

UNIVERZA V LJUBLJANI  
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Matevž Pavlič

**Ocenjevanje kvalitete argumentov pri  
argumentiranem strojnem učenju**

MAGISTRSKO DELO  
ŠTUDIJSKI PROGRAM DRUGE STOPNJE  
RAČUNALNIŠTVO IN INFORMATIKA

MENTOR: doc. dr. Matej Guid

Ljubljana, 2015



Rezultati magistrskega dela so intelektualna lastnina avtorja in Fakultete za računalništvo in informatiko Univerze v Ljubljani. Za objavljanje ali izkoriščanje rezultatov magistrskega dela je potrebno pisno soglasje avtorja, Fakultete za računalništvo in informatiko ter mentorja.



## IZJAVA O AVTORSTVU MAGISTRSKEGA DELA

Spodaj podpisani Matevž Pavlič sem avtor magistrskega dela z naslovom:

*Ocenjevanje kvalitete argumentov pri argumentiranem strojnem učenju*

S svojim podpisom zagotavljam, da:

- sem magistrsko delo izdelal samostojno pod mentorstvom doc. dr. Mateja Guida,
- so elektronska oblika magistrskega dela, naslov (slov., angl.), povzetek (slov., angl.) ter ključne besede (slov., angl.) identični s tiskano obliko magistrskega dela,
- soglašam z javno objavo elektronske oblike magistrskega dela v zbirki "Dela FRI".

V Ljubljani, 26. marca 2015

Podpis avtorja:



*Zahvaljujem se doc. dr. Mateju Guidu za spodbudo in nasvete pri izdelavi magistrskega dela.*

*Hvala Črtomirju, Michelu, Andreju in Slavici za odgovore na vprašanja iz računovodstva in financ. Zahvalil bi se dr. Martinu Možini za pomoč pri zagonetkah argumentiranega strojnega učenja.*

*Zahvala gre tudi Alešu in Danijelu za njuno sodelovanje pri eksperimentu.*





*Even gravity can hold me down.*



# Kazalo

<b>1</b>	<b>Uvod</b>	<b>1</b>
<b>2</b>	<b>Argumentirano strojno učenje</b>	<b>5</b>
2.1	Argumentirano učenje pravil . . . . .	7
2.2	Interaktivna zanka za zajemanje ekspertnega znanja . . . . .	9
<b>3</b>	<b>Pristopi za ocenjevanje argumentov</b>	<b>11</b>
3.1	Pristop P1: ocena . . . . .	12
3.2	Pristop P2: prispevek . . . . .	13
3.3	Pristop P3: potencial . . . . .	14
<b>4</b>	<b>Zajemanje znanja iz eksperta/učitelja</b>	<b>17</b>
4.1	Opis učnega problema . . . . .	18
4.2	Priprava podatkov . . . . .	19
4.3	Opis začetnih atributov . . . . .	19
4.4	Zajemanje ekspertnega znanja . . . . .	24
<b>5</b>	<b>Zajemanje znanja iz učenca</b>	<b>33</b>
5.1	Iteracija 1 . . . . .	35
5.2	Iteracija 3 . . . . .	39
5.3	Iteracija 5 . . . . .	43
<b>6</b>	<b>Evalvacija</b>	<b>47</b>
6.1	Analiza učne seje . . . . .	47
6.2	Povzetek učnih sej . . . . .	51

## KAZALO

<b>7 Sklepne ugotovitve</b>	<b>53</b>
<b>A Povzetek učne seje zajemanja znanja iz učenca</b>	<b>59</b>
A.1 Iteracija 2 . . . . .	59
A.2 Iteracija 4 . . . . .	60
A.3 Iteracija 6 . . . . .	62
A.4 Iteracija 7 . . . . .	64
A.5 Iteracija 8 . . . . .	65
A.6 Iteracija 9 . . . . .	67
A.7 Iteracija 10 . . . . .	68
A.8 Iteracija 11 . . . . .	69
<b>B Kritični primeri</b>	<b>71</b>

# Seznam uporabljenih kratic

<b>kratica</b>	<b>angleško</b>	<b>slovensko</b>
<b>ABML</b>	argument-based machine learning	argumentirano strojno učenje
<b>AUC</b>	area under curve	površina pod krivuljo
<b>CA</b>	classification accuracy	klasifikacijska točnost
<b>CAGR</b>	compound annual growth rate	sestavljena letna rast
<b>ITS</b>	intelligent tutoring system	inteligentni tutorski sistem
<b>SKD</b>	standard classification of activities	standardna klasifikacija dejavnosti



# Povzetek

Interaktivna zanka za zajemanje znanja s pomočjo argumentiranega strojnega učenja (angl. *argument-based machine learning (ABML) knowledge refinement loop*) omogoča interakcijo med metodo strojnega učenja in domenskimi strokovnjakom. Predstavlja zmogljivo orodje za zajemanje (elicitacijo) ekspertnega znanja, ki ga lahko uporabimo tudi v težavnih domenah. Strokovnjaku v izbrani domeni omogoča, da se osredotoči le na problematične dele trenutne baze znanja, in mu pomaga pri razlagi avtomatsko izbranih “kritičnih” primerov. Strokovnjak se posveti razlagi le enega primera hkrati, kar olajša podajanje čim ustrežnejših argumentov. S pomočjo avtomatsko izbranih “protiprimerov” lahko strokovnjak zazna pomanjkljivosti svojih razlag in na podlagi tega izboljša podane argumente.

Nedavno je bilo pokazano, da omenjeni pristop omogoča tudi izdelavo interaktivnega učnega orodja, ki temelji na argumentiranju. Ključna pomanjkljivost tovrstnega orodja, temelječega na argumentiranem strojnem učenju, je bila do sedaj njegova nezmožnost posredovanja koristnih povratnih informacij v zvezi s podanimi argumenti. Ne le učiteljem, ki s sodelovanjem v postopku zajemanja znanja omogočijo izdelavo orodja za poučevanje, pač pa tudi učencem, ki to orodje nato uporabljajo pri usvajanju znanja v izbrani domeni.

V delu smo zasnovali tri pristope za podajanje takojšnjih povratnih informacij o kvaliteti argumentov, uporabljenih v interaktivni zanki za zajemanje znanja s pomočjo argumentiranega strojnega učenja. Za eksperimentalno domeno smo izbrali analizo finančnih izkazov oz. natančneje: napo-

vedovanje bonitetnih ocen podjetij. Naš cilj je bil dvodelen, in sicer pridobiti uspešen napovedni model za napovedovanje bonitetnih ocen, hkrati pa učencem omogočiti usvajanje znanja v tej sicer zahtevni domeni.

V eksperimentalnem delu so bili tako učitelj (oz. domenski strokovnjak) kot učenci udeleženi v poskusnih sejah zajemanja znanja, pri tem pa prejemali povratne informacije o svojih argumentih oz. razlagah. Cilj seje z učiteljem je bil pridobiti naprednejše koncepte (značilke oz. attribute), ki dobro opisujejo izbrano domeno in so hkrati primerni za poučevanje ter omogočajo uspešne napovedi. Pri tem je v vlogi učitelja sodeloval strokovnjak s področja financ. Učenci so se v učnih sejah najprej seznanili z učno domeno, nato pa si prizadevali za doseg čim uspešnejšega napovednega modela, pri tem pa v svojih razlagah uporabljali (tudi) učiteljeve naprednejše koncepte.

Glavni prispevki dela so:

- zasnova treh pristopov za ocenjevanje kvalitete argumentov, uporabljenih v interaktivni zanki za zajemanje znanja s pomočjo argumentiranega strojnega učenja,
- implementacija interaktivnega učnega orodja za napovedovanje bonitetnih ocen z uporabo realnih podatkov,
- podroben opis učne seje z učencem, in sicer z uporabo vseh treh omenjenih pristopov za ocenjevanje kvalitete argumentov.

## Ključne besede

inteligentni tutorski sistemi, interaktivna zanka za zajemanje znanja s pomočjo argumentiranega strojnega učenja, na argumentiranju temelječe interaktivno učno orodje, ocenjevanje kvalitete argumentov, finančna analiza, napovedovanje bonitetnih ocen podjetij



# Abstract

Argument-based machine learning (ABML) knowledge refinement loop enables an interaction between a machine learning algorithm and a domain expert. It represents a powerful knowledge elicitation tool, suitable for obtaining expert knowledge in difficult domains. The loop enables the expert to focus on the most critical parts of the current knowledge base, and helps him or her to argue about automatically chosen relevant examples. The expert only needs to explain a single example at the time, which facilitates articulating arguments. It also helps the expert to improve the explanations by providing (automatically chosen) relevant counter examples.

It has been shown recently that ABML knowledge refinement loop also enables design of argumentation-based interactive teaching tool. However, so far the machine was not able to provide neither the teachers (that designed such a tool) nor the students (that used it for learning) with concrete estimations about the quality of their arguments.

In this thesis, we have designed three approaches for giving immediate feedback about the quality of arguments used in the ABML knowledge refinement loop. The chosen experimental domain was financial statement analysis, more concretely estimating credit scores of companies (enterprises). Our goal was twofold: to obtain a successful classification model for predicting the credit scores, and to enable the students to learn about this rather difficult domain.

In the experimental sessions, both the teacher and the students were involved in the process of knowledge elicitation with the ABML knowledge

refinement loop, receiving the feedback about their arguments. The goal of the learning session with the teacher was in particular to obtain advanced concepts (attributes) that describe the domain well, are suitable for teaching, and also enable successful predictions. This was done with the help of a financial expert. In the “tutoring” sessions, the students learned about the intricacies of the domain and strived for the best predictive model as possible, also by using the teacher’s advanced concepts in their arguments.

The main contributions of this work are:

- the design of three approaches for estimating the quality of arguments used in the argument-based machine learning (ABML) knowledge refinement loop,
- implementation of argumentation-based interactive teaching tool for estimating credit scores of companies (enterprises), using real data,
- a detailed description of the learning session, where the student received three types of feedback about the arguments used.

## **Keywords**

intelligent tutoring systems, argument-based machine learning knowledge refinement loop, argumentation-based interactive teaching tool, estimating the quality of arguments, financial analysis, credit scoring

# Poglavje 1

## Uvod

Interaktivna zanka za zajemanje znanja s pomočjo argumentiranega strojnega učenja (angl. *argument-based machine learning (ABML) knowledge refinement loop*) omogoča interakcijo med metodo strojnega učenja in domenskim strokovnjakom (ekspertom) [9]. Predstavlja zmogljivo orodje za zajemanje (elicitacijo) ekspertnega znanja, ki ga lahko uporabimo tudi v težavnih domenah. Med drugim je bilo pokazano, da vodi do človeško razumljivih modelov, ki so konsistentni z znanjem strokovnjaka [8]. Strokovnjaku v izbrani domeni omogoča, da se osredotoči le na problematične dele trenutne baze znanja in mu pomaga pri razlagi avtomatsko izbranih “kritičnih” primerov. Strokovnjak se posveti razlagi le enega primera hkrati, kar olajša podajanje čim ustrežnejših argumentov. S pomočjo avtomatsko izbranih “protiprimerov” lahko strokovnjak zazna pomanjkljivosti svojih razlag in na podlagi tega izboljša podane argumente.

Nedavno je bilo pokazano, da omenjeni pristop omogoča tudi izdelavo interaktivnega učnega orodja, ki temelji na argumentiranju [14]. Ključna pomanjkljivost tovrstnega orodja, temelječega na argumentiranem strojnem učenju, je bila do sedaj njegova nezmožnost posredovanja koristnih povratnih informacij v zvezi s podanimi argumenti. Ne le učiteljem, ki s sodelovanjem v postopku zajemanja znanja omogočijo izdelavo orodja za poučevanje, pač pa tudi učencem, ki to orodje nato uporabljajo pri usvajanju znanja v izbrani

domeni.

Podajanje povratnih informacij v zvezi s podanimi argumenti lahko omogočimo prek vpeljave metode za vrednotenje ekspertnih argumentov. Razvoj takšne metode je bil tudi eden izmed glavnih ciljev našega dela. Z vpeljavo pristopa za ocenjevanje kakovosti argumenta smo poskušali rešiti dva aktualna problema:

- ni nujno, da uporabnikov argument rezultira v odločitvenem pravilu, kar pomeni, da ne vemo, kakšna je kvaliteta argumenta,
- uporabnikov argument ni nujno enak pravilu, kar pomeni, da je uporabnik podal pomanjkljiv argument.

Del magistrskega dela je posvečen tudi razvoju inteligentnega tutorskega sistema (v nadaljevanju ITS), ki temelji na argumentiranju. ITS-ji so računalniški sistemi, namenjeni poučevanju. Pri tem omogočajo avtonomno in inteligentno prilagajanje specifičnim potrebam učencev. ITS-ji so v tesni povezavi s pedagoškimi vedami, računalništvom (predvsem umetno inteligenco) in psihologijo (predvsem kognitivno znanostjo) [13]. Eden izmed glavnih ciljev ITS-ja je doseči uspešnost poučevanja ena na ena. Kako zelo koristen je takšen način učenja, je pokazal Bloom v odmevni študiji leta 1984. Iz nje namreč lahko razberemo, da so dosežki učencev (uspešnosti pri učenju) pri poučevanju ena na ena v povprečju boljši kar od 98 % dosežkov učencev pri poučevanju v razredu [2]. Uspešnost trenutno najboljših ITS-jev je nekje na polovici uspešnosti med učenjem v razredu in poučevanjem ena na ena. Nismo seznanjeni z učnim orodjem, ki bi temeljilo na argumentiranju in pri tem uporabljalo strojno učenje. Obstajajo učna orodja, ki učijo večšine argumentiranja [12], kar je drugačen problem kot ta, ki smo si ga zastavili v tem delu: usvajati domensko znanje s pomočjo argumentiranja.

Kot je bilo že omenjeno, lahko uporabimo zanko za zajemanje znanja kot interaktivno učno orodje, ki temelji na argumentiranju. Natančneje, po zajemanju ekspertnega znanja izvedemo nov postopek zajemanja znanja iz učenca. Slednji poskuša čim bolj razložiti oz. argumentirati dane kritične

primere, pri tem pa v svojih razlagah uporablja tudi koncepte, ki jih je poprej vpeljal učitelj. S tem ga učno orodje postopoma seznanja z učno domeno in koncepti. Prek podajanja povratnih informacij o kakovosti argumenta lahko učinkovitost učenja izboljšamo.

V magistrskem delu smo zasnovali tri pristope za podajanje takojšnje povratne informacije o kakovosti argumenta: *P1*, *P2* in *P3*. V pristopu *P1* je povratna informacija numerična vrednost, ki pove, kako dobro razlogi argumenta zagovarjajo, da je nek primer v danem razredu. Omenjena vrednost je izračunana v postopku iskanja pravil ABML algoritma. Novost je, da jo sedaj prikažemo tudi uporabniku. *P2* poskuša izmeriti, koliko novih informacij prispeva podan argument v primerjavi z znanjem, pridobljenim iz nabora podatkov in že vnesenih argumentov, medtem ko *P3* oceni, ali je argument pomanjkljiv oz. preveč specifičen. V obeh primerih *P3* ponudi uporabniku namige za skrčitev oz. razširitev argumenta.

Naslednji korak magistrskega dela je predstavljal razvoj inteligentnega sistema za poučevanje, ki temelji na argumentiranju. Z namenom evalvacije omenjenih treh pristopov in prikazom njihovih uporabnosti kot del inteligentnega sistema za poučevanje smo izvedli tri učne seje. Pridobili smo tri udeležence, ki so nastopali v vlogi učenca v eni izmed sej. Za učni problem smo si izbrali problem iz poslovne domene – podajanje bonitetne ocene podjetjem. V učnih sejah se je pokazalo, da zanka zajemanja znanja s pomočjo ABML-ja skupaj z opisanimi razvitimi idejami predstavlja uporaben inteligentni sistem za poučevanje. Menimo, da poleg glavnega namena učno orodje lahko pripomore tudi k izboljšanju veščin argumentiranja.

Struktura dela je naslednja. V poglavju 2 predstavimo argumentirano strojno učenje in podrobno opišemo zanko za zajemanje znanja. Poglavje 3 opisuje obravnavane pristope, poglavje 4 predstavi zasnovo dvodelnega eksperimenta, opis domene in rezultate prvega dela eksperimenta – zajemanje ekspertnega znanja. V poglavju 5 se nahaja kratek povzetek učne seje in prikaz nekaj ilustrativnih iteracij učne seje (drugi del eksperimenta). Poglavje 6 predstavi rezultate evalvacije učnih sej. Delo zaključimo s sklepnimi

ugotovitvami v poglavju 7. Dodatek A vsebuje povzetek izbrane učne seje, v dodatku B pa so prikazani finančni podatki kritičnih primerov, omenjenih v povzetku učne seje.

## Poglavje 2

# Argumentirano strojno učenje

Argumentirano strojno učenje je pristop, ki združuje strojno učenje iz učnih podatkov in argumentov [10]. Namen uporabe argumentov v učenju je zmanjšanje iskalnega prostora v prostoru hipotez in pridobitev takšnih, ki so razumljivejše. Argumenti predstavljajo razlage posameznih primerov s strani domenskega strokovnjaka. S tem, ko se osredotočimo na posamezne primere, je delo strokovnjaku olajšano, saj navedba splošnega znanja predstavlja problem, ki se imenuje Feigenbaumovo ozko grlo [6].

Primere, ki jih ponudimo strokovnjaku v razlago, imenujemo kritični primeri. To so tisti, ki jih ABML ne zna napovedovati. Z osredotočanjem na manjše število primerov, ki so kritični, prihranimo ekspertov čas.

Problem učenja iz učnih primerov se glasi:

- z danimi učnimi primeri,
- najdi hipotezo, konsistentno z učnimi primeri.

Z ABML-jem razširimo ta problem na iskanje hipoteze z učnimi primeri in argumenti.

Vsak primer je opisan z atributi in razredom, kamor spada. Z argumenti zagovarjamo, zakaj primer spada v dan razred (*pozitivni argumenti*) oz. zakaj ne (*negativni argumenti*).

Ime	Temperatura	CepljenjeOpravljeno	Kašljanje	Spol	Gripa
g. Sluga	normalna	ne	da	moški	ne
ga. Novak	visoka	ne	da	ženska	da
g. Mlinar	visoka	da	da	moški	ne
ga. Kralj	visoka	ne	ne	ženska	da
ga. Knez	visoka	ne	da	ženska	da

Tabela 2.1: Učni primeri za učenje diagnosticiranja gripe.

Za ponazoritev argumentiranja si pogledjmo enostaven učni problem: učenje diagnosticiranja gripe. Vsak pacient je opisan s petimi atributi: *Ime*, *Temperatura*, *CepljenjeOpravljeno*, *Kašljanje*, *Spol* in razredom *Gripa*. Kot lahko vidimo v tabeli 2.1, imamo pet učnih primerov.

Zelo verjetno je, da se bo učni algoritem iz teh podatkov naučil naslednje pravilo:

$$\text{ČE } \textit{Spol} = \textit{ženski} \text{ POTEM } \textit{Gripa} = \textit{da}$$

Zgornje pravilo je videti uporabno, saj je kratko in pravilno diagnosticira vse paciente v množici podatkov. Vendar iz pogoja vidimo, da ni smiselno.

Z argumenti se učni problem spremeni v:

- z danimi učnimi primeri + argumenti za nekatere primere,
- najdi hipotezo, konsistentno z učnimi primeri in argumenti. To pomeni, da naj razlaga razreda vsebuje razloge, navedene v argumentu.

V ABML-ju si strokovnjak lahko izbere učne primere, ki bi jih rad razložil. Npr. da ekspert argumentira drugi primer iz tabele: “Ga. Novak ima gripo, ker ima visoko temperaturo.” Ta primer je zdaj **argumentiran učni primer**. Če pogledamo zgornje pravilo, vidimo, da pravilno uvrsti primer ge. Novak, a brez upoštevanja navedenega argumenta. Zatorej bi algoritem ABML induciral primernejše pravilo:

$$\text{ČE } \textit{Temperatura} = \textit{visoka} \text{ POTEM } \textit{Gripa} = \textit{da}$$



Takšno pravilo AB pokrije go. Novak.

Z argumentiranim strojnim učenjem pridobimo naslednje prednosti:

1. ker se omejimo na razlago posameznih učnih primerov, lažje izrazimo več domenskega znanja,
2. argumenti omejujejo prostor možnih hipotez in s tem zmanjšajo kompleksnost iskanja,
3. naučena hipoteza bo bolj smiselna, saj za razlago uporablja enake razloge kot strokovnjak sam.

Druga prednost posledično prispeva k hitrejšemu in učinkovitejšemu iskanju hipotez ter k manjši verjetnosti prevelikega prilagajanja podatkom.

Z omejitvijo razlag na posamezne primere se izognemo navedbam argumentom, ki bi veljali za celo domeno. Zadošča, da držijo v okviru argumentiranega primera. Algoritem ABML bo nato poskušal med učenjem posplošiti argument do te mere, da ohranimo konsistentnost z drugimi primeri.

## 2.1 Argumentirano učenje pravil

Obstaja veliko možnosti implementacije argumentiranega strojnega učenja. Ena izmed njih je učenje argumentiranih pravil, ki se imenuje ABCN2. Ta metoda je uporabljena tudi v magistrskem delu. Njena osnova je znan algoritem za učenje klasifikacijskih pravil CN2 [5].

Standardna oblika učnega primera E je sestavljena iz vrednosti atributov A in vrednosti razreda C. Poleg takšnih primerov ABCN2 sprejema tudi argumentirane primere. Argumentiran primer AE je oblike:

$$AE = (A, C, \text{arguments})$$

*Arguments* je množica argumentov  $Arg_1 \dots Arg_n$ . Argument je lahko *pozitiven* (vsebuje razloge v prid razredu), ali *negativen* (vsebuje razloge proti razredu). V magistrskem delu dovolimo samo en argument k vsakemu primeru, prav tako ne bomo uporabljali negativnih argumentov.

Argument vsebuje razloge, ki so konjunkcija pogojev, kjer se vsak pogoj nanaša samo na en atribut. Posamezen pogoj ima več možnih oblik:

- $X = x_i$  pomeni, da je vrednost  $x_i$  atributa  $X$  razlog v prid razredu. To je edina dovoljena oblika za diskretne attribute,
- $X > x_i$ ,  $X < x_i$  ali  $(X \geq x_i, X \leq x_i)$ . Ker je  $X$  večji/manjši od  $x_i$ , spada primer v dan razred,
- $X >$  ali  $X <$  pomeni, da je  $X$  visok oz. nizek. Oblika je zelo podobna zgornji, razlika je v tem, da ne poznamo mejne vrednosti, in bi radi, da jo algoritem določi avtomatsko.

Argument, dan k primeru *ge. Novak*, je v tej notaciji zapisan kot:

$$\textit{Gripa} = \textit{da}, \text{ ker } \textit{Temperatura} = \textit{visoka}.$$

V CN2 pravilo pokrije primer, če so vsi pogoji resnični za dani primer. V ABCN2 je definicija, kdaj je primer pokrit, razširjena: pravilo R AB pokrije argumentiran primer E, če:

1. morajo biti vsi pogoji v pravilu R resnični za primer E (enako kot v CN2),
2. je R konsistentno z vsaj enim pozitivnim argumentom E,
3. R ni konsistentno s kakšnim od negativnih argumentov E.

Za boljšo razumljivost razlik med AB- in običajno pokritostjo si oglejmo naslednji primer. Naj spomnimo, *ga. Novak* ima gripo, ker ima povišano temperaturo.

**R1:** ČE *Spol = ženski* POTEM *Gripa = da*.

**R2:** ČE *Spol = ženski in Temperatura = visoka* POTEM *Gripa = da*.

Obe pravili pokrivata omenjen primer, toda samo drugo pravilo AB pokrije primer.

## 2.2 Interativna zanka za zajemanje ekspertnega znanja

ABML je sestavljen iz dveh delov, in sicer iz modificiranega učnega algoritma, ki zna uporabljati tudi argumente ABCN2, in interativne zanke za zajemanje ekspertnega znanja, ki skrbi za interakcijo med strokovnjakom in programom. V vsakem ciklu zanke procedura najde kritični primer, ki ga je najprimerneje argumentirati. Vsaka iteracija vsebuje naslednje korake:

1. nauči se hipotezo z ABML-jem na danih učnih podatkih,
2. poišči kritični primer, ki bi bil primeren za argumentacijo. Ko ne najdemo več kritičnih primerov, je postopek končan,
3. ekspert poskuša razložiti izbran primer in nato doda argument. Če je primer pretežek, ga lahko preskoči,
4. vrnemo se na prvi korak.

Iskanje kritičnih primerov je izvedeno prek  $k$ -kratnega prečnega preverjanja, ponovljenega  $n$  krat (e. g.  $n = 4$ ,  $k = 5$ ). Napovedi razredov ABCN2 predstavljajo verjetnosti, da primer pripada določenemu razredu. Tako je najbolj kritičen primer tisti, ki ima najvišjo verjetnostno napako. Posledično je zelo verjetno, da bodo med kritičnimi primeri tudi osamelci (angl. *outlier*), kar ni nujno najboljše.

### 2.2.1 Izboljšava ekspertovih argumentov

V postopku učenja se velikokrat zgodi, da mora ABCN2 sam izpolniti del nepopolnega argumenta. V primeru, da tega ABCN2 ne uspe, potrebujemo dopolnitev argumenta s strani eksperta. Za ta namen je argumentiranje posameznega primera (tj. tretji korak zanke za zajemanje znanja) razdeljeno v nadaljnjih pet korakov:

1. razloži kritični primer. Če je primer pretežak, zaključimo s proceduro in najdemo nov kritični primer,
2. dodaj argument k primeru. Argument predstavlja več razlogov. Če razlog vsebuje koncept, ki ga še ni v domeni, je treba pred dodajanjem argumenta dodati ustrezen atribut,
3. najdi protiprimere. Če so argumenti nepopolni in jih ABCN2 ne zna dopolniti, potem se bo to videlo v protiprimerih. To so vsi tisti primeri, ki imajo različen razred od kritičnega primera, in njihova verjetnostna napaka se je povečala z uporabo argumenta pri učenju,
4. izboljšaj argument. Ekspertu je zdaj postavljeno vprašanje: “Zakaj je kritični primer v tem razredu in protiprimer v drugem?” Odgovor je dodan trenutnemu argumentu,
5. vrni se na tretji korak, če smo našli protiprimer.

Teh pet korakov predstavlja zajemanje znanja v sklopu postopka ABML.

V našem primeru diagnosticiranja gripe učni algoritem poda ekspertu protiprimer: “G. Mlinar ima povišano temperaturo, toda nima gripe.” Ekspertov odgovor na to vprašanje je: “G. Mlinar je opravil cepljenje proti gripi.”

Z izboljšanim argumentom ABML pride do pravila s 100-odstotno natančnostjo:

ČE *Temperatura = visoka* IN *CepljenjeOpravljeno = ne*  
POTEM *Gripa = da*

## Poglavje 3

# Pristopi za ocenjevanje argumentov

ABCN2 v originalni implementaciji ne posreduje informacije o kakovosti danega argumenta. Izvemo samo, kateri so najdeni protiprimeri. Če se je argument pokazal v novem pravilu, lahko pričakujemo, da je argument dober. Ne poznamo pa kakovosti argumenta, če ostane naučena hipoteza nespremenjena. S podajanjem takojšnje povratne informacije o kvaliteti podanega argumenta bi tako domenskemu ekspertu omogočili boljši vpogled v njegovo znanje in mu tudi pomagali k bolj jasni artikulaciji znanja. Povratne informacije o ustreznosti argumenta bi bile uporabne tudi kot del inteligentnega tutorskega sistema, saj s tem učenca vodimo k pravilom, ki so bolj skladna z učiteljevim znanjem.

Ker pristopa  $P1$  in  $P3$  delujeta v teoretičnem okviru ocenjevanja kakovosti odločitvenih pravil (angl. *decision rules*), bomo najprej na kratko predstavili ocenjevanje kakovosti pravil. Z oceno kakovosti pravila se poskuša oceniti točnost pravila pri napovedi novih primerov. Algoritem CN2 v originalni izvedbi uporablja Laplaceovo formulo  $\frac{p+1}{n+2}$ . Tu je  $p$  število pozitivnih pokritih primerov,  $n$  pa število vseh pokritih primerov. Namesto Laplaceove formule je v ABCN2 uporabljena  $m$ -ocena [3]. Razlika med formulama je v tem, da Laplaceova formula predpostavlja enakomerno apriorno distribu-

cijo primerov, medtem ko  $m$ -ocena uporabi število pozitivnih in negativnih primerov v učni množici za določitev apriorne distribucije.

$$\frac{p + m \cdot p_a}{n + m} \quad (3.1)$$

Tu je  $p$  število pozitivnih pokritih primerov,  $p_a$  apriorna verjetnost in  $m$  parameter metode. Npr. ocena pravila brez pozitivnih pokritih primerov bo tako enaka apriorni verjetnosti pozitivnih primerov v učni množici namesto enakomerne apriorne verjetnosti  $\frac{1}{2}$  (pri Laplaceu). S parametrom  $m$  lahko določamo pomembnost apriorne verjetnosti v oceni. Višje vrednosti  $m$  dajo večjo težo apriorni verjetnosti, kar je primerno pri šumnih učnih podatkih.

### 3.1 Pristop P1: ocena

P1 z numerično oceno pove, kako dober je argument. Ta ocena se izračuna tudi v postopku iskanja pravil z algoritmom ABCN2. S to oceno ABCN2 določi, kateri argumenti bodo uporabljeni najprej v postopku iskanja pravil. Prek dane ocene izvemo uspešnost nerazširjenega argumenta, tj., kako dobro pogoji v argumentu zagovarjajo, da je nek primer v danem razredu.

V postopku računanja ocene se podan argument pretvori v pravilo, kot če bi bil argument pravilo oblike:

ČE razlogi argumenta POTEM trditev argumenta

Ocena argumenta je nato ocena pravila, ocenjenega z  $m$ -oceno. Primer prikaza povratne informacije o oceni argumenta je prikazan v izpisu 3.1. Poleg ocene argumenta, ki se nahaja v tretji vrstici, prikažemo še najdeno pravilo.

```
1 Computing |P1|
2 IF equity_ratio > 0.40 THEN credit_score=A<51.000, 14.000>
3 m: 0.78
```

Izpis 3.1: Primer izhoda P1.

Tu je uporabnik navedel argument: Če ima podjetje *equity\_ratio* > 0.4, potem spada v bonitetni razred A. Atribut *equity\_ratio* predstavlja delež

lastnega kapitala v podjetju. Ker je ustrezna velikost lastnega kapitala v podjetju le eden izmed pogojev za dobro bonitetno oceno podjetja, je ta argument ocenjen slabo, ima namreč oceno  $m = 0.77$ . Argumenti, ki imajo oceno nad 0.9, veljajo za zelo dobre argumente.

## 3.2 Pristop P2: prispevek

Prek *P2* poskušamo izmeriti, koliko bi argument prispeval k trenutni hipotezi. Tu primerjamo dve hipotezi, in sicer HP ter HPOneRule. HP so pravila, naučena z algoritmom ABCN2 z upoštevanjem vseh do sedaj vnesenih argumentov razen trenutnega. HPOneRule vsebuje samo eno pravilo, ki je sestavljeno iz razlogov trenutnega argumenta, torej na enak način kot v *P1*.

Izračunamo tri števila, ki povejo, koliko primerov je “popravljenih”, “pokvarjenih” in “nepopravljenih”. Tu gre samo za primere, ki jih pokrijeta obe hipotezi. Popravljeni primeri so tisti, ki jih HP napove narobe in HPOneRule prav. Pokvarjene primere HP napove pravilno in HPOneRule narobe. Nepopravljene primere obe hipotezi uvrstita narobe. Zgoraj opisane kategorije primerov so predstavljene tudi v tabeli 3.1.

		HP	
		Prav	Narobe
HPOneRule	Prav	/	#popravljenih
	Narobe	#pokvarjenih	#nepopravljenih

Tabela 3.1: Kategorije primerov, izračunane v *P2*.

V izpisu lahko vidimo tudi primer prikaza povratnih informacij izračunanih prek *P2*.

```

1 Computing |P2|
2 Corrected: 1, faulted: 10, not corrected: 0

```

Izpis 3.2: Primer izhoda *P2*.

V tem primeru z argumentom pridemo do pravila, ki pravilno uvrsti nov primer, a ima težave pri uvrščanju že pravilno uvrščenih primerov.

### 3.3 Pristop P3: potencial

Povratne informacije, podane v sklopu *P3*, so uporabne predvsem kot del inteligentnega tutorskega sistema. Ustreznost argumenta ugotavljamo s pomočjo možnih razširitev in obrezovanj pogojev. Natančneje, za dan argument generiramo obrezana pravila, ki ne vsebujejo enega izmed pogojev v argumentu, in razširjena pravila, ki imajo dodan en nov pogoj. Pri razširjanju argumenta so posamično preizkušeni vsi atributi, ki niso omenjeni v argumentu.

Dobljena pravila ocenimo z  $m$ -oceno in razvrstimo po kvaliteti. Nato izračunamo absolutno razliko v oceni med pravilom, ki je najbolj ocenjeno v množici obrezanih in razširjenih pravil, ter pravilom, najdenim s *P1*, kar lahko vidimo v enačbi 3.2.

$$\text{razlika} = |m_{P3_{\text{najboljši}}} - m_{P1}| \quad (3.2)$$

Potencial argumenta predstavlja vrednost  $m_{P3_{\text{najboljši}}}$ . Izračunamo tudi, ali je katero izmed obrezanih pravil ocenjeno bolje kot originalno pravilo. V tem primeru gre za predolg argument.

Uporabniku prikažemo razliko, potencial in informacijo, ali vsebuje argument preveč razlogov. Poleg tega ima na voljo tudi dve najbolj ocenjeni obrezani pravili in pet najbolj ocenjenih razširjenih pravil.

Z opazovanjem obrezanih pravil lahko uporabnik opazi, ali je kakšen del argumenta odveč, medtem ko nova pravila delujejo kot namigi k boljšemu argumentu. V izpisu 3.3 lahko vidimo primer prikaza povratnih informacij *P3* z argumentom: visok *equity.ratio* in visok *current.ratio*.

Iz obrezanih pravil, prikazanih med šesto in deseto vrstico, vidimo, da sta oba razloga v argumentu koristna. V razširjenih pravilih, ki so vidna med dvanajsto in dvaindvajseto vrstico, pa so predstavljene možne razširitve, ki



pokažejo, s katerimi razlogi lahko dosežemo še boljši argument.

```
1 Computing |P3|
2 one rule:
3 m: 0.84 IF equity.ratio >0.40 AND current.ratio >1.34
4     THEN bon.ocena=A<45, 8>
5
6 pruned rules:
7 m: 0.78 IF equity.ratio >0.40
8     THEN bon.ocena=A<51, 14>
9 m: 0.73 IF current.ratio >1.89
10    THEN bon.ocena=A<34, 12>
11
12 extended rules:
13 m: 0.98 IF cisti.dobicek >122.64K AND equity.ratio >0.30 AND current.ratio >0.85
14    THEN bon.ocena=A<40, 0>
15 m: 0.97 IF equity.ratio >0.40 AND EBIT >78.38K AND current.ratio >0.85
16    THEN bon.ocena=A<38, 0>
17 m: 0.97 IF equity.ratio >0.40 AND DT >261.91K AND current.ratio >1.17
18    THEN bon.ocena=A<34, 0>
19 m: 0.95 IF equity.ratio >0.40 AND krtk.obv >1.93M AND current.ratio >1.17
20    THEN bon.ocena=A<21, 0>
21 m: 0.95 IF equity.ratio >0.40 AND zaloge >1.22M AND current.ratio >-9.91
22    THEN bon.ocena=A<19, 0>
23 abs. diff: 0.14
24 potential: 0.98
25 is too specialized: False
```

Izpis 3.3: Primer izhoda *P3*.

Zadnje tri vrstice predstavljajo najpomembnejši del izhoda. Prikazujejo namreč izračunano razliko, potencial najboljšega pravila in informacijo o tem, ali je argument predolg.



## Poglavje 4

# Zajemanje znanja iz eksperta/učitelja

Za učni problem smo si izbrali dodeljevanje bonitetnih ocen podjetjem na podlagi finančnih izkazov. V ciljih magistrskega dela je naveden tudi prikaz interaktivne zanke za zajemanje znanja s pomočjo ABML, uporabljene kot tutorski sistem. S kombinacijo zgornjih dveh nalog smo razvili ITS, ki učenca nauči osnove finančne analize. Z izvedbo tega eksperimenta smo pokazali tudi uporabnost razvitih pristopov za pomoč pri argumentiranju.

Finančni izkazi in bonitetne ocene so bile pridobljene prek aplikacije Gvin [16] podjetja Bisnode, d. o. o. Finančni strokovnjak je izbral začetne attribute in nato z uporabo zanke za zajemanje znanja uvedel izpeljane attribute, ki predstavljajo višjenivojske koncepte, in preoblikoval primere v skladu s svojim znanjem. Pod preoblikovanje štejemo spremembo razreda pri posameznih primerih. To je pomemben del priprave tutorskega sistema, saj hočemo študentu omogočiti čim lažje učenje in ga nočemo obremenjevati z nekonsistentnim znanjem.

Po izvedbi postopka ABML smo s strokovnjakom prišli do desetih novih atributov in konsistentne učne množice. Ta je bila nato uporabljena v tutorskem sistemu za učenje dodeljevanja bonitetnih ocen. Primeri, ki so sestavljali testno množico v zajemanju znanja iz učitelja, niso bili del na-

bora podatkov v tutorskem sistemu. Uspešnost učenja učencev s tutorskim sistemom smo preverili na treh udeležencih.

## 4.1 Opis učnega problema

Dodeljevanje bonitetnih ocen oz. ocenjevanje kreditnega tveganja igra pomembno vlogo v zagotavljanju finančnega zdravja finančnih in nefinančnih podjetij. Dajalec kredita se na podlagi bonitetne ocene odloči, ali je podjetje primerno za odobritev posojila in kakšna naj bo cena le-tega. Podjetja z višjim tveganjem težje pridobijo nova posojila, saj obstaja večja možnost, da dolg ne bo odplačan, kar lahko privede do velikih izgub na strani posojilodajalca. Ocena kreditnega tveganja ni pomembna samo za finančne institucije, ampak tudi za običajna podjetja, saj je večina prodaje med podjetji izvedena na kredit.

Če hočemo dobiti dobro oceno kreditnega tveganja, moramo izvesti analizo tveganj različnih dejavnikov, ki vplivajo na delovanje podjetja. Ti dejavniki so [1]:

- značilnosti države (stanje infrastrukture, politična klima, pravni red, korupcija ...),
- tveganja, prisotna v industriji (gradbeništvo je ena izmed bolj tveganih panog, zamirajoče panoge imajo slab prodajni potencial ...),
- tveganja, specifična za podjetje (premajhen nabor dobaviteljev/kupcev, občutljivost na spremembe cen surovin ...),
- ocena menedžmenta (integriteta, sposobnost ...),
- ocena finančnega tveganja (profitabilnost, stopnja uporabe finančnega vzvoda ...),
- ocena vpliva dosedanjih dolgov na prihodnje poslovanje (datum zapadlosti dolga, dogovorjene finančne obveze v kreditnih pogodbah ...) itd.

V našem učnem problemu smo se osredotočili na oceno finančnega tveganja. Ta ocena je narejena na podlagi finančnih izkazov. V postopku reševanja učnega problema smo uporabili naslednje izkaze: bilanco stanja, izkaz poslovnega izida in izkaz denarnega toka. Bilanca stanja prikazuje finančno stanje podjetja na določen datum. V izkazu poslovnega izida so zajeti prihodki in odhodki ter končen poslovni izid v obračunskem letu. Ostane še izkaz denarnih tokov, ki prikazuje prejeme in izdatke v okviru treh različnih aktivnosti: poslovanja, naložbenja in financiranja.

## 4.2 Priprava podatkov


Iz aplikacije Gvin smo pridobili bilanco stanja, izkaz poslovnega izida, del izkaza denarnega toka in finančno oceno za 325 podjetij. Finančni izkazi so vsebovali podatke za leta 2010, 2011, 2012 in 2013. Gvinove finančne ocene prikazujejo poslovanje podjetja v preteklem letu in se izračunavajo enkrat na leto. Možnih je pet ocen, označenih s črkami od A do E.

Z namenom boljše razumljivosti pri učenju s tutorskim sistemom smo teh pet razredov razdelili med dva nova razreda, in sicer med A in E. Novi razred A so dobila vsa podjetja z oceno A in B, v novem razredu E pa so vsa podjetja z oceno C, D in E. Oceno A si zaslužijo vsa podjetja, za katera lahko rečemo, da v prihodnosti ne bodo imela problemov s plačevanjem obveznosti. Oceno E dobijo tista podjetja, ki so prezadolžena oz. kažejo na to, da bodo imela probleme s plačevanjem obveznosti.

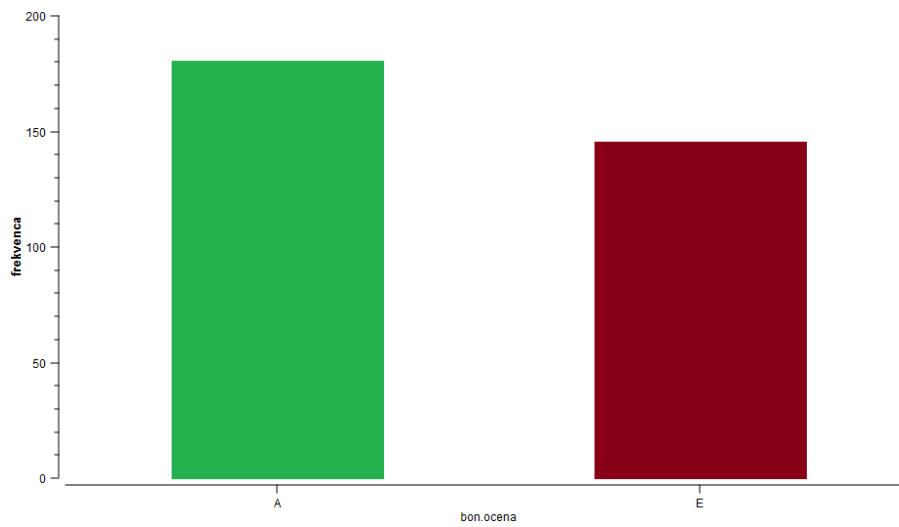
Na slikah 4.1 in 4.2 lahko vidimo začetno in končno porazdelitev razredov. V končni porazdelitvi nastopa 180 primerov podjetij z bonitetno oceno A in 145 podjetij z oceno E.

## 4.3 Opis začetnih atributov

Skupaj s finančnim strokovnjakom smo izbrali 28 atributov. 25 jih je uporabljenih za učenje pravil, ostali trije so informativne narave. Vsi atributi, ki



Slika 4.1: Začetna distribucija razredov.



Slika 4.2: Končna distribucija razredov.

so vzeti iz finančnih izkazov, so iz zadnjega poslovnega leta (2013). Pri opisu atributov smo si pomagali z viroma [15, 16].

**1. id**

Informativni atribut ime podjetja.

**2. dejavnost**

Dejavnost podjetja po standardni klasifikaciji dejavnosti (v nadaljevanju SKD) na prvem nivoju (vrednosti od A do U).

**3. dejavnost.id**

Informativni atribut id dejavnosti po SKD-ju.

**4. dejavnost.naziv**

Informativni atribut ime dejavnosti po SKD-ju.

**5. velikost**

Velikost podjetja: malo, srednje ali veliko (S, M, L).

**6. prihodki.od.prodaje**

Prodajne vrednosti prodanih proizvodov oziroma trgovskega blaga in materiala ter opravljenih storitev v obračunskem obdobju.

**7. stroški.blaga.materiala.in.storitev**

Stroški nabavne vrednosti prodanega blaga in materiala, stroški porabljenega materiala in stroški storitev.

**8. stroški.dela**

Stroški, ki se nanašajo na obračunane plače, nadomestila plač in dajatve, ki pripadajo zraven.

**9. odpisi.vrednosti**

Odpisi vrednosti zajemajo:

- stroške amortizacije, ki so stroški, povezani s prenašanjem vrednosti amortizirljivih sredstev na poslovne učinke,

- prevrednotenje določenih vrst sredstev (npr. odpisa terjatev).

#### 10. fin.odhodki

Finančni odhodki so odhodki za financiranje in odhodki za naložbenje.

Sestavljajo jih:

- stroški danih obresti,
- prevrednotovalni finančni odhodki (npr. odpis naložb).

#### 11. obresti

Tisti del finančnih odhodkov, ki predstavlja stroške obresti.

#### 12. EBIT

Poslovni izid iz poslovanja.

$$EBIT = EBITDA - odpisi.vrednosti$$

#### 13. EBITDA

Poslovni izid pred davki, obrestmi in amortizacijo.

$$EBITDA \approx prihodki.od.prodaje - stroški.blaga.materiala.in.storitev - stroški.dela$$

#### 14. cisti.dobicek

Razlika med vsemi prihodki in vsemi odhodki, zmanjšana za obračunan davek.

#### 15. sredstva

Celotna sredstva podjetja (bilančna vsota).

#### 16. kapital

Lastniški kapital v podjetju. Razlika med celotnimi sredstvi in vsemi obveznostmi.

#### 17. fin.dolg

Celoten finančni dolg podjetja. Vsota kratkoročnih in dolgoročnih finančnih obveznosti.



**18. denarna.sredstva**

Denarna sredstva so sredstva v blagajni, prejeti čeki in drugi takoj unovčljivi vrednostni papirji ter knjižni denar (denar na računih pri bankah in drugih finančnih institucijah, depoziti na vpogled).

**19. dlг.sredstva**

Sestavljajo neopredmetena sredstva in dolgoročne aktivne časovne razmejitve, opredmetena osnovna sredstva, naložbene nepremičnine, dolgoročne finančne naložbe, dolgoročne poslovne terjatve in odložene terjatve za davek.

**20. krtk.sredstva**

So sredstva, ki se nenehno preoblikujejo, sestavljajo jih sredstva za prodajo, zaloge, kratkoročne finančne naložbe, kratkoročne poslovne terjatve, denarna sredstva in kratkoročne aktivne časovne razmejitve.

**21. cel.posl.obv**

Celoten poslovni dolg podjetja, tj. dolg, povezan s poslovanjem podjetja. Sem spadajo dobaviteljski krediti, obveznosti do zaposlencev, obveznosti do države iz naslova davkov ...

**22. krtk.posl.obv**

So poslovne obveznosti podjetja, ki zapadejo v plačilo v obdobju, krajšem od leta dni. Primeri obveznosti so naštetih v prejšnjem opisu.

**23. obratni.kapital**

Višina sredstev brez obveznosti, ki jih ima podjetje za poslovanje in uporabo dodatnih finančnih obveznosti. Ponazarja nam višino denarnih sredstev, ki jih mora priskrbeti podjetje za financiranje obratnega kapitala iz dodatnih virov.

**24. dlг.obv**

Dolgoročne obveznosti so obveznosti (poslovne in finančne) z rokom zapadlosti plačila, daljšim od leta dni od njihovega nastanka oziroma od datuma bilance stanja.

**25. krtk.obv**

Kratkoročne obveznosti so obveznosti v zvezi s financiranjem lastnih sredstev, ki zapadejo v plačilo v obdobju, krajšem od leta dni. Zajemajo obveznosti, vključene v skupine za odtujitev, kratkoročne finančne obveznosti in kratkoročne poslovne obveznosti.

**26. zaloge**

Zaloge so praviloma sredstva v opredmeteni obliki, ki bodo porabljena pri ustvarjanju proizvodov ali opravljanju storitev oziroma pri proizvodnji za prodajo ali prodana v okviru rednega delovanja. Zajemajo zaloge materiala, zaloge nedokončane proizvodnje, zaloge gotovih proizvodov in zaloge trgovskega blaga ter predujme za zaloge.

**27. DT**

Denarni tok iz poslovanja.

$$DT = \text{cisti.dobicek} + \text{odpisi.vrednosti}$$

**28. PDT**

Denarni tok iz poslovanja, popravljen za spremembe v obratnih sredstvih. Spremembe v obratnih sredstvih so posledica investicij oz. dezinvesticij v obratna sredstva. Povečanje obratnih sredstev je lahko posledica povečanega obsega prodaje gospodarske družbe ali dolgotrajnejšega zadrževanja sredstev v zalogah in terjatvah. Povečanje obratnih sredstev pomeni odtok (negativna vrednost).

$$PDT = DT + \text{spremembe.v.obratnih.sredstvih}$$

Vsi zgoraj naštetih atributi so zbrani v tabeli 4.1.

## 4.4 Zajemanje ekspertnega znanja

V tej sekciji je na kratko opisan potek zajemanja ekspertnega znanja, s katerim smo prišli do konsistentne baze znanja in uvedli deset novih atributov, ki predstavljajo naprednejše koncepte finančne analize in so tudi primernejši za primerjavo med podjetji.

#	Atribut	Opis
1	id	Ime podjetja
2	dejavnost	Tip dejavnosti
3	dejavnost.id	Id dejavnosti
4	dejavnost.ime	Ime dejavnosti
5	velikost	Velikost podjetja
6	prihodki.od.prodaje	Čisti prihodki od prodaje
7	stroski.blaga.materiala. in.storitev	Stroški blaga, materiala in storitev
8	stroski.dela	Stroški dela
9	odpisi.vrednosti	Odpisi vrednosti
10	fin.odhodki	Finančni odhodki
11	obresti	Stroški obresti
12	EBIT	Poslovni izid iz poslovanja
13	EBITDA	Poslovni izid pred davki, obrestmi in amortizacijo
14	cisti.dobicek	Čisti dobiček
15	sredstva	Bilančna vsota
16	kapital	Kapital
17	fin.dolg	Kratkoročne + dolgoročne finančne obveznosti
18	denarna.sredstva	Denarna sredstva
19	dlg.sredstva	Dolgoročna sredstva
20	krtk.sredstva	Kratkoročna sredstva
21	cel.posl.obv	Kratkoročne + dolgoročne poslovne obveznosti
22	krtk.posl.obv	Kratkoročne poslovne obveznosti
23	obratni.kapital	Obratni kapital
24	dlg.obv	Dolgoročne obveznosti
25	krtk.obv	Kratkoročne obveznosti
26	zaloge	Zaloge
27	DT	Denarni tok iz poslovanja
28	PDT	Popravljen denarni tok

Tabela 4.1: Seznam začetnih atributov.

#### **4.4.1 Potek postopka ABML**

Pred učenjem smo podatke razdelili na učno (70 %) in testno (30 %) množico. V prvi iteraciji postopka se ABCN2 nauči hipoteze z 41 pravili. Klasifikacijska točnost teh pravil je 80 %. Lahko rečemo, da točnost ni slaba, a moti nas število pravil in njihova slaba razumljivost.

V tabeli 4.2 so zbrane pomembnejše informacije o poteku postopka. Vidimo, da je večino novih atributov dodanih v sklopu prvih štirih iteracij. Prav tako je v teh štirih iteracijah izvedenih 72 % sprememb razreda primerov. Zelo hitro pridemo tudi do nizkega števila naučenih pravil, nato je število pravil bolj ali manj konstantno. Klasifikacijska točnost je največja med šesto in dvanaajsto iteracijo. Razlog temu je, da s podajanjem novih argumentov in popravljanjem razredov določenih primerov učitelj oblikuje nabor podatkov v skladu s svojim znanjem. To pa ne prispeva nujno k povečanju klasifikacijske točnosti napovedi na testni množici, saj primeri v tej množici ne pridejo v učiteljev pregled in tako lahko ostanejo označeni z manj primernim razredom.

#### **4.4.2 Opis dobljenih atributov**

Pomemben del zajemanja ekspertnega znanja je bila pridobitev novih atributov, ki predstavljajo pogosto uporabljene koncepte v sklopu finančne analize podjetja. S poznavanjem teh atributov bodo učenci pridobili osnovno razumevanje in prepoznavanje finančnega tveganja. Sem spadajo ocenjevanje primernosti kapitalske strukture, ocena uspešnosti podjetja (dobičkonosnost, rast prihodkov ...) in presoja, ali podjetje ustvarja zadosten denarni tok.

Dobljeni atributi so večinoma finančni kazalniki, ki predstavljajo razmerja med atributi iz začetnega nabora podatkov. Del opisov smo povzeli iz virov [1, 4, 15].

it	CA	# pravil	# novih atributov	skupno # novih atr.	# sprememb razreda
1	0.806	41	3	3	10
2	0.837	25	2	5	3
3	0.837	31	1	6	0
4	0.847	30	2	8	3
5	0.878	24	0	8	1
6	0.867	26	0	8	0
7	0.867	26	0	8	1
8	0.867	26	0	8	0
9	0.867	26	0	8	1
10	0.867	25	1	9	0
11	0.867	25	0	9	1
12	0.867	23	0	9	1
13	0.847	26	0	9	1
14	0.847	22	0	9	0
15	0.847	22	1	10	0
16	0.847	22	0	10	0
17	0.837	24	0	10	0
18	0.837	24	0	10	0
19	0.837	24	0	10	0
20	0.837	24	0	10	0
21	0.837	24	0	10	0
22	0.847	23	0	10	0
23	0.847	23	0	10	0
F	0.847	23	0	10	/

Tabela 4.2: Evalvacija zajemanja znanja iz učitelja.

**1. cel.posl.obv/sredstva [%]**

$$\frac{\textit{Celotne poslovne obveznosti}}{\textit{Celotna sredstva}} \quad (4.1)$$

Finančni kazalnik 4.1 predstavlja strukturni delež poslovnih obveznosti v celotni bilanci. Z drugimi besedami, kolikšen je obseg poslovnega dolga, to so krediti, dobljeni na podlagi kreditnih pogodb, dolg pri dobaviteljih, obveznosti do zaposlenecv itd. Podjetja z visoko vrednostjo tega kazalnika so po navadi zelo zadolžena pri dobaviteljih. Razlog temu je lahko otežen dostop do financiranja prek bank, izdanih obveznic in drugih bolj običajnih načinov pridobivanja finančnih sredstev.

**2. current.ratio**

$$\frac{\textit{Kratkoročna sredstva}}{\textit{Kratkoročne obveznosti}} \quad (4.2)$$

Kratkočni koeficient likvidnosti 4.2 nam pove, ali podjetje obvladuje svoje kratkoročne obveznosti. Ponazarja denarna sredstva in ostala kratkoročna sredstva, ki se bodo v roku enega leta preoblikovala v denar, v razmerju z obveznostmi, ki zapadejo v plačilo v enem letu. Visoka vrednost kaže, da naj bi imelo podjetje na razpolago zadosti tekočih sredstev za poplačilo tekočih dolgov, medtem ko majhna vrednost kaže na pomanjkanje tekočih sredstev za odplačilo. V nekaterih primerih lahko visok kratkoročni koeficient pomeni tudi, da ima podjetje težave s prodajo zalog in pobiranjem terjatev. Zadovoljiva vrednost koeficienta je okoli 1.5.

**3. dlj.rast.prihodkov [%]**

$$\sqrt[t_n-t_0]{\frac{\textit{Prihodki od prodaje}_{t_n}}{\textit{Prihodki od prodaje}_{t_0}}} - 1 \quad (4.3)$$

Dolgoročna rast prihodkov je izračunana s formulo 4.3, ki nam da sestavljeno letno rast "Compound Annual Growth Rate". S CAGR-jem ublažimo volatilitnost prihodkov skozi leta. V naši zbirki podatkov

imamo dostop do prihodkov med letoma 2010 in 2013, zato sta  $t_0$  in  $t_n$  enaka 2010 in 2013. Za podjetja, ki imajo letno rast prihodkov nad 7-odstotno, lahko rečemo, da imajo zelo dobro rast.

#### 4. krtk.rast.prihodkov [%]

Kratkoročna rast prihodkov je podobna prejšnjemu kazalniku, le da tu gledamo, kakšna je sprememba v prihodkih glede na zadnje leto. Tudi dobrim podjetjem lahko v posameznih letih padejo prihodki od prodaje, ampak če je ta padec zelo visok, lahko to privede podjetje v finančne težave.

#### 5. spr.ebit.marzi

$$\frac{EBIT_{t_n}}{\text{Prihodki od prodaje}_{t_n}} - \frac{EBIT_{t_0}}{\text{Prihodki od prodaje}_{t_0}} \quad (4.4)$$

Sprememba v marži EBIT med izbranimi letoma je izračunana s formulo 4.4. Marže so zaslužki, izraženi v odstotkih od prodaje. Z maržami izmerimo, kakšna je dobičkonosnost podjetja. Naš kazalnik nam s primerjavo dveh marž EBIT v različnih letih poskuša prikazati, kako velika je sprememba v dobičkonosnosti podjetja. Z dobro rastjo in slabšo dobičkonosnostjo lahko pridemo do istega rezultata kot brez rasti prihodkov in brez sprememb v maržah. V našem primeru smo gledali, kakšne so bile spremembe na dolgi rok, tj., da smo uporabili vrednosti za leti 2010 in 2013.

#### 6. net.fin.dolg/EBITDA

$$\frac{\text{Finančni dolg} - \text{Denarna sredstva}}{EBITDA} \quad (4.5)$$

Finančni kazalnik 4.5 je eden izmed najbolj informativnih kazalnikov. Meri sposobnost odplačila dolga na dolgi rok. Kazalnik predstavlja, koliko let bi trajalo odplačilo dolga pri nespremenjenem dolgu in konstantni EBITDI. Ta služi kot približek denarnega toku. Dolg namreč

lahko poplačamo samo z denarnimi sredstvi in ne z računovodsko postavko, kot je EBITDA. Vrednost, manjša ali enaka 0, pomeni, da podjetje nima dolga oz. so njegova denarna sredstva večja od finančnih obveznosti. Vrednosti, večje od 4, kažejo na povečano tveganje o odplačevanju dolga v prihodnosti.

Zaradi lažje primerjave med podjetji in izogibanja ekstremnim vrednostim smo zgornjo mejo kazalnika postavili na vrednost 30. Poleg tega smo vsem podjetjem z negativno EBITDO določili vrednost kazalnika na 30.

## 7. *equity.ratio*

$$\frac{Kapital}{Sredstva} \quad (4.6)$$

Delež kapitala v celotnih sredstvih 4.6 nam pove, koliko sredstev je financiranih z lastnim kapitalom. Podjetja lahko z uporabo dolga zmanjšajo potrebe po lastnem kapitalu in s tem povečajo donosnost vloženega kapitala. Temu pravimo tudi uporaba finančnega vzvoda. Posledica visokega finančnega vzvoda je visoko finančno tveganje. Primeren delež lastninskega kapitala v podjetju je odvisen od več kriterijev: sektorja, velikosti, ciljev itd. Podjetja z majhno vrednostjo kazalnika (manj kot 0.3) težje pridejo do ugodnega financiranja.

## 8. TIE (angl. *times interest earned*)

$$\frac{EBIT}{Stroški\ obresti} \quad (4.7)$$

Kazalnik TIE nakazuje, kolikokrat poslovni prihodki iz poslovanja pokrijejo stroške obresti. Sprejemljiva vrednost je nad 1.2. Tukaj smo omejili maksimalno vrednost na 100. Podjetjem brez stroškov obresti smo določili maksimalno vrednost.



**9. ROA (angl. return on assets) [%]**

$$\frac{EBIT}{Sredstva} \quad (4.8)$$

Donosnost sredstev meri uspešnost uporabe sredstev neodvisno od financiranja teh sredstev. Večja vrednost kazalnika pomeni boljšo donosnost podjetja.

**10. javno**

Možne vrednosti atributa *javno* so: TRUE, FALSE. Atribut označuje, katera podjetja so v javni lasti. Za ta podjetja velja, da je njihovo zagotovilo država, kar bistveno zmanjša tveganje neodplačila dolga.

Povzetek novih atributov je viden v tabeli 4.3.

#	Atribut	Opis
1	cel.posl.obv/sredstva [%]	Delež poslovnih obveznosti v celotni bilanci
2	current.ratio	Kratkoročni koeficient likvidnosti $krt.sredstva / krt.obveznosti$
3	dlg.rast.prihodkov [%]	Dolgoročna rast prihodkov
4	krtk.rast.prihodkov [%]	Kratkoročna rast prihodkov
5	spr.ebit.marzi	Razlika v marži EBIT med letoma 2010 in 2013
6	net.fin.dolg/EBITDA	Zmožnost poplčila finančnega dolga $(fin.dolg - denarna.sredstva) / EBITDA$
7	equity.ratio	Delež kapitala v celotni bilanci $kapital / sredstva$
8	TIE	Zmožnost plačila obresti $EBIT / obresti$
9	ROA [%]	Donosnost sredstev $EBIT / sredstva$
10	javno	Ali je podjetje v javni lasti

Tabela 4.3: Seznam novih atributov.



## Poglavje 5


# Zajemanje znanja iz učenca

Pred začetkom učenja z ITS-jem so bili učencem na kratko predstavljeni atributi, s katerimi bodo lahko argumentirali. Za boljše razumevanje naprednejših konceptov, ki se skrivajo v izpeljanih atributih, so morali učenci poznati osnovne postavke finančnih izkazov. Zato smo učencem z manjkajočim znanjem najprej obrazložili osnove finančne analize.

Nato je bila učencem dana naloga, naj z uporabo atributov določijo pravila, ki podajo bonitetno oceno podjetju. Pri tem se naj osredotočijo predvsem na izpeljane attribute. To so atributi, ki so bili pridobljeni v postopku zajemanja znanja iz učitelja. Učencem smo tudi svetovali, naj podajajo razloge:

- ki vsebujejo najbolj pomembne attribute, ki razlagajo trenutni primer,
- da uporabijo najmanjše število atributov v samem argumentu,
- da se poskusijo izogniti ponavljanju istih argumentov.

Poleg kratkih navodil so imeli učenci na voljo tudi prikaz distribucij izpeljanih atributov. S tem so pridobili občutek o možnih vrednostih posameznih atributov. S podporo raznih izrisov (distribucije, statistike ...) bi ITS postal še uporabnejši in spodbujal še hitrejše učenje. Na sliki 5.1 lahko vidimo primer prikaza atributa ROA.



Slika 5.1: Histogram distribucije atributa ROA.

Definicija razredov je bila podana takole: oceno A si zaslužijo vsa podjetja, za katera lahko rečemo, da v prihodnosti ne bodo imela problemov s plačevanjem obveznosti. Oceno E dobijo tista podjetja, ki so prezadolžena oz. kažejo na to, da bodo imela probleme s plačevanjem obveznosti.

V nadaljevanju bodo predstavljene tri ilustrativne iteracije izbrane učne seje, ki prikazujejo delovanje razvitih pristopov. Celoten postopek je obsegal enajst iteracij. Povzetek ostalih iteracij učne seje je opisan v dodatku A. Učenec je v povprečju podal dva argumenta na iteracijo.

## 5.1 Iteracija 1

Prvi kritični primer je bilo podjetje *GOZDNO GOSPODARSTVO NOVO MESTO*, d. d. 5.1.

1		id	GOZDNO GOSPODARSTVO
2		dejavnost.id	2.2
3		dejavnost.ime	SECNJA
4	1	dejavnost	A
5	2	velikost	M
6	IPI		
7	3	prihodki.od.prodaje	17,269,248
8	4	stroski.blaga.materiala.in.stor	9,132,386
9	5	stroski.dela	4,482,689
10	6	odpisi.vrednosti	908,997
11	7	fin.odhodki	254,141
12	8	obresti	254,141
13	9	EBIT	563,758
14	10	EBITDA	1,472,755
15	11	cisti.dobicek	344,212
16	BS		
17	12	sredstva	17,155,984
18	13	kapital	9,537,284
19	14	fin.dolg	4,770,110
20	15	denarna.sredstva	142,605
21	16	dlg.sredstva	12,355,141
22	17	krtk.sredstva	4,800,843
23	18	cel.posl.obv	2,375,524
24	19	krtk.posl.obv	2,375,524
25	20	dlg.obv	1,467,846
26	21	krtk.obv	5,677,788
27	22	zaloge	683,007
28	CF		
29	23	DT	1,076,205
30	24	PDT	1,665,647
31	Ratios		
32	25	**cel.posl.obv/sredstva	13.8 %
33	26	**current.ratio	0.85
34	27	**dlg.rast.prihodkov	4.4 %
35	28	**krtk.rast.prihodkov	12.3 %
36	29	**spr.ebit.marzi	-0.2
37	30	**net.fin.dolg/EBITDA	3.14
38	31	**equity.ratio	0.56
39	32	**TIE	2.22
40	33	**ROA	3.3 %
41	34	**javno	FALSE
42		bon.ocena	E

Izpis 5.1: Kritični primer 1.

Atributi, ki imajo pred imenom znak \*\*, zaenkrat še niso vključeni v domeno. Aktivirajo se ob prvi pojavitvi v argumentu. Učenčeva naloga je bila podati argument, ki poda razloge, zakaj spada ta primer v razred E.

Po ogledu številke podjetja je učenec na kratko povzel svoje razmišljanje: "Podjetje posluje pozitivno, ima nekaj dolga in je rastoče. Motita me vi-

sok kratkoročni dolg in nizek *current.ratio*.” Omenil je tudi, da kazalnik *current.ratio* nakazuje na to, da podjetje ne bo moglo odplačati svojih kratkoročnih obveznosti. Na koncu se je odločil za argument: “Podjetje spada v razred E, ker ima visoke *krtk.obv* in nizek *current.ratio*.”

### 5.1.1 Analiza argumenta - 1

Argument: visoke *krtk.obv* in nizek *current.ratio*.

Po vnosu argumenta sledi njegova analiza. Najprej so bila učencu prikazana pravila, s katerimi dobimo protiprimerne 5.2.

```

1 Analysing argument ...
2 -----
3 Fold 1
4 Rules:
5 IF current.ratio <1.09 AND krtk.obv >2.02M
6 THEN bon.ocena=E<2, 22> 0.886 test_data=<1, 8>
7 counter examples= PUBLICUS gospodarjenje z odpadki, trgovina, ..., d.o.o., Ljubljana
8 -----
9 Fold 3
10 Rules:
11 IF current.ratio <1.09 AND krtk.obv >4.21M
12 THEN bon.ocena=E<0, 18> 0.952 test_data=<1, 1>
13 counter examples= JAVNO PODJETJE LJUBLJANSKI POTNISKI PROMET, d.o.o.
14 -----
15 Entire rules:
16 IF current.ratio <1.09 AND krtk.obv >4.21M
17 THEN bon.ocena=E<1, 19> 0.911 test_data=<0, 3>
18 counter examples=

```

Izpis 5.2: Računanje protiprimerov.

Ta pravila so naučena v postopku  $k$ -kratnega prečnega preverjanja ( $k = 4$ ). Vsak pregib (angl. *fold*) nam da novo kombinacijo učnih primerov, iz katerih se nato naučimo novo pravilo. Protiprimer je primer iz pripadajoče testne množice, ki ga pravilo napačno klasificira. Izpišemo informacije samo o pregibih, ki producirajo protiprimerne. V izseku 5.2 je prikazan del *Entire rules*, kjer je podana informacija o pravilu, ki je naučeno na celotni učni množici. Testna množica je tu ista kot v  $k$ -tem pregibu, kar pomeni, da se primeri v tej testni množici nahajajo tudi v učni.

Nadalje dobi učenec informacije o ocenah argumenta, kar je prikazano v izpisu 5.3. Kot smo opisali že v poglavju 3, nam  $P1$  oceni nerazširjen argument, pretvorjen v pravilo z  $m$ -oceno.  $P2$  pove število “popravljenih”,

“pokvarjenih” in “nepopravljenih” primerov. In nazadnje  $P3$  učencu razkrije, kateri razlogi so odvečni oz. kateri razlogi tvorijo boljše argumente. V celotnem eksperimentu je bil parameter  $m$  pri  $m$ -oceni enak 2.

```

1 Computing |P1|
2 IF current.ratio <1.09 AND krtk.obv >4.21M
3 THEN bon.ocena=E<1, 19>
4 m: 0.91
5 =====
6 Computing |P2|
7 Corrected: 0, faulted: 1, not corrected: 0
8 =====
9 Computing |P3|
10 one rule
11 m: 0.91 IF current.ratio <1.09 AND krtk.obv >4.21M
12     THEN bon.ocena=E<1, 19>
13
14 pruned rules:
15 m: 0.84 IF current.ratio <1.09
16     THEN bon.ocena=E<7, 41>
17 m: 0.73 IF krtk.obv >5.57M
18     THEN bon.ocena=E<8, 23>
19
20 extended rules:
21 m: 0.96 IF current.ratio <1.08 AND zaloge >404.87K AND krtk.obv >1.86M
22     THEN bon.ocena=E<0, 20>
23 m: 0.95 IF current.ratio <1.09 AND krtk.obv >4.21M AND PDT <4.42M
24     THEN bon.ocena=E<0, 17>
25 m: 0.95 IF current.ratio <1.09 AND krtk.obv >4.21M AND DT <4.71M
26     THEN bon.ocena=E<0, 16>
27 m: 0.94 IF current.ratio <1.09 AND obresti >39.40K AND krtk.obv >177.19K
28     THEN bon.ocena=E<1, 32>
29 m: 0.94 IF current.ratio <0.94 AND cisti.dobicek <355.28K AND krtk.obv >397.11K
30     THEN bon.ocena=E<1, 32>
31 abs diff: 0.05
32 potential: 0.96
33 is too specialized: False

```

Izpis 5.3: Ocene argumenta: visoke *krtk.obv* in nizek *current.ratio*.

Argument učenca je bil ocenjen z oceno 0.91, kar pomeni zelo dober argument. To lahko vidimo tudi iz distribucije pravila (1, 19).  $P2$  nam pove, da smo “pokvarili” en primer, s čimer se ni treba obremenjevati. Iz odseka informacij sklopa  $P3$  lahko razberemo, da je kombinacija obeh razlogov dober argument. Ponudi nam tudi boljša pravila, ki imajo manj privlačne razloge.

Pred možnostjo popravljanja argumenta se učencu prikažejo še protiprimeri. Za lažjo primerjavo med primerom, ki ga trenutno argumentiramo in protiprimeri prikažemo kritični primer skupaj s protiprimeri. V izseku 5.4 zaradi prostorskih razlogov prikažemo samo prvi protiprimer. Trenutna verzija učnega sistema prikaže podatke vseh protiprimerov, kar zna biti nepregle-

dno ob njihovem večjem številu. Bolj primeren bi bil prikaz skrbno izbranih največ štirih oz. petih podjetij.

1		id	GOZDNO GOSPODARSTVO		PUBLICUS gospodarjen
2		dejavnost.id	2.2		38.11
3		dejavnost.ime	SECNJA		ZBIRANJE IN ODVOZ NE
4	1	dejavnost	A		E
5	2	velikost	M		M
6		IPI			
7	3	prihodki.od.prodaje	17,269,248		8,908,000
8	4	stroski.blaga.materiala.in.stor	9,132,386		5,709,000
9	5	stroski.dela	4,482,689		1,856,000
10	6	odpisi.vrednosti	908,997		609,000
11	7	fin.odhodki	254,141		145,000
12	8	obresti	254,141		0
13	9	EBIT	563,758		667,000
14	10	EBITDA	1,472,755		1,276,000
15	11	cisti.dobicek	344,212		473,000
16		BS			
17	12	sredstva	17,155,984		6,659,000
18	13	kapital	9,537,284		1,627,000
19	14	fin.dolg	4,770,110		2,274,000
20	15	denarna.sredstva	142,605		7,000
21	16	dlg.sredstva	12,355,141		4,784,000
22	17	krtk.sredstva	4,800,843		1,865,000
23	18	cel.posl.obv	2,375,524		2,240,000
24	19	krtk.posl.obv	2,375,524		2,240,000
25	20	dlg.obv	1,467,846		299,000
26	21	krtk.obv	5,677,788		4,215,000
27	22	zaloge	683,007		9,000
28		CF			
29	23	DT	1,076,205		473,000
30	24	PDT	1,665,647		912,000
31		Ratios			
32	25	**cel.posl.obv/sredstva	13.8 %		33.6 %
33	26	current.ratio	0.85		0.44
34	27	**dlg.rast.prihodkov	4.4 %		6.2 %
35	28	**krtk.rast.prihodkov	12.3 %		14.9 %
36	29	**spr.ebit.marzi	-0.2		3.4
37	30	**net.fin.dolg/EBITDA	3.14		1.78
38	31	**equity.ratio	0.56		0.24
39	32	**TIE	2.22		100.00
40	33	**ROA	3.3 %		10.6 %
41	34	**javno	FALSE		FALSE
42		bon.ocena	E		A

Izpis 5.4: Najdeni protiprimeri v iteraciji 1.

V nasprotju s prejšnjimi izvedbami postopkov ABML [7, 11, 14] naš program omogoča primerjavo kritičnega primera z vsemi ostalimi protiprimeri. Mislimo, da je s tem pristopom učencu/ekspertu omogočeno lažje argumentiranje, saj so nekateri protiprimeri manj relevantni od drugih (npr. osamelci). Takšen prikaz zbere tudi podobne primere na enem mestu, kar lahko privede do globljih in splošnejših spoznanj, ki razkrijejo, kaj loči manjše skupine primerov med seboj.



Učenec je bil zadovoljen z oceno argumenta  $m = 0.91$  in ga zato ni spreminjal. K tej odločitvi so prispevale tudi povratne informacije  $P3$ , saj niso vsebovale boljšega pravila, ki bi imelo tudi smiselne pogoje.

## 5.2 Iteracija 3

V iteraciji 3 je bil učenec soočen z argumentiranjem sledečega primera 5.5.

1		id	BELIMED pomivalni si
2		dejavnost.id	28.29
3		dejavnost.ime	PROIZVODNJA DRUGIH S
4	1	dejavnost	C
5	2	velikost	M
6		IPI	
7	3	prihodki.od.prodaje	15,424,608
8	4	stroski.blaga.materiala.in.stor	9,274,508
9	5	stroski.dela	4,149,638
10	6	odpisi.vrednosti	874,364
11	7	fin.odhodki	588,386
12	8	obresti	588,386
13	9	EBIT	1,086,695
14	10	EBITDA	1,961,059
15	11	cisti.dobicek	470,819
16		BS	
17	12	sredstva	22,304,336
18	13	kapital	3,934,548
19	14	fin.dolg	12,552,277
20	15	denarna.sredstva	249,657
21	16	dlg.sredstva	13,154,345
22	17	krtk.sredstva	9,104,133
23	18	cel.posl.obv	3,627,757
24	19	krtk.posl.obv	3,627,757
25	20	dlg.obv	11,800,000
26	21	krtk.obv	4,380,034
27	22	zaloge	2,827,924
28		CF	
29	23	DT	1,328,506
30	24	PDT	437,333
31		Ratios	
32	25	**cel.posl.obv/sredstva	16.3 %
33	26	current.ratio	2.08
34	27	dlg.rast.prihodkov	9.3 %
35	28	**krtk.rast.prihodkov	24.3 %
36	29	**spr.ebit.marzi	1.4
37	30	**net.fin.dolg/EBITDA	6.27
38	31	**equity.ratio	0.18
39	32	**TIE	1.85
40	33	**ROA	4.7 %
41	34	javno	FALSE
42		bon.ocena	E

Izpis 5.5: Kritični primer 3.

Vidimo, da je podjetje *BELIMED pomivalni sistemi, d. o. o.*, dobičkonosno in izkazuje dobro rast. Po drugi strani ima nizko finančno moč zaradi zelo vi-

sokega dolga in premalo lastnega kapitala. Do podobnih ugotovitev je uspelo priti tudi učencu. Po kratki analizi se je odločil za argument: visok *fin.dolg*.

### 5.2.1 Analiza argumenta - 1

Argument: visok *fin.dolg*.

Rezultati v izpisu 5.6 razkrijejo, da je argument slab. *P1* namreč vrne oceno argumenta  $m = 0.77$ . Prav tako nas *P2* opozori, da smo “pokvarili” deset primerov. *P3* sicer prikaže predloge zelo uspešnih pravil, toda učencu se ta ne zdijo intuitivna. Algoritem najde tudi štiri protiprimere.

```

1 Computing |P1|
2 IF fin.dolg>2.84M
3 THEN bon.ocena=E<10, 35>
4 m: 0.77
5 =====
6 Computing |P2|
7 Corrected: 1, faulted: 10, not corrected: 0
8 =====
9 Computing |P3|
10 one rule
11 m: 0.77 IF fin.dolg>2.84M
12     THEN bon.ocena=E<10, 35>
13
14 pruned rules:
15
16 extended rules:
17 m: 0.96 IF fin.dolg>2.84M AND PDT<953.33K
18     THEN bon.ocena=E<0, 24>
19 m: 0.96 IF fin.dolg>3.74M AND EBITDA<1.99M
20     THEN bon.ocena=E<0, 20>
21 m: 0.95 IF fin.dolg>3.74M AND kapital<5.84M
22     THEN bon.ocena=E<0, 19>
23 m: 0.95 IF fin.dolg>3.98M AND stroski.dela<4.50M
24     THEN bon.ocena=E<0, 16>
25 m: 0.93 IF fin.dolg>3.74M AND DT<2.21M
26     THEN bon.ocena=E<1, 24>
27 abs diff: 0.20
28 potential: 0.96
29 is too specialized: False

```

Izpis 5.6: Ocene argumenta: visok *fin.dolg*.

Z opazovanjem štirih protiprimerov ugotovi, da bi bil tu verjetno bolj primeren atribut *net.fin.dolg/EBITDA*. Odloči se za dopolnitev argumenta z razlogoma: visok *net.fin.dolg/EBITDA* in nizek *equity.ratio*.

## 5.2.2 Analiza argumenta - 2

Argument: visok *fin.dolg*, visok *net.fin.dolg/EBITDA* in nizek *equity.ratio*.

Ocena argumenta je odlična, in sicer  $m = 0.98$  5.7. A argument ni popoln, saj *P3* opozori učenca, da je argument preveč specifičen. Ta informacija je prikazana v 33. vrstici in v sklopu obrezanih pravil. Z argumentom pridelamo dva protiprimera.

```

1 Computing |P1|
2 IF net.fin.dolg/EBITDA>5.53 AND fin.dolg>-10.00 AND equity.ratio<10.99
3 THEN bon.ocena=E<0, 49>
4 m: 0.98
5 =====
6 Computing |P2|
7 Corrected: 0, faulted: 0, not corrected: 0
8 =====
9 Computing |P3|
10 one rule
11 m: 0.98 IF net.fin.dolg/EBITDA>5.53 AND fin.dolg>-10.00 AND equity.ratio<10.99
12     THEN bon.ocena=E<0, 49>
13
14 pruned rules:
15 m: 0.98 IF net.fin.dolg/EBITDA>5.53
16     THEN bon.ocena=E<0, 49>
17 m: 0.98 IF net.fin.dolg/EBITDA>5.53 AND equity.ratio<10.99
18     THEN bon.ocena=E<0, 49>
19
20 extended rules:
21 m: 0.98 IF net.fin.dolg/EBITDA>5.53 AND fin.dolg>-10.00 AND equity.ratio<10.99 AND dlj.
22     rast.prihodkov<166.20
23     THEN bon.ocena=E<0, 49>
24 m: 0.98 IF net.fin.dolg/EBITDA>5.53 AND fin.dolg>-10.00 AND equity.ratio<10.99 AND
25     current.ratio<49.55
26     THEN bon.ocena=E<0, 49>
27 m: 0.98 IF net.fin.dolg/EBITDA>5.53 AND fin.dolg>-10.00 AND equity.ratio<10.99 AND
28     current.ratio>-9.91
29     THEN bon.ocena=E<0, 49>
30 m: 0.98 IF javno=['FALSE'] AND net.fin.dolg/EBITDA>5.53 AND fin.dolg>-10.00 AND equity.
31     ratio<10.99
32     THEN bon.ocena=E<0, 49>
33 m: 0.98 IF net.fin.dolg/EBITDA>5.53 AND fin.dolg>-10.00 AND equity.ratio<10.99 AND dlj.
34     rast.prihodkov>-107.70
35     THEN bon.ocena=E<0, 49>
36
37 abs diff: 0.00
38 potential: 0.98
39 is too specialized: True

```

Izpis 5.7: Ocene argumenta: visok *fin.dolg*, nizek *equity.ratio* in visok *net.fin.dolg/EBITDA*.

Ob ogledu protiprimerov se učenec odloči odstraniti pogoj visok *fin.dolg*. Sodeč po prikazanih informacijah, bi lahko odstranil tudi atribut *equity.ratio*, ampak je mnenja, da je vrednost 0.18 prenizka in da je to eden izmed razlogov za uvrstitev kritičnega primera v razred E.

### 5.2.3 Analiza argumenta - 3

Argument: nizek *equity.ratio* in visok *net.fin.dolg/EBITDA*

V izseku 5.8 vidimo, da argumenta ne moremo izboljšati s trenutnimi atributi domene. *P3* nas ponovno opozori, da je argument preveč specifičen, a hkrati nam tudi pokaže uporabnost razloga nizek *equity.ratio*. Namreč, pravilo, ki sledi iz tega razloga, ima zelo dobro distribucijo pokritosti primerov, kar pomeni, da je pogoj relevanten in pripomore k boljšemu ločevanju primerov. Algoritem vrne enaka protiprimera kot pri prejšnjem argumentu.

```

1 Computing |P1|
2 IF net.fin.dolg/EBITDA>5.53 AND equity.ratio <10.99
3 THEN bon.ocena=E<0, 49>
4 m : 0.98
5
6 Computing |P2|
7 Corrected: 0, faulted: 0, not corrected: 0
8
9 Computing |P3|
10 one rule
11 m: 0.98 IF net.fin.dolg/EBITDA>5.53 AND equity.ratio <10.99
12     THEN bon.ocena=E<0, 49>
13
14 pruned rules:
15 m: 0.98 IF net.fin.dolg/EBITDA>5.53
16     THEN bon.ocena=E<0, 49>
17 m: 0.94 IF equity.ratio <0.19
18     THEN bon.ocena=E<1, 29>
19
20 extended rules:
21 m: 0.98 IF net.fin.dolg/EBITDA>5.53 AND equity.ratio <10.99 AND dlj.rast.prihodkov
22     >-107.70
23     THEN bon.ocena=E<0, 49>
24 m: 0.98 IF net.fin.dolg/EBITDA>5.53 AND equity.ratio <10.99 AND current.ratio >-9.91
25     THEN bon.ocena=E<0, 49>
26 m: 0.98 IF javno=['FALSE'] AND net.fin.dolg/EBITDA>5.53 AND equity.ratio <10.99
27     THEN bon.ocena=E<0, 49>
28 m: 0.98 IF net.fin.dolg/EBITDA>5.53 AND equity.ratio <10.99 AND dlj.rast.prihodkov <166.20
29     THEN bon.ocena=E<0, 49>
30 m: 0.98 IF net.fin.dolg/EBITDA>5.53 AND equity.ratio <10.99 AND PDT>-42.46M
31     THEN bon.ocena=E<0, 49>
31 abs diff: 0.00
32 potential: 0.98
33 is too specialized: True

```

Izpis 5.8: Ocene argumenta: nizek *equity.ratio* in visok *net.fin.dolg/EBITDA*.

Navedena dejstva potrdijo učenčeva razmišljanja, zato se odloči za končanje trenutne iteracije.

## 5.3 Iteracija 5

Kritični primer iteracije 5 je podjetje *SKUPINA KARIERA, d. o. o.* 5.9.

1		id	SKUPINA KARIERA	naci
2		dejavnost.id		78.2
3		dejavnost.ime	POSREDOVANJE	ZACASNE
4	1	dejavnost		N
5	2	velikost		S
6		IPI		
7	3	prihodki.od.prodaje		9,435,821
8	4	stroski.blaga.materiala.in.stor		1,385,242
9	5	stroski.dela		7,774,369
10	6	odpisi.vrednosti		10,578
11	7	fin.odhodki		162
12	8	obresti		162
13	9	EBIT		201,554
14	10	EBITDA		212,132
15	11	cisti.dobicek		162,818
16		BS		
17	12	sredstva		3,313,493
18	13	kapital		470,602
19	14	fin.dolg		0
20	15	denarna.sredstva		1,040,542
21	16	dlg.sredstva		61,889
22	17	krtk.sredstva		3,166,626
23	18	cel.posl.obv		2,796,391
24	19	krtk.posl.obv		2,796,391
25	20	dlg.obv		0
26	21	krtk.obv		2,796,391
27	22	zaloge		0
28		CF		
29	23	DT		165,610
30	24	PDT		697,134
31		Ratios		
32	25	**cel.posl.obv/sredstva		84.4 %
33	26	current.ratio		1.13
34	27	dlg.rast.prihodkov		74.1 %
35	28	**krtk.rast.prihodkov		50.8 %
36	29	spr.ebit.marzi		-2.0
37	30	net.fin.dolg/EBITDA		-4.91
38	31	equity.ratio		0.14
39	32	**TIE		100.00
40	33	**ROA		5.6 %
41	34	javno		FALSE
42		bon.ocena		E

Izpis 5.9: Kritični primer 5.

Podjetja izstopa po strukturi dolga; je brez finančnega dolga, a ima zato veliko kratkoročnih poslovnih obveznosti. Učenec poleg tega opazi, da ima podjetje zelo malo lastnega kapitala in nizek denarni tok glede na velikost prihodkov iz prodaje. Poda argument: nizek *equity.ratio*, nizek *DT* in visok kazalnik *cel.posl.obv/sredstva*.

### 5.3.1 Analiza argumenta - 1

Argument: nizek *equity.ratio*, nizek *DT* in visok kazalnik *cel.posl.obv/sredstva*.

Algoritmu je uspelo najti dva protiprimera. Ocene v izpisu 5.10 kažejo, da je argument zelo dober. *P3* nas dodatno informira o tem, da je zato zadolžen pogoj nizek *equity.ratio*. Ostala dva pogoja sta odveč. Na podlagi namiga v prvem razširjenem pravilu in ostalih omenjenih informacijah se učenec odloči za odstranitev dveh pogrešljivih pogojev in doda novega: nizek *current.ratio*.

```

1 Computing |P1|
2 IF equity.ratio <0.23 AND DT<325.00K AND cel.posl.obv/sredstva >-9.10
3 THEN bon.ocena=E<0, 27>
4 m: 0.97
5 =====
6 Computing |P2|
7 Corrected: 0, faulted: 0, not corrected: 0
8 =====
9 Computing |P3|
10 one rule:
11 m: 0.97 IF equity.ratio <0.23 AND DT<325.00K AND cel.posl.obv/sredstva >-9.10
12     THEN bon.ocena=E<0, 27>
13
14 pruned rules:
15 m: 0.97 IF equity.ratio <0.23 AND DT<325.00K
16     THEN bon.ocena=E<0, 27>
17 m: 0.97 IF equity.ratio <0.18
18     THEN bon.ocena=E<0, 26>
19
20 extended rules:
21 m: 0.97 IF equity.ratio <0.23 AND current.ratio <1.38 AND DT<19.92M AND cel.posl.obv/
22     sredstva >-9.10
23     THEN bon.ocena=E<0, 31>
24 m: 0.97 IF equity.ratio <0.23 AND cisti.dobicek <175.46K AND DT<19.92M AND cel.posl.obv/
25     sredstva >-9.10
26     THEN bon.ocena=E<0, 30>
27 m: 0.97 IF equity.ratio <0.19 AND krtk.obv>800.79K AND DT<19.92M AND cel.posl.obv/
28     sredstva >-9.10
29     THEN bon.ocena=E<0, 29>
30 m: 0.97 IF javno=['FALSE'] AND equity.ratio <0.23 AND DT<573.77K AND cel.posl.obv/
31     sredstva >-9.10
32     THEN bon.ocena=E<0, 28>
33 m: 0.97 IF equity.ratio <0.23 AND DT<573.77K AND net.fin.dolg/EBITDA>-8.16 AND cel.posl.
34     obv/sredstva >-9.10
35     THEN bon.ocena=E<0, 28>
36
37 abs. diff: 0.00
38 potential: 0.97
39 is too specialized: False

```

Izpis 5.10: Ocene argumenta: nizek *equity.ratio*, nizek *DT* in visok kazalnik *cel.posl.obv/sredstva*.

Tako nov argument sestavljata: nizek *equity.ratio* in nizek *current.ratio*. Po vpisu argumenta učenec izpostavi dejstvo, da absolutne vrednosti niso primerne za argumentiranje, saj imamo različno velika podjetja. Ravno to

je eden izmed zelenih konceptov, ki naj bi se ga učenec začel zavedati skozi potek učne seje. Bolj kot absolutne vrednosti postavk so pomembni deleži.

### 5.3.2 Analiza argumenta - 2

Argument: nizek *equity.ratio* in nizek *current.ratio*.

V izpisu 5.11 opazimo, da ima argument isto oceno *P1* kot prej z razliko v tem, da pravilo pokrije štiri primere več in koristi oba pogoja. Obrezani pravili generirani prek *P3* pokažeta, da sta oba pogoja koristna. Razširjena pravila nam ne podajo nobenih vrednejših informacij.

```

1 Computing |P1|
2 IF equity.ratio <0.23 AND current.ratio <1.38
3 THEN bon.ocena=E<0, 31>
4 m: 0.97
5 =====
6 Computing |P2|
7 Corrected: 0, faulted: 0, not corrected: 0
8 =====
9 Computing |P3|
10 one rule:
11 m: 0.97 IF equity.ratio <0.23 AND current.ratio <1.38
12     THEN bon.ocena=E<0, 31>
13
14 pruned rules:
15 m: 0.97 IF equity.ratio <0.18
16     THEN bon.ocena=E<0, 26>
17 m: 0.82 IF current.ratio <1.18
18     THEN bon.ocena=E<10, 48>
19
20 extended rules:
21 m: 0.97 IF equity.ratio <0.23 AND krtk.obv >806.66K AND current.ratio <1.63
22     THEN bon.ocena=E<0, 32>
23 m: 0.97 IF equity.ratio <0.23 AND current.ratio <1.63 AND stroski.dela >265.59K
24     THEN bon.ocena=E<0, 32>
25 m: 0.97 IF javno=['FALSE'] AND equity.ratio <0.23 AND current.ratio <1.38
26     THEN bon.ocena=E<0, 31>
27 m: 0.97 IF equity.ratio <0.23 AND current.ratio <1.38 AND net.fin.dolg/EBITDA >-43.33
28     THEN bon.ocena=E<0, 31>
29 m: 0.97 IF equity.ratio <0.23 AND current.ratio <1.38 AND net.fin.dolg/EBITDA <40.00
30     THEN bon.ocena=E<0, 31>
31 abs. diff: 0.00
32 potential: 0.97
33 is too specialized: False

```

Izpis 5.11: Ocene argumenta: nizek *equity.ratio* in nizek *current.ratio*.

Učenec se nato osredotoči na tri najdene protiprimere. Dva sta prikazana, ker sta ravno na meji pogoja v pravilu – *equity.ratio* imata enak 0.23. Tretji protiprimer *TAURUS TRANSPORT, d. o. o* se je pojavil že malo prej. Njegovi vrednosti za *equity.ratio* in *current.ratio* sta 0.18 in 1.38. Učencu

ne uspe najti atributa, ki bi izboljšal argument, zato se odloči za končanje iteracije.



# Poglavje 6

## Evalvacija

V tem poglavju analiziramo učno sejo, opisano v poglavju 5 in v dodatku A, ter opišemo povzetek rezultatov vseh treh izvedenih učnih sej.

### 6.1 Analiza učne seje


Učenca smo pred postopkom dobro seznanili z nalogo, atributi in potekom učne seje. Za to smo potrebovali eno uro. Celoten čas učnega postopka je znašal dve uri in pol. Skupni čas učenja je torej tri ure in pol.

Kot je razvidno iz tabele 6.1, je obravnavana učna seja obsegala enajst iteracij. Končna dosežena klasifikacijska točnost je 97 %. Iz vrstic tabele vidimo, da je aktivacija novih atributov primerno razporejena čez učno sejo. Zadnji stolpec predstavlja število različnih argumentov, ki jih je učenec preizkusil v posamezni iteraciji. To število nam tudi pove, koliko analiz argumentov je bilo izvedenih v iteracijah.

Na sliki 6.1 lahko vidimo, koliko časa je učenec porabil za posamezno iteracijo. Število različnih argumentov in porabljen čas nakazujeta, da je bil učenec raziskovalno usmerjen v prvih šestih iteracijah. Prikaz porabljenega časa prav tako potrjuje naše izkušnje, da se je učenec v tem delu naučil razumevanja večjega dela konceptov. Ostali del seje (od sedme iteracije dalje) je večinoma predstavljal utrjevanje naučenih konceptov.

it	CA	# pravil	# akt. atributov	skupno # akt. atr.	# razlicnih argumentov
1	0.910	32	1	1	1
2	0.851	30	2	3	2
3	0.896	25	2	5	3
4	0.910	21	1	6	3
5	0.925	21	1	7	2
6	0.910	22	1	8	3
7	0.940	20	1	9	2
8	0.940	20	1	10	2
9	0.955	18	0	10	2
10	0.955	18	0	10	2
11	0.955	18	0	10	1
F	0.970	21	0	10	/

Tabela 6.1: Pomembnejši kazalniki učne seje.



Slika 6.1: Porabljen čas v posamezni iteraciji učne seje.

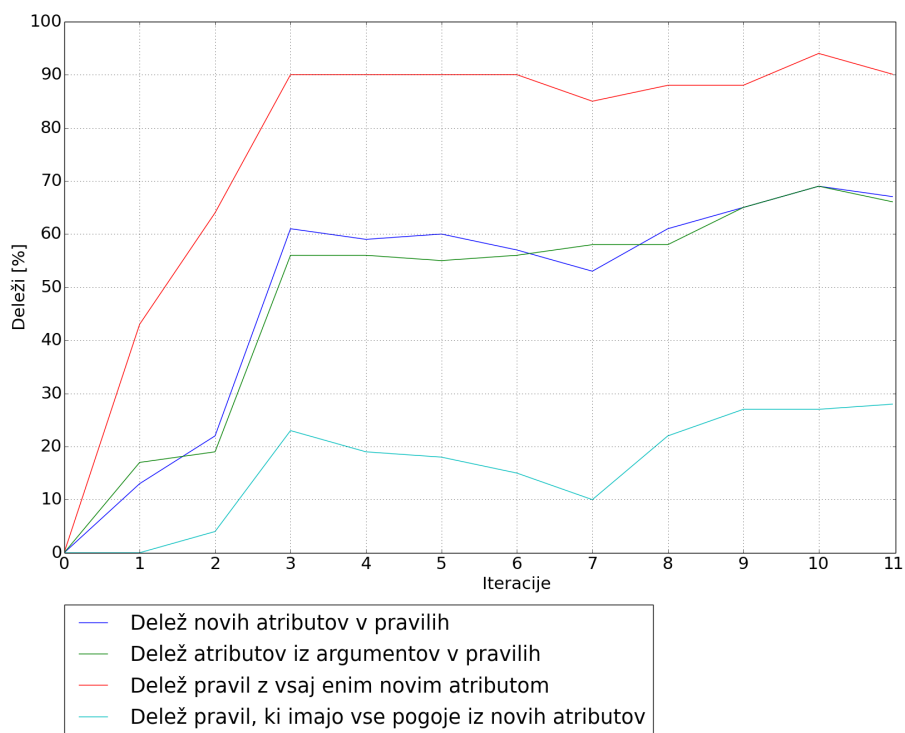
Z namenom evalvacije učenčevega vpliva na učni algoritem ABCN2 skozi postopek smo beležili zastopanost navedenih argumentov v pravilih. Učenec je v sklopu postopka aktiviral vseh deset izpeljanih atributov. Merili smo naslednje vrednosti:

- delež novih atributov v pravilih,
- delež atributov iz argumentov v pravilih,
- delež pravil z vsaj enim novim atributom,
- delež pravil, ki imajo vse pogoje iz novih atributov.


Rezultati merjenja so prikazani na sliki 6.2. Pričakovano vrednosti konvergirajo proti višjim vrednostim. Predvsem zanimiv je zelo visok delež pravil, ki uporabljajo vsaj en nov atribut (90 %). To pomeni, da so novi atributi bistveni pri razlaganju primerov. Malo manj kot tretjina pravil ima vse pogoje iz novih atributov, kar je nižje od pričakovanega. Ta rezultat pomeni, da so osnovni atributi prav tako pomembni pri razlagi domene. Delež novih atributov v pravilih znaša skoraj 70 %, kar pomeni, da novi atributi predstavljajo dve tretjini hipoteze in osnovni atributi ostalo tretjino. Delež atributov iz argumentov v pravilih se obnaša presenetljivo podobno kot delež novih atributov v pravilih. Vrednost deleža lahko interpretiramo kot intenzivnost vpliva argumentov na hipotezo. Učenec torej s svojimi argumenti ustvari dve tretjini hipoteze.

Za sledenje učenčevega napredka smo v vsaki iteraciji preverjali uspešnost pravil, naučenih z ABCN2. Prav tako nas je zanimal vpliv argumentov na učenje, zato smo naredili primerjavo klasifikacijske točnosti še z naslednjimi učnimi algoritmi: odločitvena drevesa (DT), CN2 in Naivni Bayes (NB). Testiranje je bilo izvedeno na testni množici (30 % primerov), ki je bila dana na stran pred začetkom učne seje. Slika 6.3 prikazuje rezultate testiranj.


Vidimo, da je s končno točnostjo 97 % algoritem ABCN2 najuspešnejši. Ta rezultat je precej boljši od rezultata CN2 (92,5 %), kar dokazuje, da so argumenti bistveni za uspešnost ABCN2.



Slika 6.2: Zastopanost novih atributov v pravilih skozi iteracije.



Slika 6.3: Napredek klasifikacijskih točnosti (CA) skozi iteracije.



Slika 6.4: Število vnešenih argumentov skozi iteracije.

## 6.2 Povzetek učnih sej

Vsi učenci so izvajali učni postopek na enakih podatkih. V povprečju je učna seja obsegala 10.33 iteracije in trajala dve uri ter 50 minut. Končna klasifikacijska točnost je znašala v povprečju 96.5 %, AUC 0.984 in Brier score 0.075.

Na sliki 6.4 si lahko ogledamo potek učnih sej z vidika števila analiziranih argumentov. Učenec 1 je analiziral 31 argumentov, kar je precej več od učenca 2 in učenca 3, ki sta vnesla vsak po 23 argumentov.

Z namenom ovrednotenja dosežkov učenja so vsi učenci po koncu učne seje morali uvrstiti 30 še nikoli videnih primerov. Njihova povprečna klasifikacijska točnost je bila 87 %.

Rezultati kažejo na to, da je inteligentni tutorski sistem na podlagi argumentiranega strojnega učenja lahko uspešno učno orodje. Sistem s podajanjem informacij o kakovosti danih argumentov učencu olajša argumentiranje in mu postopoma razkriva implicitno znanje, ki je vsebovano v podatkih.

Ob koncu učne seje smo učence povprašali za komentar o učnem pro-

gramu. Povedali so, da jim je bil učni postopek všeč, predlagali pa so več grafičnih prikazov podatkov, prek katerih bi bilo primerjanje podjetij lažje.

# Poglavje 7

## Sklepne ugotovitve

V magistrskem delu smo se ukvarjali z ocenjevanjem kakovosti argumenta pri argumentiranem strojnem učenju. Za ta namen smo zasnovali tri pristope za podajanje povratnih informacij o kvaliteti argumentov, in sicer *P1*, *P2* in *P3*. Drugi cilj magistrskega dela je bil pokazati uporabnost inteligentnega sistema za poučevanje, temelječega na argumentiranju, ki s podajanjem ocene argumenta omogoča učencu učinkovito učenje. V razvit tutorski sistem smo vključili vse tri razvite pristope. Uporabnost teh je bila evalvirana prek izvedenih učnih sej s tutorskim sistemom.

Za učni problem smo si izbrali dodeljevanje bonitetnih ocen podjetjem. S tem smo hoteli učence naučiti razumevanja postavk v finančnih izkazih in podati znanje, kako interpretirati posamezne finančne kazalnike. Za pridobitev konsistentne baze podatkov in atributov, ki bi ustrezno opisovali problem, smo najprej izvedli zajemanje znanja iz eksperta. Po pridobitvi ustrezne baze znanja smo učni sistem testirali na treh učencih. Pokazalo se je, da zamišljeni pristopi pripomorejo k lažjemu in bolj učinkovitejšemu učenju učenca. Za najkoristnejšega se je izkazal *P3*. Ta prek obrezanih pravil prikaže učencu pomembnost posameznih razlogov v argumentu. Prav tako pomembna so razširjena pravila, saj z njimi učenec dobiva namige, kako izboljšati argument. S tem razširjena pravila usmerjajo učenca k novim odkritjem. *P1* z numerično oceno argumenta na kratek in preprost način pove,

kako dober je dani argument. Za najmanj uporabnega se je izkazal pristop *P2*. Menimo, da je ta primernejši za probleme, kjer obstoječa hipoteza doseže manjšo klasifikacijsko točnost. Omembe vredna je tudi razvita novost primerjanja kritičnega primera z več protiprimeri istočasno. S tem je uporabniku omogočeno lažje argumentiranje, saj so nekateri protiprimeri manj uporabni od drugih (npr. osamelci).

Uporaba razvitega učnega sistema je pokazala veliko možnih izboljšav. Sistem je bil razvit kot konzolna aplikacija, kar omejuje interaktivnost, zato predlagamo razvoj grafičnega uporabniškega vmesnika. Učinkovitost učenja bi bila večja s slikovnimi prikazi podatkov, ki bi povzemali njihove ključne lastnosti. Sem spadajo tudi naprednejše statistike (povprečje, mediana, distribucija itd.). Pri argumentih, kjer mora algoritem določiti mejo več razlogom, ima ta težave. Ena izmed možnih rešitev je učencu omogočiti navedbo pogoja, ki ne bi zahteval arbitrarnega števila in bi bil hkrati bolj precizen kot relacija visok/nizek. Možna rešitev bi omogočala navedbo argumenta v takšni obliki: atribut  $x$  je v tretjem kvartilu, atribut  $x$  je večji od mediane. Trenutno so informacije o kakovosti argumenta podane prek vseh treh pristopov. Smiselno bi bilo premisliti, na kakšen način se da pristope združiti in s tem izboljšati podajanje informacij učencu.



# Literatura

- [1] G. Blaise, J. Bilardello, “Standard and Poor’s Fundamentals of Corporate Credit Analysis”, McGraw-Hill Companies, 2004.
- [2] B. S. Bloom, “The 2 sigma problem: The search for methods of group instruction as effective as one-to-one tutoring”, Educational researcher, 1984, str. 4–16.
- [3] B. Cestnik, “Estimating probabilities: A crucial task in machine learning”, v Proceedings of the Ninth European Conference on Artificial Intelligence, 1990, str. 147–149.
- [4] J. Ciby, “Advanced Credit Risk Analysis and Management”, John Wiley & Sons, 2013, str. 99–172.
- [5] P. Clark, R. Boswell, “Rule induction with CN2: Some recent improvements”, v Machine Learning - Proceeding of the Fifth European Conference (EWSL-91), Berlin, 1991, str. 151–163.
- [6] E. A. Feigenbaum. “Some challenges and grand challenges for computational intelligence”, v Journal of the ACM (JACM), 2003, vol. 50, no.1, str. 32–40.
- [7] V. Groznik, M. Guid, A. Sadikov, M. Možina, D. Georgiev, V. Kragelj, S. Ribarič, Z. Pirtošek, I. Bratko, “Elicitation of neurological knowledge with argument-based machine learning”, Artificial intelligence in medicine, 2013, vol. 57, no. 2, str. 133–144.

- [8] M. Guid, M. Možina, V. Groznik, D. Georgiev, A. Sadikov, Z. Pirtošek, I. Bratko, “ABML knowledge refinement loop : a case study”, v *Foundations of intelligent systems. Lecture notes in artificial intelligence*, 2012, vol. 7661, str. 41–50.
- [9] M. Možina, M. Guid, J. Krivec, A. Sadikov, I. Bratko, “Fighting knowledge acquisition bottleneck with argument based machine learning”, v *ECAI 2008 - 18th European Conference on Artificial Intelligence, Proceedings. Frontiers in Artificial Intelligence and Applications*, 2008, vol. 178, str. 234–238.
- [10] M. Možina, J. Žabkar, I. Bratko, “Argument based machine learning”, *Artificial intelligence*, 2007, vol. 171, no. 10/15, str. 922–937.
- [11] M. Možina, J. Žabkar, T. Bench-Capon, I. Bratko, “Argument based machine learning applied to law”, *Artificial intelligence and law*, 2005, vol. 13, no. 1, str. 53–73.
- [12] O. Scheuer, F. Loll, N. Pinkwart, B. M. McLaren, “Computer-supported argumentation: A review of the state of the art”, v *International Journal of Computer-Supported Collaborative Learning*, 2010, 5(1), str. 43-102.
- [13] B. P. Woolf, “Building intelligent interactive tutors: Student-centered strategies for revolutionizing e-learning”, Morgan Kaufmann, 2010, pogl. 1.
- [14] M. Zapušek, M. Možina, I. Bratko, J. Rugelj, M. Guid, “Designing an Interactive Teaching Tool with ABML Knowledge Refinement Loop”, *ITS 2014, Honolulu, Havaji (ZDA); 7-9 Junij, 2014*, v *Intelligent Tutoring Systems, Lecture Notes in Computer Science*, 2014, vol. 8474, str. 575-582.
- [15] Ajpes, Pojasnila za gospodarske družbe, zadruga in druge podjetnike. Dostopno na: [https://www.ajpes.si/fipo/Pojasnila\\_za\\_gd\\_2006.asp](https://www.ajpes.si/fipo/Pojasnila_za_gd_2006.asp) [dostop: 15.3.2015]

- [16] Gvin. Dostopno na: <http://www2.gvin.com/> [dostop: 15.3.2015]



# Dodatek A

## Povzetek učne seje zajemanja znanja iz učenca

V dodatku A je opisan še tisti del učne seje, ki ni bil predstavljen v poglavju 5. Izmed enajstih iteracij so tri (1, 3, 5) že bile opisane, ostale (2, 4, 6, 7, 8, 9, 10, 11) se nahajajo tu.

### A.1 Iteracija 2

**Kritični primer** LPP, d. o. o. B.1.

**Opis** Javno podjetje, LPP d. o. o., je uvrščeno v razred A kljub nekaterim slabšim kazalnikom. Učenec je opazil zelo nizko profitabilnost podjetja in visok dolg, kar kvečjemu kaže na pripadnost razredu E. Zelo spodbudni sta bili visoka dolgoročna rast prihodkov in velika pozitivna sprememba v marži EBIT. Za argument je izbral visoko *dlg.rast.prihodkov* in dejstvo, da je podjetje *javno*. Algoritmu ni uspelo najti protiprimerov, kar da slutiti, da je argument zelo dober. Ocene argumenta razkrijejo, da je argument preveč specifičen. To je bilo razvidno iz obrezanih pravil v sklopu *P3*. Sam pogoj *javno = TRUE* je zadostoval za pravilo s čisto distribucijo. Učenec je v nadaljevanju odstranil razlog *dlg.rast.prihodkov* iz argumenta. Analiza novega, krajšega argumenta

A2 je podala rezultate, podobne prejšnji.

**A1** visoka *dlg.rast.prihodkov*, javno = *TRUE*

**A2** javno = *TRUE*

### Ocene

		A1	A2
P1	m-estimate	0.87	0.87
	corrected	0	0
P2	faulted	0	0
	not corrected	0	0
	abs. diff	0.00	0.00
P3	potential	0.87	0.87

**Protiprimeri A1** Ni protiprimerov.

**Protiprimeri A2** Ni protiprimerov.

## A.2 Iteracija 4

**Kritični primer** ELBI, d. o. o. B.2.

**Opis** Podjetje *ELBI*, elektroinstalacije, projektiranje, trgovina, d. o. o., *Kranj* ima težave s premajhno dobičkonosnostjo in padajočimi prihodki. Učenec je to prepoznal in vnesel argument: nizek *EBIT*, nizka *dlg.rast.prihodkov* in nizka *spr.ebit.marzi*.

Ocena argumenta  $m = 0.96$ , dobljena s *P1*, nakazuje na zelo dober argument. Iz obrezanih pravil sklopa *P3* je učenec razbral, da je pogoj *dlg.rast.prihodkov* odvečen, pogoj *EBIT* pa centralen del argumenta. *P3* mu je predlagal boljše ocenjena razširjena pravila, a so bila ta tudi težje razumljiva. Učenec je na podlagi predloga *P3* odstranil razlog nizka *dlg.rast.prihodkov*. Poleg tega je v pregledu protiprimerov opazil, da sta obe podjetji javni. Zaradi tega je k argumentu dodal razlog javno = *FALSE*.

Z izboljšanim argumentom A2 je algoritem pridelal samo en protiprimer. Argument je bil ocenjen za odtenek boljše. Učenec je iz pravil sklopa P3 prepoznal, da razlog *spr.ebit.marzi* ne prispeva bistvene razlike. Dejansko ima ta atribut manjšo moč napovedovanja, saj bi prišel do izraza le z naprednejšo kombinacijo drugih atributov. Za takšne koncepte so odločitvena pravila, ki uporabljajo meje pri številskih atributih, manj primerna. Učenec v zadnji verziji argumenta odstrani razlog *spr.ebit.marzi*.

Argument A3 ponovno privede do istega protiprimera. Ocene potrdijo domnevo, da je argument zelo dober in ga je težko izboljšati. Zato se je učenec odločil za končanje iteracije.

**A1** nizek *EBIT*, nizka *dlg.rast.prihodkov*, nizka *spr.ebit.marzi*

**A2** nizek *EBIT*, nizka *spr.ebit.marzi*, *javno = FALSE*

**A3** nizek *EBIT*, *javno = FALSE*

### Ocene

		A1	A2	A3
P1	m-estimate	0.96	0.97	0.97
	corrected	0	0	0
P2	faulted	0	0	0
	not corrected	0	0	0
	abs. diff	0.01	0.00	0.00
P3	potential	0.97	0.97	0.97

### Protiprimeri A1

id	ocena	EBIT	dlg.rast.prihodkov	spr.ebit.marzi	javno
<b>ELBI, d. o. o</b>	E	-21,878	-12.4 %	-9.4	FALSE
Uradni list RS, d. o. o.	A	-113,520	-15.6 %	-2.2	TRUE
KOVOD Postojna, d. o. o.	A	-21,159	3.5 %	-4.8	TRUE

### Protiprimeri A2, A3

id	ocena	EBIT	spr.ebit.marzi	javno
<b>ELBI, d. o. o</b>	E	-21,878	-9.4	FALSE
MAROS, d. o. o.	A	-2,659	-3.0	FALSE

## A.3 Iteracija 6

**Kritični primer** AC, d. o. o. B.3.

**Opis** Podjetje *AC, agrocenter, d. o. o.*, je uvrščeno v razred A. Kazalci prikazujejo uspešno poslovanje, a tudi veliko finančnega dolga – visok *net.fin.dolg/EBITDA*. Učenec je moral argumentirati, zakaj spada primer v razred A kljub visoki zadolženosti. Odločil se je za argument: visok *equity.ratio* in visok *current.ratio*.

Algoritmu uspe najti tri protiprimere. Ocene argumenta A1 povejo, da je argument dober, ampak nepopoln. Pravila sklopa *P3* so pokazala, da sta oba razloga koristna. Manjka le pogoj, ki bi upošteval še dobičkonost podjetja. S takšnim argumentom lahko pridemo do ocene  $m = 0.98$ . Učenec je primerjal kritični primer s protiprimeri in opazil, da je atribut *TIE* bistveno večji pri kritičnem primeru (3.0) kot pri protiprimerih (1.0, 0, 0). Ta atribut upošteva tudi dobičkonosnost, saj ima v imenovalcu *EBIT*. Posledično je učenec k argumentu dodal nov pogoj visok *TIE*.

Z novim argumentom A2 dobimo dva protiprimera. Argument je bil ocenjen z odlično oceno  $m = 0.98$ . Obrezana pravila sklopa *P3* so pokazala, da so vsi trije pogoji koristni. Iz razširjenih pravil smo lahko razbrali, da lahko s popravo argumenta dosežemo le malenkostne razlike. Pri učenčevi zasnovi novega argumenta so bili spet odločilni protiprimeri. Opazil je namreč zanimivo situacijo. Kritični primer ima vrednost atributa *PDT* 163K, medtem ko protiprimera -921K in -479K. Tu gre za izrazito razliko, zato se je učenec odločil, da bo k argumentu dodal še razlog visok *PDT*.

Nov, še bolj specifičen argument A3 ni prinesel velikih sprememb. Učenec je iz pravil sklopa *P3* spoznal, da razlog visok *PDT* ne pripomore k izboljšanju argumenta. Iz praktičnega stališča nizek *PDT* ni zmeraj slaba lastnost. V primeru uvajanja novega produkta ali močno povečane prodaje podjetje poveča svoj obratni kapital. Tega je treba



seveda financirati, kar pomeni zmanjšana *PDT*. Ta se vrne k višjim vrednostim, ko se ekspanzija obratnih sredstev upočasni in začnejo pritekati denarna sredstva, pridobljena iz večje prodaje.

Na koncu se je učenec odločil za odstranitev atributa *PDT*, kar pomeni, da je zaključil iteracijo z argumentom A2.

**A1** visok *equity.ratio*, visok *current.ratio*

**A2** visok *equity.ratio*, visok *current.ratio*, visok *TIE*

**A3** visok *equity.ratio*, visok *current.ratio*, visok *TIE*, visok *PDT*

### Ocene

		A1	A2	A3
P1	m-estimate	0.84	0.98	0.98
	corrected	0	0	0
P2	faulted	8	0	0
	not corrected	0	0	0
	abs. diff	0.14	0.00	0.00
P3	potential	0.98	0.98	0.98

### Protiprimeri A1

id	ocena	equity.ratio	current.ratio	TIE
AC, d. o. o.	A	0.45	1.9	3.05
LENTHERM-INVEST, d. o. o.	E	0.58	1.34	1
PricewaterhouseCoopers, d. o. o.	E	0.58	2.22	0
ZARJA, d. o. o., Novo mesto	E	0.7	2.15	0

### Protiprimeri A2

id	ocena	equity.ratio	current.ratio	TIE	PDT
AC, d. o. o.	A	0.45	1.9	3.05	163,609
GORENJE GTI, d. o. o.	E	0.35	1.27	100	-921,000
ST-TREND, d. o. o.	E	0.4	2.38	2.43	-479,067

## A.4 Iteracija 7

**Kritični primer** IMP PROMONT-ELEKTRO, d. o. o., Novo mesto B.4.

**Opis** Podjetje *IMP PROMONT-ELEKTRO* je uvrščeno v razred A. Učenec se je po kratkem pregledu podatkov odločil za precej dolg argument: visok *current.ratio*, visok *equity.ratio*, visok *TIE* in visoka *krtk.rast.prihodkov*.

Dan argument A1 je pridelal štiri protiprimere. Ocena argumenta *P1* nam pove, da gre tu za odličen argument  $m = 0.98$ . Iz pravil prikazanih v *P3* je bilo razvidno, da so trije izmed štirih pogojev zelo koristni, medtem ko zadnji pogoj visoka *krtk.rast.prihodkov* ne prispeva veliko. Razširjena pravila so pokazala, da lahko dosežemo še boljšo distribucijo pokritosti z razširjenim argumentom. Eden izmed primer-nih pogojev za razširitev je bil nizek *net.fin.dolg/EBITDA*. Ker za tri od štirih danih protiprimerov velja, da imajo višjo vrednost kazalnika *net.fin.dolg/EBITDA* kot sam kritični primer, se je učenec odločil za razširitev argumenta s tem atributom.

Algoritem je z novim argumentom A2 našel samo en protiprimer. Ta se je pojavil že v prejšnji analizi argumenta – J.U.A. FRISCHEIS, d. o. o. Ocena *P1* je enaka prejšnji oceni, saj je nov dodan pogoj prezrt. Obrezana pravila v *P3* so pokazala, da lahko tudi brez omembe razlogov visoke *krtk.rast.prihodkov* in nizke *net.fin.dolg/EBITDA* pridemo do enako dobrih rezultatov. Razširjena pravila tu niso bila preveč v pomoč, ker so bila prezapletena. Učenec se je na podlagi prikazanih informacij odločil, da ne bo spreminjal argumenta. Na tem mestu je zaključil z iteracijo.

**A1** visok *current.ratio*, visok *equity.ratio*, visok *TIE*, visoka *krtk.rast.prihodkov*

**A2** visok *current.ratio*, visok *equity.ratio*, visok *TIE*, visoka *krtk.rast.prihodkov*,  
*net.fin.dolg/EBITDA*

## Ocene

		A1	A2
P1	m-estimate	0.98	0.98
	corrected	0	0
P2	faulted	0	0
	not corrected	0	0
	abs. diff	0.01	0.00
P3	potential	0.98	0.98

## Protiprimeri A1

id	ocena	current.r	equity.r	TIE	krtk.rast.pri	net.fin.dolg/EBITDA
<b>IMP PROMONT-ELEKTRO</b>	A	1.38	0.43	2.18	2.3	3.49
G G NOVO MESTO, d. d.	E	0.85	0.56	2.22	0.1	3.14
NCM, d. o. o.	E	0.88	0.56	2.17	-0.2	4.52
ST-TREND, d. o. o.	E	2.38	0.52	2.43	-0.5	7.05
J.U.A. FRISCHEIS, d. o. o.	E	12.45	0.4	2.24	0.0	6.21

## A.5 Iteracija 8

### Kritični primer PricewaterhouseCoopers, d. o. o. B.5.

**Opis** Tu gre za podjetje z nizko zadolženostjo, a z negativnimi prihodki iz poslovanja. Učenec se je po pregledu podatkov osredotočil na zadnji neaktiviran atribut *ROA*. Atribut meri donosnost podjetja glede na vložena sredstva. Po kratkem premisleku je učenec argumentiral: “Nizek *ROA* je glavni razlog za uvrstitev podjetja v razred E.”

Algoritem je z argumentom A1 našel tri protiprimere. Argument je bil ocenjen z oceno  $m = 0.91$ . Z danim argumentom sta bila “pokvarjena” dva primera. Tu je šlo predvidoma za dve javni podjetji, pri katerih profitabilnost podjetja ni tako odločilna za uvrščanje. Razširjena pravila so podala namige, kako priti do čiste distribucije pokritosti pravila iz argumenta. Najboljša izbira se je nahajala v prvem pravilu, tj. razlog *javno = FALSE*. Podobno informacijo so učencu posredovali protiprimeri. Med njimi imamo namreč dve javni podjetji. Učenec se je na podlagi podanih informacij odločil za razširitev argumenta z razlogom *javno = FALSE*.

Argument A2 je pridelal samo en protiprimer – MAROS, d. o. o. Ocena izboljššanega argumenta je odlična, in sicer  $m = 0.97$ . Obrezana pravila *P3* so potrdila, da je potrebna kombinacija obeh razlogov za tako dober rezultat. Razširjena pravila so podala nekaj minimalnih izboljšav argumenta. Na tem mestu se je učenec osredotočil na primerjavo kritičnega primera s protiprimerom. Ni mu uspelo najti razloga, ki bi pomagal k boljši ločitvi obeh primerov. Omenil je, da obstajajo kombinacije atributov, s katerimi bi odpravili protiprimer, a bi s tem prišli do argumenta, ki je preveč specifičen.

**A1** nizek *ROA*

**A2** nizek *ROA*, *javno = FALSE*

### Ocene

		A1	A2
P1	m-estimate	0.91	0.97
	corrected	0	0
P2	faulted	2	0
	not corrected	0	0
	abs. diff	0.06	0.00
P3	potential	0.97	0.97

### Protiprimeri A1

id	ocena	ROA	javno
PricewaterhouseCoopers, d. o. o.	E	-0.4 %	FALSE
Uradni list RS, d. o. o.	A	-2.2 %	TRUE
KOVOD Postojna, d. o. o.	A	-1.0 %	TRUE
MAROS, d. o. o.	A	0.0 %	FALSE

## A.6 Iteracija 9

**Kritični primer** KG-EKO, d. o. o. B.6.

**Opis** Podjetje je uvrščeno v razred A. Ima malo dolga, a ni zelo donosno. Učenec se je tu osredotočil predvsem na majhno zadolženost podjetja in podal argument nizek *net.fin.dolg/EBITDA* in nizek kazalnik *cel.posl.obv/sredstva*.

Algoritmu je uspelo najti sedem protiprimerov. Ocena argumenta  $m = 0.92$  nakazuje, da je argument zelo dober. Iz distribucije pravila generiranega v *P1* je bilo razvidno, da pravilo pravilno pokrije zelo veliko primerov. *P3* je pojasnil, da nobeden izmed pogojev ni bil odvečen. Nadalje je razkril, da lahko pridemo do odličnega argumenta, če je ta razširjen z atributom, ki se navezuje na dobičkonosnost podjetja. Učenec je iz sedmih protiprimerov izluščil podobne informacije kot iz *P3*. Oodločil se je za razširitev argumenta s pogojem visok *ROA*.

Nov argument *A2* je zmanjšal število protiprimerov na 5. Ocenjen je bil kot odličen argument  $m = 0.98$ . Iz pravil prikazanih v *P3* smo lahko razbrali, da so vsi trije pogoji potrebni za tako dober rezultat argumenta. Učencu ni uspelo najti nadaljnjih možnih izboljšav argumenta, zato se je na tem mestu odločil za zaključek iteracije.

**A1** nizek *net.fin.dolg/EBITDA*, nizek *cel.posl.obv/sredstva*

**A2** nizek *net.fin.dolg/EBITDA*, nizek *cel.posl.obv/sredstva*, visok *ROA*

**Ocene**

		A1	A2
P1	m-estimate	0.92	0.98
	corrected	0	0
P2	faulted	4	0
	not corrected	0	0
	abs. diff	0.06	0.00
P3	potential	0.98	0.98

## Protiprimeri A1

id	ocena	cel.posl.obv/sredstva	net.fin.dolg/EBITDA	ROA
KG-EKO, d. o. o.	A	23.1 %	0	0.9 %
G G NOVO MESTO, d. d.	E	13.8 %	3.14	3.3 %
ELBI, d. o. o	E	10.4 %	0.4	-0.8 %
STREET TOUR, d. o. o.	E	18.8 %	2.1	3.5 %
ARMAT PROJEKT, d. o. o.	E	8.3 %	-2.04	-3.6 %
AVTO TRIGLAV, d. o. o.	E	84.1 %	-1.67	3.3 %
PricewaterhouseCoopers, d. o. o.	E	38.8 %	-33.33	-0.4 %
KARIERA, d. o. o.	E	84.4 %	-4.91	5.6 %

## A.7 Iteracija 10

### Kritični primer ELMO, d. d. B.7.

**Opis** Podjetje je uvrščeno v razred E. Učenec se je po kratkem pregledu podatkov odločil za argument visok *cel.posl.obv/sredstva*, nizek *net.fin.dolg/EBITDA* in nizka *krtk.rast.prihodkov*. Presenetljiv je predvsem drugi pogoj. Atribut *net.fin.dolg/EBITDA* je eden izmed bolj zapletenih, kar je učenca privedlo do napačno zastavljenega pogoja. To je ugotovil v nadaljevanju tudi sam prek informacij podanih s *P3*.

Argument A1 je pridelal pet protiprimerov. *P1* je ocenil argument kot zelo dober, in sicer  $m = 0.93$ . Po seznanitvi s pravili v sklopu *P3* je učenec spoznal, da je napačno vnesel razlog *net.fin.dolg/EBITDA*. Obrezana pravila nadalje povedo, da sta ostala dva razloga koristna. Na podlagi enega izmed predlaganih razširjenih pravil učenec razširi argument s pogojem nizek *equity.ratio* in odstrani narobe zastavljeni pogoj nizek *net.fin.dolg/EBITDA*.

Z argumentom A2 se število najdenih protiprimerov zmanjša na dva. Argument dobi boljšo oceno kot prej, in sicer  $m = 0.96$ . Učencu nobeno izmed razširjenih pravil v sklopu *P3* ni bilo privlačno, saj se mu niso zdeli intuitivna. Prav tako mu ne uspe najti dodatnih razlogov za boljšo ločitev kritičnega primera od protiprimerov. Zaradi tega se na tem mestu odloči za končanje iteracije.

**A1** visok *cel.posl.obv/sredstva*, nizek *net.fin.dolg/EBITDA*, nizka *krtk.rast.prihodkov*

**A2** visok *cel.posl.obv/sredstva*, nizka *krtk.rast.prihodkov*, nizek *equity.ratio*

### Ocene

		A1	A2
P1	m-estimate	0.93	0.96
	corrected	0	0
P2	faulted	0	0
	not corrected	0	0
	abs. diff	0.04	0.02
P3	potential	0.97	0.98

### Protiprimeri A1

id	ocena	cel.posl.obv/sredstva	net.fin.dolg/EBITDA	krtk.rast.pri	equity.r
ELMO, d. d.	E	55.6	0.62	-11.1 %	0.27
ADD, d. o. o.	A	44.2	0.5	-16.9 %	0.38
RC MASPOS, d. o. o.	A	42.2	0	-97.7 %	0.58
CAT LOGISTIC, d. o. o.	A	59.4	-1.56	11.2 %	0.19
DUKART, d. o. o.	A	59.8	2.29	8.1 %	0.23
SLOREST, d. o. o.	A	62.7	-0.75	-2.5 %	0.23

### Protiprimeri A2

id	ocena	cel.posl.obv/sredstva	krtk.rast.pri	equity.r
ELMO, d. d.	E	55.6	-11.1 %	0.27
Beyond Devices, d. o. o.	A	18.3	-16.9 %	0.38
SLOREST, d. o. o.	A	62.7	-97.7 %	0.58

## A.8 Iteracija 11

**Kritični primer** AVTO TRIGLAV, d. o. o. B.8.

**Opis** Podjetje *AVTO TRIGLAV, d. o. o.*, je uvrščeno v razred E. Učenec je opazil, da ima podjetje zelo malo lastniškega kapitala in zelo veliko poslovnih obveznosti. Na podlagi tega je podal argument: visok kazalnik *cel.posl.obv/sredstva* in nizek *equity.ratio*.

Algoritem je z argumentom A1 našel en protiprimer. Sodeč po oceni ( $m = 0.97$ ), gre za odličen argument. Pravila iz sklopa *P3* so nakazovala,

da je pogoj z atributom *cel.posl.obv/sredstva* odvečen. Prikazana so bila tudi razširjena pravila, ki so dosegla za odtenek boljšo oceno, a večina izmed njih ni imela smiselnih pogojev. Učenec se ni obremenjeval s protiprimerom, saj je imel po njegovem mnenju zadosti nizek kazalnik *cel.posl.obv/sredstva* in zaradi tega ni tako relevanten. Odločil se je, da ne bo odstranjeval atributa *cel.posl.obv/sredstva*, in s tem zaključil iteracijo.

**A1** visok *cel.posl.obv/sredstva*, nizek *equity.ratio*

### Ocene

		A1
P1	m-estimate	0.97
	corrected	0
P2	faulted	0
	not corrected	0
	abs. diff	0.01
P3	potential	0.97

### Protiprimeri A1

id	ocena	cel.posl.obv/sredstva	equity.ratio
AVTO TRIGLAV d. o. o.	E	84.1	0.1
TAURUS TRANSPORT d. o. o.	A	44.1	0.18





# Dodatek B

## Kritični primeri

### Kritični primer 2

1		id	JAVNO PODJETJE LJUBL
2		dejavnost.id	49.31
3		dejavnost.ime	MESTNI IN PRIMESTNI
4	1	dejavnost	H
5	2	velikost	L
6		IPI	
7	3	prihodki.od.prodaje	45,444,464
8	4	stroski.blaga.materiala.in.stor	19,048,142
9	5	stroski.dela	21,662,304
10	6	odpisi.vrednosti	4,670,354
11	7	fin.odhodki	760,013
12	8	obresti	760,013
13	9	EBIT	345,237
14	10	EBITDA	5,015,591
15	11	cisti.dobicek	56,574
16		BS	
17	12	sredstva	37,735,536
18	13	kapital	12,033,043
19	14	fin.dolg	16,145,928
20	15	denarna.sredstva	397,553
21	16	dlg.sredstva	32,463,290
22	17	krtk.sredstva	5,110,223
23	18	cel.posl.obv	4,594,001
24	19	krtk.posl.obv	4,578,850
25	20	dlg.obv	6,407,667
26	21	krtk.obv	14,332,262
27	22	zaloge	404,874
28		CF	
29	23	DT	4,712,630
30	24	PDT	4,423,320
31		Ratios	
32	25	**cel.posl.obv/sredstva	12.2 %
33	26	current.ratio	0.36
34	27	**dlg.rast.prihodkov	12.5 %
35	28	**krtk.rast.prihodkov	5.8 %
36	29	**spr.ebit.marzi	23.0
37	30	**net.fin.dolg/EBITDA	3.14
38	31	**equity.ratio	0.32
39	32	**TIE	0.45
40	33	**ROA	0.9 %
41	34	**javno	TRUE
42		bon.ocena	A

## Kritični primer 4

1		id	ELBI, elektroinstala
2		dejavnost.id	47.54
3		dejavnost.ime	TRGOVINA NA DROBNO V
4	1	dejavnost	G
5	2	velikost	S
6		IPI	
7	3	prihodki.od.prodaje	1,611,747
8	4	stroski.blaga.materiala.in.stor	1,309,352
9	5	stroski.dela	268,838
10	6	odpisi.vrednosti	62,596
11	7	fin.odhodki	1,201
12	8	obresti	727
13	9	EBIT	-21,878
14	10	EBITDA	40,718
15	11	cisti.dobicek	31,688
16		BS	
17	12	sredstva	2,694,571
18	13	kapital	2,250,811
19	14	fin.dolg	16,795
20	15	denarna.sredstva	574
21	16	dlg.sredstva	442,292
22	17	krtk.sredstva	2,242,097
23	18	cel.posl.obv	280,448
24	19	krtk.posl.obv	280,448
25	20	dlg.obv	10,097
26	21	krtk.obv	287,146
27	22	zaloge	376,873
28		CF	
29	23	DT	87,211
30	24	PDT	89,972
31		Ratios	
32	25	**cel.posl.obv/sredstva	10.4 %
33	26	current.ratio	7.81
34	27	dlg.rast.prihodkov	-12.4 %
35	28	**krtk.rast.prihodkov	-26.1 %
36	29	**spr.ebit.marzi	-9.4
37	30	net.fin.dolg/EBITDA	0.40
38	31	equity.ratio	0.84
39	32	**TIE	0.00
40	33	**ROA	-0.8 %
41	34	javno	FALSE
42		bon.ocena	E

Izpis B.2: Kritični primer 4.

## Kritični primer 6

1		id AC, agrocenter, d.o.	
2		dejavnost.id	45.31
3		dejavnost.ime	TRGOVINA NA DEBELO Z
4	1	dejavnost	G
5	2	velikost	S
6		IPI	
7	3	prihodki.od.prodaje	4,165,138
8	4	stroski.blaga.materiala.in.stor	3,215,495
9	5	stroski.dela	629,390
10	6	odpisi.vrednosti	114,762
11	7	fin.odhodki	67,660
12	8	obresti	67,660
13	9	EBIT	206,519
14	10	EBITDA	321,281
15	11	cisti.dobicek	160,624
16		BS	
17	12	sredstva	5,209,009
18	13	kapital	2,327,787
19	14	fin.dolg	1,860,092
20	15	denarna.sredstva	84,460
21	16	dlg.sredstva	1,409,047
22	17	krtk.sredstva	3,799,962
23	18	cel.posl.obv	970,181
24	19	krtk.posl.obv	970,181
25	20	dlg.obv	828,205
26	21	krtk.obv	2,002,068
27	22	zaloge	3,275,146
28		CF	
29	23	DT	265,380
30	24	PDT	163,609
31		Ratios	
32	25	cel.posl.obv/sredstva	18.6 %
33	26	current.ratio	1.90
34	27	dlg.rast.prihodkov	2.2 %
35	28	**krtk.rast.prihodkov	2.7 %
36	29	spr.ebit.marzi	-1.2
37	30	net.fin.dolg/EBITDA	5.53
38	31	equity.ratio	0.45
39	32	**TIE	3.05
40	33	**ROA	4.0 %
41	34	javno	FALSE
42		bon.ocena	A

Izpis B.3: Kritični primer 6.

## Kritični primer 7

1		id	IMP PROMONT-ELEKTRO
2		dejavnost.id	43.21
3		dejavnost.ime	INSTALIRANJE ELEKTRI
4	1	dejavnost	F
5	2	velikost	S
6		IPI	
7	3	prihodki.od.prodaje	11,374,385
8	4	stroski.blaga.materiala.in.stor	10,821,487
9	5	stroski.dela	343,619
10	6	odpisi.vrednosti	33,906
11	7	fin.odhodki	79,090
12	8	obresti	79,090
13	9	EBIT	172,125
14	10	EBITDA	206,031
15	11	cisti.dobicek	97,163
16		BS	
17	12	sredstva	5,289,935
18	13	kapital	2,280,296
19	14	fin.dolg	722,643
20	15	denarna.sredstva	3,821
21	16	dlg.sredstva	872,534
22	17	krtk.sredstva	4,101,497
23	18	cel.posl.obv	2,286,996
24	19	krtk.posl.obv	2,286,996
25	20	dlg.obv	33,922
26	21	krtk.obv	2,975,717
27	22	zaloge	2,805,137
28		CF	
29	23	DT	130,441
30	24	PDT	546,151
31		Ratios	
32	25	cel.posl.obv/sredstva	43.2 %
33	26	current.ratio	1.38
34	27	dlg.rast.prihodkov	59.5 %
35	28	**krtk.rast.prihodkov	231 %
36	29	spr.ebit.marzi	-9.9
37	30	net.fin.dolg/EBITDA	3.49
38	31	equity.ratio	0.43
39	32	TIE	2.18
40	33	**ROA	3.3 %
41	34	javno	FALSE
42		bon.ocena	A

Izpis B.4: Kritični primer 7.

## Kritični primer 8

1		id	PRICEWATERHOUSECOOPE	
2		dejavnost.id	69.2	
3		dejavnost.ime	RACUNOVODSKE, KNJIGO	
4	1	dejavnost	M	
5	2	velikost	S	
6		IPI		
7	3	prihodki.od.prodaje	5,979,742	
8	4	stroski.blaga.materiala.in.stor	3,230,958	
9	5	stroski.dela	2,606,197	
10	6	odpisi.vrednosti	56,202	
11	7	fin.odhodki	4,051	
12	8	obresti	4,051	
13	9	EBIT	-12,264	
14	10	EBITDA	43,938	
15	11	cisti.dobicek	20,658	
16		BS		
17	12	sredstva	3,546,980	
18	13	kapital	2,043,771	
19	14	fin.dolg	0	
20	15	denarna.sredstva	1,464,346	
21	16	dlg.sredstva	475,903	
22	17	krtk.sredstva	3,051,469	
23	18	cel.posl.obv	1,377,432	
24	19	krtk.posl.obv	1,377,432	
25	20	dlg.obv	0	
26	21	krtk.obv	1,377,432	
27	22	zaloge	0	
28		CF		
29	23	DT	76,860	
30	24	PDT	458,882	
31		Ratios		
32	25	cel.posl.obv/sredstva	38.8 %	
33	26	current.ratio	2.22	
34	27	dlg.rast.prihodkov	9.9 %	
35	28	krtk.rast.prihodkov	-10.7 %	
36	29	spr.ebit.marzi	4.3	
37	30	net.fin.dolg/EBITDA	-33.33	
38	31	equity.ratio	0.58	
39	32	TIE	0.00	
40	33	**ROA	-0.4 %	
41	34	javno	FALSE	
42		bon.ocena	E	

Izpis B.5: Kritični primer 8.

## Kritični primer 9

1		id	KG-EKO, Proizvodnja	
2		dejavnost.id	43.99	
3		dejavnost.ime	DRUGA SPECIALIZIRANA	
4	1	dejavnost	F	
5	2	velikost	S	
6		IPI		
7	3	prihodki.od.prodaje	1,310,336	
8	4	stroski.blaga.materiala.in.stor	1,038,720	
9	5	stroski.dela	177,429	
10	6	odpisi.vrednosti	238,726	
11	7	fin.odhodki	37,821	
12	8	obresti	37,821	
13	9	EBIT	16,143	
14	10	EBITDA	254,869	
15	11	cisti.dobicek	7,192	
16		BS		
17	12	sredstva	1,693,687	
18	13	kapital	1,289,034	
19	14	fin.dolg	5,191	
20	15	denarna.sredstva	6,360	
21	16	dlg.sredstva	1,393,268	
22	17	krtk.sredstva	300,419	
23	18	cel.posl.obv	391,916	
24	19	krtk.posl.obv	391,916	
25	20	dlg.obv	0	
26	21	krtk.obv	397,107	
27	22	zaloge	13,374	
28		CF		
29	23	DT	245,918	
30	24	PDT	144,103	
31		Ratios		
32	25	cel.posl.obv/sredstva	23.1 %	
33	26	current.ratio	0.76	
34	27	dlg.rast.prihodkov	5.1 %	
35	28	krtk.rast.prihodkov	-36.0 %	
36	29	spr.ebit.marzi	-4.3	
37	30	net.fin.dolg/EBITDA	0.00	
38	31	equity.ratio	0.76	
39	32	TIE	0.43	
40	33	ROA	0.9 %	
41	34	javno	FALSE	
42		bon.ocena	A	

Izpis B.6: Kritični primer 9.

## Kritični primer 10

1		id	ELMO Elektromontazno	
2		dejavnost.id	43.21	
3		dejavnost.ime	INSTALIRANJE ELEKTRI	
4	1	dejavnost	F	
5	2	velikost	M	
6		IPI		
7	3	prihodki.od.prodaje	5,145,154	
8	4	stroski.blaga.materiala.in.stor	3,874,660	
9	5	stroski.dela	1,119,112	
10	6	odpisi.vrednosti	78,264	
11	7	fin.odhodki	28,392	
12	8	obresti	28,392	
13	9	EBIT	277,031	
14	10	EBITDA	355,295	
15	11	cisti.dobicek	30,516	
16		BS		
17	12	sredstva	2,751,875	
18	13	kapital	745,144	
19	14	fin.dolg	388,054	
20	15	denarna.sredstva	166,523	
21	16	dlg.sredstva	477,659	
22	17	krtk.sredstva	2,274,216	
23	18	cel.posl.obv	1,531,051	
24	19	krtk.posl.obv	1,531,051	
25	20	dlg.obv	0	
26	21	krtk.obv	1,919,105	
27	22	zaloge	241,290	
28		CF		
29	23	DT	98,500	
30	24	PDT	-125,554	
31		Ratios		
32	25	cel.posl.obv/sredstva	55.6 %	
33	26	current.ratio	1.19	
34	27	dlg.rast.prihodkov	-3.6 %	
35	28	krtk.rast.prihodkov	-11.1 %	
36	29	spr.ebit.marzi	22.3	
37	30	net.fin.dolg/EBITDA	0.62	
38	31	equity.ratio	0.27	
39	32	TIE	9.76	
40	33	ROA	6.0 %	
41	34	javno	FALSE	
42		bon.ocena	E	

Izpis B.7: Kritični primer 10.



## Kritični primer 11

1		id	AVTO TRIGLAV trgovin	
2		dejavnost.id	45.11	
3		dejavnost.ime	TRGOVINA Z AVTOMOBIL	
4	1	dejavnost	G	
5	2	velikost	L	
6		IPI		
7	3	prihodki.od.prodaje	118,629,088	
8	4	stroski.blaga.materiala.in.stor	113,712,920	
9	5	stroski.dela	2,795,655	
10	6	odpisi.vrednosti	143,845	
11	7	fin.odhodki	147,633	
12	8	obresti	147,633	
13	9	EBIT	1,525,413	
14	10	EBITDA	1,669,258	
15	11	cisti.dobicek	1,467,387	
16		BS		
17	12	sredstva	47,786,436	
18	13	kapital	4,909,145	
19	14	fin.dolg	1,556,199	
20	15	denarna.sredstva	4,341,712	
21	16	dlg.sredstva	954,483	
22	17	krtk.sredstva	46,812,568	
23	18	cel.posl.obv	40,173,096	
24	19	krtk.posl.obv	40,173,096	
25	20	dlg.obv	24,134	
26	21	krtk.obv	41,705,160	
27	22	zaloge	16,689,567	
28		CF		
29	23	DT	1,611,232	
30	24	PDT	278,384	
31		Ratios		
32	25	cel.posl.obv/sredstva	84.1 %	
33	26	current.ratio	1.12	
34	27	dlg.rast.prihodkov	-4.9 %	
35	28	krtk.rast.prihodkov	-1.4 %	
36	29	spr.ebit.marzi	0.3	
37	30	net.fin.dolg/EBITDA	-1.67	
38	31	equity.ratio	0.10	
39	32	TIE	10.33	
40	33	ROA	3.3 %	
41	34	javno	FALSE	
42		bon.ocena	E	

Izpis B.8: Kritični primer 11.