

Analiza priznavanja izpitov v izobraževanju odraslih s pomočjo strojnega učenja

Tatjana Kovač¹, Marko Bohanec²

1 UPI - Ljudska univerza Žalec, Ulica Ivanke Uranjek 6, 3310 Žalec, Slovenija, e-pošta: tanja.kovac@upi.si

2 Institut Jožef Stefan, Jamova c. 39, 1000 Ljubljana, Slovenija, e-pošta: marko.bohanec@ijs.si

Pripravek predstavlja praktično uporabo strojnega učenja kot ene od metod umetne inteligence pri reševanju problemov priznavanja izpitov v izobraževalnih programih za odrasle. Priznavanje izpitov udeležencem je zahteven proces, saj je odvisen od mnogih parametrov, kot so: primerljivost vsebin po učnem načrtu, zastaranje vsebin, čas, ki je potekel od tedaj, ko je udeleženec te vsebine poslušal, starost udeleženca ipd. V tem procesu delamo strokovni delavci napake, na katere so udeleženci še posebej občutljivi. S pomočjo metod strojnega učenja lahko analiziramo svoje postopke ter ugotovimo, kako dejansko postopamo, kje največkrat pogrešimo in katerim predmetom je potrebno posvetiti posebno pozornost. V opisani analizi je bil uporabljen računalniški program za strojno učenje See5, ki omogoča razmeroma preproste in učinkovite raziskave na tem področju.

Ključne besede: metode umetne inteligence, strojno učenje, odločitvena drevesa, See5, izobraževanje odraslih, priznavanje izpitov.

1. Uvod

Na UPI - Ljudski univerzi v Žalcu organiziramo in izvajamo široko paleto srednješolskih izobraževalnih programov za odrasle (Katalog izobraževalne ponudbe 2001/2002). Ker so to programi za pridobitev izobrazbe, je izvajanje podrejeno šolski zakonodaji in posebnim predpisom, ki veljajo za izobraževanje odraslih (Zakon o izobraževanju odraslih, 1996). V procesu prilagajanja izobraževanja za odrasle obstajajo aktivnosti, ki niso opredeljene v zakonodaji, kot je na primer postopek priznavanja izpitov iz predhodnega izobraževanja. Takšne aktivnosti rešuje ekspert, strokovni delavec andragog oziroma vodja izobraževalnega programa na osnovi svojega znanja in izkušenj.

V srednješolske programe izobraževanja, kot je npr. program ekonomsko-komercialni tehnik (EKT), se vključujejo udeleženci z različno stopnjo poklicne izobrazbe. Priznavanje izpitov iz pretekle izobrazbe v predmetniku EKT je zahtevno. Razredniku povzroča probleme pri pojasnjevanju, zakaj ima nekdo določen predmet priznan, drugi pa ne. Priznavanje izpitov je namreč odvisno od primerljivosti vsebine, števila ur po predmetniku, od zastaranja vsebin in podobno. Čeprav na Ljudski univerzi posvečamo veliko pozornost tem pravilom, se zavedamo, da delamo napake; včasih priznamo preveč in včasih premalo. Še posebej občutljivi so predmeti zaključnega izpita (matematika, slovenski jezik, tuji jezik, gospodarsko poslovanje, računovodstvo), predmeti, ki hitro zastarajo (računalništvo in informatika, sociologija in pravo) in predmeti, ki se pojavljajo kot del drugih predmetov v različnih predmetnikih poklicnih šol (poslovna matematika, ekonomija).

Osnovni namen opisane raziskave je bil podpreti reševanje opisanega problema z metodami strojnega učenja. Strojno učenje (Mitchell 1997; Kononenko 1997) je eden od

pristopov, razvitih v okviru raziskav umetne inteligence (Winston 1992; Russell, Norvig 1994; Dean et al. 1995). Med drugim se ta pristop danes uspešno uporablja na področju analize podatkov in iskanja zakonitosti v podatkih (Han, Kamber 2001). Strojno učenje izhaja iz podatkov, ki praviloma opisujejo konkretne primere preteklih dogodkov, odločitev ali aktivnosti. Algoritem strojnega učenja iz teh primerov zgradi ("se nauči") splošno pravilo, ki naj bi praviloma:

- na človeku čim bolj razumljiv način opisalo zakonitosti, ki nastopajo v množici primerov, ter
- omogočilo odločanje oziroma napovedovanje izida pri novih dogodkih modeliranega sistema.

Poleg tega se med postopkom strojnega učenja pogosto pokažejo protislovja in "praznine" v učnih primerih, kar je lahko znak in opozorilo na napačno ravnanje v preteklosti.

V našem primeru smo izhajali iz konkretnih podatkov iz pedagoške dokumentacije naših udeležencev. Podatke smo analizirali z računalniškim programom za strojno učenje See5 (RuleQuest 2001), ki gradi klasifikacijska pravila v obliki odločitvenih dreves. Osnovni cilji raziskave so bili naslednji:

- spoznati pravila, po katerih je doslej potekalo priznavanje izpitov,
- pravila analizirati in odkriti morebitne pomanjkljivosti oziroma nelogičnosti,
- oceniti napake, ki nastopajo v procesu priznavanja izpitov, ter
- na tej osnovi ugotoviti, katerim predmetom moramo v postopku priznavanja izpitov posvetiti posebno pozornost oziroma ta postopek po potrebi spremeniti ali prilagoditi.

Raziskava je potekala v naslednjih treh korakih:

- *Priprava podatkov:* zbiranje podatkov o priznanju izpitov in priprava za obdelavo.

- *Strojno učenje* odločitvenih dreves s programom See5.
- *Analiza rezultatov*, ki jih kvantitativno ovrednotimo z apriorno in aposteriorno klasifikacijsko napako, kvalitativno oceno pa oblikujemo na osnovi subjektivne ocene dobljenih odločitvenih dreves.

Podrobneje so ti koraki in doseženi rezultati opisani v nadaljevanju.

2. Priprava podatkov

Za namen raziskave smo izbrali primere iz šolske evidence, kjer predvidevamo, da največkrat prihaja do napak. Pripravili smo:

- podatke desetih najštevilnejših poklicev (triletnih programov), iz katerih se udeleženci vključujejo v program EKT: prodajalec, natak, mehanik, kuhar, konfekcionar, frizer, šivilja, električar, cvetličar in strojnik.
- podatke iz individualnih načrtov izobraževanja za 178 udeležencev (Centrih, 2001),

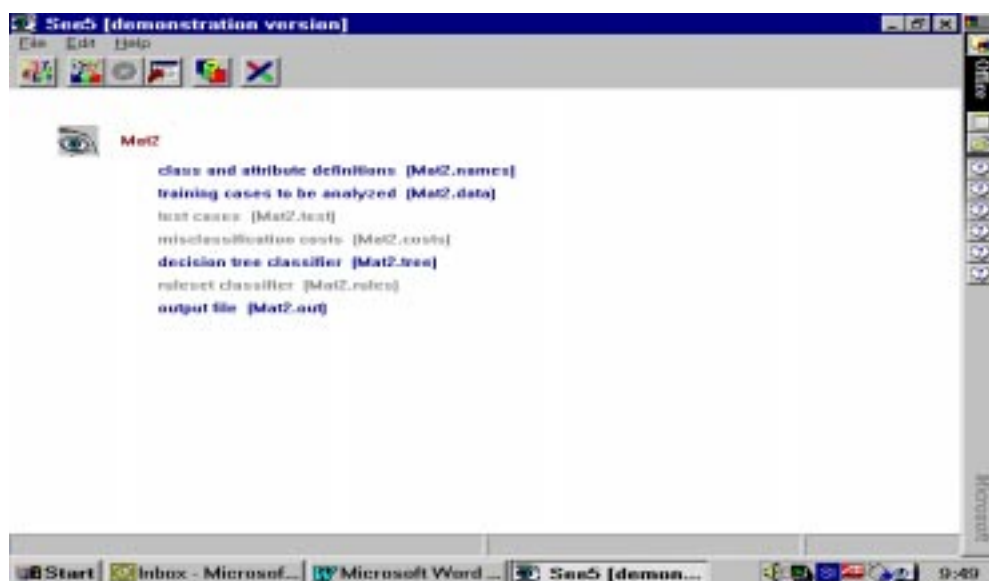
- štiri tipične predmete, kjer je priznanje odvisno od predvidenih parametrov, kot npr. čas od dokončanja prejšnje šole, starost udeleženca, spremembe vsebine programov. Ti predmeti so: matematika za 2. letnik (Mat2), računalništvo in informatika za 1. letnik (Rai1), poslovna matematika za 1. letnik (Pma1) in prvi tuji jezik za 2. letnik (Tj2).

Primere za izvedbo strojnega učenja dobimo tako, da vsakega udeleženca v izobraževanju opišemo z naslednjimi osnovnimi podatki (*atributi*): poklic, starost udeleženca, spol in čas, ki je pretekel od zaključka predhodne izobrazbe do vpisa v program EKT. Za vsakega udeleženca dodamo tudi podatke o priznanih oziroma nepriznanih izpitih; v ta namen za vsakega od štirih predmetov, upoštevanih v raziskavi, označimo s "p" oziroma "n". Pri strojnem učenju imajo ti podatki vlogo *razredov*, za katere gradimo klasifikacijska pravila.

Na ta način smo dobili zbirko podatkov, katere del prikazuje tabela 1. Celotna zbirka vsebuje 178 zapisov, ki predstavljajo učne primere za nadaljnje postopke strojnega učenja.

Tabela 1: Nekaj učnih primerov

ID	POKLIC	STAROST	SPOL	DOKONC	Mat2	Pma1	Rai1	Tj2
618	električar	22	m	4	p	n	p	p
631	električar	20	m	0	p	n	p	n
622	električar	22	m	1	n	p	p	n
576	cvetličar	18	z	0	n	n	p	p
586	cvetličar	21	z	4	n	n	n	p
84	cvetličar	25	z	6	n	n	n	p
23	električar	24	m	6	p	n	n	n



Slika 1: Osnovno okno programa See5

3. Strojno učenje s programom See5

Strojno učenje smo izvedli z računalniškim programom See5 (RuleQuest 2001). Gre za nekoliko izpopolnjeno računalniško izvedbo znanega algoritma za učenje klasifikacijskih odločitvenih dreves C4.5 (Quinlan 1993).

Odločitveno drevo je hierarhično zgrajeno pravilo, ki je sestavljeno iz *notranjih vozlišč*, ki ustrezajo atributom, *vej*, ki ustrezajo (podmnožicam) vrednosti atributov, in *listov*, ki ustrezajo razredom. V celoti gre za preslikavo, katere vhodi so vrednosti atributov, izhod pa je vrednost razreda. Če torej poznamo vrednosti atributov, lahko z drevesom določimo razred in sicer tako, da v skladu s poznanimi vrednostmi atributov poiščemo pot od korena drevesa do enega od listov. To je pomembno, saj lahko na ta način klasificiramo tudi primere, ki niso nastopali pri učenju oziroma njihov razred še ni znan.

Demonstracijska verzija programa See5 je brezplačna in dosegljiva na spletnem naslovu <http://www.rulequest.com/>. Omejena je na največ 200 učnih primerov, kar je zadostovalo za našo raziskavo. Osnovne funkcije, ki jih podpira program, so (gumbi na sliki 1): določitev lokacije podatkov, nastavitve vrednotenja, izvedba klasifikacije, prikaz rezultata, zaustavitev izvajanja in različni načini prikazovanja oziroma pregledovanja odločitvenih dreves.

See5 ne ponuja svojih funkcij za pripravo vhodnih podatkov, pač pa zahteva, da jih pripravimv posebnem tekstovnem formatu in to na dveh datotekah:

- *Names File* (ime.names): definicija atributov, razredov in njihovih vrednosti,
- *Data File* (ime.data): učni primeri, opisani z vrednostmi atributov in razredov, ločeni z vejicami in zaključeni s piko.

Konkretni primer prve datoteke je v celoti prikazan na sliki 2. Vsebina določa naslednje:

- Prva vrstica definira razred; zahtevamo torej gradnjo odločitvenega drevesa za predmet Mat2.
- Podatki, označeni kot "label" se pri gradnji drevesa ne upoštevajo; ignoriramo torej oznako ID in podatke za tri ostale predmete, Pma1, Rai1 in Tj2.
- Ostale vrstice določajo zaloge vrednosti atributov in razredov, ki so bodisi zvezne ("continuous"), bodisi diskretne, pri čemer moramo zanje naštetiti vse možne vrednosti.

```
Mat2.
ID:      label.
Poklic:  prodajalec, natakarak, mehanik, kuhar, konfekcionar,
         frizer, elektrikar, cvetlicar, sivilja, strojnik.
Starost: continuous.
Spol:    zm.
Dokonc:  continuous.
Mat2:    n.p.
Pma1:    label.
Rai1:    label.
Tj2:     label.
```

Slika 2: Primer datoteke tipa Names

```
617,natakarak,24,z,5,n,n,n,p.
624,mehanik,26,m,7,p,n,n,n.
558,prodajalec,22,m,1,n,p,p,p.
559,prodajalec,26,z,7,n,p,n,n.
560,frizer,19,z,0,n,n,p,p.
645,frizer,22,z,3,n,n,p,p.
618,elektrikar,22,m,4,p,n,p,p.
595,kuhar,29,z,10,n,n,n,p.
644,natakarak,22,m,0,n,n,n,p.
```

Slika 3: Del datoteke tipa Data

Slika 3 prikazuje vsebino datoteke z učnimi primeri. Prikazanih je le 9 od 178 primerov, uporabljenih pri opisani raziskavi. Vsak učni primer je naveden v eni vrstici. Vrtni red in vsebina posameznih podatkov morata ustrezati določilom v datoteki tipa *Names*.

Program See5 smo potem za vsakega od štirih predmetov uporabili na dva načina:

- *Gradnja enega odločitvenega drevesa nad vsemi učnimi primeri*. Na ta način smo dobili pravilo, ki je dobro opisalo vse vhodne podatke. Uporabili smo ga za spoznavanje in subjektivno presojo dosedanjih postopkov priznavanja izpitov. Zavedali smo se dejstva, da lahko pri takšnem načinu gradnje pride do pretirane prilagoditve drevesa učnim primerom ("overfitting"), zato to drevo praviloma ni primerno za oceno klasifikacijske napake, niti za klasifikacijo novih primerov.
- *Ocena klasifikacijske točnosti dreves z metodo desetkratnega prečnega preverjanja*. Pri tej metodi See5 razdeli učno množico na 10 približno enakih delov. Gradnjo dreves opravi desetkrat, pri čemer vsakič za učenje uporabi le 9 delov, klasifikacijsko napako drevesa pa oceni na preostali desetini primerov. Pri tem je klasifikacijska napaka definirana kot delež napačnih klasifikacij.

```
[ Fold 0 ]
Decision tree:
Dokonc <= 6: n (112/7)
Dokonc > 6:
  Spol = m: p (16/1)
  Spol = z:
    Poklic in {elektrikar, cvetlicar, strojnik}: n (0)
    Poklic = prodajalec: n (15/2)
    Poklic = natakarak: n (3)
    Poklic = mehanik: p (1)
    Poklic = kuhar: n (2)
    Poklic = konfekcionar: p (7/1)
    Poklic = frizer: n (4/1)
    Poklic = sivilja: n (1)
```

```
Evaluation on hold-out data (17 cases):
Size  Errors
9      1( 5.9%)
```

Slika 4: Prikaz odločitvenega drevesa v See5

Primer enega od dreves, ki ga dobimo pri prečnem preverjanju, je prikazan na sliki 4; razložimo ga lahko takole: drevo je zgrajeno iz 10 listov. Prva veja pomeni delitev glede na čas od dokončanja predhodne izobrazbe. Če je ta manjša ali enaka 6 let, izpita ne priznamo (oznaka "n"). V nasprotnem primeru upoštevamo spol in moškimi brezpogojno priznamo izpit ("p"), ženskam pa le v odvisnosti od poklica. Na vsakem listu sta v ulomku navedeni števili primerov v učni množici, ki ustrezajo (števec) oziroma ne ustrezajo (imenovalec) klasifikaciji v navedeni razred. Na koncu je navedena klasifikacijska napaka, to je delež napačno klasificiranih testnih primerov.

Posebej velja opozoriti na to, da je drevo s slike 4 lep primer, ki jasno razgali pomanjkljivosti dosedanjega postopka priznavanja izpitov. Izkazuje se namreč, da je odločitev odvisna od spola udeleženca in je strožja za ženske. Prav tako – vsaj na prvi pogled – ni logično veliko število priznanih izpitov pri udeležencih s starejšim, morda že zastarelim, znanjem (več o tem v razdelku 4.2.1).

4. Analiza rezultatov

Dobljene rezultate ovrednotimo z dveh vidikov: kvantitativno in kvalitativno. Pri kvantitativni oceni se opremo predvsem na apriorno in aposteriorno klasifikacijsko napako, kvalitativno oceno pa dobimo na osnovi subjektivne interpretacije odločitvenih dreves.

4.1 Kvantitativna ocena

Pri kvantitativni oceni ugotavljamo kvaliteto zgrajenih odločitvenih dreves, izraženo z *aposteriorno klasifikacijsko napako*: čim manjša je napaka, tem boljši klasifikator je to drevo. To napako izračuna See5 kot povprečje klasifikacijskih napak desetih dreves, zgrajenih pri prečnem preverjanju.

Klasifikacijska napaka je odvisna od konkretnega problema, zato jo moramo primerjati z *apriorno napako klasifikacije*. Gre za napako, ki bi jo v povprečju naredili, če bi klasificirali "na slepo" in to tako, da bi vedno navedli najbolj verjetni odgovor. Apriorno napako ocenimo na osnovi porazdelitve razredov v učni množici.

Rezultate kvantitativne analize prikazuje tabela 2. Prav v vseh primerih je bila aposteriorna napaka bistveno manjša od apriorne, kar pomeni, da so uporabljeni atributi relevantni za ta primer, odločitvena drevesa, zgrajena s strojnimi učenjem, pa bistveno boljša od klasificiranja "na pamet". Še posebej je opazna velika razlika pri predmetu Rai1. Po drugi strani pa ne smemo prezreti, da so vse aposteriorne napake blizu 10%, kar jasno pokaže, da postopek priznavanja izpitov še zdaleč ni brez napak. Možna razloga sta dva: (1) nekonsistentnost pri dosedanjih postopkih priznavanja izpitov, ki se odražajo v učnih primerih, ter (2) vpliv atributov, ki niso zajeti v učni množici.

Tabela 2: Rezultati kvantitativne analize

Predmet	Število "n"	Število "p"	Apriorna napaka	Aposteriorna napaka
Mat2	143	35	$35/178 = 0,196 = 19,6\%$	11,8%
Pma1	117	61	$61/178 = 0,343 = 34,3\%$	10,6%
Rai1	101	77	$77/178 = 0,433 = 43,3\%$	7,9%
Tj2	143	36	$36/178 = 0,202 = 20,2\%$	9,6%

4.2 Kvalitativna ocena

Kvalitativno oceno odločitvenih dreves poda ekspert na osnovi njihovega subjektivnega pregleda in interpretacije. Osnovni namen je oceniti "smiselnost" oziroma vsebinsko ustreznost dreves. Zanima nas, po kakšnih pravilih je doslej potekalo priznavanje izpitov. Ali je bilo to smiselno, logično? Ali odločitvena drevesa pokažeje kakšne hude napake, nelogičnosti? Ali pravila zajemajo vse realne situacije? Ali so atributi, ki nastopajo v drevesu, smiselni in pravilno razporejeni? Ali pa morda manjkajo pomembni atributi? Odgovori na ta vprašanja predstavljajo pomembno osnovo za razumevanje in morebitno izboljšanje postopkov priznavanja izpitov v prihodnosti.

4.2.1 Mat2: Matematika za 2. letnik

Struktura odločitvenega drevesa, ki ga je zgradil See2 iz celotne učne množice za predmet Mat2, je enaka strukturi, prikazani na sliki 4. Prva vejitev je torej odvisna od časa, ki je pretekel od dokončanja predhodne izobrazbe. Pri priznavanju izpitov dejansko upoštevamo čas okoli 6-8 let, v katerem nekatere vsebine zastarajo. Pri matematiki ni problem v zastaranju vsebin, ampak v prenavljanju izobraževalnih programov v preteklosti (usmerjeno izobraževanje, dveletni poklicni programi, itd), tako da je delitev v drevesu dejansko ustrezna, čeprav je na prvi pogled lahko presenetljiva. Druga delitev po spolu pa ni ustrezna, saj priznavanje ne bi smelo biti odvisno od spola udeleženca. Bolj logična je klasifikacija glede na poklice.

Atribut, ki opisuje starost udeleženca ni v klasifikaciji nikjer prisoten, torej je nepotreben. Razlog je v tem, da že kriterij „čas od dokončanja“ vsebuje lastnosti kriterija „starost udeleženca“.

Napaka takšne klasifikacije je v poprečju 7,3%, kar govori o tem, kako dobro se je drevo prilagodilo vhodnim podatkom. Napaka na prvem listu, ki zajema daleč največji delež vhodnih podatkov, je 5,9% (8/135).

Pma1

Poklic = prodajalec: p (67/12)

Poklic = mehanik: n (8)

Poklic = kuhar: n (12/2)

Poklic = konfekcionar: n (8)

Poklic = frizer: n (24)

Poklic = električar: n (8/1)

Poklic = cvetlicar: n (11)

Poklic = sivilja: n (20)

Poklic = strojnik: n (9)

Poklic = natakar:

Starost ≤ 20: p (3/1)

Starost > 20: n (8/1)

Rai1

Dokonc > 5: n (61/3)

Dokonc ≤ 5:

Poklic = konfekcionar: p (0)

Poklic = natakar: n (7)

Poklic = mehanik: n (2)

Poklic = kuhar: n (7)

Poklic = električar: p (4)

Poklic = cvetlicar: n (10/1)

Poklic = sivilja: n (13)

Poklic = strojnik: n (2/1)

Poklic = frizer:

Starost ≤ 22: p (17)

Starost > 22: n (3/1)

Poklic = prodajalec:

Starost ≤ 26: p (41)

Starost > 26:

Starost ≤ 27: n (2)

Starost > 27: p (9)

Tj2

Poklic = prodajalec: p (67/6)

Poklic = natakar: p (11)

Poklic = kuhar: p (12)

Poklic = konfekcionar: n (8/1)

Poklic = frizer: p (24/1)

Poklic = električar: n (8/2)

Poklic = cvetlicar: p (11)

Poklic = sivilja: p (20/3)

Poklic = mehanik:

Dokonc ≤ 6: p (2)

Dokonc > 6: n (6)

Poklic = strojnik:

Dokonc ≤ 4: p (2)

Dokonc > 4: n (7)

Slika 5: Klasifikacijska drevesa za tri predmete

4.2.2 Pma1: Poslovna matematika za 1. letnik

Klasifikacijsko drevo za predmet poslovna matematika za 1. letnik prikazuje levi stolpec slike 5. Delitev po poklicih na prvem nivoju je smiselna, saj poslovna matematika ni prisotna v predmetniku vseh poklicev. Delitev po starosti je posledica sprememb v predmetniku, saj se je vsebina poslovne matematike, npr. v programu trgovec, natakar, kuhar, obravnavala kot del matematike. Ocena napake tega drevesa je v poprečju 9,6%.

4.2.3 Rai1: Računalništvo in informatika za 1. letnik

To je tipični predmet, pri katerem vsebina hitro zastara, zato je smiselna delitev po kriteriju „Dokonc“ (čas od dokončanja predhodne šole), ki kot najpomembnejši kriterij nastopa na prvem nivoju odločitvenega drevesa (slika 5, srednji stolpec). Sledi klasifikacija po poklicih in starosti. Tu je zopet razvidna posledica prenavljanja poklicnih programov v preteklosti. Poprečna napaka drevesa je 3,4%.

4.2.4 Tj2: Prvi tuji jezik za 2. letnik

Delitev po poklicih na prvem nivoju je smiselna, saj tuji jezik ne zastara (slika 5, desni stolpec). V preteklosti v predmetniku nekaterih poklicev ni bilo tujega jezika, zato je tudi vejanje glede na čas od dokončanja smiselno. Poprečna ocena napake drevesa je 7,3%.

5. Zaključek

Priznavanje izpitov je zelo občutljiv del procesa organizacije izobraževanja odraslih in za vodjo programa zelo odgovorno

opravilo. Predvsem mora tisti, ki priznava izpite, vedeti, zakaj je nekomu izpit priznal, drugemu pa ne. Pri tem skušamo biti nepristranski in objektivni, predvsem pa moramo do vseh udeležencev uporabiti enake kriterije in merila. Le-te moramo tudi znati utemeljiti in razložiti udeležencem izobraževanja.

Zaradi množice različnih poklicev, različnih vhodnih parametrov, delamo napake. S pomočjo metod umetne inteligence, konkretno strojnega učenja, ki jo računalniško podpira program See5, lahko spoznamo občutljive točke v postopku priznavanja izpitov in ugotovimo, katerim predmetom je potrebno posvetiti največ pozornosti ter kateri parametri bistveno vplivajo na postopek in kako. Te ugotovitve predstavljajo osnovo za izpopolnjevanje nadaljnjih postopkov.

Čeprav so rezultati naloge pokazali, da se je računalnik v poprečju dobro naučil pravil iz podatkov, nam to ne daje ocene napake našega dela v praksi. Če bi hoteli natančno preveriti, kako pogosto se zmotimo, bi morali primerjati dejanske podatke o priznanih izpitih z rešitvami, predlaganimi na drugačen način, na primer z ekspertnim modelom, za katerega smo ocenili, da je ustrezen.

Bistvena so naslednja spoznanja, ki jih velja upoštevati v naši vsakdanji praksi:

- pri priznavanju navedenih predmetov, ki so še posebej občutljivi, je potrebno upoštevati različne dejavnike, ne le poklicno izobrazbo udeleženca;
- priznavanja izpitov ni mogoče opravljati šablonsko, ampak za vsakega udeleženca posebej;
- potrebno je razmisliti, zakaj prihaja do nenavadnih rezultatov (npr. vpliv spola na priznavanje izpita iz matematike za 2. letnik) ter primerno spremeniti postopek.

Povzetek spoznanj lahko strnemo v naslednja priporočila za nadaljnje delo:

- analizirati bi bilo potrebno vse možne vplivne dejavnike, da bi odkrili bistvene parametre (attribute),

- analizo bi bilo potrebno razširiti tudi na druge izobraževalne programe in na vse predmete posameznih predmetnikov ter ugotoviti oceno napake,
- metodo strojnega učenja bi lahko vključili v postopek evalvacije strokovnega dela kot obliko notranje presoje kakovosti.

Literatura

Dean, T., Allen, J., Aloimonos, Y. (1995): *Artificial Intelligence: Theory and Practice*, Addison Wesley.

Centrih, F. (2001): Pravilnik o kakovosti UPI – Ljudske univerze Žalec.

Han, J., Kamber, M. (2001): *Data Mining: Concepts and Techniques*, Morgan Kaufman.

Kononenko, I. (1997): *Strojno učenje*, Založba FE in FRI, Ljubljana.

Mitchell, T.M (1997): *Machine Learning*, McGraw-Hill.

Ministrstvo za šolstvo, znanost in šport, (1996), Zakon o izobraževanju odraslih.

Quinlan, J.R. (1993): *C4.5: Programs for Machine Learning*, Morgan Kaufmann.

Russell, S., Norvig, P. (1994): *Artificial Intelligence: A Modern Approach*, Prentice-Hall.

RuleQuest (2001): *See5*, <http://www.rulequest.com/>.

UPI – Ljudska univerza Žalec, (2001), Katalog izobraževalne ponudbe 2001/2002,.

Winston, P.H. (1992): *Artificial Intelligence*, Addison Wesley.

Tatjana Kovač je diplomirala leta 1996 na Fakulteti za organizacijske vede Univerze v Mariboru smer Organizacijska informatika. Na isti fakulteti nadaljuje magistrski študij, smer management informacijskih sistemov. V dolgoletni delovni praksi je pridobila veliko praktičnih znanj s področja načrtovanja informacijskih sistemov v gospodarstvu in negospodarstvu. Zadnjih pet let je zaposlena kot strokovna sodelavka na UPI - Ljudski univerzi v Žalcu.

Marko Bohanec je znanstveni sodelavec Instituta Jožef Stefan in docent za področje računalniških informacijskih sistemov na Fakulteti za organizacijske vede, Univerze v Mariboru. 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.



Gasilski dom, Tina Lebar, 13 let, OŠ Hinka Smrekarja, mentorici: Bojana M. Makuc, Irena Kerin