

UNIVERZA V LJUBLJANI  
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO  
FAKULTETA ZA MATEMATIKO IN FIZIKO

Gregor Weiss

**Ocenjevanje pomembnosti atributov  
iz uspešnosti učnih algoritmov  
na vzorcih atributnega prostora**

DIPLOMSKO DELO  
NA UNIVERZITETNEM INTERDISCIPLINARNEM ŠTUDIJU  
RAČUNALNIŠTVO IN MATEMATIKA

Mentor: prof. dr. Blaž Zupan

Ljubljana 2011

Št. naloge: 00023/2010

Datum: 01.09.2010



Univerza v Ljubljani, Fakulteta za računalništvo in informatiko ter Fakulteta za matematiko in fiziko izdaja naslednjo naložo:

Kandidat: **GREGOR WEISS**

Naslov: **OCENJEVANJE POMEMBNOSTI ATRIBUTOV IZ USPEŠNOSTI UČNIH ALGORITMOV NA VZORCIH ATRIBUTNEGA PROSTORA**  
**ATTRIBUTE SCORING BASED ON PERFORMANCE OF AN LEARNING ALGORITHM ON SAMPLES OF ATTRIBUTE SPACE**

Vrsta naloge: Diplomsko delo univerzitetnega študija

Tematika naloge:

V diplomskem delu razvijte novo tehniko za ocenjevanje pomembnosti diskretnih atributov za nadzorovano strojno učenje. Vaš pristop naj temelji na predpostavki, da prisotnost pomembnih oz. koristnih atributov v učni domeni tipično izboljša napovedno točnost izbranega algoritma za strojno učenje. Za ocenjevanje pomembnosti atributov tako preučite možnosti uporabe ocen uspešnosti strojnega učenja na naborih podatkov z različno izbranimi kombinacijami atributov in določevanja pomembnosti danega atributa iz njih glede na uspešnosti učenja na domenah, ki so vključevale ta atribut. Pripravite primerno metodologijo za testiranje in delovanje eksperimentalno ovrednotite.

Mentor:

prof. dr. Blaž Zupan



Dekan Fakultete za računalništvo in informatiko:

prof. dr. Nikolaj Zimic

Dekan Fakultete za matematiko in fiziko:

prof. dr. Andrej Likar



Namesto tega lista **vstavite** original izdane teme diplomskega dela s podpisom mentorja in dekana ter žigom fakultete, ki ga diplomant dvigne v študentskem referatu, preden odda izdelek v vezavo!

# **IZJAVA O AVTORSTVU**

diplomskega dela

Spodaj podpisani      Gregor Weiss,

z vpisno številko      63040304,

sem avtor diplomskega dela z naslovom:

Ocenjevanje pomembnosti atributov iz uspešnosti učnih algoritmov na vzorcih atributnega prostora

Attribute scoring based on performance of an learning algorithm on samples of attribute space

S svojim podpisom zagotavljam, da:

- sem diplomsko delo izdelal samostojno pod mentorstvom:  
prof. dr. Blaž Zupan,
- so elektronska oblika diplomskega dela, naslov (slo., ang.), povzetek (slo., ang.) ter ključne besede (slo., ang.) identični s tiskano obliko diplomskega dela,
- soglašam z javno objavo elektronske oblike diplomskega dela v zbirki "Dela FRI".

V Ljubljani, dne 14. 3. 2011

Podpis avtorja:

To diplomsko delo je ponujeni pod licenco *Creative Commons Priznanje avtorstva-Deljenje pod enakimi pogoji 2.5 Slovenija* (CC BY-SA 2.5) ali (po želji) novejši različici. To pomeni, da se tako besedilo, slike, grafi in druge sestavnine dela kot tudi rezultati diplomskega dela lahko prosto distribuirajo, reproducirajo, uporabljajo, dajejo v najem, priobčujejo javnosti in predelujojo, pod pogojem, da se jasno in vidno navede avtorja in naslov tega dela in da se v primeru spremembe, preoblikovanja ali uporabe tega dela v svojem delu, lahko distribuira predelava le pod licenco, ki je enaka tej. Podrobnosti licence so dostopne na spletni strani <http://creativecommons.si/licence> ali na Inštitutu za intelektualno lastnino, Strelška 1, 1000 Ljubljana.



Izvorna koda diplomskega dela in v ta namen razvita programska oprema je ponujena pod GNU General Public License, različica 3 ali (po želji) novejši različici. To pomeni, da se lahko prosto uporablja, distribuira in/ali predelujo pod njenimi pogoji. Podrobnosti licence so dostopne na spletni strani <http://www.gnu.org/licenses/>.

*Besedilo je oblikovano z urejevalnikom besedil L<sup>A</sup>T<sub>E</sub>X.*

---

## Zahvala

Na tem mestu bi se zahvalil vsem, ki so me kakorkoli podpirali, motivirali in vzpodbujali tekom celotnega študija in pisanja obsežnega diplomskega dela. Pri tem bi še posebej izpostavil družino in se zahvalil za vso potrpljenje, ki so ga imeli z menoj. Zahvalil bi se tudi vsem ostalim, ki so soprispevali k dokončanju diplomskega dela na dan števila  $\pi$ , 14. 3. 2011.

---

# Kazalo

|   |           |
|---|-----------|
| <b>Povzetek</b>   | <b>1</b>  |
| <b>Abstract</b>   | <b>2</b>  |
| <b>1 Uvod</b>   | <b>3</b>  |
| <b>2 Pregled področja</b>   | <b>7</b>  |
| 2.1 Običajni načini uporabe . . . . .   | 10        |
| <b>3 Ocenjevanje pomembnosti atributov iz uspešnosti učnih algoritmov na vzorcih atributnega prostora</b> | <b>13</b> |
| 3.1 Generiranje podmnožic atributov . . . . .   | 15        |
| 3.2 Ocenjevalni model . . . . .   | 18        |
| 3.3 Učni algoritem . . . . .  | 19        |
| 3.4 Vrednotenje uspešnosti . . . . .  | 21        |
| 3.5 Združevanje rezultatov . . . . .  | 23        |
| <b>4 Eksperimenti in rezultati</b>  | <b>27</b> |
| 4.1 Podatki . . . . .   | 30        |
| 4.2 Metodologija testiranja . . . . .   | 33        |
| 4.3 Rezultati . . . . .   | 36        |
| 4.4 Diskusija . . . . .   | 45        |
| <b>5 Zaključek</b>  | <b>47</b> |
| 5.1 Nadaljnje delo . . . . .  | 48        |
| <b>Literatura</b>   | <b>50</b> |

|   |    |
|---|----|
| A Ostali grafi povprečnih rangov osnovne analize  | 53 |
| B Celotna združena tabela osnovne analize         | 57 |
| C Ostali grafi povprečnih rangov podrobne analize | 71 |
| D Celotna združene tabele podrobne analize        | 73 |

---

# Povzetek

Na področju strojnega učenja in odkrivanja znanj iz podatkov imajo osrednjo vlogo atributi ali značilke, zaradi česar se je smiselno spraševati tudi o njihovi kvaliteti oz. pomembnosti za dani problem. Ker gre v splošnem za težek problem, smo se v okviru diplomskega dela lotili razviti novo metodo za ocenjevanje pomembnosti atributov.

Nova metoda temelji na vzorčenju atributnega prostora, ocenjevanju uspešnosti algoritmov za strojno učenje in sklepanju o pomembnostih posameznih atributov glede na pridobljene ocene. Natančneje povedano najprej izbira različne kombinacije atributov in pripravlja z njimi manjše nabore podatkov nato na njih s postopkom testiranja z vzorčenjem pridobiva ocene uspešnosti poljubnega izbranega učnega algoritma. Zbrane ocene uspešnosti za vsak vzorec atributov se na koncu statistično obdela glede na njihovo prisotnost in po podani formuli združi v končne ocene pomembnosti po posameznih atributih.

Da bi se ugotovilo kako dobro se obnesejo različne variante nove metode, se je določilo ustrezno eksperimentalno metodologijo in pripravilo veliko množico raznolikih naborov podatkov. Nekaj uspenejših metod se je nato še podrobneje analiziralo in podkrepilo ugotovitev, da so nekatere variante nove metode res opazno statistično signifikantno boljše od običajnih razširjenih metod za ta problem, žal pa izboljšana nadgradnja najboljše od teh izgleda še boljša. Diplomsko delo se zaključi z diskusijo o rezultatih in raznolikimi idejami za nadaljnje delo, izboljšavami in uporabami metode.

## Ključne besede:

nadzorovano strojno učenje, ocenjevanje pomembnosti atributov, vzorčenje atributnega prostora, posplošitev metode z ovojnico na poljubnih učnih algoritmih

---

# Abstract

In the field of machine learning and knowledge discovery in databases attributes or features have a central role, thus it is reasonable to also question their quality and importance for the given problem. Because this is in general a difficult problem, we focused in the thesis on the development of a new method for estimating attribute importance.

The new method is based on sampling the attribute space, evaluating the performance of algorithms for machine learning and reasoning about the importance of individual attributes based on the obtained scores. More specifically, at first different combinations of attributes are chosen and smaller data sets that contain them are prepared on which a testing procedure with sampling obtains estimates on performance of an arbitrary chosen learning algorithm. Performance estimates obtained that way are statistically processed for each attribute according to their presence and with a given formula joined into final scores for individual attributes.

In order to determine how well different variants of the new method work, an appropriate experimental methodology and many diverse data sets has been prepared. Some successful methods have also been further tested in more detail to reinforce the conclusion, that certain variants of the new method really are statistically significant better than conventional widely used methods for this problem, but unfortunately an improved version of the best one of them still seems to be better. The thesis concludes with a discussion of the results and various ideas for further work, improvements and applications of the method.

## **Key words:**

supervised machine learning, estimating attribute importance, sampling of attribute space, generalized wrapper method on arbitrary learning algorithms

---

---

# Poglavlje 1

---

## Uvod

Na področju strojnega učenja in odkrivanja znanj iz podatkov se ponavadi ukvarjamо z obravnavanjem atributov ali značilk (ang. *features*). Na njih učimo različne učne algoritme, sestavljamo modele, jih testiramo in skušamo kje uporabiti ali pa se iz njih naučiti kaj o problemu in podatkih. Zato se je smiseln spraševati tudi o njihovi kvaliteti in pomembnosti za dani problem. Ocenjevanje pomembnosti atributov je tako ključna sestavina nekaterih pogostih opravil kot na primer izbor koristnih podmnožic atributov (ang. *feature subset selection*), določanje uteži atributov, konstruktivne indukcije, gradnje klasifikacijskih ter regresijskih dreves in raziskovanje danega nabora podatkov.

Pri problemih klasifikacije in regresije daleč najpogosteje delamo z atributno predstavitvijo naborov podatkov, kjer imamo vsak primer opisan z vektorjem večih atributov. Atribut je spremenljivka v podani diskretni ali zvezni domeni oz. množici dovoljenih vrednosti, ki predstavlja neko lastnost primera. Eden od atributov je posebej odlikovan in predstavlja v primeru klasifikacije diskretni razred v katerega je primer uvrščen, v primeru regresije pa odvisno zvezno vrednost. Cilj učenja pa predstavlja najti zakonitosti, vzorce in pravila v učnih primerih, ki bodo omogočale, da bomo za primer, ki ga še nismo videli, s čim večjo verjetnostjo pravilno napovedali odlikovani ciljni atribut. Ključnega pomena je torej sposobnost pospoljevanja in gradnja ustreznih modelov.

Vrednosti atributov za dani primer predstavljajo njegove lastnosti in nam zato povedo nekaj o ciljnem atributu. Nekatere več, nekatere manj ali celo nič, nekatere pa nekaj samo v primeru, če jih obravnavamo v skupini z izbranimi drugimi. Ti pojavi so posledice kompleksnih medsebojnih odvisnosti, neodvisnosti in koreliranosti med atributi od katerih osnovno nepoenostavljivo

varianto imenujemo interakcija. Za množico atributov  $\mathcal{V} = \{A_1, \dots, A_m\}$  pravimo, da so v interakciji, če se funkcijo gostote verjetnosti celotne množice  $f(\mathcal{V})$  ne da sestaviti iz njenih delov z nobeno funkcijo  $g$ :

$$f(\mathcal{V}) \neq g(f(A_2, A_3, \dots), f(A_1, A_3, \dots), \dots, f(A_1, \dots, A_{m-1})) \quad (1.1)$$

Z drugimi besedami povedano je množica atributov v interakciji natanko takrat, ko nam koristi obravnavati njihove vrednosti skupaj. Odnose med atributi v interakciji lahko opisujemo s t. i. interakcijskimi prispevki (ang. *interaction gain*) [7, 8]. Pozitivni interakcijski prispevek odraža pozitivno interakcijo ali sodejavnost (ang. *synergy*), negativni interakcijski prispevek pa negativno interakcijo, odvečnost ali soodvisnost (ang. *redundancy*). Skupen interakcijski prispevek oz. doprinos informacij je vsota pozitivne sinergije in negativne odvečnosti spremenljivk. Pri soodvisnosti velja, da nam posamezni atributi podajo deloma iste informacije, ki nam povedo o ciljnem manj kot bi pričakovali, če bi kar sešteli količino informacij, ki jih podajajo posamično. Po drugi strani pa nam pri sodejavnosti atributi, če jih obravnavamo hkrati, podajo več informacij o ciljnem atributu, ki nam jih ne bi podal noben od njih brez vseh ostalih. V kolikor je interakcijski prispevek nič gre ali za popolnoma neodvisne attribute ali pa se učinki pozitivne sinergije in negativne soodvisnosti ravno izničijo. Atributi, ki niso v nobeni množici v interakciji s ciljnim atributom, so nekoristni za ta problem in jih je najboljše odstraniti, saj lahko le zmedejo algoritme in podaljšujejo čas izvajanja.

V običajnih naborih podatkov se skriva vrsta kompleksnih težko določljivih interakcij, a pri pogostih opravilih nas njihove podrobnosti sploh ne zanimajo. Običajno potrebujemo le preprosto oceno kako pomemben, kvaliteten, informativen oz. uporaben je posamezen atribut za napovedovanje v danem problemu. Pri tem se seveda pojavi vprašanje kaj sploh je prava pomembnost oz. kvaliteta atributov in kako jo lahko ocenjujemo. Izkaže se, da v resnici prave pomembnosti atributov na realnih podatkih iz realnih problemov skoraj nikoli ne poznamo in tudi na umetno ustvarjenih, kjer se uporablja naključnost, ne moremo natančno poznati vsega. Problem običajno predstavlja končen obvladljiv nabor podatkov na katerih se učimo in testiramo. Le-ta skoraj nikoli ne more predstavljati vseh možnih kombinacij v resničnih razmerjih. Kot posledica tega navidezno nekoristni naključni atributi več niso nujno naključni za dani problem, med njimi nastopajo kakšne interakcije in po naključju lahko kombinacije teh celo predstavljajo kakšen del informacije. Zato razne metode v skladu s kakšno teorijo le okvirno ocenjujejo pomembnosti atributov.

Za ocenjevanje pomembnosti atributov glede na njihovo informativnost za ciljni atribut obstajajo številne različne mere oz. metode. Najpreprostejše med njimi obravnavajo attribute že od začetka neodvisno in običajno računajo z verjetnostnimi porazdelitvami glede na ciljni atribut. Kompleksnejše pa

upoštevajo tudi kontekst drugih atributov in včasih iterativno izboljšujejo ocene. Pri tem še velja omeniti, da skušajo metode za ocenjevanje pomembnosti atributov najti vse pomembne attribute, kar pomeni, da je na koncu predstavljen rezultat za vsak atribut posebej neodvisen od ostalih, in posledično se s tem tudi zakrijejo medsebojne interakcije med atributi. Tako so na primer vsi odvečni (ang. *redundant*) informativni atributi ocenjeni približno enako dobro. Rezultati teh metod so številčne vrednosti, ki nimajo absolutnega pomena in se lahko od metode do metode zelo razlikujejo. Edina skupna lastnost je, da višja kot je vrednost, boljši oz. bolj pomemben je verjetno atribut za dani problem:

$$\text{Ocena}(A_1) > \text{Ocena}(A_2) \implies A_1 \text{ bolj pomemben od } A_2 \quad (1.2)$$

Za cilj diplomskega dela smo si tako zadali razviti kakšen nov algoritem oz. pristop za ocenjevanje pomembnosti diskretnih atributov za nadzorovano strojno učenje (stran 13). Ideja temelji na predpostavki, da prisotnost pomembnih oz. koristnih atributov v učni domeni tipično izboljša napovedno točnost izbranega algoritma za strojno učenje. Za ocenjevanje pomembnosti atributov smo tako preučili možnost uporabe ocen uspešnosti strojnega učenja na naborih podatkov z različno izbranimi kombinacijami atributov in določevanjem pomembnosti danega atributa iz njih glede na uspešnosti učenja na domenah, ki so vključevale ta atribut. Pri novi metodi se kot sestavlje komponente uporablja mnogi drugi algoritmi iz strojnega učenja s katerimi se vpliva na delovanje in način ocenjevanja. Ker gre za veliko število možnih različnih kombinacij, smo v nadaljevanju pripravili poseben sistem poimenovanja le-teh, ki ima kot skupen del oznake kratico Lea.

Variante razvite tehnike smo eksperimentalno primerjali z obstoječimi razširjenimi in ustaljenimi metodami za ocenjevanje atributov (stran 27). V okviru tega smo sestavili primerno eksperimentalno metodologijo, velik poligon raznolikih naborov podatkov in pridobljene rezultate smiseln predstavili ter ovrednotili (stran 36). Nekaj uspenejših metod smo nato še natančneje preizkušali in podkrepili ugotovitev, da so nekatere variante nove metode res opazno statistično signifikantno boljše od običajnih razširjenih metod za ta problem, žal pa izboljšana različica najboljše od teh izgleda še boljša.

Ker je sama ideja metode preprosta in zelo splošna, se jo lahko uporablja tudi v drugačnih okoljih, če ustrezno izberemo njene komponente. Zato smo na koncu podali še nekaj smernic za številne izboljšave, načine uporabe in nadaljnje raziskovalno delo (stran 48). Problem je v splošnem težek, a kot se vidi v nadaljevanju se ga je dokaj uspešno rešilo.

---

---

## Poglavlje 2

---

### Pregled področja

Kot že omenjeno obstajajo številne različne mere oz. metode za ocenjevanje pomembnosti atributov, ki so običajno specializirane le za določen tip podatkov in problemov. V okviru diplomskega dela se bomo zato bolj poglobili v tiste, ki delujejo na diskretnih atributih pri problemu klasifikacije.

Standardne mere za ocenjevanje atributov pri klasifikaciji temeljijo na funkcijah razredne nečistoče (ang. *impurity function*), večina teh pa na teoriji informacij. Informacija, merjena v bitih, nastane, ko se zgodi eden od možnih dogodkov danega eksperimenta za katere običajno poznamo verjetnosti  $p(x_j)$ . Entropijo slučajne spremenljivke  $H(X)$  pa definiramo kot povprečno količino informacije potrebne za določitev izida med  $m$  možnimi izidi  $\{x_1, \dots, x_m\}$  nekega eksperimenta z lastnostjo  $\sum_{j=1}^m p(x_j) = 1$  po:

$$H(X) = - \sum_{j=1}^m p(x_j) \log_2 p(x_j) \quad (2.1)$$

Za namen nadaljnje razlage tako definiramo še entropijo ciljnega razrednega atributa  $C$ , poljubnega atributa  $A$ , entropijo združenega dogodka le-teh  $CA$  in pogojno razredno entropijo ob podani vrednosti atributa  $C|A$ :

$$\begin{aligned} H(C) &= - \sum_{c_k \in C} p(c_k) \log_2 p(c_k) \\ H(A) &= - \sum_{a_j \in A} p(a_j) \log_2 p(a_j) \\ H(CA) &= - \sum_{c_k \in C} \sum_{a_j \in A} p(c_k \wedge a_j) \log_2 p(c_k \wedge a_j) \\ H(C|A) &= - \sum_{a_j \in A} p(a_j) \sum_{c_k \in C} p(c_k|a_j) \log_2 p(c_k|a_j) \end{aligned} \quad (2.2)$$

kjer so s  $c_k$  in  $a_j$  predstavljene vrednosti, ki jih zavzemata atributa  $C$  in  $A$ .

Sledi kratek opis običajnih in razširjenih mer za ocenjevanje pomembnosti atributov, ki so se uporabile v okviru diplomskega dela:

- **Informacijski prispevek** (krat. Info) (ang. *information gain*) je mera za ocenjevanje pomembnosti atributov, ki je definirana kar s količino informacije pridobljene iz atributa pri določevanju razreda po enačbi (2.3). Njena slabost je pristransko precenjevanje atributov z domenami, ki vsebujejo veliko različnih vrednosti.

$$\text{Info}(A) = H(C) - H(C|A) \quad (2.3)$$

- **Razmerje informacijskega prispevka** (krat. IGR) (ang. *information gain ratio*) [18] je definirano po enačbi (2.4) kot vrednost informacijskega prispevka normalizirana z atributno entropijo  $H(A)$ . Z normalizacijo se sicer odstrani pristranskost za večvrednostne attribute, a pojavi se precenjevanje atributov z majhno entropijo.

$$\text{IGR}(A) = \frac{\text{Info}(A)}{H(A)} \quad (2.4)$$

- **Mera oddaljenosti** (krat. Dist) (ang. *distance measure*) [2] zapisana v obliki bližine je definirana kot vrednost informacijskega prispevka normalizirana z združeno entropijo  $H(CA)$  po enačbi (2.5). Ta mera nima prej omenjenih slabosti, hkrati pa je rezultat vedno na intervalu  $[0, 1]$ .

$$\text{Dist}(A) = 1 - d(C, A) = \frac{\text{Info}(A)}{H(CA)} \quad (2.5)$$

- **Gini indeks** (krat. Gini) (ang. *Gini-index*) [1] se lahko interpretira kot verjetnost, da bosta dva naključno izbrana primera pripadala različnim razredom. Po uporabi splošne formule za izbrani atribut pride do enačbe (2.6). Znano pa je, da ta metoda precenjuje večvrednostne attribute.

$$\text{Gini}(A) = \sum_{a_j \in A} p(a_j) \sum_{c_k \in C} p(c_k|a_j)^2 - \sum_{c_k \in C} p(c_k)^2 \quad (2.6)$$

- **Logaritem razmerja obetov** (krat. LogO) (ang. *logarithmic odds ratio*) je klasična mera iz statistike za binarne attribute, ki računa logaritem razmerij verjetnosti pripadnosti ciljnemu razredu:

$$\text{LogO}(A) = \log \frac{\frac{p(c|a_0)}{1-p(c|a_0)}}{\frac{p(c|a_1)}{1-p(c|a_1)}} \quad (2.7)$$

- **Mera s  $\chi^2$  statistiko** (krat. Chi2) [21] je poskus uporabe le-te za ocenjevanje pomembnosti atributov za katero so predhodne študije pokazale, da ni dobra za primerjanje različnih atributov [14]. Izračuna se po enačbi (2.8), ki predstavlja  $\chi^2$  s  $(|A| - 1)(|C| - 1)$  prostostnimi stopnjami. V njej  $e(c_k, a_j)$  predstavlja pričakovano število in  $n(c_k, a_j)$  opazovano število primerov z razredom  $c_k$  in vrednostjo atributa  $a_j$  ob predpostavki neodvisnosti med njima.

$$\chi^2(A) = \sum_{c_k \in C} \sum_{a_j \in A} \frac{(e(c_k, a_j) - n(c_k, a_j))^2}{e(c_k, a_j)} \quad (2.8)$$

- **Relieff** (krat. RelF) je učinkovita nadgradnja osnovnega preprostega algoritma *Relief* [11, 10] katerega ideja v primerjavi z zgoraj omenjenimi pristopi je ne samo upoštevati razlike v vrednostih atributov, temveč tudi razdalje med primeri. Osnovni algoritem deluje tako, da za vsak primer iz naključnega vzorca velikosti  $m$  poišče najbližji primer iz istega (ang. *nearest hit*) in najbližji primer iz nasprotnega razreda (ang. *nearest miss*) ter posodobi oceno pomembnosti atributa glede na to kako dobro loči med primeroma iz istega razreda (nezaželjena lastnost) in primeroma iz nasprotnega razreda (zaželjena lastnost). Naprednejša različica *Relieff* [13, 19] upošteva  $k$  najbližjih sosedov in je sposobna obravnavati večrazredne probleme z manjkajočimi in šumnimi atributi. Ta metoda je izjemno uspešna pri ocenjevanju pomembnosti diskretnih in zveznih atributov, četudi nastopajo med njimi močne sinergijske interakcije oz. sodejavnosti. Izkaže pa se, da na njeno uspešnost močno vpliva prisotnost večjega števila nekoristnih in šumnih atributov.

**RelievedF** (krat. RedF) [12] je deterministična varianta algoritma *Relieff*, ki namesto naključnega vzorca obravnavava kar vse primere iz nabora podatkov  $m = n$ . Posledično pri ponovitvi poskusa ocenjevanja pomembnosti atributov na istem naboru podatkov ne prihaja več do naključnih razlik v rezultatih, kar pride prav pri primerjanju algoritmov med seboj.

- **RelieffFS** (krat. ReFS) [17] je koristna nadgraditev algoritma *Relief*, ki namesto konstantnega parametra  $k$  pregleda vse možne vrednosti in vrne kot oceno pomembnosti atributa najvišjo najdeno vrednost.

**RelievedFS** (krat. RdFS) je deterministična brezparametrična varianta tega algoritma, ki smo jo obravnavali v okviru diplomske naloge.

Sicer obstajajo še mnoge bolj ali manj uspešne različice teh metod, a se jih tako kot številne druge v diplomskem delu ni obravnavalo (npr. ang. *Weight of evidence* (WE), *Minimum description length* (MDL), *J-measure*, *G statistics*, *Orthogonality of class distribution vectors* (ORT), *Contextual merit* (CM), ...).

## 2.1 Običajni načini uporabe

Ocenjevanje pomembnosti atributov je ključna sestavina nekaterih pogostih opravil v strojnem učenju, ki so nastete v nadaljevanju in pri katerih bi se tudi lahko uporabljalo novo metodo.

Pri **gradnji klasifikacijskih in regresijskih dreves** potrebujemo za odločitve v vozliščih primerno funkcijo, ki bo izbirala atribut s katerimi bo nastalo čim boljše odločitveno drevo. Klasično se za to uporablja preproste funkcije razredne nečistoče.

**Izbor koristnih podmnožic atributov** (ang. *feature subset selection*) je pogosto uporabljan proces v strojnem učenju, saj se pogosto izkaže za pametno potezo delati le z optimalno podmnožico atributov, ki še vedno vsebuje dovolj informacij za uspešnost učenja. Po eni strani nam namreč preveliko število atributov podaljšuje čas izvajanja učnega algoritma, po drugi pa nam preveliko število nekoristnih, naključnih in odvečnih atributov zmanjšuje uspešnost učenja. Ker je število vseh možnih podmnožic  $m$  atributov običajno preveliko ( $2^m$ ), ne moremo pregledati celotnega problemskega prostora in potrebujemo kakšno hevristiko za izbor dobrih podmnožic atributov:

- Preprost in hiter pristop k temu predstavlja **predobdelava podatkov** (ang. *filter approach*) [10], ki deluje tako, da ocenimo pomembnosti vseh atributov z želeno metodo (katero od prej naštetih ali to predstavljeno v diplomskem delu) in izberemo določeno število najboljše ocenjenih atributov.
- Naprednejši, a počasnejši pristop, pa predstavlja **metoda z ovojnico** oz. notranjo optimizacijo (ang. *wrapper approach*) [12]. Pri tem uporabimo ciljni učni algoritem kot podprogram, ki ga v notranjem prečnem preverjanju testiramo na različnih podmnožicah atributov dokler ne najdemo lokalnega optimuma. Najbolj pereča slabost teh metod je velika računska zahtevnost, zato se jih pogosto uporablja kot dopolnilo osnovnim s predobdelavo podatkov. Kot se bo videlo v nadaljevanju spominja v tem diplomskem delu predstavljena metoda za ocenjevanje pomembnosti atributov na pristop z ovojnico. Vendar gre pri tem za posplošitev ideje, saj omogoča uporabljati drug učni algoritem in tehniko ocenjevanja za izbor atributov od tiste uporabljene pri končnem učenju.

Ker je problemski prostor vseh možnih podmnožic atributov ogromen, se ga običajno preiskuje s požrešnim algoritmom, ki ga vodijo ocene oz. napake obiskanih stanj. Pri tem se mora računati napake na množici za preverjanje in ne tisti za učenje, saj se s tem izognemo prekomernemu prileganju. Najpogosteje tehnike preiskovanja so:

- Iskanje naprej (ang. *forward selection*), kjer začnemo s prazno množico in dodajamo v vsakem nadalnjem koraku po en ali naključno izbran ali najboljše ocenjen atribut vse dokler se napaka še zmanjšuje.
- Vzvratno iskanje (ang. *backward search*), kjer začnemo z vsemi atributi in jih postopoma odstranjujemo dokler napaka ne začne naraščati.
- Kombinirani pristop, kjer začnemo z naključno podmnožico atributov in v nadalnjih korakih ali dodajamo nove atrubute kot pri iskanju naprej ali odstranjujemo obstoječe kot pri vzvratnem iskanju.

**Izluščevanje značilk** (ang. *feature extraction*) je drug pristop za zmanjševanje števila dimenzij, katerega predstavnik je na primer metoda PCA (ang. *Pricipal component analysis*) [16, 9]. Gre za proces pretvorbe ogromne količine pretirano odvečnih oz. soodvisnih vhodnih podatkov (veliko podatkov, ki ne vsebujejo veliko informacije) v zmanjšano predstavitev z množico značilk. Pravilno izbrane značilke bodo nosile koristne informacije iz vhodnega nabora podatkov in bodo, ker jih je manj, toliko bolj učinkovite v nadaljevanju.

**Določanje uteži atributov** (ang. *feature/attribute weighting*) [20] predstavlja idejo, da naj učni algoritmi obravnavajo različne atrubute z različnimi utežmi, saj niso vsi enako pomembni za rešitev danega problema.

**Konstruktivna indukcija** je postopek izdelave novih atrubutov s kombiniranjem prvotnih tako, da bodo primernejši za dani problem in izbrani učni algoritem.

Z raziskovanje danega nabora podatkov, ocenjevanjem pomembnosti atrubutov, odkrivanjem interakcij in gradnjo raznih modelov se lahko iz podatkov tudi kaj naučimo in dobimo boljšo predstavo o realnem sistemu, ki jih je ustvaril.

---

---

## Poglavlje 3

---

# Ocenjevanje pomembnosti atributov iz uspešnosti učnih algoritmov na vzorcih atributnega prostora

Nov pristop pri ocenjevanju pomembnosti atributov predstavlja sledeča metoda, ki temelji na upoštevanju vpliva vzorcev atributnega prostora na uspešnost učnih algoritmov. Sama ideja metode je preprosta in zelo splošna, zato se jo tudi lahko uporablja v bistveno drugačnih okoljih z različnimi izbirami njenih komponent.

Ocenjevanje pomembnosti atributov iz danega nabora podatkov poteka s ponavljajočim postopkom. Najprej izbiramo oz. vzorčimo različne poddomene oz. podmnožice atributov. Upoštevajoč njih pripravljam nabore podatkov z manj atributi na katerih s postopkom vzorčenja in testiranja ocenjujemo uspešnost poljubnega učnega algoritma. S tem dobimo za vsak vzorec oz. podmnožico atributov, ki nas zanima, ustrezno oceno uspešnosti. Zbrane rezultate na koncu statistično obdelamo in združimo v končne ocene pomembnosti po posameznih atributih.

Tako pridobljeni končni rezultati odražajo koliko je posamezen atribut doprinesel k uspešnosti učnega algoritma in so zato primera mera za ocenjevanje pomembnosti atributov. Natančneje povedano odražajo kako uspešne so bile kombinacije atributov v katerih je posamezen nastopal in so seveda odvisne od izbire komponent uporabljenih za delovanje metode. Tako pomembnost tukaj pomeni vpliv in ne predstavlja nujno pravo pomembnost oz. kvaliteto atributov. V bistvu je le-ta skoraj vedno neznana ali se jo zato le okvirno ocenjuje. Pri tem še velja omeniti, da metoda, tako kot ostale za ocenjevanje pomemb-

nosti, skuša najti vse pomembne atributte. Kar pomeni, da na koncu predstavi vsak atribut posebej, neodvisno od ostalih, in s tem zakrije njihove medsebojne interakcije tako, da na primer vse odvečne (ang. *redundant*) informativne atributte oceni približno enako dobro. Seveda pa je metodo tudi možno uporabiti za odkrivanje interakcij med atributti (okvirne ideje v poglavju 5.1), a to presegajo obseg tega diplomskega dela.

Obravnavano metodo se tako lahko razdeli na sledeče komponente oz. vstavljeni module, ki so med seboj skoraj neodvisni:

- **generator podmnožic atributov** (poglavlje 3.1), ki ustvarja različne podomene s kombinacijami atributov in tako skrbi za pripravo podatkov
- **ocenjevalni model** (poglavlje 3.2), ki predstavlja postopek vzorčenja in testiranja
- **učni algoritem** (poglavlje 3.3), ki je načeloma lahko poljuben, a se v nadaljevanju obravnavajo le klasifikacijski
- **vrednotenje uspešnosti** (poglavlje 3.4) mora biti združljivo z izbranim učnim algoritmom
- **združevanje rezultatov** (poglavlje 3.5) v končne ocene pomembnosti atributov s pomočjo statistične analize in normalizacije

Visoka stopnja nastavljalnosti, ki izhaja iz splošnosti postopka, ki mu lahko podamo najrazličnejše kombinacije komponent, ki so običajno tudi same po sebi nastavljeni, prinese s seboj težavno odločitev izbire dobrih ali celo optimálnih parametrov. V okviru tega se pojavi osnovno vprašanje kaj sploh so dobri rezultati, ki jih želimo doseči. Odgovori so lahko različni glede na namen in, ker je namen diplomske naloge čim boljše ocenjevanje prave pomembnosti atributov v sprejemljivem času, bo na tem temeljila naša ocenjevalna funkcija. Z ocenjevalno funkcijo lahko za dano kombinacijo parametrov sicer določimo njeno uspešnost, a za pregled vseh je kombinacij daleč preveč. Pri parametrovih metode gre namreč za ekstremno visoko dimenzionalni problemski prostor, saj imamo 5 nastavljenih komponent od katerih je možno vsako realizirati na praktično neomejeno število načinov. Povrhu še ne poznamo oblike kompleksnega problemskega prostora in se lahko z optimizacijskimi metodami dokaj hitro ujamemo v kakšnem lokalnem optimumu ter se tega morda sploh ne zavedamo. Temeljit in tudi malo manj temeljit pregled celotnega problemskega prostora za dani vhodni nabor podatkov je zaradi njegove neomejenosti in tudi časovne potratnosti praktično neizvedljiv.

Tekom preprostega preizkušanja različnih kombinacij in nastavitev komponent na raznolikih naborih podatkov so se izkazala kot dokaj dobra sledeča

kombinacija naključnega generatorja poddomen brez omejitev, testiranja z 1-kratnim proporcionalnim testom z razmerjem 70 : 30, preprostimi klasifikacijskimi drevesi kot učnim algoritmom, ocenjevanjem uspešnosti s klasifikacijsko točnostjo (ang. krat. *CA*) in združevanjem rezultatov kot povprečje kvadratov uspešnosti brez dodatne normalizacije. S kraticami opisanimi v nadalnjih podpoglavljih bi to pomenilo **Gr Tp1 tree CA Sa2**.

### 3.1 Generiranje podmnožic atributov

Prvi korak ponavljajoče zanke v metodi ocenjevanja pomembnosti atributov iz uspešnosti učnih algoritmov predstavlja generator podmnožic atributov. Za učni algoritmom, ki je v jedru metode, je namreč potrebno pripravljati ustrezne nabore podatkov na katerih se lahko uči in testira uspešnosti ter na njihovi podlagi sklepa o vplivu oz. pomembnosti atributov. Najpreprostejši način za to je preizkušanje različnih kombinacij atributov brez posebnih hevristik, ki se jih je tudi raziskalo.

Cilj izbiranja in ustvarjanja različnih poddomen oz. podmnožic obstoječih atributov vhodnega nabora podatkov je s čim bolj reprezentativnimi in koristnimi izbirami preleteti prostor vseh kombinacij. Na podlagi uspešnosti izbranih kombinacij atributov bo namreč skušal zadnji korak, združevanje rezultatov (poglavlje 3.5), pravilno sklepiti o pomembnostih atributov.

V okviru diplomske naloge se je tako preizkusilo sledeče tehnike pregledovanja oz. generiranja podmnožic atributov:

- **Generator vseh kombinacij** (krat. *Ga, all*) predstavlja idejo izčrpnegra preiskovanja vseh možnih kombinacij atributov. V bistvu gre za pregled celotne potenčne množice, ki ima  $2^m$  elementov, kjer je  $m$  število atributov.

Takšen faktor postane v praksi dokaj hitro resna omejitev, zato se ga lahko skuša delno zmanjšati z zgornjo in spodnjo omejitvijo za velikosti podmnožic. Po razmisleku se lahko pride do zaključka, da je najnižja smiselna spodnja meja enaka velikosti najmanjše še informativne kombinacije atributov. Za najvišjo smiselno zgornjo mejo pa velja, da mora obsegati vse posamične ali v kombinaciji z drugimi vsaj malo informativne attribute. Ti podatki so nam običajno neznani, zato v praksi ni splošnega recepta in je potrebno pregledati vse.

Variantna omejevanja vseh kombinacij je tudi pristop "izloči enega" (ang. *leave-one-out*), kjer se nastavi tako zgornja kot spodnja meja na  $m - 1$ . S tem preizkusimo kombinacije kjer le en atribut manjka, vsi ostali pa so prisotni, - teh je  $\binom{m}{m-1} = m$ . Izkaže se, da je ta pristop neuporaben

ob prisotnosti odvečnih (ang. *redundant*) atributov, saj bodo le-ti nosili informacijo odstranjenega atributa in se zato pri idealnem učnem algoritmu, ki se vedno nauči najboljši koncept glede na podane attribute, ne bi opazilo razlike v uspešnosti.

- **Naključni generator** (krat. `Gr`, `random`) predstavlja idejo naključnega vzorčenja prostora vseh možnih kombinacij atributov brez posebne logike (ang. *trivial random sampling*). Generator se torej zanaša na to, da bo dovolj velik naključen vzorec iz potenčne množice vseh poddomen reprezentativno predstavljal celotno potenčno množico. Kaj je dovolj veliko je seveda odvisno od števila atributov  $m$  in želene natančnosti. Za manjše vrednosti  $m$  se je izkazalo za solidno število naključnih kombinacij  $m^2$ .

Tako kot pri prejšnji tehniki je tudi tukaj možno omejevati zgornjo in spodnjo velikost podmnožice. V bistvu se lahko naredi še več in se kar določi porazdelitev naključne spremenljivke. Torej verjetnosti za izbiro velikosti podmnožic s katerimi nato vplivamo na generator vzorcev. V primeru, da želimo, da naši vzorci čim bolje odražajo pregled celotne potenčne množice, moramo izbirati velikosti vzorcev z verjetnostmi binomske porazdelitve ali vsaj njenim zveznim približkom, Gaussovo porazdelitvijo, ki se je zaradi hitrejšega izračuna tudi uporabljala.

- **Plavajoči generator** (krat. `Gt`, `float`) je ideja, kjer na začetku izberemo naključno podmnožico atributov in nato pri vsaki naslednji dodamo ali odstranimo kakšnega (podobno kot mešani pristop pri izbiranju koristnih podmnožic atributov). Sosednje kombinacije atributov v generiranem zaporedju so si tako med seboj podobne, kar pomeni da bomo za večino atributov videli kakšna je uspešnost, ko so prisotni, in kakšna, ko več niso, a je večina preostalih še vedno istih. Ker generator s svojim prestavljanjem na naključne kombinacije iz bližnje okolice v prostoru vseh podmnožic atributov spominja na počasno naključno plavanje, izhaja od tu tudi njegovo ime.

Podobno kot prej je tudi tukaj možno in smiselnno omejiti zgornjo in spodnjo mejo velikosti podmnožic, saj lahko v splošnem dodamo večje število atributov kot jih odstranimo ali obratno in ne želimo, da zaide v prenizke ali previsoke velikosti, kjer je okolica manjša. Ker gre za naključno plavanje čez kombinacije in tudi velikosti le-teh, sta smiselnii nastavitevi tudi zgornji omejitvi za število dodanih ali odstranjenih atributov v eni ponovitvi, ki nekako določata zgornjo mejo "hitrosti gibanja" skozi prostor kombinacij. Ta tehnika načeloma nima konca, zato jo je potrebno prekiniti po določenem času. Med testiranjem se jo je zato

omejilo na generiranje  $m^2$  kombinacij atributov.

- **Navaden pregibalni generator** (krat. `Gf`, `fold`) skuša odstraniti pomajkljivost prej omenjenih naključnih generatorjev, ki nimajo zagotovila, da bodo sploh kdaj ustvarili kombinacijo v kateri bo nastopal določen atribut. O atributu, ki sploh ni prisoten v nobeni izbrani podmnožici ali le par krat, namreč ne moremo kaj dosti povedati in sklepati na njegovo pomembnost. Tehnika pregibanja zato naključno razdeli vse attribute na *fold* množic brez ponavljanja, jih vrača kot kombinacije in postopek ponavlja želeno mnogo krat. Ker se vsak atribut pojavi v natanko eni podmnožici pri vsaki ponovitvi, prej omenjene nevarnosti več ni. Ideja spominja na tehniko prečnega preverjanja, a namesto da bi delovala na primerih, deluje na atributih.

Pri navadni tehniki pregibanja je tako smiselno govoriti o številu *fold* na koliko podmnožic razdelimo attribute oz. z njim povezanim številom priблиžne velikosti ustvarjenih podmnožic  $m'$ . Velikosti podmnožic namreč ne morejo biti vse enako velike v kolikor število atributov ni deljivo s *fold* in zato je zadnja podmnožica le manjši preostanek. Med preizkušanjem tehnike se je običajno za solidno izbiro izkazalo približno fiksirati velikost ustvarjenih podmnožic na  $m' = 5$ , za število ponovitev pa uporabiti  $4m'$ .

- **Pregibalni generator vseh velikosti** (krat. `G1`, `foldAll`) je nadgradnja prejšnje tehnike, kjer jo preprosto poganja za vse možne velikosti podmnožic atributov. Na takšen način se izogne potencialni težavi generiranja podmnožic le določene velikosti s katero ne moremo ugotoviti ničesar o uspešnosti večjih kombinacij atributov, ki so lahko le skupaj informativni.

Nastavljeni parametri za to tehniko so ponovno zgornja in spodnja meja velikosti generiranih podmnožic in število ponovitev za navaden pregibalni generator. Za solidno izbiro mej se je izkazalo imeti podmnožice velikosti med 5 atributi in 1/4 od vseh atributov (oz.  $fold = 4$ ).

Časovna zahtevnost celotne metode za ocenjevanje pomembnosti atributov je najbolj odvisna od izbrane tehnike in nastavitev generiranja podmnožic atributov. Le-ti namreč določajo kolikokrat se bo glavna zanka metode sploh ponovila in na koliko atributih se bo moral učni algoritem učiti. Zaradi tega je tudi prva tehnika pregleda vseh kombinacij praktično zdaleč najbolj neuporabna, čeprav bo zagotovo preizkusila vse informativne kombinacije atributov.

Pri generiranju podmnožic atributov se pojavi vprašanje zakaj ne bi skušali uporabiti ocen uspešnosti trenutnih kombinacij za vodenje generiranja. Ideja je

sicer dobra in si je možno zamisliti kakšne tehnike, ki jo uporablja (poglavlje 5.1), a pri tem ni smiselno uporabljati identičnih pristopov kot jih sorodne raziskave za namen izbora koristnih podmnožic atributov (ang. *feature subset selection*). Njihov cilj se namreč bistveno razlikuje od našega, saj mi ne želimo odkriti optimalne kombinacije atributov pri kateri bo učni algoritem deloval najboljše, vendar oceniti pomembnosti vseh atributov, tudi slabših oz. manj informativnih. Tako da vsi generatorji, ki temeljijo na idejah optimizacijskih metod in iščejo najuspešnejšo podmnožico atributov, odpadejo in jih je potrebno drugače zastaviti.

## 3.2 Ocenjevalni model

Ocenjevalni model za ocenjevanje uspešnosti učnega algoritma predstavlja poljuben kompatibilen postopek vzorčenja in testiranja. Jedro metode temelji na ocenjevanju uspešnosti kombinacij atributov in ta komponenta določa kako bo to potekalo.

Tako kot običajno je namen ocenjevalnega modela dobiti čim bolj pravilno in stabilno oceno. Pri tem se uporablja različne metode vzorčenja in razdeljevanja vhodnih podatkov, ki se jih v naslednji fazi posreduje učnemu algoritmu in kasneje njegove rezultate metodi za vrednotenje uspešnosti. Glede na potrebe ocenjevalnega modela se sledeči fazi ponavljata in s tem izboljšujeta natančnost rezultatov.

V okviru diplomske naloge se je preizkusilo sledeče postopke vzorčenja in testiranja:

- **Proporcionalni test** (krat. Tp) (ang. *proportion test*) je postopek pri katerem se nabor podatkov v podanem razmerju najprej naključno razdeli na učno in testno množico, na učni nauči učni algoritem ter na testni preverja uspešnost pridobljenega klasifikatorja. Običajno se razdeli v razmerju 70 : 30 s stratifikacijo, ki ohranja razmerja pripadnosti razredom. Postopek se nato večkrat ponovi za različne razdelitve (običajno 10-krat).

Histro varianto tega predstavlja 1-kratno vrednotenje z naključnim razbitjem na učno in testno množico (krat. Tp1) (ang. *1-time proportion test*) v razmerju 70 : 30, ki se je izkazal za dokaj solidno in hitro izbiro.

- **Prečno preverjanje** (krat. Tc) (ang. *CV, cross validation*) je verjetno najpogostejši ocenjevalni model za problem klasifikacije. Temelji na tem, da se nabor podatkov razdeli na želeno število podmnožic (običajno 10), nato na vseh razen eni uči učni algoritem in testira na izključeni.

Učenje in testiranje se ponovi za vsako od podmnožic ter tako pridobi zanesljivejšo meritev uspešnosti učnega algoritma na vhodnih podatkih.

Hitro varianto postopka predstavlja 3-kratno prečno preverjanje (krat. Tc3) (ang. *3-fold cross validation*), ki se je izkazala za dokaj solidno izbiro.

Posebno deterministično varianto pa predstavlja metoda "izloči enega" (krat. To) (ang. *leave-one-out*), ki je enaka  $n$ -kratnemu prečnemu preverjanju pri čemer predstavlja  $n$  število primerov v naboru podatkov.

Ker sama metoda ocenjevanja atributov v zadnji fazi združuje in normalizira pridobljene rezultate, ima tukaj izbrani ocenjevalni model le manjši vpliv na končni rezultat, a velik na časovno zahtevnost. Ravno zato je najpočasnejša metoda "izloči enega" vsekakor praktično neuporabna, hitre variante pa so se izkazale kot solidne izbire.

### 3.3 Učni algoritem

Poljuben izbrani učni algoritem predstavlja osnovno idejo pri tej metodi ocenjevanja pomembnosti atributov in vse ostalo je prilagojeno ter zgrajeno okoli njega. Predhodni koraki večinoma pripravljajo vhodne podatke, naslednji pa vrednotijo rezultate in sklepajo na pomembnosti atributov. Zaradi splošnosti metode je sam učni algoritem načeloma lahko poljuben v kolikor mu ustrezajo vhodni podatki in zna funkcija za vrednotenje uspešnosti interpretirati njegove rezultate. V diplomski nalogi in preizkušanju pa smo se omejili le na algoritme s področja klasifikacije z atributno predstavitvijo vhodnih podatkov.

Cilj učnega algoritma pri klasifikaciji je iz učnega nabora podatkov skonstruirati takšen klasifikator, ki bo sposoben nove vhodne primere iz testne množice čim bolj uspešno umestiti v pravilne razrede. Uspešnost se pri tem meri s funkcijami iz naslednjega poglavja.

Pri raziskovanju se je preizkusilo sledeče običajne učne algoritme, ki se jih lahko uporablja za klasifikacijo:

- **Metoda najbližjih sosedov** (krat. kNN) (ang. *k-Nearest Neighbours*) je algoritem za klasifikacijo novih primerov na podlagi  $k$  najbližjih sosedov iz učne množice. Najbližji sosed tukaj predstavlja tiste, ki so najbolj podobni obravnavanemu primeru glede na izbrano funkcijo razdalje (običajno evklidska mera).
- **Klasifikacijska drevesa** (krat. tree) (ang. *classification trees*) predstavljajo tehniko učenja klasifikacijskih modelov v obliki odločitvenih dreves. Pri teh listi določajo rezultat klasifikacije, notranja vozlišča pa

odločitve na podlagi atributov, ki so vodila do njih. Namen algoritma je konstruirati čim boljša klasifikacijska drevesa, ki bodo uspešno napovedovala neznani razred novih primerov.

Klasifikacijska drevesa spadajo verjetno med najbolj raziskane učne algoritme in za njih poznamo številna pravila za izbiro vozlišč, gradnjo in tudi izboljšanje uspešnosti. Med slednje spadajo tehnike rezanja (ang. *pruning*) s katerimi preprečimo prekomerno prileganje (ang. *overfitting*). V splošnem se za solidno izbiro izkaže pravilo za izbiranje atributov v vozliščih na podlagi pridobitka informacijskega razmerja (ang. *information gain ratio*) in naknadnim rezanjem (ang. *post-pruning*) z ocenjevanjem napake na podlagi  $m$ -ocene za  $m = 2$  (ang.  *$m$ -estimate*).

Poljuben učni algoritem je tudi možno uporabiti z metodami z ovojnico v ansamblu klasifikatorjev (ang. *ensemble wrapper method*) s tehnikami kot sta ‐bagging‐ (krajše za ‐bootstrap aggregation‐) in ‐boosting‐. Pri prvi zgradimo množico klasifikatorjev iz različnih vzorcev učnih podatkov, ki nato glasujejo o umestitvi novih primerov v razrede. Pri drugi pa ponavljamo učenje šibkih klasifikatorjev na obteženi množici primerov, kjer imajo tisti, ki so bili predhodno napačno klasificirani, višjo težo. Rezultat klasifikacije pa dobimo z obteženim glasovanjem šibkih klasifikatorjev glede na njihovo uspešnost na učnih podatkih. Zaradi hitrosti klasifikacijskih dreves se jih je preizkušalo tudi v kombinaciji s prvo metodo z ovojnico (krat. **bag tree**).

- **Metoda podpornih vektorjev** (krat. **SVM**) (ang. *support vector machines*) je tehnika gradnje hiperravnin v visoko dimenzionalnem prostoru ustvarjenim iz atributov s ciljem čim boljše ločitve med primeri, ki pripadajo različnim razredom. Dobra hiperravnina je tista meja, ki jih čim bolj loči in je hkrati najširša, tj. najdlje oddaljena od najbližjih primerov različnih razredov. Čiste ločitve s hiperravninami lahko dosežemo le, če so primeri linearно ločljivi, kar v praksi običajno ni res in zato poteka iskanje v še višje dimenzionalnem prostoru. Vanj na srečo ni potrebno preslikovati vsega, saj potrebujemo le vektorski produkt med vektorji primerov, ki ga določa posebna jedrna funkcija (ang. *kernel function*).

Pri algoritmu je možno nastavljati različne podrobnosti, ki za samo ocenjevanje pomembnosti atributov niso tako pomembne, zato bi se samo omenilo, da se je uporabljala varianta, ki najprej normalizira nabor podatkov, nato pa skuša najti boljše parametre za metodo podpornih vektorjev.

- **Naivni Bayesov klasifikator** (krat. **bayes**) (ang. *naive Bayes classifier*) je preprost verjetnostni klasifikator, ki temelji na uporabi Bayeso-

vega izreka ob naivni predpostavki stroge neodvisnosti atributov. Ker le-ta pogosto ne velja, lahko v nekaterih primerih napoveduje zelo slabo. Tako v splošnem temelji naivni Bayesov klasifikator na enačbi 3.1:

$$p(C|A_1, \dots, A_m) = \frac{p(C)p(A_1, \dots, A_m|C)}{p(A_1, \dots, A_m)} \quad (3.1)$$

- **Metoda večinske klasifikacije** (krat. *majority classifier*) predstavlja najbolj neuporaben in preprost klasifikator, ki vse primere vedno uvrsti v večinski razred iz učne množice. Uporablja se le za primerjavo z ostalimi klasifikatorji, ki bi morali biti občutno uspešnejši od tega, če bi naj bili koristni.

Časovna zahtevnost in zahtevnost izračunov se med učnimi algoritmi močno razlikuje. Ker pa je poraba časa v tem koraku ključnega pomena za uporabnost celotne metode ocenjevanja pomembnosti atributov, se še bolj časovno potratnih algoritmov sploh ni preizkušalo. Med zgoraj naštetimi pa so se za različne vhodne podatke za dokaj soliden in hiter učni algoritmom izkazala kar običajna klasifikacijska drevesa.

## 3.4 Vrednotenje uspešnosti

Pridobitev ocen uspešnosti klasifikatorjev pride na vrsto v koraku testiranja učnega algoritma. Z izbrano metodo vrednotimo uspešnosti klasifikacij, kar se običajno uporablja za primerjanje učnih algoritmov med seboj, v tem primeru pa za ocenjevanje uspešnosti izbrane kombinacije atributov. Pogoj pri ocenjevalni funkciji predstavlja njena kompatibilnost z rezultati izbranega učnega algoritma in še dodatno, da imajo uspešnejše ocene višje vrednosti. Slednji pogoj teoretično ni potreben in bi se ga lahko upoštevalo v fazi združevanja ter sestavljanja končnih rezultatov, a zaradi preprostosti in razumljivosti so v nadaljevanju vse ocenjevalne funkcije takšne oblike.

Pri vrednotenju uspešnosti želimo izbrati takšno ocenjevalno funkcijo, ki bo za podani učni algoritmom v primeru, da se izkaže kot slab na izbrani podmnožici atributov, vrnila čim nižjo vrednosti in čim višjo, če je dober. Večja razlika bo namreč povišala zanesljivost in olajšala sklepanje o pomembnostih atributov fazi združevanja.

V okviru diplomske naloge se je preizkusilo nekaj ocenjevalnih funkcij za vrednotenje uspešnosti učnih algoritmov:

- **Klasifikacijska točnost** (krat. CA) (ang. *classification accuracy*) predstavlja razmerje med pravilno uvrščenimi testnimi primeri v razrede in

vsemi. V primeru binarnega razreda, kjer imamo pozitivne (oznaka  $TP$  za pravilno uvrščene pozitivne oz. ang. *true positive* in oznaka  $FP$  za napačno uvrščene oz. ang. *false positive*) in negativne primere (oznaka  $TN$  za pravilno uvrščene negativne oz. ang. *true negative* in oznaka  $FN$  za napačno uvrščene oz. ang. *false negative*), opisuje izračun enačba 3.2:

$$CA = \frac{TP + TN}{TP + FP + FN + TN} \quad (3.2)$$

- **Povprečna verjetnost** (krat. AP) (ang. *average probability*) računa povprečno verjetnost umestitve v pravilni razred.

$$AP = \frac{1}{n} \sum_X p(c|C=c) \quad (3.3)$$

kjer  $p(c|C=c)$  predstavlja verjetnost, da je klasifikator uvrstil v razred  $c$  pri pogoju, da je pravi razred  $C$  tudi  $c$ .

- **Bierjeva ocena** (krat. BrS) (ang. *Brier's score*) je definirana s sledečo enačbo 3.4:

$$BS = \frac{1}{n} \sum_c (p(c) - t(c))^2 \quad (3.4)$$

kjer  $c$  predstavlja razred,  $p(c)$  verjetnost, da je klasifikator uvrstil v razred  $c$ , in  $t(c)$  pa je 0 za napačen in 1 za pravilen razred.

- **Informacijska ocena** (krat. IS) (ang. *information score*) predstavlja na poseben način izračunan informacijski prispevek, ki je definiran v enem članku [15].
- **Ploščina pod krivuljo ROC** (krat. AUC) (ang. *area under receiver operating characteristic curve*) ocenjuje verjetnost, da bo za par primerov od katerih je eden v izbranem razredu in drug ni tudi pripisana večja verjetnost, da je v razredu. Pridobljena vrednost predstavlja ploščino pod ROC krivuljo, od koder tudi ime. V primeru večrazredne klasifikacije se je uporabljala varianta z izračunom povprečja AUC vseh parov razredov in tudi varianta z računanjem ploščin enega proti vsem ostalim (krat. AUC2).
- **Občutljivost** (krat. Se) (ang. *sensitivity*) predstavlja verjetnost pri binarni klasifikaciji, da je primer v razredu tudi bil uvrščen v ta razred kot opisuje enačba 3.5.

$$Sens = \frac{TP}{TP + FN} \quad (3.5)$$

- **Specifičnost** (krat. Sp) (ang. *specificity*) pa predstavlja verjetnost pri binarni klasifikaciji, da je primer, ki ni v razredu, tudi bil uvrščen, da ni v njem. Opisuje jo enačba 3.6:

$$Spec = \frac{TN}{TN + FP} \quad (3.6)$$

- **Koren povprečne kvadratne napake** (krat. RMSE) (ang. *root mean square error*) se običajno uporablja za ocenjevanje uspešnosti pri regresijskih problemih, a ga lahko uporabljamo tudi v drugih okoljih.

Vse omenjene ocenjevalne funkcije v praktično zanemarljivem času izračunajo svoje ocene. Za solidno izbiro se je izkazala kar klasifikacijska točnost, čeprav so ostale tehnike prav tako dobre.

## 3.5 Združevanje rezultatov

Zadnja faza nove metode ocenjevanja pomembnosti atributov je namenjena statistični obdelavi prej zbranih uspešnosti in njihovi združitvi v končne ocene. V okviru združevanja lahko poteka tudi normalizacija vrednosti, ki ocene naredi uporabne za kakšne druge namene.

Cilj združevanja je iz ocen o uspešnosti učnega algoritma na različno izbranih kombinacijah atributov sklepiti na vpliv oz. pomembnost posameznih atributov za dani učni algoritem. Z drugimi besedami to pomeni, da bi se naj atributu, za katerega so vse podmnožice v katerih je bil prisoten bile nadpovprečno uspešne, dodelila tudi višja ocena pomembnosti in ostalim, s podpovprečnimi uspešnostmi, nižja.

Med tehnikami združevanja in ocenjevanja pomembnosti atributov so se preizkusile sledeče formule:

- **Povprečna uspešnost** (krat. Sa) predstavlja izračun povprečne uspešnosti vsakega atributa  $A$  na vseh podmnožicah atributov v katerih je nastopal. Potencialno težavo pri računanju povprečne vrednosti predstavlja prevelika količina šuma v obliki kombinacij atributa, ki sam po sebi je informativen, s povsem neinformativnimi. Takšen šum lahko namreč hitro zasenči zelo visoko uspešnost katere od redkih uspešnih kombinacij. Tehniko opisuje sledeča enačba 3.7, kjer je  $z$   $s(\mathcal{V})$  označena

ocena uspešnosti učnega algoritma na preizkušeni podmnožici atributov  $\mathcal{V}$ .

$$f(A) = \operatorname{avg}_{A \in \mathcal{V}} s(\mathcal{V}) \quad (3.7)$$

- **Povprečje kvadratov (ali drugih potenc) uspešnosti** (krat. Sa2, avg2, avgExp) je podobno kot prej z razliko, da namesto povprečenja osnovnih uspešnosti povprečimo kvadrate vrednosti (ali celo višje potence) le-teh kot je prikazano v enačbi 3.8. Cilj potenciranja je omiliti učinek šuma, a hkrati ne preveč favorizirati slučajnih zelo uspešnih kombinacij.

$$f(A) = \operatorname{avg}_{A \in \mathcal{V}} s(\mathcal{V})^2 \quad (3.8)$$

- **Minimalna uspešnost** (krat. Sm, min) se poračuna kot najmanjša vrednost, ki se je pojavila med uspešnostmi vseh kombinacij atributov v katerih je nastopal opazovani atribut, kot je predstavljeno v enačbi 3.9. Ideja za tem je, da bo dober atribut, tudi ob prisotnosti najslabših drugih izbranih atributov pripomogel k višji uspešnosti. Po premisleku pa se lahko sklepa, da takšna ocena sploh ne bo delovala pri atributih s sinergijo, ki so informativni samo v kombinaciji z določenim drugim.

$$f(A) = \min_{A \in \mathcal{V}} s(\mathcal{V}) \quad (3.9)$$

- **Maksimalna uspešnost** (krat. SM, max) predstavlja idejo opazovanja za vsak atribut le najvišje dosežene uspešnosti učnega algoritma izmed vseh kombinacij v katerih je nastopal. Po premisleku pa se lahko ugotovi, da sploh ne bo delovala dobro ob prisotnosti kakšnega samostojnjega zelo informativnega atributa, ker bodo vse podmnožice v katerih je le-ta nastopal imele zelo visoko uspešnost in posledično ostali atributi iz teh podmnožic. Formula za njo:

$$f(A) = \max_{A \in \mathcal{V}} s(\mathcal{V}) \quad (3.10)$$

- **Povprečje zmanjšane uspešnosti** (krat. S/, DivM) predstavlja splošno idejo računanja povprečne pomembnosti atributa iz ocen uspešnosti, ki so bile zmanjšane za nek faktor, glede na vse kombinacije atributov, kjer je nastopal.

Prvo varianto tega predstavlja deljenje uspešnosti učnega algoritma s kvadratnim korenom števila atributov (krat.  $S/\sqrt{s}$ , DivSqrtM). S tem bi se favoriziralo in bolj upoštevalo manjše uspešne kombinacije atributov, kjer bi naj posamezni atributi več soprispevali k skupni uspešnosti kot pri večjih podmnožicah.

$$f(A) = \operatorname{avg}_{A \in \mathcal{V}} \frac{s(\mathcal{V})}{\sqrt{\operatorname{len}(\mathcal{V})}} \quad (3.11)$$

Druga varianta je zelo podobna, le da se uspešnosti za posamezne kombinacije delijo z logaritmom števila atributov (krat.  $S/\log l$ , DivLogM).

$$f(A) = \operatorname{avg}_{A \in \mathcal{V}} \frac{s(\mathcal{V})}{\log \operatorname{len}(\mathcal{V})} \quad (3.12)$$

- **Povprečje povečane uspešnosti** (krat.  $S*$ , MulM) predstavlja obratno idejo od prejšnje, kjer bi se vrednosti povečalo oz. pomnožilo za nek faktor. Ta ideja se je po pričakovanjih izkazala za zelo neuporabno pri praktičnih namenih.

Pridobljene rezultate iz združitve po atributih se lahko za nadaljnjo uporabo še normalizira. Ta korak je neobvezen in popolnoma neodvisen od prejšnjih, zato se lahko tu naštete tehnike normaliziranja uporabi tudi na drugih metodah za ocenjevanje pomembnosti atributov ter s tem omogoči okvirno primerjanje med njimi. Preizkusilo se je sledeče načine normaliziranja:

- **Rangiranje** (krat. NR, rank) je postopek v katerem vrednostim preprosto dodelimo range oz. uvrstitve na padajoče urejeni lestvici. Pri tem najvišja vrednost dobi rang 1, druga najvišja 2 in tako naprej. V primeru enakih vrednosti pa se jim dodeli povprečen rang.
- **Deljenje z največjim** (krat. N/M, DivMax) predstavlja deljenje vseh vrednosti z največjo po absolutni vrednosti med njimi. Le-ta tako postane ali 1 ali  $-1$ , vse ostale pa padejo na interval omejen z njima. Tako normalizirane vrednosti so običajno občutno zamaknjene proti eni od skrajnosti v kolikor njihova povprečna vrednost ni enaka 0, 0.
- **Odštevanje najnižjega in deljenje z dolžino intervala** (krat. N-m/I, SubMinDivInt) predstavlja idejo preslikati celoten seznam vrednosti na interval med 0 in 1.

- **Odštevanje povprečja in deljenje z največjim odstopanjem** (krat. N-A/D, SubMeanDivDiff) je postopek, kjer najprej izračunamo povprečno vrednost seznama ter jo odštejemo od vseh vrednosti, nato med novimi poiščemo največjo absolutno vrednost ter vse delimo še z njo. Takšna metoda ima prednost, da bo povprečje razporeditve vrednosti v seznamu poravnano okoli 0,0 in bodo vse vrednosti na intervalu med -1 in 1.
- **Odštevanje povprečja in deljenje s standardno deviacijo** (krat. N-A/SD, SubMeanDivStDev) predstavlja pogost pristop k normalizaciji seznama vrednosti. Najprej izračunamo povprečno vrednost in standardno deviacijo vrednosti seznama, nato pa vsem odštejemo povprečje ter delimo s standardno deviacijo. Postopek ima dobro lastnost, da je povprečje razporeditve poravnano okoli 0,0, koliko bodo izstopajoče vrednosti izstopale pa je odvisno od splošnega odstopanja vseh vrednosti.

V naslednjem poglavju so vsi rezultati eksperimentov vseh metod ocenjevanja pomembnosti atributov bili normalizirani s tehniko odštevanja povprečja in deljenja z največjim odstopanjem, ki se jo je označevalo kar s kratico N. S tem so se vse njihove vrednosti preslikale na interval med -1 in 1 s čimer se je omogočilo okvirno primerjanje njihovih rezultatov med seboj.

---

---

## Poglavlje 4

---

### Eksperimenti in rezultati

Kot je razvidno iz prejšnjih poglavij obstaja za metodo za ocenjevanje pomembnosti atributov iz uspešnosti učnih algoritmov na vzorcih atributnega prostora ogromno variacij. Nekatere od teh so se že pri preprostem preizkušanju izkazale za zelo slabe in se jih zato v nadaljevanju sploh ni obravnavalo. Med ostalimi, ki so se obravnavale v osnovni analizi, pa se je nekaj najboljših na koncu še podrobneje primerjalo med seboj.

Ker se je želelo v okviru diplomske naloge razvito metodo čim bolje preizkusiti in ovrednotiti njeno uspešnost, se je njene variante primerjalo še z nekaterimi drugimi bolj ali manj običajnimi razširjenimi metodami. Eksperimentiranje in primerjanje je tako potekalo na sledečih metodah, ki so že bile podrobneje opisane v poglavju 2, zato so tukaj naštete le bistvene lastnosti:

- **R<sub>e</sub>dF** oz. *RelievedF* [12] je deterministična varianta *Relieff* [13, 19].
- **RdFS** oz. *RelievedFS* je deterministična brezparametrična varianta metode *ReliefFS* [17], ki pa je nadgradnja *ReliefF*.
- **IGR** oz. *razmerje informacijskega prispevka* [18] je vrednost informacijskega prispevka normalizirana z atributno entropijo.
- **Gini** oz. *Gini indeks* [1] predstavlja verjetnost, da bosta dva naključno izbrana primera pripadala različnim razredom.
- **Chi2** oz. *mera s  $\chi^2$  statistiko* [21, 14] je poskus uporabe le-te za ocenjevanje pomembnosti atributov.
- **Dist** oz. *mera oddaljenosti* [2] je vrednost informacijskega prispevka normalizirana z združeno entropijo  $H(CA)$ .

- Log0 oz. logaritem razmerja obetov je statistična mera, ki računa logaritem razmerij verjetnosti pripadnosti razredu.

Pri metodi ocenjevanja pomembnosti atributov iz uspešnosti učnih algoritmov na vzorcih atributnega prostora obstaja veliko število možnih različnih kombinacij izbire modulov. Zaradi tega se je pripravilo poseben sistem poimenovanja le-teh pri katerem imajo vsi kot skupen del oznake kratico **Lea**. Dodatne pripone pa so odvisne od izbranih komponent in so podrobneje razložene v prejšnjih poglavjih. Eksperimentiralo in primerjalo se je s sledečimi variantami:

- **Lea** je osnovna varianta nove metode za ocenjevanje pomembnosti atributov iz uspešnosti učnih algoritmov na vzorcih atributnega prostora. Uporablja naključen generator poddomen brez omejitev, testira z 1-kratnim proporcionalnim testom z razmerjem 70 : 30, ima za učni algoritem preprosta klasifikacijska drevesa, uspešnost vrednoti s klasifikacijsko točnostjo (ang. krat. *CA*) in združuje rezultate kot povprečje kvadratov uspešnosti brez dodatne normalizacije. S kraticami opisanimi v prejšnjih poglavjih bi to pomenilo **Lea Gr Tp1 +tree CA Sa2**.
- **LeaGt** je varianta osnovne metode **Lea**, ki za generiranje podmnožic atributov uporablja plavajoči generator.
- **LeaGf** je varianta osnovne metode **Lea**, ki za generiranje podmnožic atributov uporablja navaden pregibalni generator.
- **LeaGl** je varianta osnovne metode **Lea**, ki za generiranje podmnožic atributov uporablja pregibalni generator vseh velikosti.
- **LeaTc3** je varianta osnovne metode **Lea**, ki za ocenjevalni model uporablja 3-kratno prečno preverjanje.
- **Lea+kNN euc** je varianta osnovne metode **Lea**, ki za učni algoritem uporablja metodo najbližjih sosedov.
- **Lea+bag tree** je varianta osnovne metode **Lea**, ki za učni algoritem uporablja “bagging” metodo z ovojnico ansambla klasifikacijskih dreves.
- **Lea+bayes** je varianta osnovne metode **Lea**, ki za učni algoritem uporablja naivni Bayesov klasifikator.
- **LeaAP** je varianta osnovne metode **Lea**, ki za vrednotenje uspešnosti uporablja povprečno verjetnost.

- 
- **LeaBrS** je varianta osnovne metode **Lea**, ki za vrednotenje uspešnosti uporablja Brierjevo oceno.
  - **LeaIS** je varianta osnovne metode **Lea**, ki za vrednotenje uspešnosti uporablja informacijsko oceno.
  - **LeaAUC** je varianta osnovne metode **Lea**, ki za vrednotenje uspešnosti uporablja ploščino pod krivuljo ROC, kjer se pri večrazredni klasifikaciji izračuna povprečje AUC vseh parov razredov.
  - **LeaAUC2** je varianta osnovne metode **Lea**, ki za vrednotenje uspešnosti uporablja ploščino pod krivuljo ROC, kjer se pri večrazredni klasifikaciji izračuna ploščino enega proti vsem ostalim.
  - **LeaSe** je varianta osnovne metode **Lea**, ki za vrednotenje uspešnosti uporablja občutljivost.
  - **LeaSp** je varianta osnovne metode **Lea**, ki za vrednotenje uspešnosti uporablja specifičnost.
  - **LeaRMSE** je varianta osnovne metode **Lea**, ki za vrednotenje uspešnosti uporablja koren povprečne kvadratne napake.
  - **LeaSa** je varianta osnovne metode **Lea**, ki za združevanje rezultatov uporabljala povprečno uspešnost.
  - **LeaSM** je varianta osnovne metode **Lea**, ki za združevanje rezultatov uporabljala maksimalno uspešnost.
  - **LeaS/s** je varianta osnovne metode **Lea**, ki za združevanje rezultatov uporabljala povprečje zmanjšane uspešnosti s kvadratnim korenom števila atributov.
  - **LeaG1Tc3AP** predstavlja eno varianto nove metode sestavljeno iz več različnih komponent z namenom doseči občutno boljše delovanje od osnovne metode **Lea**. Uporablja pregibalni generator poddomen vseh velikosti med 5 atributi in 1/4 od vseh atributov, 3-kratno prečno preverjanje, ima za učni algoritem preprosta klasifikacijska drevesa, uspešnost vrednoti s povprečno verjetnostjo in združuje rezultate kot povprečje kvadratov uspešnosti brez dodatne normalizacije.

Na vseh naštetih 27 metodah se je najprej izvedlo osnovno analizo, ki je izgledala kot 5-kratna ponovitev izvajanja eksperimentov na 192 variantah naborov podatkov opisanih v naslednjem poglavju. Zbrane rezultate ocen

pomembnosti atributov za vsako metodo na vsakem naboru podatkov se je nato normaliziralo in skušalo oceniti njihove uspešnosti glede na velikost vrzeli med pomembnimi informativnimi in nepomembnimi ostalimi atributi. Ocenam posameznih metod se je na vsakem naboru podatkov podelilo range iz katerih se je na koncu izračunalo povprečne range uspešnosti različnih metod. Za vrednotenje in razumevanje pridobljenih rezultatov se je še izvedelo statistični *Nemenyi test* s katerim se določa značilne oz. signifikantne razlike med testiranimi metodami.

Ker so bile pri osnovni analizi ocene pomembnosti atributov zaradi manjše ga števila ponovitev manj natančne in se je med seboj primerjalo veliko število metod, ki so povzročile visoko kritično razliko pri statističnem testu, se je najboljših 6 metod še podrobnejše analiziralo. S tem se je skušalo podkrepiti ugotovitev, da so nekatere variante nove metode res pogosto statistično signifikantno boljše od običajnih razširjenih metod za ta problem, ter natančneje določiti prednosti in slabosti najboljših. Na koncu se je izkazalo, da je izboljšana nadgradnja najboljše imenovana *RelievedFS* (krat. *RdFS*) skoraj vedno vsaj tako dobra kot najboljša varianta nove metode, vendar ne signifikantno boljša.

V nadaljevanju sledijo podrobnosti celotnega postopka.

## 4.1 Podatki

Eksperimentiranje je potekalo na ogromni množici različnih naborov podatkov s katerimi se je želelo pokriti različne lastnosti metod, ugotoviti v čem so dobre in kaj jim povzroča največje težave. Ker imamo v praksi pogosto opravka z majhno količino primerov in velikim številom atributov, se je v diplomske nalogi skušalo raziskati vpliv količine primerov v naborih podatkov z različnimi števili atributov. Pripravljeni nabori podatkov se delijo na simulacije oz. umetno ustvarjene podatke za katere so že v naprej poznane zakonitosti njihovega nastanka in realne podatke iz standardnih naborov podatkov.

**Simulirani nabori podatkov** so bili vsi umetno ustvarjeni v variantah z različnim številom atributov  $m$  (10, 20, 40, 80) in različnimi velikostmi množice primerov  $n$  (v osnovni 30, 60, 180 in pri podrobnejši analizi še dodatno 15, 120). Sledi seznam vseh umetno ustvarjenih naborov podatkov z opisi zakonitosti po katerih so bili ustvarjeni. V izrazih je množica atributov predstavljena z  $\mathcal{V} = A_0, \dots, A_{m-1}$ , ciljni razred pa s  $C$ . Vsi atributi, ki niso posebej omenjeni med pravili so bili ustvarjeni enakomerno naključno in bi morali biti nekoristni (ang. *irrelevant*).

- **only-a0** vsebuje preproste binarne atribute, ki sledijo pravilu:

$$C = A_0$$

- **modulo-2-2** vsebuje binarne atributte, ki ustrezajo družini naborov podatkov *Modulo-p-l* [19] (formula  $\tau(\mathcal{V}) = (\sum_{i=1}^l A_i) \text{ mod } p$ ) s pravilom:

$$C = A_0 \oplus A_1 = (A_0 + A_1) \text{ mod } 2$$

- **modulo-2-4** vsebuje binarne atributte in podobna pravila kot prej:

$$C = A_0 \oplus A_1 \oplus A_2 \oplus A_3$$

- **modulo-4-2** vsebuje atributte iz diskretne domene s 4 vrednostmi in podobna pravila kot prej:

$$C = (A_0 + A_1) \text{ mod } 4$$

- **modulo-8-2** vsebuje atributte iz diskretne domene z 8 vrednostmi in podobna pravila kot prej:

$$C = (A_0 + A_1) \text{ mod } 8$$

- **only-a0-cp-2** vsebuje binarne atributte, ki sledijo pravilom:

$$C = A_0$$

$$A_1 = A_0$$

$$A_2 = A_0$$

- **modulo-2-2-cp-1** vsebuje binarne atributte, ki sledijo pravilom:

$$C = A_0 \oplus A_1 = (A_0 + A_1) \text{ mod } 2$$

$$A_2 = A_0$$

$$A_3 = A_1$$

- **modulo-2-2-a1-cp-2** vsebuje binarne atributte, ki sledijo pravilom (v skladu z eno idejo iz [19]):

$$C = A_0 \oplus A_1 = (A_0 + A_1) \text{ mod } 2$$

$$A_2 = A_3 = A_1$$

- **modulo-2-2-irr-a2-cp** vsebuje binarne atributte, ki sledijo pravilom:

$$C = A_0 \oplus A_1 = (A_0 + A_1) \text{ mod } 2$$

$$A_3 = A_4 = \dots = A_{m-1} \quad (\text{odvečnost med nekoristnimi})$$

- **and-2** vsebuje binarne atributе od katerih imata  $A_0$  in  $A_1$  spremenjeno verjetnostno distribucijo ( $p(A_i = 1) = \sqrt{\frac{1}{2}}$ ) in se pravilo glasi:

$$C = A_0 \wedge A_1$$

- **and-4** vsebuje binarne atributе od katerih imata  $A_0$  in  $A_1$  spremenjeno verjetnostno distribucijo ( $p(A_i = 1) = \sqrt[4]{\frac{1}{2}}$ ) in se pravilo glasi:

$$C = A_0 \wedge A_1 \wedge A_2 \wedge A_3$$

- **if-a0-2** vsebuje binarne atributе, ki sledijo pravilu:

$$C = \begin{cases} A_1, & \text{če } A_0 = 0 \\ A_2, & \text{sicer} \end{cases}$$

- **if-a0-4** vsebuje atributе iz diskretne domene s 4 vrednostmi in podobno pravilo kot prej:

$$C = \begin{cases} A_1, & \text{če } A_0 = 0 \\ A_2, & \text{če } A_0 = 1 \\ A_3, & \text{če } A_0 = 2 \\ A_4, & \text{sicer} \end{cases}$$

- **bool-simple-1** vsebuje binarne atributе, ki sledijo pravilu (enaka formula kot v [19]):

$$C = (A_0 \oplus A_1) \vee (A_2 \wedge A_3)$$

**Realni podatki** iz UCI standardnega nabora [6], ki jih je vse razen zadnjega možno najti tudi v paketu *Orange* [4], so bili povprečno vzorčeni s ponavljanjem (ang. *stratified sample*) z različnimi velikostmi množic primerov  $n$  (v osnovni 30, 60, 180 in pri podrobnejši analizi še 15, 120). Atributi pri njih so zelo raznoliki in za vse razen enega sploh ne poznamo pravila oz. zakonitosti za določitev razreda, saj gre za podatke iz realnih zbirk. Eksperimentiranje je potekalo na ustrezno velikih podmnožicah sledečih realnih naborov podatkov:

- **adult** vsebuje 32561 primerov, ki so opisani z 8 kategoričnimi in 6 zveznimi atributti ter imajo binarni razred.
- **ionosphere** vsebuje 351 primerov, ki so opisani z 32 kategoričnimi in 0 zveznimi atributti ter imajo binarni razred.
- **lung-cancer** vsebuje 32 primerov, ki so opisani z 56 kategoričnimi in 0 zveznimi atributti ter imajo diskretni razred s 3 vrednostmi.

- **monks-1** vsebuje 556 primerov, ki so opisani s 6 kategoričnimi in 0 zveznimi atributi ter imajo binarni razred za katerega je znano pravilo:

$$C = (a == b) \vee (e == 1)$$

- **promoters** vsebuje 106 primerov, ki so opisani z 57 kategoričnimi in 0 zveznimi atributi ter imajo binarni razred.
- **voting** vsebuje 435 primerov, ki so opisani s 16 kategoričnimi in 0 zveznimi atributi ter imajo binarni razred.
- **zoo** vsebuje 101 primer, ki so opisani s 16 kategoričnimi in 0 zveznimi atributi ter imajo diskretni razred s 7 vrednostmi.
- **pima-indians** vsebuje 768 primerov, ki so opisani z 0 kategoričnimi in 8 zveznimi atributi ter imajo binarni razred.

## 4.2 Metodologija testiranja

Pri **osnovni analizi** se je vsak eksperiment za vsako od preizkušanih metod na vsakem naboru podatkov ponovil na naključno izbranih vzorcih po 5-krat tako, da so se iz rezultatov lahko poračunale povprečne vrednosti ocen in njihove standardne deviacije. Pripravilo se je 192 (168+24) raznolikih naborov podatkov, ki so sestavljeni iz 14 simuliranih naborov s po 4 različnimi števili atributov (10, 20, 40, 80) s po 3 velikostmi množic primerov (30, 60, 180) in iz 8 realnih naborov podatkov prav tako vzorčenih s 3 različnimi velikostmi množic primerov (30, 60, 180).

Kasneje se je 6 najboljših metod za ocenjevanje pomembnosti atributov pogledalo še **podrobnejše analiziralo**. Potevalo je podobno kot prej, a s 10 ponovitvami naključno izbranih vzorcev za računanje povprečja in standardne deviacije in z razliko, da se je vse nabore podatkov preizkušalo na 5 različnih velikostih množic primerov (15, 30, 60, 120, 180). Skupno to pomeni eksperimentiranje na 320 (280 + 40) različnih naborih podatkov.

Za namen primerjanja različnih metod med seboj je bilo potrebno določiti primerno funkcijo za ocenjevanje njihove uspešnosti. Osnovna načela na katerih naj temelji so, da naj vse vrednosti ustrezno normalizira in s tem omogoči primerjanje med njimi, ter, da boljše ocenjuje tiste, ki dobro ločijo med pomembnimi informativnimi ( $\mathcal{V}_T$ ) in ostalimi nekoristnimi oz. odvečnimi atributi ( $\mathcal{V}_R$ ) ter daje pomembnim nasploh višje ocene.

Pridobljene ocene pomembnosti atributov se je tako najprej normaliziralo s tehniko odštevanja povprečja in deljenja z največjim odstopanjem, ki je opisana v poglavju 3.5 in se jo je v rezultatih označevalo kar s kratico  $\mathbb{N}$ . S tem so se vse

njihove vrednosti preslikale na interval med  $[-1, 1]$ , kar je omogočilo okvirno primerjanje njihovih rezultatov.

Najprimernejši funkciji za vrednotenje uspešnosti metod za ocenjevanje pomembnosti atributov (povzeti po [19]) potrebujeta za svoje delovanje informacijo o tem kateri atributi so pomembni in kateri ne. To poznamo le pri **simuliranih naborih podatkov**, zato sta se lahko uporabljali samo na njih:

- **Ločljivost**  $s(W)$  (ang. *separability*) predstavlja razliko med najnižjo vrednostjo pomembnih informativnih atributov  $W_I$  in najvišjo med ostalimi odvečnimi  $W_R$  kot jo opisuje enačba (4.1). Za metodo ocenjevanja pomembnosti atributov rečemo, da dobro izpolni svojo nalogu, če ima  $s(W) > 0$ .

$$s(W) = (\min_{I \in \mathcal{V}_T} W_I) - (\max_{R \in \mathcal{V}_R} W_R) \quad (4.1)$$

- **Uporabnost**  $u(W)$  (ang. *usability*) pa predstavlja razliko med najvišjo vrednostjo pomembnih informativnih atributov in najvišjo med ostalimi odvečnimi po enačbi (4.2). Pri tem za metodo rečemo, da je vsaj malo uporabna, če je  $u(W) > 0$ , saj nam odkrije vsaj del pomembnih informacij oz. atributov. Med obema ocenama velja zveza  $u(W) \geq s(W)$ .

$$u(W) = (\max_{I \in \mathcal{V}_T} W_I) - (\max_{R \in \mathcal{V}_R} W_R) \quad (4.2)$$

Ker pa smo za namene testiranja pripravili tudi **realne nabore podatkov** pri katerih ne poznamo pomembnosti oz. informativnosti različnih atributov, se je za vrednotenje njihove uspešnosti pripravilo posebni funkciji, ki to približno omogočata. Zaradi svoje oblike delujeta sledeči funkciji na vseh naborih podatkov, vključno s simuliranimi:

- **Razpon vrednosti**  $t(W)$  je funkcija, ki vrne razliko med najvišjo in najnižjo vrednostjo kot je določeno v enačbi (4.3). Temelji na predpostavki, da imamo v realnem naboru podatkov nekaj bolj pomembnih atributov, ki jih bo metoda ocenila z najvišjimi vrednostmi, ter nekaj nekoristnih, ki bodo dobili najnižje ocene. V kolikor je to res in metoda dobro opravlja svoje delo, bo razlika med njimi visoka, sicer pa nizka. Izkazalo pa se je, da takšna funkcija daje previsoke ocene močno nestabilnim metodam.

$$t(W) = (\max_{A \in \mathcal{V}} W_A) - (\min_{A \in \mathcal{V}} W_A) \quad (4.3)$$

- **Povprečna standardna deviacija**  $v(W)$  je ocena uspešnosti pri kateri se poračuna povprečna vrednost med standardnimi deviacijami ocen pomembnosti posameznih atributov pri ponavljanju poskusa na naključnih vzorcih iz istega nabora podatkov po enačbi (4.4). Ta ocena ne meri uspešnosti pri ločevanju med pomembnimi informativnimi in nekoristnimi ostalimi atributi, temveč bolj zanesljivost ocen, ki jih vrača izbrana metoda. Pri dobri metodi bi namreč bilo zaželeno imeti višjo stabilnost rezultatov in manjšo občutljivost na slučajne pojave.

$$v(W) = -\operatorname{avg}_{A \in \mathcal{V}} \operatorname{stdev}(W_A) \quad (4.4)$$

Ker naštete funkcije za vrednotenje uspešnosti ocenjujejo dokaj različne stvari, se je pri obeh analizah preizkusilo vse, a se zaradi obsežnosti ni v okviru diplomskega dela podrobno predstavilo vseh. Zaradi želje po združitvi in krajsi predstavitvi rezultatov se je za primarno funkcijo za vrednotenje uspešnosti metod in rangiranje sestavilo kar **kombinacijo** ločljivosti  $s(W)$  in razpona vrednosti  $t(W)$ . Odločitev o tem katera funkcija se bo dejansko uporabila je odvisna od nabora podatkov in kaj vemo o njem, tako da se je za simulirane nabore podatkov uporabljala prva, za realne pa druga funkcija.

Za vrednotenje uspešnost metod na posameznih naborih podatkov se je tako vzela normalizirana kombinirana ocena na kateri se je poračunalo statistični *Nemenyi test* za primerjavo vseh metod z vsemi [3]. Statistično gledano je za primerjavo  $k$  metod med seboj potrebno izvesti  $\frac{k(k-1)}{2}$  elementarnih primerjav oz. dokazati ali ovreči toliko različnih statističnih hipotez. Z velikim številom primerjav pa se seveda veča nevarnost, da je katera razlika v uspešnosti popolnoma slučajno značilna oz. signifikantna. Za zmanjšanje negotovosti je potrebno izvesti toliko večje število eksperimentov na različnih naborih podatkov, kar je razlog, da se jih je toliko pripravilo. Za *Nemenyi test* se je najprej določilo vsem metodam na vsakem od  $n$  naborov podatkov range glede na ocene uspešnosti. Nato se je iz njih izračunalo nekaj bolj zanimivih povprečnih rangov za vsako metodo ter na koncu iz njih v skladu z *Nemenyi testom* z  $\alpha = 0,05$  poračunalo kritično razliko po enačbi (4.5) (ang. *critical difference, CD*). Le-ta nam pove katere razlike povprečnih rangov dveh metod ( $\overline{R}_i$  in  $\overline{R}_j$ ) se smatrajo za značilno oz. signifikantno različne in katere ne. Z drugimi besedami kdaj je bila nična hipoteza, da sta obe metodi enako uspešni zavrnjena z želeno stopnjo zaupanja.

$$|\overline{R}_i - \overline{R}_j| \geq CD = q_\alpha \sqrt{\frac{k(k+1)}{6n}} \quad (4.5)$$

## 4.3 Rezultati

Ker se je tekom celotnega procesa preizkušanja proizvedla ogromna količina podatkov, teh še zdaleč ni možno v celoti podrobno predstaviti v tej diplomski nalogi, kaj šele v tem poglavju. Za boljšo predstavo obsega sledi okvirni seznam pridobljenih vmesnih podatkov in rezultatov:

- Za vsak pripravljen nabor podatkov se je ustvarilo za vse velikosti in števila atributov po 5 vzorcev v osnovni in po 10 vzorcev v podrobni analizi. To predstavlja skupno 960 in 3200 manjših naborov podatkov za nadaljne delo.
- Na vseh teh se je nato izvajalo vseh 27 v osnovni in 6 v podrobni analizi izbranih metod ocenjevanja pomembnosti atributov in poračunalo povprečne ocene ter njihove standardne deviacije. Iz tega je torej nastalo 192 in 320 tabel z rezultati vseh preizkušanih metod. Implementacija metode in preizkušanja v okolju *Orange* [4] je na sodobnem procesorju potrebovala približno 13 dni. Manjši primer rezultatov je v tabeli 4.1.
- Na tako pridobljenih vmesnih rezultatih se je s prej omenjenimi funkcijami za vrednotenje uspešnosti različnih metod primerjalo in določilo njihove range. Iz tega sta nastali dve ogromni pomembni združeni tabeli ocen uspešnosti in rangov metod na vseh raznolikih naborih podatkov, ki ju lahko za najdete v dodatkih B in D.
- Ker gre za ogromni več strani dolgi tabeli in se je želelo primerjati metode med seboj, se je poračunalo za vsako metodo različna zanimiva povprečja (tabeli 4.2 in 4.4), izvedlo na njih statistični *Nemenyi test* in vizualiziralo rezultate primerjave s kritično razliko. Vrednosti povprečnih rangov in pomembnejši grafi le-teh so predstavljeni v tem poglavju, ostali pa v dodatku A za osnovno analizo in dodatku C za podrobno analizo.

Za namen primerjave različnih metod med seboj so od vseh teh podatkov zagotovo najpomembnejše povprečne ocene uspešnosti in na podlagi njih izračunani povprečni rangi, ki so bili opisani v prejšnjem podpoglavlju. Primer teh povprečnih uspešnosti za kombinirano funkcijo je predstavljen v tabeli 4.2. V njej si za vsako metodo sledijo povprečne vrednosti funkcij  $s(W)$  ali  $t(W)$  (kombinirana funkcija), povprečne vrednosti funkcij  $u(W)$  ali  $v(W)$  in na koncu povprečni rangi glede na kombinirano funkcijo. Za prvi dve vrednosti v tem primeru je sicer vprašanje ali ju je smiselno neposredno interpretirati, saj se je tam povprečilo po različnih funkcijah za vrednotenje uspešnosti. Tretja vrednost oz. povprečni rang pa nam dejansko pove veliko o uspešnosti vsake

| Attr | <i>RedFN</i> | <i>RdFSN</i> | <i>LogON</i> | <i>LeaN</i>  | <i>LeaGIc3APN</i> | <i>LeaTc3N</i> |
|------|--------------|--------------|--------------|--------------|-------------------|----------------|
| a00  | 0.965 0.165  | 1.000 0.221  | -0.248 0.338 | 0.820 0.714  | 1.000 0.542       | 0.892 0.485    |
| a01  | 1.000 0.168  | 0.892 0.130  | -0.175 0.518 | 1.000 0.659  | 0.915 0.584       | 1.000 0.395    |
| a02  | 0.258 0.263  | 0.086 0.188  | 0.840 0.304  | 0.145 0.530  | 0.190 0.388       | 0.146 0.453    |
| a03  | 0.413 0.485  | 0.123 0.194  | 1.000 0.436  | -0.043 0.610 | 0.137 0.582       | 0.031 0.522    |
| a04  | -0.474 0.074 | -0.364 0.075 | -0.388 0.179 | -0.421 0.536 | -0.277 0.477      | -0.411 0.498   |
| a05  | -0.450 0.131 | -0.356 0.053 | -0.244 0.428 | -0.382 0.452 | -0.437 0.372      | -0.482 0.438   |
| a06  | -0.445 0.106 | -0.356 0.034 | -0.492 0.348 | -0.171 0.458 | -0.308 0.438      | -0.164 0.386   |
| a07  | -0.435 0.131 | -0.348 0.041 | -0.134 0.330 | -0.333 0.569 | -0.395 0.502      | -0.413 0.495   |
| a08  | -0.431 0.113 | -0.345 0.049 | -0.130 0.288 | -0.276 0.454 | -0.477 0.373      | -0.324 0.340   |
| a09  | -0.402 0.117 | -0.332 0.074 | -0.029 0.384 | -0.340 0.524 | -0.348 0.396      | -0.275 0.451   |

**Tabela 4.1:** Primer manjše tabele z normaliziranimi ocenami pomembnosti atributov s standardnimi deviacijami za izbrane metode pri podrobni analizi na simuliranem naboru podatkov **bool-simple-1** z 10 atributi in 120 primeri.

|              | <i>RedFN</i>  | <i>RdFSN</i> | <i>IGRN</i>  | <i>GiniN</i>              | <i>Chi2N</i>        | <i>DistN</i>        |
|--------------|---------------|--------------|--------------|---------------------------|---------------------|---------------------|
| avg-gen      | 0.029 0.443   | 12.708       | 0.489 0.858  | 7.923 -0.359 0.140 15.833 | -0.385 0.132 17.179 | -0.376 0.135 17.155 |
| avg-real     | 1.533 -0.217  | 13.083       | 1.625 -0.293 | 9.958 1.444 -0.124 14.733 | 1.447 -0.120 14.200 | 1.414 -0.115 14.800 |
| avg-size-030 | -0.275 -0.007 | 16.844       | 0.388 0.521  | 8.969 -0.341 0.029 15.803 | -0.373 0.014 16.836 | -0.363 0.022 17.000 |
| avg-size-060 | 0.329 0.453   | 11.687       | 0.650 0.751  | 8.602 -0.181 0.106 15.713 | -0.203 0.101 16.951 | -0.199 0.102 16.893 |
| avg-size-180 | 0.597 0.635   | 9.734        | 0.855 0.872  | 6.961 -0.111 0.220 15.713 | -0.128 0.219 17.016 | -0.127 0.219 16.992 |
| avg-all      | 0.217 0.360   | 12.755       | 0.631 0.714  | 8.177 -0.211 0.118 15.743 | -0.235 0.111 16.934 | -0.230 0.114 16.962 |

|              | <i>LogON</i> | <i>LeaN</i>  | <i>LeaGIc3APN</i>   | <i>LeaGtN</i>       | <i>LeaGfN</i>      | <i>LeaGiN</i>       | <i>LeaTc3N</i>     |
|--------------|--------------|--------------|---------------------|---------------------|--------------------|---------------------|--------------------|
| -0.104 0.376 | 13.337       | 0.333 0.711  | 9.887 0.355 0.730   | 11.286 0.123 0.588  | 16.329 0.177 0.627 | 15.095 0.222 0.654  | 14.009 0.385 0.755 |
| 1.448 -0.180 | 11.667       | 1.579 -2.373 | 12.271 1.521 -0.876 | 14.750 1.660 -3.439 | 9.125 1.595 -1.258 | 11.375 1.639 -1.278 | 9.042 1.477 -1.553 |
| -0.112 0.307 | 12.011       | 0.241 -0.001 | 10.297 0.239 0.312  | 11.922 0.115 -0.147 | 14.078 0.123 0.201 | 14.500 0.139 0.148  | 13.852 0.269 0.184 |
| -0.081 0.360 | 13.489       | 0.478 0.302  | 10.055 0.535 0.549  | 11.289 0.285 0.019  | 15.905 0.378 0.391 | 13.687 0.369 0.437  | 13.859 0.527 0.477 |
| -0.014 0.423 | 14.400       | 0.748 0.675  | 10.203 0.728 0.729  | 11.945 0.548 0.373  | 16.297 0.563 0.584 | 15.703 0.689 0.651  | 12.453 0.768 0.740 |
| -0.069 0.363 | 13.300       | 0.489 0.325  | 10.185 0.501 0.530  | 11.719 0.316 0.082  | 15.424 0.355 0.392 | 14.630 0.399 0.412  | 13.388 0.522 0.467 |

| <i>Lea + kNNeuCN</i> | <i>Lea + bagtreeN</i> | <i>Lea + bayesN</i> | <i>LeaAPN</i>        | <i>LeaBrSN</i>      | <i>LeaISN</i>       | <i>LeaAUCN</i>      |
|----------------------|-----------------------|---------------------|----------------------|---------------------|---------------------|---------------------|
| 0.363 0.758          | 11.423                | 0.342 0.743         | 9.970 -0.356 0.180   | 18.024 0.358 0.712  | 9.214 -1.345 -0.942 | 24.030 0.319 0.697  |
| 1.680 -3.128         | 8.292                 | 1.544 -2.191        | 13.125 1.566 -2.918  | 10.875 1.584 -2.361 | 12.771 1.604 -2.242 | 10.875 1.512 -2.135 |
| 0.260 0.046          | 11.953                | 0.234 0.105         | 10.547 -0.238 -0.458 | 16.594 0.281 -0.002 | 9.367 0.984 -1.166  | 21.031 0.142 -0.004 |
| 0.559 0.427          | 10.641                | 0.502 0.340         | 9.781 -0.119 -0.265  | 16.977 0.494 0.309  | 9.648 0.989 -1.129  | 22.766 0.502 0.371  |
| 0.764 0.346          | 10.500                | 0.742 0.684         | 10.766 0.009 0.101   | 17.820 0.759 0.676  | 9.961 0.955 -1.018  | 23.359 0.760 0.661  |
| 0.528 0.273          | 11.031                | 0.492 0.376         | 10.365 -0.116 -0.207 | 17.130 0.512 0.328  | 9.659 0.976 -1.104  | 22.385 0.468 0.343  |

| <i>LeaAUC2N</i> | <i>LeaSeN</i> | <i>LeaSpN</i> | <i>LeaRMSEN</i>     | <i>LeaSaN</i>        | <i>LeaSMN</i>       | <i>LeaS/sN</i>           |
|-----------------|---------------|---------------|---------------------|----------------------|---------------------|--------------------------|
| 0.315 0.690     | 10.199        | 0.341 0.732   | 13.542 0.333 0.762  | 13.917 -1.326 -0.912 | 23.714 0.307 0.697  | 11.280 0.250 0.015       |
| 1.551 -2.486    | 12.500        | 1.523 -2.482  | 13.278 1.665 -2.334 | 8.111 1.584 -2.096   | 11.750 1.584 -2.348 | 12.000 1.246 -417.787    |
| 0.205 0.066     | 10.914        | 0.220 0.113   | 14.430 0.279 0.237  | 12.440 -0.956 -1.081 | 21.109 0.240 0.003  | 10.797 0.173 -0.128      |
| 0.453 0.287     | 10.672        | 0.524 0.243   | 13.520 0.476 0.416  | 14.310 -0.967 -1.075 | 22.297 0.428 0.278  | 12.141 0.22.058 -156.369 |
| 0.753 0.527     | 9.875         | 0.705 0.682   | 12.580 0.722 0.518  | 12.910 -0.965 -1.025 | 23.250 0.731 0.667  | 11.172 0.040 -0.133      |
| 0.470 0.293     | 10.487        | 0.483 0.346   | 13.510 0.492 0.390  | 13.220 -0.963 -1.060 | 22.219 0.466 0.316  | 11.370 0.063 -52.210     |

**Tabela 4.2:** Primer različnih povprečih ocen uspešnosti s povprečnimi rangi za kombinirano funkcijo na vseh 27 metodah za ocenjevanje pomembnosti atributov pri osnovni analizi.

metode v primerjavi z ostalimi, ker se je v kombinirani funkciji skušalo za oba tipa naborov uporabiti tiste, ki najbolj sledijo željenim lastnostim.

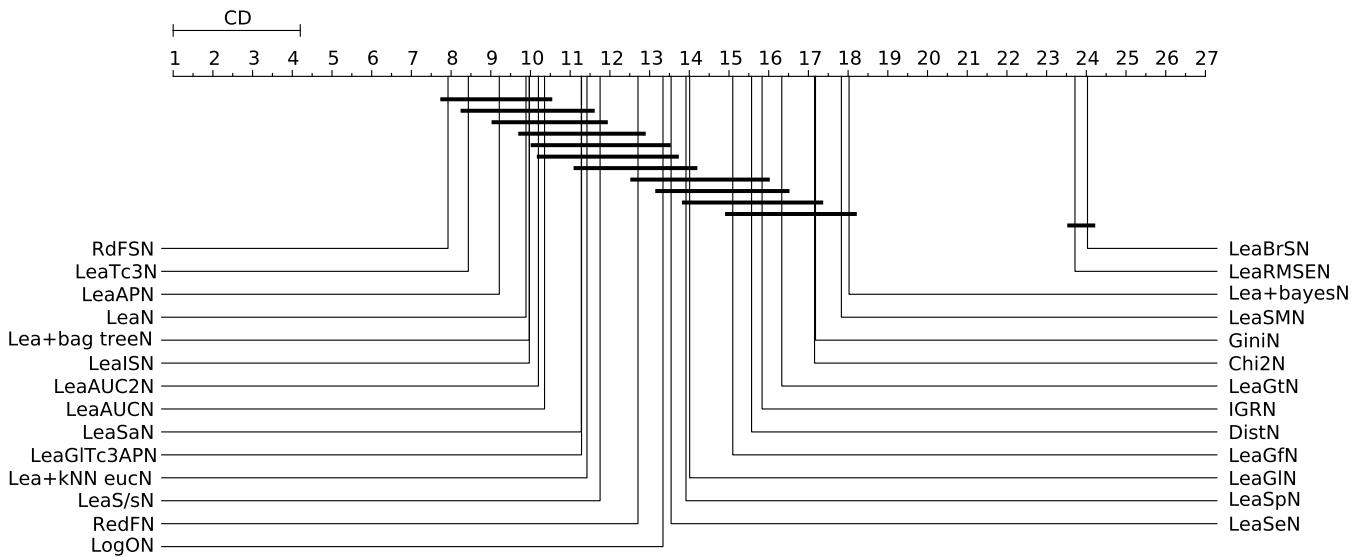
Točno na teh povprečnih rangih pa bazira poseben statistični test, ki omogoča primerjavo vseh metod z vsemi, določitev kritične razlike in odkrivanje statistično signifikantnih razlik med metodami. Na celotni združeni tabeli z ocenami uspešnosti metod se je tako izvedlo *Nemenyi test* z  $\alpha = 0,05$  na vsakem od poračunanih povprečnih rangov. Le-ta glede na število izvedenih eksperimentov določi kritične razlike (*CD*), ki omogočajo preprosto vizualno predstavo rezultatov uspešnosti različnih metod. V tabeli 4.3 so predstavljene vse kritične razlike pri **osnovni analizi**.

| Povprečje                 | Naborov podatkov | Kritična razlika ( <i>CD</i> ) |
|---------------------------|------------------|--------------------------------|
| avg-all <sup>1</sup>      | 192              | 2.994437                       |
| avg-gen <sup>1</sup>      | 168              | 3.201188                       |
| avg-real <sup>1</sup>     | 24               | 8.469546                       |
| avg-size-030 <sup>1</sup> | 64               | 5.186517                       |
| avg-size-060 <sup>1</sup> | 64               | 5.186517                       |
| avg-size-180 <sup>1</sup> | 64               | 5.186517                       |
| avg-all <sup>2</sup>      | 168              | 3.201188                       |
| avg-size-030 <sup>2</sup> | 56               | 5.544620                       |
| avg-size-060 <sup>2</sup> | 56               | 5.544620                       |
| avg-size-180 <sup>2</sup> | 56               | 5.544620                       |

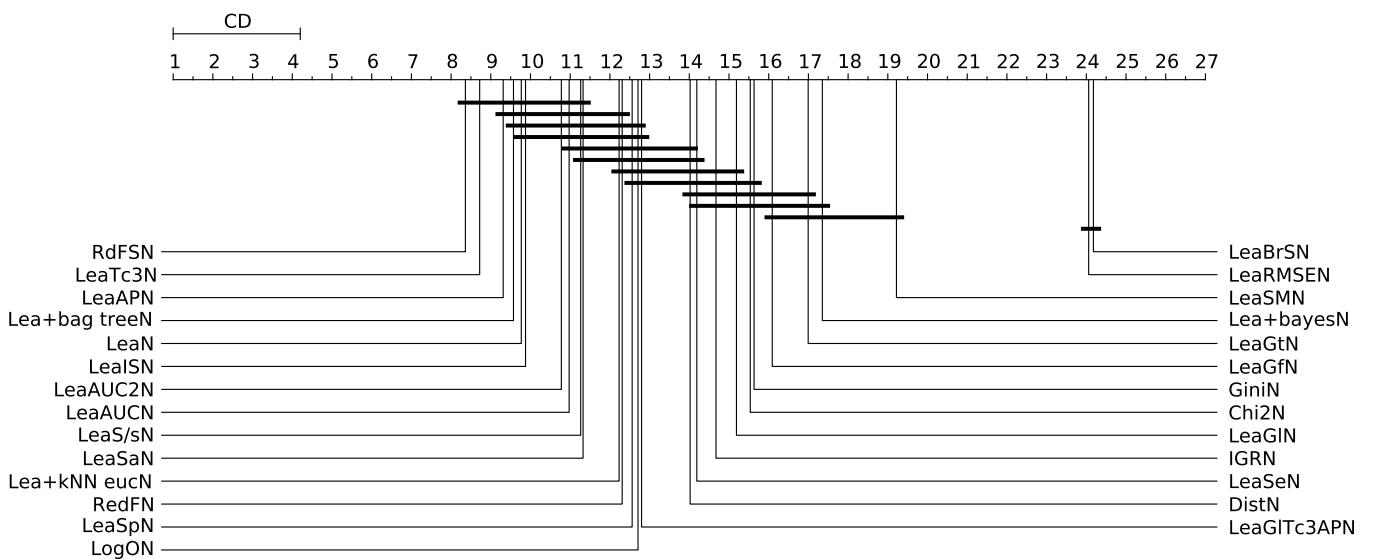
**Tabela 4.3:** Kritične razlike (ang. critical difference) za povprečne range funkcij za vrednotenje uspešnosti vseh 27 metod pri osnovni analizi pri Nemenyi testu z  $\alpha = 0,05$ . <sup>(1)</sup> označuje kombinirano funkcijo,  $t(W)$  in  $v(W)$ , <sup>(2)</sup> pa  $s(W)$  in  $u(W)$ .

Za lažje razumevanje in primerjanje povprečnih rangov vsake od funkcij za vrednotenje uspešnosti preizkušenih metod se jih je tudi vizualiziralo. Ker se različne funkcije za vrednotenje uspešnosti med seboj razlikujejo, se med seboj razlikujejo tudi grafi ustvarjeni z njimi. Vseh grafov je daleč preveč, zato so pri osnovni analizi predstavljeni le povprečni za vse nabore podatkov, da se prikaže razlike med ocenjevalnimi funkcijami, v nadaljevanju pa se bo uporabljala le še kombinirana funkcija za vrednotenje uspešnosti.

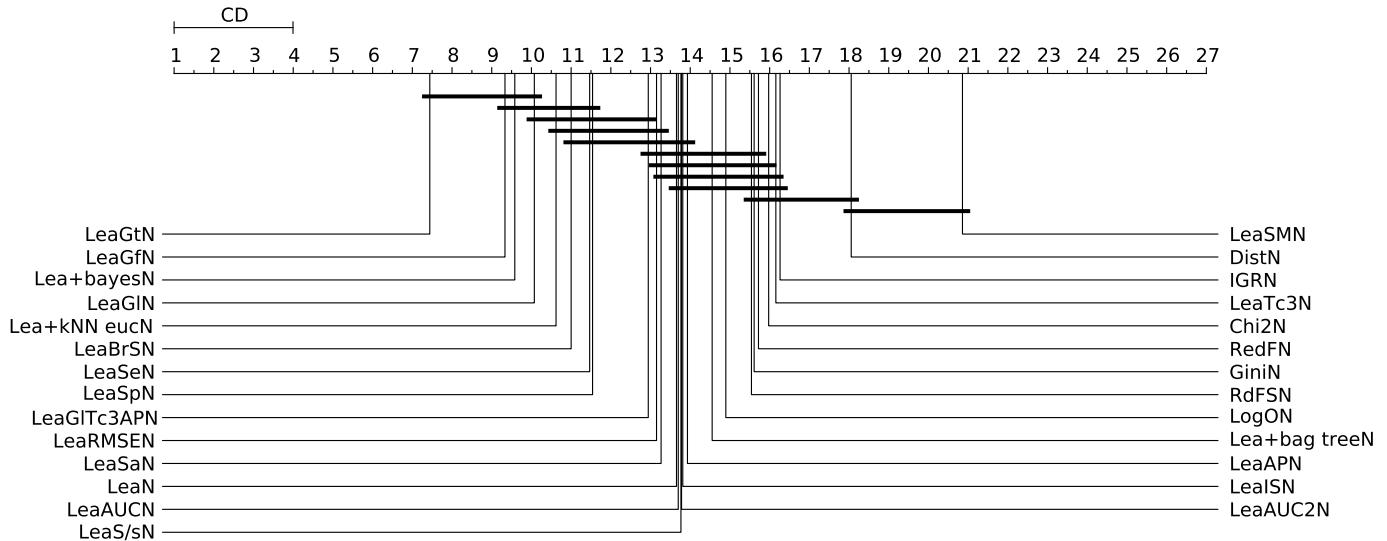
Vizualizacije povprečnih rangov z označenimi kritičnimi razlikami tako predstavljajo slike: 4.1 za funkcijo  $s(W)$ , 4.2 za funkcijo  $u(W)$ , 4.3 za funkcijo  $t(W)$  in 4.4 za funkcijo  $v(W)$ . Vizualizacija za kombinirano funkcijo pa je zelo podobna 4.1, saj predstavlja simulirani nabori podatkov pri katerih se je uporabljalo  $s(W)$  večino. Grafe ostalih različnih povprečnih rangov za kombinirano funkcijo pri osnovni analizi se lahko najde v dodatku A.



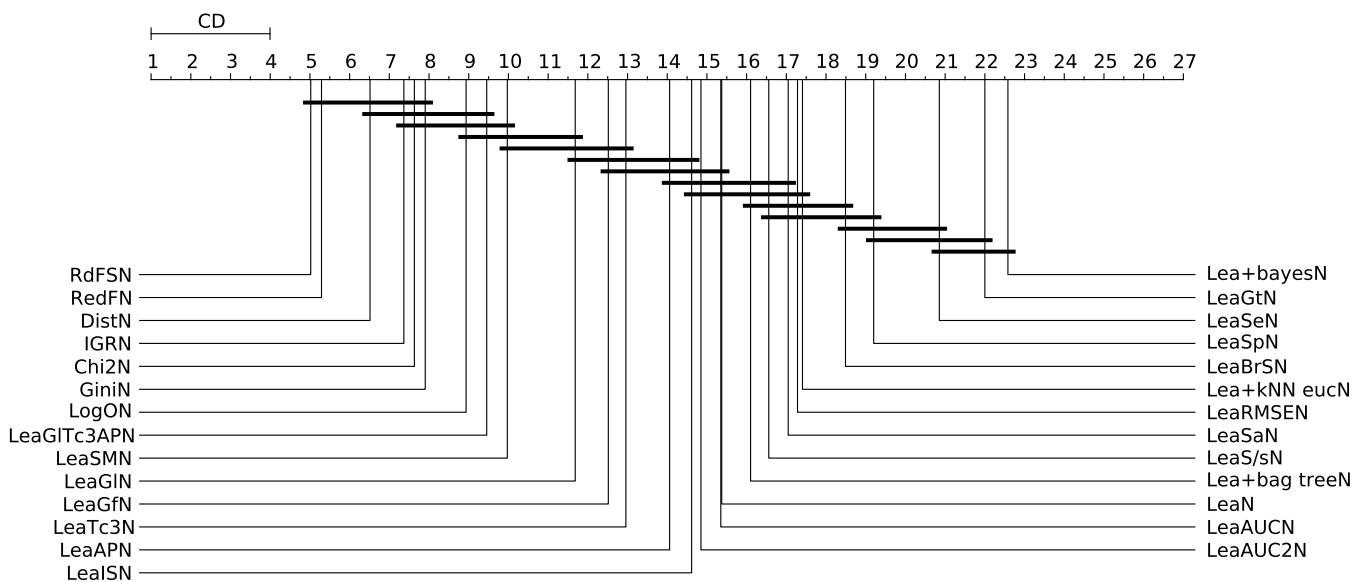
Slika 4.1: Graf kritične razlike za Nemenyi test iz povprečnih rangov funkcije  $s(W)$  za vrednotenje uspešnosti pri osnovni analizi (CD iz avg-all<sup>2</sup>).



Slika 4.2: Graf kritične razlike za Nemenyi test iz povprečnih rangov funkcije  $u(W)$  za vrednotenje uspešnosti pri osnovni analizi (CD iz avg-all<sup>2</sup>).



**Slika 4.3:** Graf kritične razlike za Nemenyi test iz povprečnih rangov funkcije  $t(W)$  za vrednotenje uspešnosti pri osnovni analizi (CD iz avg-all<sup>1</sup>).



**Slika 4.4:** Graf kritične razlike za Nemenyi test iz povprečnih rangov funkcije  $v(W)$  za vrednotenje uspešnosti pri osnovni analizi (CD iz avg-all<sup>1</sup>).

Kot je razvidno iz rezultatov osnovne analize so kljub ogromnemu številu naborov podatkov in eksperimentov vrednosti kritičnih razlik še vedno zelo višoke kar je posledica primerjanja velikega števila metod med seboj. Posledično je na podlagi povprečnih rangov težje določiti in dokazati statistično signifikantne razlike v uspešnostih različnih metod. Ravno zato se je v okviru diplomske naloge izvedlo še **podrobnejšo analizo** na le par izbranih najboljših metodah.

Na podlagi rezultatov osnovne analize se je za podrobnejšo analizo izbral 6 metod za ocenjevanje pomembnosti atributov, ki so v splošnem najboljše. Od tega so 3 variante nove metode in 3 konkurenčne metode s katerimi se je želelo primerjati:

- **RedF** oz. *RelievedF*
- **RdFS** oz. *RelievedFS*
- **Log0** oz. *logaritem razmerja obetov*
- **Lea** je osnovna varianta nove metode
- **LeaTc3** je varianta osnovne metode **Lea**
- **LeaG1Tc3AP** je kompleksnejša varianta nove metode **Lea**

Postopek priprave rezultatov pri podrobnejši analizi je podoben, razlike so predvsem v obsegu analize in so opisane v poglavju 4.2. V nadaljevanju tako sledijo podobne tabele in slike kot pri osnovni analizi. Le da so omejene na kombinirano funkcijo in natančneje prikazujejo vplive povprečanja rangov na različno izbranih naborih podatkov (tabela 4.4).

|              | <i>RedFN</i>        | <i>RdFSN</i>       | <i>LogON</i>       | <i>LeaN</i>        | <i>LeaG1Tc3APN</i> | <i>LeaTc3N</i>     |
|--------------|---------------------|--------------------|--------------------|--------------------|--------------------|--------------------|
| avg-gen      | 0.051 0.460 3.793   | 0.489 0.850 2.927  | -0.141 0.309 3.895 | 0.354 0.728 3.450  | 0.365 0.743 3.577  | 0.408 0.761 2.907  |
| avg-real     | 1.560 -0.279 2.775  | 1.646 -0.372 2.050 | 1.446 -0.242 3.200 | 1.529 -2.476 3.225 | 1.521 -0.893 3.250 | 1.471 -1.886 4.050 |
| avg-size-015 | -0.254 -0.048 4.203 | 0.165 0.359 3.078  | -0.156 0.180 3.756 | 0.093 -0.092 3.055 | 0.046 0.178 3.266  | 0.055 -0.012 2.977 |
| avg-size-030 | -0.171 0.076 4.469  | 0.518 0.599 2.719  | -0.063 0.293 3.400 | 0.318 0.118 3.187  | 0.331 0.386 3.469  | 0.357 0.185 2.984  |
| avg-size-060 | 0.448 0.594 3.547   | 0.729 0.780 2.734  | -0.095 0.352 4.044 | 0.556 0.389 3.570  | 0.627 0.623 3.531  | 0.647 0.487 2.992  |
| avg-size-120 | 0.533 0.564 3.164   | 0.850 0.856 2.805  | -0.165 0.265 4.111 | 0.729 0.529 3.633  | 0.752 0.726 3.625  | 0.799 0.715 3.102  |
| avg-size-180 | 0.644 0.654 2.945   | 0.905 0.892 2.750  | -0.052 0.394 4.089 | 0.810 0.693 3.664  | 0.792 0.779 3.789  | 0.844 0.777 3.195  |
| avg-all      | 0.240 0.368 3.666   | 0.634 0.697 2.817  | -0.106 0.296 3.880 | 0.501 0.328 3.422  | 0.510 0.539 3.536  | 0.541 0.430 3.050  |

**Tabela 4.4:** Primer različnih povprečih ocen uspešnosti s povprečnimi rangi za kombinirano funkcijo na izbranih 6 metodah za ocenjevanje pomembnosti atributov pri podrobni analizi.

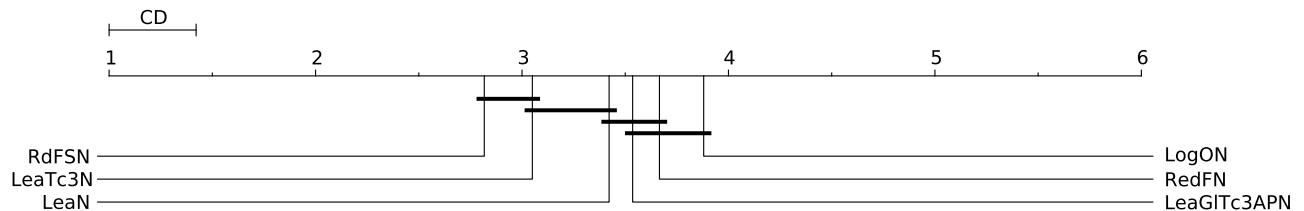
V tabeli 4.5 so predstavljene kritične razlike po *Nemenyi testu* z  $\alpha = 0,05$  za podrobnejšo analizo, ki so tokrat občutno manjše. Sledijo pa grafi z vizualizacijo vseh teh različnih povprečnih rangov na podlagi kombinirane funkcije za

ovrednotenje uspešnosti metod. Ostale grafe osnovnih povprečnih vrednosti drugih ocenjevalnih funkcij na vseh naborih podatkov pa je možno videti v dodatku C.

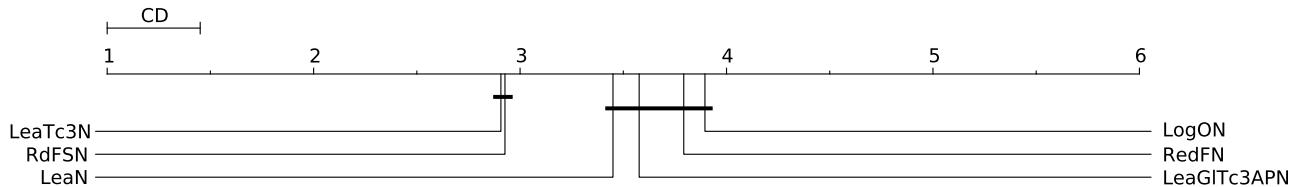
| Povprečje                 | Naborov podatkov | Kritična razlika ( $CD$ ) |
|---------------------------|------------------|---------------------------|
| avg-all <sup>1</sup>      | 320              | 0.421477                  |
| avg-gen <sup>1</sup>      | 280              | 0.450578                  |
| avg-real <sup>1</sup>     | 40               | 1.192117                  |
| avg-size-015 <sup>1</sup> | 64               | 0.942451                  |
| avg-size-030 <sup>1</sup> | 64               | 0.942451                  |
| avg-size-060 <sup>1</sup> | 64               | 0.942451                  |
| avg-size-120 <sup>1</sup> | 64               | 0.942451                  |
| avg-size-180 <sup>1</sup> | 64               | 0.942451                  |
| avg-all <sup>2</sup>      | 280              | 0.450578                  |
| avg-size-015 <sup>2</sup> | 56               | 1.007523                  |
| avg-size-030 <sup>2</sup> | 56               | 1.007523                  |
| avg-size-060 <sup>2</sup> | 56               | 1.007523                  |
| avg-size-120 <sup>2</sup> | 56               | 1.007523                  |
| avg-size-180 <sup>2</sup> | 56               | 1.007523                  |

**Tabela 4.5:** Kritične razlike (ang. critical difference) za povprečne range funkcij za vrednotenje uspešnosti izbranih 6 metod pri podrobni analizi pri Nemenyi testu z  $\alpha = 0,05$ . <sup>(1)</sup> označuje kombinirano funkcijo,  $t(W)$  in  $v(W)$ , <sup>(2)</sup> pa  $s(W)$  in  $u(W)$ .

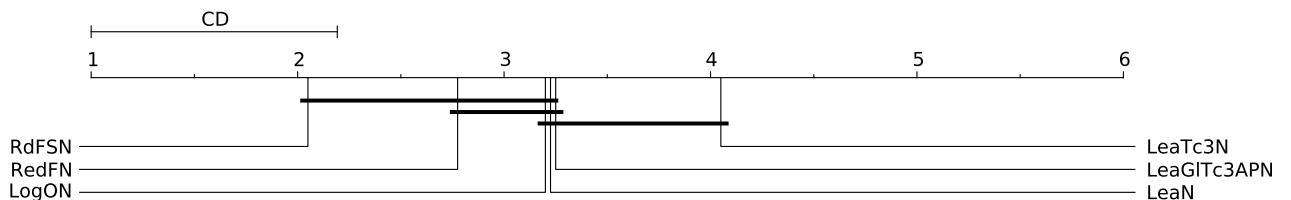
Na podlagi podrobne analize se je lahko boljše primerjalo in sklepalo o uspešnostih in lastnostih izbranih najboljših variant nove in ostalih metod.



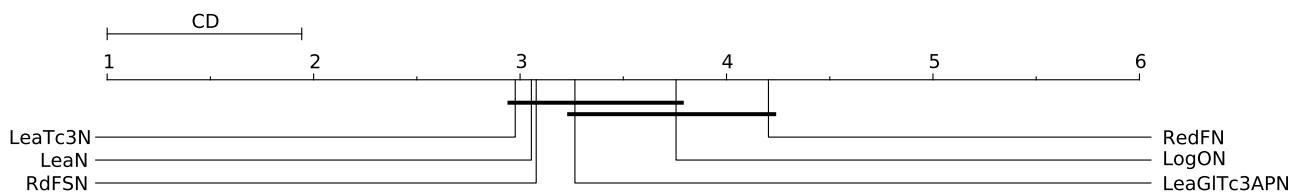
**Slika 4.5:** Graf kritične razlike za Nemenyi test iz povprečnih rangov kombinirane funkcije za vrednotenje uspešnosti na vseh naborih podatkov pri podrobni analizi ( $CD$  iz avg-all<sup>1</sup>).



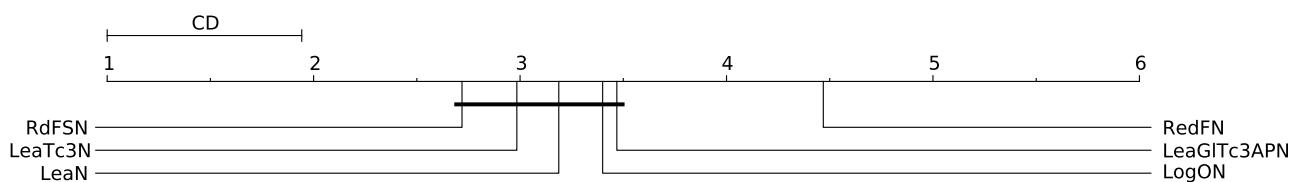
**Slika 4.6:** Graf kritične razlike za Nemenyi test iz povprečnih rangov kombinirane funkcije za vrednotenje uspešnosti na simuliranih naborih podatkov pri podrobni analizi (CD iz avg-gen<sup>1</sup>).



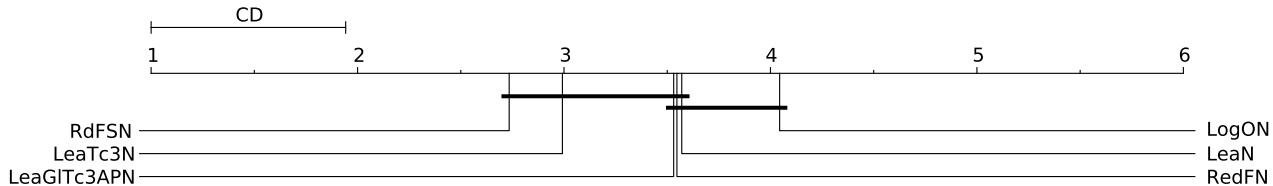
**Slika 4.7:** Graf kritične razlike za Nemenyi test iz povprečnih rangov kombinirane funkcije za vrednotenje uspešnosti na realnih naborih podatkov pri podrobni analizi (CD iz avg-real<sup>1</sup>).



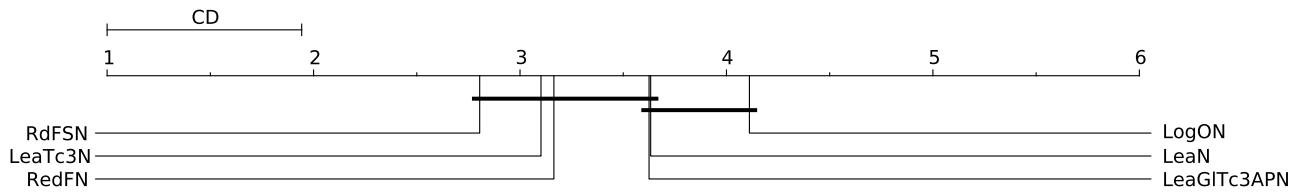
**Slika 4.8:** Graf kritične razlike za Nemenyi test iz povprečnih rangov kombinirane funkcije za vrednotenje uspešnosti na naborih podatkov s 15 primeri pri podrobni analizi (CD iz avg-size-015<sup>1</sup>).



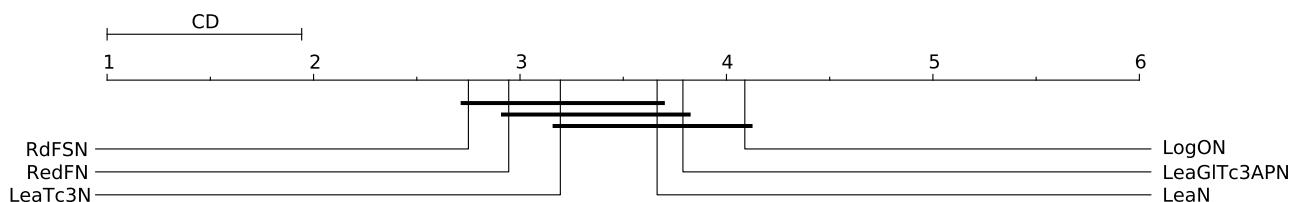
**Slika 4.9:** Graf kritične razlike za Nemenyi test iz povprečnih rangov kombinirane funkcije za vrednotenje uspešnosti na naborih podatkov s 30 primeri pri podrobni analizi (CD iz avg-size-030<sup>1</sup>).



**Slika 4.10:** Graf kritične razlike za Nemenyi test iz povprečnih rangov kombinirane funkcije za vrednotenje uspešnosti na naborih podatkov s 60 primeri pri podrobni analizi (CD iz avg-size-060<sup>1</sup>).



**Slika 4.11:** Graf kritične razlike za Nemenyi test iz povprečnih rangov kombinirane funkcije za vrednotenje uspešnosti na naborih podatkov s 120 primeri pri podrobni analizi (CD iz avg-size-120<sup>1</sup>).



**Slika 4.12:** Graf kritične razlike za Nemenyi test iz povprečnih rangov kombinirane funkcije za vrednotenje uspešnosti na naborih podatkov s 180 primeri pri podrobni analizi (CD iz avg-size-180<sup>1</sup>).

## 4.4 Diskusija

Iz celotne tabele združenih rezultatov **osnovne analize**, ki se jo lahko najde v dodatku B, je razvidno, da so imele pri težjih konceptih vse metode za ocenjevanje pomembnosti atributov težave, pri najlažjih pa sploh ne. Kot najtežja skupina pripravljenih naborov podatkov se je izkazala **modulo-2-4** pri kateri so skoraj vse metode neuporabne, občasna uspešna ločljivost ( $s(W) > 0$ ) pa se pojavlja le pri nekaterih variantah nove metode (z oznako **Lea**) in najboljši konkurenčni **RdFS**. Ciljni koncept uporabe večkratne ekskluzivne disjunkcije (ang. *XOR*) je očitno zelo težek in metode zanj potrebujejo večje število primerov v naboru podatkov, kar v skladu s pričakovanimi lastnostmi metod za ocenjevanje pomembnosti atributov.

S povprečenjem teh vrednosti in predvsem rangov v takšnih združenih tabelah se je pridobilo najpomembnejše informacije o uspehnostih različnih primerjanih metod (npr. tabela 4.2). Po izvedbi statističnega *Nemenyi testa* z  $\alpha = 0,05$  na njih pa se je povprečne range s kritičnimi razlikami prav tako vizualiziralo za različne ocenjevalne funkcije (od slike 4.1 do 4.4) kot tudi različno izbrane nabore podatkov (dodatek A). Iz vseh teh slik je razvidno, da se v diplomski nalogi razvita metoda obnese dokaj dobro pri večini variant izbire njenih komponent. Ker bi se interpretacijo rezultatov s podrobnim upoštevanjem vseh funkcij za vrednotenje uspešnosti nepotrebitno zakompliciralo, se je v nadaljevanju obravnavalo le kombinirano ocenjevalno funkcijo.

Osnovna varianta nove metode (krat. **Lea**) sicer ni vedno med najboljšimi, je pa preprosta in dokaj hitra v primerjavi z nekaterimi drugimi, ki ponavadi tudi niso signifikantno boljše. V splošnem pa se je kot najboljša varianta nove metode izkazala **LeaTc3**, sledi pa ji **LeaAP**, ki pa se je ni obravnavalo v podrobnejši analizi. Iz slike 4.1, 4.2 in nekaterih iz dodatka A lahko sklepamo, da sta ti varianti v splošnem statistično signifikano boljši od vseh običajnih razširjenih metod za ocenjevanje pomembnosti atributov kot so **RedF**, **IGR**, **Gini**, **Chi2**, **Dist** in **Log0** (opisi so v poglavju 2).

Med prej naštetimi običajnimi razširjenimi metodami pa se je v skladu s pričakovanjji izkazala kot najboljša metoda **RedF** oz. *RelievedF*, sledi pa ji **Log0**. Iz vseh rezultatov pa se prav tako vidi, da je nadgradnja najboljše konkurenčne metode v splošnem še boljša od vseh preizkušenih v okviru diplomske naloge. Pri tem gre za deterministično brezparametrično nadgradnjo *Relieff* imenovano *RelievedFS*, ki se je označevala s kratico **RdFS**. Variante nove v diplomskem delu razvite metode so ji sicer glede uspešnosti vedno za petami in nikoli ni statistično signifikantno boljša od njih, a kljub temu so njeni rezultati presenetljivo dobri.

Na podlagi teh ugotovitev se je nato izbral 6 v splošnem najboljših metod in se jih še **podrobneje analiziralo**. Iz vseh grafov podrobne analize je

razvidno, da sta metodi **RdFS** in **LeaTc3** res najboljši in med njima ni statistično signifikantne razlike. Iz grafa povprečnih rangov na vseh naborih podatkov (slika A.1) pa se na primer lepo vidi, da je po uspešnosti prva signifikantno slabša od **RdFS** kar osnovna varianta nove metode **Lea**, sledijo pa vse ostale, ki so tudi signifikantno slabše od **LeaTc3**. Iz grafov povprečnih rangov na različno velikih naborih podatkov (slike 4.8, 4.9, 4.10, 4.11 in 4.12) se lepo vidi, da večja količina podatkov zelo močno vpliva na uspešnost metode **RelievedF** oz. **RelievedF**, na povprečen rang njene nadgradnje **RdFS** ali najboljše variante nove metode **LeaTc3** pa skoraj ne. Ker so na grafih vizualizirani povprečni rangi, ki so relativni oz. odvisni od uspešnosti ostalih metod v istih okoliščinah, gre pri spremembah razporeditve za posebne lastnosti nekaterih metod glede na ostale. Na sliki 4.8 lahko sicer gre za slučajen pojav, morda pa se iz nje vidi kako res kritično majhna količina podatkov bolj kvarno vpliva na metodo **RdFS** kot na variante nove metode, čeprav ne signifikantno bolj. V kolikor bi kaj takšnega bilo res, to pomeni, da se bolj splača uporabljati varianto nove metode **LeaTc3** kot **RdFS** v situacijah, ko imamo na voljo nabor podatkov s kritično majhno količino primerov.

Odvisnost med uspešnostjo delovanja metod in količino podatkov iz katerih lahko sklepa na pomembnosti atributov je povsem logična, a vendar povzroča nekaterim metodam to večje težave kot drugim. Ker imamo v praksi pogosto nabore podatkov z majhnim številom primerov, je ta lastnost metod med pomembnejšimi. Na podlagi rezultatov podrobnejše analize sodeč so za takšne okoliščine primernejši varianti nove metode **LeaTc3** in **Lea**, izmed konkurenčnih metod s katerimi se je preizkušalo pa le **RdFS**.

---

---

## Poglavlje 5

---

### Zaključek

V diplomskem delu se uspešno razvilo nov razred metod za ocenjevanje pomembnosti atributov, pripravilo eksperimentalno metodologijo in preizkusilo veliko metod na ogromni množici naborov podatkov.

Problem novega razreda metod za ocenjevanje pomembnosti atributov iz uspešnosti učnih algoritmov na vzorcih atributnega prostora predstavlja časovna zahtevnost in tudi velika nastavljivost. Obe sta posledici preprostosti ideje s ponavljanjočo zanko v okviru katere se lahko izvajajo skoraj poljubne komponente. Ker te komponente vključujejo velikokrat izvajanj poljuben učni algoritem, predstavlja ta glavni razlog za počasnost metode. Kljub visoki nastavljivosti pa se je izkazalo, da je večina variant nove metode v povezavi s problemom klasifikacije dokaj dobrih, celoten prostor vseh možnih komponent in parametrov pa tako velik, da praktično ni možno najti optimalne konfiguracije od katere verjetno niti ne bi imeli veliko koristi.

Nova metoda ima tudi posrečeno lastnost, da je razлага njenih ocen preprosto razumljiva. Z njo pridobljene ocene pomembnosti atributov namreč predstavljajo kar vpliv atributov iz podanega nabora podatkov na uspešnost klasifikacije za izbran učni algoritem in ostale komponente.

Iz rezultatov je razvidno, da se variante nove metode obnesejo dokaj dobro v primerjavi z ostalimi metodami s katerimi se je primerjalo. Najboljši varianti nove metode LeaTc3 in LeaAP celo statistično signifikantno boljše od vseh običajnih razširjenih metod. Odkrilo pa se je tudi posebno nadgradnjo najboljše izmed njih imenovano *RelievedFS* oz. s kratico RdFS, ki izgleda še boljša od vseh, vendar ni simfikantno boljša od najboljših variant nove metode.

Z raziskavo vpliva količine primerov v naboru podatkov na oceno uspešnosti metode se je tudi ugotovilo, da sta v okoliščinah z manjših številom primerov primernejši varianti nove metode LeaTc3 in Lea, izmed konkurenčnih metod s

katerimi se je preizkušalo pa le RdFS.

## 5.1 Nadaljnje delo

Pri izdelavi diplomskega dela in prebiranju več ali manj sorodnih člankov so se pojavile tudi mnoge ideje za nadaljnje delo in raziskave. Le-te seveda presegajo obseg tega diplomskega dela in so zato nekatere od njih navedene le kot okvirne ideje:

- Glede na to, da gre za zelo splošno in preprosto idejo, bi se lahko le-to uporabilo tudi za raziskovanje drugih področij, ki niso povezani s problemom klasifikacije. Celotna metoda je namreč zastavljena tako, da bi se s preprosto izbiro pravilnih alternativnih komponent lahko doseglo ocenjevanje pomembnosti atributov v bistveno drugačnih okoljih.
- Tako kot ostale metode za ocenjevanje pomembnosti atributov se lahko tudi ta uporabi pri izbiranju koristnih podmnožic atributov (ang. *feature subset selection*). Čeprav sama metoda zelo spominja na metodo z ovojnico (ang. *wrapper method*), temu ni tako, saj gre za posprošitev ideje, ki omogoča uporabiljati drug učni algoritem in postopek ocenjevanja za izbor atributov od končnega učenja. Zato spada metoda, kljub temu da je počasnejša od ostalih, med tehnike predobdelave podatkov (ang. *filter methods*). Pri tem jo je možno uporabiti tako s klasičnimi prijemi kot sta postavitev praga ali vzvratna eliminacija (ang. *backward elimination*) kot tudi s tehniko inkrementalnega izbiranja (ang. *forward selection*) (opisani v poglavju 2). Med procesom ocenjevanja uspešnosti učnega algoritma je namreč možno fiksirati nekaj atributov tako, da bodo vedno v izbrani poddomeni. Posledično dobimo kot rezultat ocene pomembnosti ostalih atributov ob prisotnosti fiksiranih atributov, kar pomeni, da bodo vsi atributi z odvečnimi (ang. *redundant*) informacijami glede na fiksirano množico dobili nižje ocene. Če torej inkrementalno izbiramo in dodajamo v fiksirano množico najpomembnejši atribut med ostalimi, bomo teoretično dobili množice najbolj informativnih atributov s čim manjšo stopnjo odvečnosti oz. soodvisnosti. Na to se celo lahko gleda kot nekakšen postopek ortogonalne izbire atributov.
- Medsebojne interakcije med atributi, kjer le posebne kombinacije teh predstavljajo kakšno informacijo o ciljnem razredu (sinergija), bi se prav tako lahko določevalo s to metodo. Opazovali bi lahko razliko med brezpogojno ocenjenenimi pomembnostmi atributov in ocenami pridobljenimi ob fiksiranju določenega atributa (spominja na idejo v [5]). Odvečnim

atributom bi, kot že omenjeno, ocena verjetno padla, sodejavnim, ki so v kombinaciji informativnejši, narasla, pri ostalih neodvisnih pa bi v luči ciljnega razreda ostala ocena enaka.

- Pojavila se je tudi ideja poskušati napovedovati pomembnosti atributov v nasprotni smeri. Namesto, da bi iz podmnožic atributov napovedovali ciljni razred in uspešnosti združevali po atributih, bi lahko iz ostalih atributov in prvotnega razreda skušali napovedovati izbrani atribut. Z drugimi besedami to pomeni, da bi nastavili izbrani atribut kot ciljni razred ter ocenjevali uspešnost starega razreda. Teoretična predpostavka pri tem je, da će lahko iz informativnega atributa dobro napoveduješ ciljni razred, lahko tudi iz ostalih atributov in starega razreda dobro napoveduješ informativni atribut.
- V skladu z združenima idejama iz prejšnjih točk bi lahko tudi odkrivali splošne interakcije med atributi ne glede na izbrani ciljni razred. Na interakcijski prispevek med dvema atributoma se namreč lahko gleda kot na razliko med uspešnostjo učnega algoritma, če za ciljni razred izberemo en atribut in napovedujemo ob ali brez prisotnosti drugega. Takšne medsebojne odvisnosti verjetno niso zelo uporabne pri klasifikaciji s podanim ciljnim razredom, a bi lahko prišle prav pri raznih drugih metodah strojnega učenja.

---

## Literatura

- [1] Leo Breiman, J. H. Friedman, R. A. Olshen, and C. J. Stone. *Classification and Regression Trees*. Wadsworth, 1984.
- [2] Ramon López de Mántaras. A distance-based attribute selection measure for decision tree induction. *Machine Learning*, 6:81–92, 1991.
- [3] Janez Demsar. Statistical comparisons of classifiers over multiple data sets. *Journal of Machine Learning Research*, 7:1–30, 2006.
- [4] Janez Demšar, Blaž Zupan, Gregor Leban, and Tomaz Curk. Orange: From experimental machine learning to interactive data mining. In Jean-François Boulicaut, Floriana Esposito, Fosca Giannotti, and Dino Pedreschi, editors, *PKDD*, volume 3202 of *Lecture Notes in Computer Science*, pages 537–539. Springer, 2004.
- [5] François Fleuret. Fast binary feature selection with conditional mutual information. *Journal of Machine Learning Research*, 5:1531–1555, 2004.
- [6] A. Frank and A. Asuncion. UCI machine learning repository, 2010.
- [7] Aleks Jakulin and Ivan Bratko. Analyzing attribute dependencies. In Nada Lavrac, Dragan Gamberger, Hendrik Blockeel, and Ljupco Todorovski, editors, *PKDD*, volume 2838 of *Lecture Notes in Computer Science*, pages 229–240. Springer, 2003.
- [8] Aleks Jakulin and Ivan Bratko. Testing the significance of attribute interactions. In Carla E. Brodley, editor, *ICML*, volume 69 of *ACM International Conference Proceeding Series*. ACM, 2004.

- [9] I. T. Jolliffe. *Principal Component Analysis*. Series in Statistics. Springer-Verlag, 1986.
- [10] Kenji Kira and Larry A. Rendell. The feature selection problem: Traditional methods and a new algorithm. In *AAAI*, pages 129–134, 1992.
- [11] Kenji Kira and Larry A. Rendell. A practical approach to feature selection. In Derek H. Sleeman and Peter Edwards, editors, *ML*, pages 249–256. Morgan Kaufmann, 1992.
- [12] Ron Kohavi and George H. John. Wrappers for feature subset selection. *Artif. Intell.*, 97(1-2):273–324, 1997.
- [13] Igor Kononenko. Estimating attributes: Analysis and extensions of relief. In Francesco Bergadano and Luc De Raedt, editors, *ECML*, volume 784 of *Lecture Notes in Computer Science*, pages 171–182. Springer, 1994.
- [14] Igor Kononenko. On biases in estimating multi-valued attributes. In *IJCAI*, pages 1034–1040, 1995.
- [15] Igor Kononenko and Ivan Bratko. Information-based evaluation criterion for classifier’s performance. *Machine Learning*, 6:67–80, 1991.
- [16] K. Pearson. On lines and planes of closest fit to points in space. *Philosophical Magazine*, 2:559–572, 1901.
- [17] Peter Peer, Boštjan Čargo, and Igor Kononenko. Extension of relieff, 1997.
- [18] J. Ross Quinlan. Induction of decision trees. *Machine Learning*, 1(1):81–106, 1986.
- [19] Marko Robnik-Šikonja and Igor Kononenko. Theoretical and empirical analysis of relieff and rrelief. *Machine Learning*, 53(1-2):23–69, 2003.
- [20] Dietrich Wetschereck, David W. Aha, and Takao Mohri. A review and empirical evaluation of feature weighting methods for a class of lazy learning algorithms. *Artif. Intell. Rev.*, 11(1-5):273–314, 1997.
- [21] Allan P. White and Wei Zhong Liu. Bias in information-based measures in decision tree induction. *Machine Learning*, 15(3):321–329, 1994.



---

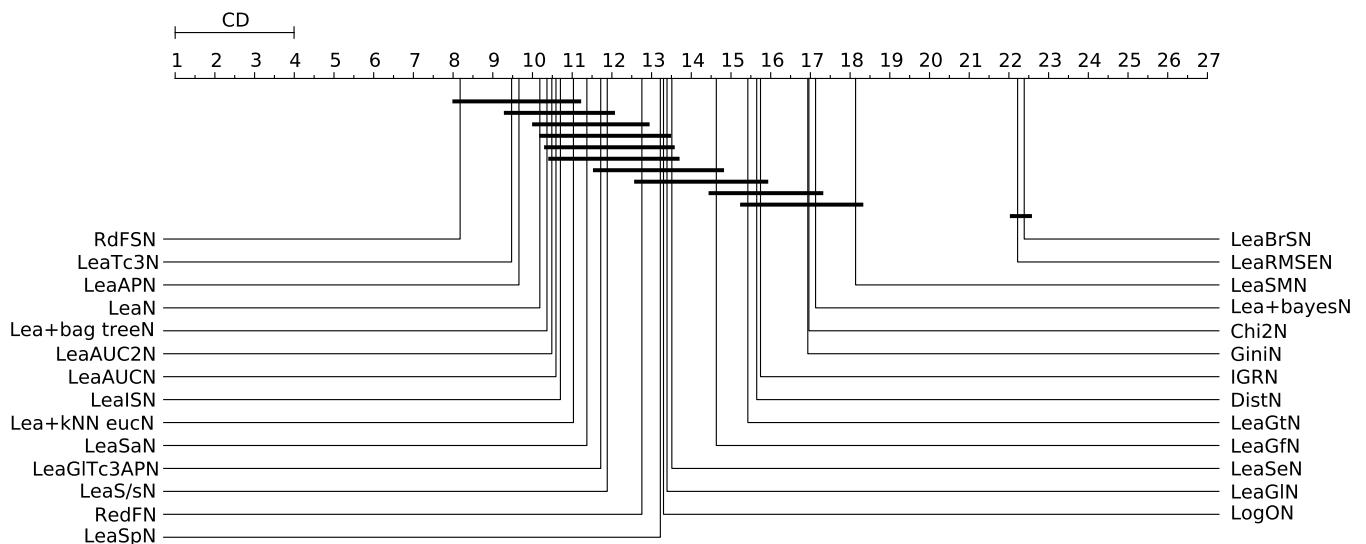
---

## Dodatek A

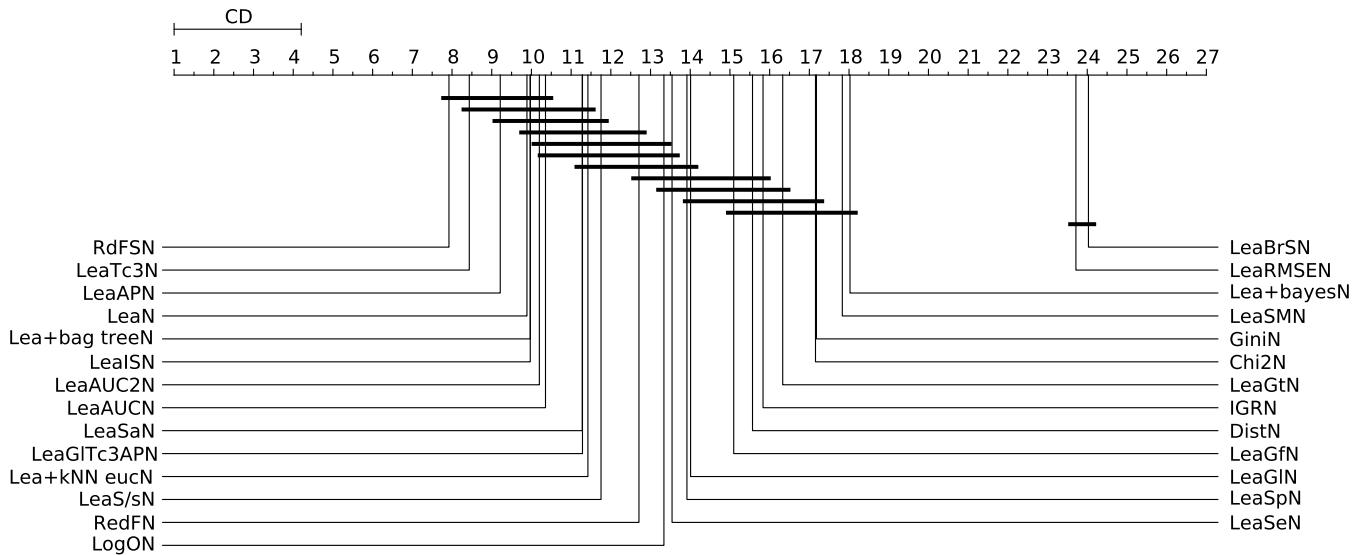
---

### Ostali grafi povprečnih rangov osnovne analize

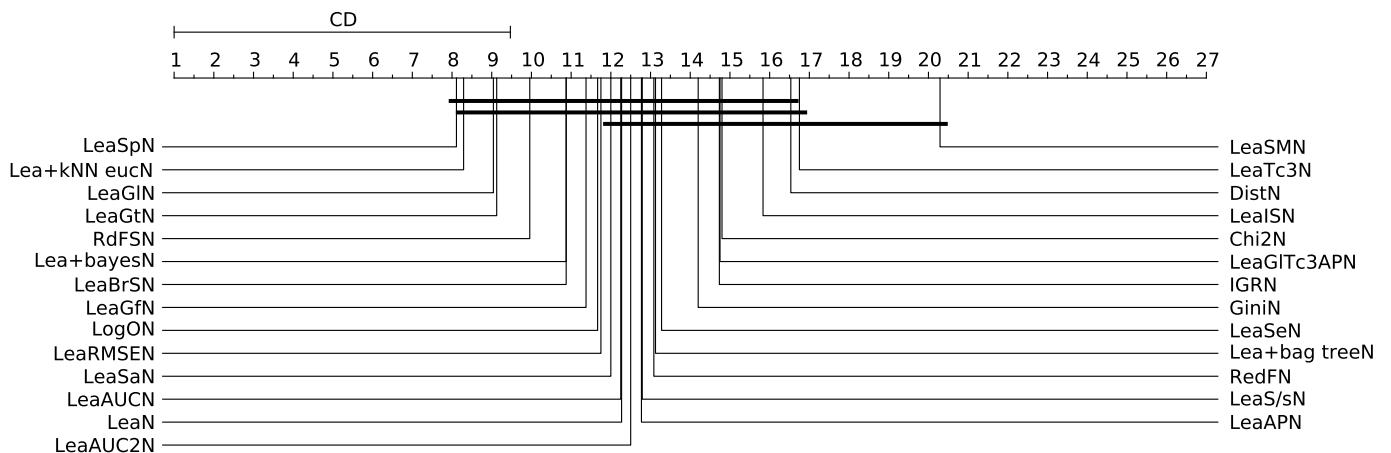
Sledijo ostali grafi povprečnih rangov kombinirane funkcije s kritično razliko po statističnem *Nemenyi testu* z  $\alpha = 0,05$ , ki se jih ni predstavilo v poglavju 4.3. Kritične razlike uporabljene v sledečih grafih pa je možno najti v tabeli 4.3.



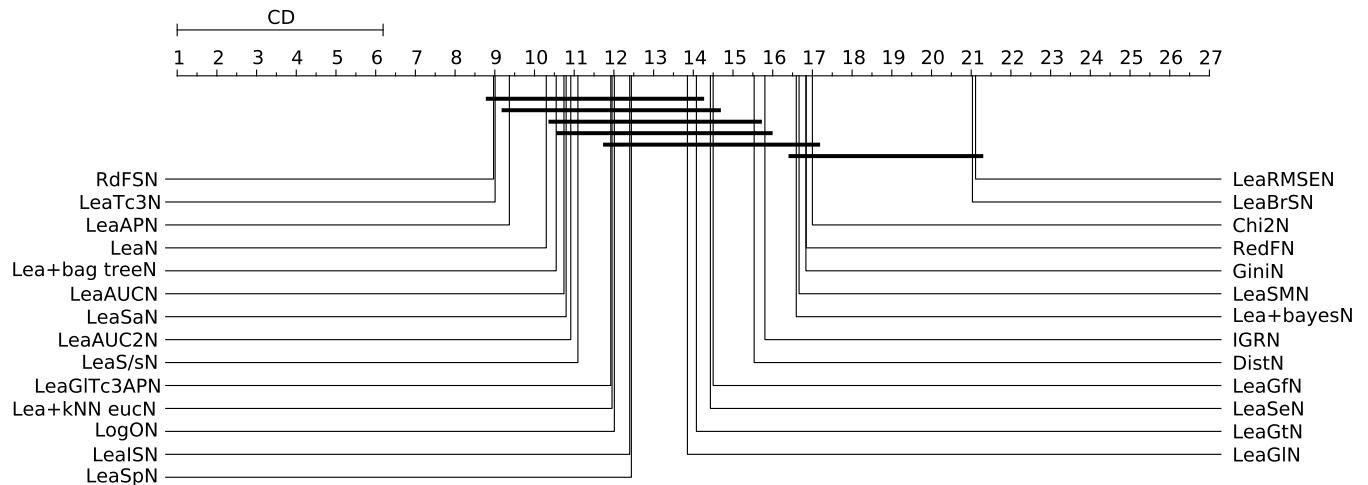
**Slika A.1:** Graf kritične razlike za Nemenyi test iz povprečnih rangov kombinirane funkcije za vrednotenje uspešnosti na vseh naborih podatkov pri osnovni analizi (CD iz avg-all<sup>1</sup>).



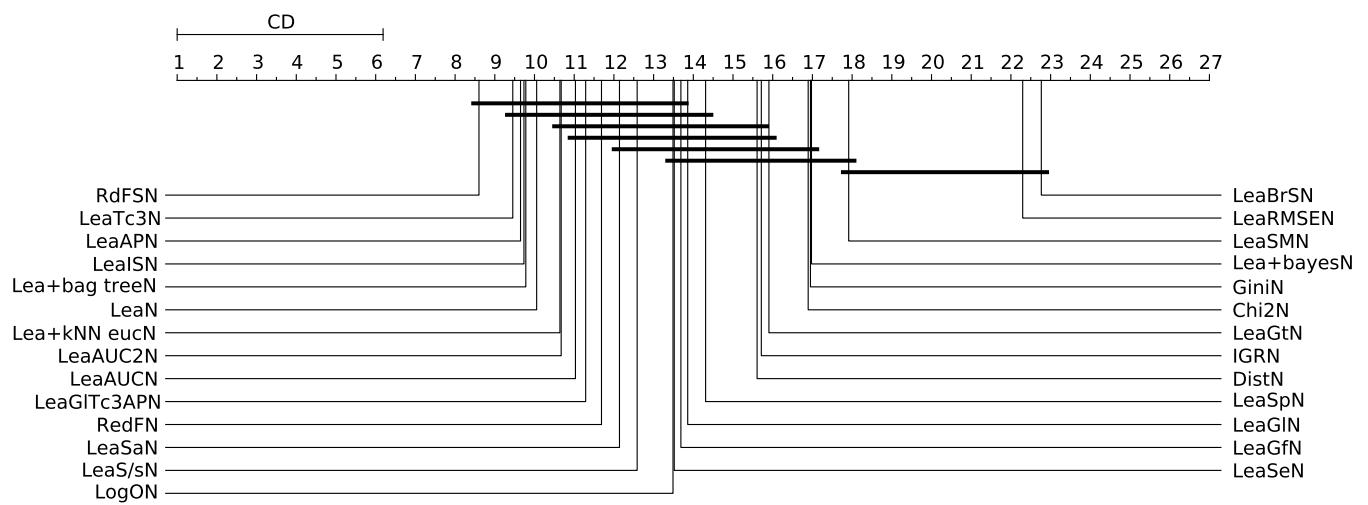
**Slika A.2:** Graf kritične razlike za Nemenyi test iz povprečnih rangov kombinirane funkcije za vrednotenje uspešnosti na simuliranih naborih podatkov pri osnovni analizi (CD iz avg-gen<sup>1</sup>).



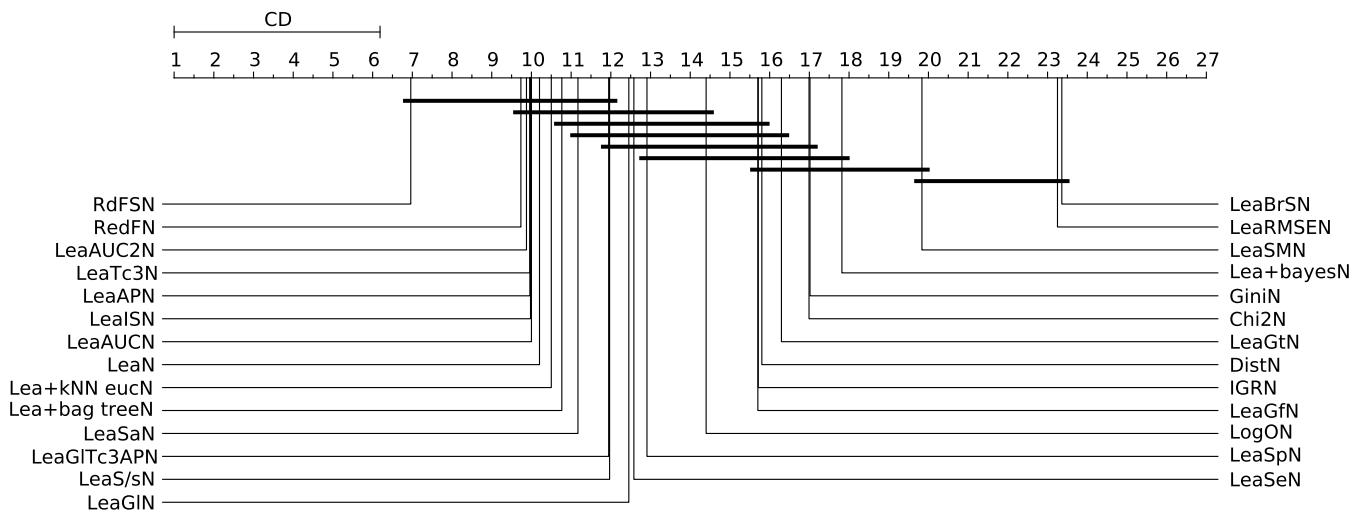
**Slika A.3:** Graf kritične razlike za Nemenyi test iz povprečnih rangov kombinirane funkcije za vrednotenje uspešnosti na resničnih naborih podatkov pri osnovni analizi (CD iz avg-real<sup>1</sup>).



**Slika A.4:** Graf kritične razlike za Nemenyi test iz povprečnih rangov kombinirane funkcije za vrednotenje uspešnosti na naborih podatkov s 30 primeri pri osnovni analizi (CD iz avg-size-030<sup>1</sup>).



**Slika A.5:** Graf kritične razlike za Nemenyi test iz povprečnih rangov kombinirane funkcije za vrednotenje uspešnosti na naborih podatkov s 60 primeri pri osnovni analizi (CD iz avg-size-060<sup>1</sup>).



**Slika A.6:** Graf kritične razlike za Nemenyi test iz povprečnih rangov kombinirane funkcije za vrednotenje uspešnosti na naborih podatkov s 180 primeri pri osnovni analizi (CD iz avg-size-180<sup>1</sup>).

---

---

## Dodatek B

---

### Celotna združena tabela osnovne analyze

Na naslednjih 12 straneh sledi razrezana združena tabela osnovne analize pri kateri se je primerjalo vseh 27 metod večkrat na raznolikih naborih podatkov. Za ocenjevanje uspešnosti pa se je uporabila kombinirana funkcija. Zaradi svoje velikosti je razdeljena na kvadrante od (1, 1) do (3, 4), ki so označeni v opisih pod deli tabele.

| Dataset             | <i>RedFN</i>         | <i>RdFSN</i>         | <i>IGRN</i>          | <i>GiniN</i>         | <i>Chi2N</i>         | <i>DistN</i>         |
|---------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| only-a0 10-030      | 1.032 1.032 6.000    | 1.006 1.006 11.000   | 1.052 1.052 3.000    | 1.033 1.033 5.000    | 1.034 1.034 4.000    | 1.080 1.080 2.000    |
| only-a0 10-060      | 1.085 1.085 6.000    | 1.074 1.074 7.000    | 1.093 1.093 3.000    | 1.086 1.086 4.500    | 1.086 1.086 4.500    | 1.102 1.102 2.000    |
| only-a0 10-180      | 1.100 1.100 7.000    | 1.101 1.101 6.000    | 1.107 1.107 3.000    | 1.105 1.105 4.500    | 1.105 1.105 4.500    | 1.109 1.109 2.000    |
| only-a0 20-030      | 1.013 1.013 4.000    | 0.909 0.909 23.000   | 1.023 1.023 3.000    | 1.011 1.011 6.000    | 1.012 1.012 5.000    | 1.036 1.036 2.000    |
| only-a0 20-060      | 1.021 1.021 4.000    | 1.008 1.008 8.000    | 1.025 1.025 3.000    | 1.015 1.015 5.500    | 1.015 1.015 5.500    | 1.038 1.038 2.000    |
| only-a0 20-180      | 1.036 1.036 6.000    | 1.024 1.024 7.000    | 1.046 1.046 3.000    | 1.044 1.044 4.500    | 1.044 1.044 4.500    | 1.049 1.049 2.000    |
| only-a0 40-030      | 0.977 0.977 17.000   | 0.932 0.932 23.000   | 0.991 0.991 11.000   | 0.979 0.979 16.000   | 0.981 0.981 15.000   | 1.007 1.007 2.000    |
| only-a0 40-060      | 0.983 0.983 17.000   | 0.963 0.963 20.000   | 0.996 0.996 11.000   | 0.985 0.985 15.500   | 0.985 0.985 15.500   | 1.010 1.010 2.000    |
| only-a0 40-180      | 1.016 1.016 6.000    | 1.003 1.003 7.000    | 1.020 1.020 3.000    | 1.018 1.018 4.500    | 1.018 1.018 4.500    | 1.023 1.023 2.000    |
| only-a0 80-030      | 0.951 0.951 17.000   | 0.863 0.863 24.000   | 0.966 0.966 14.000   | 0.949 0.949 19.000   | 0.950 0.950 18.000   | 0.987 0.987 9.500    |
| only-a0 80-060      | 0.980 0.980 17.500   | 0.926 0.926 22.000   | 0.992 0.992 13.500   | 0.983 0.983 16.000   | 0.984 0.984 15.000   | 1.002 1.002 2.000    |
| only-a0 80-180      | 0.985 0.985 18.000   | 0.967 0.967 22.000   | 1.003 1.003 3.000    | 1.000 1.000 4.500    | 1.000 1.000 4.500    | 1.008 1.008 2.000    |
| modulo-2-2 10-030   | -1.190 -0.965 24.000 | 0.871 1.102 8.000    | -1.145 -0.952 22.000 | -1.130 -0.958 20.000 | -1.136 -0.943 21.000 | -1.155 -0.952 23.000 |
| modulo-2-2 10-060   | 0.910 1.043 15.000   | 0.981 1.184 10.000   | -1.169 -0.676 20.000 | -1.177 -0.650 23.000 | -1.174 -0.650 22.000 | -1.173 -0.678 21.000 |
| modulo-2-2 10-180   | 1.172 1.199 3.000    | 1.198 1.231 1.000    | -1.659 -1.156 24.000 | -1.661 -1.155 27.000 | -1.660 -1.154 26.000 | -1.659 -1.157 25.000 |
| modulo-2-2 20-030   | -1.519 -1.282 20.000 | 0.393 0.935 3.000    | -1.590 -1.344 24.000 | -1.560 -1.305 21.000 | -1.566 -1.313 22.000 | -1.576 -1.345 23.000 |
| modulo-2-2 20-060   | 0.684 0.807 16.000   | 0.676 0.982 17.000   | -1.396 -0.509 24.000 | -1.396 -0.505 25.000 | -1.397 -0.504 26.000 | -1.394 -0.503 23.000 |
| modulo-2-2 20-180   | 1.015 1.069 1.000    | 0.944 1.056 2.000    | -1.668 -1.584 26.000 | -1.669 -1.584 27.000 | -1.666 -1.583 25.000 | -1.664 -1.581 24.000 |
| modulo-2-2 40-030   | -1.192 -0.183 21.000 | 0.494 0.571 7.000    | -1.234 -0.232 25.000 | -1.227 -0.230 22.000 | -1.229 -0.222 23.000 | -1.233 -0.251 24.000 |
| modulo-2-2 40-060   | 0.437 0.613 16.000   | 0.837 0.880 2.000    | -1.235 -1.162 25.000 | -1.231 -1.159 22.000 | -1.231 -1.160 23.000 | -1.231 -1.156 24.000 |
| modulo-2-2 40-180   | 0.971 0.976 1.000    | 0.946 0.980 3.000    | -1.445 -0.333 24.000 | -1.449 -0.322 25.000 | -1.449 -0.323 26.000 | -1.442 -0.331 23.000 |
| modulo-2-2 80-030   | -1.384 -1.135 24.000 | -0.192 0.286 1.000   | -1.386 -1.164 25.000 | -1.419 -1.163 27.000 | -1.414 -1.164 26.000 | -1.369 -1.160 23.000 |
| modulo-2-2 80-060   | 0.363 0.501 4.000    | 0.389 0.692 3.000    | -1.320 -1.119 25.000 | -1.322 -1.116 26.000 | -1.322 -1.116 27.000 | -1.295 -1.109 24.000 |
| modulo-2-2 80-180   | 0.816 0.899 4.000    | 0.755 0.903 8.000    | -1.063 -0.903 22.000 | -1.063 -0.900 23.500 | -1.063 -0.900 23.500 | -1.060 -0.906 21.000 |
| modulo-2-4 10-030   | -0.744 0.807 18.000  | 0.130 0.871 1.000    | -0.717 0.820 17.000  | -0.705 0.822 15.000  | -0.712 0.819 16.000  | -0.658 0.846 14.000  |
| modulo-2-4 10-060   | -1.892 -0.920 26.000 | 0.608 1.339 1.000    | -1.843 -0.778 22.000 | -1.881 -0.837 24.000 | -1.884 -0.782 25.000 | -1.849 -0.757 23.000 |
| modulo-2-4 10-180   | -1.946 -1.785 27.000 | 1.278 1.519 1.000    | -1.299 -0.040 21.000 | -1.297 -0.043 19.000 | -1.297 -0.047 20.000 | -1.299 -0.039 22.000 |
| modulo-2-4 20-030   | -1.147 -0.679 7.000  | -1.435 -0.896 15.000 | -1.210 -0.706 11.000 | -1.171 -0.697 8.000  | -1.181 -0.717 9.000  | -1.205 -0.679 10.000 |
| modulo-2-4 20-060   | -1.126 -0.663 6.000  | -0.381 0.371 1.000   | -1.321 -0.539 8.000  | -1.321 -0.530 9.000  | -1.321 -0.532 10.000 | -1.321 -0.534 11.000 |
| modulo-2-4 20-180   | -1.802 -0.995 27.000 | 0.431 0.708 1.000    | -1.484 -1.002 23.000 | -1.484 -1.004 24.000 | -1.484 -1.003 25.000 | -1.481 -1.001 22.000 |
| modulo-2-4 40-030   | -1.162 0.115 17.000  | -1.137 -0.498 15.000 | -1.135 0.195 14.000  | -1.184 0.142 19.000  | -1.185 0.143 20.000  | -1.155 0.178 16.000  |
| modulo-2-4 40-060   | -1.324 -0.831 21.000 | -1.185 -0.630 8.000  | -1.273 -0.687 17.000 | -1.297 -0.646 20.000 | -1.292 -0.661 19.000 | -1.269 -0.697 16.000 |
| modulo-2-4 40-180   | -1.732 -0.858 27.000 | -0.751 0.405 4.000   | -1.379 -0.719 19.000 | -1.388 -0.713 21.000 | -1.383 -0.718 20.000 | -1.371 -0.724 18.000 |
| modulo-2-4 80-030   | -1.225 -0.791 10.000 | -1.132 -0.422 6.000  | -1.250 -0.744 14.000 | -1.253 -0.733 15.000 | -1.249 -0.738 13.000 | -1.239 -0.769 11.000 |
| modulo-2-4 80-060   | -0.951 -0.798 9.000  | -1.748 -0.355 27.000 | -1.214 -0.837 23.000 | -1.212 -0.837 22.000 | -1.215 -0.829 24.000 | -1.211 -0.835 21.000 |
| modulo-2-4 80-180   | -0.837 -0.514 4.000  | -1.145 -0.520 9.000  | -1.203 -0.705 14.000 | -1.203 -0.704 15.500 | -1.203 -0.704 15.500 | -1.200 -0.707 13.000 |
| modulo-4-2 10-030   | -1.156 -0.034 19.000 | 0.474 0.930 14.000   | -1.499 -0.244 22.000 | -1.439 -0.508 20.000 | -0.815 -0.362 18.000 | -1.595 -0.238 23.000 |
| modulo-4-2 10-060   | -1.464 -1.413 17.000 | 1.025 1.095 1.000    | -1.594 -1.566 21.000 | -1.653 -1.480 24.000 | -1.504 -1.494 18.000 | -1.596 -1.550 22.000 |
| modulo-4-2 10-180   | 1.106 1.183 2.000    | 1.224 1.224 1.000    | 0.326 0.680 19.000   | 0.261 0.658 21.000   | 0.340 0.701 18.000   | 0.323 0.685 20.000   |
| modulo-4-2 20-030   | -1.430 -1.056 21.000 | -0.049 0.389 7.000   | -1.395 -1.169 19.000 | -1.350 -1.124 20.000 | -1.531 -1.210 23.000 | -1.423 -1.173 20.000 |
| modulo-4-2 20-060   | -1.983 -1.870 24.000 | 0.737 0.984 1.000    | -1.748 -1.670 20.000 | -1.833 -1.670 22.000 | -1.854 -1.827 23.000 | -1.751 -1.668 21.000 |
| modulo-4-2 20-180   | 0.971 1.013 10.000   | 0.986 1.049 4.000    | 0.021 0.439 19.000   | -0.006 0.466 21.000  | -0.068 0.457 22.000  | 0.022 0.437 18.000   |
| modulo-4-2 40-030   | -1.248 -0.778 20.000 | 0.083 0.311 1.000    | -1.442 -1.025 23.000 | -1.439 -1.001 22.000 | -1.413 -0.944 21.000 | -1.486 -1.037 24.000 |
| modulo-4-2 40-060   | -0.815 -0.674 22.000 | 0.689 0.701 1.000    | -0.387 -0.373 17.000 | -0.740 -0.654 21.000 | -0.737 -0.720 20.000 | -0.387 -0.367 18.000 |
| modulo-4-2 40-180   | 0.820 0.874 13.000   | 0.925 0.933 2.000    | -0.582 -0.438 20.000 | -0.603 -0.488 22.000 | -0.561 -0.404 19.000 | -0.593 -0.443 21.000 |
| modulo-4-2 80-030   | -1.229 -1.132 18.000 | -0.939 -0.894 10.000 | -1.306 -1.224 20.000 | -1.555 -1.464 23.000 | -1.356 -1.248 21.000 | -1.285 -1.203 19.000 |
| modulo-4-2 80-060   | -0.987 -0.949 17.000 | 0.327 0.714 3.000    | -1.062 -1.057 21.000 | -1.030 -1.016 19.000 | -0.999 -0.981 18.000 | -1.047 -1.047 20.000 |
| modulo-4-2 80-180   | 0.736 0.738 3.000    | 0.721 0.808 4.000    | -1.233 -1.067 21.500 | -1.261 -1.117 23.000 | -1.229 -1.077 20.000 | -1.233 -1.067 21.500 |
| modulo-8-2 10-030   | -1.431 -1.325 20.000 | 0.010 0.433 1.000    | -1.520 -1.199 22.000 | -1.656 -1.086 24.000 | -1.564 -1.384 23.000 | -1.451 -1.105 21.000 |
| modulo-8-2 10-060   | -1.076 -0.797 22.000 | 0.914 0.984 1.000    | -1.063 -0.802 21.000 | -0.924 -0.752 20.000 | -0.810 -0.677 18.000 | -1.097 -0.815 23.000 |
| modulo-8-2 10-180   | -1.881 -1.537 21.000 | 1.202 1.228 1.000    | -1.825 -1.578 19.000 | -1.979 -1.593 23.000 | -1.885 -1.570 22.000 | -1.828 -1.572 20.000 |
| modulo-8-2 20-030   | -1.477 -0.780 20.000 | -0.202 0.333 3.000   | -1.794 -0.616 23.000 | -1.772 -0.661 21.000 | -1.901 -0.982 24.000 | -1.775 -0.514 22.000 |
| modulo-8-2 20-060   | -1.849 -1.649 23.000 | 0.499 0.798 2.000    | -1.867 -1.547 24.000 | -1.838 -1.474 21.000 | -1.653 -1.623 20.000 | -1.846 -1.518 22.000 |
| modulo-8-2 20-180   | 0.049 0.170 17.000   | 1.025 1.040 1.000    | -0.390 -0.282 19.000 | -0.435 -0.314 21.000 | -0.491 -0.468 22.000 | -0.406 -0.273 20.000 |
| modulo-8-2 40-030   | -1.190 -0.642 19.000 | -0.457 -0.191 3.000  | -1.227 -0.436 21.000 | -1.305 -0.432 22.000 | -0.946 0.394 13.000  | -1.374 -0.420 23.000 |
| modulo-8-2 40-060   | -1.425 -0.983 20.000 | 0.273 0.642 2.000    | -1.456 -0.930 22.000 | -1.439 -0.967 21.000 | -1.571 -0.983 24.000 | -1.476 -0.930 23.000 |
| modulo-8-2 40-180   | -0.088 0.036 17.000  | 0.872 0.912 1.000    | -0.592 -0.489 20.000 | -0.630 -0.412 21.000 | -0.633 -0.425 22.000 | -0.584 -0.477 19.000 |
| modulo-8-2 80-030   | -1.491 -1.206 19.000 | -0.975 -0.406 11.000 | -1.696 -1.159 21.000 | -1.781 -1.338 22.000 | -1.866 -1.435 24.000 | -1.798 -1.178 23.000 |
| modulo-8-2 80-060   | -0.884 -0.771 13.000 | 0.296 0.518 1.000    | -1.102 -0.962 19.000 | -1.001 -0.967 17.000 | -0.934 -0.812 15.000 | -1.106 -0.963 21.000 |
| modulo-8-2 80-180   | -0.433 -0.305 16.000 | 0.727 0.832 10.000   | -1.193 -1.040 22.000 | -1.057 -0.864 20.000 | -1.027 -0.899 19.000 | -1.192 -1.033 21.000 |
| only-a0-cp-2 10-030 | 1.383 1.383 4.000    | 1.377 1.377 6.000    | 1.389 1.389 3.000    | 1.377 1.377 6.000    | 1.377 1.377 6.000    | 1.406 1.406 2.000    |
| only-a0-cp-2 10-060 | 1.420 1.420 3.500    | 1.415 1.415 7.000    | 1.420 1.420 3.500    | 1.418 1.418 5.500    | 1.418 1.418 5.500    | 1.425 1.425 2.000    |
| only-a0-cp-2 10-180 | 1.419 1.419 7.000    | 1.424 1.424 5.000    | 1.425 1.425 3.000    | 1.424 1.424 5.000    | 1.424 1.424 5.000    | 1.427 1.427 2.000    |
| only-a0-cp-2 20-030 | 1.119 1.119 4.000    | 1.093 1.093 7.000    | 1.131 1.131 3.000    | 1.111 1.111 6.000    | 1.116 1.116 5.000    | 1.152 1.152 2.000    |
| only-a0-cp-2 20-060 | 1.146 1.146 4.500    | 1.146 1.146 4.500    | 1.152 1.152 3.000    | 1.145 1.145 6.000    | 1.144 1.144 7.000    | 1.163 1.163 2.000    |
| only-a0-cp-2 20-180 | 1.162 1.162 4.000    | 1.137 1.137 7.000    | 1.164 1.164 3.000    | 1.159 1.159 5.500    | 1.159 1.159 5.500    | 1.170 1.170 2.000    |
| only-a0-cp-2 40-030 | 1.013 1.013 9.000    | 0.939 0.939 20.000   | 1.026 1.026 3.500    | 1.011 1.011 11.000   | 1.010 1.010 12.000   | 1.052 1.052 2.000    |
| only-a0-cp-2 40-060 | 1.022 1.022 16.500   | 0.970 0.970 21.000   | 1.045 1.045 3.000    | 1.031 1.031 8.000    | 1.031 1.031 8.000    | 1.062 1.062 2.000    |
| only-a0-cp-2 40-180 | 1.052 1.052 6.000    | 1.042 1.042 7.000    | 1.075 1.075 3.0      |                      |                      |                      |

| <i>LogON</i>         | <i>LeaN</i>          | <i>LeaGITc3APN</i>   | <i>LeaGtN</i>        | <i>LeaGfN</i>        | <i>LeaGlN</i>        | <i>LeaTc3N</i>       |
|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| 1.111 1.111 1.000    | 0.985 0.985 15.000   | 1.030 1.030 7.000    | 0.940 0.940 22.000   | 0.908 0.908 24.000   | 0.975 0.975 18.500   | 1.008 1.008 10.000   |
| 1.111 1.111 1.000    | 1.034 1.034 15.000   | 0.963 0.963 23.000   | 0.966 0.966 22.000   | 0.987 0.987 21.000   | 0.903 0.903 24.000   | 1.051 1.051 9.000    |
| 1.111 1.111 1.000    | 1.014 1.014 15.000   | 0.975 0.975 22.000   | 0.823 0.823 24.000   | 0.927 0.927 23.000   | 1.021 1.021 11.000   | 1.020 1.020 12.000   |
| 1.053 1.053 1.000    | 1.005 1.005 10.500   | 0.965 0.965 18.000   | 0.947 0.947 20.000   | 0.939 0.939 21.000   | 0.900 0.900 24.000   | 1.005 1.005 10.500   |
| 1.053 1.053 1.000    | 1.002 1.002 13.500   | 0.931 0.931 23.000   | 0.972 0.972 21.000   | 0.929 0.929 24.000   | 0.952 0.952 22.000   | 0.995 0.995 18.000   |
| 1.053 1.053 1.000    | 1.004 1.004 16.000   | 0.940 0.940 23.000   | 0.840 0.840 24.000   | 0.957 0.957 21.000   | 0.942 0.942 22.000   | 1.005 1.005 15.000   |
| 1.026 1.026 1.000    | 0.997 0.997 7.500    | 0.965 0.965 18.000   | 0.938 0.938 22.000   | 0.953 0.953 21.000   | 0.959 0.959 20.000   | 1.005 1.005 3.000    |
| 1.026 1.026 1.000    | 0.998 0.998 9.500    | 0.956 0.956 22.000   | 0.880 0.880 24.000   | 0.917 0.917 23.000   | 0.972 0.972 19.000   | 1.000 1.000 5.000    |
| 1.026 1.026 1.000    | 1.000 1.000 11.500   | 0.985 0.985 21.000   | 0.928 0.928 24.000   | 0.967 0.967 23.000   | 0.980 0.980 22.000   | 0.997 0.997 18.000   |
| 1.013 1.013 1.000    | 0.989 0.989 7.000    | 0.971 0.971 13.000   | 0.907 0.907 22.000   | 0.915 0.915 21.000   | 0.959 0.959 16.000   | 0.993 0.993 2.000    |
| 1.013 1.013 1.000    | 0.996 0.996 5.000    | 0.980 0.980 17.500   | 0.906 0.906 24.000   | 0.960 0.960 21.000   | 0.973 0.973 19.000   | 0.996 0.996 5.000    |
| 1.013 1.013 1.000    | 0.998 0.998 11.500   | 0.984 0.984 19.000   | 0.926 0.926 24.000   | 0.928 0.928 23.000   | 0.980 0.980 20.000   | 0.998 0.998 11.500   |
| -1.421 -1.153 25.000 | 0.950 1.013 4.000    | 0.734 0.774 15.000   | 0.336 0.771 17.000   | 0.898 1.042 5.000    | 0.763 1.035 13.000   | 0.757 0.860 14.000   |
| -1.220 -0.562 24.000 | 0.998 1.068 8.000    | 0.955 1.088 12.000   | 0.954 1.010 13.000   | 0.845 0.987 18.000   | 0.977 1.029 11.000   | 1.142 1.180 1.000    |
| -0.507 0.400 20.000  | 1.107 1.146 7.000    | 1.102 1.108 8.000    | 0.826 0.939 17.000   | 0.845 0.885 16.000   | 0.801 0.846 18.000   | 1.045 1.121 13.000   |
| -1.017 -0.460 19.000 | 0.069 0.566 8.000    | 0.531 0.551 2.000    | -0.558 0.092 17.000  | -0.379 0.188 16.000  | 0.169 0.523 4.000    | 0.075 0.095 7.000    |
| -1.895 -0.931 27.000 | 0.990 1.043 5.000    | 0.833 0.894 13.000   | 0.535 0.573 18.000   | 0.756 0.815 14.000   | 0.703 0.897 15.000   | 0.996 1.023 4.000    |
| -0.699 -0.692 20.000 | 0.903 0.932 11.000   | 0.918 0.976 4.000    | 0.792 0.819 17.000   | 0.677 0.716 18.000   | 0.900 0.917 12.000   | 0.874 0.980 15.000   |
| -1.179 -0.288 20.000 | 0.595 0.777 4.000    | 0.260 0.581 10.000   | 0.050 0.303 15.000   | 0.161 0.275 12.000   | -0.031 0.053 16.000  | 0.522 0.697 6.000    |
| -0.648 -0.577 20.000 | 0.720 0.788 5.000    | 0.661 0.687 10.000   | 0.461 0.585 15.000   | 0.665 0.698 9.000    | 0.639 0.649 13.000   | 0.341 0.557 17.000   |
| -1.357 -1.307 22.000 | 0.781 0.905 12.000   | 0.866 0.911 6.000    | 0.539 0.708 18.000   | 0.581 0.724 17.000   | 0.849 0.867 7.000    | 0.953 0.995 2.000    |
| -1.284 -0.921 22.000 | -0.925 -0.848 12.500 | -1.190 -0.513 21.000 | -1.138 -0.781 19.000 | -1.177 -0.913 20.000 | -0.661 -0.432 9.000  | -0.357 -0.133 3.000  |
| -1.175 -0.568 21.000 | -0.215 -0.163 12.000 | 0.360 0.419 5.000    | -0.661 0.031 17.000  | -0.440 -0.388 15.000 | 0.012 0.244 7.000    | 0.082 0.098 6.000    |
| -1.221 -0.837 25.000 | 0.660 0.716 12.000   | 0.913 0.931 1.000    | 0.517 0.558 16.000   | 0.441 0.492 18.000   | 0.792 0.806 6.000    | 0.784 0.791 7.000    |
| -1.485 -0.967 24.000 | -0.404 0.066 9.000   | -0.200 0.191 5.000   | -0.802 0.465 20.000  | -0.273 0.577 7.000   | -0.756 0.078 19.000  | -0.571 0.021 12.000  |
| -1.603 -0.414 18.000 | -0.706 0.973 10.000  | -0.158 0.867 5.000   | -1.797 -0.036 21.000 | -0.730 0.550 11.000  | -0.586 0.937 9.000   | 0.308 0.907 4.000    |
| -1.770 -0.588 23.000 | 0.484 0.853 8.000    | 1.061 1.290 3.000    | -1.04 1.028 18.000   | 0.569 0.916 6.000    | 0.021 0.487 17.000   | 0.695 1.122 5.000    |
| -1.106 -0.759 6.000  | -1.827 -0.889 24.000 | -1.991 -0.354 27.000 | -1.230 -0.582 12.000 | -1.541 -0.948 17.000 | -1.548 -0.891 18.000 | -1.708 0.378 21.000  |
| -1.567 -0.584 23.000 | -1.494 -0.401 13.000 | -1.144 -0.502 7.000  | -1.079 -0.212 5.000  | -1.383 -0.612 12.000 | -1.558 -0.974 22.000 | -1.703 -0.582 24.000 |
| -0.855 -0.001 15.000 | -0.230 0.074 5.000   | -0.739 -0.052 13.000 | -0.865 -0.355 16.000 | -1.297 -0.651 18.000 | -1.437 -1.098 20.000 | -0.407 0.604 11.000  |
| -1.291 -0.748 21.000 | -0.762 0.272 5.000   | -1.292 0.004 22.000  | -0.465 0.317 1.000   | -1.034 -0.339 13.000 | -1.327 -0.337 23.000 | -0.739 0.134 3.000   |
| -1.450 -0.793 25.000 | -1.202 -0.519 10.000 | -1.278 -0.505 18.000 | -1.568 -0.382 26.000 | -1.217 -0.546 11.000 | -1.401 -0.174 23.000 | -1.249 -0.559 14.000 |
| -1.184 -0.622 11.000 | -0.755 -0.354 5.000  | -1.493 -0.887 24.000 | -1.521 -0.237 25.000 | -1.281 -1.003 13.000 | -1.489 -1.129 23.000 | -1.103 -0.682 10.000 |
| -1.453 -0.035 25.000 | -1.312 -0.879 22.500 | -1.268 -0.655 19.000 | -1.152 -0.516 7.000  | -1.256 -0.509 18.000 | -1.277 -0.799 21.000 | -1.519 -0.995 26.000 |
| -0.949 -0.578 8.000  | -0.900 -0.657 4.000  | -1.016 -0.647 13.000 | -0.993 -0.618 12.000 | -0.805 -0.382 3.000  | -1.059 -0.376 16.000 | -1.307 -0.105 25.000 |
| -1.095 0.150 7.000   | -1.356 -0.457 20.000 | -1.157 -0.587 11.000 | -0.799 -0.436 3.000  | -1.012 -0.344 5.000  | -0.715 -0.146 2.000  | -1.081 -0.609 6.000  |
| nan nan nan          | 0.897 0.898 1.000    | 0.529 0.706 12.000   | -0.237 0.536 17.000  | 0.587 0.841 11.000   | 0.747 0.812 5.000    | 0.738 0.868 6.000    |
| nan nan nan          | 0.624 0.926 9.000    | 0.891 0.918 2.000    | 0.328 0.851 15.000   | 0.867 0.938 3.000    | 0.385 0.453 14.000   | 0.821 1.033 4.000    |
| nan nan nan          | 1.076 1.157 9.000    | 1.100 1.105 3.000    | 0.595 1.043 16.000   | 1.028 1.058 13.000   | 1.077 1.095 7.000    | 0.980 1.105 15.000   |
| nan nan nan          | 0.371 0.633 4.000    | -0.277 -0.127 9.000  | 0.478 0.664 3.000    | -1.166 -0.693 17.000 | -0.318 -0.236 10.000 | -0.509 0.051 11.000  |
| nan nan nan          | -0.609 -0.572 8.000  | 0.365 0.471 4.000    | -0.295 0.477 7.000   | -0.030 0.288 5.000   | -1.036 -0.188 16.000 | 0.465 0.583 3.000    |
| nan nan nan          | 0.981 0.992 8.000    | 0.763 0.802 15.000   | 0.209 0.669 17.000   | 0.923 0.953 13.000   | 0.917 0.933 14.000   | 1.027 1.058 1.000    |
| nan nan nan          | -0.620 -0.556 11.000 | -1.117 -0.657 17.000 | -0.797 -0.435 14.000 | -0.452 0.216 5.000   | 0.071 0.464 2.000    | -0.978 -0.747 16.000 |
| nan nan nan          | 0.618 0.714 7.000    | 0.630 0.728 6.000    | 0.128 0.358 15.000   | 0.279 0.521 13.000   | 0.311 0.597 12.000   | 0.680 0.752 2.000    |
| nan nan nan          | 0.868 0.908 5.000    | 0.851 0.921 10.000   | 0.720 0.795 15.000   | 0.552 0.611 16.000   | 0.874 0.927 4.000    | 0.933 0.948 1.000    |
| nan nan nan          | -0.537 -0.512 4.000  | -1.080 -0.105 16.000 | -0.700 -0.693 8.000  | -1.135 -0.826 17.000 | -1.523 -1.483 22.000 | -0.954 -0.890 11.000 |
| nan nan nan          | 0.286 0.409 5.000    | 0.243 0.412 7.000    | 0.332 0.660 2.000    | -0.584 0.239 15.000  | -0.031 0.043 8.000   | -1.141 -0.881 23.000 |
| nan nan nan          | -0.583 -0.349 12.000 | 0.744 0.824 2.000    | -0.786 -0.445 17.000 | 0.525 0.631 8.000    | 0.563 0.610 7.000    | 0.835 0.849 1.000    |
| nan nan nan          | -1.122 -0.968 15.000 | -0.324 -0.146 3.000  | -0.884 -0.870 9.000  | -1.362 -0.832 18.000 | -1.184 -1.028 17.000 | -0.731 -0.136 6.000  |
| nan nan nan          | 0.467 0.716 7.000    | 0.699 0.868 3.000    | -0.109 0.802 16.000  | 0.403 0.786 10.000   | 0.183 0.351 12.000   | 0.517 0.636 6.000    |
| nan nan nan          | 0.529 0.994 13.000   | 0.719 0.829 6.000    | 0.111 0.783 16.000   | 0.678 0.717 7.000    | 0.863 0.960 3.000    | 0.801 1.060 4.000    |
| nan nan nan          | -0.536 -0.525 8.000  | -0.812 -0.711 13.000 | -0.536 0.078 9.000   | 0.007 0.038 1.000    | -0.587 0.042 12.000  | -0.997 -0.421 15.000 |
| nan nan nan          | -1.066 -0.904 12.000 | -0.808 -0.081 9.000  | -0.752 -0.589 8.000  | -0.698 -0.584 5.000  | -0.205 -0.101 4.000  | -1.579 0.039 19.000  |
| nan nan nan          | 0.784 0.962 10.000   | 0.806 0.843 7.000    | 0.619 0.737 15.000   | 0.886 0.890 2.000    | 0.790 0.805 9.000    | 0.725 0.919 14.000   |
| nan nan nan          | -0.839 -0.821 8.000  | -1.160 -0.906 18.000 | -0.578 -0.549 4.000  | -1.512 -0.833 24.000 | -1.066 -1.053 16.000 | -0.917 -0.876 11.000 |
| nan nan nan          | -1.084 -0.771 14.000 | -0.089 -0.031 3.000  | -1.172 -0.942 19.000 | -0.607 -0.474 5.000  | -1.166 -0.897 18.000 | -0.695 -0.612 8.000  |
| nan nan nan          | 0.857 0.885 2.000    | 0.694 0.740 9.000    | 0.215 0.648 15.000   | 0.526 0.569 13.000   | 0.768 0.778 7.000    | 0.833 0.859 5.000    |
| nan nan nan          | -0.560 -0.544 6.000  | -1.066 -0.938 17.000 | -1.062 -0.991 16.000 | -1.048 -1.023 15.000 | -1.160 -0.859 18.000 | -0.730 -0.669 8.000  |
| nan nan nan          | -0.290 -0.121 4.000  | -1.083 -0.872 18.000 | 0.092 0.156 2.000    | -0.690 -0.677 11.000 | -0.887 -0.850 14.000 | -0.646 -0.518 8.000  |
| nan nan nan          | 0.921 0.929 2.000    | 0.761 0.826 8.000    | 0.621 0.744 12.000   | -0.506 -0.422 17.000 | 0.650 0.706 11.000   | 0.728 0.776 9.000    |
| 1.428 1.428 1.000    | 1.156 1.156 15.000   | 0.952 0.952 24.000   | 0.959 0.959 23.000   | 1.280 1.280 8.000    | 1.061 1.061 19.000   | 1.130 1.130 17.000   |
| 1.429 1.429 1.000    | 1.231 1.231 15.000   | 1.050 1.050 20.000   | 1.026 1.026 21.000   | 1.104 1.104 19.000   | 1.172 1.172 17.000   | 1.247 1.247 10.000   |
| 1.429 1.429 1.000    | 1.245 1.245 9.000    | 1.225 1.225 15.000   | 0.863 0.863 24.000   | 0.944 0.944 23.000   | 1.057 1.057 22.000   | 1.206 1.206 19.000   |
| 1.176 1.176 1.000    | 1.052 1.052 10.000   | 1.020 1.020 19.000   | 0.768 0.768 24.000   | 0.955 0.955 22.000   | 0.850 0.850 23.000   | 1.055 1.055 9.000    |
| 1.176 1.176 1.000    | 1.019 1.019 13.000   | 0.977 0.977 22.000   | 0.772 0.772 24.000   | 0.969 0.969 23.000   | 0.992 0.992 19.000   | 1.021 1.021 10.000   |
| 1.176 1.176 1.000    | 1.080 1.080 14.500   | 1.006 1.006 22.000   | 0.927 0.927 24.000   | 0.978 0.978 23.000   | 1.007 1.007 21.000   | 1.078 1.078 16.000   |
| 1.081 1.081 1.000    | 1.016 1.016 7.500    | 0.981 0.981 18.000   | 0.864 0.864 24.000   | 0.876 0.876 23.000   | 0.967 0.967 19.000   | 1.022 1.022 5.000    |
| 1.081 1.081 1.000    | 1.031 1.031 8.000    | 0.994 0.994 19.000   | 0.856 0.856 24.000   | 0.943 0.943 22.000   | 0.972 0.972 20.000   | 1.031 1.031 8.000    |
| 1.081 1.081 1.000    | 0.995 0.995 15.5     |                      |                      |                      |                      |                      |

| <i>Lea + kNN</i> | <i>LeucN</i> | <i>Lea + bagtreeN</i> | <i>Lea + bayesN</i> | <i>LeaAPN</i> | <i>LeaBrSN</i> | <i>LeaISN</i> | <i>LeaAUCN</i> |        |        |        |        |        |        |        |        |        |        |        |        |        |
|------------------|--------------|-----------------------|---------------------|---------------|----------------|---------------|----------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 1.001            | 1.001        | 12.000                | 0.986               | 0.986         | 14.000         | 0.958         | 0.958          | 21.000 | 0.996  | 0.996  | 13.000 | -1.318 | -1.318 | 27.000 | 1.027  | 1.027  | 9.000  | 0.977  | 0.977  | 16.500 |
| 1.049            | 1.049        | 10.000                | 1.039               | 1.039         | 13.000         | 1.066         | 1.066          | 8.000  | 1.044  | 1.044  | 12.000 | -1.250 | -1.250 | 27.000 | 1.046  | 1.046  | 11.000 | 1.028  | 1.028  | 17.000 |
| 1.016            | 1.016        | 13.000                | 1.009               | 1.009         | 21.000         | 1.022         | 1.022          | 9.500  | 1.013  | 1.013  | 16.000 | -1.179 | -1.179 | 26.000 | 1.015  | 1.015  | 14.000 | 1.010  | 1.010  | 19.000 |
| 0.952            | 0.952        | 19.000                | 0.990               | 0.990         | 17.000         | 1.004         | 1.004          | 12.000 | 1.006  | 1.006  | 9.000  | -1.136 | -1.136 | 27.000 | 1.002  | 1.002  | 13.500 | 1.001  | 1.001  | 15.500 |
| 0.992            | 0.992        | 20.000                | 1.003               | 1.003         | 10.500         | 0.994         | 0.994          | 19.000 | 1.003  | 1.003  | 10.500 | -1.141 | -1.141 | 27.000 | 0.999  | 0.999  | 17.000 | 1.002  | 1.002  | 13.500 |
| 1.008            | 1.008        | 13.000                | 1.001               | 1.001         | 17.500         | 1.014         | 1.014          | 8.500  | 1.007  | 1.007  | 14.000 | -1.125 | -1.125 | 27.000 | 1.014  | 1.014  | 8.500  | 1.012  | 1.012  | 11.500 |
| 0.923            | 0.923        | 24.000                | 0.988               | 0.988         | 13.000         | 0.996         | 0.996          | 9.000  | 0.997  | 0.997  | 7.500  | -1.078 | -1.078 | 27.000 | 1.004  | 1.004  | 4.000  | 0.999  | 0.999  | 5.500  |
| 0.960            | 0.960        | 21.000                | 1.001               | 1.001         | 4.000          | 0.994         | 0.994          | 13.000 | 0.998  | 0.998  | 9.500  | -1.057 | -1.057 | 27.000 | 1.004  | 1.004  | 3.000  | 0.999  | 0.999  | 7.000  |
| 0.995            | 0.995        | 20.000                | 0.998               | 0.998         | 17.000         | 0.996         | 0.996          | 19.000 | 1.000  | 1.000  | 11.500 | -1.058 | -1.058 | 27.000 | 1.001  | 1.001  | 8.000  | 1.000  | 1.000  | 11.500 |
| 0.889            | 0.889        | 23.000                | 0.987               | 0.987         | 9.500          | 0.989         | 0.989          | 7.000  | 0.989  | 0.989  | 7.000  | -1.055 | -1.055 | 27.000 | 0.992  | 0.992  | 4.000  | 0.992  | 0.992  | 4.000  |
| 0.921            | 0.921        | 23.000                | 0.992               | 0.992         | 13.500         | 0.996         | 0.996          | 5.000  | 0.995  | 0.995  | 9.000  | -1.064 | -1.064 | 27.000 | 0.995  | 0.995  | 9.000  | 0.996  | 0.996  | 5.000  |
| 0.968            | 0.968        | 21.000                | 0.997               | 0.997         | 15.000         | 0.996         | 0.996          | 17.000 | 0.998  | 0.998  | 11.500 | -1.044 | -1.044 | 27.000 | 0.998  | 0.998  | 11.500 | 0.999  | 0.999  | 7.500  |
| 0.802            | 0.945        | 10.000                | 1.049               | 1.068         | 1.000          | -1.023        | -0.594         | 19.000 | 1.011  | 1.024  | 2.000  | -1.626 | -1.511 | 27.000 | 0.967  | 1.025  | 3.000  | 0.795  | 0.940  | 11.500 |
| 1.033            | 1.057        | 4.000                 | 1.039               | 1.103         | 3.000          | -1.306        | -0.685         | 25.000 | 1.093  | 1.100  | 2.000  | -1.349 | -1.171 | 26.000 | 1.021  | 1.130  | 7.000  | 1.033  | 1.053  | 5.500  |
| 1.068            | 1.098        | 12.000                | 1.138               | 1.150         | 6.000          | -1.433        | -0.147         | 23.000 | 1.069  | 1.125  | 11.000 | -1.398 | -1.338 | 22.000 | 1.042  | 1.107  | 14.000 | 1.100  | 1.134  | 9.500  |
| 0.672            | 0.679        | 1.000                 | -0.245              | 0.399         | 15.000         | -1.693        | -0.420         | 25.000 | 0.080  | 0.563  | 6.000  | -1.889 | -1.024 | 27.000 | 0.149  | 0.290  | 5.000  | -0.016 | 0.528  | 10.500 |
| 0.902            | 0.949        | 11.000                | 0.986               | 0.990         | 7.000          | -1.032        | -0.952         | 20.000 | 1.009  | 1.042  | 3.000  | -1.214 | -1.176 | 21.000 | 0.989  | 1.013  | 6.000  | 1.019  | 1.039  | 1.500  |
| 0.920            | 0.930        | 3.000                 | 0.904               | 0.938         | 10.000         | -1.593        | -0.805         | 23.000 | 0.910  | 0.939  | 7.000  | -1.318 | -1.292 | 22.000 | 0.912  | 0.960  | 6.000  | 0.910  | 0.941  | 8.500  |
| 0.242            | 0.384        | 11.000                | 0.536               | 0.659         | 5.000          | -0.913        | -0.352         | 19.000 | 0.596  | 0.777  | 3.000  | -1.807 | -1.342 | 26.000 | 0.139  | 0.506  | 13.000 | 0.606  | 0.763  | 1.500  |
| 0.753            | 0.825        | 4.000                 | 0.792               | 0.833         | 3.000          | -0.822        | -0.718         | 21.000 | 0.719  | 0.789  | 6.000  | -1.718 | -1.554 | 27.000 | 0.875  | 0.880  | 1.000  | 0.713  | 0.787  | 7.500  |
| 0.870            | 0.916        | 5.000                 | 0.924               | 0.980         | 4.000          | -1.461        | -1.129         | 27.000 | 0.784  | 0.905  | 11.000 | -1.256 | -1.090 | 21.000 | 0.776  | 0.866  | 13.000 | 0.787  | 0.896  | 9.500  |
| -0.379           | 0.046        | 4.000                 | -0.383              | -0.374        | 5.000          | -1.020        | -0.887         | 14.000 | -0.925 | -0.848 | 12.500 | -1.038 | -0.985 | 16.000 | -1.042 | -0.919 | 17.000 | -0.638 | -0.579 | 7.500  |
| 0.489            | 0.507        | 2.000                 | 0.538               | 0.650         | 1.000          | -1.022        | -0.786         | 20.000 | -0.216 | -0.164 | 13.000 | -1.243 | -1.206 | 22.000 | -0.765 | -0.753 | 18.000 | -0.209 | -0.180 | 10.500 |
| 0.858            | 0.883        | 3.000                 | 0.879               | 0.918         | 2.000          | -0.995        | -0.791         | 20.000 | 0.662  | 0.720  | 11.000 | -1.577 | -1.507 | 27.000 | 0.795  | 0.816  | 5.000  | 0.666  | 0.731  | 9.500  |
| -0.576           | -0.165       | 13.000                | -0.876              | -0.362        | 21.000         | -1.810        | -0.453         | 27.000 | -0.216 | 0.118  | 6.000  | -1.533 | -1.243 | 25.000 | -1.013 | 0.367  | 22.000 | -0.129 | 0.092  | 3.500  |
| -0.321           | 1.074        | 6.000                 | -0.880              | 0.613         | 12.000         | -1.962        | -0.487         | 27.000 | -0.517 | 0.954  | 8.000  | -1.733 | -0.182 | 20.000 | 0.541  | 1.025  | 2.000  | -0.931 | 0.786  | 15.500 |
| 0.529            | 1.013        | 7.000                 | 0.441               | 0.956         | 10.000         | -1.889        | -0.224         | 25.000 | 0.912  | 1.128  | 4.000  | -1.931 | -1.086 | 26.000 | 1.090  | 1.320  | 2.000  | 0.421  | 0.797  | 11.500 |
| -1.060           | -0.113       | 5.000                 | -0.915              | -0.503        | 3.000          | -1.314        | 0.060          | 13.000 | -1.814 | -0.884 | 23.000 | -0.638 | 0.036  | 1.000  | -0.986 | -0.651 | 4.000  | -1.935 | -0.729 | 25.500 |
| -1.714           | -0.596       | 26.000                | -1.710              | 0.077         | 25.000         | -1.527        | -0.587         | 19.000 | -1.530 | -0.385 | 20.000 | -1.033 | -0.030 | 3.000  | -1.541 | -0.250 | 21.000 | -1.512 | -0.407 | 17.500 |
| -0.183           | 0.482        | 4.000                 | -1.469              | -0.410        | 21.000         | -0.852        | -0.605         | 14.000 | -0.285 | 0.030  | 7.000  | -1.487 | -1.045 | 26.000 | 0.151  | 0.859  | 3.000  | -0.352 | -0.015 | 9.500  |
| -1.497           | 0.105        | 24.000                | -0.843              | 0.567         | 9.000          | -0.685        | -0.168         | 2.000  | -0.759 | 0.276  | 4.000  | -1.830 | -0.722 | 25.000 | -1.170 | -0.650 | 18.000 | -0.971 | 0.125  | 11.500 |
| -1.052           | -0.170       | 3.000                 | -1.196              | -0.275        | 9.000          | -1.833        | -0.668         | 27.000 | -1.226 | -0.528 | 12.000 | -1.239 | -0.683 | 13.000 | -0.948 | -0.497 | 2.000  | -1.103 | -0.539 | 5.500  |
| -1.322           | -0.358       | 15.000                | -1.280              | -0.520        | 12.000         | -1.287        | -0.403         | 14.000 | -0.717 | -0.311 | 3.000  | -1.368 | -0.975 | 17.000 | -1.398 | -0.584 | 22.000 | -0.496 | -0.102 | 1.500  |
| -1.276           | -0.544       | 20.000                | -1.075              | -0.648        | 4.000          | -1.241        | -0.519         | 12.000 | -1.312 | -0.879 | 22.500 | -1.070 | -0.874 | 1.000  | -1.541 | -0.943 | 27.000 | -1.255 | -0.932 | 16.500 |
| -1.374           | -0.578       | 26.000                | -1.098              | -0.660        | 17.000         | -0.925        | -0.472         | 7.000  | -0.916 | -0.673 | 6.000  | -1.129 | -0.834 | 18.000 | -0.909 | -0.349 | 5.000  | -1.028 | -0.777 | 14.500 |
| -0.682           | -0.255       | 1.000                 | -1.251              | -0.038        | 19.000         | -1.147        | -0.304         | 10.000 | -1.364 | -0.422 | 21.000 | -1.523 | -0.302 | 27.000 | -1.104 | -0.323 | 8.000  | -1.377 | -0.057 | 23.500 |
| 0.505            | 0.805        | 13.000                | 0.824               | 0.855         | 3.000          | -0.041        | 0.490          | 16.000 | 0.833  | 0.891  | 2.000  | -1.761 | -1.650 | 24.000 | 0.760  | 0.777  | 4.000  | 0.736  | 0.809  | 7.000  |
| 0.677            | 1.060        | 7.000                 | 0.655               | 1.041         | 8.000          | -1.559        | -0.431         | 19.000 | 0.681  | 0.915  | 6.000  | -1.561 | -1.327 | 20.000 | 0.722  | 0.919  | 5.000  | 0.502  | 0.810  | 11.000 |
| 0.988            | 1.109        | 14.000                | 1.040               | 1.121         | 12.000         | 0.517         | 0.712          | 17.000 | 1.071  | 1.154  | 10.000 | -1.408 | -1.403 | 23.000 | 1.068  | 1.152  | 11.000 | 1.088  | 1.146  | 5.000  |
| -0.512           | -0.374       | 12.000                | -0.668              | -0.321        | 14.000         | -1.483        | -0.958         | 22.000 | 0.511  | 0.621  | 2.000  | -1.734 | -1.391 | 24.000 | 0.537  | 0.708  | 1.000  | -0.527 | -0.187 | 13.000 |
| 0.552            | 0.704        | 2.000                 | -0.081              | -0.070        | 6.000          | -1.419        | -0.619         | 19.000 | -0.856 | -0.855 | 13.000 | -1.302 | -1.053 | 18.000 | -0.785 | -0.698 | 12.000 | -0.947 | -0.838 | 15.000 |
| 0.931            | 0.972        | 12.000                | 0.982               | 1.000         | 6.000          | 0.430         | 0.603          | 16.000 | 0.985  | 0.996  | 5.000  | -1.203 | -1.109 | 23.000 | 0.988  | 0.990  | 3.000  | 0.989  | 1.012  | 2.000  |
| -0.217           | -0.063       | 3.000                 | -0.710              | -0.521        | 12.000         | -0.868        | -0.691         | 15.000 | -0.612 | -0.543 | 10.000 | -1.136 | -1.100 | 19.000 | -0.730 | -0.655 | 13.000 | -0.519 | -0.515 | 6.000  |
| 0.399            | 0.415        | 8.000                 | 0.664               | 0.741         | 4.000          | -0.388        | 0.098          | 19.000 | 0.668  | 0.702  | 3.000  | -1.381 | -1.316 | 23.000 | 0.664  | 0.769  | 5.000  | 0.229  | 0.345  | 14.000 |
| 0.764            | 0.850        | 14.000                | 0.906               | 0.954         | 3.000          | -0.240        | -0.041         | 18.000 | 0.866  | 0.908  | 6.000  | -1.432 | -1.363 | 23.000 | 0.864  | 0.903  | 7.000  | 0.833  | 0.852  | 12.000 |
| -1.039           | -0.871       | 13.000                | -0.966              | -0.917        | 12.000         | -1.958        | -1.671         | 24.000 | -0.460 | -0.456 | 2.000  | -1.051 | -1.030 | 14.000 | -0.597 | -0.580 | 7.000  | -0.735 | -0.732 | 9.000  |
| -0.124           | 0.150        | 9.000                 | 0.280               | 0.605         | 6.000          | -0.943        | -0.210         | 16.000 | 0.322  | 0.335  | 4.000  | -1.076 | -1.061 | 22.000 | 0.757  | 0.775  | 1.000  | -0.438 | -0.436 | 14.000 |
| 0.591            | 0.753        | 6.000                 | 0.663               | 0.797         | 5.000          | -0.819        | -0.683         | 18.000 | -0.537 | -0.415 | 11.000 | -1.000 | -0.921 | 19.000 | -0.438 | -0.343 | 10.000 | -0.759 | -0.591 | 16.000 |
| -0.253           | 0.174        | 2.000                 | -0.394              | -0.299        | 4.000          | -0.866        | -0.262         | 8.000  | -1.036 | -1.026 | 12.000 | -1.399 | -1.837 | 19.000 | -1.029 | -1.003 | 11.000 | -0.835 | -      |        |

| <i>LeaAUC2N</i>      | <i>LeaSeN</i>        | <i>LeaSpN</i>        | <i>LeaRMSEN</i>      | <i>LeaSaN</i>        | <i>LeaSMN</i>        | <i>LeaS/sN</i>       |
|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| 0.977 0.977 16.500   | 0.935 0.935 23.000   | 1.029 1.029 8.000    | -1.246 -1.246 26.000 | 0.975 0.975 18.500   | 0.000 0.000 25.000   | 0.968 0.968 20.000   |
| 1.028 1.028 17.000   | 1.028 1.028 17.000   | 1.037 1.037 14.000   | -1.237 -1.237 26.000 | 1.012 1.012 19.000   | 0.000 0.000 25.000   | 1.009 1.009 20.000   |
| 1.010 1.010 19.000   | 1.010 1.010 19.000   | 1.022 1.022 9.500    | -1.180 -1.180 27.000 | 1.012 1.012 17.000   | 0.000 0.000 25.000   | 1.035 1.035 8.000    |
| 1.001 1.001 15.500   | 0.923 0.923 22.000   | 1.002 1.002 13.500   | -1.127 -1.127 26.000 | 1.007 1.007 7.500    | 0.000 0.000 25.000   | 1.007 1.007 7.500    |
| 1.002 1.002 13.500   | 1.009 1.009 7.000    | 1.000 1.000 16.000   | -1.115 -1.115 26.000 | 1.004 1.004 9.000    | 0.000 0.000 25.000   | 1.002 1.002 13.500   |
| 1.012 1.012 11.500   | 1.013 1.013 10.000   | 0.994 0.994 20.000   | -1.112 -1.112 26.000 | 0.999 0.999 19.000   | 0.000 0.000 25.000   | 1.001 1.001 17.500   |
| 0.999 0.999 5.500    | 0.960 0.960 19.000   | 0.985 0.985 14.000   | -1.055 -1.055 26.000 | 0.991 0.991 11.000   | 0.000 0.000 25.000   | 0.991 0.991 11.000   |
| 0.999 0.999 7.000    | 0.999 0.999 7.000    | 0.979 0.979 18.000   | -1.048 -1.048 26.000 | 0.994 0.994 13.000   | 0.000 0.000 25.000   | 0.994 0.994 13.000   |
| 1.000 1.000 11.500   | 1.000 1.000 11.500   | 1.000 1.000 11.500   | -1.054 -1.054 26.000 | 0.999 0.999 15.500   | 0.000 0.000 25.000   | 0.999 0.999 15.500   |
| 0.992 0.992 4.000    | 0.960 0.960 15.000   | 0.935 0.935 20.000   | -1.042 -1.042 26.000 | 0.983 0.983 11.500   | 0.000 0.000 25.000   | 0.983 0.983 11.500   |
| 0.996 0.996 5.000    | 0.967 0.967 20.000   | 0.995 0.995 9.000    | -1.032 -1.032 26.000 | 0.993 0.993 11.500   | 0.000 0.000 25.000   | 0.993 0.993 11.500   |
| 0.999 0.999 7.500    | 0.997 0.997 15.000   | 0.997 0.997 15.000   | -1.029 -1.029 26.000 | 0.999 0.999 7.500    | 0.000 0.000 25.000   | 0.999 0.999 7.500    |
| 0.795 0.940 11.500   | 0.545 0.901 16.000   | 0.897 1.076 6.000    | -1.529 -1.460 26.000 | 0.869 0.938 9.000    | 0.000 0.000 18.000   | 0.892 0.981 7.000    |
| 1.033 1.053 5.500    | 0.991 1.089 9.000    | 0.874 1.037 17.000   | -1.362 -1.237 27.000 | 0.921 1.046 14.000   | 0.000 0.000 19.000   | 0.906 1.061 16.000   |
| 1.100 1.134 9.500    | 1.021 1.102 15.000   | 1.175 1.182 2.000    | -1.396 -1.372 21.000 | 1.142 1.166 5.000    | 0.000 0.000 19.000   | 1.160 1.162 4.000    |
| -0.016 0.528 10.500  | -0.840 0.146 18.000  | -0.157 -0.102 14.000 | -1.707 -1.080 26.000 | -0.067 0.560 13.000  | 0.000 0.000 9.000    | -0.032 0.619 12.000  |
| 1.019 1.039 1.500    | 0.947 0.974 10.000   | 0.889 0.998 12.000   | -1.225 -1.164 22.000 | 0.950 1.011 9.000    | 0.000 0.000 19.000   | 0.960 1.015 8.000    |
| 0.910 0.941 8.500    | 0.914 0.935 5.000    | 0.856 0.934 16.000   | -1.293 -1.270 21.000 | 0.900 0.923 13.000   | 0.000 0.000 19.000   | 0.889 0.939 14.000   |
| 0.606 0.763 1.500    | 0.126 0.363 14.000   | -0.617 -0.610 18.000 | -1.874 -1.535 27.000 | 0.271 0.610 9.000    | -0.384 -0.384 17.000 | 0.276 0.608 8.000    |
| 0.713 0.787 7.500    | 0.207 0.265 18.000   | 0.479 0.708 14.000   | -1.639 -1.544 26.000 | 0.642 0.737 12.000   | 0.000 0.000 19.000   | 0.648 0.746 11.000   |
| 0.787 0.896 9.500    | 0.789 0.928 8.000    | 0.774 0.886 14.000   | -1.222 -1.087 20.000 | 0.763 0.898 15.000   | 0.000 0.000 19.000   | 0.760 0.893 16.000   |
| -0.638 -0.579 7.500  | -1.032 -0.981 15.000 | -0.506 -0.497 6.000  | -1.051 -0.986 18.000 | -0.854 -0.789 10.000 | -0.236 0.000 2.000   | -0.856 -0.792 11.000 |
| -0.209 -0.180 10.500 | -0.469 -0.380 16.000 | -0.806 -0.806 19.000 | -1.292 -1.247 23.000 | -0.204 -0.159 8.000  | -0.268 0.000 14.000  | -0.206 -0.163 9.000  |
| 0.666 0.731 9.500    | 0.651 0.670 13.000   | 0.476 0.623 17.000   | -1.512 -1.451 26.000 | 0.621 0.682 14.000   | 0.000 0.000 19.000   | 0.619 0.684 15.000   |
| -0.129 0.092 3.500   | -1.252 -0.527 23.000 | -0.296 0.647 8.000   | -1.681 -1.138 26.000 | -0.488 0.055 11.000  | 0.000 0.476 2.000    | -0.431 0.108 10.000  |
| -0.931 0.786 15.500  | -0.466 0.871 7.000   | -1.000 0.544 17.000  | -1.647 0.236 19.000  | -0.910 0.973 13.000  | 0.460 0.575 3.000    | -0.927 0.889 14.000  |
| 0.421 0.797 11.500   | 0.365 0.717 13.000   | 0.460 0.843 9.000    | -1.864 -1.500 24.000 | 0.295 0.659 14.000   | 0.276 0.276 15.000   | 0.096 0.534 16.000   |
| -1.935 -0.729 25.500 | -1.438 -0.946 16.000 | -1.382 -0.429 14.000 | -0.759 0.065 2.000   | -1.716 -0.892 22.000 | -1.613 0.000 19.000  | -1.689 -0.876 20.000 |
| -1.512 -0.407 17.500 | -1.907 -0.430 27.000 | -1.006 0.151 2.000   | -1.053 0.053 4.000   | -1.494 -0.388 14.000 | -1.509 0.000 16.000  | -1.506 -0.410 15.000 |
| -0.352 -0.015 9.500  | -0.895 0.097 17.000  | -0.427 -0.223 12.000 | -1.413 -1.120 19.000 | -0.282 0.011 6.000   | 0.346 0.577 2.000    | -0.314 0.026 8.000   |
| -0.971 0.125 11.500  | -0.831 -0.168 8.000  | -0.937 0.087 10.000  | -1.844 -0.775 26.000 | -0.779 0.290 7.000   | -1.846 0.000 27.000  | -0.775 0.294 6.000   |
| -1.103 -0.539 5.500  | -1.416 -0.204 24.000 | -1.076 -0.363 4.000  | -1.369 -0.711 22.000 | -1.257 -0.599 15.000 | -0.510 -0.255 1.000  | -1.183 -0.531 7.000  |
| -0.496 -0.102 1.500  | -0.954 -0.622 9.000  | -0.765 -0.446 7.000  | -1.347 -0.967 16.000 | -0.760 -0.380 6.000  | -1.524 -1.143 26.000 | -0.777 -0.380 8.000  |
| -1.255 -0.932 16.500 | -1.450 -0.960 24.000 | -1.072 -0.734 2.000  | -1.073 -0.717 3.000  | -1.217 -0.861 9.000  | -1.127 0.000 5.000   | -1.214 -0.857 8.000  |
| -1.028 -0.777 14.500 | -0.722 -0.595 2.000  | -1.143 -0.935 19.000 | -1.143 -0.875 20.000 | -0.968 -0.700 11.000 | -0.493 0.000 1.000   | -0.959 -0.691 10.000 |
| -1.377 -0.057 23.500 | -1.230 -0.664 17.000 | -1.199 -0.320 12.000 | -1.250 -0.290 18.000 | -1.376 -0.416 22.000 | -1.379 0.000 25.000  | -1.380 -0.415 26.000 |
| 0.710 0.774 9.000    | nan nan nan          | nan nan nan          | -1.441 -0.385 21.000 | 0.716 0.748 8.000    | 0.233 0.233 15.000   | 0.688 0.748 10.000   |
| 0.581 0.826 10.000   | nan nan nan          | nan nan nan          | -1.631 -0.671 23.000 | 0.457 0.913 12.000   | 0.000 0.000 16.000   | 0.447 0.917 13.000   |
| 1.088 1.154 4.000    | nan nan nan          | nan nan nan          | -1.409 -1.298 24.000 | 1.087 1.164 6.000    | 0.000 0.000 22.000   | 1.077 1.140 8.000    |
| -0.169 -0.165 8.000  | nan nan nan          | nan nan nan          | -0.964 -0.691 16.000 | 0.164 0.578 6.000    | -0.909 -0.303 15.000 | 0.191 0.594 5.000    |
| -0.913 -0.871 14.000 | nan nan nan          | nan nan nan          | -1.080 -0.109 17.000 | -0.698 -0.629 10.000 | -0.690 0.000 9.000   | -0.718 -0.621 11.000 |
| 0.982 1.008 7.000    | nan nan nan          | nan nan nan          | -1.248 -1.184 24.000 | 0.968 1.006 11.000   | 0.000 0.000 20.000   | 0.973 1.006 9.000    |
| -0.547 -0.518 7.000  | nan nan nan          | nan nan nan          | -1.128 -1.080 18.000 | -0.611 -0.548 8.500  | -0.339 0.000 4.000   | -0.611 -0.548 8.500  |
| 0.380 0.436 9.000    | nan nan nan          | nan nan nan          | -1.882 -1.606 24.000 | 0.327 0.423 10.000   | -0.244 -0.163 16.000 | 0.317 0.413 11.000   |
| 0.849 0.879 11.000   | nan nan nan          | nan nan nan          | -1.511 -1.453 24.000 | 0.858 0.903 9.000    | 0.000 0.000 17.000   | 0.859 0.901 8.000    |
| -0.514 -0.508 3.000  | nan nan nan          | nan nan nan          | -1.062 -1.025 15.000 | -0.538 -0.511 5.000  | 0.000 0.000 1.000    | -0.542 -0.513 6.000  |
| -0.275 -0.185 11.000 | nan nan nan          | nan nan nan          | -1.539 -1.288 24.000 | -0.422 -0.175 13.000 | -0.206 -0.206 10.000 | -0.421 -0.177 12.000 |
| -0.638 -0.500 13.000 | nan nan nan          | nan nan nan          | -1.550 -1.164 24.000 | -0.662 -0.393 14.000 | -0.284 -0.142 9.000  | -0.663 -0.394 15.000 |
| -0.970 -0.729 10.000 | nan nan nan          | nan nan nan          | -1.099 -0.890 13.000 | -1.101 -0.852 14.000 | -0.455 0.000 5.000   | -1.134 -0.924 16.000 |
| 0.389 0.672 11.000   | nan nan nan          | nan nan nan          | -0.825 -0.738 19.000 | 0.455 0.714 8.000    | 0.000 0.208 14.000   | 0.439 0.654 9.000    |
| 0.567 1.027 9.000    | nan nan nan          | nan nan nan          | -1.983 -1.408 24.000 | 0.558 0.992 10.000   | -0.076 0.000 17.000  | 0.605 1.002 8.000    |
| -0.207 -0.080 4.000  | nan nan nan          | nan nan nan          | -1.381 -1.338 19.000 | -0.558 -0.440 11.000 | -0.224 0.000 5.000   | -0.549 -0.418 10.000 |
| -1.157 -0.900 18.000 | nan nan nan          | nan nan nan          | -1.007 -0.825 11.000 | -1.105 -0.885 17.000 | 0.000 0.000 3.000    | -1.101 -0.889 16.000 |
| 0.793 0.957 8.000    | nan nan nan          | nan nan nan          | -1.613 -1.569 24.000 | 0.842 0.964 4.000    | 0.000 0.000 18.000   | 0.839 0.961 5.000    |
| -0.931 -0.838 12.000 | nan nan nan          | nan nan nan          | -1.199 -1.073 20.000 | -0.665 -0.638 5.000  | 0.000 0.000 2.000    | -0.667 -0.637 6.000  |
| -1.063 -0.863 12.000 | nan nan nan          | nan nan nan          | -1.153 -0.824 17.000 | -0.906 -0.643 10.000 | -0.327 0.000 4.000   | -0.918 -0.651 11.000 |
| 0.822 0.883 6.000    | nan nan nan          | nan nan nan          | -1.746 -1.122 23.000 | 0.579 0.758 10.000   | -0.034 0.000 16.000  | 0.576 0.757 11.000   |
| -1.016 -1.013 12.000 | nan nan nan          | nan nan nan          | -1.017 -0.990 13.000 | -0.460 -0.443 2.500  | 0.000 0.000 1.000    | -0.460 -0.443 2.500  |
| -1.217 -0.894 23.000 | nan nan nan          | nan nan nan          | -0.994 -0.631 16.000 | -0.654 -0.420 10.000 | -0.638 0.000 7.000   | -0.653 -0.418 9.000  |
| 0.807 0.884 7.000    | nan nan nan          | nan nan nan          | -1.353 -1.102 23.000 | 0.843 0.854 5.500    | -0.237 0.000 15.000  | 0.843 0.854 5.500    |
| 1.188 1.188 11.500   | 1.158 1.158 14.000   | 1.237 1.237 9.000    | -1.733 -1.733 26.000 | 1.164 1.164 13.000   | 0.000 0.000 25.000   | 1.039 1.128 20.000   |
| 1.241 1.241 13.500   | 0.957 0.957 24.000   | 0.969 0.969 23.000   | -1.751 -1.751 26.000 | 1.222 1.222 16.000   | 0.000 0.000 25.000   | 1.013 1.208 22.000   |
| 1.234 1.234 11.500   | 1.232 1.232 13.000   | 1.224 1.224 16.500   | -1.651 -1.651 26.000 | 1.254 1.254 8.000    | 0.000 0.000 25.000   | 1.103 1.245 21.000   |
| 1.049 1.049 12.500   | 1.038 1.038 16.000   | 1.041 1.041 14.500   | -1.326 -1.326 26.000 | 1.041 1.041 14.500   | 0.000 0.000 25.000   | 1.027 1.066 18.000   |
| 1.019 1.019 13.000   | 1.019 1.019 13.000   | 0.987 0.987 20.000   | -1.360 -1.360 26.000 | 1.016 1.016 16.000   | 0.000 0.000 25.000   | 0.999 1.025 18.000   |
| 1.081 1.081 11.500   | 1.062 1.062 18.000   | 1.050 1.050 19.000   | -1.255 -1.255 26.000 | 1.080 1.080 14.500   | 0.000 0.000 25.000   | 1.072 1.085 17.000   |
| 1.006 1.006 13.500   | 0.923 0.923 22.000   | 1.012 1.012 10.000   | -1.164 -1.164 26.000 | 1.002 1.002 16.000   | 0.000 0.000 25.000   | 1.002 1.006 17.000   |
| 1.030 1.030 11.500   | 1.018 1.018 18.000   | 1.022 1.022 16.500   | -1.140 -1.140 26.000 | 1.033 1.033 5.000    | 0.000 0.000 25.000   | 1.028 1.031 13.000   |
| 0.995 0.995 15.500   | 1.005 1.005 9.000    | 1.013 1.013 8.000    | -1.170 -1.170 26.000 | 0.995 0.995 15.500   | 0.000 0.000 25.000   | 0.991 1.000 21.000   |
| 1.001 1.001 3.500    | 0.946 0.946 15.500   | 1.002 1.002 2.000    | -1.090 -1.090 26.000 | 1.000 1.000 5.000    | 0.000 0.000 25.000   | 0.996 0.998 9.000    |
| 0.998 0.998 9.500    | 1.001 1.0            |                      |                      |                      |                      |                      |

| Dataset                     |  | RedFN                | RdFSN               | IGRN                 | GiniN                | Chi2N                | DistN                |
|-----------------------------|--|----------------------|---------------------|----------------------|----------------------|----------------------|----------------------|
| modulo-2-2-cp-1 10-030      |  | -1.129 -0.768 24.000 | 1.467 1.486 1.000   | -1.104 -0.773 20.000 | -1.111 -0.745 22.000 | -1.111 -0.748 23.000 | -1.109 -0.797 21.000 |
| modulo-2-2-cp-1 10-060      |  | 1.504 1.531 2.000    | 1.539 1.605 1.000   | -1.311 -1.181 23.000 | -1.313 -1.162 24.000 | -1.300 -1.168 21.000 | -1.302 -1.178 22.000 |
| modulo-2-2-cp-1 10-180      |  | 1.609 1.634 1.000    | 1.565 1.629 2.000   | -0.932 -0.864 24.000 | -0.928 -0.861 22.500 | -0.928 -0.861 22.500 | -0.924 -0.855 21.000 |
| modulo-2-2-cp-1 20-030      |  | -1.157 -1.033 21.000 | 0.806 1.092 1.000   | -1.219 -1.096 24.000 | -1.197 -1.087 22.000 | -1.212 -1.091 23.000 | -1.243 -1.115 25.000 |
| modulo-2-2-cp-1 20-060      |  | 1.126 1.129 1.000    | 0.924 1.145 4.000   | -1.396 -1.181 25.000 | -1.389 -1.179 22.000 | -1.394 -1.177 24.000 | -1.391 -1.178 23.000 |
| modulo-2-2-cp-1 20-180      |  | 1.177 1.208 2.000    | 1.192 1.209 1.000   | -1.263 -1.049 25.000 | -1.262 -1.047 22.500 | -1.262 -1.047 22.500 | -1.262 -1.050 24.000 |
| modulo-2-2-cp-1 40-030      |  | -1.453 -1.022 24.000 | 0.761 0.873 1.000   | -1.482 -1.057 26.000 | -1.461 -1.086 25.000 | -1.492 -1.042 27.000 | -1.424 -1.034 23.000 |
| modulo-2-2-cp-1 40-060      |  | 0.632 0.797 11.000   | 0.922 0.940 1.000   | -1.107 -0.496 21.000 | -1.100 -0.484 20.000 | -1.108 -0.491 22.000 | -1.110 -0.508 23.000 |
| modulo-2-2-cp-1 40-180      |  | 1.071 1.078 1.000    | 0.996 1.061 2.000   | -0.910 -0.851 21.000 | -0.912 -0.853 23.500 | -0.912 -0.853 23.500 | -0.911 -0.855 22.000 |
| modulo-2-2-cp-1 80-030      |  | -1.498 -0.427 27.000 | 0.333 0.389 2.000   | -1.336 -0.589 23.000 | -1.386 -0.574 25.000 | -1.426 -0.525 26.000 | -1.348 -0.564 24.000 |
| modulo-2-2-cp-1 80-060      |  | 0.651 0.792 3.000    | 0.719 0.859 2.000   | -0.498 -0.116 19.000 | -0.557 -0.174 23.000 | -0.543 -0.169 21.000 | -0.551 -0.108 22.000 |
| modulo-2-2-cp-1 80-180      |  | 0.990 1.004 1.000    | 0.957 0.967 2.000   | -1.130 -0.724 20.000 | -1.131 -0.735 22.000 | -1.131 -0.723 23.000 | -1.130 -0.721 21.000 |
| modulo-2-2-a1-cp-2 10-030   |  | -0.969 -0.682 19.000 | 0.060 1.087 12.000  | -1.020 -0.780 23.000 | -1.011 -0.729 21.000 | -1.005 -0.732 20.000 | -1.013 -0.782 22.000 |
| modulo-2-2-a1-cp-2 10-060   |  | 0.125 1.111 3.000    | 0.111 1.109 4.000   | -0.546 -0.304 23.000 | -0.547 -0.307 24.000 | -0.544 -0.296 22.000 | -0.553 -0.309 25.000 |
| modulo-2-2-a1-cp-2 10-180   |  | 0.217 1.180 1.000    | 0.214 1.180 2.000   | -1.769 -0.876 27.000 | -1.765 -0.866 24.500 | -1.765 -0.866 24.500 | -1.765 -0.876 26.000 |
| modulo-2-2-a1-cp-2 20-030   |  | -1.308 -1.307 23.000 | 0.045 0.978 1.000   | -1.306 -1.306 21.000 | -1.310 -1.309 24.000 | -1.307 -1.307 22.000 | -1.291 -1.291 20.000 |
| modulo-2-2-a1-cp-2 20-060   |  | 0.181 1.010 1.000    | 0.122 1.021 2.000   | -1.232 -1.107 21.000 | -1.236 -1.107 22.000 | -1.242 -1.109 23.000 | -1.242 -1.112 24.000 |
| modulo-2-2-a1-cp-2 20-180   |  | 0.277 1.082 1.000    | 0.172 1.062 3.000   | -0.291 0.196 20.000  | -0.291 0.200 21.000  | -0.293 0.195 22.500  | -0.293 0.195 22.500  |
| modulo-2-2-a1-cp-2 40-030   |  | -1.280 -1.106 25.000 | 0.029 0.889 2.000   | -1.248 -1.096 22.000 | -1.261 -1.094 24.000 | -1.260 -1.094 23.000 | -1.237 -1.095 20.000 |
| modulo-2-2-a1-cp-2 40-060   |  | 0.114 0.868 2.000    | 0.098 0.954 4.000   | -1.196 -0.921 25.000 | -1.194 -0.923 23.000 | -1.192 -0.916 22.000 | -1.195 -0.923 24.000 |
| modulo-2-2-a1-cp-2 40-180   |  | 0.286 1.019 1.000    | 0.173 1.015 4.000   | -0.918 -0.572 20.000 | -0.920 -0.583 22.000 | -0.921 -0.576 23.000 | -0.919 -0.567 21.000 |
| modulo-2-2-a1-cp-2 80-030   |  | -1.320 -0.583 23.000 | 0.054 0.759 4.000   | -1.353 -0.610 25.000 | -1.372 -0.563 27.000 | -1.357 -0.596 26.000 | -1.325 -0.625 24.000 |
| modulo-2-2-a1-cp-2 80-060   |  | 0.158 0.835 2.000    | 0.075 0.877 5.000   | -1.034 -0.895 22.000 | -1.046 -0.897 25.000 | -1.041 -0.898 24.000 | -1.039 -0.905 23.000 |
| modulo-2-2-a1-cp-2 80-180   |  | 0.284 0.984 1.000    | 0.136 0.958 5.000   | -1.066 -0.544 22.000 | -1.074 -0.544 24.000 | -1.067 -0.546 23.000 | -1.064 -0.544 21.000 |
| modulo-2-2-irr-a2-cp 10-030 |  | -1.438 -0.210 23.000 | 1.215 1.221 1.000   | -1.458 -0.136 24.000 | -1.459 -0.090 25.000 | -1.481 -0.111 26.000 | -1.380 -0.080 21.000 |
| modulo-2-2-irr-a2-cp 10-060 |  | 1.216 1.223 1.000    | 1.194 1.230 2.000   | 0.255 0.953 22.000   | 0.262 0.965 21.000   | 0.272 0.969 19.000   | 0.265 0.969 20.000   |
| modulo-2-2-irr-a2-cp 10-180 |  | -0.149 -0.132 19.000 | 1.216 1.234 1.000   | -1.209 0.453 23.000  | -1.215 0.449 25.000  | -1.212 0.443 24.000  | -1.208 0.471 22.000  |
| modulo-2-2-irr-a2-cp 20-030 |  | -0.976 -0.546 21.000 | 1.060 1.089 1.000   | -1.003 -0.545 23.000 | -1.008 -0.519 25.000 | -1.002 -0.527 22.000 | -1.004 -0.560 24.000 |
| modulo-2-2-irr-a2-cp 20-060 |  | 1.015 1.092 3.000    | 1.064 1.104 1.000   | -1.147 -1.132 22.500 | -1.146 -1.127 21.000 | -1.147 -1.132 22.500 | -1.148 -1.134 24.000 |
| modulo-2-2-irr-a2-cp 20-180 |  | -0.153 -0.136 21.000 | 1.093 1.105 1.000   | -1.051 -0.610 23.000 | -1.048 -0.604 22.000 | -1.051 -0.609 24.000 | -1.053 -0.611 25.000 |
| modulo-2-2-irr-a2-cp 40-030 |  | -0.866 -0.530 20.000 | 1.015 1.049 1.000   | -0.907 -0.473 21.000 | -0.946 -0.471 24.000 | -0.937 -0.480 23.000 | -0.920 -0.546 22.000 |
| modulo-2-2-irr-a2-cp 40-060 |  | 1.005 1.042 4.000    | 0.999 1.047 7.000   | 0.568 1.035 18.000   | 0.630 1.039 16.000   | 0.570 1.035 17.000   | 0.547 1.034 19.000   |
| modulo-2-2-irr-a2-cp 40-180 |  | -0.188 -0.168 20.000 | 1.029 1.049 1.000   | -0.864 -0.081 21.000 | -0.866 -0.083 22.000 | -0.866 -0.084 23.000 | -0.867 -0.085 24.000 |
| modulo-2-2-irr-a2-cp 80-030 |  | -1.013 -0.798 22.000 | 0.855 0.919 2.000   | -1.014 -0.747 24.000 | -1.007 -0.726 21.000 | -1.013 -0.736 23.000 | -1.018 -0.759 25.000 |
| modulo-2-2-irr-a2-cp 80-060 |  | 0.844 1.022 9.000    | 0.981 1.023 3.000   | -1.495 -0.091 26.000 | -1.445 -0.103 24.000 | -1.479 -0.102 25.000 | -1.497 -0.084 27.000 |
| modulo-2-2-irr-a2-cp 80-180 |  | -0.127 -0.093 20.000 | 0.991 1.024 3.000   | -1.806 -1.160 27.000 | -1.800 -1.149 24.000 | -1.803 -1.151 25.000 | -1.805 -1.158 26.000 |
| and-2 10-030                |  | 0.847 1.144 9.000    | 0.728 0.960 13.000  | 1.044 1.190 2.000    | 0.947 1.158 5.000    | 0.947 1.160 6.000    | 0.984 1.188 3.000    |
| and-2 10-060                |  | 1.145 1.163 7.000    | 1.177 1.181 6.000   | 1.208 1.215 2.000    | 1.190 1.199 4.000    | 1.187 1.199 5.000    | 1.202 1.219 3.000    |
| and-2 10-180                |  | 1.032 1.195 10.000   | 1.003 1.191 16.000  | 1.131 1.232 4.000    | 1.071 1.223 7.000    | 1.072 1.223 6.000    | 1.060 1.225 8.000    |
| and-2 20-030                |  | 0.620 0.981 23.000   | 0.719 0.935 17.000  | 0.823 1.014 11.000   | 0.703 0.983 18.000   | 0.703 0.984 19.000   | 0.743 1.024 16.000   |
| and-2 20-060                |  | 0.972 1.046 7.000    | 0.944 0.976 10.000  | 1.035 1.073 3.000    | 0.995 1.053 5.000    | 0.995 1.056 6.000    | 1.013 1.076 4.000    |
| and-2 20-180                |  | 0.985 1.074 17.000   | 0.939 1.052 22.000  | 1.051 1.098 4.000    | 1.020 1.092 14.000   | 1.021 1.093 13.000   | 1.025 1.098 12.000   |
| and-2 40-030                |  | 0.767 0.843 9.000    | 0.518 0.677 18.000  | 0.895 0.938 2.000    | 0.785 0.869 7.000    | 0.810 0.888 6.000    | 0.856 0.949 3.000    |
| and-2 40-060                |  | 0.895 0.972 9.000    | 0.755 0.897 17.000  | 0.966 1.016 2.000    | 0.932 1.001 5.000    | 0.937 1.002 4.000    | 0.960 1.020 3.000    |
| and-2 40-180                |  | 0.686 1.021 19.000   | 0.677 0.977 20.000  | 0.844 1.036 2.000    | 0.750 1.029 14.500   | 0.750 1.029 14.500   | 0.753 1.036 11.000   |
| and-2 80-030                |  | 0.605 0.745 17.000   | 0.583 0.618 19.000  | 0.803 0.867 6.000    | 0.690 0.791 10.000   | 0.691 0.792 9.000    | 0.779 0.878 7.000    |
| and-2 80-060                |  | 0.645 0.951 22.000   | 0.446 0.731 24.000  | 0.796 0.972 13.000   | 0.703 0.951 17.000   | 0.701 0.951 19.000   | 0.726 0.980 16.000   |
| and-2 80-180                |  | 0.871 0.966 12.000   | 0.939 0.946 4.000   | 0.954 1.007 3.000    | 0.915 0.999 6.000    | 0.914 0.999 7.000    | 0.932 1.010 5.000    |
| and-4 10-030                |  | 0.259 1.149 19.000   | 0.571 1.382 4.000   | 1.106 1.472 2.000    | 0.533 1.277 6.000    | 0.535 1.277 5.000    | 0.735 1.379 3.000    |
| and-4 10-060                |  | 1.119 1.403 8.000    | 1.163 1.436 7.000   | 1.520 1.596 2.000    | 1.328 1.506 4.000    | 1.309 1.504 5.000    | 1.387 1.558 3.000    |
| and-4 10-180                |  | 1.222 1.513 13.000   | 1.327 1.570 5.000   | 1.493 1.617 2.000    | 1.304 1.564 6.000    | 1.303 1.563 7.000    | 1.361 1.587 4.000    |
| and-4 20-030                |  | -0.354 0.684 24.000  | -0.244 0.842 22.000 | 0.571 1.020 2.000    | 0.047 0.859 17.000   | 0.067 0.873 15.000   | 0.281 0.981 3.000    |
| and-4 20-060                |  | 0.575 1.040 17.000   | 0.522 0.931 20.000  | 0.997 1.185 2.000    | 0.730 1.118 4.000    | 0.724 1.123 6.000    | 0.807 1.164 3.000    |
| and-4 20-180                |  | 0.834 1.159 7.000    | 0.763 1.089 11.000  | 1.081 1.212 2.000    | 0.909 1.174 4.500    | 0.909 1.174 4.500    | 0.960 1.195 3.000    |
| and-4 40-030                |  | 0.124 0.538 19.000   | -0.107 0.590 23.000 | 0.724 0.919 2.000    | 0.363 0.743 13.000   | 0.382 0.750 10.000   | 0.589 0.896 3.000    |
| and-4 40-060                |  | 0.189 0.803 22.000   | -0.139 0.622 25.000 | 0.753 0.986 2.000    | 0.394 0.864 17.000   | 0.392 0.868 18.000   | 0.555 0.967 4.000    |
| and-4 40-180                |  | 0.717 1.029 8.000    | 0.530 0.921 22.000  | 0.956 1.075 2.000    | 0.792 1.039 5.000    | 0.792 1.040 6.000    | 0.849 1.066 3.000    |
| and-4 80-030                |  | 0.058 0.549 22.000   | -0.502 0.027 25.000 | 0.788 0.903 3.000    | 0.483 0.754 14.000   | 0.483 0.756 15.000   | 0.671 0.882 4.000    |
| and-4 80-060                |  | 0.340 0.761 16.000   | -0.084 0.581 25.000 | 0.783 0.927 2.000    | 0.518 0.820 15.000   | 0.521 0.821 14.000   | 0.644 0.908 4.000    |
| and-4 80-180                |  | 0.713 0.899 10.000   | 0.575 0.730 19.000  | 0.950 1.014 2.000    | 0.842 0.976 5.500    | 0.842 0.976 5.500    | 0.895 1.010 3.000    |

**Tabela B.5:** Tabela uspešnosti kombinirane funkcije na vseh metodah za ocenjevanje pomembnosti atributov in vseh naborih podatkov pri osnovni analizi (kvadrant (2, 1) od (3, 4)).

| <i>LogON</i>         | <i>LeaN</i>          | <i>LeaGITc3APN</i>  | <i>LeaGtN</i>        | <i>LeaGfN</i>        | <i>LeaGln</i>       | <i>LeaTc3N</i>       |
|----------------------|----------------------|---------------------|----------------------|----------------------|---------------------|----------------------|
| -0.499 0.044 19.000  | 0.858 1.358 10.000   | 0.524 0.916 16.000  | 0.114 0.765 17.000   | 0.863 1.128 9.000    | 1.158 1.342 2.000   | 1.003 1.415 4.000    |
| -0.258 -0.029 20.000 | 1.140 1.385 9.000    | 0.925 1.282 17.000  | 0.329 0.784 18.000   | 1.002 1.264 15.000   | 0.977 1.181 16.000  | 1.229 1.463 7.000    |
| -1.536 -0.805 25.000 | 1.170 1.387 9.000    | 1.245 1.433 4.000   | 0.883 1.257 18.000   | 1.054 1.329 16.000   | 1.409 1.532 3.000   | 1.105 1.336 13.000   |
| -0.863 -0.177 20.000 | 0.370 0.625 10.000   | 0.580 0.995 3.000   | 0.127 0.591 17.000   | 0.531 0.927 6.000    | 0.753 0.966 2.000   | 0.550 0.920 4.000    |
| -1.073 -0.655 20.000 | 0.608 0.854 14.000   | 0.711 0.985 7.000   | 0.299 0.690 18.000   | 0.715 1.078 6.000    | 0.399 0.887 17.000  | 0.893 0.988 5.000    |
| -1.059 -0.163 20.000 | 1.026 1.100 8.000    | 0.921 1.103 14.000  | 0.150 0.871 18.000   | 0.673 1.007 17.000   | 0.825 1.008 16.000  | 1.079 1.089 4.000    |
| 0.000 0.000 4.500    | -0.715 -0.579 13.000 | 0.277 0.613 3.000   | -0.842 -0.392 17.000 | -0.125 0.621 7.000   | -0.103 0.527 6.000  | -0.655 -0.592 11.000 |
| -1.290 -0.795 25.000 | 0.665 0.837 10.000   | 0.612 0.893 12.000  | 0.238 0.539 18.000   | 0.598 0.890 13.000   | 0.673 0.840 6.000   | 0.723 0.816 4.000    |
| -1.509 -1.259 27.000 | 0.751 0.823 13.000   | 0.727 0.949 14.000  | 0.035 0.669 18.000   | 0.602 0.847 17.000   | 0.705 0.931 15.000  | 0.910 1.012 4.000    |
| -1.285 -0.730 22.000 | -0.691 -0.580 13.000 | 0.346 0.548 1.000   | -0.845 -0.070 17.000 | -0.521 0.470 9.000   | -0.360 0.268 4.000  | -0.517 -0.428 8.000  |
| -1.054 -0.390 25.000 | 0.297 0.472 10.500   | 0.643 0.730 4.000   | -0.500 -0.167 20.000 | 0.127 0.659 16.000   | 0.541 0.809 7.000   | 0.616 0.787 6.000    |
| -1.400 -0.520 26.000 | 0.929 0.971 6.000    | 0.770 0.941 16.000  | 0.249 0.570 17.000   | -0.166 0.639 19.000  | 0.812 0.928 14.000  | 0.787 0.837 15.000   |
| -1.703 -1.273 27.000 | 0.126 1.110 4.000    | -0.013 0.991 15.000 | -0.252 0.863 18.000  | 0.182 1.133 2.000    | 0.033 0.898 13.000  | 0.115 1.115 5.000    |
| 0.206 0.470 1.000    | 0.078 1.136 7.000    | 0.005 1.114 17.000  | -0.062 1.010 20.000  | 0.093 1.116 6.000    | -0.193 1.034 21.000 | 0.031 1.089 15.000   |
| -0.928 -0.811 20.000 | 0.136 1.152 5.500    | -0.053 1.038 18.000 | 0.053 1.093 13.000   | -0.154 1.016 19.000  | 0.001 1.035 16.000  | 0.123 1.145 8.000    |
| -0.926 -0.669 19.000 | 0.014 0.884 4.000    | 0.007 0.855 5.000   | -0.492 0.635 18.000  | -0.339 0.710 17.000  | -0.215 0.815 14.000 | -0.109 0.788 13.000  |
| -1.530 -0.922 27.000 | 0.055 0.925 9.000    | -0.064 0.924 16.000 | -0.191 0.784 18.000  | 0.049 0.920 11.000   | 0.024 0.937 14.000  | 0.073 0.988 6.000    |
| -0.359 -0.215 24.000 | 0.115 1.012 10.000   | 0.076 0.960 16.000  | -0.034 0.937 19.000  | 0.106 0.979 14.000   | 0.072 0.969 17.000  | 0.130 1.037 4.000    |
| -0.816 -0.550 16.000 | -0.388 0.377 12.000  | -0.015 0.818 4.000  | -0.956 0.115 19.000  | 0.015 0.710 3.000    | -0.192 0.699 7.000  | -0.102 0.811 5.000   |
| -1.178 -0.627 21.000 | 0.038 0.906 8.500    | 0.155 0.923 1.000   | -0.394 0.631 19.000  | 0.109 0.894 3.000    | 0.018 0.895 12.000  | 0.019 0.883 11.000   |
| -1.300 -0.628 26.000 | 0.071 0.957 11.000   | 0.020 0.882 17.000  | -0.070 0.900 18.000  | 0.079 0.909 7.000    | 0.191 0.950 3.000   | 0.072 0.957 10.000   |
| -0.988 -0.701 17.000 | -0.403 0.004 9.500   | 0.122 0.549 2.000   | -1.006 -0.811 18.000 | 0.260 0.483 1.000    | -0.049 0.170 5.000  | -0.314 0.482 6.000   |
| -0.859 -0.186 20.000 | -0.496 0.386 15.000  | 0.133 0.844 3.000   | -1.030 -0.535 21.000 | -0.052 0.695 6.000   | 0.120 0.783 4.000   | -0.122 0.737 7.000   |
| -1.230 -0.762 25.000 | 0.072 0.932 12.000   | 0.246 0.956 2.000   | -0.110 0.737 18.000  | 0.089 0.759 6.000    | 0.234 0.926 3.000   | 0.086 0.955 8.000    |
| -0.570 -0.523 19.000 | 0.312 0.896 13.000   | 0.977 1.044 4.000   | 0.412 0.895 12.000   | 0.503 0.956 8.000    | 0.279 0.925 15.000  | 0.515 0.798 7.000    |
| -1.310 -1.180 26.000 | 0.858 1.119 12.000   | 1.140 1.155 3.000   | 0.749 0.794 16.000   | 0.957 1.115 9.000    | 0.824 1.008 13.000  | 1.099 1.148 4.000    |
| -1.058 0.933 21.000  | 1.109 1.126 2.000    | 1.057 1.066 9.000   | 0.845 0.858 16.000   | 1.026 1.065 13.000   | 1.073 1.079 5.000   | 1.078 1.154 3.000    |
| -0.427 0.992 19.000  | 0.604 1.029 11.000   | 0.815 0.983 5.000   | 0.563 0.953 13.000   | 0.245 0.914 17.000   | 0.371 0.883 16.000  | 0.973 1.017 2.000    |
| -0.528 0.125 20.000  | 0.747 1.046 12.000   | 0.914 0.998 7.000   | 0.646 0.875 13.000   | 0.625 0.864 17.000   | 0.443 0.914 18.000  | 0.966 1.049 5.000    |
| 0.294 0.494 18.000   | 1.040 1.045 2.000    | 0.884 0.906 12.000  | 0.518 0.909 17.000   | 0.714 0.867 15.000   | 0.787 0.925 14.000  | 0.946 1.047 11.000   |
| -1.687 -0.278 27.000 | 0.821 1.014 7.000    | 0.930 0.983 3.000   | 0.727 0.854 12.000   | 0.409 0.691 17.000   | 0.447 0.647 16.000  | 0.830 1.006 6.000    |
| -1.022 0.405 25.000  | 0.909 1.021 9.000    | 0.859 0.919 13.000  | 0.539 0.812 20.000   | 0.386 0.868 22.000   | 0.429 0.916 21.000  | 1.019 1.022 3.000    |
| 0.293 0.363 18.000   | 0.975 0.987 8.000    | 0.882 0.949 12.000  | 0.662 0.844 16.000   | 0.652 0.678 17.000   | 0.796 0.835 13.000  | 0.918 0.988 11.000   |
| -0.438 0.680 20.000  | 0.629 0.954 9.000    | -0.254 0.437 19.000 | 0.721 0.847 5.000    | -0.184 0.854 18.000  | -0.096 0.955 17.000 | 0.700 0.996 7.000    |
| -0.429 0.253 19.000  | 0.890 0.974 6.000    | 0.713 0.860 15.000  | 0.638 0.888 16.000   | -1.203 -0.439 22.000 | -1.265 0.284 23.000 | 0.946 0.999 4.000    |
| 0.159 0.217 17.000   | 0.939 1.001 6.000    | 0.812 0.882 14.000  | 0.811 0.870 15.000   | 0.050 0.509 18.000   | 0.363 0.694 16.000  | 0.881 0.978 10.000   |
| 1.250 1.250 1.000    | 0.715 1.102 14.000   | 0.962 1.104 4.000   | 0.787 1.080 11.000   | 0.793 1.041 10.000   | 0.569 0.904 22.000  | 0.942 1.173 7.000    |
| 1.250 1.250 1.000    | 1.039 1.126 15.000   | 1.046 1.125 14.000  | 0.827 0.865 24.000   | 1.057 1.073 13.000   | 0.936 1.061 22.000  | 1.089 1.099 9.000    |
| 1.250 1.250 1.000    | 1.032 1.167 11.000   | 0.935 1.073 20.000  | 0.731 1.026 24.000   | 0.924 0.973 22.000   | 1.032 1.045 12.000  | 0.935 1.133 19.000   |
| 1.111 1.111 1.000    | 0.836 1.011 8.000    | 0.772 0.972 15.000  | 0.905 0.919 3.000    | 0.685 0.976 21.000   | 0.585 0.897 24.000  | 0.845 1.029 5.000    |
| 1.111 1.111 1.000    | 0.916 1.031 13.000   | 0.959 1.004 8.000   | 0.785 0.814 20.000   | 0.668 0.933 22.000   | 0.663 0.990 23.000  | 1.036 1.047 2.000    |
| 1.111 1.111 1.000    | 1.046 1.053 6.000    | 0.936 0.977 23.000  | 0.881 0.940 24.000   | 0.961 0.995 20.000   | 0.953 0.978 21.000  | 1.048 1.064 5.000    |
| 0.847 0.847 4.000    | 0.581 0.915 17.000   | 0.769 0.913 8.000   | 0.478 0.838 22.000   | 0.500 0.832 19.000   | 0.499 0.864 20.000  | 0.980 0.995 1.000    |
| 1.053 1.053 1.000    | 0.783 0.979 15.000   | 0.901 0.961 8.000   | 0.528 0.873 23.000   | 0.547 0.848 22.000   | 0.641 0.920 20.000  | 0.924 1.008 6.000    |
| 1.053 1.053 1.000    | 0.771 1.015 9.000    | 0.671 0.950 21.000  | 0.650 0.831 24.000   | 0.663 0.961 23.000   | 0.668 0.988 22.000  | 0.809 1.007 5.000    |
| 1.026 1.026 1.000    | 0.647 0.973 13.500   | 0.823 0.861 5.000   | 0.605 0.812 18.000   | 0.373 0.823 23.000   | 0.458 0.843 22.000  | 0.923 0.979 2.000    |
| 1.026 1.026 1.000    | 0.952 0.995 8.000    | 0.702 0.964 18.000  | 0.768 0.878 15.000   | 0.778 0.845 14.000   | 0.844 0.932 11.000  | 0.824 1.000 12.000   |
| 1.026 1.026 1.000    | 0.866 1.004 17.000   | 0.889 0.966 8.000   | 0.806 0.876 23.000   | 0.745 0.931 24.000   | 0.842 0.975 22.000  | 0.955 1.007 2.000    |
| 1.667 1.667 1.000    | 0.307 1.115 15.000   | 0.456 1.237 11.000  | -0.109 0.648 23.000  | 0.274 1.290 18.000   | 0.202 1.107 20.000  | 0.533 1.247 8.000    |
| 1.667 1.667 1.000    | 0.418 1.237 15.000   | 1.164 1.423 6.000   | 0.100 0.883 23.000   | 0.212 1.133 22.000   | 0.271 1.006 21.000  | 0.918 1.398 10.000   |
| 1.667 1.667 1.000    | 1.160 1.375 16.000   | 1.044 1.419 20.000  | 0.687 1.183 25.000   | 0.699 1.229 24.000   | 1.257 1.425 11.000  | 1.004 1.412 21.000   |
| 1.250 1.250 1.000    | 0.184 1.039 11.000   | 0.101 0.936 14.000  | -0.230 0.823 21.000  | -0.270 0.752 23.000  | 0.230 0.930 4.000   | 0.221 1.022 6.000    |
| 1.250 1.250 1.000    | 0.724 1.074 7.000    | 0.624 1.041 15.000  | 0.176 0.997 24.000   | 0.439 0.971 22.000   | 0.506 1.017 21.000  | 0.707 1.135 9.000    |
| 1.250 1.250 1.000    | 0.711 1.140 13.000   | 0.649 1.076 17.000  | 0.550 0.944 21.000   | 0.409 0.888 22.000   | 0.182 0.860 24.000  | 0.888 1.136 6.000    |
| 1.111 1.111 1.000    | 0.380 1.002 11.000   | 0.468 0.798 5.000   | 0.043 0.851 22.000   | 0.153 0.778 18.000   | 0.099 0.771 20.000  | 0.570 0.949 4.000    |
| 1.111 1.111 1.000    | 0.430 1.019 9.000    | 0.496 0.946 5.000   | 0.426 0.928 11.000   | 0.262 0.854 21.000   | 0.467 0.928 8.000   | 0.599 1.021 3.000    |
| 1.111 1.111 1.000    | 0.679 1.028 13.000   | 0.647 0.988 18.000  | 0.268 0.794 24.000   | 0.547 0.950 20.000   | 0.647 0.981 19.000  | 0.811 1.043 4.000    |
| 1.053 1.053 1.000    | 0.605 0.906 8.000    | 0.499 0.787 13.000  | 0.337 0.768 18.000   | 0.298 0.664 19.000   | 0.232 0.681 20.000  | 0.802 0.971 2.000    |
| 1.053 1.053 1.000    | 0.550 1.000 8.000    | 0.536 0.889 10.000  | 0.323 0.801 19.000   | 0.219 0.668 21.000   | 0.280 0.863 20.000  | 0.695 1.011 3.000    |
| 1.053 1.053 1.000    | 0.666 0.997 15.500   | 0.876 0.985 4.000   | 0.453 0.813 23.000   | 0.370 0.898 24.000   | 0.520 0.931 21.000  | 0.805 1.006 7.000    |

**Tabela B.6:** Tabela uspešnosti kombinirane funkcije na vseh metodah za ocenjevanje pomembnosti atributov in vseh naborih podatkov pri osnovni analizi (kvadrant (2, 2) od (3, 4)).

| <i>Lea + kNNeuCN</i> | <i>Lea + bagtreeN</i> | <i>Lea + bayesN</i>  | <i>LeaAPN</i>        | <i>LeaBrSN</i>       | <i>LeaISN</i>        | <i>LeaAUCN</i>       |
|----------------------|-----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| 1.021 1.398 3.000    | 0.781 1.298 14.000    | -1.244 -0.904 25.000 | 0.920 1.376 6.000    | -1.649 -1.141 27.000 | 0.978 1.364 5.000    | 0.897 1.339 7.500    |
| 1.242 1.490 6.000    | 1.090 1.421 13.000    | -1.906 -0.968 27.000 | 1.194 1.438 8.000    | -1.692 -1.294 25.000 | 1.265 1.457 5.000    | 1.112 1.387 10.500   |
| 1.096 1.359 14.000   | 1.126 1.357 11.000    | -0.682 0.077 20.000  | 1.112 1.354 12.000   | -1.780 -1.622 26.000 | 1.077 1.341 15.000   | 1.195 1.405 7.500    |
| 0.538 0.909 5.000    | 0.307 0.527 14.000    | -0.609 -0.352 19.000 | 0.366 0.607 11.000   | -1.928 -1.502 27.000 | 0.320 0.456 13.000   | 0.480 0.752 7.500    |
| 0.983 1.079 3.000    | 1.005 1.048 2.000     | -1.273 -0.951 21.000 | 0.622 0.863 13.000   | -1.638 -1.482 27.000 | 0.424 0.767 16.000   | 0.666 0.907 8.500    |
| 1.074 1.121 5.000    | 1.088 1.132 3.000     | -1.080 -0.860 21.000 | 1.025 1.103 9.000    | -1.503 -1.439 26.000 | 0.937 1.042 12.000   | 1.011 1.101 10.500   |
| 0.617 0.806 2.000    | -0.874 -0.282 18.000  | -1.395 -0.892 22.000 | -0.715 -0.580 14.000 | -1.340 -0.975 21.000 | -0.687 -0.477 12.000 | -0.640 -0.563 9.500  |
| 0.804 0.934 3.000    | 0.828 0.926 2.000     | -1.147 -0.771 24.000 | 0.670 0.839 7.000    | -1.721 -1.448 26.000 | 0.689 0.780 5.000    | 0.666 0.828 8.500    |
| 0.987 1.024 3.000    | 0.768 0.879 11.000    | -0.218 0.086 19.000  | 0.752 0.824 12.000   | -1.357 -1.323 26.000 | 0.602 0.717 16.000   | 0.772 0.846 9.500    |
| 0.253 0.607 3.000    | -0.485 -0.150 5.000   | -1.246 -0.514 20.000 | -0.691 -0.581 14.000 | -1.199 -1.110 19.000 | -1.036 -0.791 18.000 | -0.826 -0.766 15.500 |
| 0.737 0.781 1.000    | 0.629 0.821 5.000     | -0.666 -0.111 24.000 | 0.297 0.472 10.500   | -1.415 -1.138 26.000 | 0.496 0.596 9.000    | 0.248 0.410 12.500   |
| 0.861 0.962 12.000   | 0.852 0.918 13.000    | -1.725 -1.088 27.000 | 0.930 0.971 5.000    | -1.308 -1.222 24.000 | 0.914 0.962 10.000   | 0.934 0.971 3.500    |
| 0.210 1.148 1.000    | 0.150 1.144 3.000     | -1.252 -1.002 24.000 | 0.110 1.113 6.000    | -1.369 -0.523 26.000 | 0.107 1.097 7.000    | 0.106 1.098 8.500    |
| 0.107 1.124 5.000    | 0.064 1.128 9.000     | -0.029 0.703 19.000  | 0.060 1.126 11.000   | -1.327 -0.414 27.000 | 0.044 1.122 14.000   | 0.048 1.100 12.500   |
| 0.135 1.156 7.000    | 0.123 1.155 9.000     | -1.606 -0.855 23.000 | 0.138 1.156 3.000    | -1.341 -0.415 22.000 | 0.137 1.154 4.000    | 0.121 1.155 10.500   |
| -0.103 0.830 12.000  | -0.224 0.720 15.000   | -1.377 -1.194 25.000 | 0.017 0.887 3.000    | -1.462 -0.630 27.000 | -0.053 0.840 11.000  | 0.005 0.865 6.500    |
| 0.112 0.988 3.000    | 0.077 1.020 5.000     | -0.946 -0.550 20.000 | 0.053 0.927 10.000   | -1.321 -0.436 25.000 | 0.090 0.961 4.000    | 0.058 0.939 7.500    |
| 0.190 1.029 2.000    | 0.113 1.021 13.000    | -0.603 -0.004 25.000 | 0.115 1.013 11.000   | -1.171 -0.310 27.000 | 0.115 1.009 12.000   | 0.122 1.018 5.500    |
| 0.054 0.791 1.000    | -0.188 0.721 6.000    | -0.924 -0.633 18.000 | -0.388 0.379 13.000  | -1.765 -1.159 26.000 | -1.239 -0.141 21.000 | -0.385 0.358 10.500  |
| 0.015 0.843 14.000   | 0.023 0.919 10.000    | -1.150 -0.202 20.000 | 0.038 0.906 8.500    | -1.321 -0.449 27.000 | 0.058 0.935 5.000    | 0.047 0.914 6.500    |
| 0.225 0.984 2.000    | 0.117 1.000 5.000     | -1.364 -0.173 27.000 | 0.070 0.956 12.000   | -1.100 -0.214 24.000 | 0.079 0.964 8.000    | 0.070 0.954 13.500   |
| 0.099 0.397 3.000    | -0.674 -0.382 14.000  | -0.959 -0.156 16.000 | -0.403 0.004 9.500   | -1.157 -1.013 21.000 | -1.123 -0.370 20.000 | -0.458 -0.058 12.500 |
| 0.206 0.878 1.000    | -0.261 0.638 9.000    | -0.472 -0.386 13.000 | -0.487 0.396 14.000  | -1.847 -0.898 27.000 | -0.338 0.571 10.000  | -0.470 0.421 11.500  |
| 0.208 0.940 4.000    | 0.069 0.951 13.000    | -0.725 -0.384 20.000 | 0.073 0.933 11.000   | -1.477 -0.619 26.000 | 0.087 0.949 7.000    | 0.075 0.934 9.500    |
| 0.670 0.979 5.000    | 0.458 0.778 9.000     | -0.692 0.489 20.000  | 1.025 1.038 2.000    | -1.739 -1.379 27.000 | 1.016 1.079 3.000    | 0.451 0.949 10.500   |
| 1.032 1.133 6.000    | 1.001 1.137 8.000     | -0.530 0.113 24.000  | 1.022 1.131 7.000    | -1.356 -1.017 27.000 | 1.063 1.132 5.000    | 0.891 1.121 10.500   |
| 1.029 1.135 12.000   | 0.961 1.101 15.000    | -0.398 0.787 20.000  | 1.071 1.153 6.000    | -1.295 -1.167 26.000 | 1.077 1.158 4.000    | 1.051 1.125 10.500   |
| 0.858 1.011 3.000    | 0.593 1.021 12.000    | -0.454 -0.312 20.000 | 0.769 1.035 7.000    | -1.454 -0.964 27.000 | 0.835 1.042 4.000    | 0.690 1.022 8.500    |
| 0.969 1.043 4.000    | 0.850 1.053 11.000    | -1.347 -1.280 26.000 | 0.937 1.055 6.000    | -1.424 -1.000 27.000 | 1.021 1.059 2.000    | 0.862 1.039 9.500    |
| 0.991 1.041 8.000    | 0.987 1.039 9.000     | 0.000 0.000 19.500   | 0.994 1.049 7.000    | -1.201 -1.162 26.000 | 0.985 1.050 10.000   | 1.039 1.045 3.500    |
| 0.727 0.991 13.000   | 0.859 1.007 5.000     | 0.000 0.000 18.500   | 0.888 1.010 4.000    | -1.342 -1.156 26.000 | 0.976 1.007 2.000    | 0.728 1.007 10.500   |
| 0.843 1.021 14.000   | 0.943 1.021 8.000     | -0.949 -0.944 24.000 | 1.025 1.025 1.000    | -1.146 -0.973 27.000 | 1.020 1.022 2.000    | 1.003 1.020 5.500    |
| 0.933 0.989 10.000   | 0.943 0.990 9.000     | -1.206 -0.456 26.000 | 0.986 0.989 4.000    | -1.208 -1.108 27.000 | 0.982 0.989 7.000    | 0.988 0.989 2.500    |
| 0.663 0.895 8.000    | 0.702 0.910 6.000     | 0.000 0.000 15.500   | 0.831 0.886 3.000    | -1.047 -0.747 27.000 | 0.903 0.982 1.000    | 0.413 0.704 12.500   |
| 0.908 1.000 5.000    | 0.845 0.957 8.000     | 0.000 0.000 17.500   | 0.982 0.998 2.000    | -1.045 -0.824 20.000 | 0.987 1.000 1.000    | 0.820 0.944 10.500   |
| 0.980 1.001 4.000    | 0.948 1.000 5.000     | -1.092 -0.910 23.000 | 0.996 1.001 1.000    | -1.064 -1.023 22.000 | 0.995 1.001 2.000    | 0.866 0.972 11.500   |
| 0.668 1.026 17.000   | 0.593 1.043 21.000    | 0.707 1.086 15.000   | 0.761 1.112 12.000   | -1.584 -1.146 27.000 | 0.887 1.163 8.000    | 0.626 1.043 19.500   |
| 1.067 1.123 10.000   | 1.018 1.123 16.000    | 0.948 1.119 21.000   | 1.064 1.122 11.000   | -1.349 -1.318 26.000 | 0.980 1.110 20.000   | 0.981 1.116 18.500   |
| 0.954 1.145 18.000   | 1.028 1.169 13.000    | 1.127 1.180 5.000    | 1.010 1.158 14.000   | -1.339 -1.272 27.000 | 0.974 1.155 17.000   | 1.160 1.181 2.500    |
| 0.647 0.958 22.000   | 0.884 1.009 4.000     | 0.816 0.990 12.000   | 0.832 1.014 10.000   | -1.257 -1.122 27.000 | 0.832 1.038 9.000    | 0.793 1.012 13.500   |
| 0.772 0.982 21.000   | 0.823 1.025 18.000    | 0.822 1.010 19.000   | 0.917 1.031 12.000   | -1.207 -1.055 27.000 | 0.948 1.020 9.000    | 0.907 1.017 14.500   |
| 1.013 1.055 15.000   | 1.055 1.055 3.000     | 0.999 1.049 16.000   | 1.044 1.056 7.000    | -1.168 -1.161 27.000 | 1.056 1.069 2.000    | 1.032 1.062 9.500    |
| 0.479 0.694 21.000   | 0.655 0.952 10.000    | 0.593 0.967 13.000   | 0.582 0.915 16.000   | -1.494 -1.234 27.000 | 0.397 0.821 23.000   | 0.606 0.932 11.500   |
| 0.518 0.836 24.000   | 0.825 0.990 13.000    | 0.759 0.965 16.000   | 0.791 0.982 14.000   | -1.123 -0.819 27.000 | 0.858 0.995 10.000   | 0.837 0.983 11.500   |
| 0.694 0.985 18.000   | 0.741 1.004 16.000    | 0.762 1.009 10.000   | 0.776 1.016 8.000    | -1.083 -0.775 27.000 | 0.812 1.014 4.000    | 0.781 1.018 6.500    |
| 0.533 0.717 21.000   | 0.909 0.970 3.000     | 0.576 0.895 20.000   | 0.647 0.973 13.500   | -1.078 -0.656 27.000 | 0.707 0.979 8.000    | 0.669 0.970 11.500   |
| 0.609 0.793 23.000   | 0.985 0.992 4.000     | 0.909 0.972 10.000   | 0.959 0.995 6.500    | -1.055 -1.038 27.000 | 0.947 0.992 9.000    | 0.991 0.995 2.500    |
| 0.866 0.945 18.000   | 0.870 0.998 13.000    | 0.883 1.001 10.000   | 0.867 1.005 16.000   | -1.048 -0.887 27.000 | 0.886 1.007 9.000    | 0.870 1.004 14.500   |
| 0.422 0.888 12.000   | 0.533 1.266 7.000     | 0.414 1.237 13.000   | 0.491 1.182 9.000    | -1.880 -1.031 27.000 | 0.476 1.220 10.000   | 0.095 1.108 21.500   |
| 0.720 1.276 11.000   | 0.416 1.218 16.000    | 0.419 1.219 14.000   | 0.416 1.263 17.000   | -1.472 -0.673 27.000 | 0.327 1.226 20.000   | 0.406 1.272 18.500   |
| 1.049 1.339 19.000   | 1.119 1.358 18.000    | 1.243 1.433 12.000   | 1.172 1.416 15.000   | -1.718 -1.533 27.000 | 1.173 1.426 14.000   | 1.266 1.391 9.500    |
| -0.213 0.640 20.000  | 0.157 0.971 13.000    | 0.222 0.949 5.000    | 0.186 1.035 10.000   | -1.297 -0.474 26.000 | 0.050 0.992 16.000   | 0.190 1.044 8.500    |
| 0.576 0.951 16.000   | 0.725 1.087 5.000     | 0.573 1.072 18.000   | 0.672 1.069 14.000   | -1.320 -0.864 27.000 | 0.720 1.058 8.000    | 0.690 1.100 12.500   |
| 0.804 1.100 9.000    | 0.666 1.131 16.000    | 0.629 1.096 18.000   | 0.709 1.137 14.000   | -1.348 -0.971 27.000 | 0.692 1.132 15.000   | 0.621 1.113 19.500   |
| -0.504 0.316 24.000  | 0.395 0.939 8.000     | 0.312 0.922 16.000   | 0.376 0.999 12.000   | -1.150 -0.383 27.000 | 0.308 0.968 17.000   | 0.412 1.007 6.500    |
| 0.058 0.761 23.000   | 0.417 1.022 12.000    | 0.389 0.955 19.000   | 0.427 1.019 10.000   | -1.182 -0.555 27.000 | 0.484 1.033 7.000    | 0.406 1.011 15.500   |
| 0.496 0.934 23.000   | 0.718 1.031 7.000     | 0.661 1.012 17.000   | 0.677 1.027 14.000   | -1.118 -0.752 27.000 | 0.699 1.032 12.000   | 0.709 1.034 9.500    |
| -0.275 0.245 24.000  | 0.588 0.906 12.000    | 0.478 0.803 16.000   | 0.593 0.906 11.000   | -1.366 -1.078 27.000 | 0.616 0.944 7.000    | 0.634 0.899 5.500    |
| -0.048 0.642 24.000  | 0.529 0.995 13.000    | 0.340 0.902 17.000   | 0.546 0.999 9.000    | -1.124 -0.634 27.000 | 0.590 1.001 5.000    | 0.590 0.999 6.500    |
| 0.462 0.850 22.000   | 0.699 1.009 11.000    | 0.715 0.996 9.000    | 0.666 0.997 15.500   | -1.087 -0.740 27.000 | 0.687 1.003 12.000   | 0.676 0.994 13.500   |

**Tabela B.7:** Tabela uspešnosti kombinirane funkcije na vseh metodah za ocenjevanje pomembnosti atributov in vseh naborih podatkov pri osnovni analizi (kvadrant (2, 3) od (3, 4)).

| <i>LeaAUC2N</i>      | <i>LeaSeN</i>        | <i>LeaSpN</i>        | <i>LeaRMSEN</i>      | <i>LeaSaN</i>        | <i>LeaSMN</i>       | <i>LeaS/sN</i>       |
|----------------------|----------------------|----------------------|----------------------|----------------------|---------------------|----------------------|
| 0.897 1.339 7.500    | 0.857 1.072 11.000   | 0.661 1.038 15.000   | -1.601 -1.057 26.000 | 0.815 1.359 13.000   | 0.000 0.000 18.000  | 0.822 1.357 12.000   |
| 1.112 1.387 10.500   | 1.425 1.521 4.000    | 1.469 1.538 3.000    | -1.734 -1.458 26.000 | 1.070 1.346 14.000   | 0.000 0.000 19.000  | 1.097 1.351 12.000   |
| 1.195 1.405 7.500    | 1.134 1.498 10.000   | 1.023 1.421 17.000   | -1.836 -1.643 27.000 | 1.213 1.406 6.000    | 0.000 0.000 19.000  | 1.227 1.455 5.000    |
| 0.480 0.752 7.500    | 0.222 0.437 15.000   | 0.199 0.441 16.000   | -1.913 -1.612 26.000 | 0.362 0.663 12.000   | 0.000 0.000 18.000  | 0.395 0.681 9.000    |
| 0.666 0.907 8.500    | 0.561 0.697 15.000   | 0.629 0.736 11.000   | -1.591 -1.361 26.000 | 0.629 0.859 12.000   | 0.000 0.000 19.000  | 0.642 0.870 10.000   |
| 1.011 1.101 10.500   | 0.928 1.115 13.000   | 0.896 1.079 15.000   | -1.563 -1.494 27.000 | 1.031 1.100 7.000    | 0.000 0.000 19.000  | 1.035 1.095 6.000    |
| -0.640 -0.563 9.500  | -0.901 -0.425 20.000 | -0.629 -0.619 8.000  | -0.882 -0.686 19.000 | -0.744 -0.548 15.000 | 0.000 0.000 4.500   | -0.746 -0.547 16.000 |
| 0.666 0.828 8.500    | 0.591 0.824 14.000   | 0.292 0.600 17.000   | -1.730 -1.522 27.000 | 0.565 0.773 15.000   | 0.000 0.000 19.000  | 0.563 0.775 16.000   |
| 0.772 0.846 9.500    | 0.824 0.860 5.000    | 0.800 0.870 6.000    | -1.341 -1.283 25.000 | 0.799 0.857 8.000    | -0.599 0.000 20.000 | 0.800 0.858 7.000    |
| -0.826 -0.766 15.500 | -0.507 -0.402 6.000  | -0.557 -0.469 11.000 | -1.261 -1.162 21.000 | -0.521 -0.422 10.000 | -0.560 0.000 12.000 | -0.514 -0.417 7.000  |
| 0.248 0.410 12.500   | 0.541 0.715 8.000    | -0.072 0.126 17.000  | -1.486 -1.282 27.000 | 0.239 0.443 14.000   | -0.298 0.000 18.000 | 0.238 0.444 15.000   |
| 0.934 0.971 3.500    | 0.889 0.952 11.000   | 0.920 0.943 9.000    | -1.386 -1.336 25.000 | 0.924 0.974 7.500    | 0.000 0.000 18.000  | 0.924 0.974 7.500    |
| 0.106 1.098 8.500    | -0.022 0.986 16.000  | -0.103 0.971 17.000  | -1.328 -0.335 25.000 | 0.104 1.097 10.000   | 0.000 0.000 14.000  | 0.094 1.090 11.000   |
| 0.048 1.100 12.500   | 0.030 1.049 16.000   | 0.178 1.161 2.000    | -1.186 -0.136 26.000 | 0.078 1.128 8.000    | 0.000 0.000 18.000  | 0.061 1.118 10.000   |
| 0.121 1.155 10.500   | 0.032 1.103 14.000   | 0.012 1.065 15.000   | -1.274 -0.258 21.000 | 0.136 1.152 5.500    | 0.000 0.000 17.000  | 0.113 1.155 12.000   |
| 0.005 0.865 6.500    | -0.285 0.611 16.000  | 0.027 0.836 2.000    | -1.389 -0.525 26.000 | -0.011 0.853 9.000   | 0.000 0.000 8.000   | -0.021 0.857 10.000  |
| 0.058 0.939 7.500    | -0.066 0.912 17.000  | 0.038 0.919 12.000   | -1.361 -0.478 26.000 | 0.029 0.912 13.000   | -0.244 0.000 19.000 | 0.019 0.901 15.000   |
| 0.122 1.018 5.500    | 0.118 1.031 8.000    | 0.094 1.004 15.000   | -1.168 -0.269 26.000 | 0.115 1.014 9.000    | 0.000 0.000 18.000  | 0.120 1.013 7.000    |
| -0.385 0.358 10.500  | -0.825 0.006 17.000  | -0.485 -0.134 15.000 | -1.830 -1.139 27.000 | -0.289 0.402 8.000   | -0.455 0.000 14.000 | -0.291 0.378 9.000   |
| 0.047 0.914 6.500    | -0.051 0.854 16.000  | -0.182 0.746 17.000  | -1.201 -0.332 26.000 | 0.018 0.887 13.000   | -0.210 0.000 18.000 | 0.013 0.886 15.000   |
| 0.070 0.954 13.500   | 0.075 0.991 9.000    | 0.105 1.002 6.000    | -1.137 -0.251 25.000 | 0.069 0.955 16.000   | -0.834 0.000 19.000 | 0.070 0.957 15.000   |
| -0.458 -0.058 12.500 | -1.034 -0.761 19.000 | -0.758 -0.555 15.000 | -1.294 -1.039 22.000 | -0.321 -0.066 7.000  | -0.419 0.000 11.000 | -0.323 -0.063 8.000  |
| -0.470 0.421 11.500  | -0.816 -0.432 19.000 | -0.539 0.217 16.000  | -1.710 -0.801 26.000 | -0.583 0.326 17.000  | -0.260 0.000 8.000  | -0.588 0.328 18.000  |
| 0.075 0.934 9.500    | 0.059 0.924 14.000   | -0.012 0.863 17.000  | -1.532 -0.673 27.000 | 0.059 0.918 15.500   | -0.328 0.000 19.000 | 0.059 0.918 15.500   |
| 0.451 0.949 10.500   | 0.552 1.072 6.000    | 0.307 0.971 14.000   | -1.427 -0.785 22.000 | 0.235 0.877 16.000   | 0.000 0.000 18.000  | 0.183 0.840 17.000   |
| 0.891 1.121 10.500   | 0.697 1.081 18.000   | 0.699 1.063 17.000   | -1.302 -0.972 25.000 | 0.783 1.113 15.000   | 0.000 0.000 23.000  | 0.808 1.128 14.000   |
| 1.051 1.125 10.500   | 1.012 1.153 14.000   | 0.810 0.857 17.000   | -1.313 -1.276 27.000 | 1.065 1.102 7.000    | 0.000 0.000 18.000  | 1.059 1.082 8.000    |
| 0.690 1.022 8.500    | 0.614 1.032 10.000   | 0.795 0.982 6.000    | -1.304 -0.838 26.000 | 0.551 1.017 15.000   | 0.000 0.000 18.000  | 0.555 1.016 14.000   |
| 0.862 1.039 9.500    | 0.905 0.102 8.000    | 0.626 1.016 16.000   | -1.188 -0.793 25.000 | 0.646 1.041 14.500   | 0.000 0.000 19.000  | 0.646 1.041 14.500   |
| 1.039 1.045 3.500    | 0.627 0.971 16.000   | 0.876 1.045 13.000   | -1.203 -1.173 27.000 | 1.010 1.040 6.000    | 0.000 0.000 19.500  | 1.013 1.037 5.000    |
| 0.728 1.007 10.500   | 0.731 0.910 9.000    | 0.732 0.999 8.000    | -1.074 -0.779 25.000 | 0.722 1.017 14.000   | 0.000 0.000 18.500  | 0.722 1.018 15.000   |
| 1.003 1.020 5.500    | 0.905 1.008 10.000   | 0.697 0.993 15.000   | -1.098 -0.952 26.000 | 0.868 1.014 12.000   | 0.000 0.000 23.000  | 0.869 1.011 11.000   |
| 0.988 0.989 2.500    | 0.762 0.982 14.000   | 0.748 0.990 15.000   | -1.134 -1.131 25.000 | 0.983 0.986 6.000    | 0.000 0.000 19.000  | 0.984 0.988 5.000    |
| 0.413 0.704 12.500   | 0.818 0.829 4.000    | 0.232 0.995 14.000   | -1.042 -0.624 26.000 | 0.519 0.937 11.000   | 0.000 0.000 15.500  | 0.520 0.937 10.000   |
| 0.820 0.944 10.500   | 0.730 1.003 14.000   | 0.884 0.921 7.000    | -1.046 -0.875 21.000 | 0.768 0.939 12.500   | 0.000 0.000 17.500  | 0.768 0.939 12.500   |
| 0.866 0.972 11.500   | 0.932 0.994 7.000    | 0.866 0.954 13.000   | -1.051 -0.962 21.000 | 0.905 0.994 8.000    | 0.000 0.000 19.000  | 0.904 0.994 9.000    |
| 0.626 1.043 19.500   | 0.645 0.801 18.000   | 0.168 1.044 24.000   | -1.394 -1.008 26.000 | 0.686 1.072 16.000   | 0.000 0.000 25.000  | 0.553 1.003 23.000   |
| 0.981 1.116 18.500   | 0.850 0.984 23.000   | 0.983 1.113 17.000   | -1.397 -1.346 27.000 | 1.059 1.110 12.000   | 0.000 0.000 25.000  | 1.097 1.148 8.000    |
| 1.160 1.181 2.500    | 0.885 1.118 23.000   | 0.935 1.100 21.000   | -1.280 -1.161 26.000 | 1.050 1.169 9.000    | 0.000 0.000 25.000  | 1.008 1.146 15.000   |
| 0.793 1.012 13.500   | 0.940 1.014 2.000    | 0.685 1.004 20.000   | -1.223 -1.057 26.000 | 0.837 1.003 6.000    | 0.000 0.000 25.000  | 0.837 1.009 7.000    |
| 0.907 1.017 14.500   | 0.885 1.022 17.000   | 0.648 1.039 24.000   | -1.170 -1.038 26.000 | 0.904 1.036 16.000   | 0.000 0.000 25.000  | 0.919 1.042 11.000   |
| 1.032 1.062 9.500    | 0.982 0.993 18.000   | 0.978 1.017 19.000   | -1.146 -1.140 26.000 | 1.040 1.046 8.000    | 0.000 0.000 25.000  | 1.031 1.051 11.000   |
| 0.606 0.932 11.500   | 0.822 0.868 5.000    | 0.270 0.939 24.000   | -1.359 -1.045 26.000 | 0.585 0.899 14.000   | 0.000 0.000 25.000  | 0.585 0.898 15.000   |
| 0.837 0.983 11.500   | 0.903 0.956 7.000    | 0.613 0.998 21.000   | -1.094 -0.871 26.000 | 0.750 0.973 18.000   | 0.000 0.000 25.000  | 0.747 0.972 19.000   |
| 0.781 1.018 6.500    | 0.719 0.995 17.000   | 0.834 1.012 3.000    | -1.076 -0.815 26.000 | 0.753 1.014 12.000   | 0.000 0.000 25.000  | 0.752 1.013 13.000   |
| 0.669 0.970 11.500   | 0.829 0.953 4.000    | 0.269 0.962 24.000   | -1.064 -0.713 26.000 | 0.620 0.971 15.000   | 0.000 0.000 25.000  | 0.619 0.971 16.000   |
| 0.991 0.995 2.500    | 0.693 0.980 20.000   | 0.674 0.976 21.000   | -1.048 -0.102 26.000 | 0.959 0.995 6.500    | 0.000 0.000 25.000  | 0.961 0.996 5.000    |
| 0.870 1.004 14.500   | 0.881 0.998 11.000   | 0.858 0.997 19.000   | -1.041 -0.896 26.000 | 0.857 1.002 20.000   | 0.000 0.000 25.000  | 0.857 1.003 21.000   |
| 0.095 1.108 21.500   | 0.370 1.076 14.000   | -0.411 1.122 24.000  | -1.769 -0.957 26.000 | 0.302 1.114 16.000   | -1.250 0.000 25.000 | 0.288 1.145 17.000   |
| 0.406 1.272 18.500   | 0.979 1.280 9.000    | 0.096 1.134 24.000   | -1.409 -0.624 26.000 | 0.475 1.260 13.000   | 0.000 0.000 25.000  | 0.592 1.292 12.000   |
| 1.266 1.391 9.500    | 0.827 1.368 23.000   | 0.830 1.376 22.000   | -1.706 -1.490 26.000 | 1.151 1.367 17.000   | 1.429 1.429 3.000   | 1.268 1.430 8.000    |
| 0.190 1.044 8.500    | -0.005 0.937 18.000  | -0.020 0.883 19.000  | -1.275 -0.430 25.000 | 0.180 1.025 12.000   | -2.000 0.000 27.000 | 0.193 1.027 7.000    |
| 0.690 1.100 12.500   | 0.546 0.999 19.000   | 0.400 1.059 23.000   | -1.312 -0.935 26.000 | 0.705 1.082 10.000   | 0.000 0.000 25.000  | 0.703 1.090 11.000   |
| 0.621 1.113 19.500   | 0.827 1.081 8.000    | 0.349 1.066 23.000   | -1.311 -0.893 26.000 | 0.727 1.145 12.000   | 0.000 0.000 25.000  | 0.770 1.160 10.000   |
| 0.412 1.007 6.500    | 0.389 0.930 9.000    | 0.089 0.900 21.000   | -1.144 -0.476 26.000 | 0.336 1.004 14.000   | -1.026 0.000 25.000 | 0.332 1.002 15.000   |
| 0.406 1.011 15.500   | 0.490 0.943 6.000    | 0.312 1.011 20.000   | -1.145 -0.544 26.000 | 0.412 1.013 13.000   | 0.000 0.000 24.000  | 0.411 1.012 14.000   |
| 0.709 1.034 9.500    | 0.704 1.039 11.000   | 0.544 1.045 21.000   | -1.113 -0.756 26.000 | 0.669 1.026 16.000   | 0.000 0.000 25.000  | 0.670 1.023 15.000   |
| 0.634 0.899 5.500    | 0.216 0.879 21.000   | 0.369 0.944 17.000   | -1.328 -1.031 26.000 | 0.596 0.893 9.000    | 0.000 0.000 23.000  | 0.594 0.891 10.000   |
| 0.590 0.999 6.500    | 0.332 0.977 18.000   | 0.146 0.999 22.000   | -1.102 -0.639 26.000 | 0.536 0.999 11.000   | 0.000 0.000 23.000  | 0.534 0.998 12.000   |
| 0.676 0.994 13.500   | 0.756 0.986 8.000    | 0.553 1.017 20.000   | -1.085 -0.749 26.000 | 0.658 0.994 17.000   | 0.000 0.000 25.000  | 0.658 0.995 18.000   |

**Tabela B.8:** Tabela uspešnosti kombinirane funkcije na vseh metodah za ocenjevanje pomembnosti atributov in vseh naborih podatkov pri osnovni analizi (kvadrant (2, 4) od (3, 4)).

| Dataset              | <i>RedFN</i>         | <i>RdFSN</i>        | <i>IGRN</i>          | <i>GiniN</i>         | <i>Chi2N</i>         | <i>DistN</i>         |
|----------------------|----------------------|---------------------|----------------------|----------------------|----------------------|----------------------|
| if-a-2 10-030        | -0.157 1.112 20.000  | 0.617 1.178 3.000   | -0.165 1.104 22.000  | -0.151 1.111 18.000  | -0.162 1.108 21.000  | -0.153 1.116 19.000  |
| if-a-2 10-060        | 0.159 1.152 15.000   | 0.669 1.201 1.000   | -0.121 1.102 20.000  | -0.123 1.100 21.000  | -0.126 1.098 22.000  | -0.110 1.108 19.000  |
| if-a-2 10-180        | 0.646 1.260 6.000    | 0.775 1.306 4.000   | -0.046 1.196 21.000  | -0.049 1.193 23.000  | -0.048 1.194 22.000  | -0.042 1.198 20.000  |
| if-a-2 20-030        | -0.332 0.868 17.000  | 0.513 0.981 1.000   | -0.353 0.855 19.000  | -0.373 0.837 21.000  | -0.362 0.850 20.000  | -0.327 0.874 16.000  |
| if-a-2 20-060        | 0.149 1.040 16.000   | 0.422 1.020 14.000  | -0.079 1.022 21.000  | -0.082 1.017 22.000  | -0.082 1.018 23.000  | -0.073 1.028 20.000  |
| if-a-2 20-180        | 0.574 1.105 15.000   | 0.644 1.079 14.000  | 0.011 1.076 20.000   | 0.012 1.075 19.000   | 0.011 1.074 21.000   | 0.011 1.077 22.000   |
| if-a-2 40-030        | -0.279 0.780 17.000  | -0.285 0.732 18.000 | -0.289 0.776 20.000  | -0.287 0.774 19.000  | -0.300 0.763 21.000  | -0.266 0.799 15.000  |
| if-a-2 40-060        | 0.036 0.953 16.000   | 0.506 0.809 13.000  | -0.073 0.952 19.000  | -0.078 0.945 22.000  | -0.074 0.950 20.000  | -0.068 0.960 18.000  |
| if-a-2 40-180        | 0.295 1.016 15.000   | 0.406 0.983 13.000  | -0.028 1.023 20.000  | -0.029 1.022 21.500  | -0.029 1.022 21.500  | -0.026 1.024 19.000  |
| if-a-2 80-030        | -0.300 0.742 7.000   | -0.346 0.639 11.000 | -0.301 0.752 8.000   | -0.306 0.744 9.000   | -0.317 0.738 10.000  | -0.287 0.763 5.000   |
| if-a-2 80-060        | -0.098 0.846 18.000  | -0.032 0.754 16.000 | -0.219 0.845 21.000  | -0.227 0.839 22.500  | -0.227 0.839 22.500  | -0.201 0.859 20.000  |
| if-a-2 80-180        | 0.186 0.983 14.000   | 0.160 0.873 15.000  | -0.035 0.995 20.000  | -0.037 0.993 21.500  | -0.037 0.993 21.500  | -0.031 0.998 19.000  |
| if-a-4 10-030        | -0.276 1.143 12.000  | 0.292 1.329 1.000   | -0.498 1.035 18.000  | -0.385 1.063 14.000  | -0.291 1.138 13.000  | -0.496 1.044 17.000  |
| if-a-4 10-060        | -0.247 1.306 10.000  | 0.481 1.292 1.000   | -0.138 1.333 5.000   | -0.239 1.330 8.000   | -0.220 1.300 7.000   | -0.137 1.337 4.000   |
| if-a-4 10-180        | 1.194 1.730 1.000    | 0.525 1.354 4.000   | -0.046 1.394 19.000  | -0.072 1.395 21.000  | -0.052 1.401 20.000  | -0.042 1.395 18.000  |
| if-a-4 20-030        | -0.420 0.657 18.000  | -0.189 0.809 8.000  | -0.659 0.584 21.000  | -0.179 0.795 7.000   | -0.365 0.680 14.000  | -0.654 0.599 20.000  |
| if-a-4 20-060        | -0.690 0.645 18.000  | -0.072 0.937 5.000  | -0.807 0.563 21.000  | -0.586 0.694 17.000  | -0.586 0.703 16.000  | -0.781 0.574 20.000  |
| if-a-4 20-180        | 0.616 1.100 2.000    | 0.663 1.169 1.000   | -0.235 1.020 20.000  | -0.210 1.042 18.000  | -0.205 1.040 17.000  | -0.225 1.024 19.000  |
| if-a-4 40-030        | -0.601 0.627 4.000   | -0.403 0.261 2.000  | -0.667 0.566 8.000   | -0.633 0.559 5.000   | -0.644 0.560 7.000   | -0.643 0.580 6.000   |
| if-a-4 40-060        | -0.296 0.724 17.000  | -0.059 0.683 9.000  | -0.325 0.553 19.000  | -0.230 0.723 14.000  | -0.276 0.694 16.000  | -0.307 0.574 18.000  |
| if-a-4 40-180        | 0.340 1.001 6.000    | 0.507 0.862 3.000   | -0.106 1.006 20.000  | -0.096 1.016 18.000  | -0.093 1.016 17.000  | -0.102 1.008 19.000  |
| if-a-4 80-030        | -1.135 0.166 13.000  | -0.523 0.071 1.000  | -1.428 0.091 19.000  | -1.001 0.322 6.000   | -1.168 0.165 16.000  | -1.472 0.034 21.000  |
| if-a-4 80-060        | -0.289 0.772 15.000  | 0.010 0.701 2.000   | -0.469 0.604 20.000  | -0.305 0.733 16.000  | -0.306 0.744 17.000  | -0.443 0.628 19.000  |
| if-a-4 80-180        | 0.318 0.874 10.000   | 0.263 0.684 14.000  | -0.142 0.888 21.000  | -0.139 0.889 20.000  | -0.138 0.896 19.000  | -0.137 0.894 18.000  |
| bool-simple-1 10-030 | -1.063 0.069 21.000  | -0.154 1.010 2.000  | -1.062 -0.221 20.000 | -1.034 -0.126 19.000 | -1.020 -0.045 18.000 | -1.103 -0.258 22.000 |
| bool-simple-1 10-060 | 0.635 1.275 2.000    | 0.257 1.255 11.000  | -0.194 1.070 21.000  | -0.214 1.053 23.000  | -0.202 1.067 22.000  | -0.182 1.081 20.000  |
| bool-simple-1 10-180 | 0.311 1.297 4.000    | 0.321 1.320 3.000   | -0.088 1.180 19.000  | -0.087 1.181 17.000  | -0.089 1.181 20.000  | -0.087 1.180 18.000  |
| bool-simple-1 20-030 | -0.638 0.528 6.000   | -0.481 0.379 2.000  | -0.668 0.442 8.000   | -0.837 0.306 12.000  | -0.674 0.447 9.000   | -0.611 0.496 5.000   |
| bool-simple-1 20-060 | 0.253 0.997 4.000    | 0.127 0.866 8.000   | -0.208 0.974 16.000  | -0.212 0.973 17.000  | -0.220 0.969 18.000  | -0.202 0.978 15.000  |
| bool-simple-1 20-180 | 0.402 1.089 2.000    | 0.188 1.050 14.000  | -0.056 1.035 21.000  | -0.065 1.032 23.000  | -0.060 1.033 22.000  | -0.054 1.037 20.000  |
| bool-simple-1 40-030 | -0.204 0.763 13.000  | -0.329 0.118 19.000 | -0.224 0.774 15.000  | -0.201 0.781 12.000  | -0.225 0.759 16.000  | -0.219 0.783 14.000  |
| bool-simple-1 40-060 | -0.023 0.644 2.000   | -0.445 0.631 17.000 | -0.560 0.551 20.000  | -0.649 0.499 22.000  | -0.551 0.566 19.000  | -0.506 0.593 18.000  |
| bool-simple-1 40-180 | 0.500 0.960 12.000   | 0.108 0.886 18.000  | -0.278 0.815 22.000  | -0.287 0.808 24.000  | -0.283 0.811 23.000  | -0.273 0.818 21.000  |
| bool-simple-1 80-030 | -1.185 -0.516 26.000 | -0.743 0.214 6.000  | -1.097 -0.471 21.000 | -1.150 -0.489 24.000 | -1.134 -0.483 23.000 | -1.105 -0.464 22.000 |
| bool-simple-1 80-060 | -0.336 0.473 5.000   | 0.164 0.621 1.000   | -0.685 0.471 12.000  | -0.755 0.413 18.000  | -0.692 0.467 13.000  | -0.651 0.495 11.000  |
| bool-simple-1 80-180 | 0.259 0.825 12.000   | 0.205 0.730 14.000  | -0.235 0.787 20.000  | -0.242 0.780 22.000  | -0.236 0.786 21.000  | -0.228 0.794 19.000  |
| adult 00-030         | 1.838 -0.648 7.000   | 1.558 -0.682 18.000 | nan -nan nan         | nan -nan nan         | nan -nan nan         | nan -nan nan         |
| adult 00-060         | 1.561 -0.419 16.000  | 1.509 -0.257 19.000 | nan -nan nan         | nan -nan nan         | nan -nan nan         | nan -nan nan         |
| adult 00-180         | 1.739 -0.287 8.000   | 1.743 -0.288 7.000  | nan -nan nan         | nan -nan nan         | nan -nan nan         | nan -nan nan         |
| ionosphere 00-030    | 1.525 -0.297 14.000  | 1.755 -0.651 9.000  | nan -nan nan         | nan -nan nan         | nan -nan nan         | nan -nan nan         |
| ionosphere 00-060    | 1.729 -0.467 5.000   | 1.541 -0.424 9.000  | nan -nan nan         | nan -nan nan         | nan -nan nan         | nan -nan nan         |
| ionosphere 00-180    | 1.679 -0.204 5.000   | 1.812 -0.317 3.000  | nan -nan nan         | nan -nan nan         | nan -nan nan         | nan -nan nan         |
| lung-cancer 00-030   | 1.391 -0.152 23.000  | 1.598 -0.282 15.000 | 1.636 -0.211 12.000  | 1.591 -0.225 16.000  | 1.537 -0.197 17.000  | 1.492 -0.186 21.000  |
| lung-cancer 00-060   | 1.388 -0.133 18.000  | 1.536 -0.218 11.000 | 1.673 -0.187 7.000   | 1.579 -0.189 10.000  | 1.515 -0.165 12.000  | 1.427 -0.138 13.000  |
| lung-cancer 00-180   | 1.448 -0.117 18.000  | 1.603 -0.102 10.000 | 1.489 -0.059 14.000  | 1.509 -0.081 13.000  | 1.545 -0.085 11.000  | 1.450 -0.065 17.000  |
| monks-1 00-030       | 1.416 -0.345 18.000  | 1.619 -0.417 11.000 | 1.406 -0.241 20.000  | 1.388 -0.209 21.500  | 1.388 -0.209 21.500  | 1.361 -0.207 24.000  |
| monks-1 00-060       | 1.275 -0.125 22.000  | 1.767 -0.361 8.000  | 1.254 -0.088 23.000  | 1.247 -0.077 24.500  | 1.247 -0.077 24.500  | 1.238 -0.076 26.000  |
| monks-1 00-180       | 1.597 -0.094 20.000  | 1.877 -0.144 12.000 | 1.214 -0.028 25.000  | 1.216 -0.027 23.500  | 1.216 -0.027 23.500  | 1.212 -0.026 26.000  |
| promoters 00-030     | 1.221 -0.170 21.000  | 1.418 -0.289 8.000  | 1.241 -0.191 20.000  | 1.293 -0.230 15.500  | 1.293 -0.230 15.500  | 1.220 -0.179 22.000  |
| promoters 00-060     | 1.228 -0.110 18.000  | 1.416 -0.225 8.000  | 1.219 -0.111 20.000  | 1.255 -0.129 15.500  | 1.255 -0.129 15.500  | 1.206 -0.107 22.000  |
| promoters 00-180     | 1.342 -0.082 4.000   | 1.555 -0.169 3.000  | 1.187 -0.052 12.000  | 1.228 -0.064 7.500   | 1.228 -0.064 7.500   | 1.176 -0.050 13.000  |
| voting 00-030        | 1.545 -0.215 6.000   | 1.569 -0.238 4.000  | 1.512 -0.205 8.000   | 1.580 -0.219 3.000   | 1.585 -0.223 2.000   | 1.351 -0.171 15.000  |
| voting 00-060        | 1.567 -0.166 4.000   | 1.435 -0.135 6.000  | 1.516 -0.162 5.000   | 1.588 -0.170 2.000   | 1.583 -0.169 3.000   | 1.351 -0.136 8.000   |
| voting 00-180        | 1.365 -0.071 7.000   | 1.532 -0.095 4.000  | 1.560 -0.067 3.000   | 1.620 -0.065 2.000   | 1.634 -0.065 1.000   | 1.403 -0.054 6.000   |
| zoo 00-030           | 1.879 -0.109 6.000   | 1.880 -0.100 5.000  | 1.538 -0.138 20.000  | 1.436 -0.048 22.000  | 1.338 -0.039 23.000  | 1.609 -0.079 18.000  |
| zoo 00-060           | 1.907 -0.068 9.000   | 1.880 -0.078 11.000 | 1.587 -0.077 21.000  | 1.575 -0.041 22.000  | 1.410 -0.033 23.000  | 1.847 -0.063 16.000  |
| zoo 00-180           | 1.876 -0.037 3.000   | 1.879 -0.041 2.000  | 1.633 -0.042 11.000  | 1.606 -0.026 15.000  | 1.439 -0.017 22.000  | 1.891 -0.038 1.000   |
| pima-indians 00-030  | 1.470 -0.431 19.000  | 1.546 -0.565 18.000 | nan -nan nan         | nan -nan nan         | nan -nan nan         | nan -nan nan         |
| pima-indians 00-060  | 1.395 -0.266 22.000  | 1.566 -0.637 19.000 | nan -nan nan         | nan -nan nan         | nan -nan nan         | nan -nan nan         |
| pima-indians 00-180  | 1.412 -0.192 21.000  | 1.417 -0.308 19.000 | nan -nan nan         | nan -nan nan         | nan -nan nan         | nan -nan nan         |
| avg-gen              | 0.029 0.443 12.708   | 0.489 0.858 7.923   | -0.359 0.140 15.833  | -0.385 0.132 17.179  | -0.376 0.135 17.155  | -0.371 0.143 15.568  |
| avg-real             | 1.533 -0.217 13.083  | 1.625 -0.293 9.958  | 1.444 -0.124 14.733  | 1.447 -0.120 14.200  | 1.414 -0.115 14.800  | 1.416 -0.105 16.533  |
| avg-size-030         | -0.275 -0.007 16.844 | 0.388 0.521 8.969   | -0.341 0.029 15.803  | -0.373 0.014 16.836  | -0.363 0.022 17.000  | -0.361 0.036 15.533  |
| avg-size-060         | 0.329 0.453 11.687   | 0.650 0.751 8.602   | -0.181 0.106 15.713  | -0.203 0.101 16.951  | -0.199 0.102 16.893  | -0.192 0.112 15.607  |
| avg-size-180         | 0.597 0.635 9.734    | 0.855 0.872 6.961   | -0.111 0.220 15.713  | -0.128 0.219 17.016  | -0.127 0.219 16.992  | -0.119 0.221 15.803  |
| avg-all              | 0.217 0.360 12.755   | 0.631 0.714 8.177   | -0.211 0.118 15.743  | -0.235 0.111 16.934  | -0.230 0.114 16.962  | -0.224 0.123 15.648  |

**Tabela B.9:** Tabela uspešnosti kombinirane funkcije na vseh metodah za ocenjevanje pomembnosti atributov in vseh naborih podatkov pri osnovni analizi (kvadrant (3, 1) od (3, 4)).

| <i>LogON</i>         | <i>LeaN</i>          | <i>LeaGITc3APN</i>   | <i>LeaGtN</i>        | <i>LeaGFN</i>        | <i>LeaGIN</i>       | <i>LeaTc3N</i>       |
|----------------------|----------------------|----------------------|----------------------|----------------------|---------------------|----------------------|
| -0.442 0.933 23.000  | 0.317 1.124 8.000    | 0.469 0.984 5.000    | 0.125 0.974 14.000   | 0.879 1.005 1.000    | 0.245 0.824 12.000  | 0.377 1.126 6.000    |
| -0.177 1.120 23.000  | 0.200 0.928 14.000   | 0.537 1.008 6.000    | nan nan nan          | 0.591 1.109 5.000    | 0.624 1.096 2.000   | 0.612 1.112 4.000    |
| -0.115 1.118 24.000  | 0.388 1.173 13.000   | 0.364 0.953 14.000   | 0.508 1.192 7.000    | 0.336 1.041 16.000   | 0.804 1.286 2.000   | 0.433 1.192 12.000   |
| -0.563 0.770 24.000  | 0.088 0.868 8.000    | 0.186 0.996 5.000    | -0.168 0.722 14.000  | -0.211 0.649 15.000  | 0.123 0.813 7.000   | 0.202 0.969 4.000    |
| -0.298 0.884 24.000  | 0.722 1.031 7.000    | -0.007 0.925 19.000  | 0.425 0.940 13.000   | 0.253 0.859 15.000   | 0.148 0.967 17.000  | 0.794 1.079 4.000    |
| -0.077 0.985 25.000  | 0.809 1.073 7.000    | 0.419 1.016 16.000   | 0.854 0.981 5.000    | 0.260 0.959 17.000   | 0.156 0.978 18.000  | 0.814 1.077 6.000    |
| -0.166 0.735 14.000  | 0.650 0.919 4.000    | -0.112 0.833 13.000  | 0.420 0.713 7.000    | -0.268 0.598 16.000  | -0.350 0.731 22.000 | 0.153 0.867 10.000   |
| -0.077 0.888 21.000  | 0.866 1.005 4.000    | 0.288 0.971 15.000   | 0.555 0.899 10.000   | -0.133 0.842 23.000  | -0.028 0.890 17.000 | 0.686 1.002 8.000    |
| -0.148 0.943 25.000  | 0.802 1.019 5.000    | 0.120 0.957 16.000   | 0.554 0.895 12.000   | -0.091 0.937 24.000  | 0.011 0.987 17.000  | 0.752 1.023 6.000    |
| -0.297 0.741 6.000   | -0.468 0.559 18.500  | -0.096 0.841 3.000   | -0.397 0.521 15.000  | -0.499 0.622 21.000  | -0.260 0.832 4.000  | 0.018 0.917 1.000    |
| -0.247 0.756 24.000  | 0.602 0.959 6.000    | 0.019 0.904 14.000   | 0.297 0.793 11.000   | -0.255 0.757 25.000  | -0.095 0.851 17.000 | 0.501 0.978 9.000    |
| -0.071 0.892 24.000  | 0.673 0.999 7.000    | 0.146 0.984 16.000   | 0.431 0.813 12.000   | -0.168 0.888 25.000  | 0.008 0.948 17.000  | 0.750 1.004 3.000    |
| nan nan nan          | -0.067 1.004 7.000   | -0.136 0.614 9.000   | -0.425 1.052 16.000  | -0.653 0.891 19.000  | -1.840 0.098 22.000 | -0.043 1.263 5.000   |
| nan nan nan          | -0.626 0.806 19.000  | 0.088 1.087 3.000    | -0.830 0.891 21.000  | -0.590 0.932 17.000  | -0.477 0.642 14.000 | 0.351 1.225 2.000    |
| nan nan nan          | 0.364 1.277 6.000    | 0.027 1.124 17.000   | 0.159 0.890 16.000   | 0.230 1.190 15.000   | 0.349 1.293 8.000   | 0.246 1.168 14.000   |
| nan nan nan          | -0.267 0.706 11.000  | -0.407 0.762 17.000  | -0.308 0.641 12.000  | -0.258 0.434 10.000  | -0.628 0.567 19.000 | -0.177 0.924 6.000   |
| nan nan nan          | -0.126 0.666 7.000   | 0.136 0.959 1.000    | -0.737 0.258 19.000  | 0.021 0.853 3.000    | -0.093 0.842 6.000  | -0.561 0.926 15.000  |
| nan nan nan          | 0.280 1.093 8.000    | 0.343 1.059 3.000    | 0.276 1.009 9.000    | 0.297 0.992 6.000    | 0.174 0.903 16.000  | 0.310 1.086 4.000    |
| nan nan nan          | -1.558 -0.683 19.000 | -0.680 0.343 9.000   | -1.693 -0.518 24.000 | -1.158 -0.475 15.000 | -0.358 0.171 1.000  | -0.776 0.648 10.000  |
| nan nan nan          | 0.077 0.960 5.000    | 0.302 0.901 1.000    | -0.414 0.604 21.000  | -0.097 0.696 10.000  | 0.239 0.851 2.000   | 0.237 0.964 3.000    |
| nan nan nan          | 0.171 1.004 14.000   | 0.456 0.989 4.000    | 0.133 0.942 16.000   | 0.386 0.876 5.000    | 0.531 0.904 2.000   | 0.267 1.035 8.000    |
| nan nan nan          | -1.355 -0.794 18.000 | -1.159 -0.319 15.000 | -0.665 -0.306 2.000  | -1.046 -0.408 9.000  | -1.030 -0.415 7.000 | -1.095 -0.703 10.000 |
| nan nan nan          | 0.000 0.940 3.000    | -0.041 0.791 6.000   | -0.219 0.704 13.000  | -0.133 0.724 11.000  | -0.022 0.833 4.000  | -0.134 0.893 12.000  |
| nan nan nan          | 0.335 1.007 9.000    | 0.669 0.941 1.000    | 0.306 0.854 13.000   | 0.181 0.825 15.000   | 0.385 0.949 4.000   | 0.394 1.008 3.000    |
| -0.324 0.698 7.000   | -0.318 1.024 5.000   | -0.143 0.940 1.000   | -0.323 0.924 6.000   | -0.752 0.815 16.000  | -0.810 0.621 17.000 | -0.154 0.925 3.000   |
| -0.144 0.985 19.000  | 0.331 1.225 7.000    | -0.269 0.105 24.000  | 0.060 1.099 16.000   | 0.428 1.247 6.000    | -0.051 1.005 18.000 | 0.124 1.182 14.000   |
| -0.192 1.076 24.000  | 0.181 1.223 10.000   | 0.266 1.151 6.000    | -0.116 1.123 21.000  | -0.033 1.107 15.000  | -0.155 1.115 22.000 | 0.154 1.214 13.000   |
| -0.491 0.667 3.000   | -1.536 0.376 24.000  | -0.399 0.294 1.000   | -0.570 0.444 4.000   | -1.015 0.506 14.000  | -1.197 0.231 19.000 | -0.655 0.123 7.000   |
| -0.413 0.842 21.000  | 0.063 0.919 11.000   | 0.372 0.995 3.000    | -0.716 0.493 23.000  | 0.521 0.855 1.000    | 0.184 0.719 6.000   | 0.516 0.939 2.000    |
| -0.183 0.898 24.000  | 0.302 1.013 8.000    | -0.014 0.920 19.000  | 0.204 0.969 12.000   | 0.063 0.928 17.000   | 0.297 0.838 9.000   | 0.212 1.012 11.000   |
| -1.052 0.001 25.000  | -0.137 0.914 4.500   | -0.091 0.749 3.000   | -0.158 0.714 6.000   | -0.297 0.434 18.000  | -0.340 0.553 20.000 | -0.055 0.747 2.000   |
| -0.561 0.596 21.000  | -0.172 0.620 7.000   | -0.387 0.547 16.000  | 0.108 0.463 1.000    | -0.690 -0.186 23.000 | -0.064 0.381 5.000  | -0.320 0.706 15.000  |
| -0.471 0.773 25.000  | 0.661 0.977 5.000    | 0.564 0.886 9.000    | 0.450 0.722 13.000   | 0.399 0.894 15.000   | 0.326 0.745 16.000  | 0.638 0.975 6.000    |
| -1.398 -0.224 27.000 | -0.811 -0.705 9.500  | -0.922 -0.479 12.000 | -0.634 -0.210 3.000  | -0.982 0.101 14.000  | -0.526 0.305 2.000  | -1.054 -0.560 18.000 |
| -0.746 0.404 16.000  | -0.862 -0.056 19.000 | -0.317 0.591 4.000   | -0.520 0.225 7.000   | -0.748 -0.187 17.000 | -0.617 0.062 10.000 | -0.544 0.371 8.000   |
| -0.591 0.683 24.000  | 0.345 0.927 5.000    | 0.457 0.790 1.000    | 0.119 0.779 16.000   | -0.376 0.454 23.000  | 0.397 0.721 2.000   | 0.392 0.915 3.000    |
| nan -nan nan         | 1.794 -5.674 8.000   | 1.442 -3.021 22.000  | 1.961 -16.723 2.000  | 1.757 -5.913 11.000  | 1.876 -7.193 5.000  | 1.595 -1.858 17.000  |
| nan -nan nan         | 1.924 -4.838 4.000   | 1.497 -1.166 21.000  | 1.501 -1.235 20.000  | 1.582 -0.986 15.000  | 1.764 -0.867 9.000  | 1.684 -1.845 10.000  |
| nan -nan nan         | 1.646 -1.694 15.000  | 1.886 -0.943 4.000   | 1.946 -2.774 2.000   | 1.607 -0.500 17.000  | 1.735 -0.513 9.000  | 1.808 -2.181 5.000   |
| nan -nan nan         | 1.798 -2.998 7.500   | 1.513 -0.574 16.000  | 1.468 -2.246 18.000  | 1.629 -1.470 11.000  | 1.638 -1.579 10.000 | 1.394 -2.513 20.000  |
| nan -nan nan         | 1.456 -2.765 15.000  | 1.518 -0.696 10.000  | 1.618 -4.005 7.000   | 1.968 -1.119 1.000   | 1.843 -1.023 3.000  | 1.233 -1.287 22.000  |
| nan -nan nan         | 1.282 -1.783 15.000  | 1.512 -0.462 8.000   | 1.689 -6.519 4.000   | 1.618 -1.308 6.000   | 1.998 -1.632 1.000  | 1.235 -1.798 19.000  |
| nan -nan nan         | 1.860 -6.506 9.000   | 1.430 -0.663 22.000  | 1.834 -7.520 10.000  | 1.504 -0.566 20.000  | 1.534 -0.881 18.000 | 1.508 -6.318 19.000  |
| nan -nan nan         | 1.322 -2.001 22.000  | 1.686 -0.374 5.000   | 1.983 -16.096 1.000  | 1.757 -0.711 3.000   | 1.612 -0.714 9.000  | 1.652 -3.022 8.000   |
| nan -nan nan         | 1.438 -2.646 19.000  | 1.676 -0.147 7.000   | 1.947 -4.315 1.000   | 1.695 -0.325 6.000   | 1.733 -0.403 5.000  | 1.344 -0.719 22.000  |
| nan -nan nan         | 1.765 -2.403 6.000   | 1.618 -2.200 12.000  | 1.273 -0.640 26.000  | 1.308 -1.949 25.000  | 1.415 -2.148 19.000 | 1.957 -1.331 2.000   |
| nan -nan nan         | 1.600 -1.186 13.000  | 1.889 -2.407 2.000   | 1.786 -1.907 7.000   | 1.656 -3.425 10.000  | 1.718 -3.304 9.000  | 1.471 -0.734 17.000  |
| nan -nan nan         | 1.974 -0.521 4.000   | 1.837 -0.896 15.000  | 1.767 -1.479 17.000  | 1.907 -1.474 10.000  | 1.996 -0.788 1.000  | 1.904 -0.508 11.000  |
| nan -nan nan         | 1.268 -1.802 18.000  | 1.184 -0.159 25.000  | 1.541 -1.306 2.000   | 1.342 -0.329 14.000  | 1.427 -0.334 7.000  | 1.187 -1.715 24.000  |
| nan -nan nan         | 1.296 -1.552 9.000   | 1.190 -0.182 25.000  | 1.256 -0.988 14.000  | 1.204 -0.233 23.000  | 1.233 -0.251 17.000 | 1.222 -0.749 19.000  |
| nan -nan nan         | 1.124 -0.879 23.000  | 1.213 -0.137 11.000  | 1.278 -0.812 6.000   | 1.300 -0.330 5.000   | 1.226 -0.332 9.000  | 1.149 -0.670 15.000  |
| 1.895 -0.228 1.000   | 1.228 -0.741 23.000  | 1.226 -0.314 24.000  | 1.359 -0.472 14.000  | 1.286 -0.291 21.000  | 1.290 -0.301 16.000 | 1.241 -1.139 22.000  |
| 1.380 -0.180 7.000   | 1.179 -0.979 22.000  | 1.236 -0.232 13.000  | 1.240 -1.004 12.000  | 1.219 -0.406 16.000  | 1.298 -0.481 11.000 | 1.114 -0.782 26.000  |
| 1.069 -0.133 27.000  | 1.238 -0.673 18.000  | 1.233 -0.178 19.000  | 1.493 -0.889 5.000   | 1.364 -0.436 8.000   | 1.301 -0.428 11.000 | 1.175 -0.373 25.000  |
| nan -nan nan         | 1.957 -4.108 2.000   | 1.610 -0.443 17.000  | 1.812 -1.693 11.000  | 1.874 -0.780 7.000   | 1.868 -0.761 8.000  | 1.757 -0.850 14.000  |
| nan -nan nan         | 1.911 -3.375 8.000   | 1.798 -0.453 20.000  | 1.856 -2.150 13.000  | 1.947 -0.638 4.000   | 1.980 -0.527 2.000  | 1.929 -0.277 6.000   |
| nan -nan nan         | 1.632 -0.602 12.000  | 1.658 -0.291 7.000   | 1.562 -0.975 18.000  | 1.557 -0.297 19.000  | 1.618 -0.271 14.000 | 1.474 -0.355 20.000  |
| nan -nan nan         | 1.761 -2.181 11.000  | 1.466 -1.166 20.000  | 1.958 -1.424 5.000   | 1.730 -1.786 13.000  | 1.993 -2.260 1.000  | 1.440 -2.145 21.000  |
| nan -nan nan         | 1.813 -4.364 5.000   | 1.651 -2.639 14.000  | 1.965 -2.832 2.000   | 1.766 -3.109 9.000   | 1.590 -1.757 18.000 | 1.536 -2.040 20.000  |
| nan -nan nan         | 1.620 -0.678 6.000   | 1.528 -1.270 15.000  | 1.744 -2.528 2.000   | 1.705 -1.804 3.000   | 1.662 -1.915 5.000  | 1.445 -0.264 18.000  |
| -0.104 0.376 13.337  | 0.333 0.711 9.887    | 0.355 0.730 11.286   | 0.123 0.588 16.329   | 0.177 0.627 15.095   | 0.222 0.654 14.009  | 0.385 0.755 8.435    |
| 1.448 -0.180 11.667  | 1.579 -2.373 12.271  | 1.521 -0.876 14.750  | 1.660 -3.439 9.125   | 1.595 -1.258 11.375  | 1.639 -1.278 9.042  | 1.477 -1.553 16.750  |
| -0.112 0.307 12.011  | 0.241 -0.001 10.297  | 0.239 0.312 11.922   | 0.115 -0.147 14.078  | 0.123 0.201 14.500   | 0.139 0.148 13.852  | 0.269 0.184 9.008    |
| -0.081 0.360 13.489  | 0.478 0.302 10.055   | 0.535 0.549 11.289   | 0.285 0.019 15.905   | 0.378 0.391 13.687   | 0.369 0.437 13.859  | 0.527 0.477 9.453    |
| -0.014 0.423 14.400  | 0.748 0.675 10.203   | 0.728 0.729 11.945   | 0.548 0.373 16.297   | 0.563 0.584 15.703   | 0.689 0.651 12.453  | 0.768 0.740 9.961    |
| -0.069 0.363 13.300  | 0.489 0.325 10.185   | 0.501 0.530 11.719   | 0.316 0.082 15.424   | 0.355 0.392 14.630   | 0.399 0.412 13.388  | 0.522 0.467 9.474    |

**Tabela B.10:** Tabela uspešnosti kombinirane funkcije na vseh metodah za ocenjevanje pomembnosti atributov in vseh naborih podatkov pri osnovni analizi (kvadrant (3, 2) od (3, 4)).

| <i>Lea + kNNeuCN</i> | <i>Lea + bagtreeN</i> | <i>Lea + bayesN</i>  | <i>LeaAPN</i>        | <i>LeaBrSN</i>       | <i>LeaISN</i>        | <i>LeaAUCN</i>       |
|----------------------|-----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| 0.486 1.131 4.000    | 0.272 1.044 11.000    | -0.890 0.788 24.000  | 0.295 1.135 10.000   | -1.459 -0.566 27.000 | 0.211 1.082 13.000   | -0.023 1.025 15.500  |
| 0.433 0.969 9.000    | 0.269 1.008 12.000    | -0.322 1.010 24.000  | 0.480 0.977 7.000    | -1.450 -0.726 26.000 | 0.623 1.032 3.000    | 0.419 0.964 10.500   |
| 0.771 1.259 5.000    | 0.436 1.186 11.000    | -0.252 1.021 25.000  | 0.777 1.257 3.000    | -1.359 -0.531 26.000 | 0.914 1.246 1.000    | 0.507 1.220 8.500    |
| 0.028 0.716 11.000   | -0.091 0.779 13.000   | -0.557 0.696 23.000  | 0.138 0.879 6.000    | -1.557 -0.752 25.000 | -1.637 -0.166 27.000 | 0.234 0.832 2.500    |
| 0.470 0.956 12.000   | 0.571 1.027 10.000    | 0.011 0.953 18.000   | 0.772 1.037 5.000    | -1.237 -0.751 27.000 | 0.940 1.038 1.000    | 0.818 1.031 2.500    |
| 0.667 1.010 13.000   | 0.738 1.064 10.000    | -0.028 0.999 24.000  | 0.857 1.078 4.000    | -1.215 -0.720 27.000 | 0.884 1.082 1.000    | 0.871 1.072 2.500    |
| -0.645 0.440 24.000  | 0.252 0.906 8.000     | -0.971 0.332 25.000  | 0.652 0.919 3.000    | -1.280 -1.000 27.000 | -0.373 0.304 23.000  | 0.480 0.875 5.500    |
| 0.326 0.793 14.000   | 0.540 0.988 11.000    | -0.262 0.836 24.000  | 0.899 1.004 3.000    | -1.223 -0.820 26.000 | 0.716 0.992 7.000    | 0.979 1.009 1.500    |
| 0.314 0.924 14.000   | 0.665 1.010 9.000     | -0.071 0.981 23.000  | 0.815 1.019 4.000    | -1.109 -0.652 27.000 | 0.893 1.021 1.000    | 0.826 1.021 2.500    |
| -0.458 0.586 17.000  | -0.418 0.629 16.000   | -0.364 0.700 12.000  | -0.468 0.559 18.500  | -1.544 -0.538 27.000 | -0.364 0.612 13.000  | -0.628 0.394 24.500  |
| 0.019 0.822 13.000   | 0.274 0.943 12.000    | -0.138 0.870 19.000  | 0.608 0.961 5.000    | -1.084 -0.536 27.000 | 0.725 0.974 1.000    | 0.622 0.959 3.500    |
| 0.201 0.921 13.000   | 0.491 0.997 11.000    | -0.046 0.980 23.000  | 0.677 0.999 6.000    | -1.062 -0.550 26.000 | 0.813 1.001 2.000    | 0.698 1.000 4.500    |
| -0.397 0.777 15.000  | 0.195 1.261 2.000     | -0.933 0.277 20.000  | 0.078 0.815 4.000    | -1.860 -0.972 23.000 | -0.186 0.859 11.000  | 0.083 0.588 3.000    |
| -0.138 0.634 6.000   | -0.247 1.078 9.000    | -0.670 0.377 20.000  | -0.547 0.913 16.000  | -1.886 -0.760 24.000 | -0.623 0.934 18.000  | -0.512 0.603 15.000  |
| 0.569 1.370 3.000    | 0.287 1.228 11.000    | -0.209 1.181 22.000  | 0.296 1.244 10.000   | -1.399 -0.456 23.000 | 0.327 1.260 9.000    | 0.281 1.239 12.000   |
| -0.373 0.631 16.000  | -0.007 0.895 1.000    | -1.431 -0.218 23.000 | -0.213 0.513 9.000   | -1.407 -0.846 22.000 | -0.315 0.561 13.000  | -0.097 0.226 2.000   |
| -0.008 0.751 4.000   | 0.052 0.792 2.000     | -0.303 0.420 12.000  | -0.378 0.597 14.000  | -1.610 -0.609 22.000 | -0.161 0.801 8.000   | -0.308 0.600 13.000  |
| 0.274 1.007 10.000   | 0.309 1.085 5.000     | -0.260 0.947 21.000  | 0.273 1.084 11.000   | -1.266 -0.425 22.000 | 0.287 1.078 7.000    | 0.248 1.102 15.000   |
| -0.459 0.425 3.000   | -1.122 0.118 13.000   | -1.153 -0.112 14.000 | -1.450 -0.673 16.000 | -0.830 0.492 11.000  | -1.535 -0.604 17.000 | -1.606 -0.379 20.000 |
| -0.252 0.516 15.000  | -0.195 0.740 13.000   | -0.686 -0.030 22.000 | 0.083 0.943 4.000    | -1.508 -0.510 23.000 | 0.066 0.962 6.000    | 0.026 0.916 7.000    |
| 0.554 0.834 1.000    | 0.334 1.025 7.000     | -0.186 0.881 21.000  | 0.185 1.008 10.000   | -1.113 -0.273 23.000 | 0.180 1.000 11.000   | 0.197 1.006 9.000    |
| -0.678 0.281 3.000   | -1.153 -0.029 14.000  | -1.235 -0.467 17.000 | -1.447 -0.817 20.000 | -1.032 -0.408 8.000  | -1.941 -0.905 23.000 | -1.984 -0.656 24.000 |
| -0.355 0.325 18.000  | -0.244 0.760 14.000   | -0.943 -0.080 21.000 | -0.034 0.902 5.000   | -1.251 -0.244 24.000 | 0.024 0.932 1.000    | -0.129 0.860 10.000  |
| 0.050 0.577 16.000   | 0.500 1.005 2.000     | -0.045 0.792 17.000  | 0.338 1.005 8.000    | -1.065 -0.366 22.000 | 0.344 1.004 7.000    | 0.313 1.003 12.000   |
| -0.671 0.810 15.000  | -0.359 0.996 8.000    | -1.802 -0.235 27.000 | -0.260 1.066 4.000   | -1.406 0.061 26.000  | -0.413 1.037 10.000  | -0.536 0.978 12.500  |
| 0.175 1.185 12.000   | 0.281 1.178 9.000     | -0.736 0.044 25.000  | 0.456 1.277 5.000    | -1.626 -0.900 27.000 | 0.009 1.167 17.000   | 0.565 1.302 3.500    |
| 0.217 1.250 7.000    | 0.186 1.252 9.000     | -1.520 -0.329 27.000 | 0.291 1.264 5.000    | -1.419 -0.305 26.000 | 0.158 1.192 12.000   | 0.435 1.324 1.500    |
| -0.728 0.360 10.000  | -1.038 0.108 15.000   | -1.095 -0.194 16.000 | -1.317 0.448 20.000  | -1.804 -0.165 26.000 | -1.656 0.236 25.000  | -1.131 0.543 17.500  |
| -0.001 0.725 14.000  | 0.185 0.922 5.000     | -0.301 0.906 19.000  | 0.108 0.916 9.000    | -1.659 -1.021 27.000 | -0.683 0.933 22.000  | 0.008 0.850 12.500   |
| 0.202 0.991 13.000   | 0.276 1.057 10.000    | -0.225 0.770 25.000  | 0.323 1.016 4.000    | -1.325 -0.708 27.000 | 0.175 1.015 15.000   | 0.321 1.009 5.500    |
| -0.242 0.245 17.000  | -0.704 0.196 24.000   | -0.365 0.728 21.000  | -0.137 0.914 4.500   | -1.451 -0.381 27.000 | -0.173 0.829 9.000   | -0.164 0.915 7.500   |
| -0.273 0.549 13.000  | -0.027 0.693 3.000    | -0.947 0.243 25.000  | -0.168 0.622 6.000   | -1.742 -1.031 27.000 | -0.196 0.926 8.000   | -0.233 0.546 11.500  |
| 0.212 0.900 17.000   | 0.527 0.940 11.000    | -0.183 0.875 20.000  | 0.663 0.978 4.000    | -1.223 -0.720 26.000 | 0.418 0.952 14.000   | 0.667 0.979 2.500    |
| -0.966 -0.165 13.000 | -0.988 -0.709 15.000  | -1.082 -0.553 20.000 | -0.811 -0.705 9.500  | -1.033 -0.934 16.000 | -1.150 -0.907 25.000 | -0.673 -0.592 4.500  |
| -0.040 0.269 2.000   | -0.259 0.327 3.000    | -0.871 -0.199 21.000 | -0.862 -0.053 20.000 | -1.751 -0.835 27.000 | -0.886 -0.527 24.000 | -0.743 0.138 14.500  |
| -0.023 0.711 17.000  | 0.308 0.836 10.000    | -0.749 0.292 25.000  | 0.350 0.926 4.000    | -1.117 -0.473 26.000 | 0.294 0.831 11.000   | 0.337 0.913 6.500    |
| 1.770 -2.226 9.000   | 1.674 -2.746 13.000   | 1.929 -7.394 3.000   | 1.766 -5.981 10.000  | 1.848 -3.905 6.000   | 1.749 -5.012 12.000  | 1.487 -3.108 20.500  |
| 1.637 -1.923 13.000  | 1.663 -4.552 11.000   | 1.967 -2.213 3.000   | 1.896 -5.105 5.000   | 1.602 -3.074 14.000  | 1.539 -3.765 17.000  | 1.984 -3.389 1.500   |
| 1.897 -3.153 3.000   | 1.735 -2.552 10.000   | 1.949 -3.469 1.000   | 1.745 -2.312 6.000   | 1.458 -1.153 19.000  | 1.697 -2.977 11.000  | 1.422 -1.814 20.500  |
| 1.975 -7.833 2.000   | 1.302 -2.879 21.000   | 1.488 -3.171 17.000  | 1.798 -2.998 7.500   | 1.995 -2.554 1.000   | 1.524 -2.746 15.000  | 1.627 -2.683 12.500  |
| 1.687 -2.564 6.000   | 1.288 -2.002 19.000   | 1.282 -7.617 20.000  | 1.457 -2.769 14.000  | 1.788 -2.967 4.000   | 1.307 -2.723 18.000  | 1.322 -2.157 16.500  |
| 1.542 -6.652 7.000   | 1.364 -1.992 10.000   | 1.281 -2.574 16.000  | 1.278 -1.763 17.000  | 1.287 -1.619 12.000  | 1.278 -1.802 18.000  | 1.188 -1.440 20.500  |
| 1.607 -6.516 14.000  | 1.963 -5.903 2.000    | 1.634 -5.192 13.000  | 1.998 -6.750 1.000   | 1.931 -5.082 5.000   | 1.928 -6.160 6.000   | 1.963 -6.461 3.000   |
| 1.910 -3.615 2.000   | 1.707 -3.998 4.000    | 1.680 -6.362 6.000   | 1.344 -2.310 20.000  | 1.420 -2.345 15.000  | 1.294 -2.065 23.000  | 1.405 -1.962 16.000  |
| 1.780 -12.859 4.000  | 1.519 -2.419 12.000   | 1.173 -1.274 23.000  | 1.457 -3.108 16.000  | 1.675 -4.725 8.000   | 1.477 -3.502 15.000  | 1.791 -9.995 2.000   |
| 1.460 -1.629 17.000  | 1.599 -1.956 13.000   | 1.564 -1.694 14.000  | 1.993 -2.926 1.000   | 1.461 -2.970 16.000  | 1.518 -1.905 15.000  | 1.923 -2.579 3.500   |
| 1.857 -1.229 4.000   | 1.424 -0.775 20.000   | 1.295 -0.553 21.000  | 1.517 -1.279 16.000  | 1.790 -3.248 6.000   | 1.655 -1.238 11.000  | 1.471 -1.418 18.500  |
| 1.947 -0.427 6.000   | 1.910 -0.486 9.000    | 1.245 -0.252 22.000  | 1.950 -0.431 5.000   | 1.876 -0.553 13.000  | 1.769 -0.389 16.000  | 1.991 -0.443 2.500   |
| 1.489 -2.297 3.000   | 1.278 -1.767 17.000   | 1.787 -9.058 1.000   | 1.266 -1.312 19.000  | 1.486 -1.711 4.000   | 1.207 -1.281 23.000  | 1.372 -1.281 9.500   |
| 1.440 -2.066 6.000   | 1.273 -2.605 13.000   | 1.635 -1.729 1.000   | 1.473 -1.589 5.000   | 1.216 -0.871 21.000  | 1.516 -1.828 4.000   | 1.622 -1.657 2.500   |
| 1.914 -5.562 1.000   | 1.163 -0.559 14.000   | 1.224 -1.263 10.000  | 1.122 -0.790 24.000  | 1.148 -0.649 16.000  | 1.119 -0.819 25.000  | 1.140 -0.643 17.500  |
| 1.367 -1.298 13.000  | 1.195 -0.678 26.000   | 1.414 -1.400 10.000  | 1.249 -0.747 21.000  | 1.540 -0.906 7.000   | 1.215 -0.730 25.000  | 1.378 -0.799 11.500  |
| 1.333 -1.045 9.000   | 1.175 -1.014 23.000   | 1.327 -1.438 10.000  | 1.171 -0.912 24.000  | 1.230 -1.106 15.000  | 1.156 -0.943 25.000  | 1.202 -1.097 17.500  |
| 1.334 -0.777 9.000   | 1.225 -0.640 20.000   | 1.312 -0.805 10.000  | 1.180 -0.491 24.000  | 1.257 -0.705 15.000  | 1.182 -0.532 23.000  | 1.271 -0.723 13.500  |
| 1.901 -1.752 4.000   | 1.798 -2.042 13.000   | 1.861 -2.698 9.000   | 1.840 -3.262 10.000  | 1.603 -3.339 19.000  | 1.670 -2.589 16.000  | 1.729 -1.067 15.000  |
| 1.853 -2.052 15.000  | 1.921 -3.505 7.000    | 1.931 -1.664 5.000   | 1.831 -2.123 17.000  | 1.823 -3.355 18.000  | 1.854 -2.400 14.000  | 1.813 -1.971 19.000  |
| 1.586 -0.479 17.000  | 1.636 -0.631 9.000    | 1.634 -0.590 10.000  | 1.468 -0.260 21.000  | 1.743 -0.567 5.000   | 1.592 -0.403 16.000  | 1.681 -0.597 6.000   |
| 1.557 -4.352 17.000  | 1.965 -2.997 4.000    | 1.732 -2.113 12.000  | 1.821 -2.431 9.000   | 1.932 -2.268 6.000   | 1.807 -1.776 10.000  | 1.574 -2.750 15.500  |
| 1.976 -1.914 1.000   | 1.876 -2.955 3.000    | 1.826 -3.513 4.000   | 1.775 -4.354 7.000   | 1.775 -3.487 8.000   | 1.474 -2.703 21.000  | 1.601 -4.823 16.500  |
| 1.491 -0.846 17.000  | 1.408 -0.925 22.000   | 1.417 -2.006 20.000  | 1.618 -0.664 7.000   | 1.614 -0.658 8.000   | 1.759 -0.961 1.000   | 1.573 -0.656 12.500  |
| 0.363 0.758 11.423   | 0.342 0.743 9.970     | -0.356 0.180 18.024  | 0.358 0.712 9.214    | -1.345 -0.942 24.030 | 0.319 0.697 9.970    | 0.307 0.683 10.354   |
| 1.680 -3.128 8.292   | 1.544 -2.191 13.125   | 1.566 -2.918 10.875  | 1.584 -2.361 12.771  | 1.604 -2.242 10.875  | 1.512 -2.135 15.833  | 1.564 -2.313 12.250  |
| 0.260 0.046 11.953   | 0.234 0.105 10.547    | -0.238 -0.458 16.594 | 0.281 -0.002 9.367   | -0.984 -1.166 21.031 | 0.142 -0.004 12.398  | 0.210 0.069 10.742   |
| 0.559 0.427 10.641   | 0.502 0.340 9.781     | -0.119 -0.265 16.977 | 0.494 0.309 9.648    | -0.989 -1.129 22.766 | 0.502 0.371 9.734    | 0.443 0.290 11.031   |
| 0.764 0.346 10.500   | 0.742 0.684 10.766    | 0.009 0.101 17.820   | 0.759 0.676 9.961    | -0.955 -1.018 23.359 | 0.760 0.661 9.977    | 0.740 0.566 10.000   |
| 0.528 0.273 11.031   | 0.492 0.376 10.365    | -0.116 -0.207 17.130 | 0.512 0.328 9.659    | -0.976 -1.104 22.385 | 0.468 0.34           |                      |

| LeaAUC2N |         |        | LeaSeN |        |        | LeaSpN |        |        | LeaRMSEN |        |        | LeaSaN |        |        | LeaSMN |        |        | LeaS/sN |        |        |
|----------|---------|--------|--------|--------|--------|--------|--------|--------|----------|--------|--------|--------|--------|--------|--------|--------|--------|---------|--------|--------|
| -0.023   | 1.025   | 15.500 | -0.110 | 0.861  | 17.000 | 0.744  | 1.224  | 2.000  | -1.351   | -0.574 | 26.000 | 0.345  | 1.122  | 7.000  | -1.290 | 0.000  | 25.000 | 0.316   | 1.083  | 9.000  |
| 0.419    | 0.964   | 10.500 | 0.439  | 1.052  | 8.000  | 0.235  | 1.160  | 13.000 | -1.432   | -0.652 | 25.000 | 0.134  | 0.914  | 16.000 | 0.000  | 0.000  | 18.000 | 0.113   | 0.935  | 17.000 |
| 0.507    | 1.220   | 8.500  | 0.337  | 1.163  | 15.000 | 0.500  | 1.104  | 10.000 | -1.392   | -0.519 | 27.000 | 0.274  | 1.147  | 17.000 | 0.000  | 0.000  | 19.000 | 0.237   | 1.159  | 18.000 |
| 0.234    | 0.832   | 2.500  | -0.341 | 0.667  | 18.000 | -0.020 | 0.764  | 12.000 | -1.622   | -0.827 | 26.000 | 0.048  | 0.843  | 10.000 | -0.377 | 0.000  | 22.000 | 0.056   | 0.842  | 9.000  |
| 0.818    | 1.031   | 2.500  | 0.757  | 1.002  | 6.000  | 0.564  | 1.053  | 11.000 | -1.224   | -0.859 | 26.000 | 0.667  | 1.032  | 8.000  | -1.053 | 0.000  | 25.000 | 0.662   | 1.023  | 9.000  |
| 0.871    | 1.072   | 2.500  | 0.782  | 1.043  | 8.000  | 0.773  | 1.052  | 9.000  | -1.209   | -0.881 | 26.000 | 0.734  | 1.062  | 11.000 | 0.000  | 0.000  | 23.000 | 0.724   | 1.065  | 12.000 |
| 0.480    | 0.875   | 5.500  | -0.093 | 0.546  | 12.000 | 0.199  | 0.790  | 9.000  | -1.258   | -1.016 | 26.000 | 0.670  | 0.912  | 2.000  | 0.000  | 0.000  | 11.000 | 0.671   | 0.905  | 1.000  |
| 0.979    | 1.009   | 1.500  | 0.531  | 0.976  | 12.000 | 0.584  | 0.994  | 9.000  | -1.200   | -0.973 | 25.000 | 0.777  | 1.004  | 6.000  | -1.379 | 0.000  | 27.000 | 0.780   | 1.005  | 5.000  |
| 0.826    | 1.021   | 2.500  | 0.595  | 1.019  | 10.000 | 0.568  | 1.020  | 11.000 | -1.108   | -0.821 | 26.000 | 0.731  | 1.018  | 7.000  | 0.000  | 0.000  | 18.000 | 0.731   | 1.020  | 8.000  |
| -0.628   | 0.394   | 24.500 | -0.391 | 0.644  | 14.000 | -0.474 | 0.698  | 20.000 | -1.449   | -0.429 | 26.000 | -0.509 | 0.511  | 23.000 | 0.000  | 0.000  | 2.000  | -0.507  | 0.511  | 22.000 |
| 0.622    | 0.959   | 3.500  | 0.715  | 0.964  | 2.000  | 0.442  | 0.935  | 10.000 | -1.079   | -0.663 | 26.000 | 0.539  | 0.955  | 7.000  | 0.000  | 0.000  | 15.000 | 0.538   | 0.954  | 8.000  |
| 0.698    | 1.000   | 4.500  | 0.823  | 0.991  | 1.000  | 0.545  | 1.009  | 10.000 | -1.062   | -0.680 | 27.000 | 0.616  | 0.998  | 9.000  | 0.000  | 0.000  | 18.000 | 0.617   | 0.999  | 8.000  |
| -0.079   | 0.742   | 8.000  | nan    | nan    | nan    | nan    | nan    | nan    | -1.872   | -0.616 | 24.000 | -0.052 | 1.053  | 6.000  | -1.176 | 0.295  | 21.000 | -0.146  | 0.823  | 10.000 |
| -0.463   | 0.840   | 12.000 | nan    | nan    | nan    | nan    | nan    | nan    | -1.544   | -0.280 | 23.000 | -0.473 | 0.672  | 13.000 | -1.249 | 0.313  | 22.000 | -0.401  | 0.657  | 11.000 |
| 0.276    | 1.233   | 13.000 | nan    | nan    | nan    | nan    | nan    | nan    | -1.408   | -0.495 | 24.000 | 0.362  | 1.274  | 7.000  | 0.588  | 0.882  | 2.000  | 0.426   | 1.300  | 5.000  |
| -0.149   | 0.149   | 4.000  | nan    | nan    | nan    | nan    | nan    | nan    | -1.472   | -0.050 | 24.000 | -0.159 | 0.524  | 5.000  | -0.370 | 0.000  | 15.000 | -0.149  | 0.515  | 3.000  |
| -0.233   | 0.656   | 11.000 | nan    | nan    | nan    | nan    | nan    | nan    | -1.861   | -0.946 | 24.000 | -0.180 | 0.654  | 9.000  | -1.860 | -0.465 | 23.000 | -0.232  | 0.628  | 10.000 |
| 0.261    | 1.088   | 14.000 | nan    | nan    | nan    | nan    | nan    | nan    | -1.268   | -0.509 | 23.000 | 0.270  | 1.103  | 12.000 | -2.000 | 0.000  | 24.000 | 0.268   | 1.101  | 13.000 |
| -1.690   | -0.350  | 23.000 | nan    | nan    | nan    | nan    | nan    | nan    | -1.085   | 0.361  | 12.000 | -1.614 | -0.692 | 22.000 | -1.538 | -0.307 | 18.000 | -1.611  | -0.693 | 21.000 |
| -0.022   | 0.922   | 8.000  | nan    | nan    | nan    | nan    | nan    | nan    | -1.630   | -0.213 | 24.000 | -0.109 | 0.936  | 11.000 | -0.404 | -0.202 | 20.000 | -0.111  | 0.936  | 12.000 |
| 0.180    | 1.006   | 12.000 | nan    | nan    | nan    | nan    | nan    | nan    | -1.188   | -0.482 | 24.000 | 0.170  | 1.011  | 15.000 | -0.692 | 0.000  | 22.000 | 0.172   | 1.011  | 13.000 |
| -1.864   | -0.693  | 22.000 | nan    | nan    | nan    | nan    | nan    | nan    | -1.113   | -1.005 | 12.000 | -0.942 | -0.575 | 5.000  | -1.105 | 0.000  | 11.000 | -0.940  | -0.575 | 4.000  |
| -0.087   | 0.907   | 9.000  | nan    | nan    | nan    | nan    | nan    | nan    | -1.217   | -0.276 | 23.000 | -0.070 | 0.889  | 7.500  | -1.009 | 0.000  | 22.000 | -0.070  | 0.889  | 7.500  |
| 0.315    | 1.004   | 11.000 | nan    | nan    | nan    | nan    | nan    | nan    | -1.089   | -0.359 | 23.000 | 0.346  | 1.007  | 5.500  | -1.152 | 0.000  | 24.000 | 0.346   | 1.007  | 5.500  |
| -0.536   | 0.978   | 12.500 | -1.289 | 0.642  | 24.000 | -0.542 | 0.991  | 14.000 | -1.377   | -0.003 | 25.000 | -0.393 | 0.981  | 9.000  | -1.212 | 0.000  | 23.000 | -0.492  | 0.931  | 11.000 |
| 0.565    | 1.302   | 3.500  | 0.087  | 0.999  | 15.000 | 0.159  | 0.951  | 13.000 | -1.607   | -0.726 | 26.000 | 0.328  | 1.209  | 8.000  | 0.667  | 0.834  | 1.000  | 0.265   | 1.166  | 10.000 |
| 0.435    | 1.324   | 1.500  | -0.166 | 1.138  | 23.000 | 0.168  | 1.152  | 11.000 | -1.407   | -0.389 | 25.000 | 0.193  | 1.211  | 8.000  | -0.065 | 0.260  | 16.000 | 0.079   | 1.205  | 14.000 |
| -1.131   | 0.543   | 17.500 | -0.765 | 0.545  | 11.000 | -0.934 | 0.667  | 13.000 | -1.993   | -0.136 | 27.000 | -1.399 | 0.458  | 22.000 | -1.395 | -0.465 | 21.000 | -1.486  | 0.427  | 23.000 |
| 0.008    | 0.850   | 12.500 | -0.783 | 0.383  | 24.000 | -0.342 | 0.641  | 20.000 | -1.531   | -0.759 | 26.000 | 0.138  | 0.910  | 7.000  | -1.304 | 0.218  | 25.000 | 0.087   | 0.896  | 10.000 |
| 0.321    | 1.009   | 5.500  | 0.444  | 1.071  | 1.000  | 0.105  | 1.046  | 16.000 | -1.321   | -0.645 | 26.000 | 0.336  | 1.012  | 3.000  | 0.000  | 0.000  | 18.000 | 0.305   | 1.004  | 7.000  |
| -0.164   | 0.915   | 7.500  | -0.394 | 0.667  | 22.000 | -0.506 | 0.780  | 23.000 | -1.416   | -0.358 | 26.000 | -0.178 | 0.880  | 11.000 | 0.000  | 0.000  | 1.000  | -0.174  | 0.881  | 10.000 |
| -0.233   | 0.546   | 11.500 | -0.048 | 0.683  | 4.000  | -0.711 | 0.056  | 24.000 | -1.608   | -0.840 | 26.000 | -0.228 | 0.540  | 9.000  | -0.312 | 0.000  | 14.000 | -0.232  | 0.538  | 10.000 |
| 0.667    | 0.979   | 2.500  | 0.682  | 0.950  | 1.000  | 0.562  | 0.896  | 10.000 | -1.226   | -0.834 | 27.000 | 0.576  | 0.968  | 8.000  | -0.179 | 0.000  | 19.000 | 0.590   | 0.974  | 7.000  |
| -0.673   | -0.592  | 4.500  | -1.074 | -0.948 | 19.000 | -0.895 | -0.742 | 11.000 | -1.041   | -0.937 | 17.000 | -0.780 | -0.676 | 7.000  | -0.421 | 0.000  | 1.000  | -0.783  | -0.678 | 8.000  |
| -0.743   | 0.138   | 14.500 | -1.196 | -0.492 | 25.000 | -0.553 | 0.355  | 9.000  | -1.680   | -0.809 | 26.000 | -0.881 | -0.010 | 23.000 | -0.396 | 0.000  | 6.000  | -0.877  | -0.015 | 22.000 |
| 0.337    | 0.913   | 6.500  | 0.154  | 0.906  | 15.000 | 0.241  | 0.834  | 13.000 | -1.123   | -0.518 | 27.000 | 0.316  | 0.921  | 8.500  | -0.104 | 0.000  | 18.000 | 0.316   | 0.921  | 8.500  |
| 1.487    | -3.108  | 20.500 | 1.885  | -4.072 | 4.000  | 1.981  | -3.080 | 1.000  | 1.673    | -5.461 | 14.500 | 1.673  | -5.461 | 14.500 | 1.500  | -1.665 | 19.000 | 1.660   | -5.235 | 16.000 |
| 1.984    | -3.389  | 1.500  | 1.641  | -3.352 | 12.000 | 1.527  | -2.427 | 18.000 | 1.858    | -4.773 | 6.500  | 1.858  | -4.773 | 6.500  | 1.441  | -1.138 | 22.000 | 1.793   | -4.153 | 8.000  |
| 1.422    | -1.814  | 20.500 | 1.681  | -1.727 | 12.000 | 1.624  | -3.613 | 16.000 | 1.653    | -1.674 | 13.500 | 1.653  | -1.674 | 13.500 | 1.351  | -0.946 | 22.000 | 1.596   | -1.625 | 18.000 |
| 1.627    | -2.683  | 12.500 | 1.400  | -2.621 | 19.000 | 1.831  | -4.627 | 6.000  | 1.916    | -3.122 | 4.500  | 1.916  | -3.122 | 4.500  | 1.263  | -0.459 | 22.000 | 1.924   | -3.163 | 3.000  |
| 1.322    | -2.157  | 16.500 | 1.247  | -1.407 | 21.000 | 1.866  | -5.369 | 2.000  | 1.517    | -2.792 | 11.500 | 1.517  | -2.792 | 11.500 | 1.561  | -1.928 | 8.000  | 1.506   | -2.800 | 13.000 |
| 1.188    | -1.440  | 20.500 | 1.149  | -1.567 | 22.000 | 1.961  | -7.296 | 2.000  | 1.283    | -1.763 | 13.500 | 1.283  | -1.763 | 13.500 | 1.488  | -3.366 | 9.000  | 1.309   | -1.744 | 11.000 |
| 1.952    | -5.487  | 4.000  | nan    | -nan   | nan    | nan    | -nan   | nan    | 1.736    | -2.930 | 11.000 | 1.893  | -6.354 | 8.000  | 1.383  | -1.353 | 24.000 | 1.896   | -6.368 | 7.000  |
| 1.390    | -2.058  | 17.000 | nan    | -nan   | nan    | nan    | -nan   | nan    | 1.423    | -2.033 | 14.000 | 1.336  | -2.005 | 21.000 | 1.037  | -0.074 | 24.000 | 1.345   | -1.990 | 19.000 |
| 1.658    | -11.456 | 9.000  | nan    | -nan   | nan    | nan    | -nan   | nan    | 1.784    | -3.429 | 3.000  | 1.437  | -2.616 | 20.000 | 0.000  | -0.000 | 24.000 | 1.432   | -2.529 | 21.000 |
| 1.923    | -2.579  | 3.500  | 1.808  | -3.524 | 5.000  | 1.645  | -1.442 | 10.000 | 1.662    | -2.086 | 8.500  | 1.662  | -2.086 | 8.500  | 1.385  | -1.902 | 23.000 | 1.715   | -1.955 | 7.000  |
| 1.471    | -1.418  | 18.500 | 1.814  | -4.750 | 5.000  | 1.945  | -0.980 | 1.000  | 1.590    | -1.167 | 14.500 | 1.590  | -1.167 | 14.500 | 1.886  | -1.152 | 3.000  | 1.634   | -1.223 | 12.000 |
| 1.991    | -0.443  | 2.500  | 1.873  | -0.988 | 14.000 | 1.741  | -0.577 | 18.000 | 1.946    | -0.561 | 7.500  | 1.946  | -0.561 | 7.500  | 1.592  | -0.646 | 21.000 | 1.684   | -0.408 | 19.000 |
| 1.372    | -1.281  | 9.500  | 1.469  | -2.375 | 5.000  | 1.446  | -1.535 | 6.000  | 1.359    | -1.910 | 12.500 | 1.359  | -1.910 | 12.500 | 1.080  | -0.136 | 26.000 | 1.360   | -1.916 | 11.000 |
| 1.622    | -1.657  | 2.500  | 1.193  | -1.220 | 24.000 | 1.429  | -1.878 | 7.000  | 1.288    | -1.497 | 10.500 | 1.288  | -1.497 | 10.500 | 1.106  | -0.163 | 26.000 | 1.287   | -1.501 | 12.000 |
| 1.140    | -0.643  | 17.500 |        |        |        |        |        |        |          |        |        |        |        |        |        |        |        |         |        |        |

---

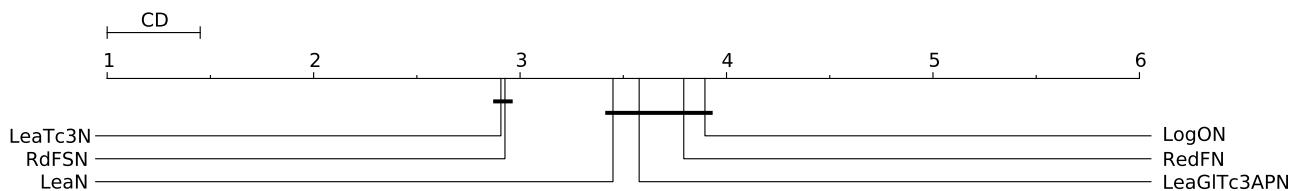
---

## Dodatek C

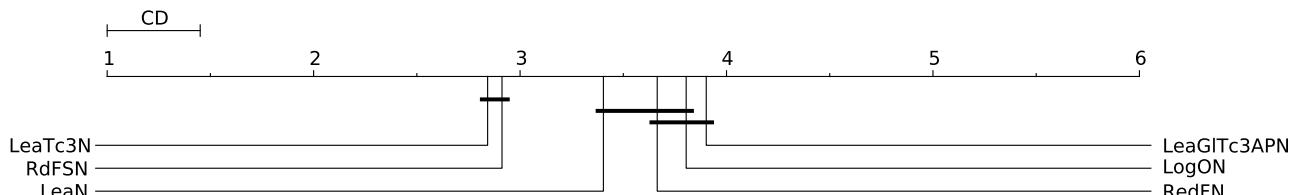
---

### Ostali grafi povprečnih rangov podrobne analize

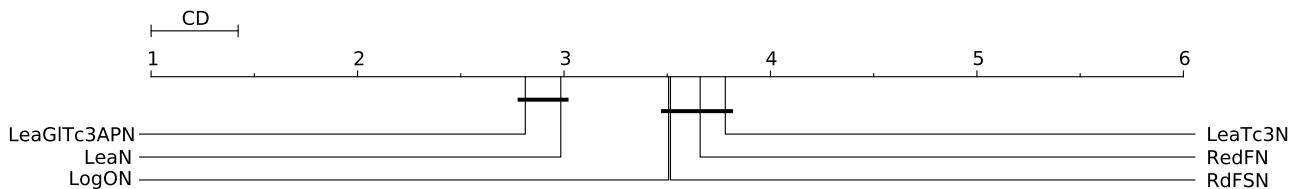
Sledijo ostali grafi povprečnih rangov s kritično razliko po statističnem *Nemenyi testu* z  $\alpha = 0,05$ , ki se jih ni predstavilo v poglavju 4.3. Kritične razlike uporabljenе v sledečih grafih pa je možno najti v tabeli 4.5.



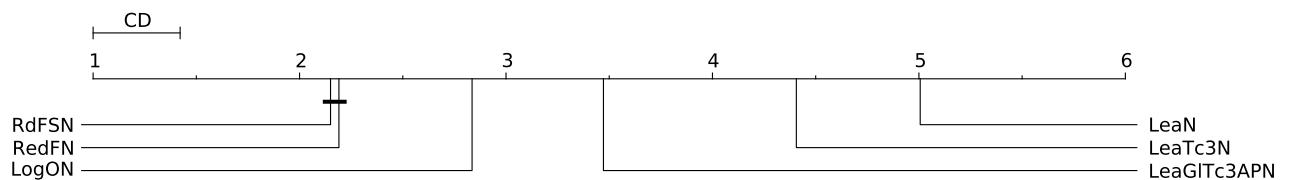
**Slika C.1:** Graf kritične razlike za Nemenyi test iz povprečnih rangov funkcije  $s(W)$  za vrednotenje uspešnosti pri podrobni analizi (CD iz avg-all<sup>2</sup>).



**Slika C.2:** Graf kritične razlike za Nemenyi test iz povprečnih rangov funkcije  $u(W)$  za vrednotenje uspešnosti pri podrobni analizi (CD iz avg-all<sup>2</sup>).



**Slika C.3:** Graf kritične razlike za Nemenyi test iz povprečnih rangov funkcije  $t(W)$  za vrednotenje uspešnosti pri podrobni analizi ( $CD$  iz avg-all<sup>1</sup>).



**Slika C.4:** Graf kritične razlike za Nemenyi test iz povprečnih rangov funkcije  $v(W)$  za vrednotenje uspešnosti pri podrobni analizi ( $CD$  iz avg-all<sup>1</sup>).

---

---

## Dodatek D

---

### Celotna združena tabele podrobne analize

Na naslednjih 5 straneh sledi razrezana združena tabela osnovne analize pri kateri se je primerjalo vseh 6 izbranih metod večkrat na raznolikih naborih podatkov. Za ocenjevanje uspešnosti pa se je uporabila kombinirana funkcija.

| Dataset           | <i>RedFN</i>        | <i>RdFSN</i>        | <i>LogON</i>        | <i>LeaN</i>         | <i>LeaGITc3APN</i>  | <i>LeaTc3N</i>      |
|-------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|
| only-a0 10-015    | 1.031 1.031 6.000   | 1.042 1.042 4.000   | 1.087 1.087 1.000   | 1.062 1.062 3.000   | 1.038 1.038 5.000   | 1.079 1.079 2.000   |
| only-a0 10-030    | 1.089 1.089 2.000   | 1.078 1.078 3.000   | 1.111 1.111 1.000   | 1.068 1.068 5.000   | 1.059 1.059 6.000   | 1.070 1.070 4.000   |
| only-a0 10-060    | 1.094 1.094 2.000   | 1.087 1.087 3.000   | 1.111 1.111 1.000   | 1.032 1.032 6.000   | 1.060 1.060 4.000   | 1.037 1.037 5.000   |
| only-a0 10-120    | 1.104 1.104 2.000   | 1.099 1.099 3.000   | 1.111 1.111 1.000   | 1.037 1.037 6.000   | 1.066 1.066 4.000   | 1.041 1.041 5.000   |
| only-a0 10-180    | 1.102 1.102 2.000   | 1.101 1.101 3.000   | 1.111 1.111 1.000   | 1.037 1.037 4.000   | 0.948 0.948 6.000   | 1.030 1.030 5.000   |
| only-a0 20-015    | 0.958 0.958 5.000   | 0.941 0.941 6.000   | 1.010 1.010 1.000   | 0.995 0.995 3.000   | 0.968 0.968 4.000   | 1.007 1.007 2.000   |
| only-a0 20-030    | 1.011 1.011 4.000   | 0.969 0.969 6.000   | 1.053 1.053 1.000   | 1.020 1.020 3.000   | 0.976 0.976 5.000   | 1.028 1.028 2.000   |
| only-a0 20-060    | 1.038 1.038 2.000   | 1.023 1.023 4.000   | 1.053 1.053 1.000   | 1.019 1.019 5.000   | 0.948 0.948 6.000   | 1.026 1.026 3.000   |
| only-a0 20-120    | 1.044 1.044 2.000   | 1.010 1.010 5.000   | 1.053 1.053 1.000   | 1.016 1.016 4.000   | 0.974 0.974 6.000   | 1.022 1.022 3.000   |
| only-a0 20-180    | 1.045 1.045 2.000   | 1.041 1.041 3.000   | 1.053 1.053 1.000   | 1.035 1.035 4.500   | 0.965 0.965 6.000   | 1.035 1.035 4.500   |
| only-a0 40-015    | 0.941 0.941 4.000   | 0.861 0.861 5.000   | 0.818 0.818 6.000   | 0.998 0.998 1.000   | 0.942 0.942 3.000   | 0.989 0.989 2.000   |
| only-a0 40-030    | 0.992 0.992 5.000   | 0.956 0.956 6.000   | 1.026 1.026 1.000   | 1.002 1.002 3.000   | 0.996 0.996 4.000   | 1.006 1.006 2.000   |
| only-a0 40-060    | 1.007 1.007 4.000   | 0.982 0.982 6.000   | 1.026 1.026 1.000   | 1.009 1.009 3.000   | 0.986 0.986 5.000   | 1.010 1.010 2.000   |
| only-a0 40-120    | 1.012 1.012 2.000   | 1.002 1.002 5.000   | 1.026 1.026 1.000   | 1.007 1.007 3.500   | 0.991 0.991 6.000   | 1.007 1.007 3.500   |
| only-a0 40-180    | 1.016 1.016 2.000   | 0.996 0.996 5.500   | 1.026 1.026 1.000   | 1.009 1.009 3.500   | 0.996 0.996 5.500   | 1.009 1.009 3.500   |
| only-a0 80-015    | 0.948 0.948 4.000   | 0.909 0.909 5.000   | 0.907 0.907 6.000   | 0.995 0.995 1.500   | 0.975 0.975 3.000   | 0.995 0.995 1.500   |
| only-a0 80-030    | 0.975 0.975 5.000   | 0.924 0.924 6.000   | 1.011 1.011 1.000   | 0.998 0.998 3.000   | 0.979 0.979 4.000   | 1.003 1.003 2.000   |
| only-a0 80-060    | 0.991 0.991 4.000   | 0.934 0.934 6.000   | 1.013 1.013 1.000   | 0.998 0.998 2.500   | 0.985 0.985 5.000   | 0.998 0.998 2.500   |
| only-a0 80-120    | 0.997 0.997 4.000   | 0.975 0.975 6.000   | 1.013 1.013 1.000   | 1.002 1.002 3.000   | 0.992 0.992 5.000   | 1.004 1.004 2.000   |
| only-a0 80-180    | 1.004 1.004 2.500   | 0.989 0.989 6.000   | 1.013 1.013 1.000   | 1.002 1.002 4.000   | 0.993 0.993 5.000   | 1.004 1.004 2.500   |
| modulo-2-2 10-015 | -1.455 -0.250 6.000 | 0.407 0.942 4.000   | -0.589 0.587 5.000  | 0.530 0.851 3.000   | 0.627 0.775 1.000   | 0.531 0.963 2.000   |
| modulo-2-2 10-030 | -1.373 -1.115 6.000 | 0.948 1.100 2.000   | -0.967 0.190 5.000  | 0.766 0.903 3.000   | 1.125 1.153 1.000   | 0.757 0.922 4.000   |
| modulo-2-2 10-060 | 1.064 1.081 2.000   | 1.134 1.200 1.000   | -1.481 -0.888 6.000 | 0.864 1.065 5.000   | 1.018 1.075 4.000   | 1.051 1.122 3.000   |
| modulo-2-2 10-120 | 1.155 1.214 2.000   | 1.129 1.218 3.000   | -1.275 -0.800 6.000 | 1.118 1.153 4.000   | 1.172 1.174 1.000   | 1.097 1.160 5.000   |
| modulo-2-2 10-180 | 1.204 1.231 1.000   | 1.189 1.234 2.000   | -1.594 -0.821 6.000 | 1.146 1.170 3.000   | 1.085 1.101 5.000   | 1.113 1.166 4.000   |
| modulo-2-2 20-015 | -1.244 -1.230 6.000 | 0.398 0.728 1.000   | -1.000 -1.000 5.000 | -0.441 -0.366 2.000 | -0.459 -0.190 3.000 | -0.544 -0.485 4.000 |
| modulo-2-2 20-030 | -1.325 -0.845 5.000 | 0.884 0.917 1.000   | -1.669 -1.551 6.000 | 0.382 0.835 4.000   | 0.527 0.572 3.000   | 0.870 0.882 2.000   |
| modulo-2-2 20-060 | 0.718 0.818 5.000   | 0.982 1.032 2.000   | -1.486 -0.969 6.000 | 0.780 0.963 4.000   | 0.864 0.918 3.000   | 0.995 1.003 1.000   |
| modulo-2-2 20-120 | 1.007 1.048 1.000   | 1.004 1.055 3.000   | -0.898 -0.315 6.000 | 0.959 1.023 4.000   | 0.935 0.946 5.000   | 1.007 1.014 2.000   |
| modulo-2-2 20-180 | 1.020 1.051 2.000   | 0.981 1.067 5.000   | -1.092 -0.573 6.000 | 1.009 1.029 3.000   | 0.982 0.988 4.000   | 1.029 1.032 1.000   |
| modulo-2-2 40-015 | -1.097 -0.935 6.000 | -0.165 0.579 1.000  | -0.953 -0.952 5.000 | -0.739 -0.654 3.000 | -0.425 -0.288 2.000 | -0.784 -0.502 4.000 |
| modulo-2-2 40-030 | -1.592 -1.186 6.000 | 0.291 0.604 3.000   | -1.300 -0.743 5.000 | -0.170 0.107 4.000  | 0.454 0.674 1.000   | 0.308 0.347 2.000   |
| modulo-2-2 40-060 | 0.747 0.801 3.000   | 0.750 0.897 2.000   | -0.576 -0.310 6.000 | 0.514 0.678 5.000   | 0.673 0.798 4.000   | 0.932 0.943 1.000   |
| modulo-2-2 40-120 | 0.944 0.967 2.000   | 0.840 0.907 5.000   | -1.054 -0.105 6.000 | 0.893 0.915 4.000   | 0.952 0.953 1.000   | 0.902 0.959 3.000   |
| modulo-2-2 40-180 | 0.955 1.007 2.000   | 0.937 0.983 4.000   | -1.122 -0.887 6.000 | 0.917 0.985 5.000   | 0.945 0.954 3.000   | 0.993 1.003 1.000   |
| modulo-2-2 80-015 | -1.316 -0.971 6.000 | -0.218 0.464 1.000  | -0.976 -0.976 3.000 | -0.596 -0.551 2.000 | -0.984 -0.571 4.000 | -1.038 -0.991 5.000 |
| modulo-2-2 80-030 | -1.348 -0.737 6.000 | -0.029 0.219 1.000  | -0.977 -0.850 4.000 | -0.992 -0.613 5.000 | -0.446 0.247 3.000  | -0.174 0.260 2.000  |
| modulo-2-2 80-060 | 0.357 0.543 2.000   | 0.605 0.760 1.000   | -0.662 -0.622 6.000 | -0.588 -0.516 5.000 | 0.303 0.502 3.000   | -0.145 -0.032 4.000 |
| modulo-2-2 80-120 | 0.828 0.892 2.000   | 0.734 0.901 5.000   | -1.645 -0.278 6.000 | 0.799 0.837 3.000   | 0.883 0.898 1.000   | 0.776 0.845 4.000   |
| modulo-2-2 80-180 | 0.906 0.949 3.000   | 0.826 0.945 5.000   | -0.482 -0.272 6.000 | 0.950 0.958 2.000   | 0.888 0.920 4.000   | 0.975 0.984 1.000   |
| modulo-2-4 10-015 | -1.268 -0.591 5.000 | -1.274 -0.217 6.000 | -1.111 -0.555 4.000 | -0.625 0.498 1.000  | -0.760 0.400 2.000  | -0.847 -0.286 3.000 |
| modulo-2-4 10-030 | -1.616 0.069 6.000  | -0.206 0.804 2.000  | -1.486 -0.744 5.000 | 0.481 0.802 1.000   | -0.674 0.439 3.000  | -1.322 0.042 4.000  |
| modulo-2-4 10-060 | -1.676 0.292 6.000  | 0.526 1.256 1.000   | -1.658 -0.673 5.000 | -0.515 0.735 4.000  | 0.397 1.138 2.000   | -0.328 0.763 3.000  |
| modulo-2-4 10-120 | -1.755 -1.437 6.000 | 1.339 1.466 1.000   | -1.309 -0.636 5.000 | 0.595 1.086 4.000   | 1.122 1.328 2.000   | 1.085 1.180 3.000   |
| modulo-2-4 10-180 | -1.635 -1.215 5.000 | 1.337 1.574 1.000   | -1.675 -0.94 6.000  | 1.037 1.243 2.000   | 0.900 1.162 3.000   | 0.878 1.423 4.000   |
| modulo-2-4 20-015 | -1.176 -1.504 2.000 | -1.271 -0.716 3.000 | -1.579 -0.526 4.000 | -1.707 0.184 6.000  | -0.864 0.335 1.000  | -1.670 -0.644 5.000 |
| modulo-2-4 20-030 | -0.207 0.718 1.000  | -0.749 -0.380 2.000 | -1.833 -0.698 6.000 | -1.785 -0.096 5.000 | -1.744 -0.042 4.000 | -0.999 -0.084 3.000 |
| modulo-2-4 20-060 | -1.564 -0.485 6.000 | -0.587 0.541 1.000  | -0.910 -0.589 3.000 | -1.021 0.395 4.000  | -1.368 -0.496 5.000 | -0.891 0.105 2.000  |
| modulo-2-4 20-120 | -1.793 -1.090 6.000 | 0.400 0.903 1.000   | -1.613 -0.679 5.000 | -0.831 0.225 3.000  | -1.440 -0.058 4.000 | -0.187 0.325 2.000  |
| modulo-2-4 20-180 | -1.716 -1.556 6.000 | 0.776 1.065 1.000   | -1.031 0.112 5.000  | 0.023 0.699 3.000   | 0.123 0.688 2.000   | -0.154 0.596 4.000  |
| modulo-2-4 40-015 | -1.318 -0.668 4.000 | -1.696 -0.947 6.000 | -1.013 0.000 2.000  | -0.600 -0.149 1.000 | -1.466 -0.955 5.000 | -1.157 -0.671 3.000 |
| modulo-2-4 40-030 | -1.437 -1.024 3.000 | -1.328 -0.208 1.000 | -1.555 -0.765 6.000 | -1.488 -0.861 5.000 | -1.410 -0.447 2.000 | -1.468 -0.725 4.000 |
| modulo-2-4 40-060 | -1.105 -0.038 1.000 | -1.333 -0.767 3.000 | -1.555 -0.960 5.000 | -1.222 -0.652 2.000 | -1.783 -0.534 6.000 | -1.385 -0.455 4.000 |
| modulo-2-4 40-120 | -1.323 -0.664 5.000 | -0.807 -0.150 1.000 | -1.999 -0.742 6.000 | -1.228 -0.631 3.000 | -0.825 -0.710 2.000 | -1.236 -0.110 4.000 |
| modulo-2-4 40-180 | -1.988 -0.620 6.000 | -0.248 0.538 1.000  | -1.471 -1.132 5.000 | -0.870 -0.124 3.000 | -1.036 -0.399 4.000 | -0.769 -0.344 2.000 |
| modulo-2-4 80-015 | -1.471 -0.802 6.000 | -1.372 -0.891 5.000 | -0.485 0.484 1.000  | -1.023 -0.951 3.000 | -1.267 -0.728 4.000 | -1.001 -0.736 2.000 |
| modulo-2-4 80-030 | -1.281 -0.452 5.000 | -1.671 -0.871 6.000 | 0.000 0.000 1.000   | -1.226 -0.728 3.000 | -1.245 -0.652 4.000 | -1.112 -0.895 2.000 |
| modulo-2-4 80-060 | -1.144 -0.854 2.000 | -1.215 -0.346 4.000 | -1.773 -0.417 6.000 | -1.097 -0.410 1.000 | -1.509 -0.989 5.000 | -1.200 -0.921 3.000 |
| modulo-2-4 80-120 | -1.323 -0.887 4.000 | -1.145 -0.400 3.000 | -1.373 -0.766 5.000 | -1.440 -0.810 6.000 | -0.953 -0.165 1.000 | -1.130 -0.667 2.000 |
| modulo-2-4 80-180 | -1.757 -0.956 6.000 | -1.397 -0.892 3.000 | -1.414 -0.185 4.000 | -1.383 -0.678 2.000 | -1.647 -0.527 5.000 | -0.952 -0.467 1.000 |
| modulo-4-2 10-015 | -1.282 -1.247 5.000 | 0.183 0.383 1.000   | nan nan nan         | -0.638 -0.321 2.000 | -0.691 -0.419 4.000 | -0.688 -0.682 3.000 |
| modulo-4-2 10-030 | -0.089 -0.025 5.000 | 0.899 1.097 3.000   | nan nan nan         | 0.948 1.044 1.000   | 0.927 1.001 2.000   | 0.769 1.102 4.000   |
| modulo-4-2 10-060 | 0.493 0.780 5.000   | 1.116 1.204 1.000   | nan nan nan         | 0.867 1.060 4.000   | 0.998 1.000 2.000   | 0.997 1.080 3.000   |
| modulo-4-2 10-120 | 0.965 0.970 5.000   | 1.183 1.208 1.000   | nan nan nan         | 1.066 1.072 3.000   | 1.012 1.025 4.000   | 1.132 1.168 2.000   |
| modulo-4-2 10-180 | 1.142 1.165 2.000   | 1.205 1.227 1.000   | nan nan nan         | 1.026 1.048 5.000   | 1.050 1.057 4.000   | 1.103 1.124 3.000   |
| modulo-4-2 20-015 | -0.822 -0.371 5.000 | 0.362 0.689 1.000   | nan nan nan         | -0.158 0.706 4.000  | -0.053 0.810 2.000  | -0.069 0.783 3.000  |
| modulo-4-2 20-030 | -1.539 -1.247 5.000 | 0.547 0.665 1.000   | nan nan nan         | -0.801 -0.566 4.000 | -0.550 -0.479 2.000 | -0.704 -0.164 3.000 |
| modulo-4-2 20-060 | -1.341 -0.964 5.000 | 0.936 0.977 1.000   | nan nan nan         | 0.761 0.813 2.000   | 0.565 0.578 4.000   | 0.759 0.898 3.000   |
| modulo-4-2 20-120 | 0.897 0.904 4.000   | 1.011 1.056 1.000   | nan nan nan         | 0.854 0.928 5.000   | 0.945 0.968 3.000   | 0.993 1.000 2.000   |
| modulo-4-2 20-180 | 1.034 1.041 1.000   | 1.024 1.068 2.000   | nan nan nan         | 0.820 1.009 5.000   | 0.959 0.960 3.000   | 0.879 1.002 4.000   |

**Tabela D.1:** Tabela uspešnosti kombinirane funkcije na izbranih metodah za ocenjevanje pomembnosti atributov in vseh naborih podatkov pri podrobni analizi (del 1 od 5).

| Dataset                | <i>RedFN</i>        | <i>RdFSN</i>        | <i>LogON</i>        | <i>LeaN</i>         | <i>LeaGITc3APN</i>  | <i>LeaTc3N</i>      |
|------------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|
| modulo-4-2 40-015      | -1.032 -0.828 4.000 | -1.040 -0.698 5.000 | nan nan nan         | -0.974 -0.861 3.000 | -0.645 -0.608 1.000 | -0.779 -0.686 2.000 |
| modulo-4-2 40-030      | -0.943 -0.868 5.000 | 0.376 0.546 1.000   | nan nan nan         | -0.939 -0.732 4.000 | -0.860 -0.280 3.000 | -0.507 -0.432 2.000 |
| modulo-4-2 40-060      | -0.703 -0.605 5.000 | 0.617 0.691 3.000   | nan nan nan         | 0.353 0.480 4.000   | 0.754 0.804 1.000   | 0.703 0.782 2.000   |
| modulo-4-2 40-120      | 0.724 0.774 5.000   | 0.859 0.957 3.000   | nan nan nan         | 0.775 0.866 4.000   | 0.889 0.905 2.000   | 0.940 0.967 1.000   |
| modulo-4-2 40-180      | 0.918 0.926 3.000   | 0.919 0.968 2.000   | nan nan nan         | 0.905 0.929 4.000   | 0.947 0.958 1.000   | 0.888 0.918 5.000   |
| modulo-4-2 80-015      | -1.370 -1.190 3.000 | -1.464 -0.762 5.000 | nan nan nan         | -1.391 -1.002 4.000 | -1.302 -0.921 2.000 | -1.082 -0.111 1.000 |
| modulo-4-2 80-030      | -1.056 -1.052 4.000 | -0.215 -0.112 1.000 | nan nan nan         | -0.747 -0.648 2.000 | -0.914 -0.884 3.000 | -1.078 -0.750 5.000 |
| modulo-4-2 80-060      | -1.580 -1.235 5.000 | 0.397 0.559 1.000   | nan nan nan         | -0.712 -0.691 3.000 | -0.338 -0.225 2.000 | -0.749 -0.630 4.000 |
| modulo-4-2 80-120      | 0.442 0.535 4.000   | 0.774 0.848 3.000   | nan nan nan         | 0.812 0.827 2.000   | 0.418 0.582 5.000   | 0.818 0.931 1.000   |
| modulo-4-2 80-180      | 0.778 0.857 4.000   | 0.833 0.880 3.000   | nan nan nan         | 0.768 0.774 5.000   | 0.859 0.907 2.000   | 0.867 0.870 1.000   |
| modulo-8-2 10-015      | -0.528 -0.148 2.000 | -0.103 0.508 1.000  | nan nan nan         | -0.886 -0.449 5.000 | -0.583 -0.410 4.000 | -0.563 -0.316 3.000 |
| modulo-8-2 10-030      | 0.249 0.318 2.000   | 0.842 1.009 1.000   | nan nan nan         | -0.640 -0.209 3.000 | -1.303 -0.168 5.000 | -0.911 -0.240 4.000 |
| modulo-8-2 10-060      | 0.278 0.506 5.000   | 1.104 1.167 1.000   | nan nan nan         | 0.669 0.946 4.000   | 0.989 0.991 3.000   | 1.003 1.061 2.000   |
| modulo-8-2 10-120      | -0.687 -0.629 5.000 | 1.212 1.230 1.000   | nan nan nan         | 0.995 1.102 2.000   | 0.983 1.038 3.000   | 0.915 1.062 4.000   |
| modulo-8-2 10-180      | -1.097 -1.073 5.000 | 1.177 1.197 1.000   | nan nan nan         | 0.895 0.998 4.000   | 1.067 1.092 2.000   | 0.898 1.062 3.000   |
| modulo-8-2 20-015      | -1.952 -1.434 5.000 | -1.637 -1.158 3.000 | nan nan nan         | -1.063 -0.963 1.000 | -1.888 -1.217 4.000 | -1.442 -1.040 2.000 |
| modulo-8-2 20-030      | -0.847 -0.494 5.000 | 0.077 0.453 1.000   | nan nan nan         | -0.126 0.542 2.000  | -0.602 -0.044 4.000 | -0.282 0.124 3.000  |
| modulo-8-2 20-060      | -0.200 -0.097 5.000 | 0.926 0.942 1.000   | nan nan nan         | 0.676 0.775 3.000   | 0.612 0.647 4.000   | 0.862 0.885 2.000   |
| modulo-8-2 20-120      | -0.491 -0.490 5.000 | 1.015 1.038 1.000   | nan nan nan         | 0.679 0.748 4.000   | 0.790 0.824 3.000   | 0.931 0.983 2.000   |
| modulo-8-2 20-180      | -0.899 -0.776 5.000 | 1.048 1.055 1.000   | nan nan nan         | 0.673 0.950 4.000   | 0.891 0.914 2.000   | 0.793 0.936 3.000   |
| modulo-8-2 40-015      | -0.761 -0.746 2.000 | -0.692 -0.599 1.000 | nan nan nan         | -1.149 -0.812 4.000 | -1.089 -0.790 3.000 | -1.234 -0.712 5.000 |
| modulo-8-2 40-030      | -1.247 -1.190 5.000 | -0.588 -0.270 2.000 | nan nan nan         | -0.496 -0.428 1.000 | -0.980 -0.806 4.000 | -0.934 -0.411 3.000 |
| modulo-8-2 40-060      | -0.413 -0.408 4.000 | 0.438 0.591 2.000   | nan nan nan         | -0.886 -0.841 5.000 | 0.593 0.641 1.000   | 0.354 0.380 3.000   |
| modulo-8-2 40-120      | -1.448 -1.423 5.000 | 0.842 0.884 1.000   | nan nan nan         | 0.198 0.683 4.000   | 0.658 0.672 3.000   | 0.773 0.789 2.000   |
| modulo-8-2 40-180      | -0.165 -0.122 5.000 | 0.853 0.861 3.000   | nan nan nan         | 0.944 0.951 1.000   | 0.846 0.870 4.000   | 0.931 0.948 2.000   |
| modulo-8-2 80-015      | -0.711 -0.576 2.000 | -0.619 -0.608 1.000 | nan nan nan         | -1.012 -0.336 4.000 | -0.958 -0.678 3.000 | -1.061 -0.371 5.000 |
| modulo-8-2 80-030      | -0.812 -0.798 3.000 | -0.583 -0.455 1.000 | nan nan nan         | -1.011 -0.955 5.000 | -0.794 -0.695 2.000 | -0.897 -0.649 4.000 |
| modulo-8-2 80-060      | -1.434 -1.195 5.000 | 0.213 0.424 1.000   | nan nan nan         | -0.943 -0.937 3.000 | -0.928 -0.492 2.000 | -0.965 -0.886 4.000 |
| modulo-8-2 80-120      | -1.602 -1.466 5.000 | 0.814 0.835 1.000   | nan nan nan         | -1.023 -0.852 4.000 | 0.400 0.566 3.000   | 0.452 0.567 2.000   |
| modulo-8-2 80-180      | 0.436 0.490 5.000   | 0.846 0.867 3.000   | nan nan nan         | 0.956 0.966 1.000   | 0.834 0.842 4.000   | 0.924 0.944 2.000   |
| only-a0-cp-2 10-015    | 1.322 1.322 2.000   | 1.377 1.377 1.000   | 1.286 1.286 4.000   | 1.257 1.257 5.000   | 1.227 1.227 6.000   | 1.313 1.313 3.000   |
| only-a0-cp-2 10-030    | 1.378 1.378 2.000   | 1.366 1.366 3.000   | 1.429 1.429 1.000   | 1.259 1.259 4.000   | 1.185 1.185 6.000   | 1.239 1.239 5.000   |
| only-a0-cp-2 10-060    | 1.406 1.406 2.000   | 1.393 1.393 3.000   | 1.429 1.429 1.000   | 1.063 1.063 6.000   | 1.290 1.290 4.000   | 1.071 1.071 5.000   |
| only-a0-cp-2 10-120    | 1.418 1.418 2.500   | 1.418 1.418 2.500   | 1.429 1.429 1.000   | 1.284 1.284 4.000   | 1.214 1.214 6.000   | 1.257 1.257 5.000   |
| only-a0-cp-2 10-180    | 1.422 1.422 2.000   | 1.421 1.421 3.000   | 1.429 1.429 1.000   | 1.206 1.206 4.000   | 0.618 0.618 6.000   | 1.193 1.193 5.000   |
| only-a0-cp-2 20-015    | 1.047 1.047 3.000   | 1.033 1.033 4.000   | 1.053 1.053 1.000   | 1.008 1.072 5.000   | 0.972 0.993 6.000   | 1.049 1.079 2.000   |
| only-a0-cp-2 20-030    | 1.152 1.152 2.000   | 1.108 1.108 3.000   | 1.176 1.176 1.000   | 1.091 1.091 4.000   | 1.057 1.057 6.000   | 1.086 1.086 5.000   |
| only-a0-cp-2 20-060    | 1.162 1.162 2.000   | 1.128 1.128 3.000   | 1.176 1.176 1.000   | 1.116 1.116 4.000   | 1.042 1.042 6.000   | 1.112 1.112 5.000   |
| only-a0-cp-2 20-120    | 1.164 1.164 2.000   | 1.152 1.152 3.000   | 1.176 1.176 1.000   | 1.047 1.047 5.000   | 1.059 1.059 4.000   | 1.038 1.038 6.000   |
| only-a0-cp-2 20-180    | 1.165 1.165 3.000   | 1.166 1.166 2.000   | 1.176 1.176 1.000   | 1.057 1.057 4.500   | 1.041 1.041 6.000   | 1.057 1.057 4.500   |
| only-a0-cp-2 40-015    | 1.010 1.010 2.000   | 0.984 0.984 4.000   | 0.874 0.874 6.000   | 1.005 1.035 3.000   | 0.980 0.980 5.000   | 1.038 1.038 1.000   |
| only-a0-cp-2 40-030    | 1.046 1.046 2.000   | 1.005 1.005 5.000   | 1.081 1.081 1.000   | 1.042 1.042 3.000   | 0.974 0.974 6.000   | 1.038 1.038 4.000   |
| only-a0-cp-2 40-060    | 1.052 1.052 2.000   | 1.039 1.039 3.000   | 1.081 1.081 1.000   | 1.030 1.030 4.000   | 1.017 1.017 6.000   | 1.028 1.028 5.000   |
| only-a0-cp-2 40-120    | 1.073 1.073 2.000   | 1.048 1.048 3.000   | 1.081 1.081 1.000   | 1.034 1.034 4.000   | 1.012 1.012 6.000   | 1.033 1.033 5.000   |
| only-a0-cp-2 40-180    | 1.067 1.067 2.000   | 1.058 1.058 3.000   | 1.081 1.081 1.000   | 1.042 1.042 4.000   | 1.017 1.017 6.000   | 1.040 1.040 5.000   |
| only-a0-cp-2 80-015    | 0.892 0.892 5.000   | 0.910 0.910 4.000   | 0.826 0.826 6.000   | 0.983 0.987 2.000   | 0.920 0.921 3.000   | 1.012 1.012 1.000   |
| only-a0-cp-2 80-030    | 0.995 0.995 4.000   | 0.956 0.956 6.000   | 1.039 1.039 1.000   | 1.011 1.011 2.000   | 0.988 0.988 5.000   | 1.010 1.010 3.000   |
| only-a0-cp-2 80-060    | 1.018 1.018 2.000   | 0.979 0.979 6.000   | 1.039 1.039 1.000   | 1.013 1.013 4.000   | 1.012 1.012 5.000   | 1.014 1.014 3.000   |
| only-a0-cp-2 80-120    | 1.025 1.025 2.000   | 1.009 1.009 5.000   | 1.039 1.039 1.000   | 1.014 1.014 4.000   | 1.002 1.002 6.000   | 1.015 1.015 3.000   |
| only-a0-cp-2 80-180    | 1.022 1.022 2.000   | 1.015 1.015 4.500   | 1.039 1.039 1.000   | 1.018 1.018 3.000   | 1.003 1.003 6.000   | 1.015 1.015 4.500   |
| modulo-2-2-cp-1 10-015 | -1.397 -0.909 6.000 | 1.499 1.566 1.000   | -1.001 -1.000 5.000 | 0.673 1.021 4.000   | 1.144 1.446 2.000   | 0.779 1.030 3.000   |
| modulo-2-2-cp-1 10-030 | -0.759 0.505 5.000  | 1.527 1.600 1.000   | -1.291 -0.988 6.000 | 0.860 1.117 4.000   | 0.943 1.291 3.000   | 1.072 1.431 2.000   |
| modulo-2-2-cp-1 10-060 | 1.492 1.576 2.000   | 1.582 1.632 1.000   | -1.957 -0.689 6.000 | 1.068 1.370 5.000   | 1.098 1.436 3.000   | 1.092 1.322 4.000   |
| modulo-2-2-cp-1 10-120 | 1.604 1.634 2.000   | 1.607 1.634 1.000   | -0.715 -0.569 6.000 | 1.354 1.520 4.000   | 1.133 1.416 5.000   | 1.375 1.520 3.000   |
| modulo-2-2-cp-1 10-180 | 1.632 1.645 1.000   | 1.632 1.646 2.000   | -1.453 0.191 6.000  | 1.059 1.398 3.000   | 0.981 1.356 5.000   | 0.992 1.369 4.000   |
| modulo-2-2-cp-1 20-015 | -0.693 -0.518 5.000 | 1.013 1.040 1.000   | -1.250 -1.250 6.000 | 0.016 0.265 4.000   | 0.438 0.700 3.000   | 0.474 0.739 2.000   |
| modulo-2-2-cp-1 20-030 | -1.283 -1.260 6.000 | 0.994 1.056 1.000   | -0.947 -0.871 5.000 | 0.531 0.887 4.000   | 0.939 1.022 2.000   | 0.693 0.845 3.000   |
| modulo-2-2-cp-1 20-060 | 1.105 1.114 1.000   | 1.050 1.192 2.000   | -1.431 -0.725 6.000 | 0.902 1.050 4.000   | 0.825 1.063 5.000   | 1.041 1.084 3.000   |
| modulo-2-2-cp-1 20-120 | 1.194 1.211 2.000   | 1.210 1.217 1.000   | -1.147 -0.912 6.000 | 0.970 1.115 4.000   | 0.821 0.960 5.000   | 1.043 1.135 3.000   |
| modulo-2-2-cp-1 20-180 | 1.214 1.230 1.000   | 1.206 1.207 2.000   | -0.431 -0.248 6.000 | 0.987 1.081 4.000   | 0.831 1.085 5.000   | 1.037 1.153 3.000   |
| modulo-2-2-cp-1 40-015 | -1.046 -0.896 5.000 | 0.541 0.772 1.000   | -1.481 -0.494 6.000 | 0.038 0.269 2.000   | -0.184 0.071 3.000  | -0.300 -0.128 4.000 |
| modulo-2-2-cp-1 40-030 | -0.999 -0.996 5.000 | 0.836 0.975 1.000   | -1.095 -0.763 6.000 | -0.127 0.191 4.000  | 0.604 0.793 2.000   | 0.548 0.709 3.000   |
| modulo-2-2-cp-1 40-060 | 0.913 0.937 2.000   | 0.949 1.014 1.000   | -1.674 -0.709 6.000 | 0.659 0.860 5.000   | 0.713 0.966 4.000   | 0.744 0.837 3.000   |
| modulo-2-2-cp-1 40-120 | 1.033 1.059 1.000   | 0.949 1.056 2.000   | -1.198 -0.444 6.000 | 0.774 0.837 5.000   | 0.911 1.009 3.000   | 0.841 0.906 4.000   |
| modulo-2-2-cp-1 40-180 | 1.072 1.082 1.000   | 1.033 1.064 2.000   | -1.138 -0.624 6.000 | 0.788 0.908 4.000   | 0.759 1.008 5.000   | 0.939 1.022 3.000   |
| modulo-2-2-cp-1 80-015 | -1.597 -1.120 6.000 | 0.279 0.682 1.000   | -0.647 -0.647 3.000 | -0.763 -0.652 5.000 | -0.523 -0.248 2.000 | -0.649 -0.569 4.000 |
| modulo-2-2-cp-1 80-030 | -1.343 -1.130 6.000 | 0.747 0.752 1.000   | -1.013 -0.102 5.000 | -0.786 -0.712 4.000 | 0.047 0.518 2.000   | -0.641 -0.457 3.000 |
| modulo-2-2-cp-1 80-060 | 0.736 0.885 2.000   | 0.778 0.859 1.000   | -1.814 -1.175 6.000 | 0.164 0.288 5.000   | 0.713 0.905 3.000   | 0.681 0.685 4.000   |
| modulo-2-2-cp-1 80-120 | 0.958 0.965 1.000   | 0.927 0.973 2.000   | -1.397 -1.265 6.000 | 0.676 0.782 5.000   | 0.763 0.954 3.000   | 0.728 0.769 4.000   |
| modulo-2-2-cp-1 80-180 | 1.000 1.004 1.000   | 0.965 0.975 2.000   | -1.382 -0.561 6.000 | 0.173 0.301 5.000   | 0.741 0.952 4.000   | 0.857 0.887 3.000   |

**Tabela D.2:** Tabela uspešnosti kombinirane funkcije na izbranih metodah za ocenjevanje pomembnosti atributov in vseh naborih podatkov pri podrobni analizi (del 2 od 5).

| Dataset                     | <i>RedFN</i>        | <i>RdFSN</i>       | <i>LogON</i>        | <i>LeaN</i>         | <i>LeaGITc3APN</i>  | <i>LeaTc3N</i>      |
|-----------------------------|---------------------|--------------------|---------------------|---------------------|---------------------|---------------------|
| modulo-2-2-a1-cp-2 10-015   | -0.247 0.669 6.000  | 0.033 1.093 3.000  | 0.000 0.001 5.000   | 0.106 1.120 2.000   | 0.027 1.114 4.000   | 0.139 1.134 1.000   |
| modulo-2-2-a1-cp-2 10-030   | -0.736 0.267 5.000  | 0.143 1.152 3.000  | -0.834 0.833 6.000  | 0.179 1.122 1.000   | 0.040 1.033 4.000   | 0.145 1.128 2.000   |
| modulo-2-2-a1-cp-2 10-060   | 0.086 1.120 4.000   | 0.149 1.144 2.000  | -1.337 -1.187 6.000 | 0.146 1.132 3.000   | 0.001 1.034 5.000   | 0.168 1.136 1.000   |
| modulo-2-2-a1-cp-2 10-120   | 0.304 1.204 1.000   | 0.198 1.170 2.000  | -1.165 -0.837 6.000 | 0.036 1.108 4.000   | -0.007 1.018 5.000  | 0.058 1.136 3.000   |
| modulo-2-2-a1-cp-2 10-180   | 0.232 1.186 1.000   | 0.230 1.185 2.000  | -1.573 -0.017 6.000 | 0.081 1.119 4.000   | 0.061 1.065 5.000   | 0.090 1.128 3.000   |
| modulo-2-2-a1-cp-2 20-015   | -1.459 -1.361 6.000 | 0.055 0.915 1.000  | -0.514 -0.513 5.000 | -0.313 0.681 4.000  | -0.171 0.726 2.000  | -0.280 0.672 3.000  |
| modulo-2-2-a1-cp-2 20-030   | -1.600 -1.041 6.000 | 0.088 1.017 3.000  | -0.451 -0.093 5.000 | 0.024 0.881 4.000   | 0.159 0.983 1.000   | 0.127 0.990 2.000   |
| modulo-2-2-a1-cp-2 20-060   | 0.296 1.011 1.000   | 0.138 1.029 4.000  | -0.473 -0.065 6.000 | 0.119 1.009 5.000   | 0.154 0.946 2.000   | 0.142 1.038 3.000   |
| modulo-2-2-a1-cp-2 20-120   | 0.318 1.084 1.000   | 0.142 1.038 5.000  | -1.502 -1.115 6.000 | 0.146 1.031 4.000   | 0.164 1.002 2.000   | 0.150 1.047 3.000   |
| modulo-2-2-a1-cp-2 20-180   | 0.282 1.086 1.000   | 0.169 1.060 2.000  | -0.695 -0.674 6.000 | 0.142 1.043 5.000   | 0.152 0.993 3.000   | 0.145 1.043 4.000   |
| modulo-2-2-a1-cp-2 40-015   | -0.920 -0.619 5.000 | 0.070 0.853 1.000  | -1.558 -0.520 6.000 | -0.517 0.430 3.000  | -0.239 0.576 2.000  | -0.610 0.359 4.000  |
| modulo-2-2-a1-cp-2 40-030   | -1.654 -0.970 6.000 | 0.146 0.925 1.000  | -1.471 -1.282 5.000 | -0.140 0.756 3.000  | 0.116 0.827 2.000   | -0.443 0.480 4.000  |
| modulo-2-2-a1-cp-2 40-060   | 0.167 0.956 2.000   | 0.163 0.994 3.000  | -1.084 -0.139 6.000 | 0.018 0.899 5.000   | 0.268 0.997 1.000   | 0.051 0.922 4.000   |
| modulo-2-2-a1-cp-2 40-120   | 0.340 1.039 1.000   | 0.150 0.994 3.000  | -1.492 -1.231 6.000 | 0.123 0.990 4.000   | 0.205 1.007 2.000   | 0.110 0.972 5.000   |
| modulo-2-2-a1-cp-2 40-180   | 0.316 1.032 1.000   | 0.168 1.010 3.000  | -1.653 -0.983 6.000 | 0.136 0.994 4.000   | 0.191 1.005 2.000   | 0.135 0.996 5.000   |
| modulo-2-2-a1-cp-2 80-015   | -1.110 -0.902 5.000 | -0.128 0.664 1.000 | -1.482 -1.481 6.000 | -0.992 -0.942 3.000 | -0.916 -0.357 2.000 | -1.107 -0.920 4.000 |
| modulo-2-2-a1-cp-2 80-030   | -1.266 -0.746 6.000 | -0.072 0.823 1.000 | -1.065 -0.690 5.000 | -0.080 0.811 2.000  | -0.124 0.695 3.000  | -0.480 0.370 4.000  |
| modulo-2-2-a1-cp-2 80-060   | 0.123 0.900 2.000   | 0.114 0.877 3.000  | -0.675 -0.660 6.000 | -0.385 0.554 4.000  | 0.201 0.919 1.000   | -0.401 0.549 5.000  |
| modulo-2-2-a1-cp-2 80-120   | 0.290 0.978 1.000   | 0.178 0.968 3.000  | -0.812 -0.772 6.000 | 0.071 0.959 4.000   | 0.235 0.963 2.000   | 0.046 0.917 5.000   |
| modulo-2-2-a1-cp-2 80-180   | 0.284 0.972 1.000   | 0.177 0.966 3.000  | -1.253 -1.163 6.000 | 0.000 0.856 5.000   | 0.210 0.959 2.000   | 0.038 0.902 4.000   |
| modulo-2-2-irr-a2-cp 10-015 | 0.861 1.197 5.000   | 0.892 1.175 4.000  | -1.818 0.000 6.000  | 1.081 1.159 1.000   | 0.909 1.043 3.000   | 0.959 1.137 2.000   |
| modulo-2-2-irr-a2-cp 10-030 | -1.271 -0.656 6.000 | 1.056 1.190 2.000  | -1.179 -1.073 5.000 | 0.958 1.168 3.000   | 0.933 0.988 4.000   | 1.176 1.198 1.000   |
| modulo-2-2-irr-a2-cp 10-060 | 1.066 1.081 4.000   | 1.191 1.227 1.000  | 0.283 0.888 6.000   | 1.130 1.131 2.000   | 1.049 1.106 5.000   | 1.075 1.116 3.000   |
| modulo-2-2-irr-a2-cp 10-120 | -0.628 -0.599 5.000 | 1.196 1.227 1.000  | -1.200 -0.617 6.000 | 1.043 1.165 3.000   | 1.033 1.040 4.000   | 1.080 1.164 2.000   |
| modulo-2-2-irr-a2-cp 10-180 | -0.134 -0.134 5.000 | 1.228 1.230 1.000  | -0.433 -0.399 6.000 | 1.109 1.138 4.000   | 1.115 1.115 2.000   | 1.114 1.133 3.000   |
| modulo-2-2-irr-a2-cp 20-015 | -1.113 -0.713 6.000 | 0.377 1.039 4.000  | -0.781 -0.696 5.000 | 0.782 1.051 3.000   | 0.935 0.941 1.000   | 0.786 1.012 2.000   |
| modulo-2-2-irr-a2-cp 20-030 | -1.165 -0.977 6.000 | 0.957 1.084 1.000  | -0.802 -0.093 5.000 | 0.861 1.046 3.000   | 0.907 0.921 2.000   | 0.843 1.059 4.000   |
| modulo-2-2-irr-a2-cp 20-060 | 1.088 1.101 2.000   | 1.090 1.101 1.000  | -1.114 -0.663 6.000 | 0.880 1.053 4.000   | 0.830 0.870 5.000   | 0.923 1.046 3.000   |
| modulo-2-2-irr-a2-cp 20-120 | -0.466 -0.289 5.000 | 1.090 1.105 1.000  | -1.918 -1.021 6.000 | 1.042 1.054 2.000   | 0.959 0.980 4.000   | 0.992 1.047 3.000   |
| modulo-2-2-irr-a2-cp 20-180 | -0.106 -0.103 5.000 | 1.104 1.106 1.000  | -1.078 0.030 6.000  | 0.924 1.051 4.000   | 0.953 0.953 3.000   | 1.044 1.059 2.000   |
| modulo-2-2-irr-a2-cp 40-015 | -0.717 -0.072 6.000 | 0.971 1.032 1.000  | 0.493 0.589 4.000   | 0.654 0.969 3.000   | 0.207 0.952 5.000   | 0.744 0.981 2.000   |
| modulo-2-2-irr-a2-cp 40-030 | -0.985 0.169 6.000  | 1.019 1.047 1.000  | -0.205 1.017 5.000  | 0.760 1.014 4.000   | 0.818 0.925 2.000   | 0.769 1.019 3.000   |
| modulo-2-2-irr-a2-cp 40-060 | 0.958 1.041 3.000   | 1.003 1.047 1.000  | 0.563 1.032 6.000   | 0.921 1.026 4.000   | 0.895 0.921 5.000   | 0.967 1.028 2.000   |
| modulo-2-2-irr-a2-cp 40-120 | -0.464 -0.353 5.000 | 1.046 1.049 1.000  | -0.933 0.151 6.000  | 0.957 1.023 3.000   | 0.909 0.932 4.000   | 0.967 1.022 2.000   |
| modulo-2-2-irr-a2-cp 40-180 | -0.107 -0.098 6.000 | 1.039 1.050 1.000  | 0.175 0.551 5.000   | 1.022 1.025 2.000   | 0.950 0.964 4.000   | 0.995 1.027 3.000   |
| modulo-2-2-irr-a2-cp 80-015 | 0.059 0.829 4.000   | 0.528 1.017 3.000  | -1.012 -1.012 6.000 | 0.670 0.972 2.000   | -0.329 0.302 5.000  | 0.767 1.006 1.000   |
| modulo-2-2-irr-a2-cp 80-030 | -1.031 -0.771 6.000 | 0.819 1.020 3.000  | -0.889 -0.673 5.000 | 0.886 1.005 2.000   | 0.811 0.930 4.000   | 0.941 1.008 1.000   |
| modulo-2-2-irr-a2-cp 80-060 | 0.961 1.020 2.000   | 1.024 1.024 1.000  | -1.043 -0.006 6.000 | 0.887 0.977 4.000   | 0.794 0.974 5.000   | 0.937 1.008 3.000   |
| modulo-2-2-irr-a2-cp 80-120 | -0.468 -0.453 5.000 | 1.005 1.024 1.000  | -1.029 -0.974 6.000 | 0.976 1.006 2.000   | 0.876 0.905 4.000   | 0.950 0.982 3.000   |
| modulo-2-2-irr-a2-cp 80-180 | -0.106 -0.102 6.000 | 1.020 1.025 1.000  | 0.366 0.526 5.000   | 0.989 1.009 3.000   | 0.919 0.945 4.000   | 1.007 1.011 2.000   |
| and-2 10-015                | 1.048 1.061 1.000   | 1.012 1.049 3.000  | 1.026 1.026 2.000   | 0.681 1.044 6.000   | 0.913 1.025 4.000   | 0.810 1.082 5.000   |
| and-2 10-030                | 0.941 1.171 3.000   | 0.883 1.097 5.000  | 1.250 1.250 1.000   | 0.552 1.141 6.000   | 0.884 1.075 4.000   | 1.026 1.190 2.000   |
| and-2 10-060                | 1.053 1.190 4.000   | 0.950 1.131 5.000  | 1.250 1.250 1.000   | 1.094 1.184 2.000   | 0.936 1.090 6.000   | 1.087 1.147 3.000   |
| and-2 10-120                | 0.926 1.189 5.000   | 0.933 1.188 4.000  | 1.250 1.250 1.000   | 1.048 1.142 2.000   | 0.789 0.994 6.000   | 0.968 1.134 3.000   |
| and-2 10-180                | 1.122 1.214 3.000   | 1.167 1.220 2.000  | 1.250 1.250 1.000   | 1.025 1.107 6.000   | 1.040 1.139 5.000   | 1.100 1.134 4.000   |
| and-2 20-015                | 0.698 0.817 3.000   | 0.630 0.854 4.000  | 0.904 0.904 1.000   | 0.510 0.929 6.000   | 0.629 0.792 5.000   | 0.771 0.872 2.000   |
| and-2 20-030                | 0.876 1.016 5.000   | 0.870 1.033 6.000  | 1.111 1.111 1.000   | 0.991 1.027 3.000   | 0.932 1.038 4.000   | 1.065 1.071 2.000   |
| and-2 20-060                | 0.907 1.056 4.000   | 0.871 1.046 5.000  | 1.111 1.111 1.000   | 0.952 1.005 2.000   | 0.822 0.942 6.000   | 0.946 1.042 3.000   |
| and-2 20-120                | 1.028 1.061 2.000   | 0.970 1.032 3.000  | 1.111 1.111 1.000   | 0.872 1.054 6.000   | 0.920 0.992 5.000   | 0.946 1.068 4.000   |
| and-2 20-180                | 0.980 1.079 2.000   | 0.957 1.061 3.000  | 1.111 1.111 1.000   | 0.930 1.063 5.000   | 0.900 0.982 6.000   | 0.939 1.070 4.000   |
| and-2 40-015                | 0.669 0.870 5.000   | 0.559 0.787 6.000  | 0.847 0.847 3.000   | 0.914 0.978 2.000   | 0.748 0.933 4.000   | 0.931 1.009 1.000   |
| and-2 40-030                | 0.882 0.986 3.000   | 0.736 0.889 6.000  | 1.050 1.050 1.000   | 0.845 1.007 5.000   | 0.856 0.964 4.000   | 0.951 1.024 2.000   |
| and-2 40-060                | 0.858 0.948 5.000   | 0.807 0.928 6.000  | 1.053 1.053 1.000   | 0.873 1.017 4.000   | 0.931 0.988 3.000   | 0.984 1.021 2.000   |
| and-2 40-120                | 0.859 1.017 3.000   | 0.797 0.954 6.000  | 1.053 1.053 1.000   | 0.856 1.024 4.000   | 0.807 0.955 5.000   | 0.927 1.029 2.000   |
| and-2 40-180                | 0.953 1.014 5.000   | 0.924 0.970 6.000  | 1.053 1.053 1.000   | 0.987 1.028 2.000   | 0.963 1.022 4.000   | 0.980 1.029 3.000   |
| and-2 80-015                | 0.186 0.831 3.000   | 0.171 0.789 5.000  | 0.922 0.922 1.000   | 0.182 0.875 4.000   | 0.222 0.861 2.000   | 0.150 0.910 6.000   |
| and-2 80-030                | 0.519 0.886 5.000   | 0.400 0.820 6.000  | 1.026 1.026 1.000   | 0.893 0.988 2.000   | 0.644 0.899 4.000   | 0.865 0.986 3.000   |
| and-2 80-060                | 0.821 0.951 4.000   | 0.747 0.914 6.000  | 1.026 1.026 1.000   | 0.801 0.999 5.000   | 0.882 0.971 3.000   | 0.954 1.006 2.000   |
| and-2 80-120                | 0.830 0.989 5.000   | 0.789 0.954 6.000  | 1.026 1.026 1.000   | 0.895 1.005 3.000   | 0.881 0.992 4.000   | 0.918 1.004 2.000   |
| and-2 80-180                | 0.936 0.984 4.000   | 0.912 0.929 5.000  | 1.026 1.026 1.000   | 0.891 1.004 6.000   | 0.945 0.985 3.000   | 1.005 1.009 2.000   |
| and-4 10-015                | 0.341 1.157 4.000   | 0.290 1.063 6.000  | 1.129 1.452 1.000   | 0.723 1.247 2.000   | 0.321 1.078 5.000   | 0.606 1.133 3.000   |
| and-4 10-030                | 0.903 1.386 4.000   | 0.968 1.366 3.000  | 1.667 1.667 1.000   | 0.777 1.378 5.000   | 0.541 1.071 6.000   | 1.084 1.493 2.000   |
| and-4 10-060                | 0.631 1.281 6.000   | 0.889 1.410 4.000  | 1.667 1.667 1.000   | 0.987 1.432 3.000   | 0.819 1.307 5.000   | 1.025 1.416 2.000   |
| and-4 10-120                | 1.094 1.518 4.000   | 1.249 1.559 2.000  | 1.667 1.667 1.000   | 1.046 1.523 5.000   | 1.023 1.399 6.000   | 1.118 1.489 3.000   |
| and-4 10-180                | 1.484 1.599 2.000   | 1.376 1.584 6.000  | 1.667 1.667 1.000   | 1.453 1.566 3.000   | 1.445 1.540 4.000   | 1.414 1.549 5.000   |
| and-4 20-015                | 0.300 0.760 3.000   | -0.166 0.314 6.000 | 0.970 1.091 1.000   | 0.129 0.957 5.000   | 0.257 0.706 4.000   | 0.486 0.882 2.000   |
| and-4 20-030                | 0.259 1.020 5.000   | 0.121 0.878 6.000  | 1.250 1.250 1.000   | 0.413 0.997 2.000   | 0.318 1.031 4.000   | 0.384 1.070 3.000   |
| and-4 20-060                | 0.710 1.078 4.000   | 0.676 1.073 5.000  | 1.250 1.250 1.000   | 0.712 1.067 3.000   | 0.577 1.017 6.000   | 0.849 1.097 2.000   |
| and-4 20-120                | 1.024 1.166 3.000   | 0.779 1.074 6.000  | 1.250 1.250 1.000   | 0.866 1.136 5.000   | 0.869 1.00          |                     |

| Dataset              | <i>RedFN</i>        | <i>RdFSN</i>        | <i>LogON</i>        | <i>LeaN</i>         | <i>LeaGITc3APN</i>  | <i>LeaTc3N</i>      |
|----------------------|---------------------|---------------------|---------------------|---------------------|---------------------|---------------------|
| and-4 40-015         | -0.227 0.182 6.000  | -0.223 0.537 5.000  | 0.778 0.889 1.000   | 0.002 0.703 4.000   | 0.160 0.501 3.000   | 0.211 0.901 2.000   |
| and-4 40-030         | 0.178 0.790 5.000   | -0.300 0.428 6.000  | 1.111 1.111 1.000   | 0.834 1.003 2.000   | 0.498 0.868 4.000   | 0.764 1.034 3.000   |
| and-4 40-060         | 0.701 0.893 4.000   | 0.532 0.777 6.000   | 1.111 1.111 1.000   | 0.688 0.997 5.000   | 0.848 1.021 2.000   | 0.804 1.059 3.000   |
| and-4 40-120         | 0.796 1.009 5.000   | 0.694 0.913 6.000   | 1.111 1.111 1.000   | 0.937 1.037 2.000   | 0.911 1.011 4.000   | 0.915 1.063 3.000   |
| and-4 40-180         | 0.820 1.042 4.000   | 0.769 0.965 6.000   | 1.111 1.111 1.000   | 0.810 1.050 5.000   | 0.824 0.995 3.000   | 0.910 1.072 2.000   |
| and-4 80-015         | -0.344 0.319 5.000  | -0.989 -0.131 6.000 | 0.524 0.839 1.000   | -0.212 0.613 4.000  | -0.079 0.481 3.000  | -0.045 0.692 2.000  |
| and-4 80-030         | 0.286 0.619 5.000   | -0.104 0.385 6.000  | 0.946 1.051 1.000   | 0.540 0.958 3.000   | 0.513 0.825 4.000   | 0.847 0.922 2.000   |
| and-4 80-060         | 0.491 0.911 5.000   | 0.322 0.708 6.000   | 1.053 1.053 1.000   | 0.754 1.004 2.000   | 0.645 0.945 4.000   | 0.672 1.018 3.000   |
| and-4 80-120         | 0.750 0.882 5.000   | 0.498 0.601 6.000   | 1.053 1.053 1.000   | 0.862 1.016 3.000   | 0.844 0.963 4.000   | 0.868 1.022 2.000   |
| and-4 80-180         | 0.722 0.963 5.000   | 0.556 0.853 6.000   | 1.053 1.053 1.000   | 0.962 1.026 2.000   | 0.867 0.997 4.000   | 0.895 1.029 3.000   |
| if-a0-2 10-015       | -0.364 0.776 4.000  | -0.106 0.832 2.000  | -0.625 0.625 6.000  | -0.001 1.008 1.000  | -0.371 0.744 5.000  | -0.111 0.906 3.000  |
| if-a0-2 10-030       | -0.244 1.067 6.000  | 0.591 1.163 4.000   | 0.000 1.250 5.000   | 0.645 1.162 1.000   | 0.633 1.095 2.000   | 0.616 1.236 3.000   |
| if-a0-2 10-060       | 0.337 1.249 5.000   | 0.850 1.236 2.000   | -0.256 1.072 6.000  | 0.637 1.162 4.000   | 0.988 1.289 1.000   | 0.659 1.204 3.000   |
| if-a0-2 10-120       | 0.714 1.309 4.000   | 0.995 1.333 2.000   | -0.001 1.127 6.000  | 0.675 1.264 5.000   | 1.053 1.254 1.000   | 0.727 1.257 3.000   |
| if-a0-2 10-180       | 0.653 1.298 2.000   | 0.848 1.331 1.000   | -0.123 1.146 6.000  | 0.645 1.252 3.000   | 0.640 1.069 4.000   | 0.586 1.222 5.000   |
| if-a0-2 20-015       | -0.055 0.934 5.000  | -0.112 0.808 6.000  | 0.183 0.917 2.000   | 0.269 0.796 1.000   | 0.064 0.931 4.000   | 0.181 0.899 3.000   |
| if-a0-2 20-030       | -0.312 0.840 6.000  | 0.280 0.903 3.000   | -0.145 0.917 5.000  | 0.518 0.986 1.000   | 0.145 0.880 4.000   | 0.467 1.050 2.000   |
| if-a0-2 20-060       | 0.068 1.049 5.000   | 0.363 1.028 3.000   | -0.194 0.912 6.000  | 0.628 1.088 1.000   | 0.232 1.024 4.000   | 0.600 1.079 2.000   |
| if-a0-2 20-120       | 0.341 1.064 5.000   | 0.626 1.082 3.000   | -0.045 0.979 6.000  | 0.698 1.085 2.000   | 0.353 1.037 4.000   | 0.724 1.094 1.000   |
| if-a0-2 20-180       | 0.570 1.121 4.000   | 0.856 1.136 3.000   | -0.093 1.030 6.000  | 0.898 1.090 2.000   | 0.396 1.017 5.000   | 0.908 1.121 1.000   |
| if-a0-2 40-015       | -0.259 0.858 3.000  | -0.502 0.466 6.000  | -0.342 0.684 5.000  | -0.130 0.912 2.000  | -0.313 0.672 4.000  | -0.104 0.881 1.000  |
| if-a0-2 40-030       | -0.187 0.910 6.000  | 0.114 0.903 1.000   | -0.001 1.025 5.000  | 0.108 0.917 2.000   | 0.002 0.921 4.000   | 0.100 0.952 3.000   |
| if-a0-2 40-060       | 0.135 1.001 5.000   | 0.337 0.947 3.000   | -0.101 0.917 6.000  | 0.576 1.026 2.000   | 0.172 0.952 4.000   | 0.680 1.026 1.000   |
| if-a0-2 40-120       | 0.267 1.002 4.000   | 0.382 0.947 3.000   | -0.101 0.968 6.000  | 0.749 1.034 2.000   | 0.182 0.991 5.000   | 0.765 1.036 1.000   |
| if-a0-2 40-180       | 0.277 1.018 4.000   | 0.489 1.003 3.000   | -0.052 0.989 6.000  | 0.775 1.030 2.000   | 0.188 0.983 5.000   | 0.776 1.038 1.000   |
| if-a0-2 80-015       | -0.232 0.791 1.000  | -0.414 0.629 5.000  | -0.680 0.341 6.000  | -0.399 0.099 4.000  | -0.241 0.772 2.000  | -0.295 0.735 3.000  |
| if-a0-2 80-030       | -0.210 0.812 5.000  | -0.247 0.731 6.000  | -0.001 1.012 3.000  | 0.196 0.942 1.000   | -0.088 0.839 4.000  | 0.139 0.953 2.000   |
| if-a0-2 80-060       | -0.023 0.911 5.000  | 0.029 0.819 4.000   | -0.144 0.857 6.000  | 0.577 0.993 1.000   | 0.061 0.952 3.000   | 0.557 1.007 2.000   |
| if-a0-2 80-120       | 0.081 0.956 5.000   | 0.150 0.912 3.000   | -0.124 0.918 6.000  | 0.635 1.016 2.000   | 0.095 0.981 4.000   | 0.745 1.010 1.000   |
| if-a0-2 80-180       | 0.205 0.994 4.000   | 0.291 0.925 3.000   | -0.042 0.939 6.000  | 0.773 1.014 1.000   | 0.111 0.976 5.000   | 0.722 1.017 2.000   |
| if-a0-4 10-015       | -1.471 0.248 4.000  | -0.977 0.601 1.000  | nan nan nan         | -1.067 0.243 2.000  | -1.307 0.625 3.000  | -1.929 -0.594 5.000 |
| if-a0-4 10-030       | -0.928 0.814 5.000  | -0.240 1.270 1.000  | nan nan nan         | -0.494 0.791 3.000  | -0.499 0.792 4.000  | -0.465 0.927 2.000  |
| if-a0-4 10-060       | -0.430 1.204 5.000  | 0.683 1.454 1.000   | nan nan nan         | 0.319 1.083 3.000   | 0.178 1.002 4.000   | 0.499 1.316 2.000   |
| if-a0-4 10-120       | 0.590 1.560 1.000   | 0.523 1.347 2.000   | nan nan nan         | 0.279 1.246 4.000   | 0.278 1.311 5.000   | 0.487 1.321 3.000   |
| if-a0-4 10-180       | 1.485 1.843 1.000   | 0.529 1.361 2.000   | nan nan nan         | 0.491 1.362 4.000   | 0.352 1.271 5.000   | 0.524 1.340 3.000   |
| if-a0-4 20-015       | -0.850 0.359 2.000  | -1.030 0.236 4.000  | nan nan nan         | -1.036 0.530 5.000  | -0.795 0.539 1.000  | -0.918 0.368 3.000  |
| if-a0-4 20-030       | -0.585 0.740 5.000  | -0.139 0.871 2.000  | nan nan nan         | -0.529 0.611 4.000  | -0.382 0.655 3.000  | -0.109 0.795 1.000  |
| if-a0-4 20-060       | -0.333 0.970 5.000  | 0.313 1.029 2.000   | nan nan nan         | -0.295 0.793 4.000  | 0.321 0.952 1.000   | -0.031 1.031 3.000  |
| if-a0-4 20-120       | 0.370 1.121 2.000   | 0.346 1.050 3.000   | nan nan nan         | 0.189 1.071 5.000   | 0.389 1.109 1.000   | 0.284 1.091 4.000   |
| if-a0-4 20-180       | 0.667 1.161 1.000   | 0.559 1.130 2.000   | nan nan nan         | 0.409 1.122 4.000   | 0.441 1.047 3.000   | 0.352 1.117 5.000   |
| if-a0-4 40-015       | -1.602 -0.143 5.000 | -1.173 -0.066 1.000 | nan nan nan         | -1.204 0.117 2.000  | -1.250 -0.545 3.000 | -1.551 -0.701 4.000 |
| if-a0-4 40-030       | -0.228 0.833 3.000  | 0.086 0.601 1.000   | nan nan nan         | -0.550 0.458 4.000  | -0.179 0.689 2.000  | -0.552 0.675 5.000  |
| if-a0-4 40-060       | -0.112 0.852 5.000  | 0.522 0.837 2.000   | nan nan nan         | 0.254 0.781 3.000   | 0.566 0.908 1.000   | 0.101 0.833 4.000   |
| if-a0-4 40-120       | 0.174 0.968 5.000   | 0.405 0.896 2.000   | nan nan nan         | 0.363 1.023 3.000   | 0.546 0.981 1.000   | 0.318 1.014 4.000   |
| if-a0-4 40-180       | 0.559 1.007 3.000   | 0.627 0.931 1.000   | nan nan nan         | 0.236 1.015 5.000   | 0.588 1.013 2.000   | 0.263 1.038 4.000   |
| if-a0-4 80-015       | -1.156 -0.163 4.000 | -1.102 -0.047 3.000 | nan nan nan         | -1.024 -0.548 2.000 | -1.206 -0.229 5.000 | -0.976 -0.161 1.000 |
| if-a0-4 80-030       | -0.742 0.572 3.000  | -0.305 0.517 1.000  | nan nan nan         | -1.197 -0.029 4.000 | -0.694 0.290 2.000  | -1.241 -0.071 5.000 |
| if-a0-4 80-060       | -0.152 0.777 5.000  | 0.267 0.656 3.000   | nan nan nan         | 0.282 0.825 1.000   | 0.271 0.861 2.000   | 0.109 0.834 4.000   |
| if-a0-4 80-120       | 0.032 0.891 5.000   | 0.223 0.681 4.000   | nan nan nan         | 0.313 0.919 2.000   | 0.276 0.863 3.000   | 0.341 0.949 1.000   |
| if-a0-4 80-180       | 0.389 0.936 3.000   | 0.507 0.827 2.000   | nan nan nan         | 0.217 1.006 5.000   | 0.713 0.993 1.000   | 0.350 1.016 4.000   |
| bool-simple-1 10-015 | -1.626 -0.385 6.000 | -0.215 1.017 2.000  | -1.600 0.000 5.000  | 0.157 1.105 1.000   | -0.851 0.849 3.000  | -0.964 0.617 4.000  |
| bool-simple-1 10-030 | -0.589 0.857 6.000  | 0.253 1.165 3.000   | 0.000 1.111 4.000   | 0.600 1.086 1.000   | -0.011 0.820 5.000  | 0.504 1.122 2.000   |
| bool-simple-1 10-060 | 0.472 1.130 1.000   | 0.262 1.280 3.000   | -0.088 1.074 6.000  | 0.228 1.172 4.000   | 0.221 1.072 5.000   | 0.396 1.269 2.000   |
| bool-simple-1 10-120 | 0.660 1.402 1.000   | 0.418 1.332 2.000   | -0.219 1.029 6.000  | 0.128 1.171 5.000   | 0.414 1.277 3.000   | 0.195 1.164 4.000   |
| bool-simple-1 10-180 | 0.428 1.360 1.000   | 0.331 1.307 2.000   | -0.322 1.068 6.000  | 0.086 1.198 5.000   | 0.200 1.240 3.000   | 0.189 1.244 4.000   |
| bool-simple-1 20-015 | -0.931 0.453 5.000  | -0.249 0.170 1.000  | -0.487 0.489 3.000  | -1.166 -0.454 6.000 | -0.364 0.539 2.000  | -0.584 0.844 4.000  |
| bool-simple-1 20-030 | -0.831 0.510 6.000  | -0.043 0.784 1.000  | -0.591 0.567 5.000  | -0.302 0.727 4.000  | -0.253 0.495 3.000  | -0.117 0.879 2.000  |
| bool-simple-1 20-060 | 0.123 0.676 5.000   | 0.204 0.848 3.000   | -0.403 0.909 6.000  | 0.197 0.949 4.000   | 0.261 0.911 2.000   | 0.389 0.963 1.000   |
| bool-simple-1 20-120 | 0.591 1.088 1.000   | 0.254 1.062 4.000   | -0.254 0.909 6.000  | 0.245 0.992 5.000   | 0.333 1.006 3.000   | 0.449 1.102 2.000   |
| bool-simple-1 20-180 | 0.539 1.148 1.000   | 0.271 1.080 5.000   | -0.229 0.917 6.000  | 0.487 1.099 3.000   | 0.431 1.073 4.000   | 0.529 1.123 2.000   |
| bool-simple-1 40-015 | -1.303 -0.180 6.000 | -0.649 0.477 3.000  | -0.667 0.001 4.000  | -0.156 0.414 1.000  | -0.965 0.234 5.000  | -0.624 0.534 2.000  |
| bool-simple-1 40-030 | -0.844 0.485 6.000  | -0.195 0.574 3.000  | -0.001 1.025 1.000  | -0.838 0.550 5.000  | -0.122 0.422 2.000  | -0.648 0.117 4.000  |
| bool-simple-1 40-060 | 0.133 0.737 4.000   | -0.118 0.772 5.000  | -0.600 0.696 6.000  | 0.242 0.751 2.000   | 0.233 0.631 3.000   | 0.364 0.898 1.000   |
| bool-simple-1 40-120 | 0.665 0.955 2.000   | 0.223 0.936 5.000   | -0.270 0.838 6.000  | 0.572 0.954 4.000   | 0.792 0.891 1.000   | 0.585 0.994 3.000   |
| bool-simple-1 40-180 | 0.691 1.005 3.000   | 0.366 0.963 5.000   | -0.327 0.789 6.000  | 0.606 0.989 4.000   | 0.780 0.981 2.000   | 0.841 1.030 1.000   |
| bool-simple-1 80-015 | -1.481 0.061 6.000  | -1.249 -0.446 4.000 | -1.000 -0.500 3.000 | -0.652 -0.266 1.000 | -1.421 -0.463 5.000 | -0.902 -0.596 2.000 |
| bool-simple-1 80-030 | -0.825 0.246 4.000  | -0.250 0.238 1.000  | -1.013 -1.012 6.000 | -0.918 -0.424 5.000 | -0.571 0.254 3.000  | -0.376 0.333 2.000  |
| bool-simple-1 80-060 | -0.243 0.584 5.000  | 0.010 0.618 2.000   | -0.434 0.644 6.000  | -0.143 0.503 4.000  | -0.013 0.694 3.000  | 0.136 0.781 1.000   |
| bool-simple-1 80-120 | 0.300 0.868 1.000   | 0.225 0.818 4.000   | -0.340 0.804 6.000  | 0.242 0.891 3.000   | 0.197 0.820 5.000   | 0.269 0.897 2.000   |
| bool-simple-1 80-180 | 0.761 0.921 1.000   | 0.328 0.877 5.000   | -0.296 0.794 6.000  | 0.564 0.973 4.000   | 0.584 0.924 3.000   | 0.703 1.000 2.000   |

**Tabela D.4:** Tabela uspešnosti kombinirane funkcije na izbranih metodah za ocenjevanje pomembnosti atributov in vseh naborih podatkov pri podrobni analizi (del 4 od 5).

| Dataset             | <i>RedFN</i>        | <i>RdFSN</i>       | <i>LogON</i>       | <i>LeaN</i>        | <i>LeaGITc3APN</i> | <i>LeaTc3N</i>     |
|---------------------|---------------------|--------------------|--------------------|--------------------|--------------------|--------------------|
| adult 00-015        | 1.902 -0.906 2.000  | 1.557 -0.557 5.000 | nan -nan nan       | 1.777 -5.904 3.000 | 1.987 -2.126 1.000 | 1.762 -4.284 4.000 |
| adult 00-030        | 1.935 -0.576 1.000  | 1.886 -0.697 2.000 | nan -nan nan       | 1.550 -3.266 4.000 | 1.751 -2.504 3.000 | 1.528 -4.097 5.000 |
| adult 00-060        | 1.952 -0.628 1.000  | 1.462 -0.427 4.000 | nan -nan nan       | 1.383 -2.312 5.000 | 1.905 -2.261 2.000 | 1.820 -2.833 3.000 |
| adult 00-120        | 1.952 -0.402 1.000  | 1.678 -0.403 3.000 | nan -nan nan       | 1.660 -2.392 4.000 | 1.529 -1.090 5.000 | 1.809 -1.510 2.000 |
| adult 00-180        | 1.625 -0.258 4.000  | 1.714 -0.343 3.000 | nan -nan nan       | 1.735 -1.252 2.000 | 1.565 -1.112 5.000 | 1.983 -1.784 1.000 |
| ionosphere 00-015   | 1.429 -0.418 3.000  | 1.752 -0.794 1.000 | nan -nan nan       | 1.273 -2.757 5.000 | 1.461 -1.056 2.000 | 1.312 -4.132 4.000 |
| ionosphere 00-030   | 1.606 -0.348 2.000  | 1.891 -0.872 1.000 | nan -nan nan       | 1.566 -2.756 3.000 | 1.451 -0.757 4.000 | 1.244 -2.789 5.000 |
| ionosphere 00-060   | 1.485 -0.278 2.000  | 1.547 -0.539 1.000 | nan -nan nan       | 1.275 -1.182 4.000 | 1.329 -0.572 3.000 | 1.130 -1.263 5.000 |
| ionosphere 00-120   | 1.606 -0.217 2.000  | 1.660 -0.562 1.000 | nan -nan nan       | 1.385 -4.767 3.000 | 1.373 -0.963 4.000 | 1.220 -1.770 5.000 |
| ionosphere 00-180   | 1.687 -0.150 1.000  | 1.580 -0.333 2.000 | nan -nan nan       | 1.295 -1.716 4.000 | 1.303 -0.559 3.000 | 1.224 -1.234 5.000 |
| lung-cancer 00-015  | 1.388 -0.284 3.000  | 1.703 -0.588 1.000 | nan -nan nan       | 1.519 -6.237 2.000 | 1.251 -0.514 5.000 | 1.382 -2.351 4.000 |
| lung-cancer 00-030  | 1.484 -0.244 5.000  | 1.668 -0.401 3.000 | nan -nan nan       | 1.899 -8.296 1.000 | 1.630 -0.956 4.000 | 1.771 -7.654 2.000 |
| lung-cancer 00-060  | 1.431 -0.150 5.000  | 1.705 -0.239 1.000 | nan -nan nan       | 1.474 -7.397 4.000 | 1.660 -0.466 2.000 | 1.592 -6.192 3.000 |
| lung-cancer 00-120  | 1.482 -0.138 3.000  | 1.455 -0.127 4.000 | nan -nan nan       | 1.619 -3.256 2.000 | 1.749 -0.293 1.000 | 1.381 -1.875 5.000 |
| lung-cancer 00-180  | 1.534 -0.116 4.000  | 1.592 -0.113 3.000 | nan -nan nan       | 1.955 -3.965 1.000 | 1.755 -0.158 2.000 | 1.361 -1.175 5.000 |
| monks-1 00-015      | 1.325 -0.626 4.000  | 1.349 -0.585 3.000 | nan -nan nan       | 1.415 -1.078 2.000 | 1.424 -2.059 1.000 | 1.291 -0.877 5.000 |
| monks-1 00-030      | 1.255 -0.336 5.000  | 1.681 -0.666 2.000 | nan -nan nan       | 1.610 -2.048 3.000 | 1.726 -2.037 1.000 | 1.603 -0.889 4.000 |
| monks-1 00-060      | 1.318 -0.197 5.000  | 1.788 -0.327 1.000 | nan -nan nan       | 1.783 -1.043 2.000 | 1.728 -1.481 3.000 | 1.661 -0.852 4.000 |
| monks-1 00-120      | 1.512 -0.122 5.000  | 1.941 -0.162 1.000 | nan -nan nan       | 1.918 -1.199 2.000 | 1.887 -1.359 3.000 | 1.755 -0.916 4.000 |
| monks-1 00-180      | 1.477 -0.103 5.000  | 1.843 -0.166 3.000 | nan -nan nan       | 1.683 -0.531 4.000 | 1.875 -0.842 2.000 | 1.914 -0.807 1.000 |
| promoters 00-015    | 1.228 -0.329 5.000  | 1.572 -0.571 1.000 | nan -nan nan       | 1.446 -3.332 3.000 | 1.260 -0.373 4.000 | 1.473 -2.571 2.000 |
| promoters 00-030    | 1.237 -0.188 4.000  | 1.378 -0.418 1.000 | nan -nan nan       | 1.314 -1.488 3.000 | 1.185 -0.212 5.000 | 1.348 -1.348 2.000 |
| promoters 00-060    | 1.232 -0.129 2.000  | 1.434 -0.266 1.000 | nan -nan nan       | 1.163 -1.004 3.000 | 1.144 -0.147 4.000 | 1.134 -1.269 5.000 |
| promoters 00-120    | 1.285 -0.104 2.000  | 1.515 -0.222 1.000 | nan -nan nan       | 1.093 -1.160 4.000 | 1.187 -0.352 3.000 | 1.091 -1.196 5.000 |
| promoters 00-180    | 1.317 -0.088 2.000  | 1.495 -0.166 1.000 | nan -nan nan       | 1.146 -1.319 4.000 | 1.237 -0.262 3.000 | 1.091 -0.634 5.000 |
| voting 00-015       | 1.583 -0.333 4.000  | 1.736 -0.426 2.000 | 1.987 -0.347 1.000 | 1.618 -2.675 3.000 | 1.434 -0.782 5.000 | 1.329 -2.134 6.000 |
| voting 00-030       | 1.613 -0.208 1.000  | 1.557 -0.259 3.000 | 1.600 -0.313 2.000 | 1.148 -0.717 5.000 | 1.290 -0.470 4.000 | 1.132 -0.728 6.000 |
| voting 00-060       | 1.580 -0.161 1.000  | 1.518 -0.196 2.000 | 1.356 -0.186 3.000 | 1.211 -0.721 5.000 | 1.225 -0.329 4.000 | 1.152 -0.494 6.000 |
| voting 00-120       | 1.406 -0.122 2.000  | 1.464 -0.142 1.000 | 1.160 -0.188 4.000 | 1.158 -0.717 5.000 | 1.183 -0.314 3.000 | 1.154 -0.459 6.000 |
| voting 00-180       | 1.338 -0.079 2.000  | 1.461 -0.093 1.000 | 1.128 -0.177 6.000 | 1.148 -0.532 4.000 | 1.212 -0.196 3.000 | 1.132 -0.275 5.000 |
| zoo 00-015          | 1.935 -0.232 1.000  | 1.859 -0.225 2.000 | nan -nan nan       | 1.753 -1.829 4.000 | 1.859 -0.676 3.000 | 1.641 -1.438 5.000 |
| zoo 00-030          | 1.884 -0.133 3.000  | 1.838 -0.123 4.000 | nan -nan nan       | 1.945 -3.020 2.000 | 1.704 -0.610 5.000 | 1.968 -3.246 1.000 |
| zoo 00-060          | 1.953 -0.085 2.000  | 1.926 -0.082 4.000 | nan -nan nan       | 1.936 -2.647 3.000 | 1.978 -0.452 1.000 | 1.896 -2.277 5.000 |
| zoo 00-120          | 1.870 -0.051 2.000  | 1.924 -0.054 1.000 | nan -nan nan       | 1.680 -1.335 3.000 | 1.637 -0.344 5.000 | 1.642 -0.474 4.000 |
| zoo 00-180          | 1.866 -0.045 2.000  | 1.893 -0.044 1.000 | nan -nan nan       | 1.620 -0.668 5.000 | 1.772 -0.297 3.000 | 1.690 -0.488 4.000 |
| pima-indians 00-015 | 1.624 -0.815 1.000  | 1.551 -0.844 3.000 | nan -nan nan       | 1.379 -2.962 5.000 | 1.580 -1.911 2.000 | 1.418 -1.795 4.000 |
| pima-indians 00-030 | 1.662 -0.768 2.000  | 1.672 -0.973 1.000 | nan -nan nan       | 1.653 -3.302 3.000 | 1.385 -2.407 5.000 | 1.411 -2.736 4.000 |
| pima-indians 00-060 | 1.348 -0.268 5.000  | 1.380 -0.332 4.000 | nan -nan nan       | 1.689 -2.096 1.000 | 1.482 -0.763 3.000 | 1.559 -0.875 2.000 |
| pima-indians 00-120 | 1.498 -0.275 3.000  | 1.644 -0.326 2.000 | nan -nan nan       | 1.829 -3.137 1.000 | 1.365 -1.070 5.000 | 1.455 -1.134 4.000 |
| pima-indians 00-180 | 1.559 -0.232 2.000  | 1.577 -0.231 1.000 | nan -nan nan       | 1.454 -1.024 3.000 | 1.385 -0.593 4.000 | 1.371 -0.593 5.000 |
| avg-gen             | 0.051 0.460 3.793   | 0.489 0.850 2.927  | -0.141 0.309 3.895 | 0.354 0.728 3.450  | 0.365 0.743 3.577  | 0.408 0.761 2.907  |
| avg-real            | 1.560 -0.279 2.775  | 1.646 -0.372 2.050 | 1.446 -0.242 3.200 | 1.529 -2.476 3.225 | 1.521 -0.893 3.250 | 1.471 -1.886 4.050 |
| avg-size-015        | -0.254 -0.048 4.203 | 0.165 0.359 3.078  | -0.156 0.180 3.756 | 0.093 -0.092 3.055 | 0.046 0.178 3.266  | 0.055 -0.012 2.977 |
| avg-size-030        | -0.171 0.076 4.469  | 0.518 0.599 2.719  | -0.063 0.293 3.400 | 0.318 0.118 3.187  | 0.331 0.386 3.469  | 0.357 0.185 2.984  |
| avg-size-060        | 0.448 0.594 3.547   | 0.729 0.780 2.734  | -0.095 0.352 4.044 | 0.556 0.389 3.570  | 0.627 0.623 3.531  | 0.647 0.487 2.992  |
| avg-size-120        | 0.533 0.564 3.164   | 0.850 0.856 2.805  | -0.165 0.265 4.111 | 0.729 0.529 3.633  | 0.752 0.726 3.625  | 0.799 0.715 3.102  |
| avg-size-180        | 0.644 0.654 2.945   | 0.905 0.892 2.750  | -0.052 0.394 4.089 | 0.810 0.693 3.664  | 0.792 0.779 3.789  | 0.844 0.777 3.195  |
| avg-all             | 0.240 0.368 3.666   | 0.634 0.697 2.817  | -0.106 0.296 3.880 | 0.501 0.328 3.422  | 0.510 0.539 3.536  | 0.541 0.430 3.050  |

**Tabela D.5:** Tabela uspešnosti kombinirane funkcije na izbranih metodah za ocenjevanje pomembnosti atributov in vseh naborih podatkov pri podrobni analizi (del 5 od 5).