

Metoda umjetne inteligencije za rudarenje podacima iz vremenskih serija i implementacija na ljudskom EKG signalu

Velić, Marko

Doctoral thesis / Disertacija

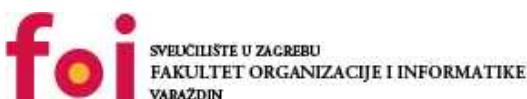
2014

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Organization and Informatics Varaždin / Sveučilište u Zagrebu, Fakultet organizacije i informatike Varaždin***

Permanent link / Trajna poveznica: <https://urn.nsk.hr/um:nbn:hr:211:684818>

Rights / Prava: [In copyright/Zaštićeno autorskim pravom.](#)

*Download date / Datum preuzimanja: **2024-05-12***



Repository / Repozitorij:

[Faculty of Organization and Informatics - Digital Repository](#)





Sveučilište u Zagrebu

FAKULTET ORGANIZACIJE I INFORMATIKE VARAŽDIN

MARKO VELIĆ

**METODA UMJETNE INTELIGENCIJE ZA
RUDARENJE PODACIMA IZ VREMENSKIH
SERIJA I IMPLEMENTACIJA NA LJUDSKOM
EKG SIGNALU**

- DOKTORSKI RAD -

Varaždin, 2014.

PODACI O DOKTORSKOJ DISERTACIJI

I. Autor

Ime i prezime	MARKO VELIĆ
Datum i mjesto rođenja	02. travnja 1984., Zagreb
Naziv fakulteta i datum diplomiranja	Fakultet organizacije i informatike Varaždin, 08. studeni 2007.
Sadašnje zaposlenje	Sveučilišni računski centar - Srce, Zagreb

II. Doktorska disertacija

Naslov	Metoda umjetne inteligencije za rudarenje podacima iz vremenskih serija i implementacija na ljudskom EKG signalu
Broj stranica, slika, tabela, priloga, bibliografskih podataka	115 stranica, 65 slika, 24 tablice, 11 grafikona, 3 priloga, 98 bibliografskih podataka
Znanstveno područje, smjer i disciplina iz koje je postignut akademski stupanj	Društvene znanosti, informacijske znanosti
Mentor ili voditelj rada	Prof. dr. sc. Mirko Čubrilo
Fakultet na kojem je rad objavljen	Fakultet organizacije i informatike
Oznaka i redni broj rada	

III. Ocjena i obrana

Datum prihvaćanja teme od Znanstveno-nastavnog vijeća	11.06.2013.
Datum predaje rada	31.12.2013.
Datum sjednice ZNV-a na kojoj je prihvaćena pozitivna ocjena rada	18.02.2014.
Sastav povjerenstva koje je rad ocijenilo	Prof. dr. sc. Neven Vrček, Prof. dr. sc. Mario Cifrek, Prof. dr. sc. Mirko Čubrilo
Datum obrane rada	12.05.2014.
Sastav povjerenstva pred kojim je rad obranjen	Prof. dr. sc. Neven Vrček, Prof. dr. sc. Mario Cifrek, Prof. dr. sc. Mirko Čubrilo
Datum promocije	

**SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE VARAŽDIN**

MARKO VELIĆ

**METODA UMJETNE INTELIGENCIJE ZA
RUDARENJE PODACIMA IZ VREMENSKIH
SERIJA I IMPLEMENTACIJA NA LJUDSKOM
EKG SIGNALU**

- DOKTORSKI RAD -

Varaždin, 2014.

Rad je izrađen na Fakultetu organizacije i informatike u Varaždinu. Za postupak predstavljen u ovom radu podnesena je patentna prijava pod brojem P20140414A pri Državnom zavodu za intelektualno vlasništvo Republike Hrvatske

Voditelj rada: Prof. dr. sc. Mirko Čubrilo

ZAHVALE

Zahvaljujem se...

Majci koja je nesebično dala baš sve što je mogla da do ove disertacije ikada dođe.

Mentoru prof. dr. sc. Mirku Čubrilu za koji ne postoje nepremostive prepreke i koji je svojom proaktivnošću pridonio završetku ovog istraživanja.

Ostalim profesorima i asistentima FOI-a, posebno dr. sc. Rubenu Piceku od čije je inicijative sve krenulo te prof. dr. sc. Nevenu Vrčeku koji me uveo u područje računalne analize EKG-a.

Posebno hvala prof. dr. sc. Goranu Klepcu koji mi je otvorio vrata svijeta strojnog učenja i rudarenja podacima, čije istraživanje je svojevrsni prethodnik ovom doktoratu i čiji je entuzijazam za znanost naprosto zarazan.

Kardiologu dr. sc. Siniši Caru na stručnim savjetima.

FOI-u kao instituciji koja je kolege i mene podržavala od najranijih studentskih dana do kasnijih poduzetničkih projekata.

Članovima povjerenstva prof. dr. sc. Mirku Čubrilu, prof. dr. sc. Nevenu Vrčeku i prof. dr. sc. Mariu Cifreku na vrlo vrijednim komentarima i sugestijama koje su pomogle u stvaranju završnog teksta.

Svim prijateljima koji su konkretno i moralno pomogli da se ovo istraživanje privede kraju.

Gradu Varaždinu na gostoprимstvu i nezaboravnim godinama...

SAŽETAK

Tehnološki razvoj u modernom društvu kao jednu od posljedica ima i povećan broj generiranih podataka čija brojnost predstavlja značajan tehnički i znanstveni izazov u smislu pohrane i obrade. Za podatke koji u sebi ne sadrže vremensku komponentu, metode i tehnike za pohranu i analizu su veoma razvijene, ali za podatke koji su producirani slijedno ovo je još uvijek izazov. Podaci u vremenskim serijama nisu podobni za analizu klasičnim statističkim metodama jer je svaki podatak mjerjenja direktno ovisan o prethodnom podatku mjerrenom na istom izvoru. Ovime je prekršeno temeljno načelo klasičnih statističkih metoda o nezavisnosti opservacija u uzorku. Jedan od složenijih problema u analizi vremenskih serija je analiza elektrokardiograma (EKG-a). Ovaj rad predlaže novu metodu za analizu vremenskih serija te predstavlja istraživanje u kojem je ista metoda primijenjena u analizi ljudskog EKG signala. EKG kao postupak relativno niskih troškova koji je k tome i neinvazivan jest jedna od osnovnih dijagnostičkih metoda. Kako dugotrajno pregledavanje mnogo-brojnih EKG valova može biti naporno i nepraktično za ljudskog eksperta, računalna analiza EKG signala je značajan znanstveni i tehnički izazov s mnogim potencijalnim primjenama. Problem analize EKG signala obuhvaća nekoliko područja istraživanja poput uklanjanja šumova i smetnji koje nastaju tijekom snimanja, detekcije otkucaja srca, analize ritma te raspoznavanja oblika EKG valova. Ovo istraživanje fokusirano je na detekciju otkucaja srca i raspoznavanje oblika valova. Inspiracija za razvoj metode dolazi iz spoznaja računalne neuroznanosti, a metoda je u okviru ovog istraživanja implementirana u programskom jeziku C++. Provedeni su eksperimenti u detekciji QRS kompleksa bez filtriranja signala, te detekciji QRS kompleksa i prepoznavanja oblika valova nakon filtriranja signala. U tu svrhu su implementirani i digitalni filtri. U istraživanju su dobiveni rezultati koji nadmašuju trenutno stanje tehnike te su dobivene spoznaje za daljnji razvoj i primjenu metode i u području računalnog vida. Postignuta je točnost detekcije otkucaja srca bez primjene filtara u prosjeku iznad 95% izračunato prema metodi unakrsne validacije nad svakim zapisom, te iznad 99% nakon filtriranja signala prema više realističnoj metodi testiranja baziranoj na subjektu te iznad 96% u raspoznavanju oblika EKG valova testirano prema preporukama AAMI standarda. Takvo testiranje realno simulira potencijalnu kliničku primjenu. U smislu računalnog vida, provedeni su eksperimenti u raspoznavanju rukom napisanih brojeva i drugih dvodimenzionalnih oblika. Rezultati u tim eksperimentima su približni trenutnom stanju tehnike i kreću se oko 90% točnosti u raspoznavanju rukom napisanih brojeva iz MNIST skupa podataka.

Ključne riječi: strojno učenje, rudarenje podacima, EKG, QRS, računalni vid, raspoznavanje uzoraka, vremenske serije, umjetna inteligencija, računalna neuroznanost

ABSTRACT

In this research, a new method (algorithm) of artificial intelligence for pattern recognition is proposed. The method is based on principles of human perception and it is a part of computer engineering domain, the field of artificial intelligence. Method is the result of perennial scientific research and development. The main implementation of the algorithm within the project is on the example of the human ECG signal analysis, which is one of the most demanding problems within the field of time series analysis. Research scope included software implementation and testing on the officially recognized databases of the human ECG signal (MIT-BIH Arrhythmia Database) by using the scientifically recognized metrics (specificity, sensitivity, positive predictivity etc.). The essence of the method is its algorithm, which, in the author's opinion, reminds of human perception principles. In the scientific literature no similar approach is yet known. The approach is based on a study of a specific field in Computational Neuroscience and also, on the conclusions about how brain neurons perceive stimuli coming from sensors (human senses). Beyond the analysis of ECG signals, the above method has many other applications, such as applications in finance, industry, energy, computer vision (recognition of 2D and 3D shapes or photographs after pre-processing) etc. Results achieved in the research are competitive with the current state of the art methods. Without signal filtering, QRS detection is accurate in more than 95% cases. After signal filtering, accuracy is above 99% tested with the subject-based methodology, which is the most realistic one. Heartbeat classification is accurate above 96% tested by the AAMI standard methodology. Handwritten character recognition is accurate around 90% (MNIST dataset). Methods are implemented in C++ programming language.

Keywords: Machine Learning, Data Mining, ECG, QRS, Computer Vision, Pattern Recognition, Time Series, Artificial Intelligence, Computational Neuroscience

S A D R Ž A J

Zahvala	V
Sažetak	VI
Abstract	VII
Sadržaj	IX
Popis slika	XIII
Popis tablica	XV
Popis grafikona	XVII
1. Uvod	1
1.1. Problem vremenskih serija	1
1.2. Rudarenje podacima iz vremenskih serija	1
1.3. Računalna analiza elektrokardiograma	2
2. Motivacija za istraživanje	4
3. Hipoteza i ciljevi istraživanja	6
4. Društveni i znanstveni doprinos rada	8
4.1. Rudarenje podacima iz vremenskih serija	9
4.2. Mogućnost implementacije unutar programskih paketa za strojno učenje	9
4.3. Primjena u analizi EKG signala	9
4.4. Primjena u računalnom vidu	10
5. Osnove rada srca i EKG kao dijagnostički postupak	11
6. Postojeći pristupi računalnoj analizi EKG-a	14
6.1. Testiranje metoda računalne obrade EKG-a	17

6.2.	Uklanjanje šumova i smetnji	18
6.3.	Detekcija otkucaja srca - QRS kompleksa	19
6.3.1.	AZTEC	20
6.3.2.	Pan-Tompkins algoritam	20
6.3.3.	Detekcija QRS kompleksa primjenom neuronskih mreža	21
6.3.4.	Stroj s potpornim vektorima u QRS detekciji	22
6.3.5.	Pristupi temeljeni na derivacijama, Hilbert, valičnim, EMD i sličnim transformacijama	22
6.3.6.	Ostali pristupi detekciji QRS-a	23
6.4.	Analiza ritma	23
6.5.	Raspoznavanje ostalih dijelova EKG signala	23
6.6.	Raspoznavanje oblika patoloških QRS kompleksa	23
7.	Medicinski zahtjevi za buduća istraživanja i kliničku primjenu	24
7.1.	P val	26
7.2.	T val	26
7.3.	ST segment	26
7.4.	Analiza više odvoda	26
7.5.	Individualne prilagodbe	27
8.	Vektori percepcije - metoda umjetne inteligencije za rudarenje podacima iz vremenskih serija	28
8.1.	Osvrt na terminologiju	29
8.2.	Inspiracija za razvoj nove metode	29
8.2.1.	Ljudski opisi oblika u vremenskim serijama	30
8.2.2.	Osnovni principi vizualne percepcije	30
8.3.	Matematički model i algoritam	34
8.3.1.	Koncept transformacije vremenske serije	36
8.3.2.	Segmentiranje signala	39
8.3.3.	Morfološke karakteristike	41
8.3.3.1.	Dinamički kumulativi	43
8.3.3.2.	Vremensko-morfološka determinanta	46
8.3.3.3.	Moguća proširenja	50
8.3.4.	Implementacija	50
8.3.5.	Vizualizacija	51
8.4.	Testiranje metode	51
8.4.1.	Podatkovni skup	51
8.4.1.1.	MIT-BIH AD baza	52
8.4.1.2.	Neprilagođenost baze predloženoj metodi i rješenje	53

8.4.2.	Problem nebalansiranih podataka	54
8.4.2.1.	Rješenja na razini podataka	56
8.4.2.2.	Rješenja na razini algoritama	57
8.4.3.	Odabir klasifikatora i primijenjeni pristup	59
8.4.4.	QRS detekcija nefiltriranih podataka	60
8.4.4.1.	Opis testa	61
8.4.4.2.	Rezultati	61
8.4.4.3.	Kritički osvrt	63
8.4.5.	Uklanjanje šuma	63
8.4.5.1.	Uklanjanje pomaka bazne linije	64
8.4.5.2.	Uklanjanje 60 Hz šuma	64
8.4.6.	QRS detekcija filtriranih podataka	65
8.4.6.1.	Opis testa	65
8.4.6.2.	Rezultati	66
8.4.7.	Raspoznavanje oblika EKG valova	68
8.4.7.1.	Testiranje bazirano na klasi	68
8.4.7.2.	Testiranje prema AAMI standardu	69
8.4.7.3.	Rezultati	71
8.4.8.	Prijedlog novih postupaka testiranja	74
8.5.	Primjena na više od jednog odvoda	75
8.6.	Analiza pogrešaka	76
8.7.	Primjena metode u nенадзiranom učenju	78
8.7.1.	Samoorganizirajuće mape	80
8.7.2.	Višedimenzionalno skaliranje	81
8.8.	Razmatranja o tehnikama za ubrzanje postupka učenja	81
8.8.1.	Analiza važnosti varijabli	82
8.8.2.	Analiza temeljnih komponenti	90
8.8.3.	Stratificiranje uzorka za učenje	90
9.	Primjena u području računalnog vida	91
9.1.	Raspoznavanje dvodimenzionalnih oblika	91
9.1.1.	Raspoznavanje rukom napisanih brojki	91
9.1.1.1.	Zaključivanje primjenom Bayesove uvjetne vjerojatnosti	92
9.1.1.2.	Rezultati	92
9.1.2.	Raspoznavanje složenijih 2D oblika	93
9.1.2.1.	Nenadzirano učenje i Mahalanobisova udaljenost	93
9.1.2.2.	Rezultati	94
9.2.	Razmatranja o raspoznavanju 3D oblika	94
9.3.	Razmatranja o raspoznavanju slika u boji	95

10.	Paralelizacija	96
11.	Buduća istraživanja	99
12.	Osvrt na pravne i etičke aspekte istraživanja	102
13.	ZAKLJUČAK	104
	LITERATURA	107

POPIS SLIKA

Broj	Naziv slike	Stranica
Slika 1.	Karakteristični dijelovi normalnog EKG odsječka	12
Slika 2.	Tipični koraci u računalnoj obradi EKG signala	16
Slika 3.	EKG signal u vremenskoj i frekvencijskoj domeni	17
Slika 4.	Morfološke i dinamičke karakteristike različitih EKG valova	18
Slika 5.	Različite vrste stanica s obzirom na inhibiciju signala. Stanica s ekscitatornim slojem (+) iznutra (slika a) i stanica s inhibirajućim slojem (-) iznutra (slika b)	31
Slika 6.	Skupina stanica koja reagira na kosu liniju	32
Slika 7.	Detekcija ruba temeljena na derivacijama	33
Slika 8.	Pojednostavljena neuronska mreža s jednim izlaznim neuronom	33
Slika 9.	Neuronska mreža s više izlaznih neurona	34
Slika 10.	Konceptualni prikaz metode	35
Slika 11.	Metoda klizećih prozora	37
Slika 12.	Metoda skačućih prozora	37
Slika 13.	Transformacija EKG signala	38
Slika 14.	Nekoliko odsječaka krivulje sa ilustriranim morfološkim razlikama koje se pokušavaju obuhvatiti vektorima kao rezultat transformacije. Istaknute su razlike u nagibu i površini (a), konkavnosti (b), dinamičkim kumulativima (c) i VMD komponentama vektora (d).	49
Slika 15.	Nekonzistentnosti u zapisu 108 iz MIT-BIH AD baze	55
Slika 16.	Uklanjanje pomaka bazne linije median filtrom	64
Slika 17.	Uklanjanje 60 Hz šuma	65
Slika 18.	Primjer rezultata bullseye testa (preuzeto iz [88])	74
Slika 19.	Promašene anotacije na signalu 101	76
Slika 20.	Detektirani a neoznačeni otkucaj u signalu 101	77
Slika 21.	Problematični dijelovi signala 104	77
Slika 22.	Izražene smetnje na signalu 105 i promašeni otkucaj	78

Slika 23.	Promašeni otkucaj na signalu 111	78
Slika 24.	Prvi T val detektiran kao QRS na signalu 215	79
Slika 25.	Transformacija slike brojke u vremensku seriju	91
Slika 26.	Primjeri pogrešno razvrstanih brojki	93
Slika 27.	Rezultati upita za dohvata sličnih oblika iz baze <i>Fish contours</i>	94

POPIS TABLICA

Broj	Naziv tablice	Stranica
	Tablica 1. Terminologija i sinonimi	29
	Tablica 2. Rasponi vrijednosti za oznake trenda i detaljnog trenda (REF)	40
	Tablica 3. Granice za kutni otklon primijenjene u istraživanju	40
	Tablica 4. Rasponi vrijednosti za oznake konkavnosti i detaljne konkavnosti	43
	Tablica 5. Granice za konkavnost primijenjene u istraživanju	43
	Tablica 6. Varijable transformacije primijenjene u istraživanju	47
	Tablica 7. Rezultati QRS detekcije nad nefiltriranim podacima	61
	Tablica 8. Matrica koštanja pojedinih klasifikacija	66
	Tablica 9. Rezultati QRS detekcije nad filtriranim podacima - 360 ms	66
	Tablica 10. Usporedba predložene metode i pristupa iz literature	68
	Tablica 11. Podjela MIT-BIH AD baze u podskup za učenje i podskup za testiranje	69
	Tablica 12. Originalne MIT-BIH AD klase (cijela baza bez isključivanja pejsmejkera)	70
	Tablica 13. Mapiranje MIT-BIH AD klasa u AAMI klase	70
	Tablica 14. Dinamičke značajke uključene u vektor	71
	Tablica 15. Matrica zabune za raspoznavanje oblika EKG valova temeljem prvog odvoda i svih atributa	71
	Tablica 16. Matrica zabune za raspoznavanje oblika EKG valova temeljem prvog odvoda i samo 30 najrelevantnijih atributa	72
	Tablica 17. Matrica zabune za raspoznavanje oblika EKG valova temeljem drugog odvoda	72
	Tablica 18. Matrica zabune za raspoznavanje oblika EKG valova ref. [61]	73
	Tablica 19. Matrica zabune za raspoznavanje oblika EKG valova ref. [95]	73
	Tablica 20. Matrica zabune za raspoznavanje oblika EKG valova ref. [16]	73
	Tablica 21. Usporedba uspješnosti različitih pristupa	73
	Tablica 22. Tablica relevantnosti značajki prema informacijskom dobitku	85
	Tablica 23. Tablica relevantnosti značajki prema ReliefF metodi	87
	Tablica 24. PCA eksperiment	90

POPIS GRAFIKONA

Broj	Naziv grafikona	Stranica
1.	Vizualizacija valova pomoću 4 dimenzije vektora percepcije	52
2.	Vizualizacija valova pomoću 5 dimenzija vektora percepcije	53
3.	Distribucija vrste valova u skupu filtriranih podataka za QRS detekciju	56
4.	Distribucija vrste valova za klasifikaciju (originalne anotacije)	57
5.	Distribucija vrste valova za klasifikaciju (AAMI anotacije)	58
6.	Problem nadziranog učenja u prostoru 3 dimenzije vektora percepcije	80
7.	Problem nенадзiranog učenja u prostoru 3 dimenzije vektora percepcije	81
8.	SOM MIT-BIH AD baze prema AAMI anotacijama - sjenčanje po zadnjoj programjeni površine	82
9.	SOM MIT-BIH AD baze prema AAMI anotacijama - sjenčanje po trajanju konkavnosti	83
10.	Rezultat optimizacije MDS algoritma nad MIT-BIH AD bazom prema AAMI anotacijama primjenom Euklidske udaljenosti	84
11.	Rezultat optimizacije MDS algoritma nad MIT-BIH AD bazom prema AAMI anotacijama primjenom ReliefF udaljenosti	85

P O P I S P R I L O G A

Prilog 1 - Vizualizacija metode primjenom SOM	II
Prilog 2 - Vizualizacija metode primjenom PolyViz prikaza	XIV
Prilog 3 - DVD medij priložen disertaciji	XXII

1. Uvod

1.1. Problem vremenskih serija

Danas, u svim aspektima ljudskog života i djelovanja postoje mnogi izvori podataka i mјerenja koji slijedno produciraju podatke. Takve podatke nazivamo podaci u vremenskim serijama ili vremenskim nizovima. S obzirom na ustaljenost termina "vremenske serije", u nastavku se koristi taj termin koji podrazumijeva i "vremenski niz". Podaci iz vremenskih serija su u praktičnim primjenama vrlo brojni te njihova pohrana i obrada predstavlja tehnički i znanstveni izazov. U svrhu pohrane i brzog pristupa velikim količinama podataka razvijeni su posebni koncepti ne-relacijskih baza podataka, a u svrhu obrade posebne tehnike proizašle iz statistike i strojnog učenja koje nazivamo rudarenje podacima ili dubinska analiza podataka. Rudarenje podacima iz vremenskih serija jedno je od najizazovnijih područja unutar discipline rudarenja podacima. Rudarenje podacima koji su ne-temporalnog karaktera veoma je razvijeno, no problemi poput grupiranja (ili klasteriranja), razvrstavanja (ili klasifikacije), otkrivanja uzoraka i predikcije, još nisu dovoljno istraženi niti zastupljeni u modernim alatima. Podaci u vremenskim serijama nisu podobni za analizu klasičnim statističkim metodama zbog međusobne zavisnosti opservacija tj. podaci su uvijek zavisni o prethodnim podacima iz iste serije.

1.2. Rudarenje podacima iz vremenskih serija

Obično, prije primjene metoda za rudarenje podacima iz vremenskih serija u svrhu ostvarivanja gore spomenutih zadataka, podaci trebaju biti filtrirani i/ili transformirani i/ili reducirani. Ove aktivnosti se nazivaju preprocesiranje. Trenutno postoje mnoge metode za ostvarivanje navedenih zadaća. Tehnike za reduciranje podataka uključuju Fourierove transformacije, valične transformacije itd. Navedene tehnike podatke iz vremenske domene prikazuju u frekvencijskoj domeni o čemu će više rijeći biti kasnije u ovom radu. Kod pronalaženja zanimljivih uzoraka ili analiziranja sličnosti različitih vremenskih serija, vrlo često je potrebno različite dijelove, ili različite vremenske serije „svesti na zajednički nazivnik“. Takve postupke nazivamo transformacijama. Transformacije uključuju: pomicanje, skaliranje, vremensko skaliranje i sl. [81]. Spomenute metode i zadaci analize vremenskih serija, vrlo često se kombiniraju u jedinstvene modele u cilju rješavanja specifičnih problema. Jedan od primjera u kojem se metode kombiniraju u svrhu ostvarenja cilja je identificiranje sličnosti između različitih vremenskih serija. Primjerice, u svrhu analize sličnosti DNA sekvenci čovjeka i čimpanze [82] ili u svrhu identifikacije povezanosti kre-

tanja vrijednosnica, indeksa i proizvoda financijskog tržišta [87]. Pored ovih analitičkih i algoritamskih problema, još jedan aspekt analize vremenskih serija je vizualizacija. Vizualizacija je važan mehanizam za prezentiranje obrađene vremenske serije za daljnju analizu od strane korisnika. Također, vizualizacija je i moćan alat za realizaciju nekih zadataka rudarenja podacima poput traženja uzorka, izvršavanje upita (engl. query by example) itd. [28]. Analiza vremenskih serija svoju primjenu nalazi u detekciji anomalija u raznim sustavima - npr. računalnim mrežama [25], medicini - npr. analiza ljudskog EKG signala [63] ili predviđanje astmatičnih napadaja uzrokovanih alergenima u zraku [56], financijama - npr. tehnička analiza vrijednosnica ili analiza zavisnosti financijskih instrumenata [87], ekologiji [59], sigurnosti - npr. predviđanje poplava [13], prepoznavanju dvodimenzionalnih oblika i trodimenzionalnih objekata [48] te mnogim drugim područjima i djelatnostima. U novije vrijeme, sve su češće integracije metoda specifičnih za analize vremenskih serija sa metodama za klasično rudarenje podacima tj. rudarenje ne-temporalnih podataka. Ovakve integracije svoju primjenu nalaze u rješavanju problema grupiranja, razvrstavanja, pronalaženja uzorka i sezonskih oscilacija [48], ali i u predviđanju [12]. O popularnosti i važnosti analize vremenskih serija u industriji, a ne samo u znanstvenoj zajednici, dovoljno govori i činjenica da vodeći svjetski proizvođači statističkih alata i računalnih paketa za rudarenje podacima, vremenske serije uključuju u svojim novijim verzijama, a posebnu pažnju posvećuju im i u svojim službenim publikacijama [80],[39].

1.3. Računalna analiza elektrokardiograma

Ovaj rad predstavlja novu metodu analize vremenskih serija te opisuje praktičnu implementaciju u analizi ljudskog elektrokardiograma (EKG). EKG je zapis varijacije bio-električkog potencijala snimljenog kroz vrijeme na površini tijela [86]. U radu je prikazano trenutno stanje tehnike u pogledu analize EKG signala te je osim literature iz područja informacijskih znanosti i računarstva obrađena i medicinska literatura u svrhu identifikacije problema koji još nisu riješeni, a stoje na putu primjene metoda naprednog računarstva u praksi tj. kliničkoj dijagnostici. U računalnoj analizi EKG-a mnogi od postojećih problema su istraživani desetljećima te su postignuti vrlo dobri rezultati. No ipak, klinička primjena navedenih dostignuća je još uvjek upitna. Veliki napredak postignut je na području uklanjanja šuma, detekcije otkucaja srca (tzv. detekcija QRS kompleksa), analize srčanog ritma (engl. heartrate variability analysis - HRV) te u manjoj mjeri u raspoznavanju oblika EKG valova. Trenutna istraživanja provedena su sa različitim pristupima testiranju algoritama te će ovaj rad pokušati razjasniti testne metodologije i predstaviti rezultate predložene metode na više načina tj. obrađujući više problema kako bi rezultati bili usporedivi sa

ostalim radovima iz područja. Kako algoritmi postaju sve moćniji i precizniji, počinju se pojavljivati i neusklađenosti između algoritamskih mogućnosti i postojećih baza podataka tj. EKG signala za testiranje algoritama. Ovaj rad opisuje neusklađenosti između testnih metodologija i potreba u kliničkoj praksi te predlaže i neke nove načine testiranja. Osim analize EKG signala, predstavljena metoda primjenjiva je i u širem smislu u domeni računalnog vida te se u ovom radu daje kratki prikaz primjene i u tom području.

2. Motivacija za istraživanje

Bolesti srca i krvožilnog sustava su najčešći uzrok smrti u razvijenim zemljama uz rastući trend incidencije uslijed modernog stila života. Motivacija za istraživanje proizlazi iz trenutnog stanja tehnike u kojem ne postoji metoda koja je u stanju pouzdano detektirati otkucaje srca temeljem EKG signala (QRS komplekse) bez prethodnog filtriranja signala i faze traženja unatrag tj. bez složenih metoda pretprocesiranja signala. Kada bi postojala takva metoda, to bi omogućilo brže programske implementacije za sustave koji će se izvoditi u realnom vremenu i u kombinaciji sa manje zahtjevnim hardverom. Također, stanje tehnike ne poznaje pouzdane metode koje su u stanju klasificirati oblike u EKG signalu s visokom točnošću što je nužan preduvjet za automatsku dijagnostiku odnosno pomoći kardiologima u dijagnostici patoloških pojava u radu srca očitovanih patološkim oblicima EKG signala. Detekcija QRS kompleksa i raspoznavanje (klasifikacija) oblika EKG valova su dva odvojena problema. QRS detekcija omogućava izračun srčanog ritma i analize temeljene na ritmu, dok raspoznavanje oblika omogućava identifikaciju šireg skupa patologija. Iako pouzdano detektiranje otkucaja srca bez primjene digitalnih filtera predstavlja zanimljiv stručni i znanstveni izazov te je u tom smislu taj problem i postavljen u hipoteze ovog rada, uklanjanje šumova i smetnji svakako je nužan dio sustava koji mogu biti korišteni u kliničkoj praksi gdje se zahtjeva izrazito velika pouzdanost i točnost algoritama. Zbog toga su u ovom istraživanju analizirani i implementirani digitalni filtri za uklanjanje šuma te je QRS detekcija testirana i nakon uklanjanja šuma. Testiranje je obavljeno prema tzv. pristupu baziranom na subjektu što je pristup koji najrealnije simulira primjenu u kliničkoj praksi. Pouzdano prepoznavanje oblika valova u EKG signalu omogućilo bi rano otkrivanje potencijalno opasnih srčanih aritmija te omogućilo pravovremenu medicinsku skrb za pacijenta. U znanstvenoj i stručnoj literaturi su opisani prototipovi sustava za mobilno praćenje i analizu rada srca, no takvim sustavima nedostaje pouzdano i precizno prepoznavanje patologija u EKG signalu. Integracija metode opisane u ovom radu sa takvim sustavima značila bi značajan pomak u telemedicini.

3. Hipoteza i ciljevi istraživanja

H1: Osmišljena i programski implementirana metoda za detekciju QRS kompleksa EKG signala će, bez prethodnog filtriranja signala i bez faze traženja unatrag, testirana na signalima iz baze podataka MIT-BIH Arrhythmia Database, biti usporediva sa trenutačnim dosezima znanosti i pripadajuće tehnologije. Podhipoteze rada su sljedeće:

H1A Metoda će imati prosječnu osjetljivost iznad 95%,

H1B Metoda će imati prosječnu pozitivnu prediktivnost iznad 95%,

H1C Metoda će imati prosječni stupanj pogreške manji od 5% i

H1D Metoda će imati prosječnu općenitu točnost algoritma iznad 95%.

Prvi cilj istraživanja je razviti algoritam koji će biti u mogućnosti detektirati QRS komplekse iz zapisa signala "MIT-BIH Arrhythmia Database" baze EKG signala bez preprocesiranja signala tj. njihovog filtriranja i faze traženja unatrag.

Drugi cilj istraživanja je implementirati novu metodu tj. algoritam u programskom kodu.

Treći cilj istraživanja je testirati novu metodu (algoritam) nad "MIT-BIH Arrhythmia Database" bazom nefiltriranih EKG signala te provjeriti mjere uspješnosti algoritma pomoću izračuna osjetljivosti, pozitivne prediktivnosti, stupnja pogreške i općenite točnosti algoritma nad svim zapisima iz baze, a potom i prosječno, a u svrhu usporedbe sa dosad poznatim metodama.

Četvrti cilj rada je implementirati digitalne filtre za uklanjanje smetnji i šuma te testirati metodu na problemu detekcije otkucaja srca po metodologiji testiranja baziranom na subjektu.

Peti cilj istraživanja je testirati metodu na filtriranom signalu u svrhu raspoznavanja oblika EKG valova tj. patoloških morfologija valova koje upućuju na nepravilnosti u radu srca prema metodologiji koju propisuje Udruženje za unaprjeđenje medicinske instrumentacije (AAMI - engl. The Association for the Advancement of Medical Instrumentation).

Šesti cilj je testirati metodu na općenitijem problemu računalnog vida tj. u raspoznavanju dvodimenzionalnih oblika.

4. Društveni i znanstveni doprinos rada

Društveni i znanstveni doprinos rada očituje se u nekoliko područja te je opisan u nastavku.

4.1. Rudarenje podacima iz vremenskih serija

Uslijed dokazane učinkovitosti, predložena metoda znači doprinos disciplini rudarenja podacima iz vremenskih serija u smislu preciznijeg prepoznavanja oblika iz vremenskih serija, sezonskih oscilacija i sličnih problema, a čije su primjene moguće u mnogim aspektima ljudskog života i djelovanja.

4.2. Mogućnost implementacije unutar programskih paketa za strojno učenje

Osim same teorijske razrade predložene metode, istraživanje za rezultat ima i programsku implementaciju metode što ju čini prikladnom za korištenje unutar alata za rudarenje podacima ili programskih paketa za strojno učenje i računalni vid. Ovo predstavlja praktičan doprinos koji će omogućiti nove načine istraživanja vremenskih serija, ali i povezivanje vremenskih serija sa ne-vremenskim atributima te omogućiti primjene postojećih metoda strojnog učenja u rješavanju novih problema.

4.3. Primjena u analizi EKG signala

Što se tiče primjene metode u analizi EKG signala, ona će omogućiti implementaciju točnih i brzih QRS detektora u sustave za praćenje i analizu rada srca jer metoda za detekciju QRS kompleksa, a samim time i analizu srčanog ritma, ne zahtijeva implementaciju filtara i faze traženja unatrag (engl. search back). Programska implementacija nove metode omogućuje kasniju implementaciju napredne analitike srčanog ritma i u sustave za mobilno praćenje i analizu rada srca koji sa razvojem mobilnih uređaja postaju sve popularniji.

Kako se nova metoda pokazala uspješnom i u prepoznavanju oblika EKG valova, a ne samo u detekciji ritma temeljem detekcije QRS kompleksa, to će za posljedicu imati mnoge mogućnosti daljnog znanstvenog rada.

Prepoznavanje oblika EKG valova je još neistraženo područje, a izučavanje povezanosti oblika valova i razmaka među karakterističnim dijelovima EKG valova sa određenim patološkim stanjima (i u smislu dijagnostike, ali i u smislu predikcije) dosad zbog nerazvijenih analitičkih metoda nije bilo moguće.

Osim dijagnostičke funkcije, nova metoda bi mogla imati utjecaj u disciplini biometrije s obzirom da u literaturi postoje čvrste naznake kako je ljudski EKG signal biometrijska karakteristika, što znači da je jedinstven za svaku osobu. Također, zbog nepostojanja snažnih analitičkih metoda, praktična provjera ovoga do sada nije bila moguća.

4.4. Primjena u računalnom vidu


U radu su prikazane tehnike kako se rudarenje podacima iz vremenskih serija može primijeniti i nad podacima koji izvorno nisu vremenska serija već rezultat transformacije originalnih podataka iz primjerice slike, dvodimenzionalnog ili trodimenzionalnog obrisa. Stoga će nova metoda svoj doprinos dati i disciplinama prepoznavanja uzorka i računalnom vidu.

5. Osnove rada srca i EKG kao dijagnostički postupak

Srce je vitalni organ koji služi kao pumpa za cirkuliranje krvi kroz krvožilni sustav. Sam srčani mišić sastoji se od nekoliko različitih dijelova sačinjenih od vrlo specijaliziranih stanica koje svojim karakteristikama omogućavaju pravilan rad srca. Tako u srcu nalazimo stanice specijalizirane za vrlo brzo provođenje električnih impulsa, stanice za vrlo sporo provođenje ili pak stanice koje uopće ne provode električne impulse. Zahvaljujući tome, u srčanom se mišiću u koordiniranom radu pomoću električnih impulsa naizmjence stežu i otpuštaju pojedini dijelovi te na taj način stvaraju razlike u tlaku u pojedinim komorama i žilama koje odvode krv u pravom smjeru. Krv koja uslijed tog procesa cirkulira krvožilnim sustavom opskrbљuje tijelo kisikom i hranjivim tvarima te istovremeno odvodi štetne tvari iz stanica. Najočitiji dijelovi srca su atriji (predklijetke) i ventrikuli (klijetke) sa svojim lijevim i desnim instancama. Glavni gradivni dio srca je miokard ili srčani mišić koji u osnovi sadrži poprečnoprugaste mišićne stanice i provedbene stanice.

Elektrokardiogram (EKG ili engl. ECG) jest snimak varijacije bio-električkog potencijala na površini tijela kroz vrijeme, a koji odražava otkucaje ljudskog srca [10]. Svaki srčani ciklus na EKG-u normalno je okarakteriziran slijednim valnim oblicima znanim kao P val, QRS kompleks i T val, tako da su vremenski intervali između početka i kraja pojedinih valova značajni te odražavaju fiziološke procese koji se odvijaju u srcu. Svaki normalni (zdravi) srčani impuls kreće iz tzv. sinusatrijskog čvora (engl. sinoatrial node, kraće: SA čvor) koji se nalazi u desnom atriju. SA čvor je pod kontrolom nesvesnog dijela živčanog sustava tzv. autonomnog živčanog sustava i endokrinog sustava. SA čvor u srcu služi kao prirodni pejsmejker (engl. pacemaker) odnosno zadaje ritam samom srcu. Zdravi ritam je onaj između 60 i 100 otkucaja u minuti sa prosjekom oko 70. Nakon nastanka u SA čvoru, električni impuls se ravnomjerno širi stanicama miokarda atrija te se zahvaljujući izolacijskom sloju između atrija i ventrikula ne nastavlja širiti dalje u ventrikule već nakon depolarizacije atrija dolazi do atrioventrikularnog čvora (kraće: AV čvor). Dosad opisani put električnog impulsa kod uspravnog čovjeka sa normalno pozicioniranim srcem možemo zamisliti kao put signala prema dolje ulijevo te je na EKG snimci taj signal vidljiv kao P val. Taj put signala kroz stanice miokarda atrija koje propuštaju signal "srednjom" brzinom možemo prikazati kao mali depolarizacijski vektor istog smjera (prema dolje lijevo). AV čvor je sačinjen od stanica koje zbog svog oblika, međusobnog rasporeda i biokemijskih karakteristika vrlo sporo provode električne impulse te se na taj način prirodno stvara pauza u propagiranju električnog impulsa kroz srce što omogućava krvi da se u potpunosti isprazni iz atrija u ventrikule. Ova pauza je na EKG snimci vidljiva kao gotovo ravna linija između P vala i QRS kompleksa. Nakon pauze tj. sporog prolaska impulsa kroz AV čvor, električna struja dolazi do stanica koje su svojim oblikom, rasporedom i

biokemijskim svojstvima specijalizirane za vrlo brzu propagaciju tzv. Purkinjeova vlakna. Dio srca koji ovim vlaknima obavlja ventrikule naziva se Hissov snop. Paralelno se signal grana u lijevu i desnu granu, a lijeva grana depolarizira septum koji se nalazi između ventrikula. Ova faza se može prikazati kao mali depolarizacijski vektor prema gore desno. Taj je vektor malen zbog male površine septuma i na EKG signalu uzrokuje mali Q val. Neposredno nakon toga djelovanjem brzih Purkinjeovih vlakana depolarizira se i cijeli ventrikul gotovo istovremeno od unutra prema van, a obzirom da je lijevi ventrikul skoro tri puta većeg volumena od desnog, ova faza može se prikazati kao veliki vektor prema dolje ulijevo i na EKG signalu ostavlja trag visokog i kratkotrajnog R zupca. Zadnji depolarizacijski događaj što se tiče ventrikula je depolarizacija gornjeg dijela lijevog i desnog ventrikula koja se može izraziti kao vektor prema gore udesno i na EKG signalu se odražava kao mali S val. Istovremeno sa depolarizacijom ventrikula događa se i repolarizacija atrija, no ona je uslijed male amplitude nevidljiva na EKG signalu tj. maskirana QRS kompleksom. Nakon nekog vremena počinje repolarizacija ventrikula koja se zbog kontrakcije ventrikula događa izvana prema unutra pa se cijeli proces može aproksimirati vektorom srednje veličine (uslijed srednje brzine propagacije signala kroz miokard) prema gore udesno. Repolarizacija ventrikula na EKG signalu je vidljiva kao T val. Primjer normalnog EKG signala sa pripadajućim valovima i odsjećima prikazan je na slici 1.



Slika 1: Karakteristični dijelovi normalnog EKG odsječka

Iz opisanog procesa nastanka jednog otkucaja srca i manifestacije pojedinih faza na EKG signalu, jasno je da će većina poremećaja u radu srca biti vidljiva i u pripadajućem EKG signalu kao odstupanje od normalnih EKG oblika te stoga EKG predstavlja vrlo koristan i pouzdan dijagnos-

tički alat.

6. Postojeći pristupi računalnoj analizi EKG-a

Računalna analiza EKG signala je ideja stara preko 40 godina. Prvi radovi iz ovog područja javljaju se krajem 60-ih godina 20. stoljeća [62], [11]. Važnost snimanja i analize EKG signala u smislu smanjenja smrtnosti hospitaliziranih pacijenata koji su doživjeli akutni infarkt srčanog mišića, a uslijed odgovarajuće brige u jedinicama intenzivne njegе dokazana je u studijama s početka 70-ih godina 20. stoljeća [91]. Ubrzo nakon toga, počinje se i sa analiziranjem performansi metoda za automatsku detekciju srčanog ritma [94].

Kako je opisano ranije, ljudski EKG signal sastoji se od nekoliko karakterističnih točaka odnosno valova koji odražavaju aktivnosti fizioloških procesa u srcu. Već spomenuta slika 1. prikazuje te valove i točke. Važno je napomenuti da je na ovoj slici prikazan idealni EKG signal, tj. EKG signal bez prisutnosti ranije spomenutih šumova i smetnji. Već pri prvom pogledu na sliku signala uočavaju se visoki i strmi dijelovi signala koje nazivamo R zubac. Većina algoritama koji su trenutno poznati za cilj imaju prepoznavanje upravo ovog dijela EKG signala. Takvi algoritmi nazivaju se QRS detektori jer njihovo prepoznavanje R zupca zapravo podrazumijeva prepoznavanje QRS kompleksa koji uključuje lokalne minimume lijevo i desno od R zupca. QRS kompleks zapravo odražava jedan otkucaj srca, a ispravno detektiranje QRS kompleksa, osnova je za analizu srčanog ritma. Iako se velik broj patoloških stanja ne može detektirati samo na temelju srčanog ritma već je potrebno analizirati oblike cjelokupnog EKG signala, među postojećim algoritmima rijetki su oni koji detektiraju ostale dijelove signala. Ovo će biti obrađeno u nastavku rada.

Stanje tehnike (engl. state of the art) u smislu najvrjednijih dostignuća očituje se u metodama koje postižu veoma visoke rezultate detekcije QRS kompleksa EKG signala mjereno prema standardima koji će biti opisani u idućim poglavljima. „State of the art“ metodama smatraju se one koje imaju osjetljivost, pozitivnu prediktivnost i općenitu točnost iznad 95% [10]. Trenutne metode postižu vrlo visoke rezultate u detekciji QRS kompleksa i sve se izvode nad filtriranim signalima te implementirajući fazu traženja unatrag (engl. search back). Faza traženja unatrag je zapravo odgovor na nekoliko problema koji se javljaju prilikom detekcije otkucaja. Prvi je jedna negativna posljedica filtriranja izvornog signala, a to je promjena morfologije izvornog signala nakon filtriranja gdje se ekstremi krivulje vrlo često nakon filtriranja pomaknu za nekoliko vremenskih jedinica, najčešće u smjeru prolaska filtra. Zbog tog posmaka u filtriranom signalu, nakon identifikacije potencijalnog R zupca QRS kompleksa, ANSI standard dozvoljava traženje stvarnog R zupca u originalnom signalu u intervalu od 150 ms ispred ili iza točke koja je pronađena u filtriranom signalu [10]. Drugi razlog je postojanje oštih i po amplitudi visokih T valova, te s druge strane malih i širokih QRS kompleksa kod nekih pacijenata. Stoga je potrebno ugraditi dodatnu lo-

giku kako bi se prilikom QRS detekcije izbjegla detekcija T valova, a omogućila uspješna detekcija malih QRS kompleksa.

Općenito, većina metoda računalne obrade EKG signala, bilo da se radi o QRS detekciji ili o klasifikaciji aritmija, podrazumijevaju dva osnovna koraka prije same detekcije, odnosno klasifikacije. Prvi korak je preprocesiranje signala (uklanjanje šuma), a sljedeći je izlučivanje značajki. Shematski prikaz ovih koraka prikazan je na slici 2.




Slika 2: Tipični koraci u računalnoj obradi EKG signala

Svaki signal, pa tako i EKG, može se osim u vremenskoj, prikazati i u frekvencijskoj domeni. Vremenska domena prikazuje promjene vrijednosti neke varijable kroz vrijeme, dok frekvencijska domena zapravo prikazuje koliko signala leži u nekom frekvencijskom pojasu. Primjer transformacije signala iz vremenske u frekvencijsku domenu su Fourierove transformacije koje izvorni signal pretvaraju u (potencijalno beskonačni) skup sinusoida (sinusi i kosinusi) različitih amplituda i frekvencija. Signal iz frekvencijske domene može se transformirat natrag u vremensku domenu inverznom Fourierovom transformacijom. Slika 3 prikazuje signal transformiran iz vremenske u frekvencijsku domenu pomoću Fourierove transformacije. Na slici je vidljiva istaknuta komponenta od 60 Hz koja je karakteristična za elektroenergetske sustave koji rade na toj frekvenciji. To je šum nastao uslijed smetnje gradske mreže u okolini snimanja i o njemu će biti riječi u narednim poglavljima.

Metode koje se temelje na tzv. nadziranom učenju tj. metode koje zahtijevaju uzorak za učenje nad kojim se gradi klasifikacijski model, koriste postojeće metode za klasifikaciju (npr. neuronske mreže, stroj s potpornim vektorima i sl.), a kreativnost autora metoda zapravo se očituje u pronalaženju značajki (varijabli) koje se onda daju kao ulaz klasifikatoru. Značajke mogu biti dobivene iz vremenske domene signala ili iz frekvencijske domene te odražavati morfološke karakteristike vala ili dinamičke karakteristike. Primjeri različitih morfoloških i dinamičkih karakteristika prikazani su na slici 4. Na slici je vidljivo kako različito označeni (anotirani) valovi imaju različite oblike (morfološke karakteristike), ali su i razmaci među tim valovima nepravilni (dinamičke karakteristike).


Možemo ustvrditi da je pronalaženje novih značajki ključni korak u cijelom procesu i ovo istraživanje je fokusirano upravo na njega. Nova metoda koja se predlaže u ovom radu je zapravo nova metoda za izlučivanje značajki iz signala.



Slika 3: EKG signal u vremenskoj i frekvencijskoj domeni

6.1. Testiranje metoda računalne obrade EKG-a

Standardizacija na području računalne obrade EKG signala započela je 1980. g. pod pokroviteljstvom Europske Komisije u okviru projekta „Common Standards for Quantitative Electrocardiography (CSE)“ [92]. Udruženje za unaprjeđenje medicinske instrumentacije - AAMI također je razvilo standard za testiranje i objavu rezultata u raspoznavanju aritmija tj. klasifikaciji valova ili grupa valova EKG signala (ANSI/AAMI EC57:1998/(R)2008) [27]. I u smislu QRS detekcije i u smislu klasifikacije aritmija, standardi preporučaju, a istraživači najčešće koriste MIT-BIH Arrhythmia Database bazu podataka EKG signala [74]. Algoritmi koji su predstavljeni znanstvenoj i stručnoj zajednici evaluiraju se na temelju parametara koji označavaju njihovu uspješnost prepoznavanja QRS kompleksa ili klase aritmija. Web mjesto na kojem su baze poput spomenute MIT-eve javno dostupne zove se Physionet [31]. EKG zapisi u takvim bazama su anotirani, što znači da su u njima, osim samog zapisa EKG signala, sadržani i zapisi o pojedinim artefaktima koji se u signalu pojavljuju. Primjeri takvih artefakata su: normalni otkucaj srca, PVC (engl. Premature Ventricular



Slika 4: Morfološke i dinamičke karakteristike različitih EKG valova

lar Contraction) kontrakcija, F (engl. Fusion beat) kontrakcija i sl. Ovakve baze signala sadrže primjere signala koji sadrže različita patološka stanja, promjene ritma, različite šumove i smetnje te su zbog toga dobar materijal za provođenje testova. Prilikom mjerjenja uspješnosti detekcije pojedinih otkucaja u EKG signalu, mjeri se koliko je puta algoritam uspješno detektirao stvarni otkucaj srca (TP - engl. True Positive), koliko puta je detektirao otkucaj tamo gdje ga u stvarnom signalu nije bilo (FP - engl. False Positive) i koliko puta R zubac nije detektiran (FN - engl. False Negative). Na temelju navedenih mjera računaju se osjetljivost algoritma (Se - engl. Sensitivity), pozitivna prediktivnost (P ili +P - engl. Positive Predictivity) i općenita točnost algoritma (CA - engl. Classification Accuracy ili Acc - engl. Accuracy). Također, iz navedenih mjera može se dobiti i mjera za grešku algoritma koju nazivamo omjer šansi pogreške (DER - engl. Detection Error Rate). U nastavku su dane formule za navedene mjere [64]:

$$\begin{aligned}
 Se(\%) &= 1 - \frac{FN}{TP + FN} = \frac{TP}{TP + FN} * 100\% \\
 +P(\%) &= 1 - \frac{FP}{TP + FP} = \frac{TP}{TP + FP} * 100\% \\
 DER &= \frac{FP + FN}{TP + FP + FN} * 100\% \\
 Acc &= \frac{TP}{TP + FP + FN} * 100\%
 \end{aligned}$$

6.2. Uklanjanje šumova i smetnji

Preprocesiranje podataka jedan je od važnih koraka u analizi vremenskih serija. Kada govorimo o analizi EKG signala, onda svakako treba spomenuti i jako važan dio preprocesiranja

takvih podataka, a to je filtriranje. Filtriranje signala je potrebno zbog različitih šumova i smetnji koji se mogu pojaviti prilikom snimanja ili prijenosa izvornog signala iz vremenske serije [30] pa tako i EKG signala. U obradi signala danas postoje mnoge vrste filtara od kojih ćemo izdvojiti i pojasniti neke. Ako uzmemo u obzir da se većina šumova koji ometaju signale ponavlja u periodičkim razmacima ili pak da šumovi sami po sebi imaju periodički karakter, postaje jasno da se takve karakteristike mogu iskoristiti za njihovu eliminaciju tj. uklanjanje posljedica koje za sobom ostavljaju kada se „pomiješaju“ sa izvornim signalom. U skladu s tim postoje frekvencijski filtri koji zatomljuju određene frekvencije nefiltriranog signala. Naravno, tu je preuvjet da znamo koja je frekvencija šuma koji želimo ukloniti. Tako razlikujemo nisko-propusne (engl. Low pass) filtre - filtre koji propuštaju samo niske frekvencije, visoko-propusne (engl. high pass) filtre - filtre koji propuštaju visoke frekvencije, pojno-propusne (engl. band pass) filtre - koji propuštaju određeni frekvencijski pojas i pojne brane (engl. notch filter) - koji ne propuštaju ciljane frekvencije. Kod snimanja i prijenosa EKG signala u realnim uvjetima razlikujemo nekoliko specifičnih problema koji uzrokuju smetnje i šum. Ovi specifični problemi posljedica su same tehnologije snimanja signala i uzrokuju ih interferencije sa drugim elektroničkim uređajima i infrastrukturom, pokreti mišića ispod kože gdje se snima EKG, pokreti tijela koji uzrokuju smetnje te trenje između kože i elektroda kojima se snima EKG signal [64]. Trenutno postoje različite metode uklanjanja šuma i smetnji kao što su one temeljene na filtrima koji propuštaju pojne frekvencije [64], Fourierovim transformacijama [14], valičnim transformacijama (engl. wavelet) [67], [47], kubičnom krivuljaru (engl. cubic spline) [2] i sl. Rezultat djelovanja jednog takvog filtra prikazan je kasnije u ovom radu.

Poseban problem prilikom snimanja i analize EKG signala predstavlja tzv. pomak bazne linije. Ovaj fenomen događa se uslijed pomaka elektroda i zahtjeva poseban pristup za njegovo uklanjanje. Navedeni problem je također obuhvaćen poglavljem o uklanjanju smetnji.

6.3. Detekcija otkucanja srca - QRS kompleksa

U nastavku slijedi pregled metoda koje se koriste u detekciji specifičnih oblika EKG signala. Navedeno će biti koje metode se koriste, koji dijelovi EKG signala se prepoznaju te tamo gdje postoje podaci, navedene će biti i mjere uspješnosti algoritama. Zadiranje u detaljne principe svake spomenute metode izlazi iz okvira ovog rada, a čitatelja se savjetuje da prouči navedene reference za svaki pojedini pristup. Za svaki navedeni pristup, reference su navedene kronološki.

6.3.1. AZTEC

Jedan od prvih algoritama za računalnu obradu EKG signala bio je sadržan u AZTEC programu. Ovaj program predstavljen je krajem 60-ih godina prošlog stoljeća, a njegovo testiranje obavljeno je 1974. Kako tada nije bilo standardizirane baze podataka za testiranje, ono je provedeno u okviru dugoročne studije nad šestoro pacijenata i kratkoročnih studija nad trideset pacijenata. Detekcija QRS kompleksa iznosila je 99%. Zanimljivost ovog programa je i detekcija tzv. PVB (engl. Premature Ventricular Beat) otkucaja odnosno preuranjene kontrakcije klijetke (ventrikula). PVB detekcija testirana je nad 28 pacijenata u ukupnom trajanju signala od 415 minuta. Za navedenih snimanja, kardiolozi su otkrili kako su 10% svih otkucaja bili PVB otkucaji. Od tih otkucaja, AZTEC program je prepoznao PVB otkucaje u 90% slučajeva. Zastupljenost lažno pozitivnih PVB otkucaja iznosila je 1%. Ipak, iako se ovi rezultati čine jako dobri, valja napomenuti kako je AZTEC imao programiranu jednu iznimku, a to je da ukoliko bi detektirao veliki šum, QRS detekcija se ne bi niti obavljala. Srž AZTEC-ovog algoritma bilo je mjerjenje nagiba tj. amplitude EKG signala, a zaključivanje o pojavi aritmije obavljalo se na temelju razmaka između detektiranih otkucaja [91], [94].

6.3.2. PAN-TOMPKINS ALGORITAM

Zanimljiv algoritam „starije generacije“ je i Pan-Tompkins-ov algoritam [76]. Ovaj algoritam koristi nekoliko matematičkih transformacija kako bi doznao širinu, amplitudu i nagib pojedinih artefakata EKG signala. Pan-Tompkinsov algoritam radi u tri faze. Prva faza podrazumijeva implementaciju linearног digitalnog filtra gdje se uklanja šum signala. U drugoj fazi se obavlja kvadriranje kako bi se svi dijelovi signala nalazili u skupu pozitivnih brojeva, a treća faza implementira pragove i logiku za detekciju QRS kompleksa. Algoritam zahtijeva fazu učenja, a njegova točnost predikcije (ACC) nad podacima iz MIT-BIH baze je 99,3%. Logika zadnjeg koraka Pan-Tompkins algoritam implementira i fazu traženja unatrag. Ukoliko se unutar 200 ms od zadnjeg detektiranog otkucaja ne detektira novi, tada se prag detekcije spušta i ponovno se pretražuje taj segment signala. Ako se unutar 360 ms detektira novi potencijalni otkucanj, aktivira se dodatna logika za odluku da li se takav val odbacuje jer se radi o izraženom T valu. Prag od 200 ms odabran je kao prvi prag jer se pretpostavlja da je medicinski nemoguće da se u tom kratkom intervalu dogode dva QRS kompleksa, a drugi prag od 360 ms odabran je empirijski jer se u njemu očekuje većina T valova. U ovom radu biti će predstavljeni rezultati QRS detekcije bez primjene filtara i faze traženja unatrag, ali će također zbog usporedbe biti predstavljen eksperiment koji obuhvaća i jedno i drugo. Kod opisa tog eksperimenta biti će razmotreni i ovi pragovi te predstavljeni rezultati

s obzirom na takve postavke.

6.3.3. DETEKCIJA QRS KOMPLEKSA PRIMJENOM NEURONSKIH MREŽA

90-ih godina 20. stoljeća, rastom popularnosti neuronskih mreža, pojavljuju se i implementacije neuronskih mreža u svrhu analize EKG signala. Predstavljeno je nekoliko algoritama čija je točnost (ACC) varirala između 72% i 90%. Za rijetke skupove podataka išla je i do 95%. Navedeni algoritmi koriste digitalne filtre za uklanjanje šuma. Implementacija iz 2007. godine daje zanimljive rezultate u prepoznavanju QRS kompleksa i jedna je od rijetkih koja uključuje i analizu P i T valova. Rezultati za QRS kompleks, tj. detekciju R zupca, opisani su osjetljivošću od 99,8% i pozitivnom prediktivnošću od 95,47%. Rezultati za abnormalne otkucaje srca (svi otkucaji koji nisu bili označeni kao normalni QRS grupirani su u jednu skupinu - abnormalni) su osjetljivost od 91,72% i pozitivna prediktivnost 95,46%. Analiza P valova dala je osjetljivost od 76,2% do 91,2% ovisno o odvodu koji se analizirao, a površina ispod ROC krivulje iznosila je 0,95. Analiza T valova dala je osjetljivost od 81,6% do 93,6%. Testiranja su vršena na MIT-BIH i European S-T bazama, a u sklopu pred-procesiranja algoritam implementira komponentu uklanjanja odstupanja bazne linije [23]. Primjena neuronskih mreža, dala je zanimljive rezultate i u radu opisanom u [17], gdje se također raspoznaju nepatološki i patološki (engl. ischemic) otkucaji te su svrstavani u te dvije skupine. Algoritam se primijenio na podatke iz kojih je bio uklonjen pomak bazne linije, testiranje je izvršeno na European S-T bazi podataka, a osjetljivost algoritma iznosi 95% do 100% ovisno o promatranom signalu i odvodu. Mnogi drugi napor da se prepoznavanje EKG signala implementira primjenom neuronskih mreža opisani su u [79] u kojem prikazani algoritmi dostižu točnost od 70% do 100%, a uglavnom se radi o prepoznavanju QRS kompleksa. Također je istaknuto kako do tada (2009. godina) ne postoji sistematska studija o performansama algoritama mjerelim na jedinstvenom skupu podataka. Zanimljiv i rijedak pokušaj detekcije raznih patoloških pojava u EKG signalu, a ne samo R zubaca je algoritam temeljen na neuronskoj mreži iz 2010 opisan u [60]. Ovaj rad također prikazuje korištenje različitih filtara za uklanjanje šuma i smetnji, a postignute točnosti su od 95% do 100% ovisno o promatranom signalu. U testiranju je korištena MIT-BIH baza, a testiranje nije obavljeno na svim signalima iz baze već na njih 8. Od novijih pokušaja, valja istaknuti i istraživanje iz 2011. [24] u kojem je algoritam testiran na 40 od 48 zapisa iz MIT-BIH baze, a prosječna postignuta točnost iznosila je 95,24%. Rješenje implementira algoritam koji također raspoznaje sve vrste zapisa iz MIT-BIH baze. Tijekom 2011. godine predstavljeno je još jedno rješenje visoke točnosti, ali autori u njemu pojašnjavaju algoritam za detekciju samo QRS kompleksa, a ne i ostalih artefakata. Točnost algoritma ispitana je nad podacima iz MIT-BIH baze sa rezultatom 98,26% [90].

6.3.4. STROJ S POTPORNIM VEKTORIMA U QRS DETEKCIJI

Još jedna tehnika umjetne inteligencije koja je popularna u rješavanju klasifikacijskih problema općenito pa tako i u detekciji QRS-a jest SVM (engl. Support Vector Machines) [36]. Primjena SVM klasifikatora zahtjeva fazu pretprocesiranja. U radu [65], za prepoznavanje QRS kompleksa iz podataka jednog EKG odvoda, korištene su tehnike digitalnog filtriranja za uklanjanje šuma i smetnji, a potom je proveden entropijski kriterij za isticanje dijelova signala koji sadrže QRS valove. Na temelju rezultata pretprocesiranja, SVM klasifikator je iskorišten za detekciju potencijalnih QRS kompleksa. U ovom radu, testiranje algoritma provedeno je nad CSE ECG standardnom bazom [92] i stupanj prepoznavanja QRS kompleksa iznosio je 99,68%. Postotak lažno pozitivnih otkucaja iznosio je 2,28, a lažno negativnih 0,32. U radu je korišten programski paket LIBSVM [7]. Isti autori kasnije su primijenili vrlo sličan pristup u detekciji QRS kompleksa, ali ovaj puta nad podacima iz 12 EKG odvoda, ponovno nad CSE ECG bazom. Rezultati ovakvog pristupa su bili prepoznavanje s točnošću od 99,93%. Postotak lažno pozitivnih iznosio je 0,54%, a lažno negativnih 0,06%. Ovime je potvrđeno da analiza nad više EKG odvoda može dati dosta preciznije rezultate u prepoznavanju QRS kompleksa, što je i logično jer više odvoda daje pogled na istu stvar iz više različitih „uglova“ [66]. Pristup temeljen na SVM-u testiran je i na MIT-BIH bazi podataka. U radu je korišteno 16 zapisa iz dotične baze i to ne u cijelosti. Rezultati pokazuju postotak greške od 2,007 do 3,772 i autori zaključuju kako ovaj pristup može u određenoj mjeri prepoznati aritmiju, ali ne i o kojoj vrsti aritmije se radi [72].

6.3.5. PRISTUPI TEMELJENI NA DERIVACIJAMA, HILBERT, VALIĆNIM, EMD I SLIČNIM TRANSFORMACIJAMA

Pristupi temeljeni na linearnim i nelinearnim transformacijama originalne vremenske serije, svakako spadaju u najpopularnije metode za otkrivanje QRS kompleksa i detekciju aritmija. U literaturi su prisutni zaista mnogi radovi iz ovog područja, a ritam njihovog objavljivanja je sve češći. Ovo potvrđuje atraktivnost ovog znanstvenog područja. Zadiranje u detaljno objašnjavanje svake implementacije ovim pristupom izlazi izvan okvira ovog rada, a čitatelj se savjetuje za detalje pogledati spomenute reference [64],[63], [98], [75]. Postoci uspješnosti detekcije QRS kompleksa ovom metodom idu i preko 99%. Generalno, zaključak o korištenju ovog pristupa možemo sažeti u sljedećoj tvrdnji. Pristup temeljen na transformacijama (valiči - engl. wavelet, Hilbert, entropija - engl. entropy i sl.) pokazao se kao vrlo dobar u nekim implementacijama, ali valja napomenuti kako se svi ovi rezultati odnose na detekciju QRS kompleksa, prema tome moguće je detektirati i aritmije, ali ne i pouzdano o kojoj vrsti patologije se radi tj. ne detektiraju se oblici QRS

kompleksa.

6.3.6. OSTALI PRISTUPI DETEKCIJI QRS-A

U literaturi su prisutni i razni drugi pristupi detekciji QRS kompleksa odnosno R zubaca. Zanimljivi pristupi predstavljeni su u radovima [14], [96]. Točnost navedenih algoritam varira od 85% do 99%.

6.4. Analiza ritma

Analiza ritma rada srca (HRV - engl. heart rate variability analysis) podrazumijeva napredne analitičke metode i modelle bazirane na statistici, entropiji i ostalim značajkama koje opisuju promjene srčanog ritma u vremenu. Recentni radovi pokazuju značajne rezultate u tom području [44, 45]. Važno je napomenuti da je temelj za analizu srčanog ritma pouzdana QRS detekcija i sva relevantna istraživanja ju podrazumijevaju. Trenutno ne postoje istraživanja koja primjenjuju iste metode na analizu pojavnosti različitih oblika u EKG signalu, a ne samo analizu pojavnosti otkucaja kao što je to slučaj u postojećim HRV istraživanjima.

6.5. Raspoznavanje ostalih dijelova EKG signala

Iako su u literaturi najzastupljeniji radovi koji opisuju razne načine detekcije QRS kompleksa, odnosno R zubaca, postoje i pokušaji prepoznavanja drugih dijelova QRS signala kao što su P i T val, ST segment, QT interval ili neke specifične aritmije. U takvim slučajevima autori su uglavnom skoncentrirani na jedan oblik patološkog signala, a rezultati detekcije nisu visoki poput detekcije samih R zubaca, uglavnom se kreću od 80% do 90%, a rijetki pristupi dostižu osjetljivost i točnost iznad 90% [77], [69], [41], [32].

6.6. Raspoznavanje oblika patoloških QRS kompleksa

Unazad nekoliko godina pojavila su se i istraživanja u kojima autori razvijaju algoritme za raspoznavanje tj. klasifikaciju oblika EKG valova. U takvim istraživanjima se prepostavlja detekcija otkucaja odnosno autori se ne bave problemom QRS detekcije. Općenito, radove koji se bave ovom problematikom možemo podijeliti u dvije osnovne skupine s obzirom na primijenjeni način testiranja (testiranje bazirano na klasi i testiranje bazirano na subjektu). Više o ovim načinima testiranja biti će pojašnjeno kasnije u ovom radu.

7. Medicinski zahtjevi za buduća istraživanja i kliničku primjenu

Iako su do sada razvijeni vrlo precizni i brzi QRS detektori, a postignuti su i dosta dobri rezultati u odnosu na postojeće testove za algoritme, automatizirana EKG dijagnostika još uvijek nije u dovoljnoj mjeri zaživjela u praksi. Osim poslovnih razloga te medicinskih certifikata i odobrenja koje takvi proizvodi moraju zadovoljiti, postoje i medicinski razlozi zašto je to tako. Ovo poglavlje pokušat će približiti medicinske zahtjeve koji se odnose na buduće algoritme za analizu EKG signala.

Kako bi se moglo razumjeti kakvi su algoritmi potrebni u kliničkoj praksi, važno je prvo razumjeti što je to normalan rad srca. Prema medicinskoj literaturi, normalan rad srca mora zadovoljiti sva četiri sljedeća uvjeta [71]:

- 1) Srčani ritam.** Srčani ritam bi trebao biti između 60 i 100 otkucaja u minuti [18], [84], [29],
- 2) Izvor otkucaja.** Izvor pojedinog otkucaja tj. električnog impulsa bi trebao biti u SA čvoru [10], [84], [29],
- 3) Put impulsa.** Impuls kroz srce mora propagirati normalnim putem [10] i
- 4) Brzina impulsa.** Impuls mora propagirati normalnom brzinom (tj. brzinama) kroz srce [10].

Iz navedenoga je vidljivo kako je srčani ritam samo jedan od četiri kriterija koji ukazuju na normalan rad srca. Dakako, kao što je objašnjeno i ranije, značajni pomaci su ostvareni u području identifikacije patoloških poremećaja rada srca temeljem analize varijabilnosti srčanog ritma, no ostala tri kriterija imaju više utjecaja na oblik EKG vala nego na sami ritam. Uvezši u obzir mehanizme rada srca i nastanka EKG valova koji su pojašnjeni ranije, možemo uočiti da ako drugi kriterij nije ispunjen, EKG će odražavati abnormalnosti P vala. U tom slučaju QRS kompleks neće uslijediti nakon točno jednog P vala ili P valovi koji rezultiraju impulsom iz neke druge stanice miokarda u atriju (koja nije SA čvor već ektopična stanica miokarda) neće imati normalnu periodičnost ili bi pak P val mogao biti obrnut zbog abnormalnog smjera propagacije impulsa. Osim ovog potonjeg slučaja, ako električni impuls ne propagira ispravnim putem kroz srce, moguće je i da EKG pokazuje kratke P-R segmente s obzirom na izostanak AV pauze. Također, različite morfološke devijacije QRS kompleksa mogu biti simptomi abnormalne ventrikulske kontrakcije uslijed obilaska ili preskakanja brzog Purkinjeovog sustava i propagacije kroz mnogo sporije stanice miokarda [10]. Ovo je primjer i kako abnormalni put propagacije impulsa posljedično dovodi i do abnormalne brzine. Obično, kod poremećaja rada srca, jedan problem može kaskadno za posljedicu imati drugi koji rezultira iz nekog kolateralnog oštećenja te se problemi samo multipliciraju

sa svakim sljedećim otkucanjem. Iz tog razloga vrlo je važno na vrijeme i točno dijagnosticirati problem.

7.1. P val

Otkrivanje i razvrstavanje P vala u EKG signalu je problem zbog njegove male amplitude i zagušenja koje se događa prilikom filtriranja signala. Ipak, P val je vrlo važna komponenta kliničkog procesa EKG dijagnostike jer može ukazivati na različite probleme s atrijem i to ne samo svojom pojavnosću i frekvencijom [1] [35], već i oblikom [18], [35]. Osim frekvencije i morfologije, smjer P vala može ukazivati na patološka stanja kao što je abnormalni položaj srca izrazito udesno (dextrocardia) [35].

7.2. T val

Promjene morfologije T vala također su vrlo važne u dijagnozi patoloških stanja. Drugačiji oblik T vala može značiti problem s izvorom otkucaja ili problem sa repolarizacijom uslijed bloka lijeve ili desne grane (grane Hissovog snopa). Obrnuti T val, između ostalog može značiti i hiper-trofiju desnog ventrikula.

7.3. ST segment

Akutni koronarni sindrom (engl. Acute Coronary Syndrome - ACS) je velik problem u razvijenim zemljama. Ovaj klinički sindrom je na EKG signalu vidljiv kao promjena u morfologiji ST segmenta. Elevacija ili depresija ST segmenta ukazuje na okluziju velike epikardijalne koronarne arterije [55].

7.4. Analiza više odvoda

Sudeći prema morfološkim karakteristikama EKG zapisa i imajući na umu elektro-mehaničke procese koji se u srcu odvijaju u trodimenzionalnom prostoru, iskusni kardiolog može ne samo identificirati patološko stanje, već i prilično precizno locirati dio srca gdje je problem. Za takvu dijagnozu, kardiologu je potreban pogled na rad srca iz više uglova, a upravo takav pogled pružaju različiti odvodi EKG signala. Analiza više odvoda je vrlo važna za identifikaciju mnogih patologija [95] i rad na tom području se od nedavno pojavljuje u literaturi [8].

7.5. Individualne prilagodbe

Još jedan izazov u primjeni naprednih algoritama za analizu EKG signala jest i činjenica da se EKG smatra biometrijskom karakteristikom što znači da je EKG signal po svojim karakteristikama različit od pojedinca do pojedinca. Nadalje, iako većina ljudi ima sličan zapis EKG signala, postoji dio populacije kod kojeg se uočavaju značajna odstupanja od onoga što nazivamo normalnim EKG-om i to ne u patološkim situacijama. Takve EKG manifestacije ukazuju na normalan rad srca i razlikuju se od patoloških stanja [22]. Algoritmi koji bi mogli pokriti ove situacije trebali bi biti u stanju naučiti što je zaista normalno za nekog pacijenta i onda prijaviti odstupanja ako se dogode.

8. Vektori percepcije - metoda umjetne inteligencije za rudarenje podacima iz vremenskih serija

8.1. Osvrt na terminologiju

Područje strojnog učenja nastalo je kombiniranjem znanja iz različitih područja poput statistike, matematike, logike i.t.d. Zbog toga je nastao cijeli niz sinonima, ali i rasprava o terminima koji bi se trebali koristiti u publikacijama i praksi. Podaci koji se analiziraju nazivaju se opservacije (redci u tablici podataka), a opisani su varijablama ili značajkama (stupci). Variable mogu biti kontinuirane ili diskretne, a u literaturi se kontinuirane navode i kao *Numeric* što treba uzeti s rezervom jer i numeričke variable mogu biti istovremeno diskretne. U ovom radu, nastojat će se koristiti konzistentna terminologija, no ipak zbog ostale literature u području, a i mogućih manjih slučajnih korištenja sinonima, sljedeća tablica prikazuje neke od njih te njihove engleske prijevode.

Tablica 1: Terminologija i sinonimi

Sinonimi na hrvatskom jeziku	Sinonimi na engleskom jeziku
Opservacija, podatak	Observation, Data instance, Example, Data Sample
Klasa, zavisna varijabla, ciljna varijabla	Class, Dependent variable, Goal, Outcome
Varijabla, značajka, atribut, nezavisna var.	Variable, Feature, Attribute, Independent var.
Prenaučenost, pretreniranost modela	Model Overfitting
Kontinuirane, kvantitativne varijable	Continuous, Numeric, Quantitative
Diskretne, kvalitativne varijable	Discrete, Qualitative
Klasifikacija, raspoznavanje, razvrstavanje	Classification
Grupiranje, klasteriranje	Clustering

Također, u statistici postoje razlike između nazivlja grafičkih prikaza. Grafikoni (engl. plot) predstavljaju prikaze za kvantitativne podatke, dijagrami (engl. chart) za kategoriske, a grafovi (engl. graph) prikazuju podatke u tri dimenzije. Zbog jednostavnijeg prikaza sadržaja, svi ovi prikazi su označeni kao grafikoni i zajedno indeksirani u tablici grafikona.

8.2. Inspiracija za razvoj nove metode

Inspiracija za razvoj nove metode dolazi iz dva smjera. Prvi izvor, koji je bio inspiracija za konceptualne ideje metode, je razmišljanje o načinu na koji ljudi opisuju oblike u vremenskim serijama, a drugi koji je izvor za tehničko rješenje jesu trenutne spoznaje iz discipline neuroznanosti. Većina postojećih pristupa analizi vremenskih serija dijeli se na dvije glavne skupine: analiza u frekvencijskoj domeni i analiza u vremenskoj domeni. Analiza u frekvencijskoj domeni je najzas-

tupljenija u postojećim pristupima, a temelji se na spoznajama iz tzv. frekvencijske analize poput Fourierovih ili valičnih transformacija gdje se signal koji se analizira razlaže na svoje frekvencijske komponente. Analiza u vremenskoj domeni pak ne razmatra frekvencijske komponente već oblike u izvornom signalu i njihove međuodnose kroz vrijeme.


8.2.1. LJUDSKI OPISI OBLIKA U VREMENSKIM SERIJAMA

Kada ljudi opisuju vremenske serije, onda se oslanjaju na analizu oblika u vremenskom nizu koji promatraju. Tako ćemo primjerice od burzovnih analitičara često čuti tumačenja grafikona koji prikazuju kretanje cijene neke dionice poput: "Nagli pad cijene...", "Cijena dionice je doživjela vrhunac...", "Oštar pad cijene u zadnjih nekoliko dana..." i sl. Pokušaja da se takvi načini interpretacije formaliziraju i primijene u računalnoj analizi je bilo i ranije poput istraživanja koja nastoje takve oscilacije prikazati diskretnim aproksimacijama [3] ili primjerice domaćeg istraživanja koje povezuje aproksimacije oblika iz vremenskih serija s "klasičnim" metodama rudarenja podacima kroz tzv. REF II model [48], a koji je primijenjen u raznim ekonomskim analizama kroz poslovne slučajeve. Oblici koji se u takvim istraživanjima aproksimiraju tj. ekstrahiraju iz vremenskih serija zapravo proizlaze iz ljudskog vokabulara kojim se opisuju oblici poput: rast, pad, jaki rast, blagi pad, konkavno rastuće, jako konkavno i sl. Otuda i naziv REF modela (od engleskih riječi *Rise* - rast, *Equal* - jednako, *Fall* - pad). U literaturi iz kardiologije se slični vokabular može primijetiti i kod opisivanja oblika EKG valova. Tako susrećemo pojmove i sintagme poput: visina od bazne linije, amplituda vala, širina, ima/nema elevacije, ima/nema depresije, zaobljen val, šiljast val, asimetričan/simetričan, strm, silazan krak, pravilni atrijalni valovi poput zubaca pile (flater atrija), prošireni QRS, bizaran QRS, diskordinantan i sl.

8.2.2. OSNOVNI PRINCIPI VIZUALNE PERCEPCIJE

Za vizualnu percepciju svijeta oko nas, osim očiju koje služe kao senzor, zaslužni su i specijalizirani dijelovi mozga, lateralna genikulatna jezgra (LGN) i vidna kora mozga (vidni korteks). Vidni korteks je dio kore mozga koji se nalazi u stražnjem dijelu mozga, točnije u zatiljnom režnju. Često korišteni termin "vidni korteks", odnosi se na primarni vidni korteks koji je također poznat i pod nazivom strijatni korteks ili V1 (vidno područje 1). Vidni korteks proteže se na obje hemisfere mozga. Desni dio vidnog korteksa prima signale iz lijevog vidnog polja i obrnuto. Trenutne spoznaje u neuroznanosti govore da se u primarnom vizualnom korteksu mozga viših sisavaca nalaze specijalizirani neuroni odnosno skupine neurona koje se nazivaju perceptivna polja (engl. perceptive fields), a koje su osjetljive na točno određene oblike iz vizualnih podražaja. Tako primjerice postoje neuroni i skupine neurona kod kojih se bilježi električna aktivnost nakon izlaganja


subjekta vizualnom podražaju koji se sastoje od malih jednostavnih sličica na kojima su prikazani određeni točkasti uzorci, kratke linije točno određenog nagiba ili pak pomicne linije točno određenog smjera kretanja. Sredinom 20. stoljeća, s razvojem tehnologije koja je omogućila praćenje aktivnosti pojedinačnih neurona u mozgu sisavaca, došlo se do spoznaja o strukturi neurona vidnog sustava. Prvi pronalasci upućivali su na postojanje vidnih polja (neurona) koji se sastoje od dva koncentrična sloja. Jedan sloj je bio ekscitatorni, a drugi inhibirajući. Otkrivene su dvije vrste takvih stanica. Jedna vrsta je imala ekscitatori sloj iznutra, a inhibirajući izvana (engl. on-centre), a druga obrnuto (engl. off-centre) [37]. Eksperimenti su pokazali da se na stanicama sa ekscitatornim središtem električna aktivnost kada je u vidnom polju prikazana svjetla točka u centru zone promatranja, a na stanicama sa inhibirajućim središtem kada je prikazan uzorak koji je osvjetljavao rub zone promatranja. Ove stanice pronađene su u gangliju šarenice te u području LGN, a pojednostavljena ilustracija strukture tih stanica prikazana je na slici 5.



Slika 5: Razlike u strukturi ekscitatornih i inhibirajućih stanica. Stanica s ekscitatornim slojem (+) iznutra (slika a) i stanica s inhibirajućim slojem (-) iznutra (slika b)

Eksperimenti nobelovaca Hubela i Wiesela otkrili su da osim navedenih, postoje i neuroni koji reagiraju na orijentirane rubove uočene na slici [38]. Pokusi su provedeni sa mačkama na kojima je izvršen kirurški zahvat da bi se mogla mjeriti električna aktivnost određenog dijela mozga i pojedinih neurona. Mačke su potom stavljene pred ekran na kojem se prikazivala slika sa uzorcima te se prilikom prikazivanja različitih uzoraka mogla izmjeriti različita aktivnost pojedinih dijelova vizualnog korteksa tj. nakupina neurona.


Zaključak ovih eksperimenata je da postoje tri glavne skupine stanica: jednostavne, složene i hipersložene stanice. Jednostavne stanice sastoje se od gore pojašnjениh koncentričnih stanica ili njihovih nakupina. U slučaju nakupina, radi se o točno određenom rasporedu stanica na način da njihov raspored određuje uzorce na kojima će se najviše javljati njihova aktivnost. Navedene stanice reagiraju na statičke stimulanse. Osim ovih, otkrivene su stanice koje reagiraju na dinamičke stimulanse tj. na kretanje unutar vidnog polja i to u točno određenom smjeru. Ovakve stanice



Slika 6: Skupina stanica koja reagira na kosu liniju


nazivaju se složene stanice. Nadalje, uočeno je da pored ovih koje su navedene, postoje i područja mozga gdje se bilježi porast električne aktivnosti kada se u vidnom polju prikažu linije ili oblici točno određene veličine. Takve stanice nazivamo hipersložene stanice. Promatrajući arhitekturu vidnog sustava mozga, polazeći od očiju (rožnice), preko LGN područja pa dalje prema višim dijelovima mozga primjećuju se sve složenije stanice (skupine stranica) sa sve složenijim zadaćama tumačenja podražaja iz vidnog polja. Takva arhitektura je na neki način hijerarhijska i temeljna je inspiracija za razvoj novih modela računalnog vida. Slika 6 prikazuje ilustraciju skupine stanica koje reagiraju na kosu liniju koja ulazi u vidno polje. Kada se linija nalazi izvan osjetljive zone vidnog polja (puna linija) ne bilježi se električna aktivnost, no kada se linija poklopi sa pozicijom osjetljive zone vidnog polja bilježi se nagli porast električne aktivnosti (isprekidana linija). Zaključak ovdje navedenog je da u mozgu postoje različite vrste neurona i nakupina neurona specijaliziranih za točno određene zadaće, a njihovo djelovanje se može opisati (i simulirati) provođenjem vrlo jednostavnih matematičkih operacija kako će biti prikazano u nastavku. Istraživanja rezultiraju spoznajama da neuroni u mozgu koji su osjetljivi na rubove tj. obrise oblika na slici zapravo imaju mogućnost provoditi kalkulacije ekvivalentne derivacijama. Jednostavan filter koji će pronaći rubove na slici ekvivalentno navedenom opisu neuronske aktivnosti, može se implementirati na sljedeći način. Promatrajući jednodimenzionalni signal kao funkciju intenziteta boje na slici prolaskom u odabranom smjeru, možemo detektirati rub kao naglu razliku između svijetle i tamne površine na slici. Ovaj postupak naziva se i Laplace-ova transformacija.

Rub se detektira na mjestu gdje druga derivacija siječe os y u vrijednosti 0, a amplituda prve derivacije govori o izraženosti ruba tj. koliko je jaki prijelaz iz područja jednog intenziteta boje u drugi. Ovo je ilustrirano na slici 7 gdje se vidi kako u gradijentnom prijelazu iz crne u bijelu boju, izračun derivacija nad intenzitetom bijele boje ukazuje na rubove. Ako opisani proces preslikamo u terminologiju linearne algebre, možemo detekciju rubova predstaviti jednostavnim filtrom. Pojednostavljenou neuronsku mrežu s jednim izlaznim neuronom v možemo prikazati kao korekciju



Slika 7: Detekcija ruba temeljena na derivacijama


ulaza u težinskim vrijednostima (sinapse između neurona) w . Shematski prikaz takve neuronske mreže i mreže s više izlaznih neurona prikazuju slike 8 i 9. Ako razmatramo mrežu sa više izlaznih



Slika 8: Pojednostavljena neuronska mreža s jednim izlaznim neuronom

neurona, tada se broj veza w povećava (između svih parova ulaznih i izlaznih neurona).

Nadalje, proces korekcije ulaznih vrijednosti i dobivanje izlaza možemo algebarski iskazati kao umnožak matrice W i vektora u . Primjerice



Slika 9: Neuronska mreža s više izlaznih neurona

$$v = Wu = \begin{bmatrix} 1 & 0 & 0 & 0 & -1 \\ -1 & 1 & 0 & 0 & 0 \\ 0 & -1 & 1 & 0 & 0 \\ 0 & 0 & -1 & 1 & 0 \\ 0 & 0 & 0 & -1 & 1 \\ 1 & 0 & 0 & 0 & -1 \end{bmatrix} \times \begin{bmatrix} 1 \\ 2 \\ 2 \\ 2 \\ 1 \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \\ -1 \\ 0 \end{bmatrix}$$

Prilikom mjerjenja neuronske aktivnosti kod pomicanja očiju subjekta ustanovljeno je da se električna aktivnost neurona poklapa sa kretanjem očiju. Konkretno, prilikom usmjeravanja pogleda u jednom smjeru, zabilježena je snažna električna aktivnost jednog neurona, a prilikom vraćanja pogleda, zabilježena je aktivnost drugog neurona. Obje aktivnosti su trajale relativno kratko, a između tih dviju aktivnosti aktivan je cijelo vrijeme bio treći neuron koji su istraživači nazvali "neuron integrator". Uzorak koji se pritom bilježi je ekvivalentan matematičkoj operaciji integriranja pa otuda i naziv [15]. Iako je moderna neuroznanost u proteklim desetljećima ostvarila velike napretke u razumijevanju načina na koji vizualna percepcija funkcioniра, točna struktura i funkcije svih dijelova vidne kore i dalje su predmet znanstvene rasprave. U sljedećem poglavlju biti će opisana transformacija vremenske serije u tzv. vektore percepcije. Transformacija se bazira na ideji simulacije neurona vizualnog korteksa koji su u stanju "računati" derivacije i integrale te ovisno o dostignutoj razini podražaja tj. akcijskog potencijala prenositi impuls na ostale neurone.


8.3. Matematički model i algoritam

Vremenska serija predstavlja vrijednost jedne kontinuirane varijable kroz vrijeme. Činjenica da se radi o mjerenu jedno te istog svojstva u različitim trenucima znači da je vrijednost izmjerena u jednom trenutku direktno ovisna o vrijednosti izmjerenoj u trenutku ranije. Ovo svojstvo vremenske serije onemogućava primjenu standardnih statističkih metoda s obzirom da mjerena u različitim trenucima (opservacije) nisu međusobno nezavisne. Upravo ova međusobna zavisnost

svih opservacija biti će temelj za razvoj nove metode predstavljene u nastavku.

Kako je opisano ranije, ljudska interpretacija vremenskih serija očituje se u opisu oblika koje primjećujemo, odnosno segmenata serije ili točnije susjednih opservacija i međuodnosa njihovih vrijednosti. Suvremenim nalazima iz područja neuroznanosti dokazuju kako i neuroni u mozgu viših sisavaca funkcioniraju na sličan način odnosno kako se grupe neurona ponašaju usklađeno te se njihova aktivacija odvija istovremeno kada se u vidnom polju subjekta nađu točno određeni uzorci.

Ove ideje bile su polazište za razvoj koncepta koji bi na neki način obuhvatio osnovne morfološke karakteristike segmenata vremenske serije. Prije svega bilo je potrebno odlučiti na koji način će se segmentirati dijelovi vremenskih serija, a potom i osmisliti način na koji će se opisati morfologija tih segmenata. Za segmentaciju su se prirodnim učinile točke infleksije, a morfološke karakteristike se pokušalo sažeti u skup jednostavnih i brzih proračuna. Koncept korištenja specijaliziranih neurona u opisivanju vremenske serije prikazan je na slici 10.



Slika 10: Konceptualni prikaz metode

I segmentiranje i morfološko opisivanje serije odvija se u vremenskoj domeni tj. na izvornoj

seriji bez pretvaranja u frekvencijsku domenu ili primjene neke druge transformacije (npr. valične). Signal iz vremenske domene transformirat će se nizom spomenutih proračuna na način da se od jednodimenzionalnog signala dobije višedimenzionalni signal čije će dimenzije zapravo govoriti o različitim morfološkim karakteristikama izvornog signala.

8.3.1. KONCEPT TRANSFORMACIJE VREMENSKE SERIJE

Skup vrijednosti takve višedimenzionalne reprezentacije izvornog signala koji odgovara točno jednom trenutku u izvornoj seriji nazvat ćemo "Vektor percepcije" $\overrightarrow{V_P}$. Vektor percepcije $\overrightarrow{V_{PT}}$ u trenutku T sastoji se od skupa vrijednosti $m_{1T}, m_{2T}, \dots, m_{nT} \in M$ koje sažimaju morfologiju signala u okolini točke u trenutku T .


$$\overrightarrow{V_{PT}} = \begin{bmatrix} m_{1T} \\ m_{2T} \\ \vdots \\ \vdots \\ m_{nT} \end{bmatrix}$$

U smislu strojnog učenja, vektor percepcije $\overrightarrow{V_{PT}}$ će predstavljati transformiranu seriju u trenutku T što je de facto skup varijabli (značajki) i uz njega se može vezati klasa K koja će biti korištena kao zavisna ili ciljna varijabla u nadziranom učenju ili statističkom modeliranju ili se pak može razmatrati samostalno kao opservacija izvorne serije u trenutku T te se koristiti kao zasebna opservacija u nenadziranom učenju. Donekle konceptualno sličan pristup, ali temeljen na dvije uzastopne opservacije i sa tri promatrane značajke opisan je u tzv. REF II modelu [48] te slično u radovima [40] i [3].

Transformacija koja će popuniti sve dimenzije vektora $\overrightarrow{V_{PT}}$ će istovremeno odraditi segmentiranje serije i popunjavanje vektora odnosno njegovih komponenti iz skupa M na način da pojedini elementi skupa M predstavljaju morfologiju u bližoj okolini M_1 , a drugi elementi predstavljaju morfologiju u daljoj okolini M_2 istog segmenta, $M_1 \subset M$ i $M_2 \subset M$. U nastavku je opisana transformacija za kreiranje skupa M .


Kako bi se "uhvatila" morfologija signala i popunili svi elementi skupa M , transformacija originalne serije će se odvijati slijedno u smjeru prolaska vremena odnosno dolaska opservacija (snimanja ili mjerena). To znači da će u različitim trenucima t_1 i t_2 biti popunjena dva vektora V_{Pt_1} i V_{Pt_2} . Transformacija će obuhvatiti morfološke karakteristike nizom kumulativnih proračuna koji su u opisani u nastavku, a navedeno se može implementirati u realnom vremenu pomoću

metode pomičnih prozora (engl. sliding window). Kako je vidljivo na slici 11, postoje konstantni pomaci prozora u kojem se promatra vremenska serija pa figurativno kažemo da prozor "klizi" kroz vrijeme.




Slika 11: Metoda klizećih prozora

Kako će biti prikazano kasnije, transformacija se ne mora odvijati samo u jednom smjeru (smjeru prolaska vremena) već se ekvivalentan postupak može obaviti i u suprotnom smjeru generirajući elemente skupa M , stvarajući podskup M_{Rev} . Tako popunjeni novonastali skup morfoloških karakteristika možemo nazvati metaskupom M_M koji je popunjen iz oba smjera tj. $M \subseteq M_M$ i $M_{Rev} \subseteq M_M$. U takvom slučaju implementacija ne bi bila moguća u realnom vremenu, već u približno realnom vremenu metodom skačućih prozora (engl. hopping window). Slika 12 prikazuje prozore u kojima se promatra vremenska serija, a koji nisu konstantnog razmaka već svaki sljedeći počinje od neke specifične točke vremenske serije detektirane u prethodnom prozoru (ekstrem ili infleksija). Figurativno rečeno, kažemo da prozor "skače" kroz vrijeme.



Slika 12: Metoda skačućih prozora

Praktično, ovaj koncept bi bio ekvivalentan procesu u kojem liječnik koji promatra EKG signal u realnom vremenu, prije donošenja svog suda, pričeka da se iscrtava cijeli QRS kompleks na ekranu. Nakon toga, liječnik fokusira svoj pogled na iscrtani val (najprominentniju infleksiju - ekstrem tj. vrh vala) te na temelju oblika cijelog vala (lijeva i desna okolina) donosi sud tj. dijagnozu. Opisani koncept prikazan je na slici 13.



Slika 13: Transformacija EKG signala

U nastavku ovog istraživanja opisan je postupak kreiranja vektora percepcije generiranjem skupova iz jednog i iz drugog smjera, obzirom da se razmatra problem raspoznavanja oblika pri čemu je bitno sagledati cijeli oblik tj. njegovu lijevu i desnu stranu. Radi jednostavnosti, u nastavku teksta koristit ćemo oznaku M kao oznaku za metaskup M_M morfoloških karakteristika (i lijevi i desni smjer transformacije), odnosno skup vrijednosti koje čine vektor $\overrightarrow{V_{PT}}$.

Transformacija u svrhu popunjavanja elemenata vektora $\overrightarrow{V_{PT}}$ može se odvijati na izvornom signalu tj. izvornoj seriji ili na seriji koja je prethodno preprocesirana (transformirana) ili reuzorkovana nekom drugom metodom, npr. minmax transformacijom, z-skaliranjem ili reuzorkovanjem (interpolacijom). Razlog iz kojeg bi tako nešto bilo potrebno je usporedivost serija iz različitih izvora. Primjerice ako se signali sa različitih mjernih uređaja žele uspoređivati ili obrađivati istim algoritmom. Kada su signali izrađeni u različitim skalama tj. amplitudama može se primijeniti min-max transformacija

$$x'_t = \frac{\max_{novi} - \min_{novi}}{\max_x - \min_x} * (x_i - \min_x) + \min_{novi}$$

ili z-skaliranje (svođenje na jedinice standardne devijacije)

$$x'_t = \frac{x_t - \mu}{\sigma}$$

gdje je μ srednja vrijednost, a σ standardna devijacija amplitude signala. Min-max transformacija

omogućuje proizvoljnu skalu, ali joj je mana što moramo znati minimalne i maksimalne vrijednosti serije koju mjerimo što je često kod implementacija u realnom vremenu nemoguće. U takvima situacijama možemo periodično računati standardnu devijaciju amplitude signala i izražavati izvornu seriju u jedinicama standardne devijacije preko navedene transformacije z-skaliranja. Ovakva transformacija biti će razmotrena i kasnije u ovom radu kod problema promjenjivih amplituda QRS kompleksa. Ukoliko su serije koje želimo obrađivati diskretizirane različitim frekvencijama, tada je prije transformacije u vektore percepcije potrebno učiniti rezorkovanje s obzirom da vrijednosti pojedinih vektora $\overrightarrow{V_{PT}}$ direktno ovise o broju opservacija koje su obuhvaćene određenim transformacijskim ciklusom što će biti pojašnjeno u nastavku. Ovo istraživanje obuhvaćalo je podatke iz iste referentne baze te stoga ovakve transformacije nije bilo potrebno provoditi, osim kod izračuna prirasta funkcije tj. kutnog otklona (*angle*) što će biti pojašnjeno u nastavku, a normalizirana vrijednost je također pohranjena u samostalnu varijablu *normalized* kao komponentu vektora $\overrightarrow{V_{PT}}$.

8.3.2. SEGMENTIRANJE SIGNALA

Razmatrajući način na koji ljudska percepcija možda funkcioniра, a na temelju iskustvenih spoznaja (lingvistička razmatranja i saznanja iz neuroznanosti), kao razdjelnici pojedinih segmenta uzete su točke infleksije signala. Metode diferencijalnog računa omogućavaju pronalazak ekstrema i točaka infleksije primjenom prve i druge derivacije, odnosno mjeranjem nagiba tangente na krivulju u trenutku T

$$\text{kutni otklon} = \frac{\text{promjena u } y}{\text{promjena u } x} = \frac{\Delta y}{\Delta x} = \frac{f(x + \Delta x) - f(x)}{\Delta x}$$

odnosno, kada Δx teži nuli

$$f'(x) = \lim_{\Delta x \rightarrow 0} \frac{f(x + \Delta x) - f(x)}{\Delta x}.$$

Kako se radi o digitalnim odnosno digitaliziranim signalima, točke infleksije nije moguće izračunati deriviranjem kontinuirane funkcije već su one aproksimirane na način kako je implementirano i u REF II modelu [48]:

$$\frac{dx}{dt} \approx x_T - x_{T-1}$$

gdje x može biti i normiran na raspon 0-1, a ΔX iznosi 1 pa nazivnika niti nema. Upravo na taj način izračunata je i prva komponenta vektora $\overrightarrow{V_{PT}}$ koju ćemo u nastavku nazivati *angle* (engl. *angle* za riječ kut). Alternativno, kada znamo da je frekvencija uzorkovanja prilikom diskretizacije izvornog signala bila konstantna, derivaciju u trenutku T možemo razmatrati kao kutni otklon

sekante krivulje koja prolazi točkama $T - 1$ i $T + 1$ s obzirom da su takva sekanta i tangenta u točki T paralelne:

$$\frac{dx}{dt} \approx \frac{x_{T+1} - x_{T-1}}{2T}.$$

Nailazak procesa transformacije na ekstrem funkcije za sobom će povlačiti logiku resetiranja pri-padajućih kumulativa te time odražavati morfološke karakteristike signala. Osim samih ekstrema, kao razdjelnici za detaljnije morfološke karakteristike (kumulative) uzete su finije promjene u trendu tj. promjene u detaljnog trendu. Na ovaj način omogućeno je pohranjivanje morfoloških karakteristika signala za bliže i dalje "susjedstvo". Kao identifikator tih promjena u trendu preuzet je sustav granica, odnosno raspona između vrijednosti kutnog otklona, opisan u REF II modelu s tim da je osim gradacije opisane REF II modelom, uvedena i općenitija komponenta trenda kako je prikazano u tablici. Sličan sustav granica prikazan je i u [40].

Tablica 2: Rasponi vrijednosti za oznake trenda i detaljnog trenda (REF)

Razred	Raspon	Oznaka trenda	REF oznaka
1	$angle \geq g1$	1	3
2	$g1 > angle \geq g2$	1	2
3	$g2 > angle \geq g3$	1	1
4	$g3 > angle \geq g4$	2	0
5	$g4 > angle \geq g5$	3	-1
6	$g5 > angle \geq g6$	3	-2
7	$g6 > angle$	3	-3

Vrijednost granica $g1-g6$ odabrana je empirijski, a metode za dinamički odabir granica odnosno njihovu optimizaciju biti će razmotrene pred kraj ovog rada u poglavljju koje opisuje buduća istraživanja. Vrijednosti granica koje su primijenjene u ovom istraživanju prikazane su u tablici 2. Različite vrijednosti granica odgovaraju za različite vrste problema koji se nastoje riješiti opisanom metodom. Ovakvi rasponi odabrani su na način da dobro obuhvaćaju razlike u strmim dijelovima QRS kompleksa EKG signala različitih patologija. Nije isključeno da navedene granice nisu optimalne.

Tablica 3: Granice za kutni otklon primijenjene u istraživanju

Granica	Vrijednost
$g1$	0.005
$g2$	0.0025
$g3$	0.0000001
$g4$	-0.0000001
$g5$	-0.0025
$g6$	-0.005

Zahvaljujući aproksimaciji prve derivacije možemo pronaći lokalne ekstreme odnosno minimume i maksimume krivulje. Nadalje, drugom derivacijom možemo pronaći točke infleksije.

$$\begin{aligned} f''(x) &= \lim_{\Delta x \rightarrow 0} \frac{f(x + \Delta x) - 2f(x) + f(x - \Delta x)}{\Delta x^2} \\ &= \frac{\frac{f(x + \Delta x) - f(x)}{\Delta x} - \frac{f(x) - f(x - \Delta x)}{\Delta x}}{\Delta x}. \end{aligned}$$

Ovime je popunjena još jedna komponenta vektora $\overrightarrow{V_{PT}}$ koju ćemo nazvati stacionarna točka ili prema engleskom nazivu *stationary_point*.

8.3.3. MORFOLOŠKE KARAKTERISTIKE

Iz REF II modela preuzeta je još i površina ispod krivulje, a dodatno su u vektor $\overrightarrow{V_{PT}}$ uvrštene ostale morfološke komponente opisane u nastavku. Navedene komponente su izvorni doprinos ovog istraživanja.

Temeljna ideja izračuna površine proizlazi iz izračuna određenog integrala odnosno pravila trapezoida. Za općeniti slučaj funkcije nad n točaka $(x_1, f(x_1)), (x_2, f(x_2)), \dots, (x_n, f(x_n))$, gdje su x_1, x_2, \dots, x_n poredani rastuće, približna vrijednost integrala $\int_{x_1}^{x_n} f(x)dx$ je određena sa

$$\begin{aligned} \int_{x_1}^{x_n} f(x)dx &= \int_{x_1}^{x_2} f(x)dx + \int_{x_2}^{x_3} f(x)dx + \dots + \int_{x_{n-1}}^{x_n} f(x)dx \\ &\approx (x_2 - x_1) \frac{f(x_1) + f(x_2)}{2} + (x_3 - x_2) \frac{f(x_2) + f(x_3)}{2} + \dots + (x_n - x_{n-1}) \frac{f(x_{n-1}) + f(x_n)}{2}. \end{aligned}$$

Kako su u slučaju signala diskretiziranog jednolikom frekvencijom 1, tada površinu između dvije točke (T i $T - 1$) jednostavno možemo aproksimirati formulom

$$\frac{f(x_{t-1}) + f(x_t)}{2}.$$

Ovime je popunjena i treća komponenta $\overrightarrow{V_{PT}}$ koju ćemo nazivati *surface*.

Dodatna morfološka karakteristika koju ćemo uključiti je i konkavnost krivulje. Na diskretnom signalu konkavnost krivulje u točki T možemo doznati promatranjem vrijednosti točke prije i nakon trenutka T te odnosa vrijednosti u toj točki i susjednih vrijednosti. U tu svrhu ćemo pojam *sredina* koji će označavati fiktivnu srednju vrijednost između točaka koje su prethodna i sljedeća u odnosu na točku T . Vrijednost *sredina* ćemo izračunati kao interpolaciju između prethodne

i sljedeće točke odnosno vrijednost koju bi navedena točka poprimila u slučaju kada bi krivulja zapravo bila pravac koji prolazi točkama $T - 1$ i $T - 2$. Kako ćemo transformaciju računati u jednom prolazu kroz vrijednosti vremenskog niza, svi izračuni provoditi će se za prethodnu točku ($T - 1$ izračunato na temelju susjednih točaka T i $T - 2$).

$$sredina = \frac{x_t + x_{t-2}}{2}$$

Nadalje, razliku prethodne vrijednosti u odnosu na izračunatu sredinu, $\Delta sredina$ definirat ćemo kao

$$\Delta sredina = |x_{t-1} - sredina|,$$

a razliku trenutne (stvarne) vrijednosti niza i prethodno izračunate sredine, $\Delta stvarni$ kao

$$\Delta stvarni = |x_t - sredina|.$$

Izračunate vrijednosti sredine stavit ćemo u omjer te ćemo dobivenu vrijednost nazvati koeficijentom konkavnosti

$$koefficijent konkavnosti = \frac{\Delta stvarni}{\Delta sredina}.$$

Na temelju odnosa sredine i vrijednosti u prethodnom trenutku ($t - 1$), odredit ćemo konkavnost krivulje u trenutku $t - 1$:

$$konkavnost = \begin{cases} konveksno, sredina < x_{t-1}; \\ konkavno, sredina > x_{t-1}; \\ linearno, sredina == x_{t-1}. \end{cases}$$

Izračunati koeficijent čini komponentu vektora $\overrightarrow{V_{PT}}$ koju ćemo nazvati *coefficient_concavity* te ćemo kao u slučaju trenda napraviti diskretizaciju ove varijable dijeljenjem u razrede kako je prikazano u tablici 3.

Ovime je popunjena još jedna komponenta vektora $\overrightarrow{V_{PT}}$ koja označava detaljnu konkavnost, a nazvat ćemo ju prema engleskom prijevodu *concavity_detail*. U slučaju linearne krivulje, odnosno nepostojanja konkavnosti, će varijable za konkavnost i detaljnu konkavnost poprimiti vrijednost 0. Kao i kod granica za trendove, granice za konkavnosti odabrane su proizvoljno na temelju empirijskih zaključaka. Također i u slučaju ovih granica, moguće je osmisiliti model za njihovu

optimizaciju.

8.3.3.1. Dinamički kumulativi

Temelj metode kreiranja vektora percepcije $\overrightarrow{V_{PT}}$ je nastojanje da se jednodimenzionalna krivulja odnosno njezin oblik opiše pomoću višedimenzionalnih vektora koji će biti jedinstveni za svaku točku krivulje (vremenske serije), a opet slični drugim vektorima koji predstavljaju one točke krivulje čije su okoline po obliku međusobno slične. Predstavljen je takvo nastojanje odnosno predložen je postupak kreiranja vektora $\overrightarrow{V_{PT}}$. Postupak koji je opisan u nastavku prema saznanjima autora nije opisan ranije u literaturi i predstavlja jedan od najvažnijih izvornih doprinosova ovog istraživanja. Ideja da se obuhvati morfologija signala "u susjedstvu" promatrane točke kojoj je pridružen vektor $\overrightarrow{V_{PT}}$ podrazumijeva tzv. dinamičke kumulative koji zapravo jednostavnim i brzim matematičkim kalkulacijama pokušavaju uhvatiti točno određene morfološke karakteristike odsječaka krivulje. Ovi kumulativi su dinamički zbog toga što trajanje njihovog kumuliranja nije fiksno već je određeno trendom i detaljnim trendom na odsječku krivulje koji se obrađuje. Tako razlikujemo kumulative koji se računaju za vrijeme trajanja trenda i one koji se računaju za vrijeme trajanja detaljnog trenda. Diskretizacija varijable kutnog otklona u ove dvije varijable trenda bila je važna upravo zbog ovih kumulativa tj. kako bi se postigla "otpornost" na male promjene u trendu i omogućilo adekvatno akumuliranje varijabli. U nastavku je opisan generalni proces akumuliranja

Tablica 4: Rasponi vrijednosti za oznake konkavnosti i detaljne konkavnosti

Razred	Oznaka konkavnosti	Raspon	Detaljna konkavnost
1	1	$coeficient_concavity \geq gk1$	1
2	1	$gk1 > coeficient_concavity \geq gk2$	2
3	1	$gk2 > coeficient_concavity \geq gk3$	3
4	1	$gk3 > coeficient_concavity \geq gk4$	4
5	1	$gk4 > coeficient_concavity \geq gk5$	5
6	-1	$coeficient_concavity \geq gk1$	-1
7	-1	$gk1 > coeficient_concavity \geq gk2$	-2
8	-1	$gk2 > coeficient_concavity \geq gk3$	-3
9	-1	$gk3 > coeficient_concavity \geq gk4$	-4
10	-1	$gk4 > coeficient_concavity \geq gk5$	-5

Tablica 5: Granice za konkavnost primijenjene u istraživanju

Granica	Vrijednost
gk1	2
gk2	1
gk3	0.66
gk4	0.5
gk5	0

vrijednosti koji je moguće primijeniti na bilo koji kontinuiranu varijablu iz transformacije.

Data: niz vrijednosti serije $x_0 \dots x_n$

Result: popunjene vrijednosti kumulativa komponente x

kreni od početka serije;

$x_T = x_0 ;$

while serija **do**

```
    if trend u točki  $x_T ==$  trend u točki  $x_{T-1}$  then
        | trajanje trenda ++;
        | kumulativ = kumulativ + x;
        | if detaljni trend u točki  $x_T ==$  detaljni trend u točki  $x_{T-1}$  then
        |     | trajanje detaljnog trenda ++;
        |     | kumulativ detaljno = kumulativ detaljno + x;
        | else
        |     | trajanje detaljnog trenda = 1 ;
        |     | kumulativ detaljno = x ;
        | end
    else
        | trajanje trenda = 1 ;
        | kumulativ = x ;
    end
     $x_T = x_{T+1} ;$ 
end
```

Algoritam 1: Izračun kumulativa x komponente vektora za vrijeme trajanja trenda

Osim akumuliranja za vrijeme trajanja trenda, vektor $\overrightarrow{V_{PT}}$ popunit ćemo i komponentama koje govore o morfološkoj stupnju konkvavnosti.

Data: niz vrijednosti serije $x_0 \dots x_n$

Result: popunjene vrijednosti kumulativa komponente x
kreni od početka serije;

$x_T = x_0 ;$

while serija **do**

```
if stupanj konkavnosti u točki  $x_T == stupanj konkavnosti u točki x_{T-1}$  then
    trajanje stupnja konkavnosti++;
    kumulativ = kumulativ + x;
    if detaljni stupanj konkavnosti u točki  $x_T == detaljni stupanj konkavnosti u x_{T-1}$ 
    then
        trajanje detaljnog stupnja konkavnosti++;
        kumulativ detaljno = kumulativ detaljno + x;
    else
        trajanje detaljnog stupnja konkavnosti = 1 ;
        kumulativ detaljno = x ;
    end
else
    trajanje stupnja konkavnosti = 1 ;
    kumulativ = x ;
end
x_T =  $x_{T+1} ;$ 
end
```

Algoritam 2: Izračun kumulativa x komponente vektora za vrijeme trajanja konkavnosti

Na ovaj način izračunate su sljedeće varijable i kumulativi: trajanje trenda (*duration_trend*), kumulativ površine (*cum_surface*), kumulativ konkavnosti za vrijeme trajanja trenda (*cum_concavity_trend*), kumulativ promjene površine (*cum_change_surface_trend*), kumulativ kutnog otklona (*cum_angle*), trajanje detaljnog trenda (*duration_ref*), kumulativna promjena površine za vrijeme trajanja detaljnog trenda (*cum_change_surface_ref*), kumulativ kutnog otklona za vrijeme trajanja detaljnog trenda (*cum_angle_detail*), kumulativ koeficijenta konkavnosti za vrijeme trajanja stupnja konkavnosti (*cum_concavity*), kumulativ koeficijenta konkavnosti za vrijeme trajanja detaljnog stupnja konkavnosti (*cum_concavity_detail*), kumulativ koeficijenta konkavnosti za vrijeme trajanja trenda (*cum_concavity_trend*). Detaljne kumulative moguće je napraviti i za varijable kumulativne površine, kumulativnog koeficijenta konkavnosti i t.d.

8.3.3.2. Vremensko-morfološka determinanta

Pored gore opisanih kumulativa, osmišljena je još jedna nelinearna metoda za kreiranje značajki (odnosno komponenti vektora $\overrightarrow{V_{PT}}$) koja za cilj ima opisivanje morfologije krivulje u okolini pojedine točke serije. S obzirom da navedeni izračun za obrađivanu vrijednost x direktno ovisi o trajanju izračuna (broju točaka serije koje su ušle u izračun) i o obliku krivulje (izračun se vrši na temelju morfoloških karakteristika), dobivene vrijednosti nazvane su "vremensko morfološke determinante" (skraćeno VMD). Za razliku od dinamičkih kumulativa koji daju određenu informaciju o tome kakav oblik se nalazi u neposrednoj okolini, cilj vremensko morfoloških determinanti je da daju i informaciju gdje se neki oblik nalazi te dodatno da što je oblik dalje u prošlosti (budućnosti) njegova devijacija (morfologija) manje utječe na vrijednost VMD varijable u promatranom trenutku. Postupak je opisan u nastavku.

Data: niz vrijednosti serije $x_0 \dots x_n$

Result: popunjene vrijednosti vmd varijabli komponente x

kreni od početka serije;

$x_T = x_0 ;$

while serija **do**

```

if trend u točki  $x_T ==$  trend u točki  $x_{T-1}$  then
    vmd brojač++;
    vmd komponenta = vmd komponenta + (vmd brojač * x);
    if detaljni trend u točki  $x_T ==$  detaljni trend u točki  $x_{T-1}$  then
        vmd brojač detaljni++;
        vmd komp. detaljno = vmd komp. detaljno + (vmd brojač detaljni * x);
    else
        vmd brojač detaljni = 1 ;
        vmd komp. detaljno = x ;
    end
else
    vmd brojač = 1 ;
    vmd komponenta = x ;
end
x_T =  $x_{T+1} ;$ 
end

```

Algoritam 3: Izračun VMD komponente vektora za vrijeme trajanja trenda

Kako je vidljivo iz prikazanog algoritma, ako promatramo neki ekstrem krivulje i preposta-

vimo da je trend prije tog ekstrema trajao neko izvjesno vrijeme, zahvaljujući linearnom povećanju $vmd_brojaca$ i njegovom množenju s ciljanom vrijednošću x razvijamo nelinearnost. Točnije, možemo uočiti da zahvaljujući ovoj nelinearnosti (množenju), morfološke promjene bliže promatranoj točki imaju veći utjecaj na vremensko morfološku determinantu od onih koje su "dalje u prošlosti" (tj. lijevo ili desno).

Na prikazani način kreirane su sljedeće vremensko morfološke determinante (VMD): VMD promjene površine za vrijeme trajanja trenda ($cum_vmd_surface_trend$), VMD prve derivacije za vrijeme trajanja trenda (cum_vmd_trend), VMD koeficijenta konkavnosti za vrijeme trajanja trenda ($cum_vmd_concavity_trend$), VMD promjene površine za vrijeme trajanja detaljnog trenda ($cum_vmd_surface_ref$), VMD prve derivacije za vrijeme trajanja trenda (cum_vmd_ref), VMD koeficijenta konkavnosti za vrijeme trajanja trenda ($cum_vmd_concavity_ref$). Kod transformacije unatrag generiraju se iste značajke sa prefiksom rev .

Kao i kod dinamičkih kumulativa, mogućnost kreiranja novih vremensko morfoloških determinanti je ograničena samo kreativnošću istraživača.


Cjelokupna opisana transformacija izvršena je i unatrag, a popis kreiranih značajki (varijabli ili komponenata vektora $\overrightarrow{V_{PT}}$) prikazan je u tablici.

Tablica 6: Varijable transformacije primijenjene u istraživanju

Naziv	Značenje
angle	kutni otklon
rev_angle	kutni otklon unatrag
normalized	normalizirana izvorna vrijednost
surface	površina ispod zadnjeg odsječka
rev_surface	površina ispod zadnjeg odsječka unatrag
difference	aproksimacija prve derivacije
rev_difference	aproksimacija prve derivacije unatrag
surface_last_change	zadnja promjena površine
rev_surface_last_change	zadnja promjena površine unatrag
ref_label	REF oznaka (detaljni trend)
rev_ref_label	REF oznaka (detaljni trend) unatrag
trend	trend
rev_trend	trend unatrag
duration_trend	trajanje trenda
rev_duration_trend	trajanje trenda unatrag

duration_ref	trajanje detaljnog trenda
rev_duration_ref	trajanje detaljnog trenda unatrag
cum_surface	kumulativ površine za vrijeme trajanja trenda
rev_cum_surface	kumulativ površine za vrijeme trajanja trenda unatrag
cum_change_surface_trend	kumulativna promjena površine za vrijeme trenda
rev_cum_change_surface_trend	kumulativna promjena površine za vrijeme trenda unatrag
cum_change_surface_ref	kum. promjena površine za vrijeme detaljnog trenda
rev_cum_change_surface_ref	kum. promjena površine za vrijeme detaljnog trenda unatrag
coefficient_concavity	koeficijent konkavnosti
rev_coefficient_concavity	koeficijent konkavnosti unatrag
cum_angle	kum. kutnog otklona za vrijeme trajanja trenda
rev_cum_angle	kum. kutnog otklona za vrijeme trajanja trenda unatrag
cum_angle_detail	kum. kutnog otklona za vrijeme trajanja detaljnog trenda
rev_cum_angle_detail	kum. kutnog otklona za vrijeme trajanja detaljnog trenda unatrag
concavity_label	oznaka konkavnosti
concavity_detail	oznaka detaljne konkavnosti
rev_concavity_label	oznaka konkavnosti unatrag
rev_concavity_detail	oznaka detaljne konkavnosti unatrag
stationary_point	vrsta stacionarne točke
duration_concavity	trajanje stupnja konkavnosti
rev_duration_concavity	trajanje stupnja konkavnosti unatrag
duration_concavity_detail	trajanje detaljnog stupnja konkavnosti
rev_duration_concavity_detail	trajanje detaljnog stupnja konkavnosti unatrag
cum_concavity	kum. konkavnosti za vrijeme trajanja konkavnosti
rev_cum_concavity	kum. konkavnosti za vrijeme trajanja konkavnosti unatrag
cum_concavity_detail	kum. konkavnosti za vrijeme trajanja konkavnosti detaljno
rev_cum_concavity_detail	kum. konkavnosti za vrijeme trajanja konk. detaljno unatrag
cum_concavity_trend	kum. konkavnosti za vrijeme trajanja trenda
rev_cum_concavity_trend	kum. konkavnosti za vrijeme trajanja trenda unatrag
cum_vmd_trend	VMD prve derivacije za vrijeme trajanja trenda
cum_vmd_ref	VMD prve derivacije za vrijeme trajanja detaljnog trenda
rev_cum_vmd_trend	VMD prve derivacije za vrijeme trajanja trenda unatrag
rev_cum_vmd_ref	VMD prve derivacije za vrijeme detaljnog trenda unatrag
cum_vmd_concavity_trend	VMD konkavnosti za vrijeme trajanja trenda

cum_vmd_concavity_ref	VMD konkavnosti za vrijeme trajanja detaljnog trenda
rev_cum_vmd_concavity_trend	VMD konkavnosti za vrijeme trajanja trenda unatrag
rev_cum_vmd_concavity_ref	VMD konkavnosti za vrijeme detaljnog trenda unatrag
cum_vmd_surface_trend	VMD površine za vrijeme trajanja trenda
rev_cum_vmd_surface_trend	VMD površine za vrijeme trajanja trenda unatrag
cum_vmd_surface_ref	VMD površine za vrijeme trajanja detaljnog trenda
rev_cum_vmd_surface_ref	VMD površine za vrijeme trajanja detaljnog trenda unatrag



Slika 14: Nekoliko odsječaka krivulje sa ilustriranim morfološkim razlikama koje se pokušavaju obuhvatiti vektorima kao rezultat transformacije. Istaknute su razlike u nagibu i površini (a), konkavnosti (b), dinamičkim kumulativima (c) i VMD komponentama vektora (d).

U svrhu ilustracije ideje za pojedine komponente vektora, na slici 14 je prikazano nekoliko parova krivulja. Prvi par krivulja (na slici a) ima očite razlike u nagibu i površini ispod krivulje.

Drugi par krivulja (na slici b) prikazuje naglašene razlike u konkavnosti. Treći par (na slici c) prikazuje dvije sigmoidalne krivulje koje se nakon obrade opisanom transformacijom uvelike razlikuju u komponentama dinamičkih kumulativa. Četvrti par krivulja (na slici označeno d) prikazuje dva slična odsječka koji imaju sličan "trbuh", ali koji se nalazi na različitim dijelovima krivulja. Ovo je obuhvaćeno VMD komponentama vektora $\overrightarrow{V_{PT}}$.

8.3.3.3. *Moguća proširenja*

Ovdje predstavljeni način kreiranja vektora $\overrightarrow{V_{PT}}$ svakako nije konačan. Za potrebe ovog istraživanja kreiran je gore opisani vektor no isti je moguće proširiti dodavanjem novih varijabli (npr. autokorelacija) ili uključivanjem dodatnih detaljnih kumulativa za trenutno izostavljene varijable (površina, koeficijent konkavnosti), ali i promjenom uvjeta za akumulaciju. Primjerice, umjesto resetiranja s obzirom na trend i detaljni trend mogu se ugraditi uvjeti koji će resetirati kumulative ili vremensko morfološke determinante periodički, prilikom pojave određenih stacionarnih točaka (ekstrema, infleksija), dostizanja određenih pragova vrijednosti ostalih varijabli i slično. Pretpostavka je da se na ovaj način može još bolje i detaljnije "uhvatiti" morfologija krivulje u okolini pojedine točke no daljnja razrada ovog koncepta izlazi izvan okvira ovog rada i biti će predmet budućih istraživanja. Kako je primjena granica za stupnjeve trenda i konkavnosti zapravo svojevrsna diskretizacija ovih inače kontinuiranih varijabli, moguće je optimizirati ove granice primjenom entropijske mjere težine dokaza (engl. weights of evidence) s obzirom na ciljnu varijablu ako se radi o problemu nadziranog učenja. Na ovaj način, ne primjenjuju se fiksne granice već se one određuju na temelju samog podatkovnog skupa koji se koristi za trening. Pretpostavka je da će se na ovaj način dobiti još bolje granice tj. da će informacijski dobitak svakog pojedinog razreda trenda i/ili konkavnosti s obzirom na ciljnu varijablu biti optimalan.

8.3.4. IMPLEMENTACIJA

U okviru ovog istraživanja opisana transformacija je implementirana u programskom jeziku C++ kao niz koraka kojima se popunjava struktura dvostruko vezane liste. Jeden vektor $\overrightarrow{V_{Pt1}}$ predstavljen je kao element vezane liste, a vektor $\overrightarrow{V_{Pt2}}$ je sljedeći vezani element. Svaki element vezane liste sadrži pokazivač na prethodni i sljedeći element te ostala polja koja odgovaraju morfološkim karakteristikama skupa M . Ovakav način omogućava lakšu manipulaciju pojedinim vektorima i njihovu selekciju (vektori na ekstremima, infleksijama i sl.) te je memorijski efikasan. Transformacija jednog polusatnog zapisa iz referentne MIT-BIH AD baze na (u trenutku pisanja teksta) prosječnom računalu (Intel Core i5 procesor na radnom taktu 2.8 GHz) izvrši se u vremenu ispod jedne sekunde. Nakon transformacije odabrani su vektori $\overrightarrow{V_{PT}}$ koji u komponenti *stationary_point*

imaju vrijednost ekstrema (maksimum ili minimum) ili koji u anotaciji (varijabla *ANN* imaju relevantnu oznaku otkucaja srca). Takvi vektori su iskorišteni za izgradnju klasifikatora.

8.3.5. VIZUALIZACIJA


Ideju vektora $\overrightarrow{V_{PT}}$ i međuodnosa pojedinih komponenti vektora i klase EKG valova pokušat ćemo dočarati vizualizacijama. Kako je teško uočiti ove odnose na nizu dvodimenzionalnih grafikona ili na statičkom 3D grafu (na papiru ili ekranu, bez mogućnosti rotacije), poslužit ćemo se tehnikom PolyViz vizualizacija koje smještaju opservacije podatkovnog skupa unutar poligona čije stranice predstavljaju skalirane dimenzije skupa. Svaka opservacija projicira se na pripadnu vrijednost skale za svaku os odnosno stranicu poligona. U nastavku su prikazana dva zanimljiva prikaza na kojima se može vidjeti grupiranje valova iste boje, nelinearnost, ali i neki zanimljivi uzorci u četiri odnosno pet dimenzija. Grafikoni 1 i 2 su temeljeni na podacima iz prvog odvoda MIT-BIH AD baze s poduzorkovanom klasom "N", na 5% njene stvarne zastupljenosti, kako bi i ostale klase mogle doći do izražaja.

Boja prikazane opservacije (točke na grafikonu) ukazuje na stvarnu pripadnost klasi tj. obliku vala. Dodatno boje linija koje izviru iz različitih dijelova rubova grafikona ukazuju gdje se na skali pripadne varijable nalazi ta opservacija. Ovdje je zanimljivo primijetiti gomilanje linija iste boje na istim segmentima osi za kontinuirane varijable (primjerice *rev_cum_vmd_surface_trend*) te grupirano zrakasto širenje istih boja kod osi koje prikazuju diskretne varijable (tj. ordinalne poput *duration_concavity*). Upravo ove pojave i "otoke" opservacija na grafičkom prikazu te uzorke koji se pojavljuju ćemo pokušati opisati (tj. obuhvatiti) izgradnjom klasifikatora u narednim poglavljima. Mogućnosti ovakvih vizualizacija su praktički neograničene te je još nekoliko zanimljivih prikaza izdvojeno u prilogu ovom radu.

8.4. Testiranje metode

8.4.1. PODATKOVNI SKUP


U svrhu provedbe ovog istraživanja korišten je dobro poznati postojeći skup podataka - MIT-BIH Arrhythmia Database (u nastavku MIT-BIH AD). Navedeni skup podataka je naširoko prihvaćen i većina radova iz područja prijavljuje rezultate nad tom bazom što ju čini dobrom "benchmarkom" za usporedbu raznih pristupa i algoritama.



Grafikon 1: Vizualizacija valova pomoću 4 dimenzije vektora percepcije

8.4.1.1. MIT-BIH AD baza

MIT-BIH AD baza nastala je suradnjom MIT-a (Massachusetts Institute od Technology) i Beth-Israel Hospital (BIH) bolnice u Bostonu, SAD. Baza je razvijena kao standardni test za evaluaciju algoritama za računalnu obradu EKG-a. Baza sadrži 48 polusatnih EKG zapisa izuzetih od 47 pacijenata. Signali su digitalizirani frekvencijom od 360 Hz. Zapisi su odabrani na način da 23 sadrže normalni sinusni ritam (NSR) i reprezentativne aritmije, dok ostalih 25 sadrži rjeđe, ali klinički značajne patološke EKG valove. Baza je anotirana, što znači da su uz signal pridružene i oznake pojedinih EKG artefakata. Ove anotacije su nastale tako da su dva ili više kardiologa neovisno označavali signale te potom usporedili i konsenzusom finalno usuglasili oznake. Svaki



Grafikon 2: Vizualizacija valova pomoću 5 dimenzija vektora percepcije

signal sadrži podatke iz dvaju EKG odvoda. U 45 slučajeva prvi odvod je modificirani odvod na ruci II (MLII), a drugi odvod je obično modificirani odvod V1 (ponekad V2, V5 i u jednom slučaju V4). U ostala tri slučaja, prvi odvod je V5 i drugi odvod je V2 (dva zapisa) ili MLII (zapis 114 ima obrnute odvode). Oblici pojedinih valova drugačiji su u prvom i drugom odvodu. Općenito, može se uočiti kako normalni sinusni ritam ima jasnije valove u prvom, a neka patološka stanja u drugom odvodu.

8.4.1.2. Neprilagođenost baze predloženoj metodi i rješenje

Kako je opisano i ranije, svaki zapis iz MIT-BIH AD baze je transformiran što znači da je od jednodimenzionalnog niza vrijednosti nastao skup vektora $\overrightarrow{V_{PT}}$. Nakon transformacije, ideja je


bila selektirati sve ekstreme (lokalne minimume i lokalne maksimume) te takav podskup koristiti dalje u postupku učenja i testiranja. U prvoj iteraciji ovog istraživanja dobiveni su relativno pessimistični rezultati te je stoga napravljena analiza pogrešaka i uočeno je da postoji značajan broj opservacija koje nemaju anotaciju na ekstremu krivulje. Razlozi za ovakva odstupanja su dvojaki. Naime prilikom kreiranja anotacija u MIT-BIH AD bazi, prvotne anotacije su smještene pomoću računala, a kardiolozi su ih potom revidirali ručno. Primjenjeni QRS detektor koristio je digitalne filtre te je prilikom filtriranja originalnog signala došlo do malog faznog pomaka što je uobičajena pojava. Mala odstupanja su gotovo nevidljiva golim okom te stoga ne iznenađuje da su promaknula ručnoj anotaciji. Zbog toga je implementiran modul za preprocesiranje baze na način da se kroz vezanu listu transformacije originalna anotacija pomakne na susjedni ekstrem krivulje unutar 20 točaka. Kako je MIT-BIH AD baza uzorkovana na 360 Hz, ovakav pomak iznosi manje od 56 ms u jednom smjeru što je prihvatljivo s obzirom da službeni standard testiranja QRS detekcije tolerira 150 ms kao područje unutar kojeg može biti otkriven otkucanj (tolerancija za fazni pomak). Nadalje, uočeno je kako na nekim mjestima iste klase anotacija imaju anotacije na različitim ekstremima te da postoje određene nekonzistentnosti u primjenjenim principima označavanja. U modul za preprocesiranje ugrađene su određene iznimke kao odgovor na "problematične" dijelove baze poput onih koji su prikazani na slici 15 i opisani u nastavku.

Posebno problematičan je bio zapis 108 na kojem je vidljiva nekonzistentnost u označavanju normalnih otkucaja (na slikama označeni točkom). Promatrajući trenutke u kojima se mijenja oblik samih valova može se uočiti podudarnost s velikim pomacima bazne linije u drugom odvodu (prva dva odsječka na slici 15). Moguće je da taj nagli pomak ukazuje na odljepljivanje elektrode za vrijeme snimanja uslijed pomicanja pacijenta ili sličnog događaja. Treći odsječak u slici 15 pokazuje slučaj iz zapisa 108 kada nije bilo takvog pomaka, a svejedno postoje nekonzistentnosti u označenom ekstremu.

Općenito, postupak izmjene originalnih anotacija bio je vođen načelom što manjih izmjena tako da niti nisu sve anotacije izmijenjene već samo one kod kojih su nekonzistentnosti najčešće (pomak na ekstrem). U poglavlju o analizi pogrešaka biti će prikazane i neke pogreške u zaključivanju algoritma za koje je po mišljenju autora ovog istraživanja upitna točnost u oznakama same baze.

8.4.2. PROBLEM NEBALANSIRANIH PODATAKA

Termin "nebalansirani podaci" koristi se u slučajevima kada opservacije koje pripadaju jednoj klasi imaju mnogo veću pojavnost u podatkovnom skupu od opservacija koje pripadaju drugoj klasi (ili klasama). Nebalansirani podaci su poseban problem u slučajevima iz prakse kada u podat-




Slika 15: Nekonzistentnosti u zapisu 108 iz MIT-BIH AD baze

kovnom setu postoje opservacije koje pripadaju klasi koja je rijetka, a važna. Iako se ovaj problem može naći u raznim domenama, posebno je izražen u medicini gdje je od većine promatranih subjekata samo manji broj njih pozitivan na neki test, bolest odnosno dijagnozu. S obzirom da većina algoritama strojnog učenja radi na način da pokušava povećati općenitu točnost modela, jasno je da se takav pristup može negativno odraziti na točnost raspoznavanja rijetke ali važne klase.

Hipotetski primjer ovakvog scenarija bi bio sljedeći slučaj. Ukoliko promatramo 100 subjekata od kojih je 99 zdravo, a samo jedan bolestan, model koji svaki put predviđa da je pacijent zdrav će imati 99%-tnu točnost. Jasno je da ovakav pristup testiranju nije zadovoljavajući. Osim samog problema mjerjenja uspješnosti u ovakvim slučajevima, činjenica da modeli pokušavaju optimizirati ukupnu točnost predikcije, može posljedično dovesti i do izgradnje tako nepreciznih modela koji "preferiraju" predikciju većinske klase. Stoga je ovaj problem dvojak - i u smislu otežane evaluacije predikcijske sposobnosti modela i u smislu tendencije ka izgradnji lošeg modela.

Razmatrajući problem detekcije QRS kompleksa u EKG signalu pomoću metode predložene

u ovom radu, jasno je da će procedura selekcije svih ekstrema iz krivulje značiti vrlo velik broj opservacija koje nisu QRS kompleks (točnije R zubac) već ostali artefakti EKG signala (P, Q, S, T, U) ili ekstremi nastali uslijed šuma.




Grafikon 3: Distribucija vrste valova u skupu filtriranih podataka za QRS detekciju

Kod raspoznavanja oblika EKG valova, također postoji problem nebalansiranih podataka, iako je on nešto manje izražen. Najveći udio u podatkovnom skupu imaju normalni QRS kompleksi (N anotacija), dok je najmanje (glezano po AAMI grupiranju) združenih (F anotacija) i neklasificiranih otkucaja (Q anotacija).

U literaturi su predloženi mnogi pristupi rješavanju problema nebalansiranih podataka [52] te se oni uglavnom mogu smjestiti u dvije kategorije: rješenja na razini podataka i rješenja na razini algoritma. Pojašnjavanje tih pristupa izlazi izvan okvira ovog rada, te će u nastavku samo ukratko biti prikazani osnovni smjerovi postojećih istraživanja uz reference na literaturu iz područja.

8.4.2.1. Rješenja na razini podataka

Na razini podataka, rješenja problema nebalansiranih podataka uglavnom se svode na razne oblike uzorkovanja. Najjednostavniji (i u ovom istraživanju primjenjeni) pristup jest slučajno poduzorkovanje podataka koji pripadaju većinskoj klasi [53]. Novi uzorak koji nastane je takav da su klase otprilike izjednačene u zastupljenosti te se tako novonastali uzorak primjenjuje za učenje. Ova metoda je najjednostavnija no ima i nedostatke. Prvi nedostatak je opasnost da se poduzorkovanjem izgubi dio informacija o većinskoj klasi odnosno da varijanca većinske klase nije dovoljno opisana novim uzorkom. Ovaj nedostatak može se očitovati u manjoj točnosti modela




Grafikon 4: Distribucija vrste valova za klasifikaciju (originalne anotacije)

prilikom testiranja na novim podacima. Drugi nedostatak očituje se u nemogućnosti klasifikatora da procijeni distribuciju vjerojatnosti klasa u populaciji jer novonastali uzorak više nije slučajan.

Slučajno pre-uzorkovanje je metoda koja ima za cilj povećati broj opservacija manjinske klase slučajnim dupliciranjem opservacija koje toj klasi pripadaju. Autori se slažu da ovaj pristup može imati za posljedicu prenaučenost modela [54], [9] s obzirom da se generiraju identične kopije opservacija koje pripadaju manjinskoj klasi. Dodatno, ovakav postupak može povećati računske zahtjeve uslijed povećanja podatkovnog skupa. Postoje i metode koje generiraju nove opservacije za manjinsku klasu na način da nakon grupiranja interpolacijom između najbližih susjednih opservacija stvaraju nove [9].

8.4.2.2. Rješenja na razini algoritama

Na razini algoritama, najčešće rješenje je promjena cijene koštanja pogrešne klasifikacije neke klase. Tako modificirani klasifikator naziva se i klasifikator osjetljiv na koštanje (engl. Cost-



Grafikon 5: Distribucija vrste valova za klasifikaciju (AAMI anotacije)

sensitive) [20]. Model koštanja u tom slučaju poprima oblik tzv. matrice koštanja gdje je koštanje klasifikacije opservacije iz klase j u klasu i predstavljeno elementom λ_{ij} . Dijagonalni elementi matrice obično sadrže vrijednost 0 što znači da pogodak prave klase nema koštanje. Nadalje, uvjetni rizik za donošenje odluke o pripadnosti opservacije x klasi α_i iznosi

$$R(\alpha_i|x) = \sum_i \lambda_{ij} P(v_j|x).$$

Cilj ovakve klasifikacije je minimizirati koštanje pogrešne klasifikacije na način da se izabere ona klasa (v_j) s najmanjim uvjetnim rizikom. Moguća rješenja su i ponderirane udaljenosti među opservacijama koje pripadaju istoj grupi kod grupiranja, korigiranje udaljenosti hiperravnine od manjinske klase kod stroja s potpornim vektorima (SVM) i sl. Također, nakon izgradnje algoritma strojnog učenja, moguće je primijeniti različite pragove vjerojatnosti (engl. threshold) za donošenje odluke o tome pripada li opservacija nekoj klasi.

8.4.3. ODABIR KLASIFIKATORA I PRIMIJENJENI PRISTUP

Razvoj specijaliziranog klasifikatora izlazi izvan okvira ovog istraživanja te su s obzirom na navedeni problem izrazito nebalansiranih podataka, brzinu izvođenja te još neke druge u nastavku opisane parametre razmotreni postojeći klasifikatori. Nakon testiranja različitih klasifikatora na ograničenom skupu podataka, odabran je algoritam Slučajne šume (RF - engl. Random Forest). RF algoritam je relativno brz i veoma precizan klasifikator, čije su mogućnosti potvrđene u ranijim sličnim istraživanjima [43]. Algoritam slučajne šume spada u skupinu tzv. ansambala klasifikatora (više zasebnih klasifikatora povezanih u jedan model) i temelji se na stablima odlučivanja. Stablo odlučivanja je jednostavan klasifikator koji se dobije izgradnjom strukture stabla na način da se u svakoj grani stabla podatkovni skup dijeli prema varijabli koja podskup u toj grani najbolje razdvaja s obzirom na ciljnu varijablu. Izračun "najbolje variable" u pojedinoj grani temelji se na entropiji ili Gini mjeri nečistoće. Postupak se ponavlja rekursivno dok se ne zadovolje uvjeti prestanka rasta stabla. Prednosti stabala odlučivanja su jednostavna matematika na kojoj se temelje, mogućnost interpretacije tj. očitavanja postupka donošenja odluke slijedom grananja stabla od korijena do listova te mogućnost interakcije s pojedinim dijelovima stabla. Zamke koje kriju modeli stabala odlučivanja su činjenica da dobro pogađaju klasu ali ne i vjerojatnosti za klasu, nestabilnost modela, sklonost pretreniranju (zbog čega se ugrađuju pravila ograničavanja rasta ili podrezivanje) te činjenica da loše podnose mnogo varijabli. U svrhu prevladavanja ovih problema Leo Breiman predložio je model Slučajne šume [6]. Općenito, ansamble klasifikatora možemo podijeliti na skupine nezavisnih klasifikatora (engl. bagging) i sekvenčjalne klasifikatore (engl. boosting). Kod nezavisnih klasifikatora, svaki pojedini klasifikator samostalno donosi odluku i onda se konačna odluka modela donosi po nekom principu glasovanja. Sekvenčjalni klasifikatori ovise jedan o drugom tj. svaki sljedeći klasifikator koji se gradi usavršava općeniti model temeljem rezultata (pogrešaka) prethodnog. RF algoritam je primjer nezavisnih stabala odlučivanja koja su izgrađena na način da je za svako pojedino stablo u šumi iskorišten samo dio podatkovnog skupa (uzorkovanje s ponavljanjem, engl. bootstrap) te je za svako grananje pojedinog stabla razmatran slučajan podskup atributa. Na ovaj način uvedena su dva izvora slučajnosti u model što pomaže prilikom sprečavanja pretreniranosti. Svako stablo šume na ovaj način nosi dio informacije, a ukupna tj. prosječna ocjena prilikom predikcije je vrlo točna. RF algoritam je po mnogim autorima jedan od najboljih algoritama strojnog učenja uopće, dobro podnosi mnogo varijabli te dobro procjenjuje buduću pogrešku modela (podaci koji nisu ušli u bootstrap uzorak ostaju za testiranje - engl. out of bag error). Nadalje, RF algoritam sam po sebi provodi analizu važnosti varijabli kroz postupak randomizirane izgradnje mnogo stabala i internog mjerjenja uspješnosti svakog od njih na pod-

skupu podataka koji nisu bili korišteni za učenje. Pored toga, RF nije osjetljiv na nenormalnosti u razdiobama varijabli prediktora niti na njihove različite skale. Mana RF algoritma je nemogućnost interpretacije no za konkretan problem u ovom istraživanju važnija je bila ukupna točnost modela. Jedan od logičnih kandidata pri odabiru algoritma strojnog učenja su svakako i neuronske mreže. Provedeno je nekoliko testnih klasifikacija i rezultati nisu bili bolji od RF algoritma. Dodatno, kod neuronskih mreža je potrebno "žrtvovati" dio podataka iz seta za učenje u svrhu validacije modela (osiguranje od efekta pretreniranosti), a s obzirom na ionako relativno mali broj opservacija koje pripadaju nekim ciljnim klasama u ovom istraživanju neuronske mreže nisu bile konačni odabir. U ovom istraživanju primijenjene su implementacije RF algoritma u programskim paketima za strojno učenje Orange [19] i Weka [34]. Implementacija u alatu Orange je korištena u QRS detekciji nefiltriranih podataka, a u kasnjim testiranjima (testiranje bazirano na subjektu i klasifikacija oblika) je zbog veličine podatkovnih setova i duljine izvršavanja iskorištena "Fast Random Forest" implementacija [83]. Što se tiče nebalansiranih podataka, kod testa na filtriranim podacima primijenjen je kombinirani pristup ranije navedenih rješenja. Konkretno, podaci su poduzorkovani na način da je odabrano 5 posto podataka koji predstavljaju negativne opservacije te je taj uzorak zajedno sa svim pozitivnim opservacijama (QRS kompleksima) činio osnovni uzorak nad kojim je onda proveden test baziran na subjektu opisan u narednim poglavljima. Također, klasifikator je kreiran kroz tzv. meta-klasifikator što znači da je u procesu učenja RF algoritma, funkcija koštanja koja optimizira algoritam vodila računa o izmijenim vrijednostima koštanja pogrešaka u korist točne detekcije QRS kompleksa. Nadalje, s obzirom na nebalansirane podatke, za zaključivanje da se dogodio otkucaj potrebni prag vjerojatnosti koji daje klasifikator spušten je sa pretpostavljenih 0,5 na 0,4. Ovo će detaljno biti opisano u poglavljju koje prikazuje rezultate testa nad filtriranim podacima.

8.4.4. QRS DETEKCIJA NEFILTRIRANIH PODATAKA

U svrhu testiranja robusnosti predložene metode obavljen je test nad podacima MIT-BIH AD baze bez ikakvog preprocesiranja podataka tj. bez filtriranja i uzorkovanja. Također, prilikom zaključivanja o tome da li neka opservacija predstavlja QRS kompleks, nije provedena metoda traženja unatrag. Opis provedenog testa i rezultati prikazani su u nastavku. Opisano pomicanje anotacija nije obavljeno za svrhu ovog testa osim pomicanja anotacija u zapisu 207 gdje se to odnosi na anotacije ventrikulskog flatera (anotacija "!!") koju ostali autori inače isključuju iz testiranja. Razlog za ovu iznimku je upravo to što inače nije uključena u testove, a u bazi su anotacije izrazito nekonzistentne i u velikom broju slučajeva nisu na ekstremima ili su nelogično raspoređene na minimume i maksimume. U prilogu ovom radu su datoteke sa svim testnim podacima pa

tako i sa ovim "ispravljenim" anotacijama za zapis 207.

8.4.4.1. Opis testa

Za svaki zapis iz MIT-BIH baze podataka obavljen je test detekcije QRS kompleksa metodom unakrsne validacije sa 10 preklopa. To znači da je deset puta izdvojeno po deset posto podataka koji su ostavljeni za test, a ostalih devedeset posto je korišteno za učenje. Nakon izračuna navedenih mjera za svaki pojedini signal iz baze, izračunate su prosječne mjere od svih signala. Korišten je klasifikator u programskom alatu Orange i to na način da su u podatkovnom skupu ostavljene sve izvorne anotacije. Korišteni klasifikator imao je jednake postavke za sve zapise - RF algoritam sa 100 stabala uz korištenje 15 najboljih varijabli mjereno po Info Gain mjeri (informacijski dobitak odnosno entropija s obzirom na ciljnu varijablu).

8.4.4.2. Rezultati

Rezultati testa su prikazani u tablici. Tablica sadrži i informaciju o broju otkucaja koji su uzeti u obzir za svaki EKG zapis. Usporedbom ovih brojeva i brojeva u tablici rezultata testa nad filtriranim podacima mogu se uočiti određena manja odstupanja. Razlog za to je izostavljanje određenih valova (konkretno anotacija "+", "|" i "!"). U literaturi autori ponekad ne navode koje su sve valove izostavili iz razmatranja, ali obično su to ove navedene i zbog toga se uvijek kod objave rezultata prikazuje i broj valova uključenih u svakom zapisu. Ovaj test podrazumijeva originalni podatkovni skup koji sadrži sve valove. Ukoliko je klasifikator dobro detektirao neki val koji je i u bazi označen kao val (bez obzira na izvornu i detektiranu vrstu vala) to se smatra dobrom detekcijom (istinito pozitivan - TP). Ukoliko je nebitni val detektiran kao neki otkucaj (bez obzira na anotaciju) to je označeno kao lažno pozitivna detekcija (FP). Analogno ako je val koji je u bazi označen nekom anotacijom detektiran kao nebitan, onda je to QRS kompleks koji nije detektiran (lažno negativan - FN).

Tablica 7: Rezultati QRS detekcije nad nefiltriranim podacima

Zapis	P	N	TP	TN	FN	FP	Se	+P	DER	Acc
100	2274	265650	2274	265650	0	0	1,0000	1,0000	0,0000	1,0000
101	1870	249309	1856	249309	14	0	0,9925	1,0000	0,0075	0,9925
102	2192	255312	2133	255312	59	0	0,9731	1,0000	0,0269	0,9731
103	2085	237815	2084	237815	1	0	0,9995	1,0000	0,0005	0,9995
104	2274	240234	2142	239605	132	629	0,9420	0,7730	0,2621	0,7379
105	2603	208790	2576	208790	27	0	0,9896	1,0000	0,0104	0,9896
106	2068	216398	2018	216398	50	0	0,9758	1,0000	0,0242	0,9758

107	2138	130741	2059	130739	79	2	0,9630	0,9990	0,0379	0,9621
108	1783	236536	1405	236536	378	0	0,7880	1,0000	0,2120	0,7880
109	2533	198910	2128	198824	405	86	0,8401	0,9612	0,1875	0,8125
111	2125	219475	1843	219488	282	13	0,8673	0,9930	0,1380	0,8620
112	2540	231880	2539	231880	1	0	0,9996	1,0000	0,0004	0,9996
113	1796	220360	1794	220360	2	0	0,9989	1,0000	0,0011	0,9989
114	1883	230181	1871	230181	12	0	0,9936	1,0000	0,0064	0,9936
115	1960	257132	1953	257132	7	0	0,9964	1,0000	0,0036	0,9964
116	2413	205503	2392	205503	21	0	0,9913	1,0000	0,0087	0,9913
117	1536	255817	1499	255816	37	1	0,9759	0,9993	0,0247	0,9753
118	2289	197657	2164	197657	125	0	0,9454	1,0000	0,0546	0,9454
119	2090	229263	2042	229263	48	0	0,9770	1,0000	0,0230	0,9770
121	1864	254815	1814	254815	50	0	0,9732	1,0000	0,0268	0,9732
122	2479	238002	2477	238002	2	0	0,9992	1,0000	0,0008	0,9992
123	1519	248660	1515	248660	4	0	0,9974	1,0000	0,0026	0,9974
124	1632	239286	1605	239286	27	0	0,9835	1,0000	0,0165	0,9835
200	2749	200664	2591	200572	158	92	0,9425	0,9657	0,0880	0,9120
201	2035	251978	1969	251978	66	0	0,9676	1,0000	0,0324	0,9676
202	2146	238322	2139	238322	7	0	0,9967	1,0000	0,0033	0,9967
203	3051	203478	2674	203478	377	0	0,8764	1,0000	0,1236	0,8764
205	2670	241062	2654	241061	16	1	0,9940	0,9996	0,0064	0,9936
207	2368	229692	1493	229679	875	13	0,6305	0,9914	0,3730	0,6270
208	3016	198516	2933	198516	83	0	0,9725	1,0000	0,0275	0,9725
209	3033	219067	3016	219067	17	0	0,9944	1,0000	0,0056	0,9944
210	2668	250470	2586	250469	82	1	0,9693	0,9996	0,0311	0,9689
212	2750	196370	2749	196370	1	0	0,9996	1,0000	0,0004	0,9996
213	3294	115171	3247	115171	47	0	0,9857	1,0000	0,0143	0,9857
214	2293	209089	2242	209089	51	0	0,9778	1,0000	0,0222	0,9778
215	3370	191164	3355	191164	15	0	0,9955	1,0000	0,0045	0,9955
217	2276	171947	2176	171947	100	0	0,9561	1,0000	0,0439	0,9561
219	2312	217060	2236	217058	76	2	0,9671	0,9991	0,0337	0,9663
220	2064	238930	2048	238930	16	0	0,9922	1,0000	0,0078	0,9922
221	2450	235435	2318	235427	132	8	0,9461	0,9966	0,0570	0,9430
222	2619	249230	2557	249230	62	0	0,9763	1,0000	0,0237	0,9763

223	2633	221719	2559	221719	74	0	0,9719	1,0000	0,0281	0,9719	
228	2121	219519	2046	219519	75	0	0,9646	1,0000	0,0354	0,9646	
230	2464	210877	2365	210876	99	1	0,9598	0,9996	0,0406	0,9594	
231	2011	238815	1909	238814	102	1	0,9493	0,9995	0,0512	0,9488	
232	1781	238483	1779	238483	2	0	0,9989	1,0000	0,0011	0,9989	
233	3152	162773	3096	162773	56	0	0,9822	1,0000	0,0178	0,9822	
234	2756	231705	2750	231705	6	0	0,9978	1,0000	0,0022	0,9978	
UKUPNO						4358	850	0,9610	0,9933	0,0448	0,9552

8.4.4.3. Kritički osvrt


Ovim rezultatima su potvrđene hipoteze ovog rada te se može zaključiti kako je metoda dovoljno robusna da sa visokom relativnom preciznošću detektira otkucaje srca na nefiltriranim signalima. Valja međutim istaknuti kako opisani test podrazumijeva fazu učenja i fazu testiranja nad podacima istog EKG zapisa, odnosno istog pacijenta. No, u praksi postoje određena odstupanja u morfološkim EKG signalima među ljudima. Ovo zapravo znači da je svaki od naučenih 48 klasifikatora pristran u odnosu na pacijenta i ovi podaci se ne mogu sa sigurnošću smatrati relevantnim pokazateljima za uspješnost postupka u kliničkoj primjeni. Rezultati testa opisanog u ovom poglavlju u smislu klasifikacije oblika valova nisu detaljno razmatrani (zbog navedene kritike), a matrice zabune s tim rezultatima prikazane su u prilogu. U vrijeme osmišljavanja ovog istraživanja ovakav način testa se činio zanimljivim za potvrdu određenih mogućnosti metode u smislu raspoznavanja oblika, no pozitivni rezultati potaknuli su razmišljanja o sljedećem koraku i provođenju kompleksnijeg testa koji bi bio relevantniji u smislu potencijalne kliničke primjene. Najpouzdaniji način testiranja metoda za QRS detekciju je izdvajanje svakog pojedinog zapisa iz podatkovnog skupa korištenog za učenje i testiranje na podacima pacijenta kojeg algoritam "nikad nije predočio" (tzv. testiranje bazirano na subjektu). U sljedećim poglavljima prikazano je i takvo testiranje, a zbog usporedbe sa ostalim relevantnim istraživanjima primjenjeni su i digitalni filtri te metoda traženja unatrag kako je opisano u poglavljima koja slijede.

8.4.5. UKLANJANJE ŠUMA

Kako je opisano i u uvodu, uklanjanje šuma je važan i neizostavan dio za pouzdanu detekciju otkucaja i raspoznavanje oblika EKG valova. Kako bi metoda predložena u ovom radu bila usporediva sa ostalim pristupima za detekciju QRS kompleksa i raspoznavanje oblika EKG valova, odnosno kako bi se dobili rezultati koji se mogu uspoređivati sa rezultatima objavljenima u literaturi, implementirani su i primjenjeni digitalni filtri za uklanjanje smetnji.

8.4.5.1. Uklanjanje pomaka bazne linije

Median filter je čest filter u digitalnoj obradi signala. Glavna ideja ovog filtra je da prođe kroz signal u nekom unaprijed definiranom klizećem prozoru i zamijeni svaku točku signala sa medijanom susjednih vrijednosti odnosno medijanom točaka obuhvaćenih prozorom. Konkretno, u ovom istraživanju median fitar je primijenjen u dva prolaza. Prvi prolaz je na širini prozora od 200 ms kako bi se eliminirali P valovi, a drugi na širini 600 ms kako bi se eliminirali T valovi iz originalnog signala. Preostali signal predstavlja pomak bazne linije koji se potom može oduzeti od izvornog signala da bi se dobio signal bez pomaka bazne linije. Postupak je prikazan na slici 16. Median filter je implementiran u jeziku C++ prilagodbom implementacije dostupne u slobodnom kodu [97].




Slika 16: Uklanjanje pomaka bazne linije median filtrom

8.4.5.2. Uklanjanje 60 Hz šuma

Butterworth filtri nazvani po svom tvorcu Stephenu Butterworthu su vrlo popularni filtri koji vrlo dobro uklanjaju neželjene frekvencije, čuvajući pritom željene. Butterworth filtri dizajniraju se odabirom odgovarajućeg reda i koeficijenata. Dizajn takvog filtra je u svrhu ovog istraživanja proveden u alatu Octave [73], a programska implementacija koja koristi tako dobivene vrijednosti koeficijenata napisana je u programskom jeziku C++ po uzoru na implementaciju slobodnog koda napisanu za isti programski paket. Kako je MIT-BIH AD baza dvostruko uzorkovana, izolirane su komponente od 30 Hz i višekratnici. Ovaj šum je smetnja gradske mreže i s obzirom da su signali

snimani u Americi, njegova frekvencija je 60 Hz. U Europi bi taj šum imao frekvenciju 50 Hz. Primjer djelovanja ovog filtra prikazan je na slici 17.



Slika 17: Uklanjanje 60 Hz šuma

8.4.6. QRS DETEKCIJA FILTRIRANIH PODATAKA

U svrhu usporedbe sa navedenim istraživanjima i pri detekciji QRS kompleksa i pri klasifikaciji aritmija, implementirani su digitalni filtri. Median-filtar za uklanjanje pomaka bazne linije te "buterworth" filter za uklanjanje šuma koji nastaje zbog smetnji gradske mreže, opisani u prethodnom poglavlju. Većina recentnih istraživanja opisuje primjenu istih ili sličnih tehnika preprocesiranja što omogućava korektnu usporedbu u smislu izlučivanja značajki i klasifikacije tako obrađenih signala.

8.4.6.1. Opis testa

Većina algoritama za QRS detekciju predstavljenih u literaturi ne zahtijeva fazu učenja. To znači da su autori osmisliili algoritam koji je testiran na svakom pojedinom zapisu iz MIT-BIH AD baze uz iste postavke algoritma. Kod takvih pristupa nema problema sa odabirom uzorka za učenje i testiranje. Ovdje predstavljeni pristup zahtijeva fazu učenja i kod takvih algoritama najrealniji test je tzv. test baziran na subjektu (engl. subject based test). Kod takvog testa, svaki zapis iz baze se izdvaja iz uzorka za učenje i služi za test metode, a ostali signali koriste se za učenje (trening) i ako je potrebno validaciju modela (regularizacija i sprečavanje pretreniranosti). Takav pristup je najbliži potencijalnoj kliničkoj primjeni metode jer se prilikom testa algoritam izlaže EKG signalu pacijenta "kojeg nikad prije nije video" (podaci nisu korišteni ni za učenje ni za validaciju modela). To zapravo znači da je izgrađeno i testirano 48 zasebnih modela (po jedan model za svaki zapis). Modeli su izgrađeni (naučeni) nad uzorkom koji je sadržavao 5% nebitnih

ekstrema i sve QRS komplekse iz 47 zapisa te su potom testirani na cjelokupnom skupu podataka 48. zapisa. Ovime se na najbolji mogući način provjerava stupanj generalizacije modela odnosno primjene na novim podacima. Kod algoritama koji ne zahtijevaju učenje postoji mogućnost da su parametri algoritma podešeni za sve zapise iz testne baze te iako algoritam ne zahtijeva učenje nije moguće pouzdano procijeniti mogućnosti generalizacije za primjenu nad novim podacima. Primjenjena je FRF implementacija, a izgrađeni model imao je 1000 stabala u šumi od kojih je svako izgrađeno razmatranjem 15 slučajnih varijabli. Zbog izrazito nebalansiranih podataka, eksperimenti su pokazali da su najbolji rezultati (prikazani u narednom poglavlju) ostvareni primjenom meta klasifikatora sa sljedećom matricom koštanja.

Tablica 8: Matrica koštanja pojedinih klasifikacija

Stvarna klasa	Predviđena klasa	
	QRS	Nije QRS
QRS	0	3.2
Nije QRS	1	0

Vrijednost 3.2 za koštanje FN pogreške odabrana je zbog dva razloga. Prvi razlog je što je nakon poduzorkovanja klase nebitnih valova omjer i dalje bio 1.6 naprema 1 u korist nebitnih, a drugi razlog su uočeni visoki i oštiri T valovi u nekim zapisima naspram QRS kompleksa male amplitude u drugim (npr. zapis 108). Zbog toga je koštanje FN pogreške duplo veće od omjera distribucija unutar klase otkucaja.

8.4.6.2. Rezultati

Tablica 9: Rezultati QRS detekcije nad filtriranim podacima - 360 ms

Zapis	P	N	TP	TN	FN	FP	Se	+P	DER	Acc
100	2273	86290	2273	86290	0	0	1,0000	1,0000	0,0000	1,0000
101	1865	75295	1865	75294	0	1	1,0000	0,9995	0,0005	0,9995
102	2178	69120	2178	69120	0	0	1,0000	1,0000	0,0000	1,0000
103	2084	65072	2084	65072	0	0	1,0000	1,0000	0,0000	1,0000
104	2229	68134	2229	68133	0	1	1,0000	0,9996	0,0004	0,9996
105	2602	57716	2601	57716	1	0	0,9996	1,0000	0,0004	0,9996
106	2027	66617	2027	66613	0	4	1,0000	0,9980	0,0020	0,9980
107	2137	36568	2137	36565	0	3	1,0000	0,9986	0,0014	0,9986
108	1762	81707	1729	81682	33	25	0,9813	0,9857	0,0325	0,9675
109	2532	43084	2532	43084	0	0	1,0000	1,0000	0,0000	1,0000

111	2124	71218	2123	71218	1	0	0,9995	1,0000	0,0005	0,9995
112	2539	73163	2539	73163	0	0	1,0000	1,0000	0,0000	1,0000
113	1795	83051	1795	83021	0	30	1,0000	0,9836	0,0164	0,9836
114	1879	89861	1879	89861	0	0	1,0000	1,0000	0,0000	1,0000
115	1952	82528	1952	82527	0	1	1,0000	0,9995	0,0005	0,9995
116	2412	68511	2393	68510	19	1	0,9921	0,9996	0,0083	0,9917
117	1535	79671	1535	79671	0	0	1,0000	1,0000	0,0000	1,0000
118	2278	74982	2278	74982	0	0	1,0000	1,0000	0,0000	1,0000
119	1987	73187	1987	73186	0	1	1,0000	0,9995	0,0005	0,9995
121	1863	89790	1861	89790	2	0	0,9989	1,0000	0,0011	0,9989
122	2476	78147	2476	78147	0	0	1,0000	1,0000	0,0000	1,0000
123	1518	82490	1518	82490	0	0	1,0000	1,0000	0,0000	1,0000
124	1619	80616	1619	80616	0	0	1,0000	1,0000	0,0000	1,0000
200	2601	68255	2599	68250	2	5	0,9992	0,9981	0,0027	0,9973
201	1963	77737	1943	77737	20	0	0,9898	1,0000	0,0102	0,9898
202	2136	80410	2135	80410	1	0	0,9995	1,0000	0,0005	0,9995
203	3006	59585	3000	59585	6	0	0,9980	1,0000	0,0020	0,9980
205	2656	85394	2655	85394	1	0	0,9996	1,0000	0,0004	0,9996
207	1860	67754	1845	67753	15	1	0,9919	0,9995	0,0086	0,9914
208	2955	57537	2943	57537	12	0	0,9959	1,0000	0,0041	0,9959
209	3005	65965	3005	65965	0	0	1,0000	1,0000	0,0000	1,0000
210	2650	65431	2640	65431	10	0	0,9962	1,0000	0,0038	0,9962
212	2748	58987	2748	58987	0	0	1,0000	1,0000	0,0000	1,0000
213	3251	43086	3251	43086	0	0	1,0000	1,0000	0,0000	1,0000
214	2262	69254	2260	69253	2	1	0,9991	0,9996	0,0013	0,9987
215	3363	60553	3363	60552	0	1	1,0000	0,9997	0,0003	0,9997
217	2208	50747	2206	50747	2	0	0,9991	1,0000	0,0009	0,9991
219	2154	68477	2154	68477	0	0	1,0000	1,0000	0,0000	1,0000
220	2048	71400	2048	71399	0	1	1,0000	0,9995	0,0005	0,9995
221	2427	76524	2426	76524	1	0	0,9996	1,0000	0,0004	0,9996
222	2483	87815	2476	87815	7	0	0,9972	1,0000	0,0028	0,9972
223	2605	63251	2605	63251	0	0	1,0000	1,0000	0,0000	1,0000
228	2053	79954	2048	79947	5	7	0,9976	0,9966	0,0058	0,9942
230	2256	63239	2256	63236	0	3	1,0000	0,9987	0,0013	0,9987

231	1571	70448	1571	70447	0	1	1,0000	0,9994	0,0006	0,9994
232	1780	80747	1780	80743	0	4	1,0000	0,9978	0,0022	0,9978
233	3079	51773	3079	51773	0	0	1,0000	1,0000	0,0000	1,0000
234	2753	79781	2753	79781	0	0	1,0000	1,0000	0,0000	1,0000
UKUPNO					140	91	99,86	99,90	99,76	0,24

Rezultati prikazuju odličnu sposobnost metode u razlikovanju bitnih od nebitnih valova EKG signala koja je usporediva sa *state of the art* metodama objavljenima u literaturi. Greške su primjetne u zapisima koji su i prema literaturi teški za raspoznavanje i koji sadrže mnogo šuma ili male QRS komplekse (poput zapisa 108). Posebno se ističe 30 FP pogrešaka iz zapisa 113. Pregledom pogrešaka utvrđeno je da se radi o T valovima koji se nalaze izvan praga od 360 ms. Kako je osjetljivost klasifikatora povećana spuštanjem praga vjerojatnosti za prihvatanje QRS kompleksa na 0,4, onda se može očekivati i raspoznavanje velikog broja T valova kao QRS kompleksa. Ove pogreške eliminirale bi se povećanjem praga (npr. na 375 ms) no onda ne bi bila moguća poštena usporedba sa radovima iz literature. Usporedba s nekim od najuspješnijih pristupa prema dostupnoj literaturi dana je u tablici.

Tablica 10: Usporedba predložene metode i pristupa iz literature

Metoda	FN	FP	Se	+P	Acc	DER
Ref. [64]	79	140	99,93	99,86	99,79	0,21
Ref. [85]	166	148	99,85	99,86	99,71	0,29
Ref. [58]	154	177	99,86	99,84	99,70	0,30
Predložena metoda	140	91	99,86	99,90	99,76	0,24

8.4.7. RASPOZNAVANJE OBLIKA EKG VALOVA

Iako je hipoteza ovog istraživanja temeljem rezultata opisanih u prethodnom poglavlju potvrđena, za vrijeme provođenja ovog istraživanja objavljeni su radovi sa respektabilnim rezultatima u raspoznavanju valova EKG signala. Kada govorimo o klasifikaciji oblika EKG valova, veoma je važno istaknuti razliku između metodologija testiranja koje se koriste pri objavi rezultata. Metodologija testiranja, odnosno način odabira uzoraka za učenje i testiranje značajno utječe na rezultate testa.

8.4.7.1. Testiranje bazirano na klasi

Česti pristup u recentnim radovima koji prikazuju istraživanja iz područja klasifikacije aritmija odnosno oblika EKG valova je testiranje bazirano na klasi. Kod ovakvih istraživanja cjelokupna

baza EKG signala se podijeli na skup podataka za učenje i skup podataka za testiranje. Uobičajena je metoda unakrsnog testiranja sa nekoliko preklopa što znači da se mjeri uspješnost algoritma na različitim uzorcima za test te se onda računaju prosječne mjere uspješnosti. Problem kod ovakvog pristupa je pristranost metoda zbog već spomenute varijacije u oblicima EKG valova koja postoji između pacijenata, a koja na ovakav način nije adekvatno obuhvaćena testom.

8.4.7.2. Testiranje prema AAMI standardu

AAMI standard opisuje procedure i metrike za testiranje algoritama za raspoznavanje patologija EKG signala [27]. Unazad nekoliko godina pojavljuju se radovi koji prate navedene preporuke što omogućuje relevantnu usporedbu različitih pristupa. Radova koji prijavljuju rezultate prema ovom standardu je u literaturi iznenađujuće malo.

U ovom poglavlju biti će prikazani rezultati testiranja u skladu s preporukama standarda i praksama u navedenim objavljenim istraživanjima. Navedeni standard preporuča izostavljanje EKG zapisa koji sadrže vođeni ritam (pejsmejker), konkretno zapise 102, 104, 107 i 217. Nadalje, skup ostalih zapisa se dijeli na dva podskupa od kojih svaki sadrži po 22 zapisa. Podjela zapisa u podskupove za učenje i testiranje prikazana je u tablici. Kako ovakav pristup testiranju osigurava da cjelokupni zapisi koji su uključeni u testni podatkovni skup nisu u skupu za učenje, ovakav način se u literaturi također podrazumijeva pod sintagmom "testiranje bazirano na subjektu". Neki od objavljenih radova koriste ovu metodologiju testiranja sa dodatnom iznimkom, a to je uključivanje malog dijela testnog signala (npr. prvih 5 minuta) u proces učenja kako bi se algoritam prilagodio na dotičnog pacijenta. Iako su rezultati u tom slučaju znatno bolji, valja napomenuti kako se u tom slučaju ne radi o potpuno automatskom klasifikatoru jer bi u stvarnoj kliničkoj primjeni bila potrebna intervencija eksperta koji bi za svakog pacijenta prilikom snimanja obavio ručno anotiranje dijela signala. Rezultati predstavljeni ovdje ne uključuju takve prilagodbe već se radi o potpuno automatskom klasifikatoru.

Tablica 11: Podjela MIT-BIH AD baze u podskup za učenje i podskup za testiranje

Podskup	MIT-BIH AD zapisi
Podskup za učenje	101, 106, 108, 109, 112, 114, 115, 116, 118, 119, 122, 124, 201, 203, 205, 207, 208, 209, 215, 220, 223, 230
Podskup za test	100, 103, 105, 111, 113, 117, 121, 123, 200, 202, 210, 212, 213, 214, 219, 221, 222, 228, 231, 232, 233, 234

Podjela je uobičajena u spomenutim radovima i učinjena je na način da se u oba podskupa nalazi otprilike podjednak broj opservacija svake klase. Originalnih 16 klasa otkucaja grupirani su prema AAMI standardu u 5 klasa, konkretno "N" (bilo koja oznaka koja ne pripada u "S", "V", "F"

ili "Q" klase), "S" (supraventrikularni ektopični otkucaj), "V" (ventrikularni ektopični otkucaj), "F" (združeni otkucaj) i Q (nepoznati otkucaj). Originalnih 16 klasa prikazane su u tablici 12. Mapiranje MIT-BIH AD klasa u AAMI klase prikazano je u tablici 13.

Učenje algoritma provodi se na prvom podskupu, a testiranje na drugom. Na ovaj način, algoritam se izlaže polovici testne baze na način da niti jedan od zapisa na kojem se testira nije uključen u učenje te je ovakva testna metodologija dobar pokazatelj mogućnosti generalizacije algoritma i mogućnosti potencijalne kliničke primjene. Kako su neki valovi koji pripadaju različitim klasama vrlo slični po obliku, a razlikuju se po dinamičkim karakteristikama (npr. N i A valovi), potrebno je uključiti i određene dinamičke karakteristike kao komponente u vektore $\vec{V_{PT}}$. S obzirom da je ovo istraživanje fokusirano na analizu morfoloških karakteristika, uključen je proizvoljni minimum takvih komponenti. U literaturi nalazimo brojne druge dinamičke karakteristike, a njihovo uključivanje može biti predmet budućih istraživanja i potencijalno poboljšati rezultate raspozna-

Tablica 12: Originalne MIT-BIH AD klase (cijela baza bez isključivanja pejsmejkera)

MIT-BIH klasa	Oznaka	Broj otkucaja
Normalni otkucaj	N	75034
Blok lijeve grane	L	8075
Blok desne grane	R	7259
Atrijska preuranjena kontrakcija	A	2546
Preuranjena ventrikulska kontrakcija	V	7130
Vođeni otkucaj	P	7028
Aberirani atrijski preuranjeni otkucaj	a	150
Ventrikulski flater	!	471
Združeni ventrikulski i normalni otkucaj	F	803
Blokirani atrijski preuranjeni otkucaj	x	191
Nodalni pobjegli otkucaj	j	229
Združeni vođeni i normalni otkucaj	f	982
Ventrikulski pobjegli otkucaj	E	106
Nodalni preuranjeni otkucaj	J	83
Atrijski pobjegli otkucaj	e	16
Neprepoznatljivi otkucaj	Q	33
Supraventrikulski preuranjeni otkucaj	S	2

Tablica 13: Mapiranje MIT-BIH AD klase u AAMI klase

AAMI klasa	MIT-BIH klasa	Ukupno otkucaja
N	N, L, R, e, j	90613
S	A, a, x, J	2972
V	V, E, !	7707
F	F	803
Q	f, Q	1015

vanja. Dinamičke karakteristike koje su uključene kao značajke prikazane su u tablici. Vrijeme promatrane točke izraženo u milisekundama označeno je kao T_0 , vrijeme prethodne točke kao T_{-1} i.t.d.

Tablica 14: Dinamičke značajke uključene u vektor

Značajka	Naziv varijable	Način izračuna
Razlika između dva vala (ms)	db_t	$T_t - T_{t-1}$
Razlika trenutnog i sljedećeg vala	df	$T_{+1} - T_0$
Omjer db_{01} i zadnjih 10 valova	db_avg10	$db_{01}/(\sum_{i=0}^{10} db_i/10)$
Omjer df i zadnjih 10 valova	df_avg10	$df/(\sum_{i=0}^{10} db_i/10)$
Omjer db_avg10 i df_avg10	log_avg_ratio	$log(db_avg10/df_avg10)$

Kako bi se "uhvatila" varijabilnost ritma odnosno relativni položaj promatranog vala u odnosu na njegove neposredne susjedne valove, promatran je lokalni prosjek trajanja intervala između prethodnih deset QRS kompleksa. Dodatno, uključen je samo jedan val u budućnosti što ostavlja mogućnost implementacije u skoro-realnom vremenu ranije opisanom metodom skačućih prozora. Omjeri prethodnog i sljedećeg intervala i prosjeka zadnjih deset valova stavljeni su u dodatni međusobni omjer, a zbog asimetrije distribucije dotične varijable učinjena je logaritamska transformacija.

8.4.7.3. Rezultati

U svrhu raspoznavanja valova izgrađena su dva modela, jedan temeljen na zapisima iz prvog EKG odvoda i drugi temeljen na zapisima drugog odvoda. Oba modela imaju istu strukturu tj. radi se o šumama sa 500 stabala od kojih je svako izgrađeno razmatranjem 15 slučajnih varijabli.

Tablica 15: Matrica zabune za raspoznavanje oblika EKG valova temeljem prvog odvoda i svih atributa

Stvarna klasa	Predviđena klasa				
	N	S	V	F	Q
N	43661	502	93	3	0
S	667	1199	106	0	0
V	206	8	3007	0	0
F	381	0	7	0	0
Q	4	0	3	0	0

U slučaju svih varijabli vektora uključenih u izgradnju modela dobivena je ukupna točnost od 96.02% što je dosad najviša točnost prema saznanjima autora. Sljedeći eksperiment uključivao je razmatranje samo 30 najrelevantnijih atributa i dao je općenito manju točnost, ali uz veću osjetljivost na raspoznavanje instanci "S" klase.

Ukupna točnost modela izgrađenog na temelju testnog seta prvog odvoda iznosi 95,812%. Možemo primijetiti kako je najlošija klasifikacija "F" valova. Ovi rezultati poklapaju se sa pronašcima drugih autora čiji pristupi također u značajnoj mjeri grijese pri raspoznavanju "F" otkucaja [61].

Model temeljen na drugom odvodu ima znatno nižu ukupnu točnost koja iznosi 90,6795%, no postiže značajno bolju klasifikaciju "F" valova. Ovo je za očekivati jer drugi odvod (koji daje perspektivu na srce iz drugog ugla) takve otkucaje prikazuje sa većom amplitudom pa ih klasifikator može lakše razaznati.

Razmatrajući samo rezultate klasifikacije dobivene na prvom odvodu i uspoređujući ih sa trenutnim stanjem tehnike tj. objavljenim radovima u literaturi, bez obzira na nemogućnost raspoznavanja "F" klase, a s obzirom na vrlo dobre rezultate u raspoznavanju ostalih klasa, možemo konstatirati kako metoda spada među trenutne "state of the art" metode. Kasnije će biti razmotreno i kombiniranje zaključaka iz dvaju odvoda.

U svrhu usporedbe s nekim od najuspješnijih algoritama dostupnima u literaturi prikazane su matrice zabune istraživanja prikazanih u [61], [95] i [16].

Tablica 21 prikazuje usporedbu tri varijante predložene metode i nekih od najuspješnijih pristupa koji su objavili rezultate prema AAMI standardu. Predložena metoda označena kao *a* odnosi se na klasifikaciju temeljem prvog EKG odvoda koja uključuje sve značajke. Varijanta označena sa *b* podrazumijeva klasifikaciju temeljenu također na odvodu 1, ali uz korištenje najrelevantnijih 30

Tablica 16: Matrica zabune za raspoznavanje oblika EKG valova temeljem prvog odvoda i samo 30 najrelevantnijih atributa

Stvarna klasa	Predviđena klasa				
	N	S	V	F	Q
N	43391	667	175	26	0
S	457	1361	154	0	0
V	194	17	3010	0	0
F	377	0	11	0	0
Q	4	0	0	3	0

Tablica 17: Matrica zabune za raspoznavanje oblika EKG valova temeljem drugog odvoda

Stvarna klasa	Predviđena klasa				
	N	S	V	F	Q
N	42604	60	1384	211	0
S	397	166	1409	0	0
V	649	218	2198	156	0
F	128	0	27	233	0
Q	6	0	1	0	0

Tablica 18: Matrica zabune za raspoznavanje oblika EKG valova ref. [61]

Stvarna klasa	Predviđena klasa				
	N	S	V	F	Q
N	34270	1807	80	8031	N/A
S	124	1403	280	28	N/A
V	46	182	2669	321	N/A
F	11	2	5	370	N/A
Q	N/A	N/A	N/A	N/A	N/A

Tablica 19: Matrica zabune za raspoznavanje oblika EKG valova ref. [95]

Stvarna klasa	Predviđena klasa				
	N	S	V	F	Q
N	39157	931	1284	2816	50
S	502	1199	252	15	7
V	284	160	2624	139	13
F	199	1	110	76	2
Q	2	0	5	0	0

Tablica 20: Matrica zabune za raspoznavanje oblika EKG valova ref. [16]

Stvarna klasa	Predviđena klasa				
	N	S	V	F	Q
N	38444	1904	303	3509	98
S	173	1395	252	16	1
V	117	321	2504	176	103
F	33	1	7	347	0
Q	4	0	3	0	0

Tablica 21: Usporedba uspješnosti različitih pristupa


Metoda	ACC	Osjetljivosti (Se) u %				
		N	S	V	F	Q
Ref. [16]	85,9	86,86	75,93	77,73	89,43	0
Ref. [61]	78	77,55	76,46	82,94	95,36	N/A
Ref. [95]	86,41	88,51	60,8	81,5	19,58	0
Predložena metoda a)	96,02	98,64	60,80	93,36	0	0
Predložena metoda b)	95,82	98,03	69,02	93,44	0	0
Predložena metoda c)	90,68	96,26	8,41	68,23	60,05	0

atributa dok varijanta c označava klasifikaciju temeljem drugog odvoda. Podebljano su označene uspješnosti na kojima je pojedini pristup najuspješniji (između tri predložena), dok je kurzivom naznačena veća uspješnost prijavljena u literaturi.

U literaturi postoji još istraživanja koja koriste AAMI standard testiranja, ali uz uključivanje prvih 5 minuta testnih EKG zapisa u fazi učenja. Takva testiranja nisu u potpunosti korektan pokazatelj potencijalne kliničke primjene s obzirom da bi za svakog pacijenta bilo potrebno 5 minuta označavati signale što u kliničkim situacijama nije uvijek praktično i vremenski je zahtjevno. Stoga usporedba s takvim istraživanjima nije niti rađena.

8.4.8. PRIJEDLOG NOVIH POSTUPAKA TESTIRANJA

Kako EKG signal sadrži velike varijacije u oblicima valova koji nominalno pripadaju istoj klasi, a algoritmi postaju sve sofisticiraniji i rezultati njihove evaluacije sve sličniji, predlaže se jedan novi način testiranja. Ovaj način testiranja dolazi iz relativno slične discipline raspoznavanja uzorka, točnije analize sličnosti oblika - tzv. *bullseye* test. Korištenje ovog načina testiranja u analizi sličnosti oblika biti će predstavljeno kasnije u ovom radu. Ovaj test može biti korišten u analizi algoritama nadziranog i nenadziranog učenja. Kod nadziranog učenja, uspješnost algoritma može se izračunati kao prosječna točnost raspoznavanja prvih n objekata [21]. Kod nenadziranog učenja, kada uz oblike ne postoji informacija o klasi, rezultati se prikazuju grafički iscrtavanjem oblika koje je algoritam prijavio kao najsličnije, a rezultati se evaluiraju vizualno [50]. Primjenom



Slika 18: Primjer rezultata bullseye testa (preuzeto iz [88])

ovakvog testa, istraživači bi mogli prezentirati koliko dobro njihova metoda raspoznaće oblike

valova bez obzira na anotiranu klasu. Primjerice, kako je prikazano na slici 18, krajnje lijevi val je val za koji se traže slični oblici, a ostali valovi na desnom dijelu slike su oblici koje je algoritam smatrao najsličnjima. Konkretno, ovdje se radi o E valovima iste orijentacije i približne širine.

8.5. Primjena na više od jednog odvoda

Kako je objašnjeno u poglavlju 7.4. analiza više EKG odvoda može donijeti značajan napredak u EKG dijagnostici u odnosu na samo jedan odvod. Mehanizam propagacije električnih impulsa i njihovog očitanja na površini tijela pacijenta, može ukazivati na poremećaje koji nisu vidljivi na jednom odvodu, povećati sigurnost zaključka o uočenoj patologiji ili čak omogućiti lociranje ishemičnih dijelova srca. Pogled na više EKG odvoda je ekvivalent pogledu na istu stvar iz različitih uglova. Rezultati prikazani u prethodnim poglavljima ovog rada odnose se na analizu jednog EKG odvoda. No, s obzirom na navedene prednosti analize više odvoda, proveden je eksperiment na nekoliko problematičnih valova kako bi se demonstrirala mogućnost i takve analize. Kako je za detekciju QRS kompleksa i klasifikaciju oblika korištena metoda slučajne šume koja za rezultat ima probabilističke procjene odnosno vjerojatnosti pripadanja opservacije pojedinoj klasi, moguće je primjenom Bayesove uvjetne vjerojatnosti kombinirati zaključke različitih klasifikatora odnosno modela kreiranih nad podacima različitih odvoda [95]. Ako promatramo podatke raspoređene u K klase, konačna procjena vjerojatnosti $\bar{P}(y = i|\{x_1, x_2\})$ može se izračunati temeljem pojedinačnih vjerojatnosti $P_l(y = i|X_l)$, $l = 1, 2$, koje su dobivene od pripadajućih klasifikatora izgrađenih nad podacima pojedinačnih EKG odvoda, pomoću Bayesovog pristupa:

$$\bar{P}(y = i|\{x_1, x_2\}) = \frac{\prod_{l=1}^2 P_l(y = i|x_l)}{\sum_{j=1}^K \prod_{l=1}^2 P_l(y = j|x_l)}$$

gdje je x_l zapravo vektor $\overrightarrow{V_{PT}}$ promatranog vala u trenutku T generiran nad podacima iz odvoda l . Taj vektor x_l iskorišten je za učenje klasifikatora za odvod l . Dakle, vjerojatnost da promatrani otkučaj pripada klasi i je združena vjerojatnost za i -tu klasu dobivena vjerojatnostima za i -tu klasu iz svakog pojedinog klasifikatora. Konačno, odluka o klasi kojoj pripada opservacija u trenutku T je ona klasa k s najvećom vjerojatnošću


$$k = \arg \max_i \bar{P}(y = i|\{x_1, x_2\}).$$

Provedeni su eksperimenti u smislu raspoznavanja oblika valova prema AAMI standardu i rezultati su prikazani u tablici. Dobiven je zanimljiv rezultat koji govori da je združena odluka donešena na temelju dva odvoda zapravo ukupno lošija od odluke dobivene temeljem samo pr-

vog odvoda. Razlog za to je znatno bolja uspješnost prvog odvoda u raspoznavanju normalnih otkucaja. Sljedeći eksperiment uključivao je uklanjanje nekih dinamičkih značajki iz podatkovnog skupa kako bi se namjerno srušila uspješnost klasifikatora nad prvim odvodom i dobila približna uspješnost nad oba odvoda. Točnost modela izgrađenog nad prvim odvodom iznosila je 93,92%, a modela izgrađenog nad drugim odvodom 92.8%. Združena vjerojatnost nad tako dobivenim klasifikatorima je bila bolja od svakog pojedinačnog i iznosila je 95,05% što je malo manje od najveće dobivene točnosti modela za prvi odvod. Zaključak je ovog eksperimenta kako združivanje vjerojatnosti u svrhu zaključivanja nad više odvoda ima smisla kada su klasifikatori izgrađeni nad pojedinim odvodima približno slične uspješnosti. U suprotnom, konačna točnost združenog modela može zapravo biti manja od najboljeg pojedinačnog modela. Buduća istraživanja analizirat će ovakav mehanizam zaključivanja nakon uvrštavanja više dinamičkih komponenti u skup značajki.

8.6. Analiza pogrešaka


U nastavku su izdvojene neke pogreške algoritma. Dodatno su pogreške izdvojene u prilogu ovom radu. Jedan prilog sadrži zanimljivije pogreške prikazane grafički, a drugi prilog podrazumijeva datoteke sa svim predikcijama. Oboje je pohranjeno na DVD medij.




Slika 19: Promašene anotacije na signalu 101

Slika 19 prikazuje valove koji nisu detektirani na zapisu 101. Vidljivo je da su valovi 7 i 9 označeni na mjestima gdje se očigledno dogodilo skliznuće elektrode ili neki sličan problem tijekom snimanja. Ove anotacije označene sa "I" su prema dokumentaciji baze izolirani artefakti nalik na QRS kompleks. Ovo je tip greške FN.

Slika 20 prikazuje situaciju u kojoj je algoritam nakon eliminacije pomaka bazne linije i šuma detektirao otkucaj, a anotacije nema u bazi (lokalni ekstrem neposredno prije visokog pomaka bazne linije). Signal je br. 101, a greška je tipa FP.



Slika 20: Detektirani a neoznačeni otkucaj u signalu 101




Slika 21: Problematični dijelovi signala 104

Slika 21 prikazuje problematične dijelove signala 104. Problematični su valovi 4, 5 i 11. Kod valova 4 i 11 postoje dva bliska ekstrema (uslijed združenog prirodnog i vođenog otkucaja). Val 5 je primjer anotacije na lokalnom minimumu umjesto na lokalnom maksimumu. Zbog ovakvih situacija bilo je potrebno ugraditi prag tolerancije na detekciju sljedećeg otkucaja (situacija pokrivena i pragom od 360 ms za T val) te implementirati pomak anotacija u fazi preprocesiranja o čemu je bilo riječi u ranijim poglavljima.


Slika 22 prikazuje dio signala 105 na kojem postoje izražene smetnje. Na ovom segmentu, dogodila se jedna pogreška - promašeni zadnji otkucaj (FN).

Slika 23 prikazuje promašeni val na signalu 111. Promašen je 7. val uslijed analize prvog odvoda na kojem se evidentno dogodio problem prilikom snimanja. U ovakvoj i sličnim situacijama, analiza dva (ili više) odvoda bi očigledno unaprijedila pouzdanost detekcije.

Slika 24 prikazuje grešku u smislu detekcije QRS kompleksa gdje je prvi T val u nedostatku prethodne anotacije za QRS kompleks detektiran kao FP. Ovo je zbog izlaska T vala izvan zone tolerancije, a uslijed slučajnog nalaženja T vala na početku signala 215 te praga odlučivanja od 0,4.



Slika 22: Izražene smetnje na signalu 105 i promašeni otkucaj



Slika 23: Promašeni otkucaj na signalu 111

Više prikaza primjera pogrešaka algoritma i problematičnih segmenata nalazi se u prilogu.

8.7. Primjena metode u nenadziranom učenju

Ranije opisani način učenja algoritama, gdje u podatkovnom setu za svaku opservaciju imamo informaciju o klasi kojoj ona pripada, spada u tzv. nadzirano učenje. Ovo je ilustrirano točkama označenim bojom na grafikonu 6. U situaciji gdje nemamo informaciju o klasi kojoj opservacija pripada, zadatak je ustvrditi kojoj grupi ona pripada tj. koje od poznatih opservacija su joj najsličnije. Navedeni problem nazivamo i grupiranje ili klasteriranje. Ovo je ilustrirano prikazom istih, ali ovaj puta jednobojnih, podataka na grafikonu 7.

Postoji mnogo algoritama za nenadzirano učenje i njihovo pojašnjavanje izlazi izvan okvira ovog rada te je u nastavku prikazan samo konceptualni model takvog procesa.

Temelj algoritama nenadziranog strojnog učenja je izračun *udaljenosti*, odnosno razlika među opservacijama. Najjednostavniji primjer izračuna udaljenosti je Euklidska udaljenost. Ako su dvije opservacije a i b opisane varijablama (a_1, a_2, a_3) i (b_1, b_2, b_3) tada udaljenost među njima (Δ)



Slika 24: Prvi T val detektiran kao QRS na signalu 215

možemo izračunati kao

$$\Delta = \sqrt{(a_1 - b_1)^2 + (a_2 - b_2)^2 + (a_3 - b_3)^2}.$$

Kod ovakvog izračuna udaljenosti potrebno je provesti ranije spomenutu normalizaciju kako bi sve varijable bile na istoj skali (minmax transformacija, z-skaliranje i sl.). Euklidska udaljenost ne vodi računa o varijabilitetu podataka unutar pojedinih varijabli te stoga postoje "naprednije" metode izračuna udaljenosti.

Jedna od naprednijih metoda izračuna udaljenosti koja u obzir uzima raspršenost podataka je Mahalanobisova udaljenost. Obuhvaćanje raspršenosti je realizirano pomoću matrice kovarijanci podataka. Zapravo možemo reći da je Mahalanobisova udaljenost na neki način višedimenzionalno z-skaliranje. Uz danu listu X koja se sastoji od N opservacija gdje svaka opservacija može biti K dimenzionalna (duljina vektora) te vektor μ_x (koji se sastoji od individualnih sredina $\mu_{1,\dots,K}$), kovarijanca je $K * K$ matrica


$$\Sigma = E[(X - \mu_x)(X - \mu_x)^T].$$

S inverzom matrice Σ možemo analogno Euklidskoj udaljenosti izračunati Mahalanobisovu udaljenost na način da iz izračuna pomoću matrice Σ^{-1} isključimo kovarijancu prostora

$$D_{Mahalanobis}(x, y) = \sqrt{(x - y)^T \Sigma^{-1} (x - y)}.$$

Mahalanobisova udaljenost je broj koji je zapravo mjera sličnosti između dvije opservacije višedimenzionalnog prostora [5].

Postoje i mnoge druge metode izračuna udaljenosti, no njihovo pojašnjavanje izlazi izvan okvira ovog rada.




Grafikon 6: Problem nadziranog učenja u prostoru 3 dimenzije vektora percepcije

Svrha ovog poglavlja je dvojaka. Prva je demonstracija mogućnosti metode vektora percepcije u opisivanju oblika krivulja i njihove primjene u nенадзiranом učenju, a druga je svojevrsna potvrda intuicije koja stoji u pozadini metode.

8.7.1. SAMOORGANIZIRAJUĆE MAPE

Samoorganizirajuće ili Kohonenove mape su algoritam nенадзiranog strojnog učenja koji neki svrstavaju i u klasu algoritama neuronskih mreža te su prema nekim autorima i najvjernija kopija procesa koji se događaju u mozgu (u smislu učenja i grupiranja sličnih opservacija) [49]. Samoorganizirajuće mape su multifunkcionalni algoritam strojnog učenja koji se može koristiti u svrhu smanjenja dimenzionalnosti, grupiranja pa čak i klasifikacije. U ovom istraživanju samoorganizirajuće mape su korištene kao algoritam nенадзiranog učenja s ciljem identifikacije zanimljivih "otoka" na mapi čije bi postojanje potvrdilo intuiciju autora u smislu postojanja jasnih granica odluke temeljenih na vektorima percepcije. Osnovna ideja samoorganizirajućih mapa je nakon početne slučajne inicijalizacije mape prilagođavati ćelije mape opservacijama iz podatkovnog skupa na temelju pronalaska najsličnijih područja na mapi. Mapa se prilagođava u ponavljaјuћem postupku na način da se za svaku opservaciju iz podatkovnog skupa pronađe najsličnija ćelija na mapi te se u istoj iteraciji osim same najsličnije ćelije (BMU - engl. Best Matching Unit), opservaciji prilagođavaju i njeni susjedi (svakim korakom se prilagođava manji broj susjeda). Na ovaj način,



Grafikon 7: Problem nenadziranog učenja u prostoru 3 dimenzije vektora percepcije


nakon svih iteracija, mapa sadržava "otoke" grupiranih sličnih opservacija. Primjeri samoorganizirajućih mapa, gdje svjetlina pozadine predstavlja vrijednost promatrane varijable, a boje krugova pripadnost klasi, prikazani su na grafikonima 8 i 9.

8.7.2. VIŠEDIMENZIONALNO SKALIRANJE

Višedimenzionalno skaliranje je tehnika vizualizacije kompleksnih podataka na dvodimenzionalnom grafičkom prikazu. Višedimenzionalno skaliranje na temelju izračunatih udaljenosti među opservacijama, nakon početne slučajne inicijalizacije pokušava optimizirati grafički prikaz da pomicanjem točaka koje predstavljaju opservacije smanjuje ukupnu cijenu koštanja koja je u ovom slučaju udaljenost sličnih opservacija na grafu u odnosu na njihovu računsku udaljenost. Postupak je ekvivalentan crtaju topografske mape samo na temelju udaljenosti među objektima. Primjeri rezultata višedimenzionalnog skaliranja prema Euklidskoj i ReliefF udaljenosti su prikazani za grafikonima 10 i 11.

8.8. Razmatranja o tehnikama za ubrzanje postupka učenja

Većina algoritama strojnog učenja ima varijabilno vrijeme potrebno za učenje s obzirom na veličinu podatkovnog seta i u smislu broja opservacija i u smislu broja varijabli (značajki). Sli-




Grafikon 8: SOM MIT-BIH AD baze prema AAMI anotacijama - sjenčanje po zadnjoj promjeni površine

jedom tih spoznaja, u okviru ovog istraživanja provedeni su eksperimenti koji uključuju izračune važnosti varijabli, analizu temeljnih komponenti (PCA, engl. Principal Component Analysis) i stratificiranje uzorka za učenje.

8.8.1. ANALIZA VAŽNOSTI VARIJABLI

Analiza važnosti (relevantnosti) varijabli jedan je od glavnih koraka u svakoj "data mining" analizi. U ranije prikazanim rezultatima, ovaj korak nije posebno izdvajan s obzirom da je kao klasifikator izabrana metoda slučajne šume. Ova metoda sama po sebi provodi analizu važnosti varijabli prilikom izgradnje svakog stabla, a nijedna od varijabli nije namjerno isključivana iz




Grafikon 9: SOM MIT-BIH AD baze prema AAMI anotacijama - sjenčanje po trajanju konkavnosti

uzorka za učenje kako bi se omogućila što veća "slučajnost" prilikom izgradnje slučajne šume. Ipak, u svrhu potpunosti ovog istraživanja, provedena je zasebna analiza važnosti varijabli u slučaju QRS detekcije i u slučaju raspoznavanja oblika.

Jedna od najčešće korištenih metoda pri analizi važnosti varijabli je tzv. informacijski dobitak (IG - engl. Info gain). Ova metoda se temelji na izračunu entropije pojedinog atributa s obzirom na klasu [68]. Entropija H skupa podataka S definirana je kao

$$H(S) = - \sum_{i=1}^k p_i \log p_i$$

gdje je k broj razreda ciljnog atributa, a p_i vjerojatnost pojave pojedinog razreda. Informacijski




Grafikon 10: Rezultat optimizacije MDS algoritma nad MIT-BIH AD bazom prema AAMI anotacijama primjenom Euklidske udaljenosti

dobitak tada je

$$IG = H(S) - \sum_{i=1}^m \frac{|S_i|}{S} H(S_i)$$

gdje je m skup vrijednosti koje atribut može poprimiti, a S_i je skup svih opservacija za koje atribut poprima pojedinu vrijednost. U teoriji informacije ovakav izračun naziva se uzajamna informacija ili Kullback-Leiblerova divergencija.

Još jedna od zanimljivih metoda izračuna važnosti varijabli koja je ujedno i metoda izračuna udaljenosti je tzv. ReliefF metoda [78]. Ova metoda je efikasna u procjeni relevantnosti varijabli kod problema gdje postoji snažna međuovisnost atributa. Ova metoda pokušava računski utvrditi koliko se pojedini atributi razlikuju u svojim vrijednostima među opservacijama koje su blizu jedna drugoj. Uzevši nasumično izabrano opservaciju I_m koja pripada klasi C , ReliefF metoda traži njenih k najbližih susjeda koji se nazivaju najbliži pogotci (H - engl. *Hits*) te također k najbližih susjeda svake druge klase, koji se nazivaju najbliži promašaji (M - engl. *Misses*). Nakon toga, ažurira se mjera relevantnosti atributa W_i za svaki i -ti atribut temeljem njihove vrijednosti



Grafikon 11: Rezultat optimizacije MDS algoritma nad MIT-BIH AD bazom prema AAMI anotacijama primjenom ReliefF udaljenosti

za opservaciju I_m te H i M . Ako opservacija I_m i one u skupu H imaju različite vrijednosti u i -tom atributu, tada se W_i smanjuje. Suprotno, ako I_m i one u skupu M imaju različite vrijednosti u i -tom atributu, tada se W_i povećava. Cijeli proces se ponavlja onoliko puta koliko je određeno postavkama algoritma od strane korisnika. Jasno je da je opisani postupak relativno spor pa se stoga u istraživanjima rjeđe koristi.

Tablica 22: Tablica relevantnosti značajki prema informacijskom dobitku

Informacijski dobitak	značajka
0.2421	db_avg_10
0.2003	df_avg_10
0.1629	cum_surface
0.1534	rev_cum_angle
0.147	rev_cum_vmd_surface_trend
0.1468	rev_cum_vmd_trend
0.1443	rev_cum_change_surface_trend
0.139	normalized

0.1341	rev_surface_last_change
0.1306	cum_vmd_surface_ref
0.1267	rev_duration_trend
0.1248	cum_vmd_surface_trend
0.1245	rev_cum_vmd_surface_ref
0.1242	cum_vmd_trend
0.1224	rev_cum_change_surface_ref
0.1176	cum_change_surface_ref
0.1172	rev_cum_surface
0.116	surface_last_change
0.1159	cum_angle
0.1146	cum_change_surface_trend
0.1119	rev_surface
0.111	surface
0.1099	value
0.1056	cum_vmd_ref
0.1039	duration_trend
0.0997	rev_cum_angle_detail
0.0974	cum_angle_detail
0.0932	rev_cum_vmd_ref
0.0849	angle
0.0848	rev_angle
0.0826	rev_duration_ref
0.0756	rev_difference
0.0753	cum_vmd_concavity_trend
0.0752	rev_cum_vmd_concavity_trend
0.0743	difference
0.0736	duration_ref
0.0735	rev_cum_vmd_concavity_ref
0.0702	rev_ref_label
0.0678	ref_label
0.0628	cum_vmd_concavity_ref
0.057	cum_concavity_trend
0.048	rev_cum_concavity_trend

0.0473	duration_concavity
0.0222	rev_duration_concavity
0.0215	stationary_point
0.0215	concavity_detail
0.0215	rev_concavity_detail
0.0215	trend
0.0214	concavity_label
0.0214	rev_trend
0.0214	rev_concavity_label
0.0182	cum_concavity
0.0106	rev_cum_concavity
0	duration_concavity_detail
0	rev_coefficient_concavity
0	cum_concavity_detail
0	rev_cum_concavity_detail
0	coefficient_concavity
0	rev_duration_concavity_detail

Tablica 23: Tablica relevantnosti značajki prema ReliefF metodi

ReliefF mjera	značajka
0.0710061143237677	normalized
0.05852534457926196	avg_10
0.05238689740784738	db_01
0.0516495884354275	rev_surface_last_change
0.04892052384959705	rev_cum_angle
0.048336732064731075	log_avg_ratio
0.04439715402728234	surface_last_change
0.0422760354104888	cum_angle
0.04185406924113212	db_avg_10
0.040531756944479594	duration_trend
0.0403440704319641	rev_angle
0.04003086583211174	rev_difference
0.03990632745953657	difference

0.03975139440228704	angle
0.039695248685262426	rev_duration_concavity
0.037867511567046507	rev_duration_trend
0.03781663110460831	rev_cum_angle_detail
0.03635007235406487	rev_cum_change_surface_trend
0.034999855958028014	df
0.03464586083008374	cum_angle_detail
0.03239277196703753	duration_concavity
0.031492857709411314	value
0.03134230888984818	surface
0.03126381477166702	rev_surface
0.030293154022762475	rev_cum_change_surface_ref
0.028895396443435722	db_03
0.02722748734053832	db_05
0.027032584540945644	db_07
0.02661443709099942	cum_change_surface_trend
0.026250955380195694	db_09
0.025054574972560795	db_02
0.02437973046147757	rev_cum_surface
0.024247865434087756	cum_change_surface_ref
0.02388402321665822	db_04
0.023528115766882192	ref_label
0.023432141082381407	df_avg_10
0.023226740130743332	db_06
0.022189186931786786	db_10
0.021497147475278672	db_08
0.020030306151288948	rev_duration_ref
0.01972584204306296	cum_vmd_ref
0.019612636248495477	cum_vmd_surface_ref
0.01857270984202017	rev_ref_label
0.018238361361937194	cum_vmd_trend
0.01807761429338125	cum_vmd_surface_trend
0.017153268434777148	rev_concavity_detail
0.017153268434777148	concavity_detail

0.014067307560884822	rev_cum_vmd_trend
0.01404452499095505	rev_cum_vmd_surface_trend
0.013063369476345886	duration_ref
0.012753584366176837	rev_cum_vmd_surface_ref
0.012589507236521294	rev_cum_vmd_ref
0.012207402740395638	coefficient_concavity
0.012207402740395638	rev_coefficient_concavity
0.011081214177778903	cum_surface
0.006665048242663017	rev_cum_concavity_detail
0.0055409789283650925	avg_ratio
0.005246209389198455	cum_concavity_detail
0.002850423050595782	trend
0.0028494531373060208	rev_trend
0.002848483224016265	stationary_point
0.002848483224016265	concavity_label
0.002848483224016265	rev_concavity_label
0.0010423144779467465	rev_cum_concavity_trend
0.0010350308422194152	cum_concavity_trend
0.0010167389506183673	cum_vmd_concavity_trend
0.0006851063593145476096	rev_cum_vmd_concavity_trend
0.0006825350075266819072	rev_cum_vmd_concavity_ref
0.0003530764221237126144	rev_cum_concavity
0.0003130102416258045952	cum_vmd_concavity_ref
0.0001167102999958730496	cum_concavity
0.0000038796531590075632	duration_concavity_detail
-0.00000000000000000000253	rev_duration_concavity_detail

Ukoliko se navedena metoda raspoznavanja uzoraka primjenjuje u istraživanjima s još većim skupovima podatka nego što je to ovdje bio slučaj, tada se navedena metoda iznalaženja važnosti varijabli može primijeniti u svrhu smanjivanja dimenzionalnosti i samim time kompleksnosti modela.

8.8.2. ANALIZA TEMELJNIH KOMPONENTI

Analiza temeljnih komponenti (PCA - engl. Principal Components Analysis), spada u skupinu metoda za redukciju odnosno smanjenje dimenzionalnosti skupova podataka. Riječ je o jednostavnoj neparametarskoj metodi koja pojednostavljeni rečeno traži novi koordinatni sustav za prikaz originalnih podataka u što manje dimenzija i uz što manji gubitak varijance izvornog skupa. U nastavku je prikazan eksperiment u kojem je dimenzionalnost originalnog skupa smanjena na glavne komponente uz zadržavanje 95% varijance te je prikazana analiza točnosti klasifikacije.

Tablica 24: PCA eksperiment

Metoda	Broj varijabli	Uspješnost
originalne varijable	62	96,02
PCA 95% varijance	21	93,88

8.8.3. STRATIFICIRANJE UZORKA ZA UČENJE

Osim smanjenja dimenzionalnosti, u svrhu skraćivanja vremena učenja algoritma moguće je smanjiti podatkovni set korišten za učenje na način da se iz cijelog seta izdvoji samo jedan njegov dio (engl. downsampling). Prilikom uzorkovanja podataka važno je obratiti pozornost na zastupljenost pojedinih klasa unutar izvornog seta i onog koji je nastao uzorkovanjem. Ukoliko je riječ o izrazito asimetričnim podacima, mogući pristup je stratificirati uzorak na način da distribucije klasa unutar novonastalog seta odgovaraju izvornom setu ili pak da klase budu podjednako zastupljene kako bi se eliminirao problem asimetričnosti. Kada govorimo o detekciji QRS kompleksa u EKG signalu, tada je ovaj pristup izrazito važan s obzirom na vrlo veliki podatkovni set koji nastaje nakon preprocesiranja izvornih signala, odnosno transformacije u vektore percepcije i odabira ekstrema. Mogući pristup je grupiranje (klasteriranje) svih "nebitnih" vektora u nekoliko klastera te potom uzorkovanje na način da svi klasteri budu jednako zastupljeni u uzorku kako bi se što bolje uhvatila varijanca valova koji u signalu ne predstavljaju otkucaje srca. Ovakvo uzorkovanje nije provedeno u ovom istraživanju, no biti će predmet budućih eksperimenata.

9. Primjena u području računalnog vida

U literaturi je do sada opisan postupak predstavljanja dvodimenzionalnih oblika pomoću vremenskih serija. Kako je metoda prikazana u ovom radu dala vrlo dobre rezultate u smislu raspoznavanja oblika u vremenskoj seriji tj. različitih EKG valova, logičnim su se činili i eksperimenti iz domene raspoznavanja dvodimenzionalnih objekata. Ovo poglavlje opisuje neke provedene eksperimente i dobivene rezultate. Kako raspoznavanje oblika nije glavna tema ovog rada i istraživanja, već svojevrsni neplanirani i sekundarni rezultat, u nastavku su samo ukratko opisani glavni koncepti i neki dobiveni rezultati. Detaljna razmatranja ovog područja primjene biti će predmet budućih istraživanja.

9.1. Raspoznavanje dvodimenzionalnih oblika

Jedan od problema iz područja računalnog vida je analiza sličnosti oblika (engl. shape similarity analysis). U literaturi postoje mnogi pristupi analizi sličnosti oblika i kao i kod većine drugih problema strojnog učenja postoje istraživanja koja za cilj imaju klasifikaciju oblika (nadzirano učenje) i pronalazak sličnih oblika (nenadzirano učenje). U narednim poglavljima ukratko će biti prikazane ideje, postupci i rezultati u primjeni metode vektora percepcije u ovakvim problemima.

Ideja raspoznavanja dvodimenzionalnih oblika pomoću analize vremenskih serija zasniva se na vrlo jednostavnoj transformaciji obrisa objekta. Najjednostavnija takva transformacija je pojašnjena u nastavku. Prvi korak je pronaći centralni moment (težište gravitacije) promatranog objekta. U drugom koraku se za svaku točku konture (rubne linije) objekta izmjeri njena udaljenost od središta. U trećem koraku se kreira vremenska serija koja zapravo predstavlja niz izmjerenih udaljenosti. Tako dobivena serija podobna je za daljnju analizu. Navedeni postupak prikazan je na slici 25.



Slika 25: Transformacija slike brojke u vremensku seriju

9.1.1. RASPOZNAVANJE RUKOM NAPISANIH BROJKI

Testiranje uspješnosti opisane metode u klasifikaciji oblika provedeno je pomoću MNIST podatkovnog skupa koji sadrži sličice rukom napisanih brojeva [93]. Skup se sastoji od 60000 sličica

za učenje i 10000 sličica za test. Postupkom opisanim ranije, svaka sličica je pretvorena u vremensku seriju. U tu svrhu korištena je programska biblioteka slobodnog koda OpenCV koja sadrži mnoge metode za manipulaciju slikama. Na svakoj sličici su pronađeni rubovi primjenom Canny detektora te su navedeni rubovi pretvoreni u konture. Od svih pronađenih kontura, izdvojena je ona sa najvećom površinom. Za najveću konturu izračunati su momenti (*HU moments*). Od centralnog momenta (centar gravitacije konture) i od svake točke konture izračunata je udaljenost metodom Euklidske udaljenost. Tako izračunate udaljenosti pohranjene su slijedno (vremenska serija).


9.1.1.1. Zaključivanje primjenom Bayesove uvjetne vjerojatnosti

Rezultat ranije opisane transformacije slike odnosno konture objekta o u vremensku seriju je skup V_o koji se sastoji od niza vektora $\overrightarrow{V_{P_i}}$ od kojih svaki odgovara jednom valu odnosno ekstremu. Za svaki od navedenih vektora, može se ustanoviti kojoj klasi potencijalno pripada uspoređujući ga sa ostalim vektorima iz skupa za učenje V . Dakle $V_o \subset V$. Klasifikacijom svakog pojedinog vektora možemo dobiti vjerojatnosti p_{ik} koje govore kolike su šanse da vektor $\overrightarrow{V_{P_i}}$ pripada klasi k . Sljedeći problem je donošenje odluke o tome kojoj klasi pripada objekt o . Ovaj problem riješen je analogno zaključivanju o vrsti EKG valova na temelju informacija iz više odvoda, dakle primjenom Bayesovog produkta, a što je opisano ranije u radu. Jedina razlika je sada što umjesto vjerojatnosti za klasu EKG vala na temelju različitih odvoda imamo vjerojatnosti za klasu oblika na temelju različitih dijelova oblika.

9.1.1.2. Rezultati

Ovisno o postavkama korištenog klasifikatora, uspješnost u klasifikaciji brojki iz MNIST skupa podataka kreće se oko 90%. U usporedbi s drugim istraživanjima gdje uspješnost dostiže i preko 99,7%, ovaj rezultat nije u vrhu trenutnih znanstvenih spoznaja. Ipak valja imati na umu kako je riječ o pilot eksperimentu primjene metode izvorno osmišljene za analizu EKG valova te o prvoj implementaciji u području analize sličnosti oblika. Opisana metoda svakako se može poboljšati, primjerice uključivanjem informacija o unutarnjim konturama zbog brojki koje takve konture imaju (brojke, 0, 6, 8, 9, ponekad i 4), uključivanjem informacija o površini konture, broju detektiranih kontura i slično. Dodatno, postupci koji prema dostupnoj literaturi daju najbolje rezultate u klasifikaciji brojki iz MNIST skupa podataka uključuju i faze preprocesiranja gdje se "umjetno" povećava skup podataka za učenje primjenom različitih distorzija i transformacija sličica iz skupa podataka za učenje. Primjer takvih distorzija su Affine transformacije kojima autori zapravo simuliraju gledanje objekta iz različitih kutova. Na ovaj način uvodi se dodatna varijanca u skup podataka za učenje i dobivaju se bolji rezultati klasifikacije. Ovdje prijavljeni rezultati (90% us-

pješnosti) dobiveni su eksperimentima u kojima takve distorzije nisu rađene, već je korišten samo originalni skup podataka za učenje. Uključivanje ovakvog i sličnih postupaka, također bi potencijalno mogli povećati uspješnost metode. Naredna istraživanja dati će odgovor na pitanje može li se ovakvim pristupom razviti "state of the art" postupak za klasifikaciju oblika. Rezultat postignut na ovom skupu podataka nije zanemariv ni za analizu EKG valova jer govori da je moguće sa relativno visokom uspješnošću raspoznavati razmjerne male oblike u vremenskim serijama s obzirom da su MNIST sličice velike svega 28×28 piksela. Ovo daje nadu da će metoda moći raspoznavati male, ali medicinski važne dijelove EKG signala (npr. P valove i ST segmente). Primjeri pogrešaka u klasifikaciji prikazani su na slici 26. Lijevi dio slike predstavlja sličice brojki iz originalnog MNIST skupa podataka za testiranje. Zaokruženi su primjeri na kojima je metoda pogriješila u klasifikaciji. Srednji dio su dobivene konture dvaju pogrešno klasificiranih slova. Desno su prikazane vjerojatnosti za prve dvije pogodjene klase za svako slovo. Vidljivo je da je najveća vjerojatnost pridružena pogrešnoj klasi, a sljedeća po vjerojatnosti je ispravna klasa.



Slika 26: Primjeri pogrešno razvrstanih brojki

9.1.2. RASPOZNAVANJE SLOŽENIJIH 2D OBLIKA

U svrhu testiranja uspješnosti opisane metode u analizi dvodimenzionalnih oblika metodama nenadziranog učenja, iskorišten je tzv. *Fish contours* skup podataka koji sadrži veće i složenije dvodimenzionalne obrise dobivene iz fotografija morskih organizama [26]. Navedeni skup podataka nema označene klase već se koristi u svrhu analize sličnosti, a test kojim se analizira uspješnost metode je tzv. Bullseye test. Cilj tog testa je za neki obris dohvatiti niz "najsličnijih" obrisa iz baze.


9.1.2.1. Nenadzirano učenje i Mahalanobisova udaljenost

Kako je objašnjeno ranije, Mahalanobisova udaljenost je dobra mjera sličnosti između dvije točke u višedimenzionalnom prostoru koja u obzir uzima i raspršenost podataka što ju čini prikladnom za uspoređivanje varijabli koje su izvorno različitih skala. Iako se u literaturi Mahalanobisova

udaljenost najčešće koristi u svrhu identifikacije netipičnih vrijednosti (engl. outlier) u višedimenzionalnim prostorima, u ovom istraživanju je proveden eksperiment koji je za cilj imao identifikaciju sličnih oblika pomoću ove mjere udaljenosti. Na temelju svih točaka ekstrema iz izvučenih i transformiranih kontura obrisa *Fish contours* podatkovnog skupa kreirana je velika matrica podataka. Nakon toga izračunata je matrica kovarijanci i njezin inverz te je za svaku točku iz testnog oblika izračunata Mahalanobisova udaljenost sa svim ostalim ekstremima iz početne matrice. Za svaki oblik iz baze izračunata je ukupna Mahalanobisova udaljenost te su rezultati poredani rastuće po udaljenosti.

9.1.2.2. Rezultati

Na slici 27 je prikazan primjer upita koji za jedan obris (u kutu gore lijevo) dohvata niz naj-sličnijih objekata temeljem gore opisanog postupka. Rezultati su poredani slijeva udesno prema padajućoj sličnosti (rastućoj ukupnoj Mahalanobisovoj udaljenosti). Na slici je vidljivo kako većina obrisa vizualno odgovara obrisu za koji je postavljen upit, no ipak potkrala su se i dva obrisa koji nisu toliko slični. To su treći i peti obris u donjem redu za koje je vidljivo da imaju određene "slične segmente" obrisa. Daljnja istraživanja biti će usmjerena na analizu i eliminaciju ovakvih pogrešaka.



Slika 27: Rezultati upita za dohvata sličnih oblika iz baze *Fish contours*

9.2. Razmatranja o raspoznavanju 3D oblika

Pojavom senzora poput stereo kamera, 3D skenera i time-of-flight kamera postalo je moguće snimati objekte u 3 dimenzije. Takvi snimci sadrže koordinate objekata u prostoru, a nazivaju se

oblaci točaka (PC - engl. Point Cloud). Kako se radi o koordinatama u prostoru, moguće je primjenom metoda sličnih onima opisanima ranije pronaći karakteristične točke objekata. Primjerice najizbočenije ili najudubljenije. Na taj način mogu se kreirati "orientirni" za računanje vremenskih serija s obzirom na ostale točke trodimenzionalne plohe i na taj način predstaviti objekt kao niz vektora \vec{V}_P i potencijalno primijeniti opisanu metodu u analizi oblika.

9.3. Razmatranja o raspoznavanju slika u boji

Kako se digitalna reprezentacija svake slike u boji sastoji od niza brojeva koji zapravo predstavljaju intenzitet pojedinih komponenti boje (npr. crvena, zelena i plava za RGB prostor boja), moguće je na slikama u boji pronaći različite karakteristične točke poput najsvjetlijih ili najtamnijih te analogno postupcima kod dvodimenzionalnih obrisa prikazati sliku kao niz vremenskih serija. Buduća istraživanja razmatrat će ovakve scenarije i iskušati predloženu metodu u raspoznavanju slika u boji (npr. različitih tekstura i sl.).

10. Paralelizacija

Bez obzira na ranije opisane metode reduciranja dimenzionalnosti podatkovnog skupa ili stratificiranja uzorka za učenje, izgradnja odnosno učenje kompleksnih modela može biti vremenski zahtjevan proces. Ponekad zbog navedenih nedostataka (u smislu malog gubitka točnosti prediktivnog modela) takve tehnike niti ne želimo ili ne možemo koristiti. Zbog toga, napredno računarstvo i primjene u znanosti posljednjih godina bilježe pokušaje da se kompleksni računski problemi koji zahtijevaju mnogo procesorskih ciklusa riješe pomoću koncepta paralelne obrade ili paralelizacije. Paralelna obrada podrazumijeva uključivanje više od jednog centralnog procesora u rješavanje računskog problema. Paralelna obrada također je analogna obradi koja se događa u mozgu, obzirom da i centralni živčani sustav obrađuje informacije u visoko paralelnom modu. U implementaciji algoritama strojnog učenja, problemi optimizacije se dijele na onoliko pod skupova koliko je procesora na raspolaganju. Često ti procesori nisu samo centralni procesori (engl. Central Processing Unit - CPU) već i grafički procesori (engl. Graphics Processing Unit - GPU) čija visoko paralelna arhitektura omogućava izvedbu takvih proračuna. GPU procesori su uglavnom projektirani za razne grafički zahtjevne aplikacije poput 3D modeliranja i video igara. No mnoge procesorske jezgre mogu biti korištene i za općenite proračune, a u novije vrijeme proizvođači na tržište plasiraju grafičke kartice specijalizirane upravo za takve općenite proračune. Takav koncept odnosno proizvodi nazivaju se GPGPU (engl. General-purpose computing on graphics processing units ili General-purpose graphics processing unit). S pojavom novih i moćnijih resursa (GPU i superračunala), u disciplini strojnog učenja ponovno su zaživjele metode koje neko vrijeme nakon inicijalnog predstavljanja nisu bile toliko popularne. Primjer takvog slučaja su neuronske mreže. Zahvaljujući prednostima paralelne obrade, istraživači imaju mogućnost treniranja velikih i dubokih neuronskih mreža (engl. deep learning) čije učenje zahtijeva iterirano ažuriranje tisuća ili čak milijuna parametara tj. veza među neuronima. Zahvaljujući modernim superračunalima posljednjih godina se izgrađuju modeli koji su bliži strukturama u ljudskom mozgu koji samo u vidnoj kori ima preko 140 milijuna neurona u svakoj hemisferi [57]. Obzirom da je ključni dio predložene metode transformacija vremenske serije u vektore percepcije, logičan je korak razmotriti je li tu transformaciju moguće paralelizirati. Razmatrajući opisani postupak transformacije vremenske serije u vektore \vec{V}_P može se konstatirati kako se svi izračuni dinamičkih kumulativa i VMD komponenti mogu odvijati paralelno tj. svaki u svojoj dretvi s obzirom da ne ovise jedni o drugima. Na ovaj način transformacija vremenskih serija bi se dodatno ubrzala što može biti posebno značajno kod primjene u području računalnog vida. Transformacijom mnogih segmenata dvodimenzionalnih, trodimenzionalnih oblika ili komponenti boja, kako je opisano ranije u radu, brzo se mogu

dobiti vektori odnosno značajke za primjenu u klasifikatoru.

11. Buduća istraživanja

Kako je opisano u poglavlju koje se bavi problemom nebalansiranih podataka, postoje mnogi pristupi u svladavanju poteškoća koji oni uzrokuju. U okviru ovog istraživanja, pri testiranju metode u detekciji QRS kompleksa nakon filtriranja signala primijenjeni su pristupi slučajnog poduzorkovanja, klasifikacije osjetljive na koštanje i spuštanja praga vjerojatnosti za detektiranje QRS kompleksa. Buduća istraživanja moguća su u smislu primjene ostalih metoda za rješavanje problema nebalansiranih podataka opisanih u ovom radu i postojećoj literaturi te njihovog kombiniranja što bi moglo dodatno poboljšati rezultate. Primjerice poduzorkovanje klase nebitnih ekstrema (valova koji nisu QRS kompleks) koje nije slučajno već je temeljeno na prethodnom grupiranju (nenadzirano) takvih valova i odabiru poduzorka koji će obuhvatiti predstavnike svih detektiranih grupa. Time bi se smanjio gubitak informacije o oblicima nebitne klase koji može nastati slučajnim poduzorkovanjem.

S obzirom da nemaju svi ljudi iste karakteristike i manifestacije EKG signala, znanstveni izazovi koji se javljaju u ovom području svakako se tiču izgradnje algoritama i pristupa koji će biti prilagodljivi individualnom pacijentu [22]. Također, u posljednje vrijeme, javljaju se i istraživanja koja pokušavaju odgovoriti na problem snimanja EKG-a u prenatalnoj dobi tj. kod trudnica (gdje se miješaju signali djeteta i majke), ali i male djece [51], [4]. Ovi izazovi daju sasvim novu dimenziju problemu prepoznavanja EKG signala, obzirom da je za očekivati kako će biti teško osmisiliti pristupe i algoritme koji će osim za odrasle i ljude opće populacije, raditi i u ovim slučajevima (trudnice, djeca i ljudi s nestandardnim EKG signalom), a moderni algoritmi koji postižu iznimno visoke rezultate (gotovo 100%) na standardnim bazama podataka, nisu testirani u ovakvim slučajevima. Pored ovoga, povezivanje praćenja EKG signala sa ne-vremenskim (ne temporalnim) atributima i rudarenje podacima iz npr. područja genetike u kombinaciji sa ovakvim metodama detektiranja aritmija mogu unijeti potpuno novu dimenziju u medicinsku skrb ne samo srčanih bolesnika, već i ljudi koji imaju predispoziciju da to postanu. Očekuje se da će rudarenje podacima, kako ne-vremenskih podataka, tako i vremenskih serija, imati važnu ulogu u medicini budućnosti koja sve više ide ka preventivnoj dijagnostici [70].

Rastom performansi mobilnih uređaja poput ručnih računala, a kasnije i mobilnih telefona, počeli su sejavljati koncepti mobilnog praćenja medicinskih parametara, pa tako i EKG-a. U literaturi nalazimo nekoliko primjera takvih sustava no za sada još nema znanstvenih potvrda o njihovoj učinkovitosti u pogledu detektiranja QRS kompleksa i srčanih aritmija [46], [89], [33]. Za prepostaviti je da je to područje koje u skoroj budućnosti očekuje implementacija nekih od opisanih ili sličnih algoritama.

Ovo istraživanje rezultiralo je zanimljivim stopama uspješnosti u detekciji i raspoznavanju pojedinačnih EKG valova. Ipak, za pružanje kompletne slike o zdravstvenom stanju pacijenata, potrebna je dijagnostika na temelju više točaka, a ne samo "R" zupca. Kako se predložena metoda pokazala uspješnom u detekciji oblika valova pa i u raspoznavanju relativno malih oblika (male sličice iz MNIST podatkovnog skupa), logičnim izazovom se čini i pokušaj detekcije i prepoznavanja manjih dijelova EKG signala (P, Q, S i T valovi). Također, zanimljivo bi bilo istražiti i mogućnosti kombiniranja prediktivne sposobnosti predložene metode sa Markovljevim modelima i temporalnim Bayesovim mrežama u svrhu analize pojavnosti određenih oblika u nizovima.

Mogućnosti dalnjih istraživanja u ovom području podrazumijevaju kreiranje novih pristupa i metoda za rudarenje podacima iz vremenskih serija, testiranje tih metoda na realnim podacima, ali i provođenje istraživanja primjenom postojećih metoda za rješavanje novih problema.

Na vizualizacijama prikazanima u radu i u prilozima može se uočiti postojanje određenih "otoka" unutar skupina iste anotacije, ali i "otoci" u kojima se anotacije preklapaju. Ovakve pojave će u budućim istraživanjima biti detaljnije istražene kako bi se utvrdilo kakve zakonitosti stoje iza tih pojava. Konkretno to može značiti da su neki valovi pogrešno anotirani ili da neke klase treba detaljnije anotirati u podskupine. Ovakve tvrdnje su samo nagađanja i trebaju biti potkrijepljene dokazima što svakako ostavlja prostora za budući znanstveni rad.

U okviru ovog istraživanja, značajan dio cijelog procesa je implementiran u programskom jeziku C++. Konkretno, to su modul za pretprocesiranje MIT-BIH AD baze, digitalni filtri (median i butterworth) te sama transformacija u vektore percepcije. Ostatak procesa odnosno klasifikacija i testiranje provedeni su u specijaliziranim alatima Orange (Python) i Weka (Java). Budući rad iz područja usmjerit će se na zaokruživanje cijelog procesa odnosno izradu funkcionalnog prototipa aplikacije kao jednog integriranog programskog paketa. Kako su se najuspješnijima u klasifikaciji pokazale metode stabla odlučivanja, mogući smjer je korištenje C/C++ implementacija stabala odlučivanja iz programskog paketa OpenCV i njegovog ML (Machine Learning) modula.

Još jedno područje budućeg istraživanja i provođenja eksperimenata je spomenuto pronalaženje optimalnih granica za trend i konkavnost optimizacijom na način da informacijski dobitak svakog razreda (izračunom entropije) bude maksimalan s obzirom na ciljnu klasu.

Iako u ovom istraživanju nisu predstavljeni rezultati korištenja neuronskih mreža kao klasifikatora, koncept neuronskih mreža zapravo je možda i najprirodniji odabir za izradu kompleksnog klasifikatora koji bi se temeljio na predstavljenoj metodi. Optimizacija takve neuronske mreže bi podrazumijevala optimizaciju granica zahvaljujući povratnoj vezi od klasifikatora (potencijalno uz kombinaciju sa izračunom entropije u odnosu na ciljnu varijablu). Pogreška klasifikatora pri određenim granicama zapravo bi bila funkcija koštanja za koju želimo da bude što manja. U

cilju smanjenja takve funkcije koštanja parametri optimizacije bi bile upravo granice transformacije koje bi onda bilo moguće optimizirati specijaliziranim algoritmima kao što je npr. gradijentni spust. Ovo bi omogućilo da se klasifikator prilagođava individualnim pacijentima u slučaju raspoznavanja EKG-a ili promjenama razine svjetla na slici ako se radi o problemu iz domene računalnog vida.

U domeni računalnog vida, buduća istraživanja su moguća u smislu testiranja metode na novim problemima odnosno skupovima podataka za raspoznavanje oblika. Nadalje, kako je ukratko opisano u radu, mogući daljnji znanstveni rad je testiranje metode u raspoznavanju slika u boji i 3D snimaka (tzv. oblaci točaka - engl. point cloud).

12. Osvrt na pravne i etičke aspekte istraživanja

Predloženo istraživanje podrazumijeva testiranje nove metode nad ljudskim EKG signalima. S obzirom da su u istraživanju korišteni EKG signali iz standardizirane baze signala MIT-BIH Arrhythmia Database u kojoj su svi signali odvojeni od bilo kojeg podatka koji bi mogao upućivati na identitet osobe čiji rad srca se snimao, nije bila potrebna nikakva dodatna suglasnost za provođenje samog istraživanja. Valja međutim imati na umu pravne aspekte za istraživanja koja bi mogla uslijediti nakon ovoga. Obzirom da su u ovom istraživanju postignuti pozitivni rezultati, potvrđene hipoteze i postignuti zadani ciljevi, logičan sljedeći korak je analiza uspješnosti nove metode u prepoznavanju oblika EKG valova nad podacima iz kliničke prakse. U tom slučaju biti će potrebno dobiti suglasnost etičkog povjerenstva ustanove u kojoj će se prikupljati signali, a u svrhu odobravanja kliničkog istraživanja. Obzirom da se neće izvoditi nikakvi postupci nad samim pacijentima niti će se testirati bilo kakvi lijekovi ili uređaji, nije potrebno tražiti mišljenje i suglasnost Središnjeg etičkog povjerenstva pri Hrvatskoj agenciji za lijekove i medicinske proizvode. U okviru ovog istraživanja razvijena je nova metoda za klasifikaciju EKG signala, a programska implementacija je korištena samo u svrhu znanstvenog istraživanja. Slijedom toga, u okviru ovog istraživanja nije bilo potrebno provoditi certifikaciju medicinskog softvera prema normama CEI/IEC 62304. Zadovoljavanje navedene i ostalih normi biti će potrebno za eventualnu kasniju komercijalnu implementaciju metode i softvera u medicinske svrhe.

13. ZAKLJUČAK

U ovom radu predstavljena je nova metoda analize vremenskih serija te njene implementacije u analizi elektrokardiograma. Vremenske serije su poseban statistički problem zbog međusobne zavisnosti opservacija što znači da klasične statističke metode u njihovoj analizi nisu primjenjive. Vremenske serije susreću se u mnogim aspektima ljudskog djelovanja, a mnogi pristupi njihovim analizama u literaturi dokazuju da se radi o kompetitivnom i zanimljivom tehničkom i znanstvenom izazovu. Jedan od zanimljivijih problema iz domene vremenskih serija je analiza elektrokardiograma (EKG). Računalna analiza EKG-a obuhvaća nekoliko područja kao što su uklanjanje šumova i smetnji, detekcija otkucaja srca (QRS kompleksa), analiza varijabilnosti ritma, raspoznavanje oblika valova i sl. Istraživanje predstavljeno u ovom radu usmjereno je na detekciju QRS kompleksa i raspoznavanje oblika valova. QRS detekcija je temelj za analizu srčanog ritma koja je jedna od važnijih metoda za otkrivanje patologija. S druge strane, raspoznavanje oblika valova je također vrlo važan izazov jer se temeljem oblika valova mogu raspoznati patologije koje se ne mogu otkriti samo analizom ritma. Tijekom istraživanja razvijena je metoda transformacije vremenske serije u višedimenzionalne vektore čija je svrha opisivanje oblika u seriji. Metoda se pokazala vrlo uspješnom i u detekciji i u raspoznavanju oblika valova. Postignuti su rezultati koji metodu svrstavaju u *state of the art* metode u obje domene. Točnost detekcije QRS kompleksa je iznad 99,7%, a u smislu raspoznavanja oblika valova postignuta je točnost iznad 96%. U smislu detekcije QRS kompleksa samo su rijetki pristupi neznatno uspješniji, a u smislu raspoznavanja oblika, u literaturi dostupnoj autoru, nisu pronađene uspješnije metode. Posebnost nove metode je i to što rješava oba problema, a takve metode nisu poznate u literaturi.

Osim analize EKG signala, istraživanje je obuhvatilo i implementaciju metode na problemima iz domene računalnog vida. Postignuti su vrlo dobri rezultati raspoznavanja rukom napisanih brojeva iz *MNIST* skupa podataka te zanimljivi rezultati u smislu pronalaženja sličnih objekata iz *Fish contours* skupa podataka.

U istraživanju su predstavljene i smjernice za buduća istraživanja te potencijalna unaprjeđenja metode koja bi u budućnosti mogla značiti još bolje rezultate u rješavanju navedenih problema. Također, predstavljena su i druga potencijalna područja primjene predložene metode u raspoznavanju 3D oblika i slika u boji.

LITERATURA

- [1] ADAMEC, J., AND ADAMEC, R. *ECG Holter: Guide to Electrocardiographic Interpretation.* Springer, 2008.
- [2] BARBERO ROMERO, V. *ECG baseline wander removal and noise suppression analysis in an embedded platform.* PhD thesis, 2009.
- [3] BATYRSHIN, I. Z., AND SHEREMETOV, L. B. Perception-based approach to time series data mining. *Appl. Soft Comput.* 8, 3 (June 2008), 1211–1221.
- [4] BAUMERT, M., JAVORKA, M., SEECK, A., FABER, R., SANDERS, P., AND VOSS, A. Multiscale entropy and detrended fluctuation analysis of qt interval and heart rate variability during normal pregnancy. *Computers in biology and medicine* 42, 3 (2012), 347–352.
- [5] BRADSKI, D. G. R., AND KAEHLER, A. *Learning OpenCV*, 1st Edition, first ed. O'Reilly Media, Inc., 2008.
- [6] BREIMAN, L. Random forests. *Machine Learning* 45, 1 (2001), 5–32.
- [7] CHANG, C.-C., AND LIN, C.-J. Libsvm: a library for support vector machines. *ACM Transactions on Intelligent Systems and Technology (TIST)* 2, 3 (2011), 27.
- [8] CHANG, P.-C., LIN, J.-J., HSIEH, J.-C., AND WENG, J. Myocardial infarction classification with multi-lead {ECG} using hidden markov models and gaussian mixture models. *Applied Soft Computing* 12, 10 (2012), 3165 – 3175.
- [9] CHAWLA, N. V., BOWYER, K. W., HALL, L. O., AND KEGELMEYER, W. P. Smote: synthetic minority over-sampling technique. *arXiv preprint arXiv:1106.1813* (2011).
- [10] CLIFFORD, G. D., AZUAJE, F., AND MCSHARRY, P. *Advanced Methods; Tools for ECG Data Analysis.* Artech House, Inc., Norwood, MA, USA, 2006.
- [11] COX, J., NOLLE, F., FOZZARD, H., AND OLIVER, G. Aztec, a preprocessing program for real-time ecg rhythm analysis. *Biomedical Engineering, IEEE Transactions on*, 2 (1968), 128–129.

- [12] CRONE, S. F. Mining the past to determine the future: Comments. *International Journal of Forecasting* 25, 3 (2009), 456–460.
- [13] DAMLE, C., AND YALCIN, A. Flood prediction using time series data mining. *Journal of Hydrology* 333, 2 (2007), 305–316.
- [14] DARRINGTON, J. M. *Real time extraction of ECG fiducial points using shape based detection*. PhD thesis, School of Computer Science and Software Engineering, University of Western Australia, 2009.
- [15] DAYAN, P., ABBOTT, L. F., AND ABBOTT, L. Theoretical neuroscience: Computational and mathematical modeling of neural systems.
- [16] DE CHAZAL, P., O'DWYER, M., AND REILLY, R. B. Automatic classification of heartbeats using ecg morphology and heartbeat interval features. *Biomedical Engineering, IEEE Transactions on* 51, 7 (2004), 1196–1206.
- [17] DE GAETANO, A., PANUNZI, S., RINALDI, F., RISI, A., AND SCIANDRONE, M. A patient adaptable ecg beat classifier based on neural networks. *Applied Mathematics and Computation* 213, 1 (2009), 243–249.
- [18] DE LUNA, A. *Basic Electrocardiography: Normal and Abnormal ECG Patterns*. John Wiley & Sons, 2008.
- [19] DEMŠAR, J., CURK, T., ERJAVEC, A., ČRT GORUP, HOČEVAR, T., MILUTINOVIC, M., MOŽINA, M., POLAJNAR, M., TOPLAK, M., STARIC, A., ŠTAJDOHAR, M., UMEK, L., ŽAGAR, L., ŽBONTAR, J., ŽITNIK, M., AND ZUPAN, B. Orange: Data mining toolbox in python. *Journal of Machine Learning Research* 14 (2013), 2349–2353.
- [20] DOMINGOS, P. Metacost: a general method for making classifiers cost-sensitive. In *Proceedings of the fifth ACM SIGKDD international conference on Knowledge discovery and data mining* (1999), ACM, pp. 155–164.
- [21] DONOSER, M., RIEMENSCHNEIDER, H., AND BISCHOF, H. Efficient partial shape matching of outer contours. In *Computer Vision–ACCV 2009*. Springer, 2010, pp. 281–292.
- [22] DOUGLAS, P. K., BATDORF, N. J., EVANS, R. T., FEIVESON, A. H., ARENARE, B., AND SCHLEGEL, T. T. Temporal and postural variation of 12-lead high-frequency qrs electrocardiographic signals in asymptomatic individuals. *Journal of electrocardiology* 39, 3 (2006), 259–265.

- [23] DUBOIS, R., MAISON-BLANCHE, P., QUENET, B., AND DREYFUS, G. Automatic ecg wave extraction in long-term recordings using gaussian mesa function models and nonlinear probability estimators. *Computer methods and programs in biomedicine* 88, 3 (2007), 217–233.
- [24] DUTTA, S., CHATTERJEE, A., AND MUNSHI, S. Identification of ecg beats from cross-spectrum information aided learning vector quantization. *Measurement* 44, 10 (2011), 2020–2027.
- [25] ERIKSSON, B., BARFORD, P., BOWDEN, R., DUFFIELD, N., SOMMERS, J., AND ROUGHAN, M. Basisdetect: a model-based network event detection framework. In *Proceedings of the 10th ACM SIGCOMM conference on Internet measurement* (2010), ACM, pp. 451–464.
- [26] F. MOKHTARIAN, CENTRE FOR VISION, S., AND SIGNAL PROCESSING, UNIVERSITY OF SURREY, U. Fish contours dataset. [Online; pristupano 2 studenoga 2013].
- [27] FOR THE ADVANCEMENT OF MEDICAL INSTRUMENTATION, A. A. ANSI/AAMI EC57:1998/(R)2008 - Testing and reporting performance results of cardiac rhythm and ST segment measurement algorithms.
- [28] FU, T.-C. A review on time series data mining. *Engineering Applications of Artificial Intelligence* 24, 1 (2011), 164–181.
- [29] GACEK, A., AND PEDRYCZ, W. Ecg signal analysis, classification, and interpretation: A framework of computational intelligence. In *ECG Signal Processing, Classification and Interpretation*, A. Gacek and W. Pedrycz, Eds. Springer London, 2012.
- [30] GHOSH, K., AND RAYCHAUDHURI, P. An adaptive approach to filter a time series data. *Technology* (2007), 6.
- [31] GOLDBERGER, A. L., AMARAL, L. A. N., GLASS, L., HAUSDORFF, J. M., IVANOV, P. C., MARK, R. G., MIETUS, J. E., MOODY, G. B., PENG, C.-K., AND STANLEY, H. E. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation* 101, 23 (2000 (June 13)), e215–e220. Circulation Electronic Pages: <http://circ.ahajournals.org/cgi/content/full/101/23/e215> PMID:1085218; doi: 10.1161/01.CIR.101.23.e215.
- [32] GREEN, C. L., KLIGFIELD, P., GEORGE, S., GUSSAK, I., VAJDIC, B., SAGER, P., AND KRUCOFF, M. W. Detection of qt prolongation using a novel electrocardiographic analysis

algorithm applying intelligent automation: Prospective blinded evaluation using the cardiac safety research consortium electrocardiographic database. *American heart journal* 163, 3 (2012), 365–371.

- [33] GUSSAK, I., VUKAJLOVIC, D., VUKCEVIC, V., GEORGE, S., BOJOVIC, B., HADZIEVSKI, L., SIMIC, G., STOJANOVIC, B., ANGELKOV, L., AND PANESCU, D. Wireless remote monitoring of reconstructed 12-lead ecgs after ablation for atrial fibrillation using a hand-held device. *Journal of Electrocardiology* 45, 2 (2012), 129–135.
- [34] HALL, M., FRANK, E., HOLMES, G., PFAHRINGER, B., REUTEMANN, P., AND WITTEN, I. H. The weka data mining software: an update. *SIGKDD Explor. Newsl.* 11, 1 (Nov. 2009), 10–18.
- [35] HAMPTON, J. R. *150 ECG problems*. Churchill Livingstone, 2003.
- [36] HSU, C.-W., CHANG, C.-C., LIN, C.-J., ET AL. A practical guide to support vector classification, 2003.
- [37] HUBEL, D. H. Evolution of ideas on the primary visual cortex, 1955-1978: A biased historical account. *PHYSIOLOGY OR MEDICINE LITERATURE PEACE ECONOMIC SCIENCES* (1993), 24.
- [38] HUBEL, D. H., AND WIESEL, T. N. Receptive fields of single neurones in the cat's striate cortex. *The Journal of physiology* 148, 3 (1959), 574–591.
- [39] INC., S. SPSS Trends 16.0.
- [40] JAGNJIĆ, Ž., BOGUNOVIĆ, N., PIŽETA, I., AND JOVIĆ, F. Time series classification based on qualitative space fragmentation. *Advanced Engineering Informatics* 23, 1 (2009), 116–129.
- [41] JEONG, G.-Y., YU, K.-H., YOON, M.-J., AND INOOKA, E. St shape classification in ecg by constructing reference st set. *Medical engineering & physics* 32, 9 (2010), 1025–1031.
- [42] JIANG, W., AND KONG, S. Block-based neural networks for personalized ecg signal classification. *Neural Networks, IEEE Transactions on* 18, 6 (2007), 1750–1761.
- [43] JOVIĆ, A. *Dubinska analiza biomedicinskih vremenskih nizova zasnovana na računalnom radnom okviru za izlučivanje značajki*. PhD thesis, Fakultet elektrotehnike i računarstva. Sveučilište u Zagrebu., 2012.

- [44] JOVIĆ, A., AND BOGUNOVIĆ, N. Feature set extension for heart rate variability analysis by using non-linear, statistical and geometric measures. In *Information Technology Interfaces, 2009. ITI '09. Proceedings of the ITI 2009 31st International Conference on* (2009), pp. 35–40.
- [45] JOVIĆ, A., AND BOGUNOVIĆ, N. Electrocardiogram analysis using a combination of statistical, geometric, and nonlinear heart rate variability features. *Artificial intelligence in medicine* 51, 3 (2011), 175–186.
- [46] JUN, D., MIAO, X., HONG-HAI, Z., AND WEI-FENG, L. Wearable ecg recognition and monitor. In *Computer-Based Medical Systems, 2005. Proceedings. 18th IEEE Symposium on* (2005), IEEE, pp. 413–418.
- [47] KABIR, M. A., AND SHAHNAZ, C. Denoising of ecg signals based on noise reduction algorithms in emd and wavelet domains. *Biomedical Signal Processing and Control* 7, 5 (2012), 481–489.
- [48] KLEPAC, G. *Otkrivanje zakonitosti temeljem jedinstvenoga modela transformacije vremenske serije*. PhD thesis, Fakultet organizacije i informatike, Varaždin. Sveučilište u Zagrebu., 2005.
- [49] KOHONEN, T. Self-organized formation of topologically correct feature maps. *Biological Cybernetics* 43, 1 (1982), 59–69.
- [50] KONTSCHIEDER, P., DONOSER, M., AND BISCHOF, H. Beyond pairwise shape similarity analysis. In *Computer Vision–ACCV 2009*. Springer, 2010, pp. 655–666.
- [51] KOTAS, M., JEZEWSKI, J., MATONIA, A., AND KUPKA, T. Towards noise immune detection of fetal qrs complexes. *Computer methods and programs in biomedicine* 97, 3 (2010), 241–256.
- [52] KOTSIANTIS, S., KANELLOPOULOS, D., PINTELAS, P., ET AL. Handling imbalanced datasets: A review. *GESTS International Transactions on Computer Science and Engineering* 30, 1 (2006), 25–36.
- [53] KOTSIANTIS, S., AND PINTELAS, P. Mixture of expert agents for handling imbalanced data sets. *Annals of Mathematics, Computing & Teleinformatics* 1, 1 (2003), 46–55.
- [54] KUBAT, M., MATWIN, S., ET AL. Addressing the curse of imbalanced training sets: one-sided selection. In *ICML* (1997), vol. 97, pp. 179–186.

- [55] KUSHNER, F. G., AND BATES, E. R. Chapter 10 - st-segment elevation myocardial infarction. In *Cardiovascular Therapeutics: A Companion to Braunwald's Heart Disease (Fourth Edition)*, fourth edition ed. W.B. Saunders, Philadelphia, 2013, pp. 178 – 213.
- [56] LEE, C.-H., CHEN, J. C.-Y., AND TSENG, V. S. A novel data mining mechanism considering bio-signal and environmental data with applications on asthma monitoring. *Computer methods and programs in biomedicine* 101, 1 (2011), 44–61.
- [57] LEUBA, G., AND KRAFTSIK, R. Changes in volume, surface estimate, three-dimensional shape and total number of neurons of the human primary visual cortex from midgestation until old age. *Anatomy and Embryology* 190, 4 (1994), 351–366.
- [58] LEWANDOWSKI, J., AROCHENA, H. E., NAGUIB, R. N., AND CHAO, K.-M. A simple real-time qrs detection algorithm utilizing curve-length concept with combined adaptive threshold for electrocardiogram signal classification. In *TENCON 2012-2012 IEEE Region 10 Conference* (2012), IEEE, pp. 1–6.
- [59] LHERMITTE, S., VERBESSELT, J., VERSTRAETEN, W., AND COPPIN, P. A comparison of time series similarity measures for classification and change detection of ecosystem dynamics. *Remote Sensing of Environment* 115, 12 (2011), 3129–3152.
- [60] LIN, C.-H., AND DU, Y.-C. Fractal qrs-complexes pattern recognition for imperative cardiac arrhythmias. *Digital Signal Processing* 20, 4 (2010), 1274–1285.
- [61] LLAMEDO, M., AND MARTÍNEZ, J. P. Heartbeat classification using feature selection driven by database generalization criteria. *Biomedical Engineering, IEEE Transactions on* 58, 3 (2011), 616–625.
- [62] LOWN, B., VASSAUX, C., HOOD JR, W. B., FAKHRO, A. M., KAPLINSKY, E., AND ROBERGE, G. Unresolved problems in coronary care. *The American journal of cardiology* 20, 4 (1967), 494–508.
- [63] MADEIRO, J. P., CORTEZ, P. C., MARQUES, J. A., SEISDEDOS, C. R., AND SOBRINHO, C. R. An innovative approach of qrs segmentation based on first-derivative, hilbert and wavelet transforms. *Medical engineering & physics* 34, 9 (2012), 1236–1246.
- [64] MANIKANDAN, M. S., AND SOMAN, K. A novel method for detecting r-peaks in electrocardiogram (ecg) signal. *Biomedical Signal Processing and Control* 7, 2 (2012), 118–128.

- [65] MEHTA, S. S., AND LINGAYAT, N. S. Support vector machine for cardiac beat detection in single lead electrocardiogram. In *IMECS* (2007), pp. 1630–1635.
- [66] MEHTA, S. S., AND LINGAYAT, N. S. Combined entropy based method for detection of qrs complexes in 12-lead electrocardiogram using svm. *Computers in biology and medicine* 38, 1 (2008), 138–145.
- [67] MISHRA, S. R., ET AL. *Real Time Classification of ECG Waveforms for Diagnosis of Diseases*. PhD thesis, 2010.
- [68] MITCHELL, T. M. Machine learning. wcb, 1997.
- [69] MITRA, S., MITRA, M., AND CHAUDHURI, B. Pattern defined heuristic rules and directional histogram based online ecg parameter extraction. *Measurement* 42, 1 (2009), 150–156.
- [70] MONTEFORTE, N., NAPOLITANO, C., AND PRIORI, S. G. Genetics and arrhythmias: diagnostic and prognostic applications. *Revista Española de Cardiología (English Edition)* 65, 3 (2012), 278–286.
- [71] NAJEEB, D. Cardiac arrhythmias 1/3 [video file], May 2011. [Online; pristupano 27 kolovoza 2012].
- [72] NAKIC, D., MADZAROV, G., AND DORDEVIC, D. Heartbeat tracking application for mobile devices - arrhythmia recognition module. In *Information Technology Interfaces (ITI), 2010 32nd International Conference on* (2010), pp. 585–590.
- [73] OCTAVE COMMUNITY. GNU/Octave, 2012.
- [74] OF TECHNOLOGY, M. I. Mit-bih ecg database. [Online; pristupano 02 veljače 2012].
- [75] PAL, S., AND MITRA, M. Empirical mode decomposition based ecg enhancement and qrs detection. *Computers in Biology and Medicine* 42, 1 (2012), 83–92.
- [76] PAN, J., AND TOMPKINS, W. J. A real-time qrs detection algorithm. *Biomedical Engineering, IEEE Transactions on*, 3 (1985), 230–236.
- [77] RAUTAHARJU, P. M., PRINEAS, R. J., AND ZHANG, Z.-M. A simple procedure for estimation of the spatial qrs/t angle from the standard 12-lead electrocardiogram. *Journal of Electrocardiology* 40, 3 (2007), 300–304.


- [78] ROBNIK-ŠIKONJA, M., AND KONONENKO, I. Theoretical and empirical analysis of reliefF and rreliefF. *Machine learning* 53, 1-2 (2003), 23–69.
- [79] SALEM, A., REVETT, K., AND EL-DAHSHAN, E.-S. Machine learning in electrocardiogram diagnosis. In *Computer Science and Information Technology, 2009. IMCSIT'09. International Multiconference on* (2009), IEEE, pp. 429–433.
- [80] SALL, J., CREIGHTON, L., AND LEHMAN, A. *JMP start statistics: a guide to statistics and data analysis using JMP and JMP IN software*. SAS Institute, 2005.
- [81] SHASHA, D. E., AND ZHU, Y. *High performance discovery in time series: techniques and case studies*. Springer, 2004.
- [82] SHIEH, J., AND KEOGH, E. isax: disk-aware mining and indexing of massive time series datasets. *Data Min. Knowl. Discov.* 19, 1 (Aug. 2009), 24–57.
- [83] SUPEK, F. FastRandomForest - An efficient implementation of the Random Forest classifier for Java.
- [84] TAYLOR, G. J. *150 Practice ECGs: Interpretation and Review*. Wiley-Blackwell, 2008.
- [85] TORBEY, S., AKL, S. G., AND REDFEARN, D. P. Multi-lead qrs detection using window pairs. In *Engineering in Medicine and Biology Society (EMBC), 2012 Annual International Conference of the IEEE* (2012), IEEE, pp. 3143–3146.
- [86] UBEYLI, E. D. Implementing wavelet transform/mixture of experts network for analysis of electrocardiogram beats. *Expert Systems* 25, 2 (2008), 150–162.
- [87] VELIĆ, M. Analysis of correlation between crobex index value change, investment fund type, investment portfolio and investment funds share value change using data mining techniques. In *Information Technology Interfaces (ITI), Proceedings of the ITI 2011 33rd International Conference on* (2011), pp. 179–184.
- [88] VELIĆ, M., PADAVIĆ, I., AND SINISA, C. Computer aided ecg analysis—state of the art and upcoming challenges. In *EUROCON, 2013 IEEE* (2013), IEEE, pp. 1778–1784.
- [89] VRČEK, N., VELIĆ, M., AND STAPIĆ, Z. Integrated mobile electrocardiography. In *Proceedings of the 30th MIPRO International Convention on Computers in Technical Systems* (2007), vol. 3, pp. 44–47.

- [90] WADHWANI, A. A real time qrs detection system used error back propagation neural network.
- [91] WHALEN, R. E., RAMO, B. W., AND WALLACE, A. G. The value and limitations of coronary care monitoring. *Progress in Cardiovascular Diseases* 13, 5 (1971), 422–436.
- [92] WILLEMS, J., ARNAUD, P., VAN BEMMEL, J., DEGANI, R., MACFARLANE, P., AND ZYWIETZ, C. Common standards for quantitative electrocardiography: goals and main results. cse working party. *Methods of Information in Medicine* 29, 4 (1990), 263.
- [93] YANN, L. The mnist database of handwritten digits. [Online; pristupano 2 studenoga 2013].
- [94] YANOWITZ, F., KINIAS, P., RAWLING, D., AND FOZZARD, H. A. Accuracy of a continuous real-time ecg dysrhythmia monitoring system. *Circulation* 50, 1 (1974), 65–72.
- [95] YE, C., BHAGAVATULA, V., AND COIMBRA, M. Heartbeat classification using morphological and dynamic features of ecg signals.
- [96] YEH, Y.-C., AND WANG, W.-J. Qrs complexes detection for ecg signal: The difference operation method. *Computer methods and programs in biomedicine* 91, 3 (2008), 245–254.
- [97] YI, Z. Relieff - libgs, a matlab package for gene selection, 2013. [Online; pristupano 2 studenoga 2013].
- [98] ZIDELMAL, Z., AMIROU, A., ADNANE, M., AND BELOUCHRANI, A. Qrs detection based on wavelet coefficients. *Computer methods and programs in biomedicine* 107, 3 (2012), 490–496.


PRILOZI

Prilog 1 - Vizualizacija metode primjenom SOM


U nastavku je prikazan niz slika vizualizacije metode pomoću samoorganizirajuće mape. Za svaku sliku je naznačeno koja varijabla je korištena za sjenčanje pozadine. Pita grafikoni unutar čelija mape odražavaju pripadnost klasi.




Slika 28: Sjenčanje po varijabli Angle




Slika 29: Sjenčanje po varijabli *cum_change_surface_ref*




Slika 30: Sjenčanje po varijabli *cum_surface*




Slika 31: Sjenčanje po varijabli *cum_vmd_surface_ref*




Slika 32: Sjenčanje po varijabli *cum_vmd_surface_trend*




Slika 33: Sjenčanje po varijabli *cum_vmd_trend*




Slika 34: Sjenčanje po varijabli *df_avg10*




Slika 35: Sjenčanje po varijabli duration_concavity




Slika 36: Sjenčanje po varijabli duration_concavity




Slika 37: Sjenčanje po varijabli `log_avg_ratio`




Slika 38: Sjenčanje po varijabli `ref_label`




Slika 39: Sjenčanje po varijabli rev_angle




Slika 40: Sjenčanje po varijabli rev_cum_change_surface_ref




Slika 41: Sjenčanje po varijabli rev_cum_change_surface_trend




Slika 42: Sjenčanje po varijabli rev_cum_surface




Slika 43: Sjenčanje po varijabli rev_cum_vmd_surface_ref




Slika 44: Sjenčanje po varijabli rev_cum_vmd_surface_trend




Slika 45: Sjenčanje po varijabli `rev_duration_trend`




Slika 46: Sjenčanje po varijabli `rev_ref_label`




Slika 47: Sjenčanje po varijabli rev_surface



Slika 48: Sjenčanje po varijabli rev_surface_last_change




Slika 49: Sjenčanje po varijabli rev_surface_last_change




Slika 50: Sjenčanje po varijabli rev_surface_last_change

Prilog 2 - Vizualizacija metode primjenom PolyViz prikaza


U ovom prilogu je prikazana vizualizacija metode s obzirom na više dimenzija pomoću PolyViz grafikona. Prikazano je nekoliko zanimljivih kombinacija varijabli transformacije.




Slika 51: PolyViz prikaz br. 1




Slika 52: PolyViz prikaz br. 2




Slika 53: PolyViz prikaz br. 3




Slika 54: PolyViz prikaz br. 4




Slika 55: PolyViz prikaz br. 5




Slika 56: PolyViz prikaz br. 6




Slika 57: PolyViz prikaz br. 7




Slika 58: PolyViz prikaz br. 8




Slika 59: PolyViz prikaz br. 9




Slika 60: PolyViz prikaz br. 10




Slika 61: PolyViz prikaz br. 11




Slika 62: PolyViz prikaz br. 12



Slika 63: PolyViz prikaz br. 13



Slika 64: PolyViz prikaz br. 14



Slika 65: PolyViz prikaz br. 15

Prilog 3 - DVD medij priložen disertaciji

Prilog je zbog veličine datoteka snimljen na DVD medij i priložen disertaciji. Medij sadrži matrice zabune za klasifikaciju nefiltriranih signala, matrice zabune i detaljne predikcije raspoznavanja morfologija signala, programske kodove, zanimljive grafičke prikaze pogrešaka algoritma i problematičnih dijelova MIT-BIH AD baze te sve ostale datoteke i podatke korištene u istraživanju.

Metoda umjetne inteligencije za rudarenje podacima iz vremenskih serija i implementacija na ljudskom EKG signalu

M. Velić

Fakultet organizacije i informatike

Varaždin, R. Hrvatska

Ovaj rad predlaže novu metodu za analizu vremenskih serija te predstavlja istraživanje u kojem je ista metoda primjenjena u analizi ljudskog EKG signala. EKG kao postupak relativno niskih troškova koji je k tome i neinvazivan jest jedna od osnovnih dijagnostičkih metoda. Problem analize EKG signala obuhvaća nekoliko područja istraživanja poput uklanjanja šumova i smetnji koje nastaju tijekom snimanja, detekcije otkucaja srca, analize ritma te raspoznavanja oblika EKG valova. Ovo istraživanje fokusirano je na detekciju otkucaja srca i raspoznavanje oblika valova. Inspiracija za razvoj metode dolazi iz spoznaja računalne neuroznanosti. Provedeni su eksperimenti u detekciji QRS kompleksa bez filtriranja signala, te detekciji QRS kompleksa i prepoznavanja oblika valova nakon filtriranja signala. U istraživanju su dobiveni rezultati koji nadmašuju trenutno stanje tehnike te su dobivene spoznaje za daljnji razvoj i primjenu metode i u području računalnog vida. Postignuta je točnost detekcije otkucaja srca bez primjene filtara u prosjeku iznad 95% izračunato prema metodi unakrsne validacije nad svakim zapisom, te iznad 99% nakon filtriranja signala prema više realističnoj metodi testiranja baziranoj na subjektu te iznad 96% u raspoznavanju oblika EKG valova testirano prema preporukama AAMI standarda. U smislu računalnog vida, provedeni su eksperimenti u raspoznavanju rukom napisanih brojeva i drugih dvodimenzionalnih oblika.

Voditelj rada:

Prof. dr. sc. Mirko Čubrilo

Povjerenstvo za ocjenu i obranu:

Prof. dr. sc. Neven Vrček, Prof. dr. sc. Mario Cifrek, Prof. dr. sc. Mirko Čubrilo

Obrana: 12.05.2014.

Promocija:

Rad je pohranjen u Biblioteci Fakulteta organizacije i informatike u Varaždinu.

(115 stranica, 65 slika, 24 tablice, 11 grafikona, 3 priloga, 98 bibliografskih podatka, original na hrvatskom jeziku)

M. Velić

DD-2	UDK AAA:BBB.C.DD:EEE(FFF.G)
1. Metoda umjetne inteligencije za rudarenje podacima iz vremenskih serija i implementacija na ljudskom EKG signalu	Strojno učenje
I. Velić, M.	Rudarenje podacima
II. Fakultet organizacije i informatike, Varaždin, Hrvatska	EKG
	QRS
	Računalni vid
	Raspoznavanje uzorka
	Vremenske serije
	Umjetna inteligencija
	Računalna neuroznanost

Bazična dokumentacijska kartica na engleskom jeziku

DD (FOI - University in Zagreb)

UDK AAA:BBB.C.DD:EEE(FFF.G)

Doctoral Thesis

Artificial intelligence method for time series data mining - implementation on the human ECG signal

M. Velić

Faculty of Organization and Informatics

Varaždin, Croatia

In this research, a new method (algorithm) of artificial intelligence for pattern recognition is proposed. The method is based on principles of human perception and it is a part of computer engineering domain, the field of artificial intelligence. It is the result of perennial scientific research and development. The main implementation of the algorithm within the project is on the example of the human ECG signal analysis, which is one of the most demanding problems within the field. Research scope included software implementation and testing on the officially recognized databases of the human ECG signal (MIT-BIH Arrhythmia Database) by using the scientifically recognized metrics (specificity, sensitivity, positive predictivity etc.). Beyond the analysis of ECG signals, the above method has many other applications, such as applications in computer vision. Results achieved in the research are competitive with the current state of the art methods. Without signal filtering, QRS detection is accurate in more than 95% cases. After signal filtering, accuracy is above 99% tested with the subject-based methodology, which is the most realistic one. Heartbeat classification is accurate above 96% tested by the AAMI standard. Handwritten character recognition is accurate around 90% (MNIST dataset).

Supervisor:

Prof. dr. sc. Mirko Čubrilo

Examiners:

Prof. dr. sc. Neven Vrček, Prof. dr. sc. Mario Cifrek, Prof. dr. sc. Mirko Čubrilo

Oral examination:

Promotion:

The thesis deposited at the Library of the Faculty of Organization and Informatics, Varaždin,
Croatia.

(115 pages, 65 figures, 24 tables, 11 graphs, 3 appendices, 98 references, original in Croatian)

M. Velić

DD-2 UDK AAA:BBB.C.DD:EEE(FFF.G)

1. Artificial intelligence method for time series data mining - implementation on the human ECG signal Machine Learning

I. Velić, M. Data Mining

II. Faculty of Organization and informatics, Varaždin, Croatia ECG

QRS

Computer Vision

Pattern Recognition

Time Series

Artificial Intelligence

Computational Neuroscience

XXX

POPIS STRUČNIH RADOVA

- 1) Velić, Marko; Padavić, Ivan; Lovrić, Zrinka. Case study: Analysis of the direct sales force performance - Clients reach by geographical area in telecommunication industry // Proceedings of the 35th International Convention MIPRO, 2012. (predavanje, međunarodna recenzija, objavljeni rad, stručni).
- 2) Velić, Marko; Padavić, Ivan; Ljubobratović, Dejan. Agilni razvoj programskih proizvoda // INFOTEH-JAHORINA Vol. 10. 2011. (predavanje, međunarodna recenzija, objavljeni rad, stručni).
- 3) Velić, Marko; Padavić, Ivan. Izazovi i zamke agilnog razvoja // CASE 24. 2012. (predavanje, objavljeni rad, stručni).
- 4) Babić Danijela; Gabriel, Dunja Marija; Velić, Marko. Implementacija pilot projekta VERGILIUS za slijepu i slabovidnu osobu u Nacionalnoj i sveučilišnoj knjižnici u Zagrebu // 13. Seminar ARHIVI, KNJIŽNICE, MUZEJI, Zbornik radova. 2009. (predavanje, ppt prezentacija, stručni).
- 5) Novak, Miroslav; Velić, Marko. Office u 3D-u? WPF + XAML + XPS // Microsoft Windays Post-konferencijski CD. Microsoft Hrvatska, 2009. (predavanje, domaća recenzija, ppt prezentacija, stručni).
- 6) Velić, Marko; Novak, Miroslav. CF + RFID = Vodič za slijepu // Microsoft Windays Post-konferencijski CD. 2008. (predavanje, domaća recenzija, ppt prezentacija, stručni).
- 7) Velić, Marko. BPMN 2.0 - Moderno modeliranje poslovnih procesa, 2010. (popularan rad).
- 8) Velić, Marko; Padavić, Ivan. iCapital.hr, 2012. (računalni programski paket).
- 9) Novak, Miroslav; Orešković, Marko; Stapić, Zlatko; Velić, Marko. Smart ECG - Sustav za automatsko nadgledanje i analizu rada srca, 2006. (računalni programski paket).

POPIS ZNANSTVENIH RADOVA

- 1) Velić, Marko; Gržinić, Toni; Drobec, Marko. Feasibility Study on Implementation of Electronic Invoicing in Public Administration Enterprise // Proceedings of the Central European Conference on Information and Intelligent Systems 2013. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
- 2) Velić, Marko; Gržinić, Toni; Padavić, Ivan. Wisdom of Crowds Algorithm for Stock Market Predictions // Proceedings of the International Conference on Information Technology Interfaces ITI 2013. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
- 3) Velić, Marko; Padavić, Ivan; Car, Siniša. Computer Aided ECG Analysis - State of the Art and Upcoming Challenges // Proceedings of the IEEE Region 8 Conference EuroCon 2013.

(predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

4) Velić, Marko; Padavić, Ivan; Lovrić Zrinka. Model of the New Sales Planning Optimization and Sales Force Deployment ERP Business Intelligence Module for Direct Sales of the Products and Services with Temporal Characteristics // Proceedings of the ITI 2012 34th International Conference on Information Technology Interfaces (ITI). (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

5) Velić, Marko; Padavić, Ivan; Dobrović, Željko. Metamodel of agile project management and the process of building with LEGO® bricks // 23rd International Conference September 19th - 21st, 2012, Varaždin, Croatia Conference Proceedings. 2012. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

6) Velić, Marko. Analysis of correlation between CROBEX index value change, investment fund type, investment portfolio and investment funds share value change using data mining techniques // Proceedings of the ITI 2011 33th International Conference on Information Technology Interfaces (ITI) 2011. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

7) Vrček, Neven; Velić, Marko; Stapić, Zlatko. Integrated mobile electrocardiography // Proceedings of the 30th MIPRO International Convention on Computers in Technical Systems / Budin, Leo ; Ribarić, Slobodan (ur.). Opatija, 2007. 44-47 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

8) Velić, Marko; Novak, Miroslav; Orešković, Marko; Padavić, Ivan; Pedljo, Hrvoje; Stapić, Zlatko; Car, Siniša. Smart ECG, solution for mobile heart work analysis and medical intervention in case of heart work problems // Abstracts of The 56th Annual Scientific Session of the American College of Cardiology : Special Topics ; u: Journal of the American College of Cardiology 50 (2007) S8. Elsevier, 2007. 280A-281A (poster, međunarodna recenzija, sažetak, znanstveni).

ŽIVOTOPIS

Marko Velić rođen je u Zagrebu 02.04.1984. gdje je završio osnovnu školu i VII. gimnaziju. Diplomirao je 2007. na Fakultetu organizacije i informatike u Varaždinu. Na istom fakultetu, 2008. upisuje poslijediplomski doktorski studij "Informacijske znanosti". Od 2007. do 2013. kao direktor je vodio malo poduzeće za razvoj informacijskih tehnologija, gdje je bio autor desetak komercijalnih projekata i inovacija od kojih neki uključuju i autorske algoritme strojnog učenja.

Dobitnik je mnogih priznanja i nagrada za stručni rad i inovativnost, od kojih se posebno ističu Rektorova nagrada 2005., plasman u završnicu svjetskog finala studentskog natjecanja Microsoft Imagine Cup 2006. u Indiji i plasman među šest najinovativnijih timova na svijetu, nagrada za najboljeg studenta Rotary kluba Varaždin 2007., medalje za inovacije na skupovima u Ženevi i Nurnbergu 2007. i 2008, te mnoge druge.

2013. godine prelazi u Sveučilišni računski centar - SRCE, Sveučilište u Zagrebu gdje radi kao voditelj odjela za analizu podataka. Također, radi kao predavač/asistent na Visokoj školi za primijenjeno računarstvo na kolegijima "Programiranje", "Sustavi potpore odlučivanju" i "Otkrivanje znanja iz baza podataka" gdje je i izabran u nastavno zvanje predavača. Profesionalni i znanstveni interes su mu statistika, metode umjetne inteligencije, strojno učenje i računalni vid.

Autor je desetak stručnih i osam znanstvenih radova predstavljenih na međunarodnim skupovima s međunarodnom recenzijom od čega je sedam kategorije A1 te jedan sažetak nastupa na kongresu objavljen u CC časopisu. Član je IEEE-a (Institute of Electrical and Electronics Engineers) i ACM-a (Association for Computing Machinery).

U slobodno vrijeme svira gitaru i rekreativno se bavi raznim sportovima poput trčanja, plivanja, alpinizma, skijanja i sl.