podataka moći napraviti predikciju budućih. Shodno tome, neki od modela koji se koriste kod prediktivne analitike jesu stablo odlučivanja, regresijske tehnike i neuronske mreže. [6]

4.3.1. Stablo odlučivanja

Stablo odlučivanja jedan je od modela koji se koristi kod prediktivne analitike. Stablo ima strukturu oblika sličnu dijagramu tijekom te se pomoću njega donose odluke temeljene na dobivenim podacima. Sam naziv sugerira da se radi o stablastom obliku, odnosno da se podaci dijele na grane i na listove. [7]

Struktura stabla odlučivanja sastoji se od korijenskog, odnosno glavnog čvora, grana, unutarnjih čvorova i listova. Korijenski čvor, kao što i sam naziv govori, je korijen, to jest početak stabla odlučivanja od kojeg se dalje granaju ostali čvorovi prema određenim uvjetima. Čvor odluke je čvor koji se dobiva kada se korijenski čvor podijeli. Listovi su zapravo završni čvorovi, nakon kojih daljnja podjela više nije moguća. [7]

Primjer, kako bi se stablo odlučivanja moglo koristiti kod analitike učenja, je da se proba napraviti predikcija koja će uzimati podatke od uspješnosti polaganja nekog kolegija prethodnih godina, kako bi se vidjelo koji su aspekti bili ključni te kakva bi prolaznost mogla biti u narednim godinama. Pomoću stabla odlučivanja može se predvidjeti gdje bi mogli postojati određeni problemi kod prolaznosti na kolegiju te se tako može doći do određenog unapređenja od strane nastavnika i studenata.

4.3.2. Regresijske tehnike

Regresijske tehnike treća su metoda kod predikcijske metode. Regresijska metoda zapravo pripada statističkim metodama koje se istražuju odnose među zavisnim i nezavisnim koje se nazivaju prediktori. Samim time, ta je tehnika zadužena za predviđanje i modeliranje vremenskih serija i pronalaženje nekih uzročno-posljedičnih veza među navedenim varijablama. Shodno svemu navedenom, postoje određene prednosti kod korištenja tehnika regresijske analize, a to su da ona ukazuje na značajne odnose između varijabli te pokazuje snagu utjecaja više nezavisnih varijabli na zavisnu. [8]

U primjeru analitike učenja u visokom obrazovanju, to može biti organiziranost studenta i njegovo vrijeme provedeno za učenje i uspješnost prolaznosti nekog kolegija. Kod tehnike regresijske analize moguće je vršiti usporedbu učinka raznih varijabli koje mogu biti mjerene na nekim ljestvicama. [8] Primjer toga mogu biti, dobiveni bodovi na određenom ispitu koji će zatim poslužiti za daljnju analizu i predikciju prolaznosti na idućem roku. Ako su rezultati loši, dolazi se do određenih predikcija te se zahtijevaju neke promjene. [8]

Isto tako, postoji nekoliko vrsta tehnika regresijske analize, a to su linearna regresija, logistička regresija, polinomna regresija, postupna regresija, regresija grebena, LASSO regresija i regresija elastične mreže. Najčešći oblik regresijske tehnike je linearna regresija kod koje postoji zavisna varijabla koja je kontinuirana, dok nezavisna varijabla može biti kontinuirana ili diskretna. Priroda same regresijske linije je linearna zato što, kao što je već spomenuto, linearna regresija uspostavlja odnos između zavisne i jedne ili više nezavisnih varijabli. Oblik linearne regresije se i koristi kod analitike učenja. Nadalje, logistička regresija se najčešće koristi za pronalaženje vjerojatnosti nekog događaja, odnosno hoće li neki događaj rezultirati uspjehom ili neuspjehom. Taj se oblik regresijske metode koristi samo kada je zavisna varijabla binarne prirode, odnosno samo kada je ona točna ili netočna. Polinomna regresija, koristi se kada je snaga zavisne varijable veća od 1 te kada linija koja najbolje odgovara nije ravna nego se odnosi na određenu krivulju. [8]

Postupna se regresija koristi kada postoje više nezavisnih varijabli. Odabir nezavisnih varijabli vrši se automatskim procesima unutar kojih nisu uključene ljudske intervencije. Ona se vrši promatranjem statističkih vrijednosti poput R-kvadrata i t-statistike kojima se pokušava uočiti značajne varijable. Na taj se način, postepeno, dolazi do ispuštanja ili dodavanja kovarijabli na temelju određenog kriterija. Nadalje, regresija grebena se koristi kada se unutar nekog sustava nalaze neovisne varijable koje su visoko korelirane. Cilj regresije grebena je što je više moguće smanjiti grešku. Slično prethodnoj regresiji, LASSO regresija odnosi se na apsolutnu veličinu regresijskih koeficijenata. Prema tome, dolazi do smanjenja varijabilnosti i poboljšavanja točnosti modela linearne regresije. Posljednja vrsta

regresijske tehnike je tehnika elastične mreže koja je zapravo kombinacija regresije grebena i laso regresije. [8]

4.3.3. Neuronske mreže

Neuronske mreže su treća tehnika koja se koristi kod prediktivne analitike. Kod neuronskih mreža postoje tri sloja strukture algoritama, a to su ulazni sloj, skriveni sloj i izlazni sloj. Kao što sam naziv govori, kod ulaznog se sloja unose vrijednosti prošlih podataka u sljedeći sloj. Skriveni sloj je zapravo ključna komponenta kod neuronskih mreža zato što ima složene funkcije koje stvaraju određene prediktore. Unutar skrivenog čvora zapravo postoje čvorovi koji predstavljaju određene matematičke funkcije za modifikaciju ulaznih podataka. Posljednji, odnosno izlazni sloj služi za prikupljanje predviđanja koja su napravljena unutar skrivenog sloja kako bi se moglo doći do završnog sloja, odnosno sloja koji će biti predviđanje modela. [9]

U odnosu na regresijske tehnike, koje rade samo s ulaznim zavisnim i nezavisnim varijablama, neuronske mreže koriste svoje skrivene slojeve kako bi predviđanja bila što točnija. Prednost toga je što se pomoću tih skrivenih čvorova zapravo uči način na koji čovjek može učiti. Iz tog razloga, neuronske mreže mogu dati dovoljno točnu predikciju, pogotovo ako su trenirane na velikom skupu podataka. [9]

Kod analitike učenja u visokom obrazovanju, može se reći da ako se neuronskoj mreži da dovoljno velik skup podataka o tehnikama učenja studenta, danim materijalima i uspješnosti prolaska kolegija, mogu se dobiti dovoljno točne predikcije o uspješnosti polaganja kolegija te uvid u prednosti određenih metoda, tehnika i materijala.

4.3.4. Rudarenje podataka

Rudarenje podataka pojam je koji se počeo javljati 1990.-tih godina te je svojom pojavom izazvao veliki broj interesnih skupina. Počeo se javljati kao proces razvoja metoda i tehnika kojima bi se od iznimno velikog broja podataka mogli iznositi određeni zaključci i kreirati uzorci. Shodno tome, postoji i disciplina rudarenja podataka u edukacijske svrhe koja se kreće prema razvoju metoda za bolje shvaćanje učitelja i metoda učenja, istraživanjem jedinstvenih i velikih edukacijskih podataka, kako bi se one mogle poboljšati. [2]

Postoji uvjerenje da tehnika rudarenja podataka može otkriti korisne informacije koje se mogu koristiti za poboljšanje učenja. Postoje tri perspektive iz kojih se gleda na moguće poboljšanje. Prva je da se rudarenje podataka može koristiti za preporuku aktivnosti učenja, resursa i zadataka, koji se koriste kod učenja, na temelju iskustva od studenata koji su te resurse i zadatke koristili prije. Druga je da rudarenje podataka može biti korisno nastavnicima jer im daje objektivnu povratnu informaciju za njihovo održavanje nastave te time pomaže pri

donošenju odluka za eventualne promjene u načinu održavanja nastave. Treća perspektivna je da administratori mogu, pomoću rudarenja podataka, dobiti povratne informacije za optimizaciju mrežnog prometa i za procjenu obrazovnih platforma koje se koriste. [2] Primjer takve platforme može biti LMS sustav.

4.4. Preskriptivna analitika

Preskriptivna analitika je zapravo statistička metoda koja se koristi za generiranje preporuka i donošenje odluka temeljenih na ishodu određenih modela. Ona se zapravo smatra proširenjem prediktivne analitike, ali se ne koristi toliko često zbog svoje iznimne složenosti zbog strojnog učenja i velikih skupova podataka. [1]

Preskriptivna se analitika može kod analitike učenja koristiti u brojne svrhe, a jedna od njih je da se kreiraju preporuke nastavnicima kako i na koji se način mogu poboljšati kolegiji. Bez obzira na to, preskriptivna se analitika trenutno ne koristi u potpunosti kod analitike učenja, upravo zbog svoje, već spomenute, složenosti. [10]

Određena prognoza nekog slučaja koja se dobiva iz prediktivne analitike može se analizirati pomoću određenih modela koji su dizajnirani za preskriptivnu analizu kojima se zatim mogu proizvesti automatizirane preporuke ili rješenja, ali problem do kojeg se dolazi je upravo to što zahtijeva iznimno složene algoritme koji su temeljeni na strojnom učenju, kako bi se došlo do donošenja određenih odluka. [10]

Za razliku od prediktivne analitike, kod koje se zbog predviđanja određenih ishodi mogu, ali i ne moraju dogoditi. Pretpostavlja se da se ishod, koji je predviđen, ne mora nužno dogoditi. Uvijek postoji određeni rizik da nešto neće imati ishod koji je predviđen. Uzrok tog rizika je ljudski faktor, odnosno ljudsko ponašanje koje se ne može predvidjeti. Taj je rizik najviše izražen kod automatiziranih preporuka. [10]

4.4.1. Umjetna inteligencija

Analitika umjetne inteligencije još uvijek nije u potpunosti razvijena. Njezin cilj je napraviti spoj umjetne inteligencije i strojnog učenja s analitikom kojom će se moći generirati uvidi, automatizacija procesa, pružiti određeno predviđanje i donošenje odluka prema procesima i događajima koji su se već dogodili. Ovim spojem, organizacije imaju mogućnost uvida u sve svoje aspekte sa svrhom da se razumije što se i zašto dogodilo te što bi se moglo dogoditi u budućnosti kako bi se mogla poduzeti određena radnja. [11]

Analitika umjetne inteligencije također može biti povezana s analitikom učenja u visokom obrazovanju i tako da se postavi pitanje što se dogodilo (na primjer, veliki broj studenata nije položilo kolegij), zašto je do toga došlo (na primjer, studenti nisu dolazili na

predavanja) i kako to poboljšati (na primjer, uvesti obavezna predavanja). Naravno, da bi se do takvih zaključaka moglo doći potreban je skup podataka o studentima, nastavnicima i kolegijima kako bi se mogla provesti analiza i odrediti točni odgovori na ova postavljena pitanja.

Postoje broje prednosti koje se mogu dobiti iz analitike umjetne inteligencije. Neke od njih su poboljšano donošenje odluka, unaprijeđena produktivnost i efikasnost i poboljšano iskustvo sudionika u organizaciji. Kod poboljšanog donošenja odluka postoje određeni podaci koji su prikupljeni s ciljem poboljšanja rada i uspješnosti određene organizacije. Umjetna inteligencija u ovom slučaju olakšava, zato što eliminira određenu subjektivnost te se temelji na sirovim podacima koji dolaze u velikim količinama. Upravo zbog toga, korištenje umjetne inteligencije može uvelike pomoći organizacijama kod prepoznavanja potencijalnih problema, rizika, uzroka ili prilika. [11]

Analitika umjetne inteligencije isto tako utječe na efikasnost i na produktivnost organizacije, jer uz pomoć nje dolazi do detektiranja problema te zatim optimizacije tih problema. Samom automatizacijom određenih procesa dolazi do pojednostavljivanja procesa pa se tako može uštedjeti i na vremenu i na resursima. Ušteda vremena i resursa najviše se očitava kod provođenja određenih izvješća koja se temelje na skupovima podataka Unutar Tablice 1. nalazi se sažeti prikaz svih metoda. [11]

Metode			
Deskriptivna metoda	Dijagnostička metoda	Prediktivna metoda	Preskriptivna metoda
<ul style="list-style-type: none"> • praćenje i validacija cilja zadatka • laka i brza izvješća • identifikacija nedostataka prije nego što oni postaju problemi <p>1) POSLOVNA INTELIGENCIJA</p> <ul style="list-style-type: none"> • donošenje odluka temeljenih na podacima 	<ul style="list-style-type: none"> • temelji se na razlozima zašto se nešto dogodilo u prošlosti • dijagnostika nedostataka i problema • korelacija i uzročnost <p>2)DIJAGNOSTIČKA REGRESIJSKA ANALITIKA</p> <ul style="list-style-type: none"> • analiza među parametrima <p>a) jednostruka linearna regresija</p> <p>b) višestruka linearna regresija</p>	<ul style="list-style-type: none"> • statistička metoda • koristi prošle i sadašnje podatke radi izrade predikcije što bi se moglo dogoditi u budućnosti • mogućnost predviđanja prilika i rizika <p>1) STABLO ODLUČIVANJA</p> <ul style="list-style-type: none"> • odluka na temelju dobivenih podataka • grane i listovi <p>2) REGRESIJSKE TEHNIKE</p> <ul style="list-style-type: none"> • statistika • odnos zavisne varijable i jedne ili više nezavisnih varijabli <p>3) NEURNOSKE MREŽE</p> <ul style="list-style-type: none"> • ulazni, skriveni i izlazni sloj • ulazne zavisne i nezavisne varijable <p>4) RUDARENJE PODATAKA</p> <ul style="list-style-type: none"> • iznimno veliki broj podataka 	<ul style="list-style-type: none"> • statistička metoda za generiranje preporuka i donošenje odluka temeljenih na ishodu • proširenje prediktivne analitike • preporuke radi poboljšanja <p>1) UMJETNA INTELIGENCIJA</p> <ul style="list-style-type: none"> • uvidi, automatizacija procesa, predviđanje i donošenje odluka • otkrivanje uzroka nekog događaja

Tablica 1. Sažeti prikaz metoda

5. Analitika učenja u visokom obrazovanju

Analitika učenja je mjerilo, kolekcija, analiza te izvještaj koji se temelji na podacima o studentima, nastavnicima i kontekstima vezanima uz njih kao sudionike u visokom obrazovanju. Ona se javlja sa svrhom razumijevanja kako optimizirati učenje i okolinu kod koje se učenje javlja. [12]

5.1. Svrha analitike učenja u visokom obrazovanju

Do sada se prošlo kroz metode koje se koristi kod analitike učenja u visokom obrazovanju, te sada slijedi funkcionalna taksonomija. Ona je definirana prema izvoru pod brojem [14] koji se temelji na *Learnig Analytics Center of Excellence (LACE)*. Svrha analitike učenja u visokom obrazovanju, u suštini se temelji na unapređenju i kvaliteti nastavnog materijala te na uspješnosti prolaska kolegija. U principu, od iznimne je važnosti da nastavnici razumiju edukacijske prednosti kako bi ih mogli zadržati i/ili unaprijediti. [13]

Analitika učenja u visokom obrazovanju ima izraziti potencijal za unapređenje sustava i kvalitete visokog obrazovanja. Osim što je moguće unapređenje, moguća je i potpuna izmjena sustava obrazovanja ako je ona napravljena na ispravan način. Načini na koje je moguće poboljšati ili preoblikovati sustav je stavljanje fokusa na tri bitna aspekta, a to su određivanje korisnika sustava i njihove interakcije za vrijeme eventualnih promjena, postavljanje pitanja što je to *učenje* uopće, što se sve smatra *učenjem* i kako bi se taj pojam mogao definirati sukladno eventualnim promjenama te na posljertku eventualno podvrgavanje promjenama vezanima uz aktivnosti i uklapanju aktivnosti u učenje. [13]

5.1.1. Funkcionalna taksonomija analitike učenja

Analitika učenja u visokom obrazovanju može se koristiti u više svrha pa prema tome postoji određena funkcionalna taksonomija kojom se određuju neki osnovi model i principi. U idućim potpoglavljima, bit će objašnjena funkcionalna taksonomija analitike učenja u visokom obrazovanju. [14]

5.1.1.1. Pristup ponašanja pri učenju

Analitika učenja u visokom obrazovanju može služiti za prikupljanje podataka koji su generirani od strane korisnika, odnosno studenata, iz njihovih aktivnosti učenja te zatim ponuditi određene trendove u učenju. Obradom i analizom tih podataka mogu se pronaći određeni uzorci i donijeti zaključci koji su povezani s ponašanjem studenata u učenju te identificiranju stilova učenja studenata. Ovdje ne dolazi do mjerenja izvedbe studenata nego

do njihovog ponašanja i angažmana. Cilj je odrediti kako i na koji način studenti koriste materijale koji su im dostupni na kolegiju. [14]

Postoji nekoliko glavnih značajki koje se javljaju kod pristupa ponašanja kod studenata, a to su:

- Poticanje na određena ponašanja studenata, što se može odnositi na stvaranje povezanosti između ponašanja studenta i mogućeg ishoda. [14] Na primjer, ako student koristi više materijala i više uči, tada će najvjerojatniji ishod biti prolaznost određenog kolegija.
- Identificiranje profila ponašanja, odnosno pristupa ponašanja u učenju i radu studenata. Nakon identifikacija ponašanja i pristupa moguće je doći do zaključaka te pružanja smjernica, podrške i resursa studentima kako bi ishod bio što optimalniji. [14] Na primjer, ako nastavnik primijeti, prema ponašanju studenata, da je potrebno dati više materijala (resursa), tada postoji veća vjerojatnost da će ishod biti bolji, odnosno da će prolaznost na kolegiju biti veća.

5.1.1.2. Ocjena socijalnog učenja

Nadalje, analitika učenja može pomoći kod pregledavanja i istraživanja aktivnosti studenata na nekog digitalnoj društvenoj platformi kao što su određeni forumi ili aktivnosti na LMS-u koji je dostupan za studente. Kod takvog oblika praćenja aktivnosti studenata fokus je na tome da se vidi na koji se način razmjenjuju informacije između studenata te studenata i nastavnika kako bi se moglo doći do zaključka imaju li studenti koristi od takvih interakcija. [14]

Glavne značajke koje se javljaju kod ocjene socijalnog učenja jesu:

- Fokusiranje na digitalne aspekte učenja kako bi se vidjelo ima li komunikacija na društvenim platformama utjecaj na uspješnost studenata. [14] Na primjer, ako je otvoren forum za studente na određenom kolegiju, hoće li uspjeh studenata koji postavljaju pitanja i studenata koji odgovaraju na njih biti veći.
- Izvođenje zaključaka temeljenih isključivo iz interakcija koje se ostvaruju između nastavnika i studenta i samo između studenata. [14]

5.1.1.3. Poboljšanje materijala i alata za učenje

Isto tako, analitika učenja u visokom obrazovanju može služiti za praćenje korištenja materijala i alata od strane studenata, kako bi se eventualno mogle identificirati potencijalne potrebne promjene ili potencijalni problemi ili nedostaci unutar resursa koji su dostupni studentima. U principu, ovdje dolazi do evaluacije materijala koji su dostupni. Taj način omogućava nastavnicima uvid u kvalitetu dostupnih resursa te, po potrebi studenata, mogu dodati, ukloniti ili izmijeniti određene materijale. [14]

Neke od ključnih značajki kod ovog pristupa jesu:

- Korištenje skupnih podataka od strane studenta kako bi se nastavni materijali mogli podvrgnuti određenim promjenama. [14] Na primjer, ako studenti postižu lošije rezultate, postoji mogućnost da je problem u materijalima ili ako studenti sami kažu da bi htjeli dodatne materijale, tada bi im to nastavnik trebao i pružiti.
- Stavljanje primarnog fokusa na ishode i procese kod studenata. [14]

5.1.1.4. Individualizirano učenje

Analitika učenja može se primjenjivati i u prilagodljivim i individualnim sustavima učenja s ciljem prilagodbe sadržaja kolegija svakom pojedinom studentu. Neki od tih sustava mogu biti korisnički profili na LMS-u ili drugi skupovi podataka koji se zatim mogu prikupljati te analizirati radi personalizacije iskustva učenja. Bitno je naglasiti da ovakav pristup mora koristiti stalne povratne informacije kako bi se zaista moglo pomoći svakom individualnom studentu u njegovom radu i učenju. [14]

Neke od funkcionalnih značajka kod ovog pristupa jesu:

- Prikupljanje informacija o prethodnim iskustvima, odnosno karakteristikama studenta kako bi se dio sustava mogao prilagoditi pojedincu. Neke od tih karakteristika mogu biti stil učenja, poznavanje sadržaja, korištenje sadržaja i tako dalje. [14]
- Stavljanje fokusa na kontinuirano praćenje i analizu povratnih informacija u stvarnome vremenu. [14]

5.1.1.5. Predikcija učinka studenta

Predikcija učinka studenata, kod analitike učenja u visokom obrazovanju, temelji se na postojećim podacima koji se odnose na učenje i uspješnosti učenja te se primjenom statističkih metoda i tehnika dolazi do predviđanja određenog učinka učenja. Na taj se način mogu predvidjeti i određeni rizici koji se onda u budućnosti mogu izbjeći te se može pružiti određena podrška u slučaju da dođe do nekog rizika. Fokus je postavljen na upotrebu podataka koji će nastavniku dati uvid u trenutnu situaciju kako bi mogao pomoći studentu da ispravi svoje eventualne greške te da uspješno položi kolegij. [14]

Funkcionalne značajke koje se javljaju kod ovog pristupa jesu:

- Pružanje povratnih informacija studentima radi poticanja navike učenja. Ovdje se misli na povratne informacije koje mogu biti u obliku bodova, ocjena, komentara i tako dalje. [14]
- Fokus je postavljen na aktivnu inteligenciju. [14] Pod aktivnom inteligencijom smatra se da student ima sposobnost samoprocjene. Ako zamijeti da ima loše bodove onda bi trebao sam shvatiti zašto je došlo do loših bodova.

5.1.1.6. Vizualizacija aktivnosti učenja

Vizualizacija aktivnosti učenja odnosi se na sve vizualne elemente koji se mogu dobiti iz praćenja i analize aktivnosti studenta na nekom digitalnom ekosustavu. Na taj način se izrađuju i kreiraju izvješća o ponašanjima i izvedbama studenata. Svrha tih izvješća je motiviranje studenata za učenje, prilagodbu i povećanje učinkovitosti u radu na kolegiju. Ovdje dolazi do samorefleksije kod studenata kako bi uvidjeli svoje obrasce ponašanja i učenja te uveli eventualne promjene. [14]

Neke od funkcionalnih značajki kod ovog pristupa jesu:

- Davanje pristupa vizualnom učenju i za studente i za nastavnike. [14] Primjer toga mogu biti određeni grafovi na kojima se vidi uspješnosti prolaznosti studenata koja se temelji na stilovima učenja.
- Olakšavanje svjesnosti koja zatim vodi do samorefleksije te stvaranja smisla i utjecaja na budući ishod. [14]

Unutar Tablice 2., napravljen je sažeti prikaz funkcionalne taksonomije analitike učenja.

Taksonomija

	Pristup ponašanja pri učenju	Ocjena socijalnog učenja	Poboljšanje materijala i alata za učenje	Individualizirano učenje	Predikcija učinka studenata	Vizualizacija aktivnosti učenja
OPIS	<ul style="list-style-type: none"> Pregled postupanja studenta s dobivenim materijalom na kolegiju 	<ul style="list-style-type: none"> Praćenje aktivnosti na platformi poput LMS-a Način razmjenjivanja informacija među studentima te studentima i nastavnicima 	<ul style="list-style-type: none"> Evaluacija dostupnih materijala Uvid u kvalitetu materijala, odnosno resursa 	<ul style="list-style-type: none"> Korisnički profili na LMS-u ili drugi individualni skup podataka 	<ul style="list-style-type: none"> Temelj na postojećim podacima Primjena statističkih metoda i tehnika radi predviđanja učinka i rizika kod učenja 	<ul style="list-style-type: none"> Izvešća o ponašanju i izvedbama studenata Motivacija studenata za učenje, prilagodba i povećanje uspješnosti
ZNAČAJKE	<ul style="list-style-type: none"> Poticanje na određenih ponašanja studenata -> povezanost ponašanja i mogućeg ishoda Identificiranje profila ponašanja -> mogućnost pružanja smjernica, resursa i podrške 	<ul style="list-style-type: none"> Fokus na digitalne aspekte učenja -> na primjer, forum na LMS-u Izvođenje zaključaka na temelju interakcija 	<ul style="list-style-type: none"> Korištenje povratnih informacija od studenata za materijale Fokus na ishodima i procesima studenata 	<ul style="list-style-type: none"> Prikupljanje informacija o prethodnim iskustvima: <ol style="list-style-type: none"> stil učenja povezivanje sadržaja korištenje sadržaja Fokus na kontinuiranom praćenju i analizi povratnih informacija 	<ul style="list-style-type: none"> Pružanje povratnih informacija studentima -> na primjer: ocjene, bodovi Fokus na aktivnoj inteligenciji, odnosno sposobnosti studenta da izvrši samoprocjenu 	<ul style="list-style-type: none"> Davanje pristupa vizualnom učenju -> na primjer: grafovi uspješnosti Samorefleksija

Tablica 2. Sažeti prikaz taksonomije analitike učenja

5.2. Koraci procesa unapređenja

U današnje se vrijeme mogu pronaći i određeni parametri i koraci prema kojima se može odrediti uspješnost učenja. Koraci unapređenja koji se najčešće koriste kod analitike učenja jesu takozvani *Data Wise* koraci. Općenito, sam proces *Data Wise* započeo je početkom 2000-ih godina kao suradnja Bostonskih javnih škola i *Harvard Graduate School* sa svrhom prikupljanja i obrade podataka za kreiranje smislenih rješenja s ciljem poboljšanja poučavanja i učenja. [15]

Postoje ukupno tri faze od kojih svaka ima nekoliko koraka. Te se faze odnose na prikupljanje podataka od studenta kako bi se određeni koraci i procesi mogli unaprijediti. Sve te faze i koraci trebali bi ići ciklički, odnosno oni bi se stalno trebali ponavljati kako bi uspješnost i poboljšanje bili što bolji. Neki od glavnih koraka su organizacija zajedničkog rada, izgradnja pismenosti za procjenu, izrada pregleda podataka, kopanje po studentskim podacima, uputa za ispitivanje, izrada akcijskog plana, planiranje za procjenu napretka te akcija i procjena. Svaki od ovih koraka bit će detaljnije pojašnjen u nastavku. [15]

5.2.1. Priprema

Nastavnici se trebaju pripremiti za rad na početku svake akademske godine i to prema rezultatima koji su postignuti prethodne godine. Time bi svake godine, prema prethodnim podacima, trebalo doći do što boljeg i većeg uspjeha, jer bi se resursi trebali unapređivati isto kao i kvaliteta svakog kolegija. Koraci koji se javljaju kod faze pripreme jesu organiziranje zajedničkog rada i izgradnja pismenosti za procjenu. [16]

5.2.1.1. Organiziranje zajedničkog rada

U školstvu je od iznimne važnosti imati razgovore vezane uz podatke koji su dobiveni od prije kako bi se kapacitet osoblja, odnosno nastavnika, mogao poboljšati u smislu razumijevanja i provedbe rada na unapređenju školstva. Da bi došlo do uspostave određene *kulture podataka* ili *kulture istraživanja* u školstvu, potrebno je da fakultet ima uspostavljen svoj tim koji će se baviti podacima i snositi tehničke i organizacijske aspekte rada. Pod time se misli da će se trebati sastavljati, proučavati i upravljati dobivenim informacijama. Cilj je da formirani tim može komunicirati što učinkovitije. [17]

Osim toga, da bi unapređenje bilo uspješno, potrebno je organizirati timske strukture kod kojih će biti mogući rad i uključivanje u planiranje suradnje, a koja će djelovati s ciljem da se performanse kod studenta poboljšaju. Razlog tome je što na početku akademske godine izvedba nastave može biti otežavajuća i neugodna za studente zbog toga što se nalaze u

novim situacijama. Shodno tome, formiranje timova koji će biti zaduženi za rješavanje ovog problema je poprilično korisno. [16]

5.2.1.2. Izgradnja pismenosti za procjenu

Nadalje, da bi se dobiveni podaci mogli dobro proučiti u idućoj fazi potrebno ih je dobro obraditi i predstaviti. Kod predstavljanja tih podataka bitno je imati dobro napisana i pregledna izvješća kako bi ona bila razumljiva svima koji ih koriste i čitaju. Upravo je iz tog razloga potreban korak procjene pismenosti. Da bi se ta izvješća mogla dobro napisati i pripremiti potrebno je dobro razumjeti pojmove koji će se koristiti kod pisanja tih izvješća. Neki od pojmova vezanih uz obradu i analizu podataka jesu pouzdanost, valjanost, pogreška mjerenja, pogreška uzrokovanja i tako dalje. Također, potrebno je dobro razmisliti i timski dogovoriti hoće li kreirano izvješće imati pozitivan ili negativan utjecaj na studente. [16]

5.2.2. Proučavanje

Nakon prve faze dolazi do faze proučavanja ili ispisivanja kod koje dolazi do traženja uzoraka u podacima koji mogu ukazivati na eventualne nedostatke kod resursa i podučavanja. Time se zatim dolazi do određenih zaključaka koji su povezani s eventualnim mogućim rješavanjima problema u trećoj fazi. Unutar druge faze, odnosno faze proučavanja, dolazi do tri koraka, a to su izrada pregleda podataka, kopanje po studentskim podacima i uputa za ispitivanje. [16]

5.2.2.1. Izrada pregleda podataka

Unutar prvog koraka kod faze proučavanja dolazi do izrade vizualnih prikaza rezultata ispitivanja koji su postavljeni u koraku prije. Izvješća mogu biti zamorna i nerazumljiva pa je stoga optimalno da postoji tehnički tim koji će ta izvješća učiniti prihvatljivijim tako da oblikuje podatke u grafičke prikaze. Tim se postupkom može uključiti više nastavnika za donošenje odluka prema dobivenim podacima. [17]

5.2.2.2. Kopanje po studentskim podacima

Idući korak je kopanje po podacima koji su vezani uz studente kako bi se mogao identificirati problem koji je usmjeren na studenta. Ovdje se pod problemom misli na razumijevanje ili vještine koje su uobičajene za studente i na kojima se temelji njihova uspješnost. Ovdje dolazi do analize velikog spektra podataka unutar kojeg se mogu obuhvatiti uzorci rada studenata na kolegiju, njihova uspješnost na ispitima pa tako i sam razgovor sa studentima. Kopanjem po podacima koji su dostupni može se doći do zaključaka i mogućih unapređenja učenja ili prolaznosti kod studenata. Također, može se doći do zaključaka o

područjima kod kojih studenti imaju najviše problema pa se onda prema tome može pružiti najviše savjeta i podrške kako nadići te prepreke. [17]

5.2.2.3. Uputa za ispitivanje

Posljednji korak kod faze proučavanja je uputa za ispitivanje. Kod tog se koraka usmjerava na rješavanje problema koji je povezan sa studentima. Taj je problem potrebno preoblikovati u *problem prakse* koju treba promijeniti. Nakon identifikacije eventualnog problema potrebno je doći do razumijevanja preko razgovora kako bi se on mogao na učinkoviti način razriješiti. [16]

5.2.3. Djelovanje

Posljednja faza je faza djelovanja kojoj je cilj da se, nakon proučenih prethodnih problema i rizika, pokušavaju provesti određena nastavna poboljšanja. Faze koje se nalaze kod ovog koraka jesu izrada akcijskog plana, planiranje za procjenu napretka te akcija i procjena. [16]

5.2.3.1. Izrada akcijskog plana

Prvi korak kod posljednje faze je izrada akcijskog plana. Nakon svih prethodnih koraka dolazi korak kod kojeg se kreće s djelovanjem i radom prema cilju. Ovdje dolazi do kretanja s odlučivanjem o strategiji podučavanja koja će voditi do rješavanja problema na koji se naišlo. Kod izrade strategije istu je potrebno detaljno opisati te odrediti kako će ona izgledati u učionici i u praksi. Nakon toga dolazi do podjele uloga i odgovornosti. [16]

5.2.3.2. Planiranje za procjenu napretka

Prije provedbe samog plana potrebno je odrediti na koji će se način mjeriti uspjeh tog plana. Kod ovog se koraka često dolazi do problema zbog toga što nema jasno definiranih metoda i načina mjerenja uspješnosti. Time se na određeni način gubi i motivacija, jer nije dovoljno jasno ima li kakvog napretka. Glavna osoba mora odrediti kratke, srednje i dugoročne načine prikupljanja i analize podataka uspješnosti. [16]

5.2.3.3. Akcija i procjena

Posljednji korak je akcija i procjena. Nakon što je napravljen početni plan kako riješiti određeni problem, potrebno je postaviti četiri glavna pitanja da bi se taj plan proveo, a to su jesu li svi sudionici fakulteta na istoj strani, hoće li se učiniti ono što je rečeno da hoće, uče li studenti sada više i koji su daljnji koraci koje možemo poduzeti. Provedba akcijskog plana, u ovom slušaju, može biti eksperimentalna kako bi se testirale teorije kako odabrane strategije utječu na studente i njihovo učenje. [16]

6. Korisnici analitike učenja u visokom obrazovanju

Korisnici analitike učenja jesu nastavnici, studenti i uprava koji sudjeluju u visokom obrazovanju. Studenti su ključni za prikupljanje podataka radi provođenja raznih analiza potrebnih za analitiku. Naime, neka od mjerila su uspješnost polaganja određenog kolegija, ocjene, motivacija, dostupnost materijala i tako dalje.

Moglo bi se reći da je uloga studenata od krucijalne važnosti zbog navedenih razloga. Isto tako, svaki je student individua za sebe pa prema tome svaki student ima određene kapacitete i sposobnosti. Iz tog se razloga isto tako, u obzir moraju uzeti i faktori koji su povezani sa studentom kao individuom. Primjer toga može biti da postoje neki studenti koji postižu bolje rezultate ako su na pismenom ispitu dok neki postižu bolje rezultate ako su na usmenom ispitu. Dakako, mjerilo uspješnosti, isto kao i cilj svakog studenta, je da on uspješno položi kolegij te da završi visoko obrazovanje.

Osim studenta, korisnici analitike učenja u visokom obrazovanju jesu i nastavnici. Razlog uključenosti nastavnika je da se prema podacima koji su prikupljeni od strane studenata može dobiti slika o tome koliko koji nastavnik mora poboljšati neki od aspekata svog kolegija. Ovdje se misli na poboljšanja vezana uz izradu i količinu dostupnih materijala, kvalitetu izvođenja nastave te posvećivanje studentima kao individuama.

Isto tako, korisnici analitike učenja i podučavanja mogu biti i uprava ustanove kod koje se ona primjenjuje. Naime, da bi se donijele neke promjene, pa tako i potaklo istraživanje problema, nedostataka i mogućih rizika, potrebno je dobiti odobrenje uprave za istim. Na primjer, ukoliko se detektira neki određeni problem u radu vezanom za nastavu, učenje i poučavanje, potrebno je javiti upravi, te poduzeti mjere koje su dogovorene od strane svih korisnika analitike.

7. Alati i pokazatelji za analitiku učenja u visokom obrazovanju

Najčešći alati koji se koriste za analitiku jesu *Moodle* i *Canvas*. *Moodle* sustav koristi se kod većine ustanova koje su posvećene visokom obrazovanju. Naime, on nudi analitiku za svakog pojedinog studenta te za sve studente zajedno. Može se saznati kada je neki student bio aktivan, koliko je puta vidio neki materijal, je li koristio materijale, koliko je aktivan na forumima i tako dalje. Svi su ti podaci relevantni jer se na temelju njih mogu provoditi određene akcije koje se temelje na poboljšanju procesa učenja i poučavanja, pa tako i prolaska kolegija. Isto tako, bitan je i uvid u ukupnu prolaznost kolegija i na određenom ispitu. Bitno je naglasiti da *Moodle* ne može napraviti predikciju ili predvidjeti kako će se stanje na kolegiju razvijati u budućnosti, ali može dati potrebne informacije kako bi se sve potrebne analize mogle napraviti i kako bi se mogla dobiti određena predikcija. [18]

Idući alat koji se može koristiti za analitiku učenja je *Analytics Canvas*. Taj alat služi za obradu prikupljenih podataka te njihovu analizu. Pomoću njega, podaci se mogu istraživati, transformirati te pripremati za daljnje analize. Drugim riječima, ovaj alat omogućava nastavak priče na alat *Moodle*. Bitno je naglasiti da *Canvas* prati glavne korake, odnosno metode koje se koriste dok analitike učenja, a to su deskriptivna metoda, dijagnostička metoda, prediktivna i preskriptivna metoda. [19]

Analytics Canvas zapravo je dio *Google Analytics Management*-a te daje brze analize, odnosno preglede podataka za daljnju obradu. Dobro je napomenuti da je taj alat poželjan zato što se pomoću njega mogu na brz i jednostavan način učiniti sve potrebne promjene kako bi svaka od tih promjena bila pravilno dokumentirana i obrađena. [20]

8. Ontologija

Ontologija, kao takva, odnosi se na znanost o nekom biću kao biću. Odnosno, ona opisuje biće onakvo kakvo ono jest. To je znanost o temeljnim uzrocima svega što postoji i svega što je postojalo. Može se zaključiti da se ontologija bavi tvrdnjama koje su usmjerene prema prirodi bića i postojanja. Preispitivanje svijeta s ontološkog aspekta dalo je ljudima priliku da krenu s preispitivanjem svega ostaloga, od svrhe postojanja, do prirode, apriornog razmišljanja, zaključivanja, pojava i pojmova i svega od čega se može kreirati neki valjani argument. U realnijem pogledu, ne toliko filozofskom, ontologija se koristi za definiranje uvjerenja o temeljnoj prirodi stvarnosti, a najviše se odnosi na društvenu stvarnost. [21]

Ontologija, u većini slučajeva, djeluje iznimno apstraktno, ali ona postavlja pitanja koja su od velike važnosti za društvene koncepte i istraživanja u društvu. Upravo se iz tog razloga, ontologija se nalazi na samom vrhu hijerarhije pod kojom se zapravo epistemologija, metodologija i metode slažu [21]. Upravo iz tog razloga, ontologija je idealna za analitiku učenja u visokom obrazovanju jer ona objedinjuje sve metode, metodologije i tehnike te dopire do same srži teme i pokušava je pojasniti.

8.1. Povijest ontologije

Da bi pojam ontologije bio u potpunosti jasan, potrebno je malo razraditi povijest same ontologije i kada je i zašto ona nastala. Prvo spominjanje ontologije, odnosno njena razrada, spomenuta je već kod Aristotela u njegovom djelu Metafizika, no prvo definiranje pojma ontologije javilo se 1646. godine u kod J. Clauberga u, istoimenom djelu, Metafizika. Unutar njegovog se djela ontologija definira kao filozofska znanost o svim općim odredbama bitka po sebi i načinima na koje su bića određena. [21]

Ontologija se počela primjenjivati u informatici i računalnoj znanosti 1980.-tih godina tako da je zajednica za umjetnu inteligenciju počela pojam ontologije koristiti za označavanje teorije modeliranog svijeta i komponente sustava znanja. U to su vrijeme neki istraživači gledali na računalnu ontologiju kao na vrstu primijenjene fizike. Danas je ontologija dio skupa standarda za semantički Web kod kojih se koristi za određivanje standardnih konceptualnim rječnika kod kojih se podaci mogu razmjenjivati među sustavima koji služe za pružanje usluge, odgovaranje na upite i tako dalje. [22]

8.2. Ontologije za potporu u učenju i poučavanju

U današnje se vrijeme sve više i više javljaju ontologije koje se odnose na obrazovanje, odnosno na pojam učenja općenito. Može se reći da se ontologije koriste s velikim uspjehom u obrazovanju baš zato što one reprezentiraju određenu domenu učenja tako da specificiraju sve koncepte koji su unutar nje uključeni te sve relacije između navedenih koncepata. Osim toga, javljaju se i sva svojstva te uvjeti koji unutar te domene postoje. [23]

Isto tako, sve te domene, koje su povezane s učenjem općenito, sadrže dovoljno znanja te bogati opis sadržaja potrebnih za učenje, za personaliziranje i proučavanje sadržaja učenja te isto tako za buduću izradu plana i programa nastave, kao i procjene procesa učenja. S obzirom na to da se ontologije, u većini slučajeva, koriste na generički način kojim se dobiva znanje o domeni, one definiraju određene semantičke modele koji se mogu kombinirati s već pridruženim znanjem domene na način da se definiraju veze između različitog semantičkog znanja. Drugim riječima, zbog svog generičkog pristupa, znanja koja se nalaze unutar ontologije mogu se nesmetano povezivati i proširivati. [23]

Može se zaključiti da se ontologije u obrazovanju i učenju najviše koriste kao generički prikazi problema i rješenja koji se javljaju u školstvu.

8.3. Alat *Protégé*

Protege je platforma koja je besplatna te je otvorenog koda. On zapravo pruža skup alata koji se koriste za izradu modela neke domene te za izradu aplikacija temeljenih na ontologiji. Alata je osnovan od strane *Stanford Center for Biomedical Informatics Research* na sveučilištu u Stanfordu. [24]

Protégé, desktop verzija, može podržati kreiranje, uređivanje i rad s jednom ili više ontologija. Isto tako, ima pregledno korisničko sučelje je svaki dio raspoređen za sebe. Upravo iz tog razloga, u svrhu ovog diplomskog rada, koristi se alat *Protégé*. Postoje dvije verzije alata, a to su desktop i Web verzija. U ovom je radu korištena desktop verzija. [24]

S obzirom da je alat namijenjen za izradu ontologija, korištenje alata te njegove mogućnosti će biti detaljnije opisane i prikazane prilikom opisa ontologije i njezinih elemenata.

9. Izrada ontologije

Kao što je prethodno spomenuto, alat u kojem je izrađena ontologija analitike učenja u visokom obrazovanju je, *Protégé*. Plan je bio sve metode, korisnike, korake unapređenja i ostale poveznice na analitiku učenja, staviti na jedno mjesto, odnosno unutar jedne ontologije. Dodane su vrste podataka koji se koriste za određenu metodu te parametri, mogući problemi i rješenja.

Cilj ontologije je na jednom mjestu povezati pojmove koji su vezani za analitiku učenja u visokom obrazovanju kako bi se to područje (domena) jasnije prikazalo te omogućio pregled važnih elemenata i njegovo bolje razumijevanje. Razvijena ontologija sadrži osnovne pojmove i veze kako bi se pokazala mogućnost njezine primjene na domenu analitike učenja te se može dodatno razvijati i proširiti dodatnim klasama, svojstvima i ograničenjima. U ontologiji će biti definirani i problemi te načini rješavanja problema s mogućnošću zadavanja upita u ontologiji.

9.1. Entiteti

Unutar alata *Protégé* nalazi se kartica *Entities*. Za ovaj je rad ta kartica najbitnija. Okviri koji se nalaze unutar nje jesu *Annotation properties*, *Datatypes*, *Individuals*, *Classes*, *Object properties* i *Data properties*. Neki od njih će biti korišteni u daljnjem radu, a svaki od njih će unutar ovog poglavlja biti više ili manje detaljno pojašnjen, ovisno o tome koliko će se koristiti.

9.1.1. Klase

Kao što je već spomenuto, unutar kartice entiteta postoji okvir koji se odnosi na klase. Klase su glavni dijelovi neke ontologije. Jedna klasa može stajati sama za sebe ili može imati svoje potklase, ovisno o tome kako je za koju ontologiju potrebno. Isto tako, jedna klasa može biti drugoj nadređena ili podređena, ovisno o kontekstu u kojem je ona zadana. Svaka je klasa prikazana u hijerarhiji klasa te može imati komentar i opis.

9.1.1.1. Hijerarhija klasa

Postoji dio, unutar okvira *Classes* koji se naziva *Class hierarchy*. Kao što i sam naziv govori, taj se dio odnosi na hijerarhiju klasa, odnosno kako je koja klasa raspoređena u odnosu na drugu za zadanu domenu. Drugim riječima, hijerarhija klasa je prikaz utvrđenih i pretpostavljenih hijerarhija klasa te je svaka hijerarhija viđena i posložena prema postavkama koje su zadane. Ona spada u primarne navigacijske uređaje unutar alata *Protégé*. [25]

Hijerarhija klasa građena je u obliku stabla gdje same klase predstavljaju čvorove. Unutar ovakvog stabla, odnos dijete i roditelj predstavljen je u obliku natklasa i potklasa. Unutar

primjera, koji je prikazan na Slici 1., može se primijetiti da je klasa *Metoda* natklasa (roditelj) klasi *DeskriptivnaAnalitika* te isto tako da je *DeskriptivnaAnalitika* (dijete) potklasa klase *Metoda*. Isto to vrijedi i za sve ostale klase, odnosno klase koje su „iznad“ su natklase, a klase koje su „ispod“, to jest, koje se granaju dalje iz neke klase, su potklase. Takav način prikaza je vidljiv u pogledu *Asserted*. Postoji i drugi pogled koji se naziva *Inferred*, ali on se koristi nakon pokretanja alata za rezoniranje. [25]

Postoji više opcija koje se mogu izvesti kod hijerarhije klasa. One se mogu dodavati kao klase, potklase ili kao susjedne klase, te se mogu brisati. Potrebno je napomenuti da se kod dodavanja klasa treba paziti na razmake, odnosno ako se unutar imena klase stavi razmak, tada je to ime potrebno staviti u navodnike. Isto tako, potrebno je izbjegavati dijakritičke znakove. [25]

1) Dodavanje klase

Način na koji se neka klasa može dodati je da se pritisne gumb za dodavanje klase. Zatim se upiše naziv klase te se klasa pohrani i prikaže unutar hijerarhije. [25]

2) Dodavanje potklase

Potklasa se dodaje na način da se pritisne na drugi gumb za dodavanje. Kod tog se dodavanja zapravo dodaje i susjedna klasa na istoj razini hijerarhije. Primjer toga vidljiv je na Slici 1., gdje je dodana *DeskriptivnaAnalitika* i njezina susjedna klasa *DijagnostičkaAnalitika*. [25]

3) Brisanje klasa

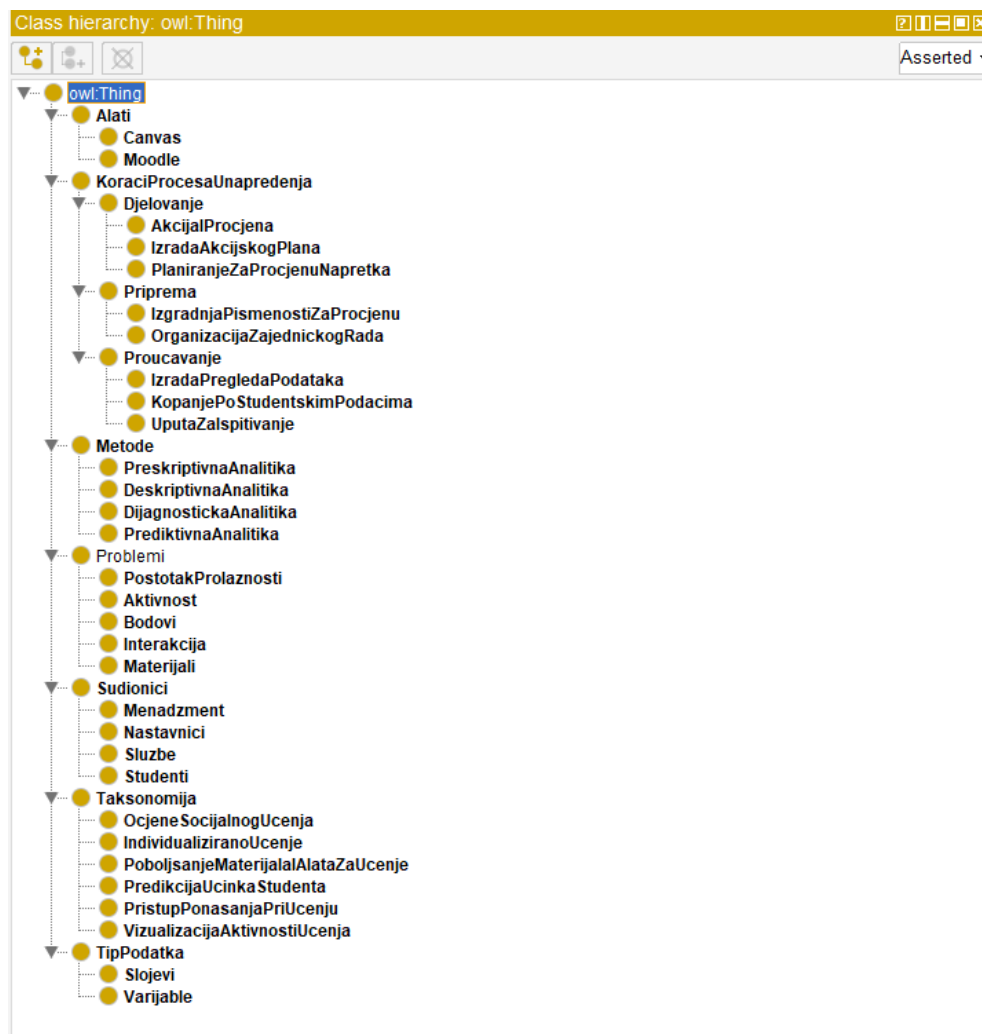
Osim što se klase mogu dodavati, one se mogu i brisati. Do brisanja klasa dolazi ukoliko se primijeti da klasa nije potrebna ili ako ona ne odgovara znanju odabrane domene ili ako je zabunom kreirana. [25]

Na Slici 1. prikazana je hijerarhija klasa za ontologiju analitike učenja u visokom obrazovanju. Klase koje su povezane s metodama, sudionicima, alatima, taksonomijom i koracima procesa unapređenja objašnjene su u prethodnim poglavljima, odnosno objašnjeni su pojmovi koji se koriste za klase. Svi ostali pojmovi koji se javljaju u hijerarhiji klasa bit će objašnjeni u nastavku.

Vidljivo je da su kao natklase postavljene klasa *Alati* koja ima susjedne natklase *KoraciProcesaUnapredenja*, *Metode*, *Problemi*, *Sudionici*, *Taksonomija* i *Podatak*. Isto tako, te klase imaju svoje potklase. Potklase klase *Alati* su *Canvas* i *Moodle*. Nadalje, potklase od klase *KoraciProcesaUnapredenja* jesu *Djelovanje*, *Proucavanje* i *Priprema*. Isto tako, svaka od tih klasa ima svoje potklase. Prema tome potklasa *Djelovanje* ima još svoju djecu, odnosno potklase, a one su *PlaniranjeZaProcjenuNapretka*, *IzradaAkcijskogPlana* i *AkcijaIProcjena*. Nadalje, potklasa *Proucavanje* ima svoje potklase *UputaZaIsplitivanje*, *KopanjePoStudentskimPodacima* i *IzradaPregledaPodataka*. Posljednja potklasa *Priprema*

ima svoje podklase, a one jesu *IzgradnjaPismenostiZaProcjenu* i *OrganizacijaZajednickogRada*.

Na isti su način raspoređene i potklase klase *Metoda*. Postoji ukupno četiri potklase, a one su *DeskriptivnaAnalitika*, *DijagnostickaAnalitika*, *PreskriptivnaAnalitika* i *PrediktivnaAnalitika*. Klasa *Problemi* isto tako ima svoje potklase koje su zapravo najčešći problemi koji se javljaju kod analitike učenja, a to su *Aktivnost*, *Bodovi*, *Interakcija*, *Materijali* i *PostotakProlaznosti*. Što se tiče klase *Sudionici*, kod ontologije analitike učenja, javljaju se četiri potklase, a to su *Menadzement*, *Sluzbe*, *Nastavnici* i *Studenti*. Iduća klasa je *Taksonomija* koja ima šest potklasa, a to su *IndividualiziranoUcenje*, *OcijeneSocijalnogUcenja*, *PoboljsanjeMaterijalaAlataZaUcenje*, *PredikcijaUcinkaStudenta*, *PristupPonasanjaPriUcenju* i *VizualizacijaAktivnostiUcenja*. Posljednja klasa koja se javlja u hijerarhiji klasa je *Podatak* koja ima svoje potklase, a to su *Slojevi* i *Varijable*. Posljednja klasa, to jest klasa koja se odnosi na vrstu podatka, zapravo definira neki podatak koji se može pronaći unutar metode ili taksonomije. Primjer toga je recimo da stablo odlučivanja ima podatke koji su grana i list. O tome će, u nastavku, sve biti definirano.



Slika 1. Prikaz hijerarhije klasa (Izvor: vlastita snimka ekrana)

9.1.2. Opisi klasa

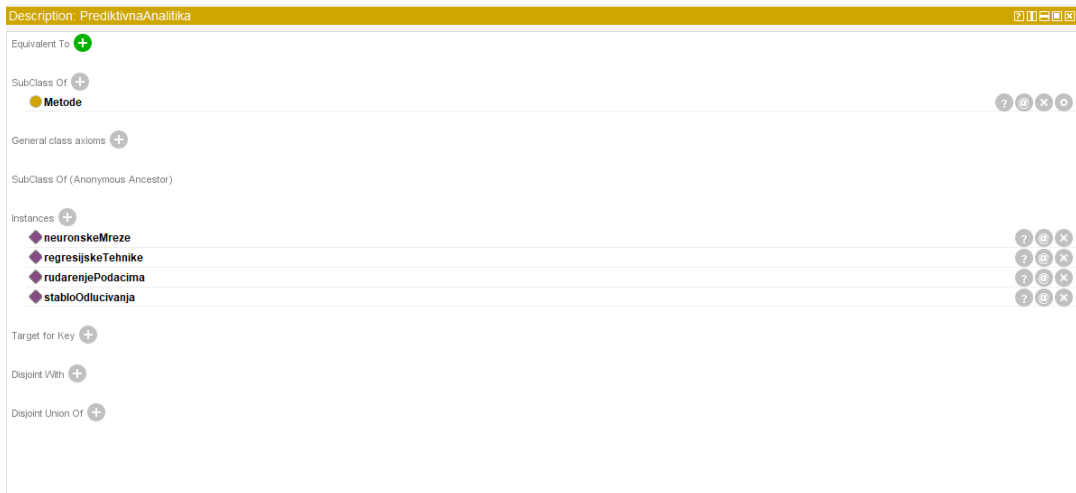
Unutar okvira *Class* postoji sekcija *Description*. Unutar te sekcije postavljaju se logičke poveznice između klasa. Unutar te sekcije, postoji više opcija koje se mogu podesiti. Bitno je napomenuti da opisi klasa vrijede za svaku pojedinu klasu i to tako da se željena klasa selektira. Te opcije su *Equivalent To*, *SubClass Of*, *General class axioms*, *SubClass Of (Anonymous Ancestor)*, *Instances*, *Target for Key*, *Disjoint With* i *Disjoint Union Of*. [26]

Unutar opisa *Equivalent To* postavlja se klasa koja je ekvivalentna klasi koja je selektirana. Ponekad će ekvivalente klase biti prikazane, ali samo kada je odabrana opcija *Inferred* i to samo kao je ona omogućena u postavkama za *Reasoner*. Nadalje, *SubClass Of*, kao što samo ime označava, unutar sebe ima naznačenu klasu od koje je selektirana klasa potklasa. Na primjer, ako je potklasa *Nastavnici* selektirana, na mjestu *SubClass Of* biti će naznačena njezina natklasa, odnosno *Sudionici*. [26]

Idući segment kod opisa klasa je *General class axioms* koji se odnosi na to da se svaki redak prikazuje aksiomom opće klase koja trenutno sadrži odabranu klasu. Ovaj segment opisa neće biti korišten u radu. Nadalje *SubClass Of (Anonymous Ancestor)* odnosi se na to da alat *Protégé* sam automatski ispituje pretke, odnosno natklase selektirane klase i akumulira njihove superklase. Ovaj dio opisa također neće biti korišten u radu. [26]

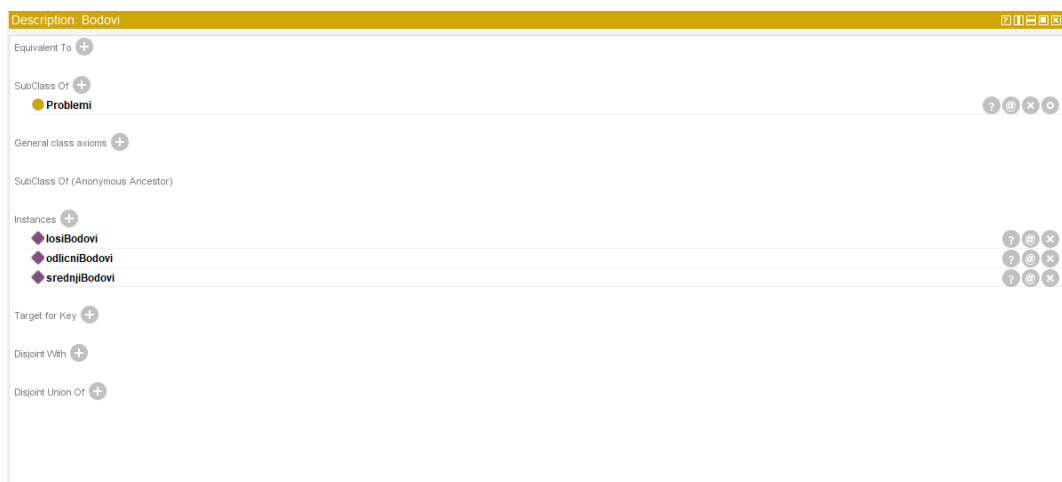
Nadalje, opis klase *Instance* označava da svaki redak može specificirati neku individuu koji ima odabranu klasu kojoj pripada u aksiomu tvrdnje klase. Zatim slijedi *Target for Key*, koji određuje kombinirani popis određenih svojstava objekta i podataka koji djeluju kao ključ za instance klase koja je selektirana. Ovaj dio se isto tako neće koristiti u radu. Preostaje još *Disjoint With* koji služi za dodavanje klase s kojima selektirana klasa nije povezana. Naposljetku postoji još i *Disjoint Union Of* koji označuje da je selektirana klasa glavna klasa u tom aksiomu klase. [26]

Većina klasa, koje su već spomenute u hijerarhiji klasa, imaju svoje instance (individue) pa tako za klasu *Metode* potklasa *PreskriptivnaAnalitika* ima jednu instancu, a to je *umjetnaInteligencija*. Potklasa *DeskriptivnaAnalitika*, ima tri instance, odnosno *poslovnaInteligencija*, *tehnikaAgregacijePodataka* i *tehnikaRudarenjaPodataka*. Potklasa *DijagnostickaAnalitika* ima, isto tako, tri instance, a to su *dijagnostickaRegresijskaAnalitika*, *jednostrukaLinearnaRegresija* i *visestrukaLinearnaRegresija*. Posljednja potklasa metoda je *PrediktivnaAnalitika* i ona ima najviše instanci, odnosno njih četiri, a to su *neuronskeMreze*, *regresijskeTehnike*, *rudarenjePodacima* i *stabloOdlucivanja*. Način na koji su postavljane instance za navedene metode je da se za svaku od njih uzeo način, odnosno tehnika kojom se provode te metode. U poglavlju *Metode* sve su te instance spomenute i detaljnije pojašnjenje. Primjer kako instance izgledaju unutar alata *Protégé*, prikazan je na Slici 2.



Slika 2. Prikaz primjera instanci unutar opisa klase PrediktivnaAnalitika (Izvor: vlastita snimka ekrana)

Nadalje, postoji još instanci koje se javljaju unutar alata. Kod klase *Problemi* za svaku potklasu javljaju se po tri instance. Unutar potklase *PostotakProlaznosti* imamo tri instance, a to su *losaProlaznosti*, *srednjaProlaznost* i *odlicnaProlaznosti*. Kod potklase *Aktivnosti* postoje instance *losaAktivnost*, *srednjaAktivnost* i *odlicnaAktivnost*. Potkategorija *Bodovi* ima instance *losiBodovi*, *srednjiBodovi* i *odlicniBodovi*. Nadalje, potklasa *Interakcija* ima instance *losaInterakcija*, *srednjaInterakcija* i *odlicnaInterakcija*. I posljednja potklasa *Materijali* ima isto tako tri instance, a to su *losaKvalitetaMaterijala*, *srednjaKvalitetaMaterijala* i *odlicnaKvalitetaMaterijala*. Logika koja stoji iza pojmova loša, srednja ili odlična je prema broju, omjeru ili postotku koji je zadan kao podatkovno svojstvo. U nastavku, unutar poglavlja s podatkovnim svojstvima, detaljnije će biti objašnjena logika koja se nalazi iza kategorizacije između instanci, ali može se već ovdje intuitivno zaključiti što bi mogla svaka od po tri instance klase označavati. Na Slici 3. prikazan je jedan opis klase za klasu *Problemi* i to za potklasu *Bodovi*.




Slika 3. Prikaz primjera instanci unutar opisa klase Bodovi (Izvor: vlastita snimka ekrana)

Iduća klasa čije potklase imaju instance je *Taksonomija*. Instance koje su pridružene potklasama ponajviše se odnose na opise i podatke koji su vezani uz tu potklasu pa tako potklasa *OcjeneSocijalnogUcenja* ima instance *aktivnostiNaForumima* i *zakljucakNaTemeljuInterakcija*. Sami nazivi instanci poprilično su intuitivni. Instanca *aktivnostiNaForumima*, odnosi se ponajviše na aktivnosti koje se odvijaju na određenom LMS sustavu, a primjer tomu može biti otvoreni forum na kojem studenti mogu postavljati pitanja vezana uz zadatke koji su dobiveni ili općenito pitanja vezana uz kolegij. Instanca *zakljucakNaTemeljuInterakcija* odnosi se na količinu interakcija koje se odvijaju između studenata te nastavnika i studenta. Drugim riječima, koliko je neki student aktivan i koliko se trudi dobiti informacije ili zatražiti pomoć vezanu uz studiranje i učenje.

Iduća potklasa je *IndividualiziranoUcenje* koja za instance ima *infoOPrethodnimIskustvima* koja se odnosi na informacije o iskustvima studenta kao individue za sebe, odnosno njegovog iskustva u učenju i korištenju materijala i instancu *kontinuiranoPracenjeStudenta* koja se odnosi na praćenje rada studenta i načina na koji uči i koristi materijale kako bi postigao poboljšanje u prolaznosti. Nadalje, potklasa *PoboljsanjeMaterijalaAlataZaUcenje* ima isto tako dvije instance, a to su *podvrgavanjeMaterijalaPromjenama* i *stavljanjePrimarnogFokusa*. Instanca *podvrgavanjeMaterijalaPromjenama* odnosi se na to da se materijali moraju prilagoditi i poboljšati, odnosno prilagoditi nekoj situaciji, ako postoji stvaran razlog za to, dok se *stavljanjePrimarnogFokusa* odnosi na stavljanje primarnog fokusa na ishode i procese vezane uz studenta.

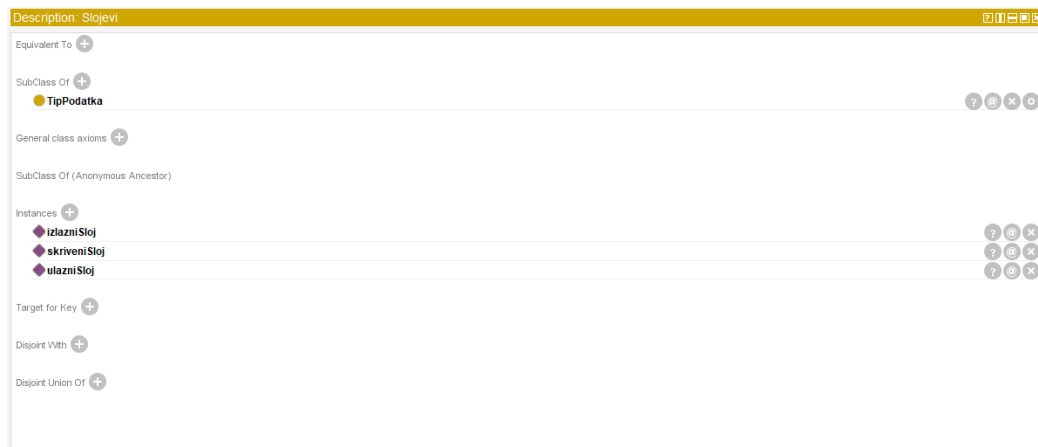
Sljedeća potklasa je *PredikcijaUcinkaStudenta* koja ima instance *aktivnaInteligencija* i *pruzanjePovratnihInformacija*. Instanca *aktivnaInteligencija* odnosi se na to da studenti kao individue moraju sami doći do određenih zaključaka vezanih uz svoje učenje i školovanje, dok se instanca *pruzanjePovratnihInformacija* odnosi na davanje određenog uvida u dosada stečeno znanje u obliku bodova, ocjena i slično. Potklasa *PristupPonasanjaPriUcenju* ima instance *identificiranjeProfilaPonasanja* i *poticanjeNaOdredenaPonasanja*. Instanca *identificiranjeProfilaPonasanja* temelji se na tome da svaki uzrok ima svoju posljedicu, odnosno na tome da kako će se student ponašati takav će rezultat i ostvariti. Primjerice, student koji je marljiv i savjestan učiti će više te će time imati i bolji rezultat na kolegiju. Instanca *poticanjeNaOdredenaPonasanja* omogućava studentu da dobije određene smjernice, podršku i resurse. Posljednja potklasa je *VizualizacijaAktivnostiUcenja* koja ima instance *pristupVizualnimElementima* koja se odnosi na kreiranje grafikona temeljenih na informacijama i podacima. Primjer toga može biti grafikon prolaznosti određenog kolegija koji je vizualna reprezentacija te analize. To je povezano s *samorefleksijom* koja je druga instanca. Ovdje se misli na samorefleksiju pomoću koje će studenti sami uvidjeti potrebu za određenom promjenom ili potrebnim naporom na nekom kolegiju. Na primjer, ako nastavnik na uvodnom predavanju kaže da je prolaznost mala na tom kolegiju, tada će student sam zaključiti da treba

uložiti više truda i napora kako bi uspio položiti navedeni kolegij. Na Slici 4. prikazan je jedan primjer opisa klasa, za klasu *Taksonomija* i njezinu potklasu *VizualnaAktivnostUcenja*.



Slika 4. Prikaz primjera instanci unutar opisa klase *VizualizacijaAktivnostiUcenja* (Izvor: vlastita snimka ekrana)

Klasa *Sudionici* ima za potklase *Nastavnici*, *Student*, *Sluzbe* i *Menadzment* svoje instance. Instance su istoimene kao i nazivi klasa, što bi značilo da potklasa *Nastavnici* ima instancu *nastavnik*, dok potklasa *Student* ima instancu *student*, potklasa *Sluzbe* instancu *sluzbe* i potklasa *Menadzment* instancu *menadzment*. Instance *nastavnik* i *student* samo su primjeri. U stvarnom svijetu, umjesto *student* pisalo bi konkretno ime i prezime studenta, dok bi umjesto *nastavnik* pisalo konkretno ime i prezime nastavnika. Isto to vrijedi i za službe i menadžment. Posljednja klasa čije potklase imaju instance je *Podatak*. Kod potklase *Slojevi* postoje tri instance, a to su *izlazniSloj*, *srednjiSloj* i *ulazniSloj*. Te instance definirane su zato što se koriste kod neuronskih mreža. Naime, neuronske mreže koriste ta tri sloja kako bi mogle raditi s podacima. Isto tako, potklasa *Varijable* ima dvije instance, a to su *nezavisneVarijable* i *zavisneaVarijable*. Taj se oblik podatka, odnosno varijabli koristi kod regresijske tehnike koja se nalazi kod prediktivne analitike. Na slici 5., prikazan je opis klase za potklasu *Slojevi* te su prikazane njezine instance.



Slika 5. Prikaz primjera instanca unutar opisa klase *Slojevi* (Izvor: vlastita snimka ekrana)

9.2. Objektna svojstva

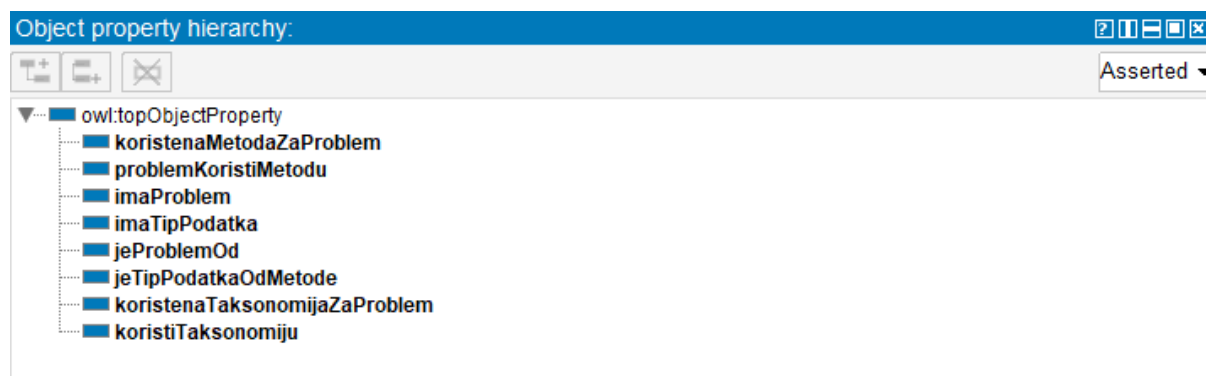
Osim što postoji hijerarhija i opis klasa, isto to postoji i za objektna svojstva. Kao i za klase, potrebno je odabrati karticu *Entities* te zatim odabrati okvir *Object properties*. Nakon toga, otvara se novi prozor koji prikazanu hijerarhiju, opis i karakteristike selektiranog objektnog svojstva.

9.2.1. Hijerarhija objektnih svojstava

Hijerarhija objektnih svojstava prikazuje hijerarhije onih svojstava koja su utvrđena i izvedena te je ona vidljiva prema postavkama koje su zadane. Kao i za klase, hijerarhija objektnih svojstava jedan je od primarnih dijelova alata *Protégé* pa samim time i ontologije. Predstavlja se isto na način kao i klasa, odnosno u obliku stabla, kog kojeg su čvorovi svojstva objekta koje može imati svoje čvorove, odnosno svoja podsvojstva objekta. [24]

Postoje opcije za dodavanje objektnih svojstava, dodavanja objektnih podsvojstava, te brisanje istih. Isto kao i kod klasa, poželjno je da se razmaci ne koriste te da se ne koriste dijakritički znakovi. Sam proces dodavanja i brisanja, jednak je kao i kod dodavanja i brisanja klasa. [27]

Unutar ontologije analitike učenja nema podsvojstva nego su definirana samo svojstva koja će se koristiti. Puno tih svojstava koristi tranzitivnost te su invertna. Primjer slike tranzitivne karakteristike i invertnog opisa svojstva bit će prikazan samo za jedno objektno svojstvo tako da se vidi na koji se način to definira unutar alata *Protégé*. Na Slici 6. prikazana je hijerarhija objektnih svojstava koja se koristi kod ove analitike. Ima ukupno osam objektnih svojstava.



Slika 6. Prikaz objektnih svojstava (Izvor: vlastita snimka ekrana)

Prvo objektno svojstvo je *koristenaMetodaZaProblem*, a ono se odnosi na metodu koja će se koristiti za postavljeni problem koji se javlja kod studenta i/ili nastavnika. Invertno svojstvo ovom svojstvu je *problemKoristiMetodu* koje se odnosi na to koji problem koristi koju metodu

da bi bio detektiran ili riješen. Primjer toga može biti da loša prolaznost *problemKoristiMetodu* dijagnostičku regresijska analiza. Time se postavlja da za navedeni problem uvijek ide ta metoda. Isto tako, ako se gleda invertno, dijagnostička regresijska analiza je *koristenaMetodaZaProblem* loše prolaznosti. Nadalje, objektno svojstvo *imaProblem* odnosi se na nekog sudionika koji može imati neki problem. To svojstvo je invertno u odnosu na svojstvo *jeProblemOd*. Primjer toga je da student *imaProblem* loših bodova, dok su loši bodovi problem studenta (*jeProblemOd*).

Potrebno je metodama pridružiti podatke s kojima one rade, pa shodno tome, postoji objektno svojstvo koje se naziva *imaPodatak*. To bi značilo da metoda ima svoju vrstu podatka. Na primjer, stablo odlučivanja *imaPodatak* grana. To bi značilo da stablo odlučivanja radi s podacima koji su definirani kao grane. Ovo svojstvo također ima svoje invertno svojstvo koje se zove *jePodatakOdMetode*. Prema tome, može se zaključiti da, grana *jePodatakOdMetode* stablo odlučivanja.

Osim što neki problem može koristiti metodu, on može koristiti i taksonomiju. Prema toj činjenici, postavljena su i dva objektna svojstva. Jedno se objektno svojstvo zove *koristiTaksonomiju* te se ono koristi kada neki problem koristi neku taksonomiju. Primjer toga može biti da problem aktivnosti *koristiTaskonomiju* aktivnosti na forumima. Isto tako, radi se o inverznom svojstvu pa se tu javlja i drugo objektno svojstvo naziva *koristenaTaksnomijaZaProblem*. Primjer toga može biti da je aktivnost na forumima *koristenaTaksonomijaZaProblem* aktivnosti.

9.2.2. Opisi objektnih svojstava


Kao i kod klasa, i za objektna svojstva postoje određeni opisi. Ti se opisi odnose na srž uređivača svojstava objekata. Pomoću njih, omogućen je pregled i uređivanje same logike koja se sakriva iza opisa svojstava selektiranog objekta. Postoji nekoliko mogućih opisa objektnih svojstava, a oni su *Equivalent To*, *SubProperty Of*, *Inverse Of*, *Domains*, *Ranges*, *Disjoint With* i *SuperProperty Of*. [28]

Equivalent To označava da selektirano objektno svojstvo ima neko objektno svojstvo koje je njemu ekvivalentno. *SubProperty Of* znači da selektirano svojstvo ima neko svoje nadsvojstvo te da je ono podsvojstveno nekog svojstva. *Inverse Of* znači da selektirano svojstvo ima neko svojstvo koje je inverzno od njega, odnosno koje je u odnosu na selektirano svojstvo u potpunosti suprotno. [28]

Domains označava da selektirano objektno svojstvo ima svaki izraz klase naveden u tom dijelu koji se nalazi u toj domeni. To bi značilo da će svaka individua koji ima vrijednost tog svojstva biti instanca klase te domene. *Ranges* znači da selektirano svojstvo ima svaki mogući izraz klase u svojem rasponu. To bi značilo da ako dano svojstvo ima danu klasu u svom rasponu, da će svaka instanca tog objektnog svojstva biti instanca te klase raspona. [28]

Disjoint With označava da je selektirano objektno svojstvo razdvojeno od svakog objektnog svojstva koje je navedeno kog tog opisa. I na poslijetku, *SubProperty Of* znači da je selektirano svojstvo zapravo nadsvojstvo svakog lanca svojstava navedenih kod ovog opisa. [28]

Unutar rada koristi se inverzno svojstvo, odnosno *Inverse Of* i domena, odnosno *Domains*. Ta se svojstva javljaju kod svakog objektnog svojstva. Unutar prethodnog podpoglavlja, opisano je koje je svojstvo inverzno kojem svojstvu. Za svojstvo *koristenaMetodaZaProblem* ima domenu *Metode* zato što je potrebno pronaći metodu koja se koristi za neki problem. Za njemu inverzno svojstvo *problemKoristiMetodu*, domena je klasa *Problemi*, jer je potrebno definirati problem za koji će se neka metoda koristiti. Kod svojstva *imaProblem* domena je klasa *Sudionici*, jer jedino sudionici mogu imati neki problem. Isto tako, inverz tog svojstva *jeProblemOd* ima za domenu klasu *Problemi*, jer mora biti definiran problem koji neki sudionik može imati. Isto tako, svojstvo *imaPodatak* za domenu ima klasu *Metode*, jer neka metoda ima svoju određenu vrstu podataka, dok inverzno svojstvo tog svojstva *jePodatakOdMetode* ima za domenu klasu *Podatak*, jer mora biti definiran podatak koji neka metoda može imati. Na poslijetku, objektno svojstvo *koristenaTaksonomijaZaProblem* ima domenu klase *Taksonomija*, jer mora biti definirana taksonomija koja će se koristiti za neki problem, pa prema tome, inverzno svojstvo tog svojstva, odnosno svojstvo *koristiTaksonomiju* ima za domenu klasu *Problemi*, jer mora biti definiran problem za koji se neka taksonomija može koristiti, to jest za koji je potrebna taksonomija da bi se problem riješio. Na Slici 7., prikazan je jedan od primjera kako je definiran inverzni opis i domena kod opisa objektnih svojstava.



Slika 7. Prikaz primjera domene i inverznog svojstva unutar opisa objektnog svojstva jeProblemOd (Izvor: vlastita snimka ekrana)

9.2.3. Karakteristike objektnih svojstava

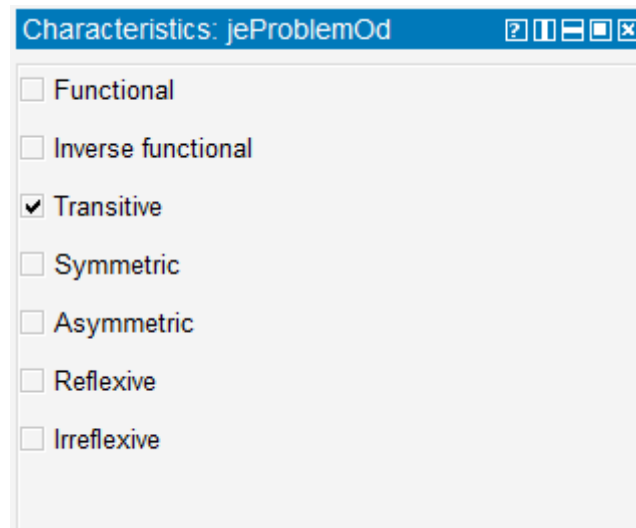
Osim što postoji opis objektnih svojstava, postoje i njihove karakteristike. One su unutar alata *Protégé* pokazane u obliku *checkboxa* te svaka od njih ima svoju funkcionalnost i značenje. Odabiru se na način da se označi kvadratić koji se nalazi ispred njih s tim da se prvo mora selektirati željeno objektno svojstvo. Karakteristike koje se javljaju u alatu jesu *Functional*, *Inverse Functional*, *Transitive*, *Symmetric*, *Asymmetric*, *Reflexive* i *Irreflexive*. U nekim slučajevima za potrebe ovog rada korištene su neke od tih karakteristika. [29]

Prva karakteristika koja se javlja na popisu istih je *Functional*. Ako se odabere ta karakteristika, to znači da je određeno svojstvo funkcionalno, dakle da svaka individuu može imati najviše jednu vrijednost. Drugim riječima, može postojati najviše jedna moguća izlazna veza na svojstvo za tu individuu. Primjer toga može biti da jedna osoba ima samo jednu majku, što bi onda značilo da osoba kao individua preko ove karakteristike može biti povezana samo s jednom majkom, kao drugom individuum. Sljedeća karakteristika je *Inverse Functional* koje označava da je svojstvo koje je inverzno selektiranom zapravo inverzna funkcija funkcionalno bez obzira na to je li eksplicitno deklarirano ili nije. To se odnosi na to da može postojati najviše jedna ulazna veza uz svojstvo selektirane individue. Primjer toga je da je svojstvo imaMajku, koje je inverzno svojstvu jeMajka, funkcionalno.. [29]

Iduća karakteristika je *Transitive*, odnosno tranzitivno svojstvo. Tranzitivnost je pojam koji se često koristi u matematici i drugim predmetima. Ono označava da ako je individua x povezana s individuum y , a individua y povezana s individuum z , onda mora i individua x biti povezana s individuum z . Primjer toga može biti da ako osoba a ima osobu b za svog pretka, a osoba b ima osobu c za svog pretka, tada i osoba a ima osobu c za svog pretka. Nakon toga slijedi karakteristika *Symmetric* kojoj je zapravo svrha da potvrdi da je neko selektirano svojstvo simetrično. To bi onda zapravo značilo da ako je individua x povezana s individuum y , onda je i individua y povezana s individuum x . Primjer toga je, na primjer, ako je neka individua u rodu s drugom, onda je i ta druga individua u rodu s prvom. [29]

Asymmetric govori da je neko selektirano svojstvo asimetrično. To je samo obrnuto od simetričnosti. Odnosno, ako je individua x povezana s individuum y , onda individua y nije povezana s individuum x tim svojstvom. Primjer toga može biti da ako je individua a majka individui b , to znači da individua b nije majka individui a . *Reflexive* označava da je neko selektirano svojstvo refleksivno. To bi značilo da je svaka individua povezana sama sa sobom preko tog svojstva. Primjer toga je da neka osoba može poznati sama sebe. Posljednja karakteristika je *Irreflexive* koja označava da je selektirano svojstvo nije refleksivno. To bi značilo da neka individua ne može biti povezana sama sa sobom. Na primjer, majka kao individua ne može sama sebi biti majka. [29]

Od karakteristika kod objektnog svojstva jedino se koristi tranzitivna karakteristika. Ona se koristi kod svih objektnih svojstava. Na primjer, ako je student povezan s nekim problemom, a taj je problem povezan s metodom kojom se može riješiti, onda je i student povezan s tom metodom, jer on mora ispraviti taj problem. Na Slici 8., prikazano je kako se selektiraju karakteristike za određena objektna svojstva.




Slika 8. Odabir karakteristike za objektno svojstvo (Izvor: vlastita snimka ekrana)

9.3. Podatkovna svojstva

Podatkovna svojstva još su jedan dio ontologije koji se često koristi. Unutar alata *Protégé* potrebno je odabrati karticu na kojoj piše *Data properties*. Ona se koristi kako bi upotpunilo znanje vezano uz neku individuu. Podatkovna svojstva rade na način da povezuju individuu s podatkovnim vrijednostima XML Scheme. Isto tako, postoje dvije vrste podatkovnih svojstava, a to su određenog ili neodređenog tipa. Podatkovna svojstva, isto kao i objektna svojstva i klase mogu dodavati i brisati i to na jednak način. Kao i za klase i za objektna svojstva, postoji isto sekcija *Description*, unutar koje se nalaze opcije *Equivalent To*, *SubProperty Of*, *Domains (intersection)*, *Ranges* i *Disjoint With*. Značenja i korištenje tih opcija jednako je kao i kod klase i objektnih svojstava. Isto tako, postoje i karakteristike, to jest, samo jedna karakteristika i to *Functional*. [30]

Unutar ovog rada, za ontologiju analitike učenja u visokom obrazovanju postoji ukupno pet podatkovnih svojstava. Podatkovna svojstva koja se koriste jesu *Prolaznost*, *BrojBodova*, *KolicinaInterakcije*, *KvalitetaMaterijala* i *RazinaAktivnosti*. Na Slici 9., prikazana su navedena podatkovna svojstva unutar alata *Protégé*. Odabrana podatkovna svojstva odabrana su kao primjer elemenata koji se mogu koristiti na temelju mojeg studetskog iskustva.



Slika 9. Popis podatkovnih svojstva unutar alata *Protégé* (Izvor: vlastita snimka ekrana)

Podatkovna svojstva koja se koriste temelje se na problemima zato što su problemi podaci koji su mjerljivi. Podatkovno svojstvo *imaBrojBodova* ima definiranu svoju domenu kao opis. Domena je klasa *Studenti*. Isto tako, definiran je i rang koji je postavljen kao cijeli broj (*xsd:int*) te može poprimiti vrijednosti od 0 do 100, gdje 0 označava da student nema uopće ostvarenih bodova, dok 100 označava da student ima ostvaren maksimalan broj bodova. Ako student ima do 33 boda, onda se to smatra lošim bodovima, ako ima do 66 onda se to smatra srednjim bodovima, a ako ima više od 66 onda se smatra da student ima odlične bodove. Nadalje, podatkovno svojstvo, *imaKolicinulInterakcije* također ima definiranu domenu *Studenti*. Isto tako, postavljen je i rang kao cijeli broj (*xsd:int*) koji može poprimiti vrijednost od 0 do 2, gdje 0 označava lošu interakciju, 1 označava srednju interakciju, a 2 odličnu interakciju. Loša interakcija se smatra interakcijom kod koje student nema nikakvu komunikaciju sa studentima i s nastavnicima, srednja interakcija se odnosi na slabu do srednju komunikaciju koja može biti u obliku pitanja vezanih za zadaće, savjete, resurse i slično, dok je odlična interakcija povezana s konstantnom interakcijom koja može biti u obliku davanja savjeta, traženja dodatnih resursa, poticanja rasprava na neku temu i tako dalje.

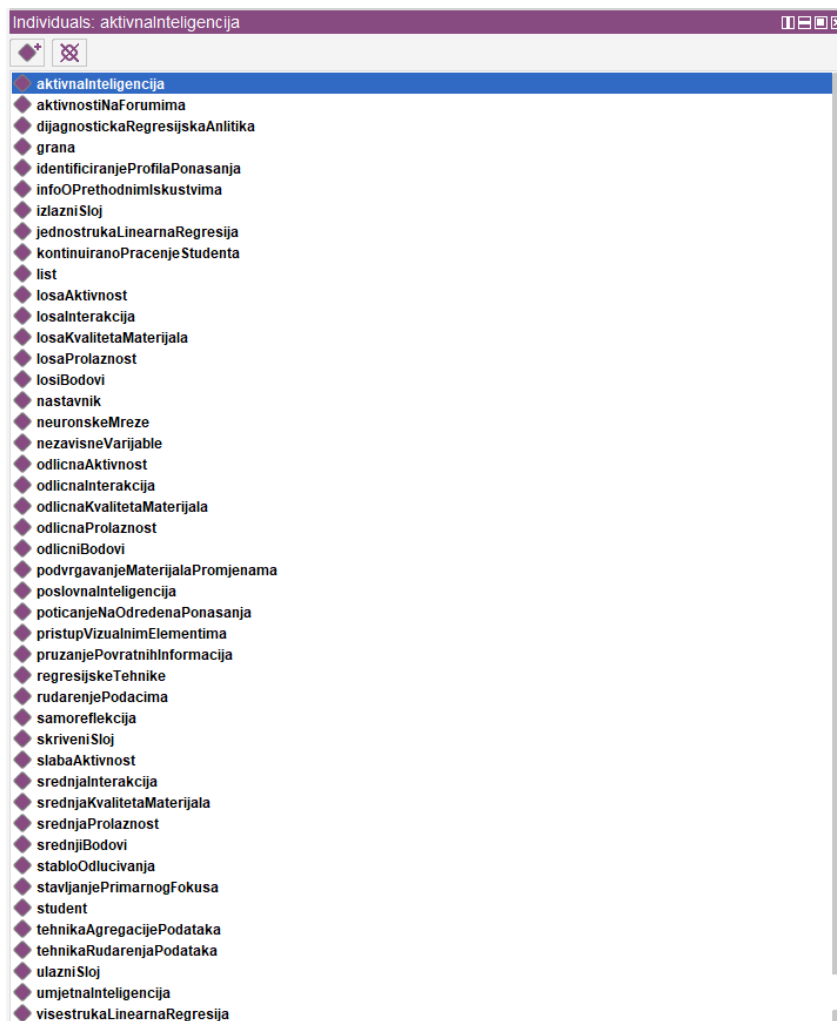
Iduće podatkovno svojstvo je *imaKvalitetuMaterijala* koja za domenu ima postavljenu klasu *Nastavnici*, a za rang ima postavljeni cijeli broj (*xsd:int*) od 0 do 2, gdje 0 označava lošu kvalitetu materijala, 1 srednju kvalitetu materijala, a 2 odličnu kvalitetu materijala. Pod lošom kvalitetom materijala smatraju se oni materijali koji nisu dovoljno dobro pojašnjeni i kojih je premalo, na primjer, pet ili manje datih materijala za učenje. Srednjom kvalitetom materijala smatraju se oni materijali koji su djelomično pojašnjeni i obrađeni te ako ih ima relativno dovoljno, na primjer od pet do 10. Odličnom kvalitetom materijala smatraju se oni materijali koji su detaljno pojašnjeni i obrađeni te kojih ima više od 10 dostupnih za učenje. Podatkovno svojstvo, *imaProlaznost*, ima zadanu domenu, koja je klasa *Nastavnici* i rang koji je cijeli broj (*xsd:int*) te je postavljen da ide od 0 do 100 gdje 0 označava nikakvu prolaznost, a 100 maksimalnu prolaznosti. Prema tome, 0 znači da niti jedan student nije položio neki kolegij, dok 100 označava da su svi studenti položili kolegij. Postoji loša prolaznosti, koja vrijedi do broja 33, što bi predstavljalo da je 33% studenata uspješno položilo kolegij, srednja prolaznost,

koja vrijedi od broja 33 do 66, odnosno da je do 66% studenata položilo kolegij, te odlična prolaznost kod koje vrijedi da je do 100% studenata položilo neki kolegij.

Posljednje podatkovno svojstvo je *imaRazinuAktivnosti* koje se odnosi na to koliko je neki student aktivan na određenom kolegiju. Za domenu je postavljena klasa *Studneti*, dok je za rang postavljen cijeli broj koji ide od 0 do 2, gdje 0 označava lošu aktivnost, 1 srednju aktivnost, a 2 odličnu aktivnost. Pod lošom se aktivnošću smatra to da student nije uopće aktivan na nastavi, forumima i slično, pod srednjom da je student djelomično aktivan, dok se pod odličnom aktivnošću smatra da je student iznimno aktivan na nastavi i na forumima. Za karakteristike podatkovnih svojstava korišteno je samo funkcionalno svojstvo zato što jedan student može imati jedan problem definiran samo jednom, na primjer, jedan student može imati samo jednu razinu aktivnosti.

9.4. Instance

Alat *Protégé* nudi opciju prikaza individua koje se smatraju instancama određene klase. Instancama se, unutar opisa, mogu pridruživati klase, one individue koje su iste ili koje su različite. Isto tako, mogu se pridruživati objektna i podatkovna svojstva koja pobliže opisuju selektiranu individuu. Za ovu ontologiju korištene su brojne individue, kao što se može vidjeti na Slici 10. Većina individua povezana je s problemima i s metodama koje se javljaju u analitici učenja u visokom obrazovanju. Bitno je naglasiti da su objektna svojstva svake instance povezana na drugu instancu. Sve individue prethodno su spomenute u radu (poglavlje s opisom klasa), a u ovom će poglavlju biti opisani detalji tih individua.



Slika 10. Popis individua u alatu *Protégé* (Izvor: vlastita snimka ekrana)

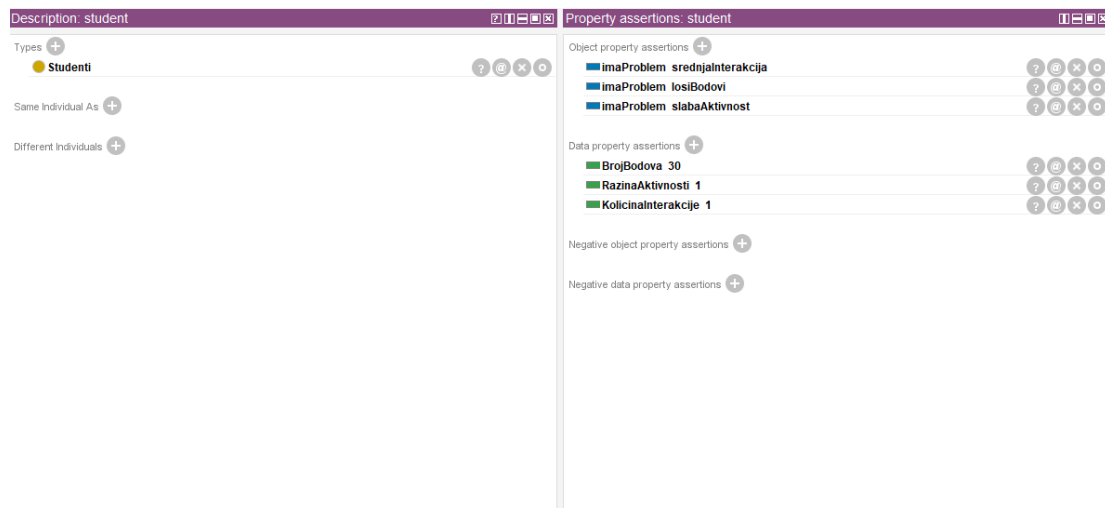
Prva individua na popisu, koja ima dodano objektno svojstvo je instanca *grana*. Objektno svojstvo koje ima dodano je *jePodatakOdMetode stabloOdlucivanja* što bi značilo da je grana podatak koji se koristi kod stabla odlučivanja. Isto takvo definirano svojstvo postoji i za instancu *list*. Isto tako, individua *stabloOdlucivanja* ima dva objektna svojstva, a to su *imaPodatak grana* i *imaPodatak list*. Iduća instanca je *izlazniSloj* te ona ima objektno svojstvo *jePodatakOdMetode neuronskeMreze* što bi značilo da je izlazni sloj vrsta podatka koji se koristi kod metode neuronske mreže. Također, instance *ulazniSloj* i *skriveniSloj* imaju isto to objektno svojstvo povezano na istu instancu metode. Instanca *losaProlaznost* ima dva objektna svojstva, a to su *jeProblemOd nastavnik*, gdje je definirano da je loša prolaznost kolegija problem od nastavnika, i *problemKoristiMetodu dijagnostickaRegresijskaAnalitika* što zapravo označava da taj problem, odnosno problem loše prolaznosti koristi metodu dijagnostičke regresijske analitike kao bi se riješio.

Instanca *losiBodovi* ima, isto tako, sva objektna svojstva, a to su *jeProblemOd student*, koji se odnosi na to da student ima ostvarene loše bodove i *problemKoristiMetodu*

dijagnostickaRegresijskaAnalitika, što bi značilo da se uzrok tog problema može pronaći pomoću te metode. Nakon toga dolazi se do instance *nastavnik* koji ima definirana dva objektna svojstva i dva podatkovna svojstva. Objektna svojstva su ista, a to je *imaProblem srednjaKvalitetaMaterijala* i *imaProblem losaProlaznost*, a to znači da nastavnik ima dva problema koja su ta da ima srednju kvalitetu materijala i lošu prolaznost na kolegiju. Podatkovna svojstva su *Prolaznost 26*, što znači da smo 26% studenta koji upišu kolegij, taj kolegij i polože i *KvalitetaMaterijala 1*, što znači da bi nastavnik trebao poraditi na kvaliteti i količini materijala koju daje studentima. Nadalje, instanca *neuronskeMreze* ima tri objektna svojstva i sva tri su *imaPodatak* na koje se vežu instance *izlazniSloj*, *ulazniSloj* i *srednjiSloj*.

Sljedeća instanca, *nezavisneVarijable* ima samo jedno objektno svojstvo, a to je *jePodatakOdMetode regresijskeTehnike* te je ovdje definirano da su nezavisne varijable vrsta podatka koji se koristi kod regresijskih tehnika. Isto objektno svojstvo vrijedi i za instancu *zavisneVarijable*. Prema tome, individua *regresijskeTehnike* ima dva objektna svojstva, a to su *imaPodatak nezavisneVarijable* i *imaPodatak zavisneVarijable*, što bi značilo da regresijske tehnike imaju zavisne i nezavisne varijable kao tipove podataka. Iduća individua je *slabaAktivnost*. Ona ima ukupno tri objektna svojstva, a to su *jeProblemOd student*, što znači da je slaba aktivnost problem od studenta, zatim *koristiTaksonomiju aktivnostiNaForumima* i *koristiTaksonomiju zakljucakNaTemeljuInterakcija*, što bi značilo da individua slaba aktivnost koristi te dvije taksonomije kako bi se taj problem poboljšao. Individua *srednjaInterakcija* koristi jedno objektno svojstvo, a to je *jeProblemOd student*, što bi značilo da je ona problem nekom studentu.

Individua *srednjaKvalitetaMaterijala* ima tri objektna svojstva, a to su *koristiTaksonomiju*, *stavljanjePrimarnogFokusa* i *koristiTaksonomiju podvrgavanjeMaterijalaPromjenama*, što znači da taj problem koristi te dvije taksonomije kao načine rješavanja. Treće objektno svojstvo je *jeProblemOd nastavnik*. Nadalje, individua *student* ima tri objektna svojstva i tri podatkovna svojstva. Sva tri objektna svojstva su *imaProblem* te to objektno svojstvo povezuje studenta s individuama *srednjaInterakcija*, *losibodovi* i *slabaAktivnost*. Podatkovna svojstva su *BrojBodova 30*, što znači da student ima ukupno ostvarenih 30 bodova, *RazinaAktivnosti 1*, što znači da je student srednje aktivan, te *KolicinaInterakcije 1*, što znači da student ima srednju komunikaciju s ostalim studentima i nastavnicima. Na Slici 11., prikazano je na koji se način dodaju domene, objektna i podatkovna svojstva za individue. Pokazan je primjer individue studenta.




Slika 11. Prikaz opisa i svojstva kod individua na primjeru individue studenta (Izvor: vlastita snimka ekrana)

9.5. Upiti

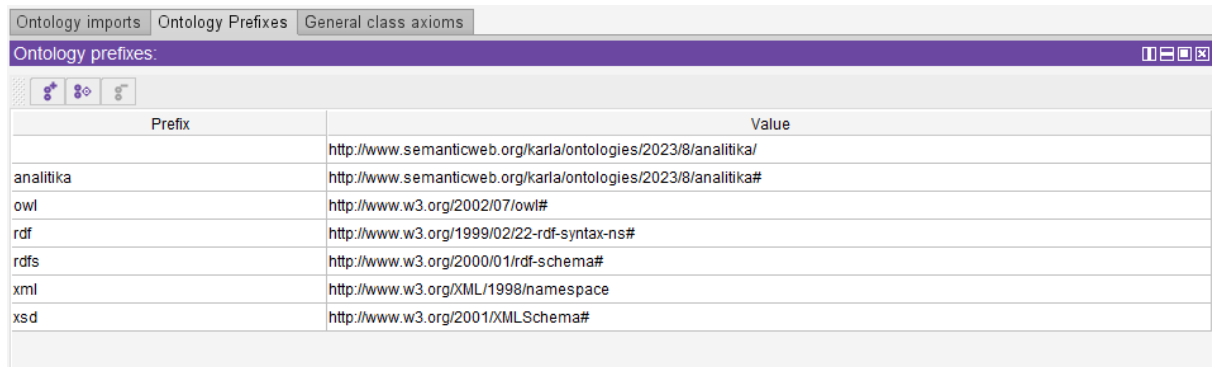
Unutar ovog rada za upite je korišten *SPARQL Query* (engl. SPARQL Protocol and RDF Query). To je jezik i protokol koji se koristi za *Linked Open Data* na webu i za *RDF* datoteke. On se u ovom primjeru koristi jer je ontologija spremljena u obliku *RDF*-a. *SPARQL* ima slične osobine kao i *SQL* jezik za postavljanje upita. Ima skup od tri uzorka koja mora svaki element upita imati, a to su subjekt, predikat i objekt. Isto tako, *SPARQL* može postaviti četiri vrste upita, a to je *ASK* kojim se provjerava postoji li neko podudaranje uzorka upita s podacima, *SELECT* koji se koristi kod pronalaženja podataka u obliku tablica te isto tako uključuje i agregaciju, paginaciju i uzrokovanje, *CONSTRUCT* koji se koristi kao zamjena *RDF* graf varijabli koje se podudaraju u skupu predložaka i *DESCRIBE* koji se koristi za pronađena podudaranja koja su konstruirana preko relevantnog *RDF* grafa. [31]

Ispod se nalaze primjeri upita napisani u *SPARQL* jeziku te je za svaki primjer upita postavljena slika da se vidi što taj upit vraća. Unutar ljsječka koda 1, prikazan je upit koji se odnosi na ispis svih metoda koje se koriste kod analitike učenja. Kod definiranja upita uvijek se mora postaviti *PREFIX* koji je povezan na ontologiju s kojom se radi. Potrebno je napisati *PREFIX* naziv_ontologije: *IRI* ontologije. *IRI* se nalazi kod kartice *Active ontology* unutar alata *Protégé*, što se vidi na Slici 12.



Slika 12. Prikaz *Ontology IRI* (Izvor: vlastita snimka ekrana)

Nakon toga, potrebno je unutar okvira *Ontology Prefixes*, koji se nalazi unutar kartice *Active ontology*, definirati prefiks aktivne ontologije koja će se koristiti za upite. To je potrebno napraviti samo jednom. Unutar stupca *Prefix* upisuje se naziv prefiksa, dok se unutar stupca *Value* upisuje *IRI* podatak aktivne ontologije. Isto tako, unutar tog dijela postoje već predefimirani prefiksi koji će se isto tako koristiti unutar upita. Navedeno je prikazano na Slici 13.



Prefix	Value
	http://www.semanticweb.org/karla/ontologies/2023/8/analitika/
analitika	http://www.semanticweb.org/karla/ontologies/2023/8/analitika#
owl	http://www.w3.org/2002/07/owl#
rdf	http://www.w3.org/1999/02/22-rdf-syntax-ns#
rdfs	http://www.w3.org/2000/01/rdf-schema#
xml	http://www.w3.org/XML/1998/namespace
xsd	http://www.w3.org/2001/XMLSchema#

Slika 13. Prikaz okvira za definiranje prefiksa (Izvor: vlastita snimka ekrana)

Unutar isječka koda 1, prikazan je upit koji se odnosi na ispis svih metoda koje se nalaze unutar ontologije. Vidljivo je da su definirani prefiksi koji su potrebni. Prefiksi *rdf*, *owl*, *rdfs* i *xsd* su predefimirani u editoru *SPARQL* upita, dok se prefiks *analitika* dodaje ručno, jer se on odnosi na navedenu ontologiju. Nakon toga, potrebno je postaviti upit. Koristi se *SELECT* kako bi se dohvatili određeni podaci. Uz *SELECT* nalazi se naziv varijable *?Metoda*, koja je ujedno i naziv tablice u ispisu. Zatim se koristi *WHERE* koji mora imati vitičaste zagrade unutar kojih se definira uvjet kojim se nešto dohvaća. Unutar vitičastih zagrada definirano je da se unutar ontologije *analitika* dohvate sve *Metode*, odnosno sve potklase (*rdfs:subClassOf*) klase *Metode*.

Isječak koda 1. Prikaz upita za ispis svih metoda

```
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX xsd: <http://www.w3.org/2001/XMLSchema#>
PREFIX analitika:
<http://www.semanticweb.org/karla/ontologies/2023/8/analitika#>
SELECT ?Metoda
WHERE {?Metoda rdfs:subClassOf analitika:Metode}
```

Na Slici 14. prikazano je kako izgleda rezultat navedenog upita, odnosno koji se podaci dobiju kada se upit izvede. Za klasu *Metode* dobivene su njezine potklase *PreskriptivnaAnalitika*, *PrediktivnaAnalitika*, *DijagnostickaAnalitika* i *DeskriptivnaAnalitika*.

Metoda
PreskriptivnaAnalitika
PrediktivnaAnalitika
DijagnostickaAnalitika
DeskriptivnaAnalitika

Slika 14. Ispis metoda (Izvor: vlastita snimka ekrana)

Idući upit koji je postavljen koristi sve iste prefikse kao i prethodni upit, pa se prema tome taj dio neće ponovo pojašnjavati, nego će se objašnjenje temeljiti na dijelu upita u kojem se radi s dohvaćanjem podataka. Unutar isječka koda 2. vidljiv je upit koji služi za ispis metoda i njihovih podataka. Način na koji se to radi jest da se unutar *SELECT* dijela upita postave dvije varijable, a u ovom su slučaju su to varijable *?Metoda* i *?Podatak*. Kao što je prije spomenuto, nazivi tih varijabli su ujedno i nazivi stupaca koji se dobivaju kod ispisa informacija iz upita. Unutar *WHERE* dijela upita postavljeno je da se žele dohvatiti individue (*rdf:type*) koje ima metoda prediktivna analitika (*analitika:PrediktivnaAnalitika*) i da se preko objektnog svojstva (*analitika:imaPodatak*) dohvaća koja je vrsta podatka za svaku individuu te metode.

Isječak koda 2. Ispis metoda i njihovih podataka

```
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX xsd: <http://www.w3.org/2001/XMLSchema#>
PREFIX analitika:
<http://www.semanticweb.org/karla/ontologies/2023/8/analitika#>

SELECT ?Metoda ?Podatak
WHERE { ?Metoda rdf:type analitika:PrediktivnaAnalitika;
analitika:imaPodatak ?Podatak }
```

Na Slici 15. prikazan je ispis podataka koji se dobivaju upitom iz isječka koda 2. Vidljivo je da se unutar stupca *Metoda* nalazi popis svih individua koje su povezane s prediktivnom analitikom, dok se unutar stupca *Podatak* nalaze podaci koji su povezani s individuama preko objektnog svojstva.

Metoda	TipPodatka
neuronskeMreze	ulazniSloj
neuronskeMreze	skriveniSloj
neuronskeMreze	izlazniSloj
stabloOdlucivanja	grana
stabloOdlucivanja	list
regresijskeTehnike	zavisneVarijable
regresijskeTehnike	nezavisneVarijable

Slika 15. Prikaz ispisa metoda i njihovih podataka (Izvor: vlastita snimka ekrana)

Unutar isječka koda 3. prikazan je dio upita koji se nalazi u isječku koda 2., odnosno samo dio kod kojeg se za određenu metodu analitike (*analitika:DeskriptivnaAnalitika*) dohvaćaju samo njezine instance (*rdf:type*).

Isječak koda 3. Ispis individua za analitiku

```

PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX xsd: <http://www.w3.org/2001/XMLSchema#>
PREFIX analitika:
<http://www.semanticweb.org/karla/ontologies/2023/8/analitika#>

SELECT ?Metoda
WHERE { ?Metoda rdf:type analitika:DeskriptivnaAnalitika}

```

Na Slici 16., prikazan je ispis individua koje se odnose na metodu deskriptivne analitike. Vidljivo je da unutar ontologije postoje samo tri individue za tu metodu, a to su *poslovnaInteligencija*, *tehnikaRudarenjaPodataka* i *tehnikaAgregacijePodataka*.

Metoda
poslovnaInteligencija
tehnikaRudarenjaPodataka
tehnikaAgregacijePodataka

Slika 16. Prikaz ispisa individua za metodu deskriptivne analitike (Izvor: vlastita snimka ekrana)

Unutar isječka koda 4. prikazan je upit koji se koristi kako bi se ispisali problemi i metode koje se mogu koristiti da bi se navedeni problem riješio. Bitno je napomenuti da se kod *SPARQL* upita mora postavljati, u ovom slučaju, upit za svaki problem posebno. Razlog tome je što se može koristiti samo jedna klasa kako bi se upit mogao postaviti. Prema tome, ovdje je korišten upit za klasu *Bodovi*. Unutar *SELECT* dijela upita definirane su dvije varijable, a to su varijable *?Problem* i *?Metoda*. Unutar *WHERE* dijela upita dohvaća se instanca klase *Bodovi*, odnosno individua (*rdf:type*) za navedenu ontologiju i klasu (*analitika:Bodovi*) te se

mora dohvatiti metoda preko objektnog svojstva kojim je individua problema povezana s individuum metode (*analitika:problemKoristiMetodu*).

Isječak koda 4. Prikaz ispisa problema i metoda koje se koriste za taj problem

```
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX xsd: <http://www.w3.org/2001/XMLSchema#>
PREFIX analitika:
<http://www.semanticweb.org/karla/ontologies/2023/8/analitika#>
SELECT ?Problem ?Metoda
WHERE { ?Problem rdf:type analitika:Bodovi; analitika:problemKoristiMetodu
?Metoda}
```

Na Slici 17. prikazan je ispis za upit koji se nalazi u isječku koda 4. Vidljivo je da postoje dva stupca *Problem* i *Metoda*. Unutar stupca *Problem* ispisan je problem koji se tražio, dok je unutar stupca *Metoda* ispisan metoda koja se može koristiti kako bi se taj problem riješio. Ovdje je vidljivo da je za problem loših bodova korisna metoda dijagnostička regresijska analitika.

	Problem	Metoda
lošiBodovi		dijagnostickaRegresijskaAnlitika

Slika 17. Prikaz ispisa problema i metoda koje se koriste za taj problem

Unutar isječka koda 5., napravljen je upit kojim se prikazuje koje probleme ima neki student. Početni dio, odnosno dio s prefiksima jednak je kao i u prethodnim upitima. Unutar *SELECT* dijela postavljene su dvije varijable, a to su *?Student* i *?Problem*. To znači da će kod ispisa podataka biti definirana dva stupca, a to su *Student* i *Problem*. Unutar *WHERE* dijela upita definirano je da se treba ispisati individua (*rdf:type*) klase *Studenti* za navedenu ontologiju (*analitika:Studenti*) te da se za individuu studenta još mora ispisati problem koji je povezan s tim studentom (*analitika:imaProblem*).

Isječak koda 5. Problemi koje ima student

```
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
```

```

PREFIX xsd: <http://www.w3.org/2001/XMLSchema#>

PREFIX analitika:
<http://www.semanticweb.org/karla/ontologies/2023/8/analitika#>

SELECT ?Student ?Problem
WHERE { ?Student rdf:type analitika:Studenti; analitika:imaProblem
?Problem}

```

Na Slici 18. prikazan je ispis koji se dobije iz prethodnog upita. Dakle, postoje dva stupca i to su stupci *Student* i *Problem*. Unutar stupca *Student* nalazi se instanca *student*. Ona je ispisana tri puta, jer za jednu instancu postoje tri problema. Unutar stupca *Problem* ispisani su problemi s kojima se susreće neki student, a to su *srednjaInterakcija*, *slabaAktivnost* i *losiBodovi*.

Student	Problem
student	srednjaInterakcija
student	slabaAktivnost
student	losiBodovi

Slika 18. Prikaz ispisa problema vezanih uz studenta (Izvor: vlastita snimka ekrana)

Unutar isječka koda 6. nalazi se upit za popis taksonomija. Upit je gotovo jednak upitu za ispis metoda. Unutar *SELECT* dijela upita, definirana je jedna varijabla i to je varijabla *?Taksonomija*. Unutar *WHERE* dijela upita nalazi se dio kojim se, preko klase *Taksonomija* za navedenu ontologiju (*analitika:Taksonomija*), dohvaća popis potklasa (*rdfs:subClassOf*).

Isječak koda 6. Ispis popisa taksonomija

```

PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>

PREFIX owl: <http://www.w3.org/2002/07/owl#>

PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>

PREFIX xsd: <http://www.w3.org/2001/XMLSchema#>

PREFIX analitika:
<http://www.semanticweb.org/karla/ontologies/2023/8/analitika#>

SELECT ?Taksonomija
WHERE { ?Taksonomija rdfs:subClassOf analitika:Taksonomija}

```

Na Slici 19. prikazan je ispis koji se dobije kada se izvrši upit koji se nalazi u isječku koda 6. Vidljivo je da postoji samo jedan stupac i to je stupac *Taksonomija*. Isto tako, vidljivo je da se unutar njega nalaze sve tražene potklase za taksonomiju, a to su *PristupPonasanjaPriUcenju*, *PredikcijaUcinkaStudenta*, *VizualizacijaAktivnostiUcenja*, *PoboljsanjeMaterijalaAlataZaUcenje*, *IndividualiziranoUcenje* i *OcjeneSocijalnogUcenja*.

Taksonomija
PristupPonasanjaPriUcenju
PredikcijaUcinkaStudenta
VizualizacijaAktivnostiUcenja
PoboljsanjeMaterijalaAlataZaUcenje
IndividualiziranoUcenje
OcjeneSocijalnogUcenja

Slika 19. Prikaz ispisa taksonomija (Izvor: vlastita snimka ekrana)

Unutar isječka koda 7. nalazi se upit koji služi za ispisivanje individue za postavljenu taksonomiju. Unutar *SELECT* dijela upita nalazi se samo jedna varijabla i to je *?Taksonomija*. Unutar *WHERE* dijela upita, postavljeno je da se traži individua (*rdf:type*) za taksonomiju vizualizacija aktivnosti učenja (*analitka:VizalizacijaAktivnostiUcenja*).

Isječak koda 7. Ispis individua taksonomije

```
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX xsd: <http://www.w3.org/2001/XMLSchema#>
PREFIX analitika:
<http://www.semanticweb.org/karla/ontologies/2023/8/analitika#>
SELECT ?Taksonomija
WHERE { ?Taksonomija rdf:type analitika:VizualizacijaAktivnostiUcenja }
```

Na Slici 20. prikazan je ispis za prethodni upit. Vidljivo je da je samo jedan stupac i to je stupac Taksonomija. Isto tako vidljivo je da za klasu vizualizacija aktivnosti učenja, postoje dvije instance, a to su *pristupVizualnimElementima* i *samorefleksija*.

Taksonomija
pristupVizualnimElementima
samorefleksija

Slika 20. Prikaz ispisa individua za taksonomiju vizualizacije aktivnosti učenja (Izvor: vlastita snimka ekrana)

Posljednji upit koji je kreiran prikazan je unutar isječka koda 8. To je upit kojim se dobiva ispis individua problema i koje taksonomije ti problemi mogu koristiti. Unutar *SELECT* upita postavljene su dvije varijable, *?Problem* i *?Taksonomija*. Unutar *WHERE* upita potrebno je definirati da se traže individue (*rdf:type*) unutar ontologije (*analitika:Aktivnost*). Individue su povezane pomoću objektnog svojstva (*analitika:koristiTaksonomiju*), odnosno svaki problem je povezan s taksonomijom kao mogućim rješenjem.

Isječak koda 8. Ispis problema i taksonomije koja se koristi za taj problem

```
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX xsd: <http://www.w3.org/2001/XMLSchema#>
PREFIX analitika:
<http://www.semanticweb.org/karla/ontologies/2023/8/analitika#>
SELECT ?Problem ?Taksonomija
WHERE { ?Problem rdf:type analitika:Aktivnost; analitika:koristiTaksonomiju
?Taksonomija}
```

Na Slici 21., prikazan je ispis problema i ispis taksonomije koja se koristi za navedeni problem. Situacija je ista kao i kod problema i metoda. U jednom trenutku, samo se za jedan problem može postaviti upit i mogu se dobiti instance taksonomija samo za taj jedan problem. Vidljivo je da postoje dva stupca, a to su *Problem* i *Taksonomija*. Unutar stupca *Problem* ispisana je individua problema, dok je unutar stupca *Taksonomija* ispisana individua taksonomije koja se koristi za taj problem.

Problem	Taksonomija
slabaAktivnost	zakljucakNaTemeljulInterakcija
slabaAktivnost	aktivnostiNaForumima

Slika 21. Prikaz ispisa problema i taksonomija koje se koriste za taj problem

10. Zaključak

Analitika učenja u visokom obrazovanju sadrži metode koje su temelj za unapređenje svakog obrazovnog sustava. Upravo iz tog razloga, analitika učenja sadrži metode kojima se dolazi do rješenja nekog problema. Metode koje se koriste jesu deskriptivna analitika, dijagnostička analitika, prediktivna analitika i preskriptivna analitika. Osim toga, postoji i taksonomija koja se koristi kako bi se došlo do poboljšanja. Treći aspekt koji je iznimno bitan su koraci unapređenja koji se temelje na *Data wire* principu. Koraci su podijeljeni u tri kategorije, a to su priprema, proučavanje i djelovanje.

Osim što je bitno da analitika učenja u visokom obrazovanju ima metode rješavanja problema, ona mora imati i sudionike koji će imati određeni problem te sudionike koji će obradom i analizom podataka doći do rješenja i zaključaka. Sudionici su studenti, nastavnici i uprava. Problemi koji se najčešće javljaju kod studenata jesu loši bodovi, loše ocijene, slaba interakcija i aktivnost te mala prolaznost kolegija. Kod učitelja, problemi koji se javljaju jesu slaba kvaliteta materijala, loša kvaliteta održavanja nastave te veliki postotak neprolaznosti studenata na kolegiju. Uprava, kao sudionik, služi da bi zajedno s ostalim sudionicima, došla do rješenja problema koji se javljaju i to tako da je rješenje u skladu s pravilima ustanove u kojoj se sudionici nalaze. Isto tako, moraju se koristiti i određeni alati kako bi se metode mogle primijeniti. Najčešće se koristi *Moodle* koji služi za prikupljanje podataka, a zatim *Canvas* koji služi za analizu prikupljenih podataka. Ontologija se u ovom radu javlja, kako bi se analitika učenja mogla jasnije prikazati i razumjeti. Ona je izrađena u alatu *Protégé* te su dani primjeri mogućih problema kod studenata i nastavnika. Ontologijom se postiglo da se na jednom mjestu nalazi znanje o domeni analitike učenja. Nakon izrade ontologije, smatram da bi se analitika učenja mogla poboljšati na način, da se strogo definiraju metode i pravila koja se moraju koristiti kod provođenja procesa poboljšanja u visokom obrazovanju. Trenutno postoji nekoliko metoda, taksonomije, koraci unapređenja i tako dalje, ali smatram da bi se svi ti elementi trebali ujediniti u jednu strukturu koja bi bila opće prihvatljiva za analitiku učenja i unapređenje.

Ontologija je korisna zato što sumira sve bitne informacije na jednom mjestu te se pomoću nje može točno odrediti koji bi mogao biti sljedeći korak kod unapređenja općenito, a u ovom slučaju, kod unapređenja analitike učenja. Na posljetku, može se doći do zaključka da ontologija analitike učenja u visokom obrazovanju, uvelike može koristiti za poboljšanje kvalitete rada pa tako i samog obrazovanja, na način da detektira nedostatke, rizike i probleme, te da teži ka pronalasku rješenja i poboljšanju cijelog sustava.

Popis literature

- [1] „Learning analytics“ (16.03.2023.). Valamis [Na internetu]. Dostupno: <https://www.valamis.com/hub/learning-analytics> [pristupano 24.07.2023.].
- [2] Ye, D. The History and Development of Learning Analytics in Learning, Design, & Technology Field. *TechTrends* 66, 607–615 (2022). [Na internetu] Dostupno: Springer link, <http://www.springer.com/> [pristupano 24.07.2023.].
- [3] „What is Descriptive Analytics?“ (14.03.2023.). Valamis [Na internetu]. Dostupno: <https://www.valamis.com/hub/descriptive-analytics> [pristupano: 24.07.2023.].
- [4] Tableau (bez dat.) *Business intelligence: A complete overview* [Na internetu]. Dostupno: <https://www.tableau.com/learn/articles/business-intelligence> [pristupano: 24.07.2023.].
- [5] C. Cote, „What is diagnostic analytics? 4 examples“, 2021. [Na internetu]. Dostupno: <https://online.hbs.edu/blog/post/diagnostic-analytics> [pristupano: 25.07.2023.].
- [6] „What is Predictive Analytics?“ (15.03.2023.). Valamis [Na internetu]. Dostupno: <https://www.valamis.com/hub/predictive-analytics> [pristupano: 25.07.2023.].
- [7] A. Saini, „Decision Tree Algorithm – A Complete Guide“, 2021. [Na internetu]. Dostupno: <https://www.analyticsvidhya.com/blog/2021/08/decision-tree-algorithm> [pristupano: 25.07.2023.].
- [8] S. Ray, „7 Regression Techniques You Should Know!“, 2023. [Na internetu]. Dostupno: <https://www.analyticsvidhya.com/blog/2015/08/comprehensive-guide-regression/> [pristupano: 26.07.2023.].
- [9] H. Warudkar, „Prediction using Neural Networks“, 2020. [Na internetu]. Dostupno: <https://www.expressanalytics.com/blog/neural-networks-prediction/> [pristupano: 26.07.2023.].
- [10] „What is Prescriptive Analytics?“ (20.03.2019.). Valamis [Na internetu]. Dostupno: <https://www.valamis.com/hub/prescriptive-analytics> [pristupano: 27.07.2023.].
- [11] S. Arora, „AI analytics explained: How it works and key industry use cases“, 2023. [Na internetu]. Dostupno: <https://www.thoughtspot.com/data-trends/ai/ai-analytics> [pristupano: 28.07.2023.].
- [12] N. Sclater, A. Peasgood, i J. Mullan. "Learning analytics in higher education." *London: Jisc. Accessed February 8.2017* (2016): 176. [Na internetu] Dostupno: Jisc, https://www.jisc.ac.uk/sites/default/files/learning-analytics-in-he-v2_0.pdf [pristupano: 28.07.2023.].

- [13] C. Lang, et al., eds. *Handbook of learning analytics*. New York: SOLAR, Society for Learning Analytics and Research, 2017.
- [14] UW–Madison Information Technology (bez. dat) *Learning Analytics Center for Excellence (LACE)* [Na internetu]. Dostupno: <https://it.wisc.edu/academic-technology/learning-analytics-center-for-excellence-lace/> [pristupano: 29.07.2023.].
- [15] S. Quay i M. Lockwood. "Sustaining a continuous improvement culture in educator preparation: A higher education network based on data wise." *Journal of Practitioner Research* 4.1 (2019): 3. Dostupno: <https://digitalcommons.usf.edu/jpr/vol4/iss1/3/> [pristupano: 30.07.2023.].
- [16] K. Parker Boudett, E. A. City, R. J. Murnane, „The Data Wise Improvement Process – Eight steps for using test data to improve teaching and learning“, 2006. [Na internetu]. Dostupno: <https://www.nesacenter.org/uploaded/conferences/FTI/2011/handouts/RussellDataWiseArticle.pdf> [pristupano: 30.07.2023.].
- [17] M. E. Oberman, K. P. Boudett, „Eight Steps to Become Data Wise“, 2015. [Na internetu] Dostupno: <https://www.ascd.org/el/articles/eight-steps-to-becoming-data-wise> [pristupano: 30.07.2023]
- [18] S. Yassine, S. Kadry i M. -A. Sicilia, "A framework for learning analytics in moodle for assessing course outcomes," *2016 IEEE Global Engineering Education Conference (EDUCON)*, Abu Dhabi, United Arab Emirates, 2016, pp. 261-266, Dostupno: <https://ieeexplore.ieee.org/abstract/document/7474563> [pristupano: 12.09.2023.].
- [19] A. Kühn, R. Joppen, F. Reinhart, D. Röltgen, S. von Enzberg i R. Dumitrescu, „Analytics Canvas – A Framework for the Design and Specification of Data Analytics Projects“, *Procedia CIRP*, 2018, pp. 162-167, Dostupno: <https://www.sciencedirect.com/science/article/pii/S2212827118301549> [pristupano: 12.09.2023.]
- [20] Analytics Canvas (bez. dat) *Google Analytics Data Management for UA and GA4* [Na internetu]. Dostupno: <https://analyticscanvas.com/> [pristupano: 12.09.2023.].
- [21] Hrvatska enciklopedija (bez. dat) *Ontologija* [Na internetu]. Dostupno: <https://www.enciklopedija.hr/ontologija#> [pristupano: 31.07.2023.].
- [22] Gruber T, „Ontology“, *Encyclopedia of Database Systems*, 2008. [Na internetu]. Dostupno: <http://web.dfc.unibo.it/buzzetti/IUcorso2007-08/mdidattici/ontology-definition-2007.htm> [pristupano: 17.09.2023.].
- [23] Stancin, K., Posic, P. & Jaksic, D. Ontologies in education – state of the art. *Educ Inf Technol* **25**, 5301–5320 (2020). [Na internetu] Dostupno: Springer link, <https://link.springer.com/article/10.1007/s10639-020-10226-z> [pristupano: 06.09.2023.].

- [24] The Board of Trustees of the Leland Stanford Junior University *Protégé* (Verzija 5.6.1.) (2023.) [Desktop aplikacija]. Dostupno: <https://protege.stanford.edu/software.php>
- [25] *Protégé 5* Documentation (bez. dat) *Class Hierarchy* [Na internetu]. Dostupno: <http://protegeproject.github.io/protege/views/class-hierarchy/> [pristupano: 06.09.2023.]
- [26] *Protégé 5* Documentation (bez. dat) *Class Description* [Na internetu]. Dostupno: <http://protegeproject.github.io/protege/views/class-description/> [pristupano: 06.09.2023.]
- [27] *Protégé 5* Documentation (bez. dat) *Object Property Hieratchy* [Na internetu]. Dostupno: <http://protegeproject.github.io/protege/views/object-property-hierarchy/> [pristupano: 06.09.2023.]
- [28] *Protégé 5* Documentation (bez. dat) *Object Property Description* [Na internetu]. Dostupno: <http://protegeproject.github.io/protege/views/object-property-description/> [pristupano: 06.09.2023.]
- [29] *Protégé 5* Documentation (bez. dat) *Object Property Characteristics* [Na internetu]. Dostupno: <http://protegeproject.github.io/protege/views/object-property-characteristics/> [pristupano: 06.09.2023.]
- [30] *Protégé 5* Documentation (bez. dat) *Data Property Hieratchy* [Na internetu]. Dostupno: <http://protegeproject.github.io/protege/views/data-property-hierarchy/> [pristupano: 07.09.2023.]
- [31] Ontotext (bez. dat) *What is SPARQL?* [Na internetu]. Dostupno: <https://www.ontotext.com/knowledgehub/fundamentals/what-is-sparql/> [pristupano: 13.09.2023.]

Popis slika

Slika 1. Prikaz hijerarhije klasa (Izvor: vlastita snimka ekrana)	27
Slika 2. Prikaz primjera instanci unutar opisa klase PrediktivnaAnalitika (Izvor: vlastita snimka ekrana).....	29
Slika 3. Prikaz primjera instanci unutar opisa klase Bodovi (Izvor: vlastita snimka ekrana)...	29
Slika 4. Prikaz primjera instanci unutar opisa klase VizualizacijaAktivnostiUcenja (Izvor: vlastita snimka ekrana).....	31
Slika 5. Prikaz primjera instanca unutar opisa klase Slojevi (Izvor: vlastita snimka ekrana) ..	31
Slika 6. Prikaz objektnih svojstava (Izvor: vlastita snimka ekrana).....	32
Slika 7. Prikaz primjera domene i inverznog svojstva unutar opisa objektnog svojstva jeProblemOd (Izvor: vlastita snimka ekrana)	34
Slika 8. Odabir karakteristike za objektno svojstvo (Izvor: vlastita snimka ekrana)	36
Slika 9. Popis podatkovnih svojstva unutar alata <i>Protégé</i> (Izvor: vlastita snimka ekrana)	37
Slika 10. Popis individua u alatu <i>Protégé</i> (Izvor: vlastita snimka ekrana).....	39
Slika 11. Prikaz opisa i svojstva kod individua na primjeru individue studenta (Izvor: vlastita snimka ekrana).....	41
Slika 12. Prikaz <i>Ontology IRI</i> (Izvor: vlastita snimka ekrana)	41
Slika 14. Ispis metoda (Izvor: vlastita snimka ekrana).....	43
Slika 15. Prikaz ispisa metoda i njihovih podataka (Izvor: vlastita snimka ekrana).....	44
Slika 16. Prikaz ispisa individua za metodu deskriptivne analitike (Izvor: vlastita snimka ekrana) 44	
Slika 17. Prikaz ispisa problema i metoda koje se koriste za taj problem.....	45
Slika 18. Prikaz ispisa problema vezanih uz studenta (Izvor: vlastita snimka ekrana).....	46
Slika 19. Prikaz ispisa taksonomija (Izvor: vlastita snimka ekrana)	47
Slika 20. Prikaz ispisa individua za taksonomiju vizualizacije aktivnosti učenja (Izvor: vlastita snimka ekrana).....	47
Slika 21. Prikaz ispisa problema i taksonomija koje se koriste za taj problem.....	48

Popis tablica

Tablica 1. Sažeti prikaz metoda.....	12
Tablica 2. Sažeti prikaz taksonomije analitike učenja	17