

Napovedovanje uspešnosti zaključka šolanja

Silvana Gasar¹, Marko Bohanec^{2,3}, Vladislav Rajkovič⁴

¹ Srednja šola Jesenice, Ruparjeva 2, 4XXX Jesenice, Slovenija

² Institut Jožef Stefan, Jamova 39, 1000 Ljubljana, Slovenija

³ Univerza v Ljubljani, Visoka upravna šola, Gosarjeva 5, 1000 Ljubljana, Slovenija

⁴ Univerza v Mariboru, Fakulteta za organizacijske vede, Kidričeva cesta 55a, 4000 Kranj, Slovenija
silvana.gasar@telesat.si, marko.bohanec@ijs.si, vladislav.rajkovic@fov.uni-mb.si

S pomočjo lupine DEX smo izdelali ekspertni sistem za napovedovanje uspešnosti zaključka šolanja na določeni srednješolski smeri. Bazo znanja smo sestavili »ročno« na podlagi ekspertnega znanja in zakonitosti učnega uspeha, ki smo jih odkrili s postopki rudarjenja na bazi podatkov o dijakih. Validacija modela je pokazala zadovoljivo napovedno točnost za poskusno uporabo. Za nadaljnji razvoj predlagamo predvsem uporabo odločitvenih dreves.

Ključne besede: napovedovanje učnega uspeha, odkrivanje znanja iz podatkov, rudarjenje podatkov, ekspertni sistemi, hierarhični odločitveni modeli

1. Uvod

Učna uspešnost je odvisna od usklajenosti posameznikovih lastnosti z zahtevami šole, zato problem neuspešnosti v srednji šoli (SŠ) izvira predvsem iz neustrezne izbire šole. O izbiri šole in poklica govorijo številne teorije (Rodič, 1980; Brančič, 1986), nanjo pa lahko gledamo tudi kot na proces večparametrskega odločanja, v katerem zaradi negotovosti vedno obstaja tveganje, da bo izbor nekvaliteten.

Za kakovosten izbor SŠ učenci nujno potrebujejo strokovno pomoč (Oman, 1976; Rodič, 1980). Za izobraževalno in poklicno svetovanje pri nas skrbijo predvsem šolske svetovalne službe, v katerih pa je premalo svetovalcev za kvalitetno svetovanje (Resman in dr., 1999). Sistematično zbranih podatkov o izvajanju izobraževalnega svetovanja ni. Ocena ustreznosti učenčeve izbire je najpogosteje intuitivna. Za primerno ukrepanje, ki naj bi preprečilo učno neuspešnost, je v času vpisa in prijave na SŠ že prepozno (Lapajne, 1984). Svetovalci lahko dijaka samo opozorijo na neustreznost izbire (če tako ocenjujejo na podlagi skromnih podatkov), vendar dijaki le redko poslušajo opozorila. Svetovalci potrebujejo orodje, s katerim bi razumljivo in zanesljivo napovedali uspešnost zaključka šolanja.

Napoved učnega uspeha omogoča preprečevanje neuspeha (Lapajne, 1984), s čemer posredno zmanjšujemo tudi mnoge nezaželene družbene pojave, kot so: nezaposlenost, delikventnost, narkomanija, suicidalnost, različne oblike nasilja (Resman in dr., 1999; Dryden in Vos, 2001). Šolske ocene lahko služijo kot prediktorji bodočega učnega uspeha, pri čemer višino uspeha določajo predmeti, v katerih so učenci najšibkejši → »načelo najšibkejšega člana verige« (Lapajne, 1984). Na splošno je učni uspeh odvisen od interakcije fizičnih, fizioloških, socialnih in psiholoških dejavnikov učenja (Musek in Pečjak, 1995), o katerih svetovalci nimajo veliko podatkov in jih pogosto tudi ne znamo natančno

izmeriti. Zato je pri napovedovanju uspešnosti zaključka šolanja nujno potrebno večparametrsko ocenjevanje po kakovostnih kriterijih.

Ekspertni sistemu (ES) so računalniški programi, ki delujejo podobno kot človeški eksperti in podpirajo proces odločanja (Schoen in Sykes, 1987; Mallach 1994; Jereb in dr., 1997; Nilsson, 1998; Pivec in Rajkovič, 1998). Lahko jih razvijemo s pomočjo programskih jezikov ali pa z uporabo lupin (Dutta, 1993; Mallach, 1994). Pred uporabo jih moramo nujno validirati in verificirati (Schoen in Sykes, 1987; Mallach, 1994; Kononenko, 1997). Bazo znanja za ES lahko sestavimo »ročno« ali pa jo izgradimo avtomatsko z uporabo metod strojnega učenja na bazi preteklih podatkov. Določena znanja in zakonitosti lahko pridobimo tudi z rudarjenjem podatkov. Odkrivanje znanja iz podatkov (KDD – Knowledge Discovery from Data) je netrivialen proces odkrivanja implicitnega, doslej neznanega in potencialno uporabnega znanja iz podatkov, rudarjenje podatkov (DM – Data Mining) pa je faza tega procesa, v kateri dejansko pride do odkrivanja znanja (Han in Kamber, 2001). Eden glavnih namenov KDD je odkrivanje pravil, ki omogočajo napovedovanje prihodnjih primerov (Michalski in Kaufman, 1998; Bohanec in dr., 2000; Brumen in dr., 2000). Baze podatkov o dijakih skrivajo zakonitosti učnega uspeha, ki jih lahko uporabimo tudi za izgradnjo ES za napovedovanje uspešnosti zaključka šolanja.

Med najpomembnejšimi metodami DM avtorji (npr. Bohanec, 2001) navajajo: statistične metode, vizualizacijo podatkov, metode strojnega učenja (npr. gradnja odločitvenih dreves in hierarhičnih modelov), asociacijska pravila in razvrščanje v skupine. Odločitvena drevesa se pogosto uporabljajo za reševanje problemov klasifikacije in predikcije (Mitchell, 1997). Odločitveno drevo je sestavljeno iz: 1) notranjih vozlišč, ki ustrezajo pogojem, 2) vej, ki ustrezajo podmnožicam vrednosti atributov in 3) listov, ki ustrezajo razredom (Kononenko, 1997; Mitchell, 1997; Michalski in

Kaufman, 1998; Brumen in dr., 2000). Nove primere klasificiramo tako, da od korena potujemo navzdol po ustreznih vejah, sledimo pogojem v notranjih vozliščih in pridemo do lista, ki klasificira primer (Kononenko, 1997; Mitchell, 1997; Brumen in dr., 2000). Metoda HINT temelji na metodi funkcijske dekompozicije (Ashenurst, 1952; Curtis, 1962) in se lahko uporablja za avtomatizirano konstrukcijo hierarhičnih odločitvenih modelov tipa DEX (Bohanec in dr., 2000). Razvrščanje v skupine primere razvrsti po »podobnosti« (Bohanec, 2001), tako da so objekti znotraj skupin čimbolj podobni in objekti različnih skupin čimbolj različni (Ferligoj, 1989). Omogoča redukcijo in zgoščevanje podatkov, olajša pregledovanje in določitev tipologije (Ferligoj, 1989; Vieira, 2000).

Cilj raziskave je bil s pomočjo lupine ES DEX izdelati večkriterijski model za napovedovanje uspešnosti zaključka šolanja po določenem izobraževalnem programu, ga ustrezno validirati, pokazati njegove prednosti, slabosti, priložnosti in pasti ter uporabnost v praksi. Znanje za bazo ES smo zagotovili predvsem s pomočjo postopkov rudarjenja na bazi podatkov o dijakih.

2. Metodologija

2.1 Odkrivanje znanja v podatkih in rudarjenje podatkov

Metode KDD smo uporabili za odkrivanje zakonitosti učnega uspeha. Delo je potekalo po fazah procesa KDD: 1. priprava podatkov, 2. rudarjenje, 3. interpretacija, vrednotenje in predstavitev (Han in Kamber, 2001).

Kot vir smo uporabili baze podatkov o dijakih, izdelane v eni od slovenskih SŠ, v programu Evidenca 3 (Galle, 1996), kot orodje za njihovo pripravo pa SQL Server 2000. Po pripravi so imeli vsi dijaki ($N = 1794$) zbrane vsaj podatke, znane pred vpisom in podatke zaključka šolanja. Atributom, ki jih poznamo pred vpisom v SŠ (npr. spol, datum rojstva, uspeh OŠ...), sledijo podatki in ocene po zaporednih letnikih SŠ. Izdelali smo tudi podbazo dijakov s popolnimi podatki za vse letnike šolanja ($N = 889$). Uspešnosti zaključka šolanja dijaka smo izrazili v petih kategorijah, ki pomenijo:

- 5 = v 4 letih je zaključil šolo s prav dobrim ali odličnim uspehom
- 4 = v 4 letih je zaključil šolo z dobrim ali zadostnim uspehom
- 3 = v 5 - 6 letih je zaključil šolo s pozitivnim uspehom
- 2 = po 1 - 2 letih je prekinil šolanje z negativnim uspehom ali kot neocenjen
- 1 = po 3 ali več letih je prekinil šolanje z negativnim uspehom ali kot neocenjen.

Izbira ustreznih metod in tehnik DM je zelo pomembna (Babić in Pavešić, 1999; Brumen in dr., 2000; Witten in Frank, 2000). Uporabili smo statistične metode, vizualizacijo in razvrščanje v skupine in dve metodi strojnega učenja: gradnjo odločitvenih dreves in gradnjo hierarhičnih modelov HINT. Rezultate smo interpretirali, vrednotili in predstavljali sproti. Pri statističnih rezultatih smo se opirali zlasti na standardni odklon, interval zaupanja in mere povezanosti, pri

odločitvenih drevesih in modelih HINT pa na klasifikacijsko točnost (prečno preverjanje 10. reda) in velikost modelov. Povsod smo preverili tudi razumljivost, smiselnost, novost in uporabnost rezultatov.

DM smo pričeli z ugotavljanjem osnovnih statistik vzorca (deskriptivne statistike, frekvenčne porazdelitve), povezanosti med spremenljivkami (koeficienti rang korelacije, test hi-kvadrat, koeficienti kontingence), razvrščanjem v skupine in vizualizacijo v programu SPSS (SPSS Inc.). Sledila je gradnja klasifikacijskih odločitvenih dreves, pri katerih je razred diskretna spremenljivka. (Kononenko, 1997). Gradili smo jih s programom Weka (University of Waikato), z uporabo algoritma J4.8 (Witten in Frank, 2000), verzijo Quinlanovega algoritma C4.5 (Quinlan, 1993). Osnovno odločitveno drevo smo zgradili iz vseh atributov, zatem pa še različna odločitvena drevesa na podlagi ekspertne, strojne in pragmatično-strojne izbire najboljših atributov. Z Weka smo dijake razvrstili na 3, 4, in 5 skupin po metodi voditeljev. S programom Orange (Zupan in Demšar, 2001) smo gradili modele HINT. Uporabili smo nenadzorovano dekompozicijo po metodi minimalne napake, s privzeto velikostjo množice 2.

2.2 Izgradnja in validacija ekspertnega sistema

Večparametrski odločitveni model smo zgradili s pomočjo DEX – lupine ES za večparametrsko odločanje (Rajkovič in Bohanec, 1988; Bohanec in Rajkovič, 1995). Hierarhični odločitveni model DEX lahko razvijemo »ročno« ali pa z uporabo strojnega učenja, kot je npr. metoda HINT (Bohanec in dr., 2000). V nalogi smo uporabili kombinacijo obeh pristopov. Model je bil razvit »ročno«, na podlagi ekspertnega znanja in znanja dobljenega s postopki rudarjenja. Za validacijo modelov smo uporabili del prvotne baze - 10% slučajni stratificirani vzorec. Točnost napovedi modelov smo primerjali s točnostjo človeškega eksperta in odločitvenih dreves.

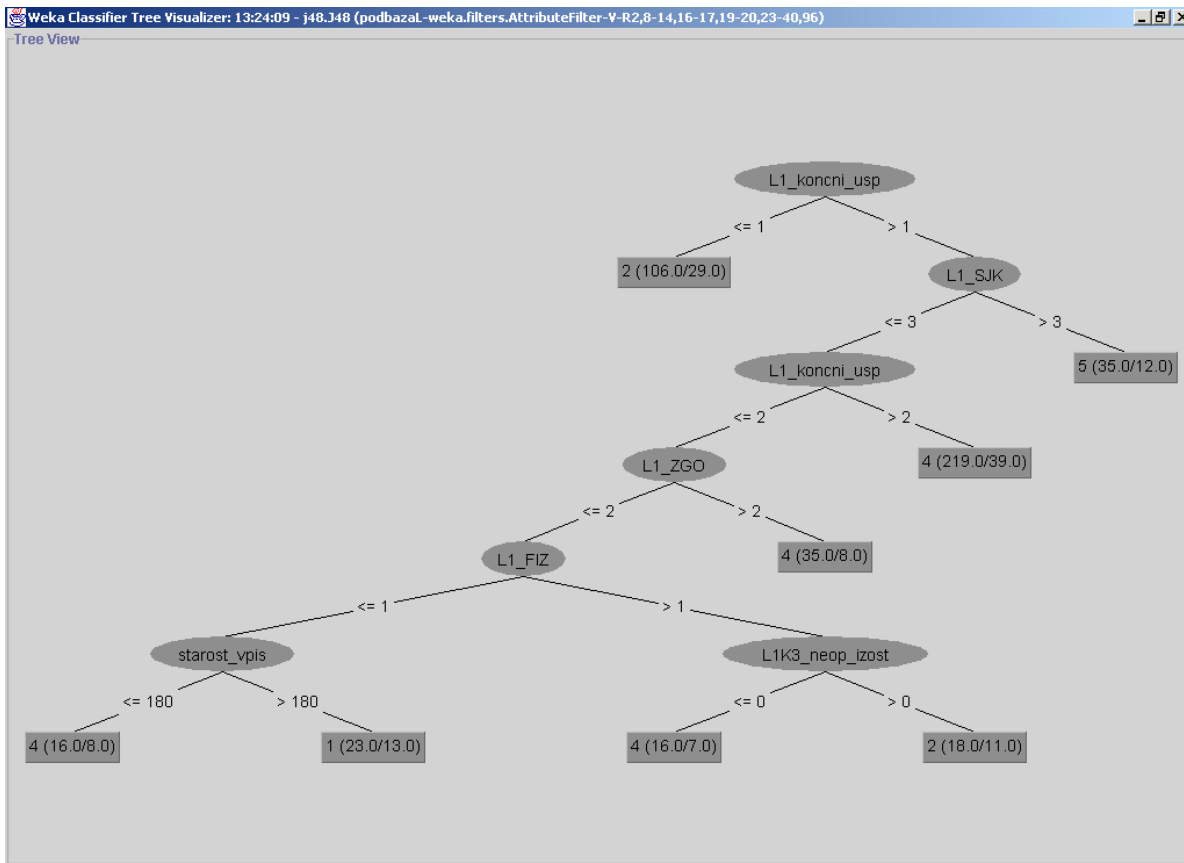
3. Rezultati rudarjenja podatkov

Statistični rezultati so pokazali, da so izbrani numerični atributi ustrezni za napovedovanje, da je dijake različnih smeri izobraževanja potrebno obravnavati ločeno, podprli pa so tudi opredelitev uspešnosti zaključka šolanja. Pokazalo se je, da so mlajše generacije nekoliko manj vztrajne in hitreje opustijo šolanje kot starejše. Največ dijakov redno zaključijo šolanje z dobrim ali zadostnim uspehom (apriorna klasifikacijska točnost 51,2%), vendar pa dobrih 20% dijakov šolanja ne zaključijo uspešno.

Najvišjo klasifikacijsko točnost so dosegla drevesa, zgrajena iz vseh atributov (99,4%) in iz strojno izbranih atributov (nad 95%), vendar so ta praktično neuporabna, saj vključujejo mnoge attribute, ki so znani šele proti koncu šolanja, ko je napoved prepozna. Ker je klasifikacijska točnost dreves, dobljenih z ekspertno in pragmatično-strojno izbiro, praktično enaka, smo se odločili za uporabo dreves iz ekspertno izbranih atributov. Različni poskusi zvišanja njihove klasifikacijske točnosti so pokazali, da najvišjo klasifikacijsko točnost dosegajo drevesa, zgrajena na podbazi z ozirom na smer

šolanja. Klasifikacijska točnost dreves iz 16 atributov, ki jih poznamo pred vpisom v SŠ, je okrog 60%, klasifikacijska točnost dreves iz 30 atributov, ki jih poznamo do konca 1. letnika SŠ, pa okrog 70%. Napovedi uspešnosti še ne izključujejo neuspešnosti, medtem ko napovedi neuspešnosti

dopuščajo le malo možnosti za drugačen izhod. Med atributi, znanimi do vpisa, ima največjo napovedno moč zaključni uspeh OŠ, med atributi, znanimi do konca 1. letnika, pa končni uspeh 1. letnika. Za primer je prikazano samo najboljšo drevo iz 30 atributov za smer »L« (slika 1).



Slika 1: Najboljše drevo iz 30 atributov za smer »L« (n = 468, KT = 69,7%).

Razvrščanje v skupine je pokazalo, da se slabši učenci v OŠ pogosteje vpisujejo na manj zahtevno smer, učenci iz velikih mest pa imajo višje izobrazbene aspiracije. Na splošno je uspeh 1. letnika SŠ močno povezan z opravičeni in neopravičeni izostanki ter za oceno do dve nižji od zaključnega uspeha OŠ. Splošna uspešnost dijakov 1. letnika je nizka, večinoma nezadostna do dobra, prav dobri in odlični pa so zelo redki.

Klasifikacijska točnost s HINT zgrajenih modelov je bila nizka, nezadovoljiva - malo višja ali celo nižja od večinskega klasifikatorja (apriorne točnosti). Tudi razumljivost zgrajenih modelov ni bila zadovoljiva, kljub vsemu pa so se pokazale nekatere zakonitosti. Modeli niso bili primerni za neposredno uporabo, dobro pa so služili kot smernice za združevanje kriterijev pri »ročni« izdelavi modela DEX.

4. Izgradnja in validacija modelov za napovedovanje

V izgradnjo modela smo zajeli samo attribute, znane do konca 1. letnika SŠ. Spisek kriterijev smo izoblikovali na podlagi ekspertnega mnenja, najboljših odločitvenih dreves in modelov HINT. Izgradnjo strukture modela in poimenovanje sestavljenih kriterijev je zelo otežilo dejstvo, da je vsak atribut odraz interakcije dijakovega predhodnega znanja, sposobnosti, motivacije in drugih osebnostnih lastnosti, natančnega deleža posameznega dejavnika pa ni mogoče točno določiti, saj je spremenljiv in odvisen tudi od dijaka. Izgradili smo dva modela DEX: prvi za grobo, primarno napoved ob vpisu, drugi pa za bolj točno, sekundarno napoved ob koncu 1. letnika SŠ. Najprej smo zgradili splošna

modela DEX ne glede na smer. Poskusno vrednotenje in analize primerov so pokazale, da je potrebno oblikovati bistveno »strožje« funkcije koristnosti, ki upoštevajo »načelo verige«, povečati teži ocenam matematike in fizike,

sposobnostim in predznanju. Zaradi obširnosti smo dokončno izdelali in validirali oba modela samo za eno od smeri izobraževanja. Slika 2 prikazuje končni model za primarno napoved.

DEXi

18.3.2002

Stran 1

Zaloga vrednosti

Kriterij	Zaloga vrednosti
uspešnost	1 ; 2 ; 3 ; 4 ; 5
sposobnosti in predznanje	neustrezne ; ustrezne ; zelo ustrezne
splošna IQ	podpovprečna ; povprečna ; nadpovprečna
-uspeh OŠ	2 ; 3 ; 4 ; 5
-uspeh 7.r	2 ; 3 ; 4 ; 5
verbalne sposobnosti	podpovprečne ; povprečne ; nadpovprečne
-SJK 8.r	2 ; 3 ; 4 ; 5
-tujji jez 8.r	2 ; 3 ; 4 ; 5
logično rezoniranje	podpovprečno ; povprečno ; nadpovprečno
-MAT 8.r	2 ; 3 ; 4 ; 5
-FIZ 8.r	2 ; 3 ; 4 ; 5
znanje tujih jezikov	neustrezno ; ustrezno
-tujji jez OŠ	ni imel ; madžarski ; nemški ; angleški
-tujji jeziki	nemški ; angleški ; angleški in nemški
znanje slovenščine	pomanjkljivo ; povprečno ; zelo dobro
-država roj	Nemčija ; Avstrija ; Srbija ; BIH ; Hrvaška ; Slovenija
-državljanstvo	BIH ; slovensko
motivacija	znižana ; ustrezna
-starost vpis	višja ; normalna
-redni vpis	ne ; da
okolščine	negativne ; ustrezne ; pozitivne
-vozač	da ; ne
-status šp	da ; ne
-spol	z ; m

Slika 2: Struktura in zaloga vrednosti modela 1 za smer »L«.

Primerjava svetovalca, modelov DEX in odločitvenih dreves, je pokazala praktično enako splošno klasifikacijsko točnost in točnosti napovedovanja po posameznih razredih. Točnost primarnih ocen vseh treh je okrog 60%, točnost sekundarnih pa okrog 70%. Uspešnim dijakom skoraj nikoli ne napovedo neuspešnosti, dijaki z nizko oceno pa so ponavadi res neuspešni. Vsi se občasno motijo tako, da neuspešnim dijakom napovedo uspešnost. Razmeroma dobro prepoznavajo izrazito neuspešne in izrazito uspešne dijake, slabo pa atipične primere določene kategorije uspešnosti. Napačne napovedi, ki so za več kot eno kategorijo višje ali nižje od dejanske uspešnosti, so razmeroma redke.

5. Zaključki in priporočila za nadaljnje raziskovanje

Izdelana modela sta primerna za poskusno uporabo s strani svetovalca, ne pa za laično uporabo s strani dijakov in staršev. Pri oblikovanju nasvetov bi se moral svetovalec še vedno opirati predvsem na lastno znanje in izkušnje, ocene modelov pa kritično pretehtati in upoštevati le ob vseh ostalih podatkih.

Prednosti obeh modelov so: 1) zahtevata podatke, s katerimi svetovalci praktično vedno razpolagajo, 2) omogočata večjo doslednost, objektivnost in sistematičnost napovedovanja, 3) svetovalcu ponujata »drugo mnenje«, kar zmanjša možnost napak, 4) možnost sekundarne ocene pa poveča zanesljivost napovedi. Domnevamo, da bi razumljivost, objektivnost in argumentiranost napovedi s pomočjo ES prispevala tudi k temu, da bi jim dijak in starši

bolj zaupali in jih večkrat upoštevali, s čemer bi se izboljšala tudi sama uspešnost.

Slaba stran obeh modelov je, da se občasno motita (neuspešnim dijakom napoveda uspešen zaključek šolanja), točnost njunih napovedi v praksi pa ni poznana. Pasti njune uporabe so naslednje. Ni mogoče predvideti, kako bo napoved vplivala na motivacijo dijaka, s tem pa tudi na končni rezultat. Napoved je tvegana in drži le pod pogojem sedanjih okoliščin. Zaradi številnih sprememb (v motivaciji, interesih in osebnosti dijaka-pubertetnika, šolskega sistema, splošnih značilnosti generacij dijakov) se napovedna točnost ES lahko hitro bistveno poslabša. Zato bi morali ES neprestano validirati in prilagajati spremembam. Neizkušeni eksperti bi se lahko preveč opirali na ocene ES in premalo na lastno presojo.

Izboljšanje napovedne točnosti ES bi lahko dosegli s spremembami modela, z uvajanjem sestavljenih atributov in vključevanjem novih kriterijev, predvsem čimbolj »čistih« mer dijakovih sposobnosti, interesov, motivacije in osebnostnih lastnosti. Idealno bi bilo razviti sistem, ki bi učencu ob zaključku OŠ podal nekaj predlogov smeri izobraževanja, ki najbolj ustrezajo njegovim lastnostim. Za razvoj takšnega sistema bi potrebovali natančen »profil« lastnosti dijaka, ki ustreza zahtevam posamezne smeri izobraževanja, ki ga naše šole nimajo definirane (Bitenc in dr., 1997). Njegova validacija pa bi zahtevala obsežna psihološka testiranja in longitudinalno spremljanje celih generacij učencev, kar ob sedanjih razmerah izobraževalnega svetovanja ni realno pričakovati.

Modifikacije in ponovne validacije ES so zahtevne in zamudne, zato smo ob hitrih spremembah dijakov

(posameznikov in generacij) in našega šolskega sistema podvomili v smiselnost nadaljnjega »ročnega« razvoja modelov DEX. Predlagamo praktično uporabo odločitvenih dreves, ki dosegajo enako klasifikacijsko točnost kot modeli DEX, zgrajena so za vse smeri, validirana na večjem številu primerov, in so lahko razumljiva. Njihova izdelava zahteva razmeroma malo časa in truda, saj je avtomatizirana, omogočajo bolj elegantno validacijo, morda pa so tudi bolj primerna glede na naravo uporabljenih podatkov.

6. Sklep

Rudarjenje podatkov je odkrilo zakonitosti, ki večinoma niso nove za pedagoške delavce z dolgoletno prakso, imajo pa velik pomen za prepričevanje dijakov in staršev, ki bolj kot subjektivni oceni svetovalca verjamejo objektivnim rezultatom raziskav.

Na podlagi atributov baze in odkritih zakonitosti smo uspeli izdelati ekspertni sistem za napovedovanje uspešnosti zaključka šolanja, ki trenutno lahko služi kot pripomoček za poskusno uporabo. Izdelava je bila zamudna in naporna, saj je možnih več smiselnih struktur modela. Glede na majhno število in nizko kvaliteto uporabljenih atributov, ki niso »čisti« in natančni pokazatelji dijakovih lastnosti, je klasifikacijska točnost modelov zadovoljiva in celo presenetljivo visoka. Ob enakih podatkih namreč zgrajeni ES dosega točnost izkušenega človeškega eksperta in odločitvenih dreves. Vendar pa se v praksi svetovalci opirajo tudi na druge podatke, kar običajno poveča točnost njihovih napovedi, zato je napovedna točnost izdelanega ES verjetno manjša kot točnost izkušenega eksperta, toda večja kot točnost ekspertanovince. Uporaba izdelanih modelov na področju izobraževalnega svetovanja je smiselna, saj je izkušenih in sposobnih ekspertov malo, pomeni pa tudi kakovosten premik v smeri bolj doslednega, objektivnega in sistematičnega ocenjevanja, evidentiranja in evaluacije napovedi, kar je v sedanjosti najbolj šibka točka izobraževalnega svetovanja (Resman in dr., 1999).

Literatura

- Ashenhurst, R.L., (1952): »The Decompositon of Switching Functions«, Technical Report, Bell Laboratories BL-1 (11), str. 541-602.
- Babić, A. in Pavešić, N., (1999): »Data Mining Principles and Applications in Clinical Domains«, v B. Zajc (ur.), Zbornik osme elektrotehniške in računalniške konference, ERK '99, september 1999, Portorož, Slovenija (str. 387-390), IEEE Region 8, Slovenska sekcija IEEE, Ljubljana.
- Bitenc, I., Pivec, M., Štribl, D. in Rajkovič, V., (1997): »Uporaba tehnologije znanja pri odkrivanju nadarjenosti otrok v pogledu nadaljnjega šolanja in zaposlovanja«, v G. Vukovič (ur.), Quo vadis management: 16. posvetovanje organizatorjev dela, april 1997, Portorož, Slovenija (str. 417-423), Moderna organizacija, Kranj.
- Bohanec, M., (2001): »Metode umetne inteligence«, učno gradivo za podiplomce FOV, (<http://www-ai.ijs.si/MarkoBohanec/ai/ai.html>).
- Bohanec, M. in Rajkovič, V., (1995): »Večparametrski odločitveni modeli«, Organizacija, 28 (7), str. 427-438.
- Bohanec, M., Zupan, B. in Rajkovič, V., (2000): »Applications of Qualitative Multi-Attribute Decision Models in Health Care«, International Journal of Medical Informatics, 58/59, str.191-205.
- Brančić, B., (1986): »Psihološke teorije izbora zanimanja«, Naučna knjiga, Beograd.
- Brumen, B.; Welzer Družovec, T., Rozman, I. in Jaakkola, H., (2000): »Razvrstitev pristopov k podatkovnemu rudarjenju«, v C. Bavec, M. Gams, V. Rajkovič, I. Rozman, J.Györkös, D. Mladenič in M. Grobelnik (ur.), Informacijska družba IS'2000 (str. 90-96), Insitut Jožef Stefan, Ljubljana.
- Curtis, H.A., (1962): »A New Approach to the Design of Switchnig Functions«, Van Nostrand, Princeton, NJ.
- Dryden, G. in Vos, J., (2001): »Revolucija učenja«, Educy, Ljubljana.
- Dutta, S., (1993): »Knowledge Processing and Applied Artificial Intelligence«, Butterworth-Heinemann, Oxford.
- Ferligoj, A., (1989): »Razvrščanje v skupine: teorija in uporaba v družboslovju«, Raziskovalni inštitut FSPN, Ljubljana.
- Galle, R., (1996): »Priročnik za uporabo programa: vodenje evidence učencev (Evidenca 3)«, september 1996 in dodatek na <http://www.s-ser.lj.edus.si/robert/evidenca.html>
- Han, J. in Kamber, M., (2001): »Data Mining: Concepts and Techniques«, Morgan Kaufman Publishers, San Francisco.
- Jereb, E., Rajkovič, V. in Gradišar, M., (1997): »Izbira delavcev za teledelo s pomočjo ekspertnega sistema«, v G. Vukovič (ur.), Quo vadis management: 16. posvetovanje organizatorjev dela, april 1997, Portorož, Slovenija (str. 424-434), Moderna organizacija, Kranj.
- Kononenko, I., (1997): »Strojno učenje«, založba FRI, Ljubljana.
- Lapajne, Z., (1984): »Proces izbire poklica«, Univerza Edvarda Kardelja, Ljubljana.
- Mallach, E.G., (1994): »Understanding Decision Support Systems and Expert Systems«, Irwin, Burr Ridge.
- Michalski, R.S. in Kaufman, K.A., (1998): »Data Mining and Knowledge Discovery: A Review of Issues and a Multistrategy Approach«, v R.S. Michalski, I. Bratko in M. Kubat (ur.), Machine Learning and Data Mining: Methods and Applications, John Wiley & Sons, Chichester.
- Mitchell, T.M., (1997): »Machine Learning«, The McGraw-Hill, New York.
- Musek, J. in Pečjak, V., (1995): »Psihologija«, Educy, Ljubljana.
- Nilsson, N.J., (1998): »Artificial Intelligence: A New Synthesis«, Morgan Kaufmann Publishers, San Francisco.
- Oman, I., (1976): »Teorija in praksa poklicnega usmerjanja«, Moderna organizacija, Kranj.
- Pivec, M. in Rajkovič, V., (1999): »Obvladovanje znanja z metodami umetne inteligence«, Organizacija, 32 (8/9), str. 449-453.

Quinlan, R.J., (1993): »C4.5: Programs for Machine Learning«, Morgan Kaufman Publishers, San Francisco.

Rajkovič, V. in Bohanec, M., (1988): »Sistemi za pomoč pri odločanju«, Organizacija in kadri, 21 (1/2), str. 127-140.

Resman, M., Bečaj, J., Bezić, T., Čačinovič-Vogrinič, G. in Musek, J., (1999): »Svetovalno delo vrtcih, osnovnih in srednjih šolah«, ZRSŠ, Ljubljana.

Rodić, R., (1980): »Izbor zanimanja«, Misao, Novi sad.

Schoen, S. in Sykes, W.G., (1987): »Putting Artificial Intelligence to Work: Evaluating & Implementing Business Applications«, John Wiley & Sons, New York.

Vieira, R., (2000): »Professional SQL Server 2000 Programming«, Wrox Press, Birmingham.

Witten, I.H. in Frank, E., (2000): »Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations«, Morgan Kaufmann, San Francisco.


Zupan, B. in Demšar, J., (2001): »Orange« University of Ljubljana, FRI, (<http://magix.fri.uni-lj.si/orange/>).

Silvana Gasar je leta 1991 diplomirala iz psihologije na Filozofski fakulteti v Ljubljani, leta 1996 pa magistrirala iz Psihološke metodologije. Leta 2002 je magistrirala iz Sistemov za podporo odločanju na Fakulteti za organizacijske vede. Doma in v tujini je objavila več strokovnih prispevkov na temo človeškega


procesiranja informacij, seksualnega narcizma, socialnega in moralnega razvoja dijakov, sistemov za podporo odločanja, elektronskega komuniciranja in rudarjenja podatkov. Pripravlja tudi splošno izobraževalne oddaje za Radio Triglav. Zaposlena je v Srednji šoli Jesenice, kjer poučuje psihologijo, kontaktno kulturo, etiko in komunikacijo, opravlja funkcijo vodje raziskovalnega aktiva ter sodeluje v projektu prenove šolskega informacijskega sistema.

Marko Bohanec je višji znanstveni sodelavec Instituta Jožef Stefan in docent za področje računalniških informacijskih sistemov. Predava na Visoki upravni šoli v Ljubljani in na Fakulteti za organizacijske vede v Kranju. Doktoriral je leta 1991 s področja računalniških znanosti na ljubljanski Fakulteti za računalništvo in informatiko. Njegovo ožje strokovno področje so sistemi za podporo odločanja, ki jih v svojem raziskovalnem, razvojnem in aplikativnem delu povezuje z metodami umetne inteligence, kot so ekspertni sistemi, sistemi strojnega učenja in sistemi za odkrivanje zakonitosti v podatkih.

Vladislav Rajkovič je redni profesor na Fakulteti za organizacijske vede Univerze v Mariboru in sodelavec Odseka za inteligentne sisteme Instituta »Jožef Stefan«. Njegovo področje so računalniški informacijski sistemi, s posebnim poudarkom na sistemih za pomoč pri odločanju. Je soavtor večkriterijske odločitvene metodologije, ki sloni na lupini ekspertnega sistema Dex. Je član Programskega sveta programa »Računalniško opismenjevanje« in vodi temeljni projekt Ekspertni sistemi v izobraževanju. Poleg tega je predstavnik Slovenije v »International Federatino for Infromation Processing« za področje izobraževanja.



TJAŠA VRESK, 4.A OŠ HINKA SMREKARJA, Marjeta Radovič



Neza Prelog, 3.c, OŠ Trnovo, Sloncek, Teja Kovac