

Dr. sc. Marijana Zekić-Sušac,
Ekonomski fakultet u Osijeku

Anita Frajman-Jakšić, univ. spec. asistent,
Nataša Drvenkar univ. spec. asistent,
Ekonomski fakultet u Osijeku

UDK 007:378.14(497.5)
Prethodno priopćenje

NEURONSKE MREŽE I STABLA ODLUČIVANJA ZA PREDVIĐANJE USPJEŠNOSTI STUDIRANJA

SAŽETAK

Rad se bavi kreiranjem modela za predviđanje uspješnosti studenata s pomoću neuronskih mreža i klasifikacijskih stabala odlučivanja, te analizom čimbenika koji utječu na uspješnost studenata. Kreiran je model koji na temelju demografskih podataka o studentima, te podacima o njihovom ponašanju i stavovima prema učenju nastoji klasificirati studenta u jednu od dviju kategorija uspješnosti. Uspješnost je mjerena prosjekom ocjena na studiju. Trenirano je i testirano više različitih arhitektura neuronskih mreža, čiji je najbolji model dobiven s pomoću višeslojne perceptron mreže. Stabla odlučivanja dala su znatno veću točnost klasifikacije od neuronskih mreža, te ih se predlaže koristiti kao točniju metodu na promatranom skupu podataka. Analiza osjetljivosti izlaznih varijabli na ulazne provedena kod neuronskih mreža upućuje da su kolokviranje, prisustvo na vježbama, važnost ocjene za studenta, te stipendije među najznačajnijim čimbenicima uspješnosti studenta. Stabla odlučivanja izlučila su vrijeme provedeno u učenju, prisustvo na vježbama, te vrstu materijala iz kojih se uči kao najznačajnije varijable. U budućim istraživanjima, uz proširenje broja ulaznih varijabli i povećanje uzorka, te proširenje metodologije drugih tehnikama umjetne inteligencije i statističkim metodama, moguće bi bilo kreirati uspješniji model koji bi bio osnova za izgradnju sustava za potporu odlučivanju u visokom obrazovanju.

KLJUČNE RIJEČI

analiza osjetljivosti, neuronske mreže, stabla odlučivanja, višeslojni perceptron, uspješnost studiranja

1. Uvod

Za visokoobrazovne ustanove analiza uspješnosti studiranja vrlo je važna jer strategijsko planiranje studijskih programa ovisi o tome da li program treba povećati ili održati postojeću uspješnost studenata ako je ona zadovoljavajuća (Oladokun i dr., 2008). Uspješnost studiranja na fakultetima do sada je uglavnom istraživana u cilju pronalazjenja prosječnih ocjena, duljine studiranja i sličnih pokazatelja, dok čimbenici koji utječu na postizanje uspjeha nisu dovoljno istraženi. Postoje razvijeni modeli za predviđanje uspješnosti koji će pomoći pri odluci o prihvatanju kandidata za upis na studij (Wilson i Hardgrave, 1995) koji uglavnom uključuju demografske podatke o studentima, a čiji autori naglašavaju značaj uključivanja i drugih informacija o aplikantima. Cilj ovog rada je pronaći važne čimbenike koji utječu na uspjeh studenata mjeren prosječnom ocjenom. Kao metodologija upotrijebljene su dvije metode rudarenja podataka pogodne za klasifikaciju: umjetne neuronske mreže i stabla odlučivanja. Neuronske mreže su u brojnim područjima pokazale uspjeh u rješavanju problema predviđanja, aproksimacije funkcija, klasifikacije i prepoznavanja uzoraka. Njihova točnost uspoređena je sa stablima odlučivanja kako bi se izlučio model koji daje točniju klasifikaciju studenata. Rad se temelji na anketnom istraživanju provedenom na studentima Ekonomskog fakulteta u Osijeku 2005./2006. akademske godine, pri čemu su osim demografskih podataka o studentima prikupljeni i podaci o njihovom uspjehu. Na temelju tih podataka kreiran je kauzalni model s demografskim i drugim karakteristikama studenata kao ulaznim varijablama, te prosječnom ocjenom u prethodnoj akademskoj godini kao izlaznom varijablom. Analiza osjetljivosti provedena nakon treniranja i testiranja neuronskih mreža, te analiza značajnosti varijabli provedena kod stabala odlučivanja ukazuju na jačinu utjecaja pojedine ulazne varijable na uspjeh studenata, čime je moguće donijeti zaključak o mogućim prediktorima uspješnosti studiranja. Rad se sastoji od prikaza upotrijebljene metodologije, pregleda prethodnih istraživanja u tom području, te od prikaza rezultata i zaključka sa smjernicama za daljnja istraživanja.


2. Metodologija

2.1. Metodologija umjetnih neuronskih mreža

Umjetne neuronske mreže pripadaju u inteligentne metode rudarenja podataka (eng. data mininga), čiji je cilj pronaći skrivene veze među podacima. Osim neuronskih mreža, za otkrivanje veza među podacima često se koriste i različite statističke metode (npr. višestruka regresija, diskriminantna analiza, clustering), genetički algoritmi, stabla odlučivanja i druge metode (Panian, Klepac, 2003). Umjetna neuronska mreža je međusobno povezana nakupina jednostavnih elemenata obrade, jedinica ili čvorova, čiji se rad temelji na načinu djelovanja neurona kod živih bića. Sposobnost obrade mreže je posljedica jačine veza među tim jedinicama, a postiže se kroz proces adaptacije ili učenjem iz skupa primjera za učenje (Russell, Norvig, 2005). Drugim riječima, neuronske mreže su programi ili hardverski sklopovi koji, najčešće iterativnim postupkom iz prošlih podataka nastoje pronaći vezu između ulaznih i izlaznih varijabli modela, kako bi se za nove ulazne varijable dobila vrijednost izlaza. Umjetni je neuron jedinica za obradu podataka (varijabli) koja prima ponderirane ulazne vrijednosti od drugih varijabli, prema nekoj formuli transformira primljenu vrijednost te šalje izlaz drugim varijablama. Učenje se odvija promjenom vrijednosti "težina" među varijablama (težine wji su ponderi kojima se množe ulazne vrijednosti u neki "neuron"). S obzirom na broj slojeva, tip učenja, tip veze između neurona, veza između ulaznih i izlaznih podataka, ulazne i prijenosne funkcije, namjenu, razlikuju se brojni algoritmi neuronskih mreža. Zbog njegove opće namjene (budući da je pogodan i za probleme predviđanja i klasifikacije), te učestale upotrebe u istraživanjima, za modeliranje je korišten algoritam višeslojni perceptron. Višeslojni perceptron pripada u nadgledane algoritme s vezom unaprijed (eng. feed forward), u kojoj se slojevi mreže povezuju na način da signali putuju samo u jednom smjeru, od ulaza ka izlazima mreže. Najpoznatiji i najčešće upotrebljavani algoritam primijenjen za učenje i treniranje višeslojnih perceptron mreža je tzv. mreža "širenje unatrag" (eng. backpropagation). Al-

goritam mreže “širenje unatrag” bio je presudan za široku komercijalnu upotrebu ove metodologije, te je neuronske mreže učinio široko upotrebljavanom i popularnom metodom u različitim područjima. Standardni algoritam mreže “širenje unatrag” uključuje optimizaciju greške koristeći deterministički algoritam gradijentnog opadanja (eng. gradient

Arhitektura testirane neuronske mreže sastojala se od tri sloja. Broj jedinica (neurona) u skrivenom sloju i duljina učenja dobiveni su postupkom unakrsne validacije. Izgradnja modela provedena je kroz tri faze (Eris, 2008: (a) priprema podataka i modeliranje, (b) treniranje i testiranje neuronskih mreža, (c) tumačenje rezultata neuronskih mreže i



Slika 1. Arhitektura mreže “širenje unatrag” (Zekić-Sušac, 2000)

descent) (Masters, 1995). Glavni nedostatak ovog algoritma je problem čestog pronalaženja lokalnog umjesto globalnog minimuma greške, stoga novija istraživanja uključuju njegovo unapređivanje nekim drugim determinističkim (npr. metode drugoga reda) ili stohastičkim metodama (npr. simulirano kaljenje). Strukturu mreže čine ulazni sloj, izlazni sloj i najmanje jedan skriveni sloj s vezom unaprijed. Tipična arhitektura “širenje unatrag” prikazana je na Slici 1 (zbog preglednosti je prikazan samo 1 skriveni sloj, kojih može biti i više).

izbor najboljeg modela. Treniranje mreže odvijalo se na uzorku za treniranje (60% ukupnog uzorka), duljina učenja mreže dobivena je postupkom unakrsne validacije, pri čemu mreža u iterativnom postupku uči na uzorku za treniranje koristeći različite parametre (npr. različit broj skrivenih neurona), a svaka kombinacija se testira na uzorku za validaciju (20% ukupnog uzorka). Cilj je pronaći onu duljinu učenja i strukturu mreže koji daju najbolji rezultat na uzorku za validaciju. Na kraju se tako dobivena mreža testira na uzorku za testiranje (20% ukupnog

uzorka), a dobiveni rezultat nakon faze testiranja korišten je kao mjerilo uspješnosti mreže.

Od izlaznih funkcija testirane su sigmoidna i tangens hiperbolna funkcija, dok je kao pravilo učenja korišteno delta pravilo s momentumom 0.7 i dinamičkim koeficijentom učenja od 0.1 do 0.9 prema formuli:

$$\Delta w_{ji}^{t(k)} = \eta_k \cdot y_{cy} \cdot \varepsilon_i + \alpha_k \Delta w_{ji}^{t-1}$$

gdje je η koeficijent učenja, α momentum, a w_{ji} razlike u težinama između neurona j i neurona i , y_{cy} je output izračunat u mreži, dok je ε greška.

Za izračunavanje greške neuronske mreže u fazi treniranja najčešće se koriste srednja kvadratna greška (eng. mean square error – MSE) ili korijen srednje kvadratne greške (RMSE) (Masters, 1995). U radu je korištena MSE greška prema formuli (Masters, 1995):

$$MSE = \frac{1}{n} \sum_{i=0}^{n-1} (y_d - y_c)^2$$

gdje je n veličina uzorka za testiranje, y_d je stvarna (željena) vrijednost izlazne varijable, dok je y_c izračunata vrijednost izlazne varijable. Budući da je u radu promatran problem klasifikacije, nakon faze testiranja neuronske mreže izračunava se stopa klasifikacije za svaku klasu pojedinačno, te prosječna stopa klasifikacije, koja se uzima kao mjerilo ocjenjivanja uspješnosti modela neuronske mreže. Stopa klasifikacije za pojedinu klasu je postotak slučajeva koji je mreža ispravno stavila u tu klasu. Npr. stopa od 75% znači da je 75% slučajeva ispravno klasificirano, dok je 25% slučajeva stavljeno u pogrešnu klasu. Prosječna stopa klasifikacije izračunava se prema formuli:

$$C = \frac{\sum_{i=1}^k c_i}{k}$$

gdje je c_i stopa klasifikacije dobivena za klasu i , dok je k broj klasa u modelu, u našem slučaju $k=2$.

2.2. Metodologija stabala odlučivanja

U cilju izgradnje što uspješnijeg modela, na promatranom uzorku testirana je još jedna neparametrijska metoda rudarenja podataka: stabla odlučivanja, točnije njihova podvrsta klasifikacijska i regresijska stabla (eng. Classification And Regression Trees – CART). Ovom metodom dobiva se grafički prikaz modela utjecaja ulaznih varijabli na izlaznu, koja je izražena u obliku klasa ili kategorija. Svaki čvor u grafičkom stablu predstavlja jednu ulaznu varijablu, na čijim su rubovima označena „djeca-čvorovi“ za svaku moguću vrijednost neke ulazne varijable. Svaki list u stablu predstavlja vrijednost ciljane (izlazne) varijable ako su dane vrijednosti ulaznih varijabli predstavljene putom od korijena stabla do tog lista. Stablo se dobiva „učenjem“ na podacima, na način da se vrši grananje (eng. splitting) izvornog skupa podataka u podskupove na temelju testiranja vrijednosti varijabli. Proces se ponavlja na svakom izvedenom podskupu na rekursivni način (eng. recursive partitioning). Rekurzija je završena kada podskup određenog čvora ima sve iste vrijednosti izlazne varijable, ili kada daljnje grananje više ne pridonosi poboljšanju rezultata (Witten, Frank, 2000).

Za izgradnju stabla korišten je CART algoritam prema Breiman et al. (u Witten i Frank, 2000), koji na temelju raspoloživih podataka o ulaznim i izlaznim varijablama kreira binarno stablo grananjem slogova u svakom čvoru prema funkciji određenoj za svaku ulaznu varijablu. Evaluacijska funkcija korištena za prijelom je Gini indeks (IG), definiran

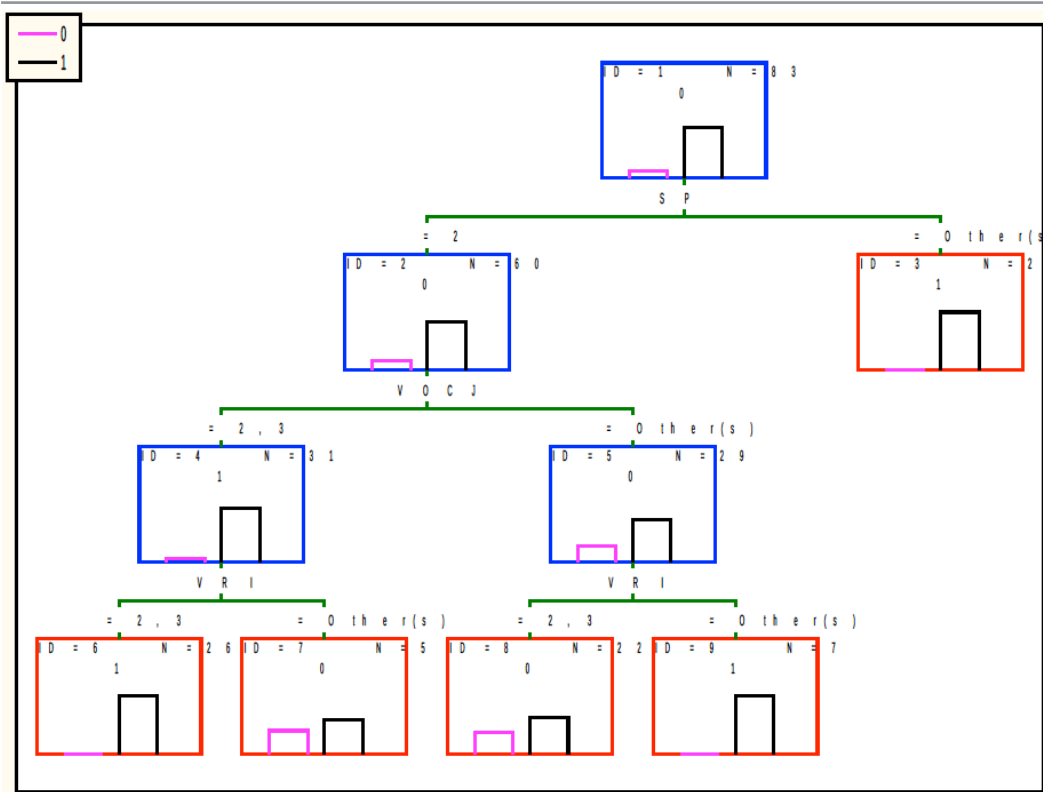
prema formuli (Apte, 1997):

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

gdje je t trenutni čvor, P_i je vjerojatnost klase i u čvoru t , a m je broj klasa u modelu (u našem slučaju $m = 2$).

Algoritam CART uzima u obzir sva moguća grananja kako bi pronašao najbolje grananje za točnost modela. Najbolje grananje određuje se za svaki atribut u svakom čvoru, a pobjednik se izabire s pomoću Gini indeksa. Algoritam može uspješno raditi s kontinuiranim i kategorijalnim varijablama. Stablo raste sve dok se ne pronađe novo grananje koje poboljšava uspješnost stabla u razdvajanju slo-

gova u klase. Budući da svako sljedeće grananje ima na raspolaganju manje reprezentativnu populaciju, potrebno je smanjivati stablo (eng. pruning), kako bi se dobilo točnija klasifikacija. Cilj je identificirati one grane koje omogućuju najmanje prediktivne sposobnosti po listu u grani, kako bi ih se izbacilo iz stabla. U proceduri smanjivanja stabla (pruning) skupovi grana smanjivani su u odnosu na početno kompletno stablo odlučivanja, što je procedura slična eliminiranju prediktora u diskriminantnoj analizi. Na kraju je izabrano stablo odgovarajuće veličine s obzirom na točnost klasifikacije. Pri tome se uzima u obzir odnos složenosti stabla i veličine greške (Breiman et al. 1984 u Galindo, Tamayo, 2000). Pobjedničko podstablo se odabire na temelju ukupne greške (stope pogrešne klasifikacije) dobivene kada se model primijeni na testnom uzorku



Slika 2. Grafički prikaz kreiranog stabla odlučivanja

(Berry i Linoff, 1997).

Stablo u ovom radu kreirano je na temelju 8 ulaznih kategorijalnih varijabli, pri čemu su korištene sljedeće vrijednosti parametara za izbor najpogodnijeg stabla: (1) minimalni broj slučajeva koji kontrolira u kojem će se trenutku zaustaviti izbor prijeloma i započeti procedura pruning-a postavljen je na 16, (2) jednake prethodne vjerojatnosti za obje klase studenata, (3) kao pravilo zaustavljanja korištena je stopa pogrešne klasifikacije. Nakon 3-fold unakrsne validacije, izabrano je najbolje klasifikacijsko stablo, koje je na kraju primijenjeno na testnom uzorku (istom uzorku na kojem su konačno testirane i neuronske mreže) radi dobivanja uvida u mogućnosti generalizacije modela na novim podacima, ali i usporedbe uspješnosti modela stabla odlučivanja i neuronskih mreža.

Struktura konačnog stabla odlučivanja dobivenog za promatrane podatke prikazana je na Slici 2.

3. Pregled prethodnih istraživanja

Istraživanja u području upotrebe inteligentnih metoda za predviđanje uspješnosti studenata uglavnom su orijentirana na razvoj modela koji će se koristiti kao pomoć pri odluci o primanju studenata na studij (Hardgrave, Wilson, 1994; Naik i Ragotthaman, 2004). Takvi modeli kao kriterije uzimaju u obzir informacije o kandidatu koje su raspoložive prije upisa, kao npr. završena srednja škola, uspjeh u srednjoj školi, socijalni status i druge informacije prije studija, te s pomoću statističkih metoda ili metoda umjetne inteligencije nastoje pronaći model koji će producirati što veću točnost u predviđanju.

Iako se neuronske mreže učestalo desetljećima uspješno koriste u brojnim područjima, posebno nakon pojave višeslojne perceptron mreže (Masters, 1995), za koju je dokazano da može aproksimirati bilo koju kontinuiranu funkciju, u obrazovanju su inteligentne metode više usmjerene na razvoj tutorskih sustava, a manje na razvoj prediktivnih modela uspješnosti studiranja. Jedni od prvih autora u tom području koji koriste neuronske mreže su Hardgrave i dr. (1994) koji uspoređuju neuronske mreže i tradicionalne statističke tehnike u predviđanju uspješnosti studenata na diplomskom studiju.

Daljnji rad istih autora (Wilson, Hardgrave, 1995) naglašava kako se odluka o tome da li primiti nekog studenta na diplomski studij temelji na brojnim čimbenicima, te je nužno razviti prediktivne modele koji će omogućiti nekom fakultetu upisivanje onih studenata za koje je vrlo vjerojatno da će studirati uspješno. Wilson i Hardgrave pokazuju da regresijska analiza nije dovoljno učinkovita u predviđanju uspjeha ili neuspjeha studenta, pa pored regresije testiraju i metode klasifikacije, poput diskriminativne analize, logističke regresije i neuronskih mreža. Njihovo istraživanje pokazuje sljedeće: (a) klasifikacijske tehnike su pogodnije za predviđanje uspjeha studenata od prediktivnih metoda, (b) predviđanje uspjeha ili neuspjeha studenata na diplomskom studiju nije dovoljno točno ako se koriste samo tipični podaci koji opisuju studenta, i (c) neparametrijske procedure, kao što su neuronske mreže, produciraju barem jednako točan rezultat kao i tradicionalne metode i vrijedan su potencijal za daljnja istraživanja u tom području. Istim problemom odluke o prihvaćanju kandidata na studij bavili su se i Naik i Ragotthaman (2004), koji su istraživali uspješnost na MBA studiju. Koristili su neuronske mreže, logit i probit modele za predviđanje uspješnosti studenta koji se upiše na MBA studij. Neuronske su mreže klasificirale studente u uspješne i neuspješne na temelju njihova prosjeka ocjena na preddiplomskom studiju, rezultatima GMAT testa, smjera na preddiplomskom studiju, starosti i drugih varijabli. Rezultati pokazuju da su neuronske mreže jednako uspješne kao i ostale tehnike, ali ih zbog brojnih prednosti preporučuju za upotrebu u tom području. Istraživanje Sulaimana i Mohezara (2006) bavi se istom tematikom, ali ide korak dalje u izlučivanju ključnih čimbenika uspješnosti. Njihov model pokazao je da je dosadašnji prosjek ocjena studenta najznačajniji prediktor njegove daljnje uspješnosti, dok varijable poput starosti, etničke skupine, spola, te godina radnog iskustva nisu značajne za uspješnost studiranja. Shulruf i dr. (2008) proučavali su korelacije između dobivenih pokazatelja od strane New Zealand National Certificate of Educational Achievement (NCEA), standardnih kvalifikacija studenata, te prosjeka ocjena postignutog na prvoj godini studija na jednom velikom sveučilištu u

Novom Zelandu. Nakon toga su usporedili rezultate dobivene za Novi Zeland s onima dobivenima na Cambridge International Examinations [CIE], zatim s međunarodnim sustavom standarda koji je usvojen na Novom Zelandu, te sa sveučilišnim prosjecima ocjena studenata koji su upisani na temelju tih kvalifikacija. U istraživanju također procjenjuju alternativne modele za donošenje odluke o upisu na studij, te njihove implikacije na različite grupe studenata. Najbolji model koji su dobili daje prednost izvrsnosti i mjerodavnosti rezultata NCEA. Autori predlažu kombinaciju takvog modela i standardnih kvalifikacija koja će osigurati bolje rezultate na studiju.

Zaidah i Daliela (2007) usporedili su neuronske mreže, stabla odlučivanja i linearnu regresijsku analizu u predviđanju uspješnosti studenata. Uspjeh su mjerili kumulativnim prosjekom ocjena kroz studij, a kao ulazne varijable koristili su demografski profil studenata i prosjek ocjena na prvom semestru preddiplomskog studija. Rezultati pokazuju da su sve tri metode proizvele točnosti veću od 80%, dok neuronske mreže daju veću točnost od ostalih dviju metoda. Oladokun i dr. (2008) koristili su neuronske mreže za predviđanje uspješnosti studenata na Sveučilištu Ibadan u Nigeriji. Koristili su višeslojnu perceptron mrežu, koja je na testnom uzorku točno predvidjela uspjeh kod 74% studenata. Kao ulazne varijable korištene su ocjene, kombinacija izbornih kolegija, uspjeh na testovima, starost pri upisu, obrazovanje roditelja, tip i lokacija završene srednje škole, spol i slično. Izlazna varijabla izražena je kroz tri kategorije uspjeha: dobar, prosječni, slab. Relevantnost pojedinih inputa nije analizirana.

Iz navedenog pregleda prethodnih istraživanja može se zaključiti da u većini slučajeva neuronske mreže pokazuju veću ili jednaku točnost od statističkih metoda u predviđanju uspješnosti studiranja, te da stoga postoji opravdanost za upotrebu ove metodologije, posebno klasifikacijskih algoritama. Izbor varijabli za model ovisi o obrazovnim sustavima zemalja u kojima su provedena istraživanja, te je važno testirati metodologiju za svaki uzorak podataka. Posebnu pažnju treba posvetiti analizi značajnosti pojedinih čimbenika u modelu, koja nije u dovoljnoj mjeri prisutna u prethodnim istraživanjima.

4. Opis podataka i modela

Podaci za model prikupljeni su putem anketnog istraživanja provedenog na Ekonomskom fakultetu u Osijeku akademske 2005./2006. godine među studentima druge, treće i četvrte studijske godine, u sklopu istraživanja Borozan i Dabić (2008). Nakon eliminiranja nepotpunih podataka, uzorak je obuhvatio 165 studenata koji su se u vrijeme provođenja istraživanja zatekli na predavanjima. Kreiran je kauzalni model uspješnosti studiranja, pri čemu je uspjeh kao izlazna varijabla mjeren prosječnom

ocjenom iz svih kolegija u prethodnoj akademskoj godini. Kao ulaz u model upotrijebljeno je 8 varijabli čiji su nazivi i deskriptivna statistika prikazani u Tablici 1.

Izlazna varijabla - prosjek ocjena studenta u prethodnoj studijskoj godini izražena je kroz dvije kategorije ili klase kodirane na sljedeći način: kategorija 0 - prosjek manji ili jednak 3 („lošiji“ studenti), te kategorija 1 - prosjek veći od 3 („bolji“ studenti). Takvom formulacijom izlazne varijable problem se svrstava u problem klasifikacije, gdje je cilj modela naučiti prepoznati koji studenti pripadaju u klasu

Tablica 1. Ulazne varijable modela i njihova deskriptivna statistika

Rb	Naziv varijable i oznaka	Opis varijable	Kodiranje i frekvencije
1	Spol (SP)	Spol studenta	1 – muški (24,85%) 2 – ženski (75,15%)
2	Stipendija (STIP)	Stipendija studenta	1 – ne prima stipendiju (67,27%) 2 – povremeno prima stipendiju (1,21%) 3 – prima stipendiju (31,52%)
3	Vrijeme (VRI)	Koliko prosječno vremena dnevno posvećuje učenju	1 – do jedan sat (16,36%) 2 – dva do tri sata (44,85%) 3 – tri do pet sati (32,73%) 4 – više od pet sati (6,06%)
4	Materijali (MAT)	Ispitni materijali iz kojih se najviše uči	1 – knjiga profesora (18,79%) 2 – skripta drugih studenata (26,06%) 3 – bilježnica s predavanja (9,70%) 4 – skripta koju je student sam napravio ili doradio (9,09%) 5 – sve što je studentu na raspolaganju (36,36%)
5	Kolokviranje (KOL)	Izlazak studenta na kolokvije kada nisu obavezni	1 – da (81,21%) 2 – uglavnom (17,58%) 3 – ne (1,21%)
6	Predavanja (PRED)	Učestalost prisustva na predavanja	1 – do 25% (6,67%) 2 – od 26 do 50% (12,73%) 3 – od 51 do 75% (24,85%) 4 – od 76 do 100% (55,76%)
7	Vježbe (VJ)	Učestalost prisustva na vježbama	1 – do 25% (18,18%) 2 – od 26 do 50% (13,33%) 3 – od 51 do 75% (22,42%) 4 – od 76 do 100% (46,06%)
8	Važna ocjena (VOCJ)	Studentu je važna visina ocjene koju dobije na ispitu	1 – potpuno se ne slažem (15,15%) 2 – ne slažem se (11,52%) 3 – neutralno (38,18%) 4 – slažem se (23,64%) 5 – u potpunosti se slažem (11,52%)

s prosjekom manjim ili jednakim 3, a koji u klasu s većim prosjekom od 3, te identificirati značajke studenta koje su važne za ispravnu klasifikaciju.

Prije kreiranja neuronskih mreža napravljeno je uzorkovanje podataka, na način da je ukupan uzorak podataka podijeljen na tri dijela: (1) poduzorak za treniranje, (2) poduzorak za unakrsnu validaciju, te (3) poduzorak za testiranje mreže. Podjela ukupnog uzorka na poduzorke vođena je činjenicom da neuronske mreže zahtijevaju jednaku raspodjelu klasa u uzorku za treniranje i unakrsnu validaciju. S obzirom na to da je u ukupnom uzorku bilo više „boljih“ od „lošijih“ studenata (ukupno 114 „boljih“ i 51 „lošijih“), struktura triju poduzoraka prema udjelu pojedinih kategorija studenata prikazana je u tablici 2.

Iz tablice 2 vidljivo je da je zadržana jednaka raspodjela obje kategorije (0 i 1) u poduzorcima za treniranje i unakrsnu validaciju, dok su svi preostali ispitanici (njih 83) smješteni u uzorak za konačno testiranje modela. Izbor ispitanika u prva dva poduzorka izvršeno je na slučajan način, pod uvjetom da je sačuvana jednaka raspodjela dviju kategorija ispitanika.

5. Rezultati

5.1. Rezultati točnosti klasifikacije neuronskih mreža i stabala odlučivanja

U radu je trenirano i testirano više arhitektura neuronskih mreža dobivenih promjenom topologije mreže (broja skrivenih neurona), prijenosnih funkcija, te pravila učenja. Za svaku arhitekturu dobivena je stopa ispravne klasifikacije za svaku klasu na uzorku za treniranje i testiranje. Kao mjerilo uspješnosti modela korištena je prosječna stopa klasifikacije na uzorku za testiranje prethodno opisana u odjeljku 3. Rezultati dobiveni za najbolju i najlošiju testiranu mrežnu arhitekturu prikazani su u tablici 3.

Najbolja prosječna stopa klasifikacije na uzorku za testiranje postignuta je mrežom pod rednim brojem 1 u Tablici 3, a iznosi 66,26%. Pri tome su u neuronskoj mreži korištena 33 skrivena neurona, logistic prijenosna funkcija, delta-bar-delta pravilo učenja, a mreža je učila na najviše 1000 epoha. Broj skrivenih neurona koji daje najmanju grešku u fazi unakrsne validacije bio je 33. Dobiveni rezultat znači da je u uzorku za testiranje 66,26% slučajeva bilo ispravno klasificirano, dok je 33,74% slučajeva stav-

Tablica 2. Struktura ukupnog uzorka i poduzoraka

Poduzorak	0 – „lošiji“ studenti	1 – „bolji“ studenti	Ukupno
Treniranje	31 (50,00%)	31 (50,00%)	
Unakrsna validacija	10 (50,00%)	10 (50,00%)	20 (100,00%)
Testiranje	10 (12,05%)	73 (87,95%)	83 (100,00%)
Ukupno	51 (30,90%)	114 (69,10%)	165 (100,00%)

Tablica 3. Rezultati metode neuronskih mreža i stabala odlučivanja na uzorku za testiranje

Rb	Metoda	Broj skrivenih neurona	Prijenosna funkcija	Stopa klasifikacije za klasu 0 (%)	Stopa klasifikacije za klasu 1 (%)	Prosječna stopa klasifikacije (%)
1	MLP neuronska mreža	2-50 (33)	Logistic	60,00	67,00	66,26
2	MLP neuronska mreža	2-50 (15)	Tangh	80,00	45,00	62,50
3	RBFN neuronska mreža	2-50 ()	Gaussian	0,00	100,00	50,00

* 0 = postotak ispravne klasifikacije za studente s prosjekom ocjena manjim ili jednakim 3
1 = postotak ispravne klasifikacije za studente s prosjekom ocjena većim od 3

ljeno u pogrešnu klasu. Ako se pogledaju posebne stope klasifikacije za svaku klasu pojedinačno, tada je vidljivo da stopa klasifikacije za klasu 0 („lošije“ studente), iznosi 60,00%, dok je stopa klasifikacije za klasu 1, tj. za „bolje“ studente 67,00%. Veća točnost klasifikacije za „bolje“ studente ukazuje na to da studenti koji imaju prosjek viši od 3 imaju zajedničke karakteristike koje model neuronske mreže uspijeva prepoznati i povezati uspješnije nego što je to slučaj kod studenata s prosjekom manjim od 3.

Rezultati dobiveni drugom metodom, CART stablima odlučivanja, prikazani su u Tablici 4.

Iz tablice 4 vidljivo je da je prosječna stopa klasifikacije koju daje stablo odlučivanja 88,36% što je više od prosječne stope klasifikacije dobivene s pomoću najboljeg modela neuronskih mreža (66,26%). Stablo je posebno točno pri prepoznavanju „lošijih“ studenata s nižim prosjekom ocjena od 3, gdje je stopa ispravne klasifikacije jednaka 100%. Nešto je niža stopa klasifikacije za klasu 1 - „boljih“ studenata (76,71%), ali je i ta stopa pokazuje da stabla odlučivanja uspijevaju točnije prepoznati i „lošije“ i „bolje“ studente od najboljeg modela neuronskih mreža. U cilju ispitivanja statističke značajnosti razlike između dva modela, statističkim t-testom razlike između dviju proporcija uspoređena je prosječna stopa klasifikacije najboljeg modela neuronskih mreža i modela stabla odlučivanja. T-test pokazuje

da je razlika znatna na razini 5% ($p=0.004$, $N=83$). Iz navedenog se može zaključiti da je model stabla odlučivanja znatno točniji od modela neuronskih mreža u klasifikaciji studenata prema uspjehu na promatranom uzorku podataka.

Rezultat klasifikacije studenata od strane stabla odlučivanja na poduzorku za testiranje može se ilustrirati i s pomoću matrice konfuzije, koja u stupcima prikazuje stvarni broj studenata koji pripada u kategoriju s nižim (0) ili višim (1) prosjekom, dok je u redcima prikazan broj studenata koje je model stabla odlučivanja svrstao u kategoriju 0 ili 1. Na dijagonali matrice konfuzije moguće je vidjeti broj studenata koje je model ispravno klasificirao.

Tablica 5 prikazuje matricu konfuzije na poduzorku za testiranje (koji broji ukupno 83 slučaja). Iz tablice je vidljivo da od ukupno 10 studenata s nižim prosjekom (kategorija 0), stablo odlučivanja uspijeva svih 10 studenata svrstati u ispravnu kategoriju. S kategorijom 1 situacija je drugačija. Model neuronske mreže uspijeva 56 studenata svrstati ispravno, dok je 17 stvarno „boljih“ studenata pogrešno svrstava u kategoriju „lošijih“ proizvođači postotak točnosti za tu klasu od 76,71%. Ukupan broj ispravno klasificiranih studenata prikazan je na dijagonali i iznosi 66 studenata od ukupno 83 studenata u poduzorku za testiranje koji se koristi za ocjenu uspješnosti modela.

Tablica 4. Rezultati metode stabala odlučivanja na uzorku za testiranje

Algoritam stabla odlučivanja	Goodness of fit	Stopa klasifikacije za klasu 0 (%)	Stopa klasifikacije za klasu 1 (%)	Prosječna stopa klasifikacije (%)
CART	Gini	100,00	76,71	88,36

* 0 = postotak ispravne klasifikacije za studente s prosjekom ocjena manjim ili jednakim 3

1 = postotak ispravne klasifikacije za studente s prosjekom ocjena većim od 3


Tablica 5. Matrica konfuzije najboljeg modela stabla odlučivanja

Predviđena kategorija studenata	Stvarna kategorija studenata		Ukupno
	0	1	
0	10	17	27
1	0	56	56
Ukupno	10	73	83

5.2. Analiza značajnosti ulaznih varijabli

Kako bi se dobio detaljniji uvid u značaj ulaznih varijabli modela, tj. uvid u značajnost pojedinih čimbenika uspješnosti studenata, za najbolju neuronsku mrežu, kao i za stablo odlučivanja izvršena je

istim intenzitetom kao i varijabla VJ (učestalost pohađanja vježbi), zatim redom slijede varijable: VOCJ (važnost ocjene), STIP (primanje stipendije), MAT (materijali iz kojih se uči), PRED (učestalost pohađanja predavanja). Najmanji utjecaj u modelu ima varijabla SP (spol). Analiza osjetljivosti poka-



Slika 3. Grafički prikaz osjetljivosti izlazne varijable na ulazne varijable u modelu najbolje neuronske mreže

analiza osjetljivosti pri kojoj se analizira utjecaj pojedine ulazne varijable modela na izlazne varijable. Na Slici 3 grafički je prikazana značajnost pojedine ulazne varijable modela najbolje neuronske mreže, kroz koeficijente osjetljivosti izlazne varijable na ulazne.

Grafikon na slici 3 prikazuje vrijednosti promjene izlazne varijable ako se pojedina ulazna varijabla promijeni za jednu jedinicu. Vidljivo je da varijabla KOL (kolokviranje) najviše utječe na output, gotovo

zuje da su redovit izlazak na kolokvije i redovito pohađanje vježbi najutjecajnije varijable pomoću kojih se može predvidjeti uspješnost studiranja u modelu neuronske mreže.

S ciljem izlučivanja najznačajnijih prediktora kod modela stabla odlučivanja provedena je nešto drugačija analiza značajnosti ulaznih varijabli omogućena kroz stabla odlučivanja, čiji su rezultati prikazani numerički u tablici 6, te grafički na slici 4. Ova analiza se temelji na zbrajanju vrijednosti koefi-

Tablica 6. Značajnost ulaznih varijabli kod stabala odlučivanja

Oznaka varijable	Rang varijable	Koeficijent značajnosti varijable
VRI	100	1.000000
VJ	74	0.741237
MAT	53	0.527794
VOCJ	47	0.467645
PRED	43	0.433490
STIP	27	0.272415
SP	20	0.195935
KOL	19	0.189504

cijenata nečistoće (delta) kroz sve varijable (čvorove) u stablu, te rangiranju varijabli u odnosu prema najvećoj dobivenoj sumi među svim prediktorima, tj. u odnosu prema najznačajnijoj varijabli.

Analiza pokazuje da je kod modela stabla odlučivanja daleko najznačajnija varijabla VRI (vrijeme provedeno u učenju), zatim po značajnosti slijede: VJ (učestalost pohađanja vježbi) i MAT (vrsta materijala iz kojih student uči) koje imaju koeficijent značajnosti veći od 0.5. Nešto manji koeficijent značajnosti imaju varijable VOCJ (važnost ocjene za studenta), PRED (učestalost pohađanja predavanja), a na kraju su po značaju varijable STIP (primanje stipendije), SP (spol), te KOL (izlasci na kolokvije).

Zanimljivo je uočiti da se rang lista varijabli po značajnosti razlikuje kod modela neuronskih mreža i modela stabla odlučivanja. S obzirom na to da su stabla odlučivanja pokazala znatno bolji rezultat u klasifikaciji studenata prema uspjehu, može se zaključiti da je vrijeme koje student uloži u učenje, pohađanje vježbi i vrsta materijala iz kojih uči jako važno za predviđanje uspješnosti studenata na promatranom uzorku.

Provedene analize osjetljivosti i značajnosti varijabli mogu se koristiti za daljnje poboljšanje obaju modela na način da se u modelu ostave samo značajnije varijable, a izbacite iz modela one manje značajne, ali i kao smjernica donositeljima odluka ukazujući na varijable na koje treba više obratiti pažnju pri predviđanju uspješnosti studiranja. Za analizu čimbenika koji najviše utječu na uspješnost, osim same identifikacije glavnih prediktora važno je napraviti i post-analizu u smislu identificiranja utjecaja različitih vrijednosti obilježja na output, npr. otkrivanje karakteristika studenata koji su uspješniji, te onih koji su manje uspješni. Za provedbu ove analize moguće je dodatno analizirati stablo odlučivanja, te provesti statističke metode analize varijance i druge.

6. Zaključak

Rad se bavi kreiranjem modela za predviđanje uspješnosti studenata i analizom čimbenika koji utječu na uspješnost. Kao metodološka osnova korištene su metode rudarenja podataka umjetne neuronske mreže i stabla odlučivanja, čija je uspješnost dokazana u brojnim problemskim područjima.

S pomoću općenitog algoritma višeslojni perceptron kreiran je inicijalni model koji producira zasad nezadovoljavajuću točnost predviđanja za praktičnu upotrebu, ali predstavlja osnovu za daljnja istraživanja u tom području. Model temeljen na stablima odlučivanja pokazao je znatno veću točnost klasifikacije od neuronskih mreža, ukazujući da su stabla odlučivanja uspješnija metoda u predviđanju uspješnosti studenata na promatranom skupu podataka. S obzirom na relativno mali broj ulaznih varijabli i limitiranost uzorka korištenog u ovom radu, točnost predviđanja modela neuronske mreže mogla bi se unaprijediti uvođenjem dodatnog broja ulaznih varijabli i povećanjem uzorka, posebno uključivanjem drugih fakulteta, što bi omogućilo veći stupanj generalizacije rezultata. Analiza čimbenika uspješnosti pokazala je da je vrijeme provedeno u učenju, prisutnost na vježbama, vrsta materijala iz kojih se uči, te važnost dobivene ocjene za studenta među najznačajnijim prediktorima uspješnosti studenta. Veća točnost predviđanja dobivena je kod studenata s prosjekom ocjena nižim od 3, što upućuje na mogućnost dizajniranja zasebnih modela za studente čije su ocjene ispod prosjeka i za one čije su ocjene iznad prosjeka.

Potencijalne koristi modela koji će uspjeti s velikom točnošću predvidjeti uspješnost studenta i ekstrahirati ključne čimbenike uspješnosti velike su, no model dobiven u ovom radu tek je početak za dublje istraživanje ove problematike. Model je nužno poboljšati i prilagoditi potrebama korisnika, tj. ustanove koja s pomoću modela uspješnosti želi donositi odluke o primanju studenata ili učenika u svoju ustanovu, ali i planiranju strategijskog razvoja studijskih programa. Npr. u mjerila uspješnosti studiranja potrebno je uključiti mjerila o ishodima učenja, što još nije dotaknuto u ovom radu. Također bi u daljnjim istraživanjima bilo od koristi usporediti metodologiju neuronskih mreža s drugim metodama rudarenja podataka, kao npr. genetičkim algoritmima, ali i statističkim metodama, te provesti dublje analize ovisnosti izlaznih varijabli s čimbenicima koji su ekstrahirani kao značajniji. Ovakve bi analize mogle dovesti do kreiranja inteligentnog sustava za potporu odlučivanju u obrazovanju, koji bi doprinio većoj uspješnosti studenata i kvaliteti studiranja u cjelini.

LITERATURA

1. Apte C, Weiss S., *Data Mining with Decision Trees and Decision Rules. Future Generation Computer Systems*, Vol. 13, 1997., str. 197-210.
2. Berry MJA, Linoff G., *Data Mining Techniques for Marketing, Sales and Customer Support*. John Wiley & Sons, Inc.: New York, Toronto, 1997.
3. Dalbelo-Bašić, B., Čupić, M., Šnajder, J., *Umjetne neuronske mreže, Nastavni materijali za kolegij Umjetna inteligencija, Fakultet elektrotehnike i računarstva Zagreb*, 2008., www.fer.hr/predmet/umjint/materijali, 09.10.2008.
4. Borozan, Đ., Dabić, M.: *Entrepreneur's attitudes as a preference of future job vision: an empirical evaluation and implications for teaching // An Enterprise Odyssey: Tourism- Governance and Entrepreneurship / Galetić, Lovorka ; Čavlek, Nevenka (ur.). Zagreb, : Sveučilišna tiskara, do.o., Zagreb, 2008., str. 329-342.*
5. ERIS, Edukacijski Repozitorij za Intelligentne Sustave: Neuronske mreže, www.eris.foi.hr/oprojektu.html, 10.01.2008.
6. Hardgrave, B.C., Wilson, R.L., Kent, K.A.: *Predicting Graduate Student Success: A Comparison of Neural Networks and Traditional Techniques. Computers & Operations Research*, 21, 1994., pp. 249-263.
7. Klepac, G., *Primjena inteligentnih računalnih metoda u managementu, Sinergija Zagreb*, 2001.
8. Masters, T., *Advanced Algorithms for Neural Networks, A C++ Sourcebook*, John Wiley & Sons, 1995.
9. Mišljenčević, D., Maršić, I., *Umjetna inteligencija, Školska knjiga Zagreb*, 1991.
10. Naik, B., Ragothaman, S., *Using Neural Networks to Predict MBA Student Success, College Student Journal*, Vol. 38, No. 1, 2004, pp.143-150.
11. Oladokun, V.O., Adebanjo, A. T., Charles-Owaba, O.E., *Predicting Students' Academic Performance using Artificial Neural Network, A Case Study of an Engineering Course, The Pacific Journal of Science and Technology*, Vol. 9. No. 1., 2008, str. 72-79.
12. Panian, Ž., Klepac, G., *Poslovna inteligencija, Masmmedia Zagreb*, 2003.
13. Russell, S.J., Norvig, P., *Artificial Intelligence, A Modern Approach, 2nd edition*, New York, Prentice Hall, 2002.
14. Shulruf, B., Hattie, J., Tumen, S., *The Predictability of Enrolment and First-Year University Results from Secondary School Performance, The New Zealand National Certificate of Educational Achievement, Studies in Higher Education*, Vol. 33, No. 6, 2008., str. 685-698,
15. Sulaiman, A., Mohezar, S., *Student Success Factors, Identifying Key Predictors, Journal of Education for Business*, Vol. 81, No. 6, 2006., str. 328-333.
16. Wilson, R.L., Hardgrave, B.C., *Predicting graduate student success in an MBA program, regression versus classification, Educational and psychological measurement*, Vol. 55, No. 2, 1995. str. 186-195.
17. Witten I.H., Frank E., *Data Mining: Practical Machine Learning Tools and Techniques with Java Implementation*. Morgan Kaufman Publishers: San Francisco, 2000.
18. Zaidah, I., Daliela, R., *Predicting students' academic performance, comparing artificial neural network, decision tree and linear regression, 21st Annual SAS Malaysia Forum, 5th September 2007, Kuala Lumpur*, str. 1-6.
19. Zekić-Sušac, M., *Nastavni materijali za kolegij Sustavi za potporu odlučivanju, Poslijediplomski studij Upravljanje ekonomskim razvojem, Ekonomski fakultet u Osijeku*, 2007/08, http://oliver.efos.hr/nastavnici/mzekic/nast_materijali/dss_razvoj/, 18.01.2008.

ZAHVALA

Autori zahvaljuju prof.dr.sc. Đuli Borozan za ustupanje podataka prikupljenih u okviru istraživanja o uspješnosti studenata i njihovim stavovima prema poduzetništvu na Ekonomskom fakultetu Sveučilišta J.J. Strossmayera u Osijeku, ak.godine 2005/06. Rad je izrađen u okviru poslijediplomskog specijalističkog studija „Upravljanje ekonomskim razvojem“ na Ekonomskom fakultetu u Osijeku.

Marijana Zekić-Sušac, Ph. D.,

Associate professor, Faculty of Economics, Osijek

Anita Frajma-Jakšić, univ. spec. assistant,

Nataša Drvenkar, univ. spec. assistant,

Faculty of Economics, Osijek

NEURON NETWORKS AND TREES OF DECISION-MAKING FOR PREDICTION OF EFFICIENCY IN STUDIES

Summary

The paper is dealing with models for prediction of students efficiency with the help of neuron networks and decision-making classification trees and then with the analysis of factors that influence the efficiency of students. A created model, based on demographic data of students as well as their behaviour and attitudes toward learning, tries to classify student in one of the two efficiency categories. The efficiency is measured by the average of marks during studies. Various architectures of neuron networks have been trained and tested and the best model is obtained with the help of stratified perceptron network. The trees of decision-making offered a significantly better accuracy than neuron networks and we suggest their using due to their being a more precise method for the set of observed data. A sensitivity analysis of output variables on the input ones carried out with neuron networks refers to the fact that preliminary exams, attendance of exercises, importance of marks to students, and scholarships are among the most significant factors for the efficiency of students. The trees of decision-making separated the most significant variables: the time spent in learning, attendance of exercises and the sorts of materials from which students learn. Future researches, with the increased number of input variables and enlargement of the pattern and methodological expansion of other artificial intelligence techniques and statistical methods, would make possible to create more successful model to be the basis for building the support system of decision-making in university level education.

Key words

Sensitivity analysis, neuron networks, trees of decision-making, stratified perceptron, efficiency in studies