

UNIVERZA V LJUBLJANI  
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Maja Madarasi

**Podatkovna analiza uspešnosti  
sodelovanja zdravnikov in  
farmacevtov**

DIPLOMSKO DELO

VISOKOŠOLSKI STROKOVNI ŠTUDIJSKI PROGRAM PRVE  
STOPNJE RAČUNALNIŠTVO IN INFORMATIKA

MENTOR: prof. dr. Marko Robnik-Šikonja

Ljubljana 2011



Št. naloge: 00128/2011

Datum: 15.06.2011

Univerza v Ljubljani, Fakulteta za računalništvo in informatiko izdaja naslednjo nalogo:

Kandidat: **MAJA MADARASI**

Naslov: **PODATKOVNA ANALIZA USPEŠNOSTI SODELOVANJA  
ZDRAVNIKOV IN FARMACEVTOV**  
**DATA ANALYSIS OF MEDICAL DOCTORS AND CLINICAL  
PHARMACISTS' COOPERATION**

Vrsta naloge: Diplomsko delo visokošolskega strokovnega študija prve stopnje

Tematika naloge:

V klinični praksi je sodelovanje farmacevtov in zdravnikov zelo dobrodošlo in lahko pripomore k večji uspešnosti zdravljenja, saj je njihovo znanje komplementarno. Žal uvajanje farmacevtov na klinične oddelke ni brez težav, k temu pa pripomore vrsta dejavnikov, od strokovnih zadržkov do osebnostnih lastnosti vpletenih. Analizirajte dano zbirko anketnih podatkov z mnenji zdravnikov, medicinskih sester in farmacevtov o potrebnosti in kompetencah kliničnih farmacevtov ter poskušajte napovedati, kje bo uvajanje novih farmacevtov uspešno in kateri faktorji vplivajo na to. Za analizo pomembnosti različnih atributov uporabite metodi OrdEval in algoritem za izbiro podmnožice pomembnih atributov ReliefF. Z metodami strojnega učenja na podlagi obstoječih podatkov zgradite napovedni model. Rezultate kritično ovrednotite.

Mentor:

  
prof. dr. Marko Robnik Šikonja

Dekan:

  
prof. dr. Nikolaj Zimic



Rezultati diplomskega dela so intelektualna lastnina Fakultete za računalništvo in informatiko Univerze v Ljubljani in avtorice. Za objavljane ali izkoriščanje rezultatov diplomskega dela je potrebno pisno soglasje Fakultete za računalništvo in informatiko ter mentorja.

*Besedilo je oblikovano z urejevalnikom besedil  $\LaTeX$ .*

## IZJAVA O AVTORSTVU DIPLOMSKEGA DELA

Spodaj podpisana Maja Madarasi, z vpisno številko **63070198**, sem avtorica diplomskega dela z naslovom: *Podatkovna analiza uspešnosti sodelovanja zdravnikov in farmacevtov*.

S svojim podpisom zagotavljam, da:

- sem diplomsko delo izdelala samostojno pod mentorstvom prof. dr. Marka Robnik-Šikonje,
- so elektronska oblika diplomskega dela, naslov (slov., angl.), povzetek (slov., angl.) ter ključne besede (slov., angl.) identični s tiskano obliko diplomskega dela
- soglašam z javno objavo elektronske oblike diplomskega dela v zbirki "Dela FRI".

V Ljubljani, dne 30. avgusta 2011

Podpis avtorja:

*Zahvaljujem se mentorju prof. dr. Marku Robnik-Šikonji za vse nasvete in pomoč pri izdelavi diplomske naloge.*

*Zahvaljujem se asist. mag. Andreji Čufar, mag. farm., spec., vodji lekarne Univerzitetnega kliničnega centra Ljubljana, ki je predstavila idejo za moje diplomsko delo in zagotovila podatke z anketnih vprašalnikov.*

# Seznam prevedenih izrazov

Classification accuracy - *klasifikacijska točnost*

Classification tree - *klasifikacijsko drevo*

Cross validation - *prečno preverjanje*

Gain-ratio - *razmerje informacijskega prispevka*

Information gain - *informacijski prispevek*

K-fold cross validation - *K-kratno prečno preverjanje*

Leave-one-out - *metoda izloči enega*

Minimum description length - *princip najkrajšega opisa*

Random forests - *naključni gozdovi*

Widget - *grafični gradnik*

# Kazalo

**Povzetek**

**Abstract**

<b>1</b>	<b>Uvod</b>	<b>1</b>
<b>2</b>	<b>Opis metod strojnega učenja</b>	<b>3</b>
2.1	Algoritem OrdEval . . . . .	3
2.2	Mere za ocenjevanje pomembnosti atributov . . . . .	4
2.2.1	Algoritem ReliefF . . . . .	5
2.2.2	Algoritem MDL . . . . .	6
2.3	Ocenjevanje učenja . . . . .	8
2.3.1	Metoda izloči enega . . . . .	8
2.3.2	K-kratno prečno preverjanje . . . . .	8
2.4	Okolja za strojno učenje . . . . .	10
2.4.1	Statistični program R . . . . .	10
2.4.2	Orange . . . . .	11
<b>3</b>	<b>Opis problema in podatkov</b>	<b>13</b>
<b>4</b>	<b>Poskusi</b>	<b>17</b>
4.1	Rezultati metode OrdEval . . . . .	17
4.2	Rezultati ocenjevanja atributov . . . . .	22
4.2.1	Ocenjevanje atributov z algoritmom ReliefF . . . . .	22

## KAZALO

4.2.2	Ocenjevanje atributov z algoritmom MDL . . . . .	25
4.3	Napovedni modeli . . . . .	28
4.3.1	10-kratno prečno preverjanje . . . . .	28
4.3.2	Metoda izloči enega . . . . .	31
<b>5</b>	<b>Zaključek</b>	<b>37</b>
<b>A</b>	<b>Anketni vprašalnik za zdravnike in medicinske sestre</b>	<b>41</b>
<b>B</b>	<b>Distribucija vrednosti odgovorov z anketnih vprašalnikov</b>	<b>51</b>
<b>C</b>	<b>Napovedane ocene sodelovanja</b>	<b>55</b>

# Povzetek

V diplomskem delu je opisana analiza anketnih vprašalnikov, ki so jih izpolnili zdravniki, medicinske sestre in farmacevti na Univerzitetnem kliničnem centru Ljubljana glede sodelovanja med njimi. Podatke smo najprej obdelali v statističnem programu R z metodo OrdEval, ki je vključena v paket CORElearn in jih primerjali z drugimi statističnimi tehnikami za analizo tovrstnih podatkov. Ocenjevanje atributov smo izvedli še z algoritmoma ReliefF in MDL ter v programu Orange izdelali napovedne modele z 10-kratnim prečnim preverjanjem in metodo izloči enega.

Ugotovili smo, da so odgovori na določena vprašanja zelo pomembni, saj odločilno vplivajo na oceno sodelovanja. Pri izdelavi napovednih modelov smo najboljšo klasifikacijsko točnost dobili s klasifikacijskim drevesom, zato smo ga uporabili tudi pri napovedi uspešnosti sodelovanja na anketnih odgovorih zdravnikov in medicinskih sester, ki še niso sodelovali s kliničnim farmacevtom in tako ugotovili, kje bi jih bilo priporočljivo vpeljati.

## **Ključne besede:**

strojno učenje, metoda OrdEval, analiza podatkov, napovedni modeli, sodelovanje zdravnikov in farmacevtov

# Abstract

The thesis describes the analysis of questionnaires filled out by doctors, nurses and pharmacists at the University Medical Centre Ljubljana about cooperation between them. The data were first processed in the statistical program R with OrdEval method, which is included in the CORElearn package and compared with other statistical techniques. Evaluation of attributes was carried out with ReliefF and MDL algorithms. Predictive models were created in the program Orange with 10-fold cross validation and leave-one-out cross-validation methods.

We discovered that answers to certain questions are very important, because they influence the assessment of cooperation. The best classification accuracy was obtained with the classification tree, so we used it to predict the success of cooperation in clinical departments, who have not cooperated with the clinical pharmacists yet.

## **Keywords:**

machine learning, OrdEval method, data analysis, predictive models, cooperation between doctors and pharmacists

# Poglavje 1

## Uvod

V Univerzitetnem kliničnem centru (UKC) Ljubljana poskušajo v klinično prakso že nekaj časa vključevati znanje kliničnih farmacevtov, saj je obravnavana s pomočjo kliničnega farmacevta za bolnika bolj prijazna, soodločanje o terapiji razbremeni zdravnika in prepreči možnost napačno predpisanih zdravil. Ker zagotavlja optimalno oskrbo bolnikov z zdravili, t.j. učinkovito, varno in farmakoekonomsko uporabo zdravil, prihrani bolnišnici tudi precej dodatnih stroškov.

Vodja lekarne UKC Ljubljana asist. mag. Andreja Čufar, mag. farm., spec. je s pomočjo anketnega vprašalnika raziskala pričakovanja in odnos zdravnikov in medicinskih sester do storitev kliničnega farmacevta na oddelkih UKC, kjer sodelovanje s kliničnimi farmacevti že poteka in na oddelkih, kjer bi jih še želela vpeljati. Rezultate anket smo obdelali z metodami strojnega učenja, da bi ji pomagali določiti oddelke, kjer bi bilo sodelovanje še dobro vpeljati. Za osnovo smo uporabili odgovore oddelkov, kjer sodelovanje že poteka. Zanimalo nas je, katera vprašanja in odgovori odločilno vplivajo na uspešnost in neuspešnost sodelovanja, da bi se jim v prihodnosti bolj posvetili.

V prvem delu diplomske naloge so podrobneje opisane metode in učni algoritmi, ki smo jih uporabili za analizo podatkov, ter programski okolji R in Orange. Najprej smo uporabili metodo OrdEval za analizo pomembnosti

različnih ordinalnih faktorjev, nato pa metodi za ocenjevanje atributov Relief in MDL. Omenjene metode so implementirane v paketu CORElearn v programu R, zato smo ga izbrali kot orodje za obdelavo.

V tretjem poglavju so opisane zastavljene naloge in podatki, ki smo jih dobili od vodje lekarne UKC Ljubljana, četrto poglavje pa predstavi rezultate naše analize, ki podrobneje opiše načine, ki smo jih uporabili za obdelavo podatkov, ocenjevanje atributov in izdelavo napovednega modela.

Peto poglavje povzame rezultate ocenjevanja atributov in izdelave napovednih modelov in glavnih ugotovitev, ki jih bo vodja lekarne lahko uporabila pri nadaljnjem vpeljevanju kliničnih farmacevtov na oddelke.

# Poglavje 2

## Opis metod strojnega učenja

Pri analizi podatkov, ocenjevanju atributov in izdelavi napovednih modelov smo uporabili metode in algoritme, ki so opisani v naslednjih podpoglavjih.

### 2.1 Algoritem OrdEval

“Ordered Evaluation” algoritem (OrdEval) se uporablja za analizo podatkov, kjer imajo spremenljivke ordinalne vrednosti, zato je primeren tudi za anketne raziskave, kjer so odgovori podani v stopnjah. Njegove lastnosti so občutljivost na kontekst, sposobnost, da izkoristi pomen urejenih lastnosti in robustnost proti šumu in manjkajočim vrednostim.

Namen algoritma OrdEval je ovrednotiti pomen in vpliv različnih dejavnikov v danih podatkih. Če imamo, na primer, podatke o zadovoljstvu kupcev z določenim produktom, lahko algoritem OrdEval določi pomembnost posamezne lastnosti produkta glede na celotno kupčevo zadovoljstvo z izdelkom in hkrati prepozna vrednosti, kjer ima zadovoljstvo s posamezno lastnostjo produkta močan pozitiven ali negativen vpliv na celotno zadovoljstvo. Rezultati algoritma OrdEval so verjetnostni faktorji, ki nakažejo verjetnost, da bo povečanje ali zmanjšanje vrednosti posamezne lastnosti vplivalo na skupno zadovoljstvo [?].

## 2.2 Mere za ocenjevanje pomembnosti atributov

Pri klasifikacijskih problemih je ena od nalog učnega algoritma oceniti pomembnost atributov za dani učni problem. Ker je množica primerov za naš problem podana v atributni predstavitvi, bomo uporabljali naslednji zapis:

- množica atributov  $A = \{A_i, i = 0 \dots a\}$ ;
- za vsak diskretni atribut  $A_i$  imamo množico možnih vrednosti  $\nu_i = \{V_1, \dots, V_{n_i}\}$ ;
- za vsak zvezni atribut  $A_i$  imamo interval možnih vrednosti  $\nu_i = [Min_i, \dots, Max_i]$ ;
- razred je podan z atributom  $A_0$ : če rešujemo klasifikacijski problem, potem je  $A_0$  diskretni atribut, če pa rešujemo regresijski problem, je  $A_0$  številski atribut;
- en učni primer je vektor vrednosti atributov  $u_j = \langle r^{(j)}, v^{(1,j)}, \dots, v^{(a,j)} \rangle$ , pri tem je razred označen z  $r^{(j)} = v^{(0,j)}$ ;
- množica učnih primerov je podana kot množica vektorjev  $\mathcal{U} = \{u_j, j = 1 \dots n\}$

Mere, ki se pogosto uporabljajo za usmerjanje iskanja v klasifikacijskih in regresijskih problemih, so [?]:

- informacijski prispevek,
- razmerje informacijskega prispevka,
- Gini-indeks,
- ReliefF,
- princip najkrajšega opisa (MDL),

- razdalja dogodkov.

V naslednjih podpoglavjih bomo opisali meri ReliefF in MDL, ki smo ju uporabili za ocenjevanje atributov.

### 2.2.1 Algoritem ReliefF

ReliefF je algoritem za ocenjevanje atributov, ki ni kratkoviden, saj ne predpostavlja apriorne in pogojne neodvisnosti atributov pri danem razredu. Omogoča nam ocenjevanje atributov na realnih problemih, saj obravnava šumne in neznane vrednosti ter večrazredne probleme.

Algoritem sta razvila Kira in Rendell [?], nato pa ga je posplošil in izboljšal Kononenko [?]. Meri uporabnost atributov glede na njihovo sposobnost razlikovanja med podobnimi primeri.

Osnovna ideja algoritma je, da za vsak učni primer poišče najbližji primer iz istega razreda (najbližji zadetek) in najbližji primer iz nasprotnega razreda (najbližji pogrešek). Tako oceni kvaliteto atributov glede na lokalne značilnosti razločevanja razredov. Ker lokalnost vključuje v oceno tudi druge attribute, ReliefF implicitno ocenjuje attribute v odvisnosti od ostalih atributov.

ReliefF pri ocenjevanju atributov uporablja tudi nepopolne podatke. Na šumnih podatkih se zanesljivost poveča z izbiro  $k$  najbližjih zadetkov in  $k$  najbližjih pogreškov ter povprečenjem njihovih prispevkov. Tipična vrednost parametra je  $k = 5, \dots, 10$ . Pri večrazrednih problemih ReliefF namesto  $k$  najbližjih pogreškov iz nasprotnega razreda poišče  $k$  najbližjih pogreškov iz vsakega razreda. Prispevki posameznih razredov so obteženi z apriornimi verjetnostmi razredov.

Psevdokoda algoritma:

```
inicializiraj polje ocen atributov
določi število najbližjih primerov  $k$ 
določi število iteracij algoritma  $m$ 
for  $i = 1$  to  $m$  do
    iz množice primerov naključno izberi primer  $I$ 
    primeru  $I$  poišči  $k$  najbližjih zadetkov
    primeru  $I$  poišči  $k$  najbližjih pogreškov
    za vse razrede
        iz najbližjih zadetkov in najbližjih pogreškov izračunaj
        oceno
        oceno zapiši v ustrezno polje ocen atributov
end
vrni polje ocen atributov
```

### 2.2.2 Algoritem MDL

Princip najkrajšega opisa (minimum description length - MDL) [?, ?] izhaja iz Occamovega rezila, ki pravi, da je najpreprostejša razlaga najbolj zanesljiva. Princip najkrajšega opisa zahteva od učnega algoritma, da poišče kompromis med kompleksnostjo teorije in njeno točnostjo. Hipoteza je kompresivna, če je opis modela skupaj z opisom izpeljave podatkov iz hipoteze krajši od opisa originalnih podatkov. Atribut je tem pomembnejši, čimbolj je kompresiven.

Imejmo primer prenosa podatkov po komunikacijskem kanalu. Oba, pošiljatelj in sprejemnik, poznata vse možne vrednosti  $V_j$  danega atributa  $A$ , število možnih razredov  $m_0$  in za vsak (učni) primer  $u_i$  poznata vrednosti atributa:  $v^{(i)}$ . Samo pošiljatelj pozna pravilne razrede za vse primere. Naloga pošiljatelja je poslati informacijo o razredih za vse primere, tako da je sporočilo čim krajše, t.j. kodirano s čim manjšim številom bitov. Število bitov, ki so potrebni za zakodiranje razredov primerov z dano verjetnostno

porazdelitvijo, lahko aproksimiramo z entropijo  $H_R$ , pomnoženo s številom primerov  $n$ , čemur prištejemo število bitov, potrebnih za zakodiranje porazdelitve po razredih. Ker imamo  $n$  primerov in  $m_0$  razredov, je število različnih porazdelitev enako:

$$\binom{n + m_0 - 1}{m_0 - 1}$$

Pri izpeljavi dobimo:

$$\begin{aligned} MDL(A) = & \frac{1}{n} \left( \log \binom{n}{n_1, \dots, n_{m_0}} - \sum_j \log \binom{n_j}{n_{1j}, \dots, n_{m_0j}} \right) + \\ & + \log \binom{n + m_0 - 1}{m_0 - 1} - \sum_j \log \binom{n_j + m_0 - 1}{m_0 - 1} \end{aligned}$$

Izkazalo se je, da je ocena  $MDL$  najprimernejša glede pristranskosti pri ocenjevanju večvrednostnih atributov [?]. Če je  $MDL < 0$ , potem je atribut nekompresiven in zatorej neuporaben [?].

## 2.3 Ocenjevanje učenja

Množico učnih primerov razdelimo na testno in učno množico. Učno množico uporabimo za učenje algoritma in naučen model preverimo na testni množici, kjer za ocenjevanje kvalitete modela uporabimo eno izmed mer. Če imamo na voljo malo podatkov, si ne moremo privoščiti, da bi postopek učenja prikrajšali za primere iz testne množice. Tudi v tem primeru želimo oceniti uspešnost zgrajenega modela, vendar tega ne smemo narediti na učni množici.

Metoda za ocenjevanje uspešnosti modela pri malo učnih primerih se imenuje “izloči enega” in jo lahko posplošimo na “izloči N/K primerov”, ki ji pravimo K-kratno prečno preverjanje.

### 2.3.1 Metoda izloči enega


Metoda izloči enega deluje tako, da na vsakem koraku izbere en testni primer, vsi ostali primeri pa so učni (učna množica). Na učni množici se izbrani algoritem strojnega učenja nauči napovednega modela, s testnim primerom pa oceni kvaliteto napovedi. Kvaliteto napovedi ocenimo npr. s klasifikacijsko točnostjo. Končna ocena kvalitete napovedi predstavlja klasifikacijsko točnost vseh primerov:

$$CA = \frac{\text{št. pravilno klasificiranih primerov}}{\text{št. vseh primerov}}$$

### 2.3.2 K-kratno prečno preverjanje

Metoda izloči enega je lahko časovno nesprejemljiva, saj moramo zgraditi  $N+1$  modelov ( $N$  je število učnih primerov), namesto enega samega ( $N$  modelov za ocenitev uspešnosti in en zaključni model iz vseh učnih primerov). Metodo izloči enega lahko posplošimo na izloči N/K primerov, ki ji pravimo tudi K-kratno prečno preverjanje (slika ??). Število  $K$  določa število modelov, ki jih zgradimo. Najprej množico razpoložljivih primerov razdelimo na  $K$  karseda enako močnih podmnožic. Za vsako podmnožico zgradimo model na uniji preostalih podmnožic in dobljeni model uporabimo za napovedovanje

primerov na dani podmnožici. Uspešnost končnega modela, ki ga zgradimo iz vseh razpoložljivih primerov, ocenimo kot povprečno uspešnost vseh  $K$  zgrajenih modelov na celotni množici testnih primerov [?].



Slika 2.1: Skica 10-kratnega prečnega preverjanja.

## 2.4 Okolja za strojno učenje

Za analizo naših podatkov smo uporabili dva programa namenjena obdelavi podatkov: statistični program R in program Orange.

### 2.4.1 Statistični program R

R (slika ??) je odprtokodno programsko okolje za statistično obdelavo. Je integrirana zbirka programske opreme za manipulacijo s podatki, računanje in grafični izris. Poleg drugih stvari vsebuje tudi orodja za:

- učinkovito obdelavo podatkov in njihovo skladiščenje,
- zbirko operatorjev za računanje s polji in matrikami,
- veliko zbirko orodij za analizo podatkov,
- grafične zmogljivosti za analizo podatkov in prikaz na računalniku ali papirju,
- dobro razvit, enostaven in učinkovit programski jezik (R izhaja iz jezika S), ki vključuje pogojnike, zanke, uporabniško določene rekurzivne funkcije ter vhodne in izhodne ukaze.



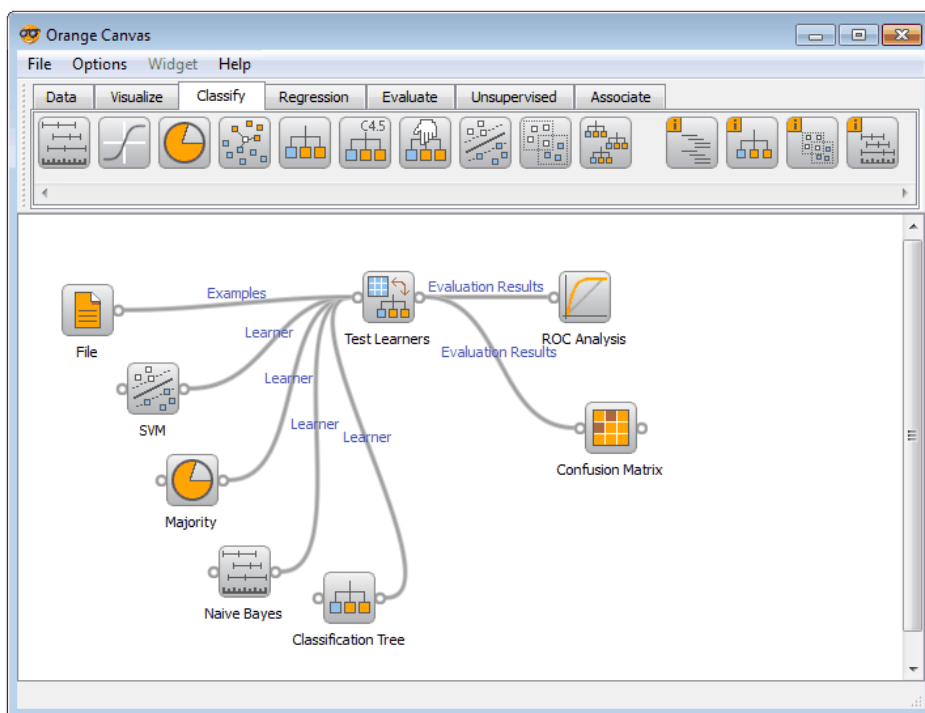
Slika 2.2: Logo programskega okolja R.

R je primerno okolje za razvoj metod interaktivne analize podatkov. Razvijalo se je zelo hitro in je razširjeno z obsežno zbirko paketov. Večina programov, napisanih v R, je kratkotrajnih, saj so napisani samo za del analize podatkov [?].

## 2.4.2 Orange

Sistem Orange so razvili v Laboratoriju za umetno inteligenco na Fakulteti za računalništvo in informatiko na Univerzi v Ljubljani.

Orange je knjižnica rutin in objektov, napisanih v jeziku C++, ki implementira standardne in manj standardne algoritme za strojno učenje in rudarjenje podatkov [?]. Prav tako je Orange skriptno okolje, v katerem lahko uporabljamo in snujemo nove algoritme. Skriptno okolje uporablja interpretirani jezik Python. Poleg knjižnice C++ in skriptnega okolja je Orange tudi skupek grafičnih gradnikov, ki jih lahko povezujemo v okolju Orange Canvas in služi kot grafični uporabniški vmesnik (slika ??).



Slika 2.3: Grafični uporabniški vmesnik Orange s shemo za klasifikacijo podatkov.



## Poglavje 3

# Opis problema in podatkov

V Univerzitetnem kliničnem centru Ljubljana že nekaj časa poskušajo na oddelkih uvesti sodelovanje kliničnih farmacevtov in tako bolje uporabiti njihovo znanje o zdravilih za izboljšanje kakovosti in varnosti obravnave bolnikov. Po podatkih iz tujine so napake pri zdravljenju z zdravili (neustrezno zdravilo, odmerek, medsebojne interakcije s predpisanimi zdravili, ...) med najpogostejšimi napakami v zdravstvu. Težave, povezane z zdravili, so tudi najpogostejši vzrok za ponovni sprejem v bolnišnico. Številne od teh zapletov se da preprečiti tako, da se v zdravstveni tim, ki obravnava bolnika na oddelku, vključuje klinične farmacevte (sodelovanje na vizitah, raportih, pregled predpisane terapije, nadzor nad pravilnostjo dajanja, analiza in interpretacija literaturnih podatkov o zdravilih, ...), ki imajo v primerjavi z zdravniki in medicinskimi sestrami veliko več specializiranih znanj o zdravilih. Na takšen način bi bolnišnica lahko prihranila mnogo stroškov dodatnega zdravljenja kot tudi stroškov za zdravila. Obravnava s kliničnim farmaceutom je za bolnika bolj prijazna, soodločanje pa lahko hkrati tudi razbremeni zdravnika.

Kljub vsem prednostnim uvajanje kliničnih farmacevtov ne poteka brez težav. Večina farmacevtov je bila na fakulteti izobrazena zelo tehnično in do zaključka študija ni imela še nobenih stikov s pacienti. Ti farmacevti potrebujejo dodatno izobraževanje oziroma specializacijo iz klinične farmacije,

preden jih lahko vključijo na oddelke skupaj z zdravniki. Poleg tega nekatere izkušnje kažejo, da farmacevti s strani zdravnikov včasih niso najboljše sprejeti. Nekateri zdravniki namreč menijo, da farmacevti na oddelku posegajo na področje dela zdravnika oz., da je sodelovanje farmacevta in njegov nadzor nad predpisovanjem zdravil nepotreben. Ugotavlja se, da naloge in pristojnosti kliničnega farmacevta na oddelku v preteklosti niso bile dovolj jasno opredeljene in usklajene z zdravniki in medicinskimi sestrami. Posledica tega je bila, da so klinični farmacevti imeli na oddelku pasivno vlogo in so čakali, da jih bodo zdravniki kaj vprašali, zdravniki pa so pričakovali proaktiven pristop in pomoči farmacevta niso znali izkoristiti. Izkušnja medsebojnega sodelovanja je bila tako slaba na obeh straneh.

Za klinični center bi bilo optimalno, če bi vsak oddelek imel vsaj enega kliničnega farmacevta, ki bi tako s svojim znanjem lahko pomagal zdravnikom in medicinskim sestram. Uvajanje kliničnih farmacevtov na oddelke UKC Ljubljana je zato eden izmed temeljnih ciljev vodstva kliničnega centra in lekarne UKC Ljubljana. Osnovni pristop uvajanja kliničnih farmacevtov na oddelke UKC Ljubljana je temeljil na ugotavljanju pričakovanj in potreb zdravnikov in medicinskih sester ter nato na podlagi tega proaktivno vključevanje kliničnega farmacevta na tistih področjih, na katerih si sodelovanja želijo vsi vpleteni. Da bi ugotovili potrebe in pričakovanja glede področij dela, ki naj bi jih na oddelku zagotavljal klinični farmacevt, je bil s strani vodstva lekarne oblikovan anketni vprašalnik za ugotavljanje pričakovanj in odnosa zdravnikov in medicinskih sester kot ključnih "uporabnikov" do storitev kliničnega farmacevta v zdravstvu. Ugotovitve raziskave bo vodstvo lekarne uporabilo tudi za izdelavo sistema kompetenc kliničnega farmacevta v UKC Ljubljana. Vprašanja v vprašalniku so razdeljena na tri vsebinske dele:

- vloga kliničnega farmacevta v sistemu bolnišnice,
- vloga kliničnega farmacevta ob pacientu in
- pomen kompetenc za uspešno delo kliničnega farmacevta v sistemu bolnišnice.

V prvih dveh vsebinskih delih je anketiranec izrazil svoje strinjanje ali ne-strinjanje s trditvijo z ocenami od 1 (sploh se ne strinjam) do 5 (zelo se strinjam), pri tretji pa je z ocenami od 1 (ni pomembna) do 5 (zelo je pomembna) opredelil, koliko je pomembna posamezna splošna oziroma specifična kompetenca za uspešno delo kliničnega farmacevta v sistemu bolnišnice. Rezultate anket smo dobili v obliki tabele, v kateri so bili naslednji podatki:

- poklic anketiranca (zdravnik, medicinska sestra ali farmacevt),
- področje dela oziroma oddelek anketiranca,
- starost in spol anketiranca,
- odgovor anketiranca na posamezno vprašanje,
- podatek, ali anketiranec že sodeluje s kliničnim farmacevtom,
- subjektivna ocena uspešnosti sodelovanja, ki jo je podala vodja lekarne UKC za tiste oddelke, ki že sodelujejo s kliničnimi farmacevti,
- predviden vpliv posamezne trditve na anketnem vprašalniku na uspešnost sodelovanja.

Te podatke smo ločili v dve tabeli, v eni so bili rezultati anketirancev, ki so že sodelovali s kliničnimi farmacevti, in ocena uspešnosti njihovega sodelovanja, v drugi pa rezultati zaposlenih na oddelkih, kjer še nimajo uvedenega kliničnega farmacevta. Preoblikovati smo jih morali tako, da so bili primerni za obdelavo v programskih okoljih R in Orange, kjer smo jih analizirali: vsebovali so lahko samo ordinalne attribute (odgovori na vprašanja ter ocena sodelovanja), saj metoda OrdEval, ki smo jo uporabili najprej, deluje samo na ordinalnih podatkih, ostali zaenkrat niso bili pomembni.

Analiza podatkov je opisana v naslednjem poglavju.



# Poglavje 4

## Poskusi

V tem poglavju najprej opišemo analizo z metodo OrdEval, nato pa še rezultate ocenjevanja atributov z algoritmoma ReliefF in MDL. Izdelamo napovedne modele z 10-kratnim prečnim preverjanjem in metodo izloči enega z naivnim Bayesovim klasifikatorjem, klasifikacijskim drevesom in naključnimi gozdovi ter komentiramo njihove rezultate.

### 4.1 Rezultati metode OrdEval

Kot podatkovno množico smo uporabili tabelo z odgovori na anketna vprašanja, ki so jih izpolnjevali zdravniki in medicinske sestre, ki so že sodelovali s kliničnimi farmacevti. Za vsakega od primerov smo dodali še oceno sodelovanja, ki jo je podala vodja lekarne UKC.


S pomočjo statističnega programa R in programske kode, ki je prikazana na sliki ??, smo na naših preurejenih podatkih pognali algoritem OrdEval in vizualizacijo rezultatov za vsak atribut posebej. Ocene atributov, ki jih vrne OrdEval, so prikazane na sliki ?. Opazimo, da vprašanja 14, 17, 26 in 38 izstopajo in da lahko s spremembo odgovora nanje vplivamo na oceno sodelovanja. Pri vseh teh vprašanjih to dosežemo, če odgovore znižamo, pri vprašanju 38 pa tudi, če odgovor povečamo. Vsebina vprašanj je zapisana v tabeli ??, distribucija vrednosti odgovorov na vprašanja pa v dodatku ??.

```
podatki<-read.table("\\Rsfar.tab",header=T)
for (i in 1:ncol(podatki))
podatki[,i] <- factor(podatki[,i], levels=c(1,2,3,4,5))
names(podatki)
require(CORElearn)
ocena<-ordEval(ocena ~ ., podatki,
               ordEvalNoRandomNormalizers=200)
plot(ocena, equalUpDown=T, ci="upper")
```


Slika 4.1: Primer uporabe algoritma OrdEval in njegove vizualizacije.

Ugotovili smo, da so tri anketna vprašanja izstopala po pomembnosti, če bi jim spremenili točno določene odgovore. Vprašanje 17 (tabela ??), ki je prikazano na sliki ??, bi oceno sodelovanja lahko zvišalo, če bi se odgovor nanj povečal s števila 4 na število 5. Ocena sodelovanja bi se prav tako zvišala pri vprašanju 21 (tabela ??), če bi odgovor s števila 3 povečali na število 4.

Odgovor na vprašanje 19 (tabela ??) pa bi na oceno sodelovanja za razliko od preostalih dveh vplival negativno. Ocena bi se lahko znižala, če bi odgovor s števila 2 znižali na število 1.



Slika 4.2: Ocene vseh atributov, ki jih vrne OrdEval.



Slika 4.3: Vizualizacija rezultata algoritma OrdEval za vprašanje 17.

---

Vprašanje 14	Klinični farmacevt razvija in predlaga sisteme za izboljšanje varnosti pri pripravi za aplikacijo in pri aplikaciji zdravil.
Vprašanje 17	Klinični farmacevt svetuje medicinski sestri pri zagotavljanju in spremljanju pogojev shranjevanja zdravil.
Vprašanje 26	Klinični farmacevt svetuje medicinski sestri in zdravniku glede medsebojne kompatibilnosti, stabilnosti in shranjevanja zdravil za parenteralno aplikacijo.
Vprašanje 38	Pomembnost pridobivanja informacij o zdravilih (tudi o cenah), o farmacevtskih ekvivalentih, farmacevtskih alternativah in bioekvivalentnih zdravilih.

---

Tabela 4.1: Vsebina vprašanj z absolutno največjim vplivom na oceno sodelovanja.

---

Vprašanje 17	Klinični farmacevt svetuje medicinski sestri pri zagotavljanju in spremljanju pogojev shranjevanja zdravil.
Vprašanje 19	Klinični farmacevt ob sprejemu pacienta v bolnišnico pripravi zgodovino terapije pacienta s seznamom zdravil, ki jih jemlje.
Vprašanje 21	Klinični farmacevt analizira terapijo pacientov (npr. tistih z velikim številom zdravil), v razgovoru s pacientom in drugim medicinskim osebjem odkriva z zdravili povezane probleme in po potrebi predlaga zdravniku spremembe.

---

Tabela 4.2: Vsebina vprašanj 17, 19 in 21.

## 4.2 Rezultati ocenjevanja atributov

Vodja lekarne je ob rezultatih ankete podala tudi svoje subjektivne ocene o pomembnosti posameznih vprašanj na celotno oceno sodelovanja. Te ocene smo primerjali z ocenami, ki smo jih pridobili z ocenjevanjem atributov s pomočjo statističnega programa R z merama za ocenjevanje ReliefF in MDL.

S programsko kodo s slike ?? smo s pomočjo funkcije attrEval iz paketa CORElearn ocenjevali attribute na rezultatih ankete o sodelovanju zdravnikov ter medicinskih sester in kliničnih farmacevtov.

```
aeR<-attrEval(ocena ~ ., podatki, estimator="ReliefFexpRank")
aeM<-attrEval(ocena ~ ., podatki, estimator="MDL")
```


Slika 4.4: Programska koda v programu R za ocenjevanje atributov z algoritmoma ReliefF in MDL.

### 4.2.1 Ocenjevanje atributov z algoritmom ReliefF

Metoda attrEval z mero za ocenjevanje atributov ReliefF vrne ocene za vsa vprašanja v intervalu od -0.097 do 0.267. Subjektivne ocene so celoštevilске od 1 do 5, zato smo morali rezultate preoblikovati v primerljivo obliko. Celoten interval smo razdelili na pet podintervalov in številske vrednosti uvrstili v ustrezne podintervale, da so tudi ocene atributov obsegale vrednosti od 1 do 5 (slika 4.5) in imele enako distribucijo odgovorov kot subjektivne ocene vodje lekarne.

Pet najpomembnejših vprašanj glede na ReliefF je predstavljenih v tabeli ??.

Pri primerjavi ocen atributov algoritma ReliefF z ocenami vodje lekarne smo opazili, da se v veliki večini ocene ujemajo. Za pomembno odstopanje smo šteli ocene, ki se razlikujejo za več kot dve vrednosti. Do razlike je od trinpetdesetih vprašanj prišlo le pri tistih, ki so prikazana v tabeli ??. Vsebina vprašanj je predstavljena v anketnem vprašalniku v dodatku ??.



Slika 4.5: Porazdelitev rezultatov ReliefF na pet podintervalov, da dobimo enako distribucijo odgovorov.

Vprašanje	ReliefF	Vsebina vprašanj
Vprašanje 46	0.266	Pomembnost vrednotenja kliničnih izidov farmakoterapije.
Vprašanje 47	0.193	Pomembnost vrednotenja humanističnih izidov farmakoterapije.
Vprašanje 30	0.166	Klinični farmacevt izvaja terapevtsko spremljanje plazemskih koncentracij zdravil in predlaga zdravniku optimizacijo odmerjanja.
Vprašanje 28	0.164	Klinični farmacevt sodeluje v procesu farmakovigilance in vigilance medicinskih pripomočkov.
Vprašanje 32	0.143	Klinični farmacevt sodeluje v kliničnih študijah zdravil in ocenjuje rezultate z vidika stroškovne učinkovitosti.

Tabela 4.3: Pet najpomembnejših atributov za algoritem ReliefF.


Vprašanje	ReliefF	Normirani ReliefF	Vodja lekarne
Vprašanje 6	0.098	4	1
Vprašanje 8	0.068	4	1
Vprašanje 19	-0.021	1	5
Vprašanje 20	-0.053	1	4
Vprašanje 22	-0.004	1	5
Vprašanje 36	0.016	2	5
Vprašanje 37	-0.058	1	5
Vprašanje 40	-0.042	1	4
Vprašanje 41	-0.042	1	5
Vprašanje 42	-0.097	1	5
Vprašanje 43	0.017	2	5
Vprašanje 44	-0.052	1	5
Vprašanje 45	-0.009	1	5
Vprašanje 48	0.019	2	5

Tabela 4.4: Razlike v rezultatih ocenjevanja atributov z algoritmom ReliefF in subjektivne ocene vodje lekarne.

Vidimo, da je vodja lekarne dve pomembni vprašanji določila za ReliefF nepomembni, medtem ko je več za ReliefF nepomembnih vprašanj določila za pomembna. Tak rezultat je zanimiv in kaže določeno previdnost vodje lekarne, ki ni izpuščala pomembnih vprašanj, ampak je celo več informacijsko gledano manj pomembnim vprašanjem pripisala velik pomen.

### 4.2.2 Ocenjevanje atributov z algoritmom MDL

V statističnem programu R smo izvedli še ocenjevanje atributov z algoritmom MDL in nato ocene predelali na enak način kot smo jih pri algoritmu ReliefF. Ocene so predstavljala števila na intervalu od -0.248 do 0.255 (slika ??).



Slika 4.6: Porazdelitev rezultatov MDL na pet podintervalov, da dobimo enako distribucijo odgovorov.

Pet najbolje ocenjenih vprašanj je z vrednostmi in ocenami prikazanih v tabeli ??. Tri vprašanja so enaka kot pri ocenjevanju z algoritmom ReliefF, preostali dve pa se razlikujeta. Vsebina vprašanj je predstavljena v anketnem vprašalniku v dodatku ??.

V tabeli ?? lahko vidimo, kje je prišlo do razlik med subjektivnim ocenjevanjem pomembnosti vprašanj in ocenjevanjem z algoritmom MDL. Manjšo pomembnost je subjektivna ocena dodelila enemu vprašanju, več pa jih je bilo ocenjeno višje.

Vprašanje	MDL	Vsebina vprašanj
Vprašanje 46	0.255	Pomembnost vrednotenja kliničnih izidov farmakoterapije.
Vprašanje 47	0.131	Pomembnost vrednotenja humanističnih izidov farmakoterapije.
Vprašanje 35	0.125	Klinični farmacevt lahko brez posveta z zdravnikom zamenjuje medsebojno zamenljiva zdravila, če je to potrebno zaradi težav z dosegljivostjo ali previsoko ceno predpisanega zdravila.
Vprašanje 23	0.060	Klinični farmacevt svetuje medicinski sestri pri pripravi zdravil za aplikacijo.
Vprašanje 32	0.053	Klinični farmacevt sodeluje v kliničnih študijah zdravil in ocenjuje rezultate z vidika stroškovne učinkovitosti.

Tabela 4.5: Pet najpomembnejših atributov za algoritem MDL.

Vprašanje	MDL	Normirani MDL	Vodja lekarne
Vprašanje 38	0.036	4	1
Vprašanje 9	-0.054	1	4
Vprašanje 11	-0.080	1	4
Vprašanje 12	-0.084	1	4
Vprašanje 13	0.008	2	5
Vprašanje 14	0.007	2	5
Vprašanje 19	-0.060	1	5
Vprašanje 20	-0.137	1	4
Vprašanje 21	-0.037	1	5
Vprašanje 22	-0.055	1	5
Vprašanje 26	-0.009	1	5
Vprašanje 27	-0.070	1	5
Vprašanje 29	-0.101	1	5
Vprašanje 31	-0.061	1	5
Vprašanje 34	-0.101	1	5
Vprašanje 36	-0.047	1	5
Vprašanje 37	-0.151	1	5
Vprašanje 40	-0.115	1	4
Vprašanje 41	-0.086	1	5
Vprašanje 42	-0.248	1	5
Vprašanje 43	-0.100	1	5
Vprašanje 44	-0.107	1	5
Vprašanje 45	-0.163	1	5
Vprašanje 48	-0.115	1	5
Vprašanje 52	-0.040	1	4

Tabela 4.6: Razlike v rezultatih ocenjevanja atributov z algoritmom MDL in subjektivnih ocen vodje lekarne.

## 4.3 Napovedni modeli

S pomočjo programa Orange smo sestavili diagnostični model za napovedovanje skupne ocene sodelovanja med zdravniki in medicinskimi sestrami ter kliničnimi farmacevti. Poskusili smo z različnimi klasifikatorji, kot so naivni Bayes, klasifikacijsko drevo in naključni gozdovi. Izračunali smo klasifikacijsko točnost, ki predstavlja razmerje med pravilno klasificiranimi primeri in vsemi primeri.

Pri izdelavi napovednih modelov smo uporabili vse podatke, ki smo jih imeli na voljo, ne samo ordinalnih, zato smo jim dodali še poklic (zdravnik ali medicinska sestra), starost in spol.

### 4.3.1 10-kratno prečno preverjanje

Napovedovanje z 10-kratnim prečnim preverjanjem smo izvedli v okolju Orange Canvas. Klasifikacijske točnosti, ki smo jih pri tem dobili, so naslednje:

- naivni Bayes: 0.567,
- klasifikacijsko drevo: 0.550,
- naključni gozdovi: 0.500.

Iz rezultatov je razvidno, da nam najboljšo napoved pri 10-kratnem prečnem preverjanju poda naivni Bayes. 56.7% klasifikacijska točnost je dobra, saj je boljša od apriorne verjetnosti najpogostejšega odgovora 5, ki je 40.9%. V našem primeru štejemo za napako napovedi oceni napovedane uspešnosti različne za eno oceno več ali manj, zato smo klasifikacijsko točnost priredili temu kriteriju.

Slika ?? prikazuje matriko napak, ki jih je naredil naivni Bayesov klasifikator. Na navpični osi so ocene iz podanega razreda, na vodoravni osi pa so napovedane ocene. Klasifikator je pravilno napovedal 20% ocen 2, 66.7% ocen 3, 40% ocen 4 in 77.8% ocen 5. Pravilni oceni 2 je v 40% primerih dodelil oceno 4 in v 40% primerih oceno 5, kar štejemo za največji napaki.

Pravilni oceni 3 je v tretjini primerov dodelil oceno 5. Eni štirici od petih (20%) je napačno dodelil oceno 2, eni 3 in eni 5. Pravilni oceni 5 je v 22.2% dodelil oceno 3.

		Napovedana ocena				
		<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	
Prava ocena	<b>2</b>	1 (20.0 %)	0 (0.0 %)	2 (40.0 %)	2 (40.0 %)	<b>5</b>
	<b>3</b>	0 (0.0 %)	2 (66.7 %)	0 (0.0 %)	1 (33.3 %)	<b>3</b>
	<b>4</b>	1 (20.0 %)	1 (20.0 %)	2 (40.0 %)	1 (20.0 %)	<b>5</b>
	<b>5</b>	0 (0.0 %)	2 (22.2 %)	0 (0.0 %)	7 (77.8 %)	<b>9</b>
		<b>2</b>	<b>5</b>	<b>4</b>	<b>11</b>	<b>22</b>

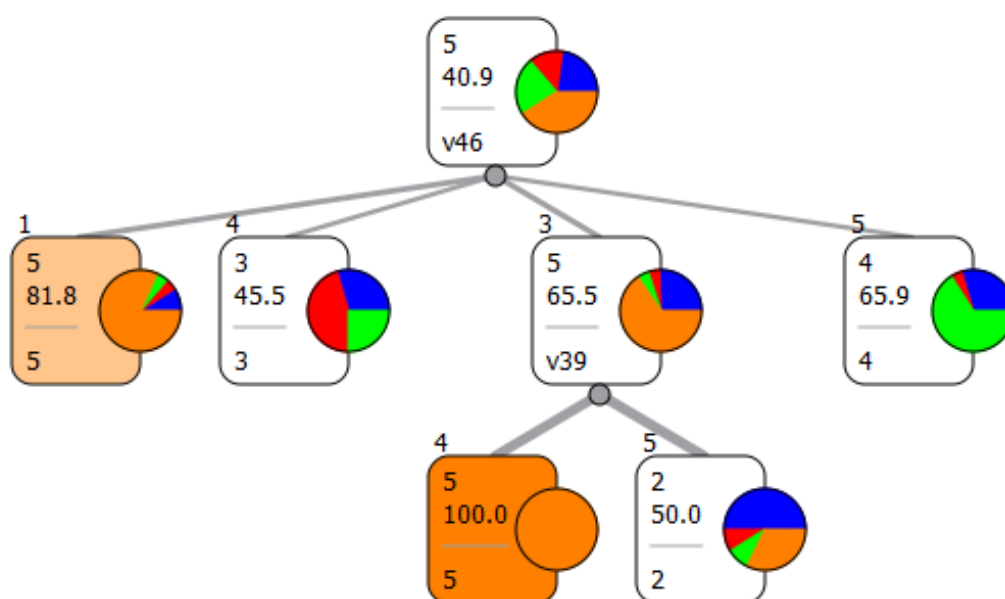
Slika 4.7: Matrika napak naivnega Bayesovega klasifikatorja pri 10-kratnem prečnem preverjanju.

Na sliki ?? je prikazana matrika napak klasifikacijskega drevesa. Največjo napako je naredil pri oceni 2, ki jih je napačno klasificiral 60% (tri primere od petih). Pravilno je napovedal vse ocene 5. Graf klasifikacijskega drevesa je prikazan na sliki ??.

		Napovedana ocena				
		<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	
Prava ocena	<b>2</b>	1 (20.0 %)	1 (20.0 %)	0 (0.0 %)	3 (60.0 %)	<b>5</b>
	<b>3</b>	2 (66.7 %)	0 (0.0 %)	0 (0.0 %)	1 (33.3 %)	<b>3</b>
	<b>4</b>	0 (0.0 %)	1 (20.0 %)	2 (40.0 %)	2 (40.0 %)	<b>5</b>
	<b>5</b>	0 (0.0 %)	0 (0.0 %)	0 (0.0 %)	9 (100.0 %)	<b>9</b>
		<b>3</b>	<b>2</b>	<b>2</b>	<b>15</b>	<b>22</b>

Slika 4.8: Matrika napak klasifikacijskega drevesa pri 10-kratnem prečnem preverjanju.

Na sliki klasifikacijskega drevesa vidimo, da na začetku večina odgovorov na vprašanja predstavlja število 5 s 40.9% verjetnostjo. Če je anketiranec vprašanju 46 dodelil oceno pomembnosti število 3 in vprašanju 39 oceno pomembnosti število 4, je bila ocena sodelovanja 5.



Slika 4.9: Graf klasifikacijskega drevesa za napoved ocene sodelovanja 5 pri 10-kratnem prečnem preverjanju.

Če je napovedni model z naivnim Bayesovim klasifikatorjem naredil sprejemljivo napako tako, da je oceno uspešnosti sodelovanja zgrešil za ena, lahko rečemo, da se je hudo zmotil pri  $\frac{8}{22}$  (36.4%) primerov oziroma jih pravilno napovedal 63.6%. Napovedni model s klasifikacijskim drevesom pa se je hudo zmotil pri  $\frac{4}{22}$  (18.2%) primerov oziroma jih pravilno napovedal kar 81.8%.

Za napovedovanje ocen sodelovanja z enakimi anketnimi vprašalniki bi zato priporočali model s klasifikacijskim drevesom.

### 4.3.2 Metoda izloči enega

Na podatkih smo izvedli še metodo izloči enega, klasifikacijske točnosti, ki smo jih dobili, so:

- naivni Bayes: 0.546,
- klasifikacijsko drevo: 0.546,
- naključni gozdovi: 0.455.

Najboljšo napoved dobimo z naivnim Bayesovim klasifikatorjem in klasifikacijskim drevesom. Ali je napoved dobra ali slaba, lahko razberemo iz matrike napak (slika ??). Napovedni model je pravilno napovedal 40% ocen 2, nobene ocene 3, 60% ocen 4 in 77.8% ocen 5. 40% ocen 2 je napovedal oceno 4 in 20% oceno 5. Eni tretjini ocen 3 je napovedal oceno 2, eni tretjini 4 in eni tretjini 5. Ocen 5 je v 11.1% primerov napovedal ocen 2 in v 11.1% primerov oceno 4.


		Napovedana ocena				
		2	3	4	5	
Prava ocena	2	2 (40.0 %)	0 (0.0 %)	2 (40.0 %)	1 (20.0 %)	<b>5</b>
	3	1 (33.3 %)	0 (0.0 %)	1 (33.3 %)	1 (33.3 %)	<b>3</b>
	4	1 (20.0 %)	0 (0.0 %)	3 (60.0 %)	1 (20.0 %)	<b>5</b>
	5	1 (11.1 %)	0 (0.0 %)	1 (11.1 %)	7 (77.8 %)	<b>9</b>
		<b>5</b>	<b>0</b>	<b>7</b>	<b>10</b>	<b>22</b>


Slika 4.10: Matrika napak naivnega Bayesovega klasifikatorja pri metodi izloči enega.

Pri upoštevanju sprejemljive napake za eno oceno, smo izračunali novo klasifikacijsko točnost za naivni Bayesov klasifikator. Ta je znašala  $\frac{16}{22}$  oziroma 72.7%. Ker je precej višja kot pri napovednem modelu z 10-kratnim prečnim preverjanjem, nas je v tem primeru zanimalo tudi, katere vrednost atributa bi

bile pri napovedi ocene sodelovanja 5 najbolj optimalne. Z uporabo naivnega Bayesovega klasifikatorja smo narisali nomogram, ki nam je to prikazal (slika ??).

Navpična črta na sredini predstavlja vrednost 0. Če izberemo vrednosti, ki so na desni strani te črte, le-te prispevajo pozitivne točke k skupni vsoti, vrednosti na levi strani pa negativne. Točke lahko preberemo iz zgornje osi na nomogramu. Bolj kot je vprašanje pomembno, bolj desno ima premaknjeno oceno pomembnosti. Najpomembnejši sta vprašanji 46 in 47, kar se sklada z našimi ugotovitvami pri ocenjevanju atributov. Sledijo jima vprašanja 13, 28, 31, 32 in 35. Vsebina vprašanj je predstavljena v dodatku ???. Pod nomogramom sta narisani še dve osi, prva prikazuje vsoto vseh točk, če poznamo napovedi atributov, iz spodnje osi pa razberemo verjetnost, da bo ocena sodelovanja enaka 5.





Slika 4.11: Nomogram naivnega Bayesovega klasifikatorja za vse attribute.

Matrika napak klasifikacijskega drevesa pri metodi izloči enega se razlikuje od matrike napak pri 10-kratnem prečnem preverjanju (slika ??). Nepravilno je napovedal vse primere ocen 2 in 3, pravilno pa je napovedal 60% ocen 4 in vse primere ocen 5. Največjo napako je naredil pri napovedi ocene 2, ki ji v 20% napove oceno 4 in v 60% primerih oceno 5.

		Napovedana ocena				
		<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	
Prava ocena	<b>2</b>	0 (0.0%)	1 (20.0%)	1 (20.0%)	3 (60.0%)	<b>5</b>
	<b>3</b>	2 (66.7%)	0 (0.0%)	0 (0.0%)	1 (33.3%)	<b>3</b>
	<b>4</b>	0 (0.0%)	1 (20.0%)	3 (60.0%)	1 (20.0%)	<b>5</b>
	<b>5</b>	0 (0.0%)	0 (0.0%)	0 (0.0%)	9 (100.0%)	<b>9</b>
		<b>2</b>	<b>2</b>	<b>4</b>	<b>14</b>	<b>22</b>

Slika 4.12: Matrika napak klasifikacijskega drevesa pri metodi izloči enega.

Za naš primer uporabe smo zanemarili vse napake, ki so oceno spremenile za eno oceno in jih določili za pravilne. Tako ima napovedni model klasifikacijskega drevesa klasifikacijsko točnost  $\frac{17}{22}$  oziroma 77.3%. Prirejena klasifikacijska točnost naivnega Bayesovega klasifikatorja in klasifikacijskega drevesa je dovolj dobra, zato ju lahko priporočamo za napovedovanje ocen sodelovanja na podlagi anketnih vprašalnikov v prihodnosti.



# Poglavje 5

## Zaključek

V diplomskem delu je opisana analiza anketnih vprašalnikov, ki so jih izpolnili zdravniki, medicinske sestre in farmacevti na UKC glede sodelovanja med njimi.

Najprej smo podatke obdelali v statističnem programu R z metodo OrdEval, ki je nakazala, ali bo povečanje ali zmanjšanje vrednosti posamezne lastnosti vplivalo na skupno oceno sodelovanja. Ugotovili smo, da so štiri anketna vprašanja (14, 17, 26 in 38) značilno izstopala po pomembnosti, kar pomeni, da bi se ocena sodelovanja spremenila, če bi se spremenil odgovor nanje. Tri vprašanja bi oceno sodelovanja spremenila pri točno določeni spremembi. Pri vprašanjih 17 in 21 bi se ocena sodelovanja zvišala, če bi se njun odgovor povečal s 4 na 5 oziroma s 3 na 4, pri vprašanju 19 pa bi se znižala, če bi se odgovor znižal z 2 na 1. Vsebina vprašanj je predstavljena v dodatku ??.

S pomočjo funkcije attrEval smo izvedli ocenjevanje atributov z algoritmoma ReliefF in MDL. Z obema smo ugotovili, da sta najpomembnejši vprašanja na anketnem vprašalniku vprašanja 46 in 47. Primerjava rezultatov z ocenami vodje lekarne je pokazala, da je bila vodja lekarne pri ocenjevanju atributov previdna, saj ni izpuščala pomembnih vprašanj, ampak je celo več informacijsko gledano manj pomembnim pripisala velik pomen.

S pomočjo programa Orange smo sestavili prognostični model za napo-

vedovanje skupne ocene sodelovanja med zdravniki in medicinskimi sestrami ter kliničnimi farmacevti na podlagi ocen dosedanjega sodelovanja, ki jih je določila vodja lekarne UKC. Tako z 10-kratnim prečnim preverjanjem kot z metodo izloči enega smo ugotovili, da najboljši napovedni model dobimo s klasifikacijskim drevesom. Ko smo upoštevali za še sprejemljivo napako odstopanje za eno oceno, je njegova klasifikacijska točnost znašala 81.8% pri 10-kratnem prečnem preverjanju in 77.3% pri metodi izloči enega, kar je po našem mnenju dovolj dobro in bi ga priporočali za nadaljnje napovedovanje uspešnosti sodelovanja.

Na tabeli z anketnimi odgovori zdravnikov in farmacevtov, ki še niso sodelovali s kliničnim farmacevtom, smo uporabili izdelan napovedni model in tako napovedali predvideno uspešnost sodelovanja med njimi. Tabela z dobljenimi ocenami je predstavljena v dodatku ???. Vodji lekarne bi tako svetovali, da farmacevte najprej uvede na center za zastrupitve, oddelek za abdominalno kirurgijo in oddelek za urologijo ter premisli o njihovi uvedbi na center za vojne veterane, nevrološko in ginekološko kliniko, oddelek za torakalno kirurgijo, oddelek za travmatologijo in kliniko za otolaringologijo in cervikofacialno kirurgijo.

Celotno delo bi lahko označili za uspešno glede na želje vodje lekarne, ki bo z dobljenimi rezultati lažje nadaljevala vpeljavo kliničnih farmacevtov na oddelke UKC. Vendar bi se dalo marsikaj izboljšati, tako na anketnih vprašalnikih, kot pri izdelavi napovednih modelov. Slabost raziskave je majhen vzorec podatkov, vprašalniki vsebujejo tudi več manjkajočih vrednosti. Priporočljivo bi bilo, da anketiranci odgovorijo na vsa vprašanja, saj bi s tem pridobili več informacij za napovedovanje. Velika pomankljivost pri dobljenih podatkih je tudi dejstvo, da je na določenih oddelkih vprašalnik izpolnil le en zaposleni. Mnenje le enega težko prikaže dejansko stanje na celotnem oddelku in predstavlja premajhen vzorec, da bi lahko zanesljivo svetovali vodji lekarne.

Pri oceni uspešnosti sodelovanja bi bilo potrebno upoštevati tudi mnenje farmacevtov. Predlagamo izdelavo napovednega modela tudi na podatkih z

anketnih vprašalnikov farmacevtov, ki so že sodelovali z zdravniki. Rezultate obeh modelov bi združili in tako dobili potencialno bolj zanesljive odgovore.



# Dodatek A

## Anketni vprašalnik za zdravnike in medicinske sestre

Anketni vprašalnik za ugotavljanje pričakovanj in odnosa zdravnikov kot ključnih “uporabnikov”, do storitev kliničnega farmacevta v zdravstvu z namenom izdelave sistema kompetenc kliničnega farmacevta v UKC Ljubljana.

### 1. Vaši podatki:

#### 1.1. Področje dela:

##### 1.1.1. Interna klinika

1.1.1.1. Klinični oddelek za endokrinologijo, diabetes in bolezni presnove

1.1.1.2. Klinični oddelek za gastroenterologijo

1.1.1.3. Klinični oddelek za kardiologijo

1.1.1.4. Klinični oddelek za hematologijo

1.1.1.5. Klinični oddelek za hipertenzijo

1.1.1.6. Klinični oddelek za intenzivno interno medicino

1.1.1.7. Klinični oddelek za nefrologijo

1.1.1.8. Klinični oddelek za pljučne bolezni in alergije

1.1.1.9. Klinični oddelek za revmatologijo

1.1.1.10. Klinični oddelek za žilne bolezni

- 1.1.1.11. Center za vojne veterane
- 1.1.1.12. Center za zastрупitve
- 1.1.1.13. Internistična prva pomoč
- 1.1.2. Kirurška klinika
  - 1.1.2.1. Klinični oddelek za abdominalno kirurgijo
  - 1.1.2.2. Klinični oddelek za torakalno kirurgijo
  - 1.1.2.3. Klinični oddelek za otroško kirurgijo in intenzivno terapijo
  - 1.1.2.4. Klinični oddelek za travmatologijo
  - 1.1.2.5. Klinični oddelek za plastično, rekonstrukcijsko, estetsko kirurgijo in opeklino
  - 1.1.2.6. Klinični oddelek za anesteziologijo in intenzivno terapijo operativnih strok
  - 1.1.2.7. Klinični oddelek za maksilofacialno in oralno kirurgijo
  - 1.1.2.8. Klinični oddelek za urologijo
  - 1.1.2.9. Klinični oddelek za nevrokirurgijo
  - 1.1.2.10. Klinični oddelek za kirurške okužbe
  - 1.1.2.11. Klinični oddelek za kirurgijo srca in ožilja
  - 1.1.2.12. Urgentni kirurški blok
  - 1.1.2.13. Operacijski blok
- 1.1.3. Nevrološka klinika
- 1.1.4. Ginekološka klinika
- 1.1.5. Pediatrična klinika
- 1.1.6. Nepovezane samostojne klinike in klinični inštituti
- 1.1.7. Dermatovenerološka klinika
- 1.1.8. Klinika za infekcijske bolezni in vročinska stanja
- 1.1.9. Očesna klinika
- 1.1.10. Klinični inštitut za radiologijo
- 1.1.11. Klinika za otorinolaringologijo in cervikofacialno kirurgijo
- 1.1.12. Ortopedska klinika
- 1.1.13. Klinika za nuklearno medicino

## 1.2. starost:

1.2.1. 20 – 29

1.2.2. 30 – 39

1.2.3. 40 – 49

1.2.4. 50 – 59

1.2.5. 60 - 69

## 1.3. spol:

1.3.1: Ž

1.3.2: M

Prosimo vas, da pri naslednjih trditvah izrazite svoje strinjanje oz. nestrinjanje z ocenami od 1 (sploh se ne strinjam) do 5 (zelo se strinjam).

**Vloga kliničnega farmacevta v sistemu bolnišnice.**

2. Klinični farmacevt informira zdravnike o medsebojno zamenljivih zdravilih in možnih zamenjavah.

3. Klinični farmacevt informira medicinske sestre o medsebojno zamenljivih zdravilih in možnih zamenjavah.

4. Klinični farmacevt z zdravnikom uskladi zamenjavo medsebojno zamenljivih zdravil na oddelkih glede na njihovo razpoložljivost (glede na izbiro na javnem razpisu, morebitne donacije itd.).

5. Klinični farmacevt informira zdravnike o razpoložljivih (katera zdravila in koliko jih je na razpolago) doniranih zdravilih.

6. Klinični farmacevt informira medicinske sestre o razpoložljivih (katera zdravila in koliko jih je na razpolago) doniranih zdravilih.

7. Klinični farmacevt informira zdravnike o razpoložljivosti (katera zdravila in če oz. v kolikšnem času so dosegljiva) neregistriranih zdravil.
8. Klinični farmacevt informira medicinske sestre o razpoložljivosti (katera zdravila in če oz. v kolikšnem času so dosegljiva) neregistriranih zdravil.
9. Klinični farmacevt išče informacije o zdravilih in jih posreduje zdravnikom in medicinskim sestram na različnih oblikah internega strokovnega izpopolnjevanja.
10. Klinični farmacevt zbira in kritično vrednoti literaturne podatke o zdravilih ter svoje ugotovitve posreduje zdravnikom.
11. Klinični farmacevt sodeluje pri oblikovanju »bolnišnične liste zdravil«.
12. Klinični farmacevt zbira in vrednoti podatke o zdravljenju z zdravili ter razvija in predlaga rešitve za zniževanje stroškov zdravljenja.
13. Klinični farmacevt sodeluje pri oblikovanju farmakoterapevtskih smernic.
14. Klinični farmacevt razvija in predlaga sisteme za izboljšanje varnosti pri pripravi za aplikacijo in pri aplikaciji zdravil.
15. Klinični farmacevt išče in zbira podatke o medicinskih pripomočkih ter jih posreduje zdravnikom in medicinskim sestram.
16. Klinični farmacevt zbira in vrednoti podatke o uporabi medicinskih pripomočkov in predlaga rešitve za zniževanje stroškov pri uporabi medicinskih pripomočkov.

17. Klinični farmacevt svetuje medicinski sestri pri zagotavljanju in spremljanju pogojev shranjevanja zdravil.

18. Klinični farmacevt sodeluje z medicinsko sestro pri obvladovanju zalog zdravil na oddelkih.

### **Vloga kliničnega farmacevta ob pacientu.**

19. Klinični farmacevt ob sprejemu pacienta v bolnišnico pripravi zgodovino terapije pacienta s seznamom zdravil, ki jih jemlje.

20. Klinični farmacevt sodeluje na vizitah na oddelkih.

21. Klinični farmacevt analizira terapijo pacientov (npr. tistih z velikim številom zdravil), v razgovoru s pacientom in drugim medicinskim osebjem odkriva z zdravili povezane probleme in po potrebi predlaga zdravniku spremembe.

22. Klinični farmacevt je na razpolago zdravniku za konzultacije o terapiji z zdravili.

23. Klinični farmacevt svetuje medicinski sestri pri pripravi zdravil za aplikacijo.

24. Klinični farmacevt na oddelku pripravlja zdravila za aplikacijo.

25. Klinični farmacevt svetuje medicinski sestri glede dajanja zdravil glede na obroke hrane, dajanja zdravil po sondi, parenteralne aplikacije zdravil, ...

26. Klinični farmacevt svetuje medicinski sestri in zdravniku glede medsebojne kompatibilnosti, stabilnosti in shranjevanja zdravil za parenteralno

aplikacijo.

27. Klinični farmacevt svetuje pri izbiri ustreznega pripravka za enteralno in parenteralno prehrano glede na bolnikovo stanje, preveri kompatibilnost dodatkov (elektrolitov, vitaminov, mikroelementov) k parenteralni prehrani.

28. Klinični farmacevt sodeluje v procesu farmakovigilance in vigilance medicinskih pripomočkov.

29. Klinični farmacevt študira farmakokinetiko zdravil in svetuje zdravniku pri optimizaciji terapije.

30. Klinični farmacevt izvaja terapevtsko spremljanje plazemskih koncentracij zdravil in predlaga zdravniku optimizacijo odmerjanja.

31. Klinični farmacevt pripravlja in izdaja zdravila za pacienta ob odpustu iz bolnišnice, svetuje pacientu ob izdaji in sodeluje s farmacevtom v javni lekarni za brezšiven prehod pacienta v domačo oskrbo.

32. Klinični farmacevt sodeluje v kliničnih študijah zdravil in ocenjuje rezultate z vidika stroškovne učinkovitosti.

33. Klinični farmacevt ima vpogled v pacientovo zdravstveno dokumentacijo.

34. Klinični farmacevt išče možnosti za zmanjšanje stroškov zdravljenja posameznega pacienta in jih predlaga zdravniku.

35. Klinični farmacevt lahko (ima pooblastilo, da) brez posveta z zdravnikom zamenjuje medsebojno zamenljiva zdravila, če je to potrebno zaradi težav z dosegljivostjo ali previsoko ceno predpisanega zdravila.

36. Klinični farmacevt lahko (ima pooblastilo, da) brez posveta z zdravnikom zamenja predpisano zdravilo z ustreznim farmacevtskim ekvivalentom, četudi ta nima dokazane bioekvivalence, vendar mora zdravnika o tem obvestiti takoj, ko je to mogoče.

37. Klinični farmacevt lahko (ima pooblastilo, da) brez posveta z zdravnikom zamenja predpisano zdravilo z ustrežno farmacevtsko alternativo, četudi ta nima dokazane bioekvivalence, vendar mora zdravnika o tem obvestiti takoj, ko je to mogoče.

Prosimo vas, da pri naslednjih trditvah opredelite, kako je po vašem mnenju pomembna splošna oz. specifična kompetenca za uspešno delo kliničnega farmacevta v sistemu bolnišnice, to opredelite z ocenami od 1 (ni pomembna) do 5 (zelo je pomembna).

**Pomen kompetence za uspešno delo kliničnega farmacevta v sistemu bolnišnice.**

38. Pridobivanje informacij o zdravilih (tudi o cenah), o farmacevtskih ekvivalentih, farmacevtskih alternativah in bioekvivalentnih zdravilih.

39. Iskanje strokovnih informacij o zdravilih v literaturi z uporabo različnih tehnologij in virov

40. Kritično vrednotenje literaturnih podatkov o zdravilih.

41. Medsebojna primerjava zdravil po farmakoloških skupinah, terapevtsko-farmakoloških podskupinah kemičnih podskupinah glede na farmakodinamske in farmakokinetične parametre.

42. Vrednotenje biokemičnih laboratorijskih izvidov pacienta z vidika vpliva teh parametrov na farmakokinetiko in farmakodinamiko zdravil, ki jih jemlje (dobiva).
43. Vrednotenje vpliva posebnih življenjskih stanj (otročstvo, starost, nosečnost, dojenje, ...) na delovanje zdravil.
44. Prepoznavanje z zdravili povezanih problemov (neželeni učinki, interakcije, primernost odmerka, primernost farmacevtske oblike, način dajanja, komplanca, izbira zdravila, potreba po zdravilu, ...).
45. Terapevtsko spremljanje plazemskih koncentracij učinkovin in optimizacijo odmerjanja na osnovi zbranih podatkov.
46. Vrednotenje kliničnih izidov farmakoterapije.
47. Vrednotenje humanističnih izidov farmakoterapije.
48. Vrednotenje ekonomskih izidov farmakoterapije.
49. Komunikacija s pacientom (pristop k pacientu, empatija, neverbalna komunikacija, aktivno poslušanje, zastavljanje odprtih in zaprtih vprašanj, prepričljivost, ...).
50. Vzpodbujanje pacienta k sodelovanju pri zdravljenju.
51. Rrazilaga delovanja zdravil in pomena jemanja posameznega zdravila za dosego terapevtskih ciljev.
52. Premoščanje fizičnih in čustvenih ovir pri komunikaciji s pacientom.

53. Komunikacija z drugimi zdravstvenimi delavci (pozitivna samopodoba, vzpostavljanje partnerstva, ...).



## Dodatek B

# Distribucija vrednosti odgovorov z anketnih vprašalnikov

Vprašanje	Odgovori					
	1	2	3	4	5	?
2	0(0.0%)	0(0.0%)	3(13.6%)	0(0.0%)	18(81.8%)	1(4.5%)
3	2(9.1%)	0(0.0%)	1(4.5%)	3(13.6%)	16(72.7%)	0(0.0%)
4	0(0.0%)	2(9.1%)	0(0.0%)	1(4.5%)	18(81.8%)	1(4.5%)
5	0(0.0%)	0(0.0%)	2(9.1%)	2(9.1%)	17(77.3%)	1(4.5%)
6	2(9.1%)	0(0.0%)	2(9.1%)	3(13.6%)	15(68.2%)	0(0.0%)
7	1(4.5%)	0(0.0%)	2(9.1%)	4(18.2%)	13(59.1%)	2(9.1%)
8	1(4.5%)	0(0.0%)	2(9.1%)	5(22.7%)	13(59.1%)	1(4.5%)
9	1(4.5%)	2(9.1%)	1(4.5%)	4(18.2%)	13(59.1%)	1(4.5%)
10	1(4.5%)	0(0.0%)	7(31.8%)	3(13.6%)	10(45.5%)	1(4.5%)
11	1(4.5%)	3(13.6%)	2(9.1%)	2(9.1%)	14(63.6%)	0(0.0%)
12	2(9.1%)	2(9.1%)	5(22.7%)	4(18.2%)	9(40.9%)	0(0.0%)
13	1(4.5%)	1(4.5%)	4(18.2%)	4(18.2%)	10(45.5%)	2(9.1%)
14	0(0.0%)	2(9.1%)	2(9.1%)	0(0.0%)	18(81.8%)	0(0.0%)

Vprašanje	Odgovori					
	1	2	3	4	5	?
15	3(13.6%)	3(13.6%)	1(4.5%)	2(9.1%)	13(59.1%)	0(0.0%)
16	3(13.6%)	3(13.6%)	2(9.1%)	3(13.6%)	11(50.0%)	0(0.0%)
17	0(0.0%)	0(0.0%)	1(4.5%)	1(4.5%)	20(90.9%)	0(0.0%)
18	1(4.5%)	1(4.5%)	4(18.2%)	3(13.6%)	13(59.1%)	0(0.0%)
19	4(18.2%)	4(18.2%)	2(9.1%)	3(13.6%)	9(40.9%)	0(0.0%)
20	4(18.2%)	3(13.6%)	5(22.7%)	3(13.6%)	7(31.8%)	0(0.0%)
21	2(9.1%)	0(0.0%)	6(27.3%)	3(13.6%)	11(50.0%)	0(0.0%)
22	0(0.0%)	2(9.1%)	0(0.0%)	3(13.6%)	16(72.7%)	1(4.5%)
23	0(0.0%)	0(0.0%)	3(13.6%)	3(13.6%)	16(72.7%)	0(0.0%)
24	4(18.2%)	2(9.1%)	4(18.2%)	2(9.1%)	10(45.5%)	0(0.0%)
25	3(13.6%)	0(0.0%)	0(0.0%)	5(22.7%)	14(63.3%)	0(0.0%)
26	2(9.1%)	0(0.0%)	0(0.0%)	4(18.2%)	16(72.7%)	0(0.0%)
27	1(4.5%)	3(13.6%)	1(4.5%)	6(27.3%)	11(50.0%)	0(0.0%)
28	4(18.2%)	0(0.0%)	0(0.0%)	4(18.2%)	12(54.5%)	2(9.1%)
29	0(0.0%)	2(9.1%)	1(4.5%)	5(22.7%)	10(45.5%)	4(18.2%)
30	3(13.6%)	0(0.0%)	5(22.7%)	3(13.6%)	6(27.3%)	5(22.7%)
31	1(4.5%)	1(4.5%)	4(18.2%)	5(22.7%)	10(45.5%)	1(4.5%)
32	4(18.2%)	1(4.5%)	2(9.1%)	2(9.1%)	12(54.5%)	1(4.5%)
33	3(13.6%)	1(4.5%)	8(36.4%)	2(9.1%)	7(31.8%)	1(4.5%)
34	3(13.6%)	1(4.5%)	4(18.2%)	3(13.6%)	9(40.9%)	2(9.1%)
35	8(36.4%)	4(18.2%)	4(18.2%)	2(9.1%)	2(9.1%)	2(9.1%)
36	9(40.9%)	4(18.2%)	3(13.6%)	1(4.5%)	2(9.1%)	3(13.6%)
37	11(50.0%)	3(13.6%)	4(18.2%)	0(0.0%)	2(9.1%)	2(9.1%)
38	0(0.0%)	0(0.0%)	0(0.0%)	1(4.6%)	21(95.5%)	0(0.0%)
39	0(0.0%)	0(0.0%)	0(0.0%)	4(18.2%)	18(81.8%)	0(0.0%)
40	1(4.5%)	0(0.0%)	1(4.5%)	4(18.2%)	16(72.7%)	0(0.0%)
41	1(4.5%)	1(4.5%)	2(9.1%)	4(18.2%)	13(59.1%)	1(4.5%)

Vprašanje	Odgovori					
	1	2	3	4	5	?
42	2(9.1%)	2(9.1%)	6(27.3%)	6(27.3%)	3(13.6%)	3(13.6%)
43	0(0.0%)	1(4.5%)	7(31.8%)	4(18.2%)	6(27.3%)	4(18.2%)
44	1(4.5%)	0(0.0%)	2(9.1%)	7(31.8%)	11(50.0%)	1(4.5%)
45	1(4.5%)	1(4.5%)	5(22.7%)	5(22.7%)	7(31.8%)	3(13.6%)
46	5(22.7%)	0(0.0%)	5(22.7%)	4(18.2%)	4(18.2%)	4(18.2%)
47	5(22.7%)	2(9.1%)	3(13.6%)	4(18.2%)	3(13.6%)	5(22.7%)
48	2(9.1%)	0(0.0%)	2(9.1%)	8(36.4%)	6(27.3%)	4(18.2%)
49	3(13.6%)	4(18.2%)	9(40.9%)	1(4.5%)	5(22.7%)	0(0.0%)
50	3(13.6%)	7(31.8%)	6(27.3%)	2(9.1%)	4(18.2%)	0(0.0%)
51	3(13.6%)	2(9.1%)	3(13.6%)	4(18.2%)	9(40.9%)	1(4.5%)
52	8(36.4%)	5(22.7%)	4(18.2%)	4(18.2%)	0(0.0%)	1(4.5%)
53	4(18.2%)	0(0.0%)	0(0.0%)	10(45.5%)	8(36.4%)	0(0.0%)



## Dodatek C

# Napovedane ocene sodelovanja

V tabelah so predstavljene ocene sodelovanja in njihove verjetnosti za zdravnike in farmacevte, ki še niso sodelovali s kliničnim farmacevtom, ki jih je napovedal model s klasifikacijskim drevesom. V prvi tabeli so ocene za vsakega anketiranca posebej, v drugi tabeli pa povprečne ocene za posamezen oddelek na UKC.

ID	Poklic	Oddelek	Ocena			
			2	3	4	5
17	zdravnik	KO ZA INTENZIVNO INTER- NO MEDICINO	0.30	0.45	0.25	0.00 – 3
18	zdravnik	KO ZA INTENZIVNO INTER- NO MEDICINO	0.30	0.05	0.66	0.00 – 4
58	sestra	KO ZA INTENZIVNO INTER- NO MEDICINO	0.00	0.00	0.00	1.00 – 5
59	sestra	KO ZA INTENZIVNO INTER- NO MEDICINO	0.30	0.45	0.25	0.00 – 3
19	zdravnik	KO ZA NEFROLOGIJO	0.30	0.05	0.66	0.00 – 4
20	zdravnik	KO ZA NEFROLOGIJO	0.30	0.05	0.66	0.00 – 2
60	sestra	KO ZA NEFROLOGIJO	0.23	0.14	0.23	0.41 – 5

ID	Poklic	Oddelek	Ocena				
			2	3	4	5	
21	zdravnik	KO ZA PLJUČNE BOLEZNI	0.30	0.45	0.25	0.00	- 3
61	sestra	KO ZA PLJUČNE BOLEZNI	0.30	0.05	0.66	0.00	- 4
22	zdravnik	CENTER ZA VOJNE VETERANE	0.30	0.45	0.25	0.00	- 3
23	zdravnik	CENTER ZA VOJNE VETERANE	0.09	0.05	0.05	0.82	- 5
65	sestra	CENTER ZA VOJNE VETERANE	0.30	0.05	0.66	0.00	- 4
24	zdravnik	CENTER ZA ZASTRUPITVE	0.09	0.05	0.05	0.82	- 5
25	zdravnik	CENTER ZA ZASTRUPITVE	0.09	0.05	0.05	0.82	- 5
66	sestra	CENTER ZA ZASTRUPITVE	0.09	0.05	0.05	0.82	- 5
26	zdravnik	NEVROLOŠKA KLINIKA	0.09	0.05	0.05	0.82	- 5
27	zdravnik	NEVROLOŠKA KLINIKA	0.09	0.05	0.05	0.82	- 5
28	zdravnik	NEVROLOŠKA KLINIKA	0.30	0.45	0.25	0.00	- 3
77	sestra	NEVROLOŠKA KLINIKA	0.30	0.45	0.25	0.00	- 3
78	sestra	NEVROLOŠKA KLINIKA	0.30	0.05	0.66	0.00	- 4
79	sestra	NEVROLOŠKA KLINIKA	0.30	0.05	0.66	0.00	- 4
80	sestra	NEVROLOŠKA KLINIKA	0.50	0.09	0.09	0.32	- 2
81	sestra	NEVROLOŠKA KLINIKA	0.30	0.05	0.66	0.00	- 4
82	sestra	NEVROLOŠKA KLINIKA	0.30	0.05	0.66	0.00	- 4
83	sestra	NEVROLOŠKA KLINIKA	0.09	0.05	0.05	0.82	- 5
84	sestra	NEVROLOŠKA KLINIKA	0.30	0.05	0.66	0.00	- 4
85	sestra	NEVROLOŠKA KLINIKA	0.23	0.14	0.23	0.41	- 5
86	sestra	NEVROLOŠKA KLINIKA	0.30	0.05	0.66	0.00	- 4
87	sestra	NEVROLOŠKA KLINIKA	0.30	0.05	0.66	0.00	- 4
29	zdravnik	GINEKOLOŠKA KLINIKA	0.30	0.05	0.66	0.00	- 4
30	zdravnik	GINEKOLOŠKA KLINIKA	0.00	0.00	0.00	1.00	- 5
31	zdravnik	GINEKOLOŠKA KLINIKA	0.30	0.05	0.66	0.00	- 4
32	zdravnik	GINEKOLOŠKA KLINIKA	0.30	0.45	0.25	0.00	- 3
33	zdravnik	GINEKOLOŠKA KLINIKA	0.30	0.05	0.66	0.00	- 4
90	sestra	GINEKOLOŠKA KLINIKA	0.30	0.05	0.66	0.00	- 4

ID	Poklic	Oddelek	Ocena			
			2	3	4	5
34	zdravnik	PEDIATRIČNA KLINIKA	0.30	0.45	0.25	0.00 – 3
35	zdravnik	PEDIATRIČNA KLINIKA	0.09	0.05	0.05	0.82 – 5
36	zdravnik	PEDIATRIČNA KLINIKA	0.50	0.09	0.09	0.32 – 2
37	zdravnik	PEDIATRIČNA KLINIKA	0.30	0.45	0.25	0.00 – 3
38	zdravnik	PEDIATRIČNA KLINIKA	0.30	0.45	0.25	0.00 – 3
39	zdravnik	PEDIATRIČNA KLINIKA	0.50	0.09	0.09	0.32 – 2
40	zdravnik	PEDIATRIČNA KLINIKA	0.30	0.05	0.66	0.00 – 4
41	zdravnik	PEDIATRIČNA KLINIKA	0.30	0.45	0.25	0.00 – 3
42	zdravnik	PEDIATRIČNA KLINIKA	0.30	0.05	0.66	0.00 – 4
43	zdravnik	PEDIATRIČNA KLINIKA	0.30	0.45	0.25	0.00 – 3
44	zdravnik	PEDIATRIČNA KLINIKA	0.30	0.45	0.25	0.00 – 3
88	sestra	PEDIATRIČNA KLINIKA	0.30	0.15	0.24	0.32 – 5
89	sestra	PEDIATRIČNA KLINIKA	0.23	0.14	0.23	0.41 – 5
45	zdravnik	DERMATOVENEROLOŠKA KLINIKA	0.30	0.45	0.25	0.00 – 3
67	sestra	KO ZA TORAKALNO KIRUR- GIJO	0.30	0.05	0.66	0.00 – 4
68	sestra	KO ZA TORAKALNO KIRUR- GIJO	0.30	0.05	0.66	0.00 – 4
69	sestra	KO ZA ABDOMINALNO KI- RURGIJO	0.23	0.14	0.23	0.41 – 5
70	sestra	KO ZA TRAVMATOLOGIJO	0.30	0.05	0.66	0.00 – 4
71	sestra	KO ZA PLASTIČNO, REKON- STRUKCIJSKO, ESTETSKO KIRURGIJO IN OPEKLINE	0.30	0.45	0.25	0.00 – 3
72	sestra	KO ZA MAKSILOFACIALNO KIRURGIJO	0.30	0.45	0.25	0.00 – 3
73	sestra	KO ZA UROLOGIJO	0.23	0.14	0.23	0.41 – 5
74	sestra	KO ZA NEVROKIRURGIJO	0.30	0.14	0.25	0.00 – 3

ID	Poklic	Oddelek	Ocena			
			2	3	4	5
75	sestra	KO ZA ZA KIRURGIJO SRCA IN OŽILJA	0.23	0.14	0.23	0.41 – 5
76	sestra	OPERACIJSKI BLOK	0.50	0.09	0.09	0.32 – 2
95	sestra	KLINIKA ZA OTOLARINGO- LOGIJO IN CERVIKOFACI- ALNO KIRURGIJO	0.30	0.05	0.66	0.00 – 4

Oddelek na UKC	Povprečna ocena
KO ZA INTENZIVNO INTERNO MEDICINO	3.75
KO ZA NEFROLOGIJO	3.67
KO ZA PLJUČNE BOLEZNI	3.50
CENTER ZA VOJNE VETERANE	4.00
CENTER ZA ZASTRUPITVE	5.00
NEVROLOŠKA KLINIKA	4.00
GINEKOLOŠKA KLINIKA	4.00
PEDIATRIČNA KLINIKA	3.46
DERMATOVENEROLOŠKA KLINIKA	3.00
KO ZA TORAKALNO KIRURGIJO	4.00
KO ZA ABDOMINALNO KIRURGIJO	5.00
KO ZA TRAVMATOLOGIJO	4.00
KO ZA PLASTIČNO, REKONSTRUKCIJSKO, ESTETSKO KIRURGIJO IN OPEKLINE	3.00
KO ZA MAKSILOFACIALNO KIRURGIJO	3.00
KO ZA UROLOGIJO	5.00
KO ZA NEVROKIRURGIJO	3.00
KO ZA ZA KIRURGIJO SRCA IN OŽILJA	5.00
OPERACIJSKI BLOK	2.00
KLINIKA ZA OTOLARINGOLOGIJO IN CERVI- KOFACIALNO KIRURGIJO	4.00

# Slike

2.1	Skica 10-kratnega prečnega preverjanja. . . . .	9
2.2	Logo programskega okolja R. . . . .	10
2.3	Grafični uporabniški vmesnik Orange s shemo za klasifikacijo podatkov. . . . .	11
4.1	Primer uporabe algoritma OrdEval in njegove vizualizacije . .	18
4.2	Ocene vseh atributov, ki jih vrne OrdEval. . . . .	19
4.3	Vizualizacija rezultata algoritma OrdEval za vprašanje 17. . .	20
4.4	Programska koda v programu R za ocenjevanje atributov z algoritmoma ReliefF in MDL. . . . .	22
4.5	Porazdelitev rezultatov ReliefF na pet podintervalov, da dobimo enako distribucijo odgovorov. . . . .	23
4.6	Porazdelitev rezultatov MDL na pet podintervalov, da dobimo enako distribucijo odgovorov. . . . .	25
4.7	Matrika napak naivnega Bayesovega klasifikatorja pri 10-kratnem prečnem preverjanju. . . . .	29
4.8	Matrika napak klasifikacijskega drevesa pri 10-kratnem prečnem preverjanju. . . . .	29
4.9	Graf klasifikacijskega drevesa za napoved ocene sodelovanja 5 pri 10-kratnem prečnem preverjanju. . . . .	30
4.10	Matrika napak naivnega Bayesovega klasifikatorja pri metodi izloči enega. . . . .	31
4.11	Nomogram naivnega Bayesovega klasifikatorja za vse attribute. .	34

4.12 Matrika napak klasifikacijskega drevesa pri metodi izloči enega. 35

# Tabele

4.1	Vsebina vprašanj z absolutno največjim vplivom na oceno sodelovanja. . . . .	21
4.2	Vsebina vprašanj 17, 19 in 21. . . . .	21
4.3	Pet najpomembnejših atributov za algoritem ReliefF. . . . .	23
4.4	Razlike v rezultatih ocenjevanja atributov z algoritmom ReliefF in subjektivne ocene vodje lekarne. . . . .	24
4.5	Pet najpomembnejših atributov za algoritem MDL. . . . .	26
4.6	Razlike v rezultatih ocenjevanja atributov z algoritmom MDL in subjektivnih ocen vodje lekarne. . . . .	27



# Literatura

- [1] Robnik-Šikonja, M., Brijs, K. & Vanhoof, K.: Ordinal Evaluation: A New Perspective on Country Images., Vol. 5633 Springer (2009), S. 261-275.
- [2] Kononenko, I., Robnik-Šikonja M.: Inteligentni sistemi, Fakulteta za računalništvo in informatiko, Ljubljana, 2010.
- [3] Kira K., Rendell L. A., A Practical Approach to Feature Selection. V Sleeman D., Edwards P., uredniki: Machine Learning: Proceedings of International Conference, ICML'92, str. 249–256. Morgan Kaufmann, 1992.
- [4] Kononenko I.: Estimating attributes: analysis and extensions of Relief. V Raedt L. D., Bergadano F., uredniki: Machine Learning: ECML-94, str. 171–182. Springer Verlag, 1994.
- [5] Li M., Vitanyi P.: An Introduction to Kolmogorov Complexity and its Applications, Springer Verlag, New York, 1993.
- [6] Rissanen, J.: A universal prior for integers and estimation by minimum description length, The annals of Statistics, 11(2), str. 416-431, 1993.
- [7] Kononenko I.: On biases in estimating multivalued attributes. V Int. Joint Conf. on Artificial Intelligence IJCAI-95, str. 1034-1040, 1995. Montreal, August 20-25.

- [8] Panjan, A.: Napovedovanje uspešnosti teniških igralcev z metodami strojnega učenja. Diplomsko delo, Fakulteta za računalništvo in informatiko, Ljubljana, 2009.
- [9] W. N. Venables, D. M. Smith and the R Development Core Team: An Introduction to R, Notes on R: A Programming Environment for Data Analysis and Graphics, Version 2.8.1, 22.12.2008.
- [10] Demšar, J., Zupan, B., Leban, Gregor & Curk, T.: Orange: From Experimental Machine Learning to Interactive Data Mining., Vol. 3202 Springer, 2004.