

OPIS IZUMA**Područje tehnike**

5 Predmetni izum se odnosi na sustav i računalno implementirani postupak detekcije i raspoznavanja oblika valova u vremenskim serijama, posebno fiziološkog signala. Postupak omogućuje detekciju zanimljivih oblika (unaprijed određenih oblika) krivulje i raspoznavanje (klasifikaciju) oblika krivulje. Temeljem rezultata postupka postiže se 10 automatska obrada signala koja ne zahtijeva ljudskog stručnjaka. Primjena računalno implementiranog postupka omogućava brzu obradu velikih količina podataka. Automatska dijagnostika temeljena na modelima za detekciju zanimljivih odsječaka EKG signala (QRS kompleksa) te klasifikaciju oblika valova omogućuje bržu dijagnostiku i olakšava rad liječnika. Predmetni izum se odnosi i na računalni program za detekciju i raspoznavanje oblika valova u vremenskim serijama.

Tehnički problem

15 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 uvek nije u dovoljnoj mjeri zaživjela u praksi. Elektrokardiogram (EKG) je crtež kojeg proizvodi elektrokardiograf, uređaj koji bilježi električnu aktivnost srca u vremenu. Analiza različitih valova i vektora depolarizacije i repolarizacije dovodi do značajnih podataka u dijagnostici bolesti. EKG se sastoji od P-vala, QRS-kompleksa (kompleks se sastoji od Q, R i S-vala), T-vala te ponekad U vala, vidi 20 sliku 1 i 2. U predmetnom području tehnike, najvrjednija dostignuća očituju se u metodama koje postižu veoma visoke rezultate detekcije QRS kompleksa EKG signala mjereno prema zadanim standardima. „State of the art“ metodama smatraju se one koje imaju osjetljivost, pozitivnu prediktivnost i općenitu točnost detektiranja QRS kompleksa iznad 25 95%. Osim detekcije zanimljivih odsječaka (otkucaja srca tj. QRS kompleksa) izazov je i raspoznavanje oblika valova koje omogućuje precizniju dijagnostiku poremećaja u radu srca. Metode raspoznavanja (klasifikacije) oblika valova tek se približavaju tim pragovima.

Tehnički problem koji se rješava predmetnim izumom je pružiti računalno implementirani postupak za rano dijagnosticiranje srčanih bolesti koji daje veću točnost i pouzdanost EKG dijagnostike u odnosu na poznate algoritme.

30 Drugi cilj izuma je stvaranje baze znanja koja sadrži skup proširenih značajki nastao izlučivanjem dinamičkih i morfoloških karakteristika signala u svrhu obrade algoritmima strojnog nenadziranog učenja i pronalaženja najsličnijih odsječaka signala za novi odsječak signala ili najsličnijih oblika valova za novi val.

Stanje tehnike

Rad „Perception-based approach to time series data mining“; BATYRSHIN, I. Z., AND SHEREMETOV, L. B.. Appl. Soft Comput. 8, 3 (June 2008), 1211–1221. općenito razotkriva metodu opisivanja oblika iz vremenskih serija temeljenu na principima ljudskih opisa oblika i korištenje takvih opisa u svrhu rudarenja podacima u vremenskim serijama. Slični koncepti prikazivanja vremenskih serija temeljeni na idejama ljudske percepcije i opisivanja oblika su prikazani u radu autora KLEPAC, G., Otkrivanje zakonitosti temeljem jedinstvenoga modela transformacije vremenske serije, doktorska disertacija, Fakultet organizacije i informatike, Varaždin, Sveučilište u Zagrebu, 2005. Rad opisuje model transformacije vremenske serije sličan onom koji se opisuje u predmetnom izumu (REF II). Prema predmetnom izumu opisani postupak pruža manju razinu detaljizacije u opisima oblika te obuhvaća manje segmente krivulja. Predmetnim izumom se postiže preciznije opisivanje oblika vremenskih serija i time pouzdanija i preciznija primjena istih u rješavanju tehničkih problema iz predmetne domene. Rad, u nastavku referenca [1], „Automatic classification of heartbeats using ecg morphology and heartbeat interval features“, DE CHAZAL, P., O'DWYER, M., AND REILLY, R. B., IEEE Transactions on Biomedical Engineering 51, 7 (2004), 1196–1206., prikazuje postupak za automatsku obradu elektrokardiograma (EKG) za klasifikaciju otkucaja srca koji uključuje tri faze: fazu pred-obrade, fazu obrade i fazu 45 klasifikacije. Razlika između postupka prema predloženom izumu i postupka u navedenom radu se sastoji od dodatnog koraka u fazi obrade signala izlučivanjem morfoloških značajki transformacijom izvornog jednodimenzionalnog signala u niz karakterističnih vektora V_{PT} percepcije koji sažimaju morfologiju signala u okolini točke u trenutku T. Tim korakom postignuta je veća točnost (ACC) algoritma u odnosu na rezultate navedenog rada (referenca [1]). Rad, u nastavku referenca [2], „Heartbeat classification using feature selection driven by database generalization criteria“, LLAMEDO, M., AND MARTÍNEZ, J. P., Biomedical Engineering, IEEE Transactions on 58, 3 (2011), 616–625, prikazuje jednostavan rad klasifikatora srca na temelju EKG modela značajki odabranih s naglaskom na poboljšanu sposobnost generalizacije. Kao i u prethodnom radu (referenca [1]), postupkom prema predmetnom izumu postignuta je 50 veća točnost algoritma. Rad, u nastavku referenca [3], „Heartbeat classification using morphological and dynamic features of ecg signals“, YE, C., BHAGAVATULA, V., AND COIMBRA, M., prikazuje novi pristup za klasifikaciju otkucaja srca koji se temelji na morfološkim i dinamičkim karakteristikama.

Prema dosadašnjim saznanjima najuspješniji pristupi u objavljenim radovima, reference [1], [2] i [3], koji su objavili rezultate prema AAMI (ANSI/AAMI EC57:1998/(R)2008) standardu u usporedbi s postupkom prema predmetnom izumu pokazuju manju točnost (ACC) algoritma. Tablica 18 prikazuje usporedbu tri varijante izvođenja postupka prema predmetnom izumu i nekih od najuspješnijih pristupa koji su objavili rezultate prema AAMI standardu. Računalno implementirani postupak detekcije i raspoznavanja oblika valova u vremenskim serijama, posebno EKG fiziološkog signala prema predmetnom izumu pokazuje u sva tri načina izvođenja izuma veću točnost (ACC) algoritma.

Osim navedenih radova, može se kao manje relevantni navesti i rad, „A novel method for detecting r-peaks in electrocardiogram (ecg) signal“, MANIKANDAN, M. S., AND SOMAN, K., Biomedical Signal Processing and Control 7, 2 (2012), 118–128 koji prikazuje algoritam za detekciju QRS segmenata.

Od patentne literature dokument US2008/0103403 prikazuje postupak za dijagnosticiranje tihih/ili simptomatskih srčanih bolesti kod ljudi, na osnovu ekstrakcije i analize skrivenih čimbenika, ili kombinacije skrivenih i poznatih čimbenika EKG signala. Postupak dijagnoze koristi EKG signal u mirovanju skupine dijagnosticiranih bolesnika. Skupina se sastoji od pacijenata s a priori dijagnozom kao bolesni pacijenti i pacijenta s a priori dijagnozom kao zdravi pacijenti. Nadalje, opisana metoda koristi neuronske mreže (NN) koje kao ulaz primaju blok signala (nakon filtriranja bez transformacija). Glavna razlika između predmetnog izuma i dokumenta US2008/013403 se sastoji u tome što navedeni dokument opisuje metodu koja klasificira samo je li pacijent zdrav ili bolestan. Postupak prema predmetnom izumu razlikuje i vrste poremećaja prema AAMI standardu. Nadalje, postupak prema predmetnom izumu kao ulaz ne uzima sekvencijalni blok signala već transformirani signal tj. rezultat transformacije dijela signala koji onda sažima morfološke karakteristike. Osim navedenoga, dokument US2008/0103403 ne daje egzaktne testove temeljem kojih bi se mogla usporediti uspješnost algoritma s algoritmom prema predmetnom izumu.

Predmet izuma

Predmetni izum se odnosi na sustav i računalno implementirani postupak detekcije i raspoznavanja oblika valova u vremenskim serijama, posebno fiziološkog signala. Postupak omogućuje detekciju zanimljivih oblika (unaprijed određenih oblika) krivulje i raspoznavanje (klasifikaciju) oblika krivulje. Postupak se posebno odnosi na transformaciju izvornog signala vremenske serije u vektore percepcije što je temelj za nekoliko primjena. To su izgradnja modela za QRS detekciju i klasifikacija QRS kompleksa, izgradnja modela za raspoznavanje oblika valova i klasifikacija valova te klasteriranje (grupiranje) sličnih valova i pronalazak valova najsličnijih promatranom valu. Izvorni signal se nakon uklanjanja šuma, poznatim tehnikama filtriranja signala, pretvara u niz vektora transformacijom prema predmetnom izumu. Tako transformirana vremenska serija je temelj za učenje klasifikatora (algoritma razvrstavanja) u svrhu otkrivanja (detekcije) QRS kompleksa u signalu. S obzirom da se radi o procesu nadziranog učenja podrazumijeva se da je signal za učenje označen (anotiran) tj. da sadrži oznake gdje se nalaze QRS kompleksi. Rezultat procesa strojnog učenja je model I za QRS detekciju (ili klasifikator) koji može biti pohranjen na računalu u obliku programskog koda (slika 10 - a)). Takav model I se potom može koristiti za klasifikaciju odnosno detekciju QRS segmenata u novim signalima (slika 10 - b)). Algoritam za klasifikaciju primijenjen u opisanom izumu je algoritam Slučajne šume – engl. Random Forest. Detektirani QRS kompleksi temelj su za izlučivanje dinamičkih značajki signala (bazirano na međusobnim razmacima QRS kompleksa). Dinamičke značajke zajedno sa morfološkim značajkama (rezultat transformacije) tvore skup proširenih značajki koje uz odgovarajuće oznake izvornog signala postaju temelj za proces nadziranog učenja u svrhu raspoznavanja oblika valova. Rezultat takvog procesa strojnog učenja je model koji se koristi za klasifikaciju odnosno raspoznavanje oblika valova (slika 10 - c)). Model se potom može koristiti za raspoznavanje oblika valova novih signala (slika 10 - d)).

Skup proširenih značajki nastao izlučivanjem dinamičkih i morfoloških karakteristika je pohranjen kao baza znanja koja se koristi u svrhu obrade algoritmima strojnog nenadziranog učenja. Takvi algoritmi rezultiraju kreiranjem grupa sličnih valova (klasteri). Primjeri takvih algoritama su algoritam K-sredina, hijerarhijsko klasteriranje, samoorganizirajuće mape i sl. Skup proširenih značajki nastao izlučivanjem dinamičkih i morfoloških karakteristika je pohranjen kao baza znanja koja se koristi u svrhu pronalaska najsličnijih valova za neki novi val. Takvi valovi pronalaze se pomoću izračuna matematičke udaljenosti između vektora koji su reprezentacija valova u bazi znanja i vala za koji se traže najsličniji valovi iz baze. Primjeri udaljenosti su Euklidska udaljenost, Manhattan udaljenost, Mahalanobisova udaljenost i sl.

Razvoj specijaliziranog klasifikatora izlazi izvan okvira ovog izuma te su s obzirom na 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. 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 varijable" u pojedinoj grani temelji se na entropiji ili Gini mjeri nečistoće. Postupak se ponavlja rekurzivno 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 RF. Općenito, ansambl klasifikatora možemo podijeliti na skupine nezavisnih klasifikatora (engl. bagging) i sekvenčalne klasifikatore (engl. boosting). Kod nezavisnih odluka modela donosi po nekom principu glasovanja. klasifikatora, svaki pojedini klasifikator samostalno donosi odluku i onda se konačna Sekvenčalni 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 mjerena uspješnosti svakog od njih na podskupu 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 tehnički problem izuma 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 izumu neuronske mreže nisu bile konačni odabir. U predmetnom izumu primijenjene su implementacije RF algoritma u programskim paketima za strojno učenje Orange i Weka. Implementacija u alatu Orange je korištena u QRS detekciji nefiltriranih podataka, a u kasnijim testiranjima (testiranje bazirano na subjektu i klasifikacija oblika) je zbog veličine podatkovnih setova i duljine izvršavanja iskorištena "Fast Random Forest" implementacija. 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 narednom tekstu. 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 izmjenim 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 prepostavljenih 0,5 na 0,4.

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. Većina recentnih istraživanja opisuje primjenu istih ili sličnih tehnika preprocesiranja što omogućava korektnu usporedbu u smislu izlučivanja značajki i klasifikacije tako obrađenih signala.

Kratki opis slika

U nastavku će izum biti detaljno opisan s pozivanjem na slike pri čemu:

Slika 1 prikazuje Morfološke i dinamičke karakteristike različitih EKG valova,

Slika 2 prikazuje Karakteristične dijelove normalnog EKG odsječka,

Slika 3 prikazuje tipične korake u računalnoj obradi EKG signala,

Slika 4 prikazuje nekoliko odsječaka krivulje sa ilustriranim morfološkim razlikama koje se pokušavaju obuhvatiti vektorima kao rezultat transformacije,

Slika 5 prikazuje konceptualni prikaz metode prema predmetnom izumu,

Slika 6 prikazuje osnovne korake postupka prema predmetnom izumu,

Slika 7 prikazuje metodu klizećih prozora,

Slika 8 prikazuje metodu skačućih prozora,

Slika 9 prikazuje transformaciju EKG signala prema predmetnom izumu,

Slika 10 prikazuje dijagram toka postupka prema predmetnom izumu, i

Slika 11 prikazuje dijagram toka nenadziranog učenja.

Detaljni opis izuma

Ljudski EKG signal prikazan na slikama 1 i 2 sastoji se od nekoliko karakterističnih točaka odnosno valova koji odražavaju aktivnosti fizioloških procesa u srcu. EKG se sastoji od P vala, QRS kompleksa (kompleks se sastoji od Q, R i S valova), T vala i ponekad U vala. Većina algoritama koji su trenutno poznati za cilj imaju prepoznavanje upravo QRS kompleksa 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. 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. 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 logiku 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 pretprecesiranje signala (uklanjanje šuma), a sljedeći je izlučivanje značajki (prikazano na slici 3). Slika 6 prikazuje osnovne korake postupka prema predmetnom izumu, koji uključuje postupak pretprecesiranja izvornog signala u svrhu uklanjanja šuma, izlučivanja morfoloških značajki signala, detekciju zanimljivih dijelova signala odnosno QRS detekciju, izlučivanje dinamičkih značajki, raspoznavanje/klasificiranje oblika valova i grupiranje/klasteriranje sličnih odsječaka signala. Prema predmetnom izumu signal sa smanjenim šumom iz vremenske domene transformirat će se nizom proračuna na način da se od jednodimenzionalnog signala dobije višedimenzionalni signal čije će dimenzije zapravo govoriti o različitim morfološkim karakteristikama izvornog signala. Izlučivanje morfoloških značajki signala se odvija transformacijom izvornog jednodimenzionalnog signala u niz karakterističnih vektora V_{PT} percepcije koji sažimaju morfologiju signala u okolini točke u trenutku T, koji vektori V_{PT} se sastoje od skupa značajki $m_{1T}; m_{2T}; \dots; m_{nT}$, pri čemu dio navedenih značajki opisuje geometrijske karakteristike odsječaka signala, dio čine dinamički kumulativni, a dio vremensko morfološke determinante VMD, pri čemu se transformacija serije provodi unaprijed i unatrag u odnosu na vremenski slijed, prikazano na slici 9.

Rezultat transformacije signala se koristi kao ulaz u klasifikator u svrhu izgradnje modela I za detekciju zanimljivih oblika odsječaka signala. Model I se koristi za detekciju zanimljivih odsječaka signala u svrhu detekcije takvih odsječaka u novim signalima, Slika 10 a i b prikazuje izgradnju i korištenje modela I. Postupak izgradnje modela I je slijedeći. Izvorni signal ili signal za učenje se podvrgava pretprecesiranju u svrhu uklanjanja šuma. Izvorni jednodimenzionalni signal sa smanjenim šumom se podvrgava transformaciji u niz karakterističnih vektora V_{PT} percepcije koji sažimaju morfologiju signala u okolini točke u trenutku T prema gore navedenom postupku, a koji će kasnije biti detaljnije opisan. Rezultat transformacije je niz karakterističnih vektora V_{PT} ili značajki koje služe za učenje u svrhu QRS detekcije. Rezultat je izgradnja klasifikatora – modela I, odnosno programski kod za QRS detekciju ili općenito zanimljivih odsječaka signala. Model I za QRS detekciju se koristi za klasifikaciju odsječaka u novim signalima koji su prethodno podvrgnuti postupku uklanjanja šuma i gore navedenoj transformaciji. S obzirom da se radi o procesu nadziranog učenja podrazumijeva se da je signal za učenje označen (anotiran) tj. da sadrži oznake gdje se nalaze QRS kompleksi. Rezultat procesa strojnog učenja je model I koji je pohranjen na računalu u obliku programskog koda (slika 10 a). Takav model se potom koristi za klasifikaciju odnosno detekciju QRS odsječaka signala u novim signalima (slika 10 b). Nadalje, rezultat gore navedene transformacije i rezultat detekcije zanimljivih oblika tj. QRS detekcije (Model I) se koristi kao ulaz u klasifikator u svrhu izgradnje modela II za raspoznavanje oblika odsječaka signala izvornog signala ili signala za učenje i novog signala. Postupak izgradnje modela II je slijedeći. Izvorni signal ili signal za učenje se podvrgava pretprecesiranju u svrhu uklanjanja šuma. Signal sa smanjenim šumom se podvrgava klasifikaciji odsječaka signala korištenjem modela I i nakon toga se izlučuju dinamičke značajke. Istovremeno se signal sa smanjenim šumom podvrgava gore navedenoj transformaciji u niz karakterističnih vektora V_{PT} percepcije. Rezultat ta dva istovremena koraka su vektori s proširenim značajkama te izgradnja klasifikatora odnosno modela II za raspoznavanje oblika odsječaka signala u svrhu raspoznavanja oblika u novim signalima, odnosno raspoznatim EKG valovima se odvija na slijedeći način. Novi signal se podvrgava postupku uklanjanja šuma i potom gore navedenoj transformaciji u niz_karakterističnih vektora V_{PT} percepcije. Korištenjem modela I se odvija detekcija zanimljivih odsječaka signala odnosno klasifikacija odsječaka signala (QRS detekcija). Otkriveni QRS segmenti se podvrgavaju izlučivanju dinamičkih značajki signala rezultat čega su proširene značajke odnosno vektori s proširenim značajkama. Korištenjem prethodno izgrađenog modela II se odvija klasifikacija oblika valova što rezultira raspoznatim EKG valovima. Detektirani QRS kompleksi temelj su za izlučivanje dinamičkih značajki signala (bazirano na međusobnim razmacima

QRS kompleksa). Dinamičke značajke zajedno sa morfološkim značajkama (rezultat transformacije) tvore skup proširenih značajki, odnosno vektore s prošireni značajkama koje uz odgovarajuće oznake izvornog signala postaju temelj za proces nadziranog učenja u svrhu raspoznavanja oblika valova. Rezultat takvog procesa strojnog učenja je model II koji se koristi za klasifikaciju odnosno raspoznavanje oblika valova (slika 10 c). Model II se potom može koristiti za raspoznavanje oblika valova novih signala (slika 10 d) odnosno raspozname EKG valove.

Model I i model II se u obliku programskog koda pohranjuju na računalu ili mogu biti pohranjeni na bilo kojem računalno čitljivom mediju. Izlučivanje dinamičkih i morfoloških karakteristika u niz karakterističnih vektora V_{PT} , odnosno rezultat transformacije se koristi u svrhu grupiranja po obliku sličnih odsječaka signala čega rezultat je kreiranje grupe ili klastera sličnih odsječaka signala. Grupiranje po obliku sličnih odsječaka signala uz izvorni signal rezultira novim pridruženim informacijama koje se pohranjuju. Izlučivanje dinamičkih i morfoloških karakteristika u niz karakterističnih vektora V_{PT} , odnosno rezultat transformacije se nadalje koristi u svrhu pronalaženja najsličnijih odsječaka signala za novi odsječak signala ili najsličnijih oblika valova za novi val.

Skup proširenih značajki nastao izlučivanjem dinamičkih i morfoloških karakteristika je pohranjen kao baza znanja te se koristi u svrhu obrade algoritima strojnog nenadziranog učenja. Takvi algoritmi rezultiraju kreiranjem grupe sličnih valova (klasteri). Primjeri takvih algoritama su algoritam K-sredina, hijerarhijsko klasteriranje, samoorganizirajuće mape i sl. Nadalje, skup proširenih značajki nastao izlučivanjem dinamičkih i morfoloških karakteristika je pohranjen kao baza znanja se koristi u svrhu pronalaženja najsličnijih valova za neki novi val. Takvi valovi pronalaze se pomoću izračuna matematičke udaljenosti između vektora koji su reprezentacija valova u bazi znanja i vala za koji se traže najsličniji valovi iz baze. Primjeri udaljenosti su Euklidska udaljenost, Manhattan udaljenost, Mahalanobisova udaljenost i sl.

Vektori V_{PT} percepcije koji sažimaju morfologiju signala u okolini točke u trenutku T se sastoje od skupa značajki $m_{1T}; m_{2T}; \dots; m_{nT}$, pri čemu dio navedenih značajki opisuje geometrijske karakteristike odsječaka signala, dio čine dinamički kumulativi, a dio vremensko morfološke determinante VMD. Dinamički kumulativi komponente x vektora $\overrightarrow{V_{PT}}$ izračunavaju se posebno za vrijeme trajanja trenda signala i za vrijeme trajanja konkavnosti signala.

U nastavku je detaljno opisan niz proračuna kojima se od jednodimenzionalnog signala dobije višedimenzionalni signal čije će dimenzije zapravo govoriti o različitim morfološkim karakteristikama izvornog signala. Također, u nastavku su opisani i postupak izračuna kumulativa komponente x vektora $\overrightarrow{V_{PT}}$ za vrijeme trajanja trenda, postupak izračuna kumulativa komponente x vektora $\overrightarrow{V_{PT}}$ za vrijeme trajanja konkavnosti i postupak izračuna VMD vrijednosti komponente x vektora $\overrightarrow{V_{PT}}$ za vrijeme trajanja trenda.

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. Suvremeni nalazi 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 osmislići 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 5. 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. 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. 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 t1 i t2 biti popunjena dva vektora V_{P1} i V_{P2} . Transformacija će obuhvatiti morfološke karakteristike nizom kumulativnih proračuna koji su u opisani u nastavku, a navedeno se može implementirati u realnom vremenu pomoću metode pomicnih prozora (engl. sliding window). Kako je vidljivo na slici 7, postoje konstantni pomaci prozora u kojem se promatra vremenska serija pa figurativno kažemo da prozor "klizi" kroz vrijeme. 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 popunjjen 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 8 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. 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 9. U nastavku je opisan 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 rezorkovana nekom drugom metodom, npr. minmax transformacijom, z-skaliranjem ili rezorkovanjem (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 skalamama 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 je potrebna kod problema promjenjivih amplituda QRS kompleksa. Ukoliko su serije koje želimo obradivati diskretizirane različitim frekvencijama, tada je prije transformacije u vektore percepcije potrebno učiniti reuzorkovanje s obzirom da vrijednosti pojedinih vektora 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 komponenta vektora V_{PT} .

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

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

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 slijedeći način kako je

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

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 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 pripadajućih 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 detaljnem 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 1 u nastavku.

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

Tablica 1: Rasponi vrijednosti za oznake trenda i detaljnog trenda (REF)

Vrijednost granica $g1-g6$ odabrana je empirijski. Vrijednosti granica koje su primijenjene u predmetnom izumu prikazane su u tablici 1. 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 2 prikazuje 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

Tablica 2

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

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

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

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 kod predmetnog izuma. 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 $x_1, x_2, x_3, \dots, x_n$ poređani 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 uest ćemo pojmom *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 provodit 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, $\Delta stvari$ kao
 $\Delta stvari = |x_t - sredina|.$

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

$$koeficijent\ konkavnosti = \frac{\Delta stvari}{\Delta sredina}.$$

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 2. 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 detaljnju konkavnost poprimiti vrijednost 0. Kao i kod granica za trendove, granice za konkavnosti odabранe su proizvoljno na temelju empirijskih zaključaka. Također i u slučaju ovih granica, moguće je osmislitи model za njihovu optimizaciju.

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. Predstavljeno 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 izvorni doprinos. 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 kumulative su dinamički zbog toga što trajanje njihovog kumuliranja nije fiksno već je određeno trendom i detalnjim 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 vrijednosti koji je moguće primijeniti na bilo koju kontinuiranu varijablu iz transformacije.

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

Tablica 3: Rasponi vrijednosti za oznake konkavnosti i detaljne konkavnosti

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

Tablica 4: Granice za konkavnost primijenjene u istraživanju

5

Postupak izračuna kumulativa komponente x vektora $\overrightarrow{V_{PT}}$ za vrijeme trajanja trenda računa se na sljedeći način. Ako je trend u točki T jednak trendu u točki $T-1$, tada se trajanje trenda poveća za jedan te se kumulativ poveća za vrijednost varijable x . Ako trend u točki T nije jednak trendu u točki $T-1$ tada se trajanje trenda postavlja na 1, a kumulativ na vrijednost varijable x . Ako je detaljni trend u točki T jednak detaljnog trendu u točki $T-1$, tada se trajanje detaljnog trenda poveća za jedan te se detaljni kumulativ poveća za vrijednost varijable x . Ako detaljni trend u točki T nije jednak detaljnog trendu u točki $T-1$ tada se trajanje detaljnog trenda postavlja na 1, a detaljni kumulativ na vrijednost varijable x .

10

10

15

Osim akumuliranja za vrijeme trajanja trenda, vektor $\overrightarrow{V_{PT}}$ popunit ćemo i komponentama koje govore o morfologiji za vrijeme trajanja stupnja konkavnosti.

20

Postupak izračuna kumulativa komponente x vektora $\overrightarrow{V_{PT}}$ za vrijeme trajanja stupnja konkavnosti računa se na sljedeći način. Ako je stupanj konkavnosti u točki T jednak stupnju konkavnosti u točki $T-1$, tada se trajanje stupnja konkavnosti poveća za jedan te se kumulativ poveća za vrijednost varijable x . Ako stupanj konkavnosti u točki T nije jednak stupnju konkavnosti u točki $T-1$ tada se trajanje stupnja konkavnosti postavlja na 1, a kumulativ na vrijednost varijable x . Ako je detaljni stupanj konkavnosti u točki T jednak detaljnog stupnju konkavnosti u točki $T-1$, tada se trajanje detaljnog stupnja konkavnosti poveća za jedan te se detaljni kumulativ poveća za vrijednost varijable x . Ako detaljni stupanj konkavnosti u točki T nije jednak detaljnog stupnju konkavnosti u točki $T-1$ tada se trajanje detaljnog stupnja konkavnosti postavlja na 1, a detaljni kumulativ na vrijednost varijable x .

25

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 kumulativne moguće je napraviti i za varijable kumulativne površine, kumulativnog koeficijenta konkavnosti itd.

30

35

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 obradivanu 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.

- 5 Postupak izračuna VMD vrijednosti komponente x vektora $\overrightarrow{V_{PT}}$ za vrijeme trajanja trenda računa se na sljedeći način.
 Ako je trend u točki T jednak trendu u točki $T-1$, tada se trajanje VMD brojača poveća za jedan te se VMD komponenta poveća za umnožak varijable x i VDM brojača. Ako trend u točki T nije jednak trendu u točki $T-1$ tada se VMD brojač postavlja na 1, a VMD komponenta na vrijednost varijable x . Ako je detaljni trend u točki T jednak detaljnemu trendu u točki $T-1$, tada se vrijednost detaljnog VMD brojača poveća za jedan te se detaljna VMD komponenta poveća za umnožak varijable x i detaljnog VDM brojača. Ako detaljni trend u točki T nije jednak detaljnemu trendu u točki $T-1$ tada se vrijednost detaljnog VMD brojača postavlja na 1, a detaljna VMD komponenta na vrijednost varijable x .

Ako promatramo neki ekstrem krivulje i pretpostavimo da je trend prije tog ekstrema trajao neko izvjesno vrijeme, zahvaljujući linearnom povećanju vmd_brojaca i njegovom množenju s ciljanom vrijednošću x razvijamo nelinearnost.
 15 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 u nastavku.

25

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	koefficijent konkavnosti
rev_coefficient_concavity	koefficijent konkavnosti unatrag
cum_angle	kum. kuta za vrijeme trajanja trenda
rev_cum_angle	kum. kuta za vrijeme trajanja trenda unatrag
cum_angle_detail	kum. kuta za vrijeme trajanja detaljnog trenda
rev_cum_angle_detail	kum. kuta 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

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

Tablica 5: Varijable transformacije primijenjene u istraživanju

Slika 4 prikazuje 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 3 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 "trbuš", ali koji se nalazi na različitim dijelovima krivulja. Ovo je obuhvaćeno VMD komponentama vektora \overline{V}_{PT} .

TESTIRANJE METODE

U svrhu provedbe ovog istraživanja korišten je dobro poznati postojeći skup podataka – MITBIH Arrhythmia Database (u nastavku MIT-BIH AD). Navedena baza podataka je naširoko prihvaćena i većina radova iz područja prijavljuje rezultate nad tom bazom što ju čini dobrom "benchmarkom" za usporedbu raznih pristupa i algoritama. MIT-BIH AD baza nastala je suradnjom MIT-a (Massachusetts Institute of 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 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.

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 najблиži potencijalnoj kliničkoj primjeni metode jer se prilikom testa algoritam izlaže EKG signalu pacijenta "kojeg nikad prije nije video" (podaci nisu korišteni ni za učenje niza 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 cijelokupnom 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 Fast Random Forest 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 ostvareni primjenom meta klasifikatora sa sljedećom matricom koštanja, prikazano u tablici 6.

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

Tablica 6: Matrica koštanja pojedinih klasifikacija

- 5 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.
- 10 U nastavku su tablici 7 dani 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

HR P20140414 B1

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

Tablica 7

5 Rezultati prikazuju odličnu sposobnost metode u razlikovanju bitnih od nebitnih valova EKG signala koja je usporedjiva 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 10 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 najuspješnjim pristupom prema dostupnoj literaturi dana je u tablici 8.

Metoda	FN	FP	Se	+P	Acc	DER
Manikandan i Soman	79	140	99,93	99,86	99,79	0,21
Predmetni izum	140	91	99,86	99,90	99,76	0,24

15 Tablica 8: Usporedba predložene metode i pristupa iz literature

Kada govorimo o klasifikaciji oblika EKG valova, veoma je važno istaknuti razliku između metodologija testiranja koje 20 se koriste pri objavi rezultata. Metodologija testiranja, odnosno način odabira uzoraka za učenje i testiranje značajno utječe na rezultate testa. 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 mjeru 25 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.

25 AAMI standard opisuje procedure i metrike za testiranje algoritama za raspoznavanje patologija EKG signala. 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 dijelu 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 (pejsmajker), konkretno zapise 102, 30 104, 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 35 algoritam prilagodio na dočićnog 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.

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

Tablica 9: Podjela MIT-BIH AD baze u podskup za učenje i podskup za testiranje

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 otkucanja 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 klase u AAMI klase prikazano je u tablici 11. 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} .

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
Vodeni 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 vodeni i normalni otkucaj	f	982
Ventrikulski pobjegli otkucaj	E	106
Nodalni preuranjeni otkucaj	J	83
Atrijski pobjegli otkucaj	e	16
Nepoznati otkucaj	Q	33
Supraventrikulski preuranjeni otkucaj	S	2

Tablica 10: Originalne MIT-BIH AD klase (cijela baza bez isključivanja pejsmejkera)

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

Tablica 11: Mapiranje MIT-BIH AD klase u AAMI klase

S obzirom da je predmetni izum fokusiran 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 raspoznavanja. Dinamičke karakteristike koje su uključene kao značajke prikazane su u tablici 12. Vrijeme promatrane točke izraženo u milisekundama označeno je kao T0, vrijeme prethodne točke kao T-1 i.t.d.

Značajka	Naziv varijable	Način izračuna
Razlika između dva vala (ms)	db_t	$T_t - T_{t-1}$
Razlika trenutnog i sljedećeg vala	df	$T_{t+1} - T_0$
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	$\log(db_avg10/df_avg10)$

Tablica 12: Dinamičke značajke uključene u vektor

5 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.

10

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.

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

15

Tablica 13: Matrica zabune za raspoznavanje oblika EKG valova temeljem prvog odvoda i svih atributa

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 pronalascima drugih autora čiji pristupi također u 20 značajnoj mjeri grijše pri raspoznavanju "F" otkucaja [2].

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 14: Matrica zabune za raspoznavanje oblika EKG valova temeljem drugog odvoda

25 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 30 ostalih klasa, možemo konstatirati kako metoda spada među trenutne "state of the art" metode. Moguće je i kombiniranje zaključaka iz dvaju odvoda primjenom uvjetnih vjerojatnosti (Bayesov produkt), a što je već opisano u literaturi. U svrhu usporedbe s nekim od najuspješnijih algoritama dostupnima u literaturi prikazane su matrice zabune istraživanja prikazanih u [2], [3] i [1].

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 15: Matrica zabune za raspoznavanje oblika EKG valova ref. [2]

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

5 Tablica 16: Matrica zabune za raspoznavanje oblika EKG valova ref. [3]

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 17: Matrica zabune za raspoznavanje oblika EKG valova ref. [1]

		Osjetljivosti (Se) u %				
Metoda	ACC	N	S	V	F	Q
Referenca 1	85,9	86,86	75,93	77,73	89,43	0
Referenca 2	78	77,55	76,46	82,94	95,36	N/A
Referenca 3	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

10 Tablica 18: Usporedba uspješnosti različitih pristupa

Tablica 18 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 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 radena.

U nastavku je dan kratki opis sustava za detekciju i raspoznavanje oblika valova u vremenskim serijama, posebno fiziološkog EKG signala koji se temelji na primjeni transformacija signala, te na računalni program i na računalno čitljiv medij.

Sustav za detekciju i raspoznavanja oblika valova u vremenskim serijama, posebno fiziološkog signala, koji sadrži ulazni sklop koji je uređen za primanje, snimanje i pohranjivanje valova u vremenskim serijama, uređaj uređen za uklanjanje šuma izvornog signala, koji nadalje sadrži:

- procesor koji je uređen na način da izlučuje morfološke značajke signala transformacijom izvornog jednodimenzionalnog signala u niz karakterističnih vektora V_{PT} percepције koji sažimaju morfologiju signala u okolini točke u trenutku T, koji vektori V_{PT} se sastoje od skupa značajki $m_{1T}; m_{2T}; \dots; m_{nT}$, pri čemu dio navedenih značajki opisuje geometrijske karakteristike odsječka signala, dio čine dinamički kumulativi, a dio vremensko morfološke determinante VMD, pri čemu se transformacija serije provodi unaprijed i unatrag u odnosu na vremenski slijed;
- model I klasifikatora pohranjenog na računalu u obliku programskog koda koji koristi rezultat transformacije za klasifikaciju odnosno detekciju zanimljivih dijelova signala u novim signalima;
- model II klasifikatora pohranjenog na računalu u obliku programskog koda koji koristi rezultat transformacije i rezultat detekcije zanimljivih oblika za klasifikaciju odnosno raspoznavanje oblika valova, koji se koristi za raspoznavanje oblika valova novih signala;
- bazu znanja koja sadrži skup proširenih značajki nastao izlučivanjem dinamičkih i morfoloških karakteristika signala u svrhu obrade algoritmima strojnog nenadziranog učenja i pronalaženja najsličnijih valova za neki novi val.

Predmetni izum se odnosi i na računalni program za detekciju i raspoznavanje oblika valova u vremenskim serijama, posebno fiziološkog signala, koji je prilagođen, da kada se izvršava na računalu, uzrokuje da računalo provodi računalno implementirani postupak detekcije i raspoznavanja oblika valova u vremenskim serijama. Prema predmetnom izumu valovi u vremenskim serijama su EKG valovi. Predmetni izum se odnosi i na računalno čitljiv medij, na kojem je pohranjen navedeni računalni program.

Predmetni izum tj. računalno implementirani postupak u obliku programskog koda što postupak čini prikladnim za razne primjene poput softvera na računalu, mobilnom telefonu ili portabilnom EKG uređaju (holter). Znanstvena i stručna literatura navode sustave u kojima su na mobilnim telefonima realizirane aplikacije za prihvrat EKG podataka putem bežične veze (npr. Bluetooth), a aplikacije na mobilnom telefonu obrađuju signal te putem mobilne mreže šalju kritične dijelove signala ili cijele signale u centralnu bazu podataka. Međutim, sustavi opisani u literaturi ne prikazuju obradu signala sa takvom točnošću kao što je to kod predmetnog izuma. Osim izvedbe softvera na mobilnom telefonu, predmetni izum je moguće implementirati i kao ugrađeni softver (engl. embedded) u specijalizirani EKG uređaj (npr. holter). U tom slučaju specijalizirani EKG uređaj osim funkcije snimanja EKG signala ima i funkciju obrade signala te detekcije QRS segmenata i klasifikacije oblika EKG valova. Takav uređaj nadalje može imati i sklopljive i programske opreme za komunikaciju sa drugim sustavima i slanje signala i obavijesti u centralnu bazu podataka.

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. 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. U nastavku je 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) 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 spomenuto 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 μ_1, \dots, μ_K), kovarijanca je $K \times K$ 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 mjeri sličnosti između dvije opservacije višedimenzionalnog prostora. Postoje i mnoge druge metode izračuna udaljenosti, no njihovo pojašnjavanje izlazi izvan okvira ovog rada.

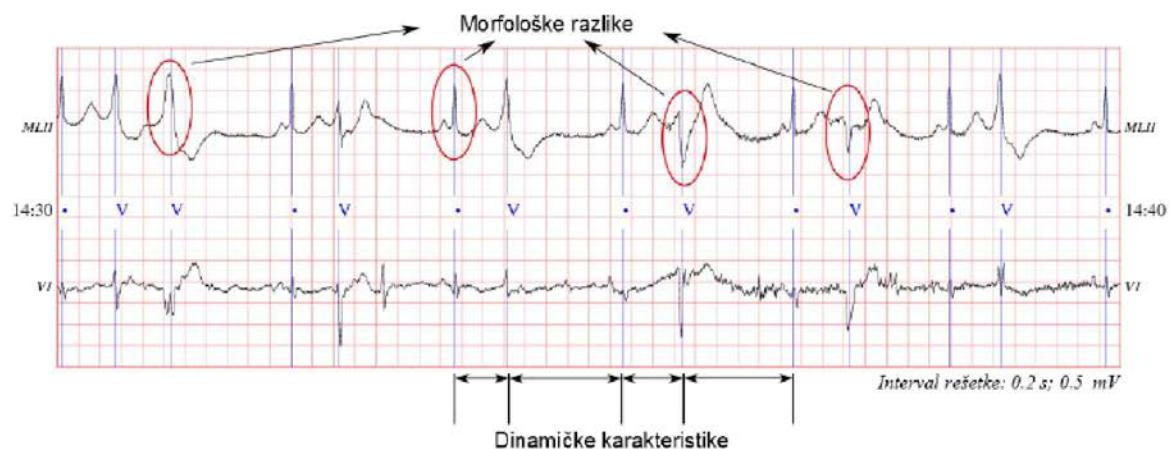
5

PATENTNI ZAHTJEVI

1. Računalno implementirani postupak detekcije i raspoznavanja oblika valova u vremenskim serijama, posebno EKG fiziološkog signala koji uključuje postupak predprocesiranja izvornog signala u svrhu uklanjanja šuma, izlučivanja morfoloških značajki signala sa smanjenim šumom, detekciju zanimljivih dijelova signala, izlučivanje dinamičkih značajki, raspoznavanje i klasificiranje oblika valova i grupiranje/klasteriranje sličnih odsječaka signala, **naznačen time** da se izlučivanje morfoloških značajki signala odvija transformacijom izvornog jednodimenzionalnog signala u niz karakterističnih vektora $\overrightarrow{V_{PT}}$ percepcije koji sažimaju morfologiju signala u okolini točke u trenutku T, koji vektori $\overrightarrow{V_{PT}}$ se sastoje od skupa značajki $m_{1T}; m_{2T}; \dots; m_{nT}$, pri čemu dio navedenih značajki opisuje geometrijske karakteristike odsječaka signala, dio čine dinamički kumulativi, a dio vremensko morfološke determinante VMD, pri čemu se transformacija serije provodi unaprijed i unatrag u odnosu na vremenski slijed.
2. Postupak prema zahtjevu 1, **naznačen time** da se rezultat transformacije signala koristi kao ulaz u klasifikator u svrhu izgradnje modela I za detekciju zanimljivih oblika odsječaka signala, te korištenje modela I za detekciju zanimljivih odsječaka signala u svrhu detekcije takvih odsječaka u novim signalima, te pohranjivanje modela I za detekciju zanimljivih odsječaka signala u obliku programskog koda.
3. Postupak prema zahtjevima 1 i 2, **naznačen time** da se transformirani odsječci signala grupiraju po obliku sličnim odsjećima signala u grupe/klastere pri čemu se generiraju nove pridružene informacije o grupiranju odsječaka uz izvorni signal koje u postupku nenadziranog strojnog učenja služe za pronalaženje sličnih oblika odsječaka signala za novi odsječak signala.
4. Postupak prema zahtjevima 1, 2 i 3, **naznačen time** da se signal istovremeno podvrgava klasifikaciji oblika odsječaka signala korištenjem modela I nakon čega se izlučuju dinamičke značajke i transformaciji u niz karakterističnih vektora $\overrightarrow{V_{PT}}$ percepcije, pri čemu rezultat ta dva istovremena koraka čine vektori s proširenim značajkama u svrhu izgradnje modela II za raspoznavanje oblika, te korištenje modela II za raspoznavanje oblika signala u svrhu raspoznavanja oblika u novim signalima, te pohranjivanje modela II za raspoznavanje oblika signala u obliku programskog koda.
5. Postupak prema zahtjevu 4, **naznačen time** da se transformirani oblici signala grupiraju po obliku sličnim oblicima signala u grupe/klastere pri čemu se generiraju nove pridružene informacije o grupiranju oblika uz izvorni signal koje u postupku nenadziranog strojnog učenja služe za pronalaženje sličnih oblika signala za novi oblik signala.
6. Postupak prema zahtjevu 1, **naznačen time** da se dinamički kumulativi komponente x vektora $\overrightarrow{\overrightarrow{V_{PT}}}$ izračunavaju posebno za vrijeme trajanja trenda signala i za vrijeme trajanja konkavnosti signala.
7. Postupak prema zahtjevu 6, **naznačen time** da se izračun kumulativa komponente x vektora $\overrightarrow{\overrightarrow{V_{PT}}}$ za vrijeme trajanja trenda odvija na sljedeći način: ako je trend u točki T jednak trendu u točki T-1, tada se trajanje trenda poveća za jedan te se kumulativ poveća za vrijednost varijable x, ako trend u točki T nije jednak trendu u točki T-1 tada se trajanje trenda postavlja na 1, a kumulativ na vrijednost varijable x, ako je detaljni trend u točki T jednak detalnjem trendu u točki T-1, tada se trajanje detaljnog trenda poveća za jedan te se detaljni kumulativ poveća za vrijednost varijable x,i ako detaljni trend u točki T nije jednak detalnjem trendu u točki T-1 tada se trajanje detaljnog trenda postavlja na 1, a detaljni kumulativ na vrijednost varijable x.
8. Postupak prema zahtjevu 6, **naznačen time** da se izračun kumulativa komponente x vektora $\overrightarrow{\overrightarrow{V_{PT}}}$ za vrijeme trajanja konkavnosti odvija na sljedeći način: ako je stupanj konkavnosti u točki T jednak stupnju konkavnosti u točki T-1, tada se trajanje stupnja konkavnosti poveća za jedan te se kumulativ poveća za vrijednost varijable x, ako stupanj konkavnosti u točki T nije jednak stupnju konkavnosti u točki T-1 tada se trajanje stupnja konkavnosti postavlja na 1, a kumulativ na vrijednost varijable x, ako je detaljni stupanj konkavnosti u točki T jednak detalnjem stupnju konkavnosti u točki T-1, tada se trajanje detaljnog stupnja konkavnosti poveća za jedan te se detaljni kumulativ poveća za vrijednost varijable x, i ako detaljni stupanj konkavnosti u točki T nije jednak detalnjem stupnju konkavnosti u točki T-1 tada se trajanje detaljnog stupnja konkavnosti postavlja na 1, a detaljni kumulativ na vrijednost varijable x.
9. Postupak prema zahtjevu 1, **naznačen time** da se izračun VMD vrijednosti komponente x vektora $\overrightarrow{\overrightarrow{V_{PT}}}$ za vrijeme trajanja trenda odvija na sljedeći način: ako je trend u točki T jednak trendu u točki T-1, tada se trajanje VMD brojača poveća za jedan te se VMD komponenta poveća za umnožak varijable x i VDM brojača, ako trend u točki T nije jednak trendu u točki T-1 tada se VMD brojač postavlja na 1, a VMD komponenta na vrijednost varijable x, ako je detaljni trend u točki T jednak detalnjem trendu u točki T-1, tada se vrijednost detaljnog VMD brojača

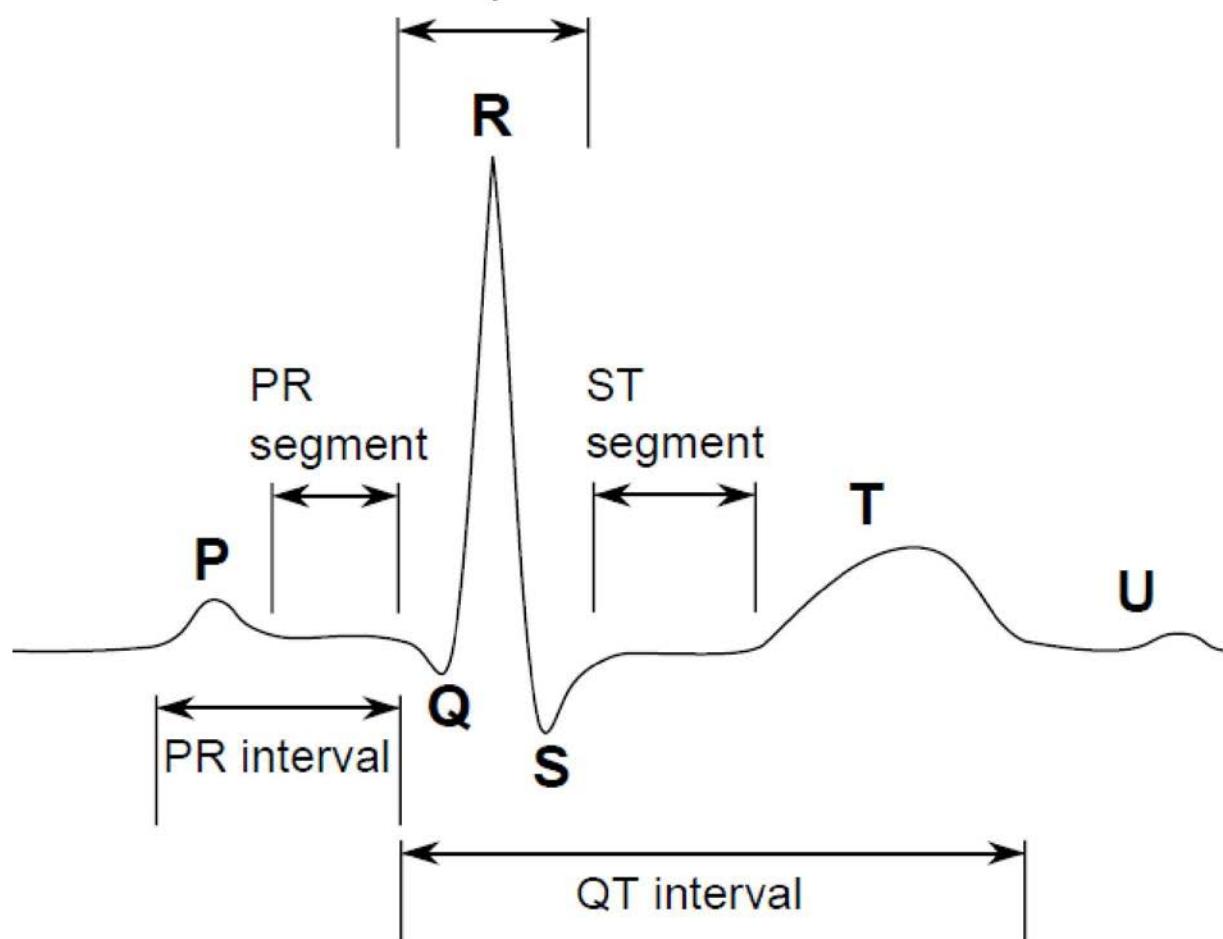
poveća za jedan te se detaljna VMD komponenta poveća za umnožak varijable x i detaljnog VDM brojača, i ako detaljni trend u točki T nije jednak detalnjom trendu u točki $T-1$ tada se vrijednost detaljnog VMD brojača postavlja na 1, a detaljna VMD komponenta na vrijednost varijable x .

10. Postupak prema zahtjevu 1, **naznačen time** da geometrijske karakteristike odsječka signala čine: kutni otklon i kutni otklon unatrag, normalizirana izvorna vrijednost, površina ispod zadnjeg odsječka i površina ispod zadnjeg odsječka unatrag, aproksimacije prve derivacije i aproksimacija prve derivacije unatrag, zadnja promjena površine i zadnja promjena površine unatrag, trend i trend unatrag, detaljni trend i detaljni trend unatrag, trajanje trenda i trajanje trenda unatrag, trajanje detaljnog trenda i trajanje detaljnog trenda unatrag, koeficijent konkavnosti i koeficijent konkavnosti unatrag, oznaka konkavnosti i oznaka konkavnosti unatrag, oznaka detaljne konkavnosti i oznaka detaljne konkavnosti unatrag, vrsta stacionarne točke i trajanje stupnja konkavnosti i trajanje stupnja konkavnosti unatrag.
11. Postupak prema zahtjevima 1 do 6, **naznačen time** da dinamičke kumulativne odsječke signala čine: kumulativne površine za vrijeme trajanja trenda, kumulativne površine za vrijeme trajanja trenda unatrag, kumulativna promjena površine za vrijeme trenda, kumulativna promjena površine za vrijeme trenda unatrag, kumulativna promjena površine za vrijeme detaljnog trenda, kumulativna promjena površine za vrijeme detaljnog trenda unatrag, kumulativne kute za vrijeme trajanja trenda, kumulativne kute za vrijeme trajanja trenda unatrag, kumulativne kute za vrijeme trajanja detaljnog trenda, kumulativne kute za vrijeme trajanja detaljnog trenda unatrag, kumulativne konkavnosti za vrijeme trajanja konkavnosti, kumulativne konkavnosti za vrijeme trajanja konkavnosti unatrag, kumulativne konkavnosti za vrijeme trajanja konkavnosti detaljno, kumulativne konkavnosti za vrijeme trajanja konkavnosti detaljno unatrag, kumulativne konkavnosti za vrijeme trajanja trenda i kumulativne konkavnosti za vrijeme trajanja trenda unatrag.
12. Postupak prema zahtjevu 1 i 9, **naznačen time** da vremensko morfološke determinante odsječka signala (VMD) čine: prve derivacije za vrijeme trajanja trenda, VMD prve derivacije za vrijeme trajanja trenda unatrag, VMD prve derivacije za vrijeme trajanja detaljnog trenda, VMD prve derivacije za vrijeme trajanja detaljnog trenda unatrag, VMD konkavnosti za vrijeme trajanja trenda, VMD konkavnosti za vrijeme trajanja trenda unatrag, VMD konkavnosti za vrijeme trajanja detaljnog trenda, VMD konkavnosti za vrijeme trajanja detaljnog trenda unatrag, VMD površine za vrijeme trajanja trenda, VMD površine za vrijeme trajanja trenda unatrag, VMD površine za vrijeme trajanja detaljnog trenda i VMD površine za vrijeme trajanja detaljnog trenda unatrag.
13. Postupak prema prethodnim zahtjevima, **naznačen time** da se za klasifikaciju signala primjenjuje algoritam Slučajne šume.
14. Postupak prema prethodnim zahtjevima, **naznačen time** da su zanimljivi dijelovi signala QRS kompleks u EKG fiziološkom signalu.
15. Sustav za detekciju i raspoznavanje oblika valova u vremenskim serijama, posebno fiziološkog signala, koji sadrži ulazni sklop koji je uređen za primanje, snimanje i pohranjivanje valova u vremenskim serijama, uređaj uređen za uklanjanje šuma izvornog signala, **naznačen time** da nadalje sadrži: procesor koji je uređen na način da izlaze morfološke značajke signala transformacijom izvornog jednodimenzionalnog signala u niz karakterističnih vektora V_{PT} percepcije koji sažimaju morfologiju signala u okolini točke u trenutku T, koji vektori V_{PT} se sastoje od skupa značajki $m_{1T}; m_{2T}; \dots; m_{nT}$, pri čemu dio navedenih značajki opisuje geometrijske karakteristike odsječka signala, dio čine dinamički kumulativni, a dio vremensko morfološke determinante VMD, pri čemu se transformacija serije provodi unaprijed i unatrag u odnosu na vremenski slijed; model I klasifikatora pohranjenog na računalu u obliku programskog koda koji model I koristi rezultat transformacije za klasifikaciju odnosno detekciju zanimljivih odsječaka signala u novim signalima; model II klasifikatora pohranjenog na računalu u obliku programskog koda koji model II koristi rezultat transformacije i rezultat detekcije zanimljivih oblika za klasifikaciju odnosno raspoznavanje oblika valova koji se koristi za raspoznavanje oblika valova novih signala; i bazu znanja koja sadrži skup proširenih značajki nastao izlučivanjem dinamičkih i morfoloških karakteristika signala u svrhu obrade algoritmima strojnog nenadziranog učenja i pronalaženja najsličnijih odsječaka signala za novi odsječak signala ili najsličnijih oblika valova za novi val.
16. Računalni program za detekciju i raspoznavanje oblika valova u vremenskim serijama, posebno fiziološkog signala, **naznačen time** da je prilagođen, da kada se izvršava na računalu, uzrokuje da računalo provodi postupak prema zahtjevima 1 do 14.
17. Računalno čitljiv medij, **naznačen time** da sadrži pohranjen računalni program iz zahtjeva 16.



Sl. 1

QRS kompleks

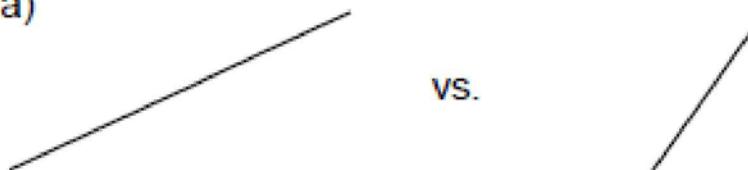


Sl. 2

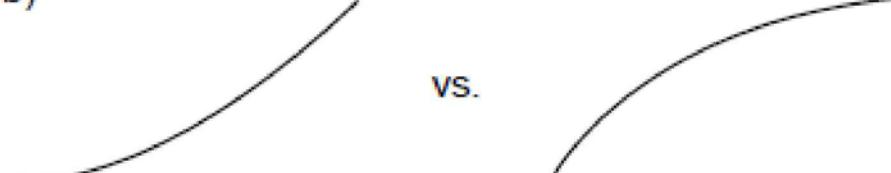


Sl. 3

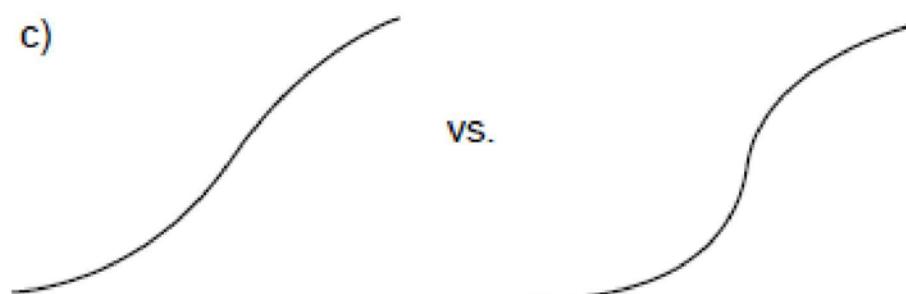
a)



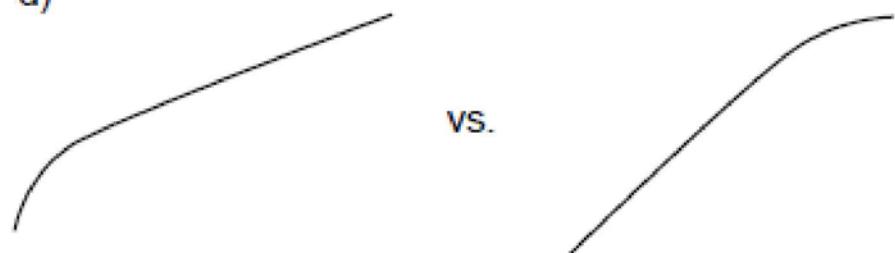
b)



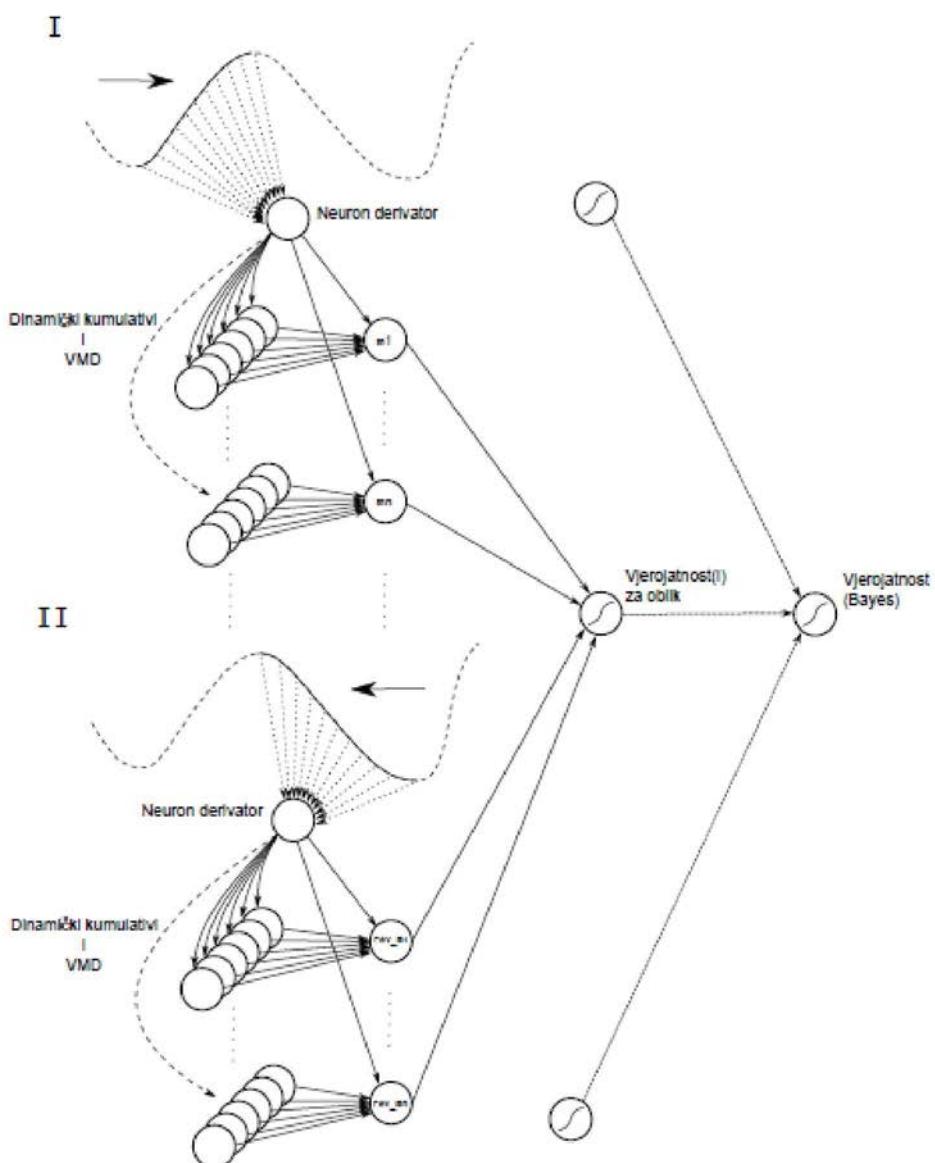
c)



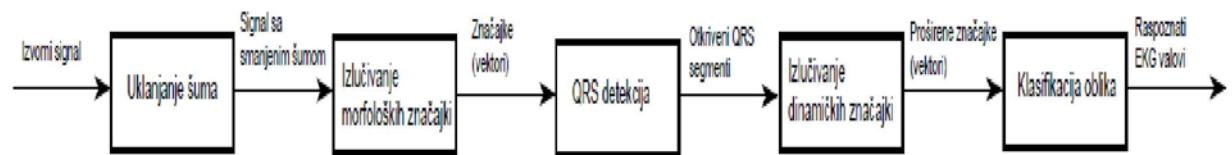
d)



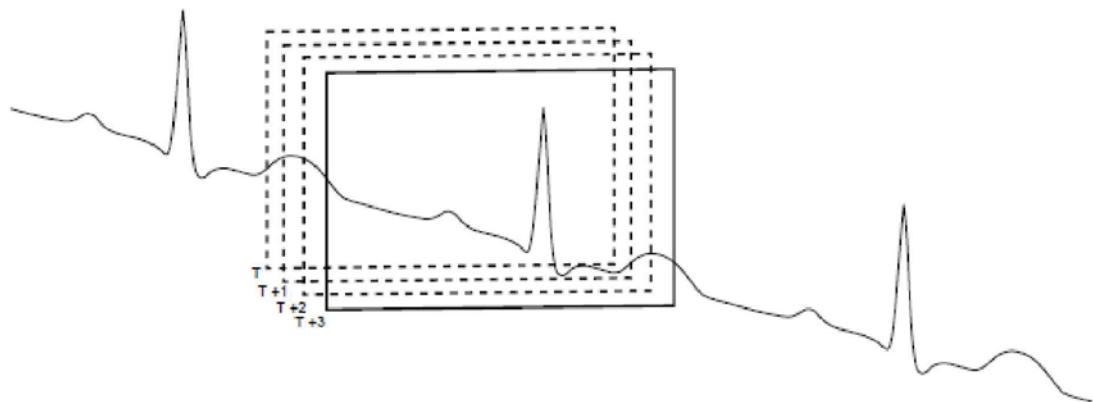
Sl. 4



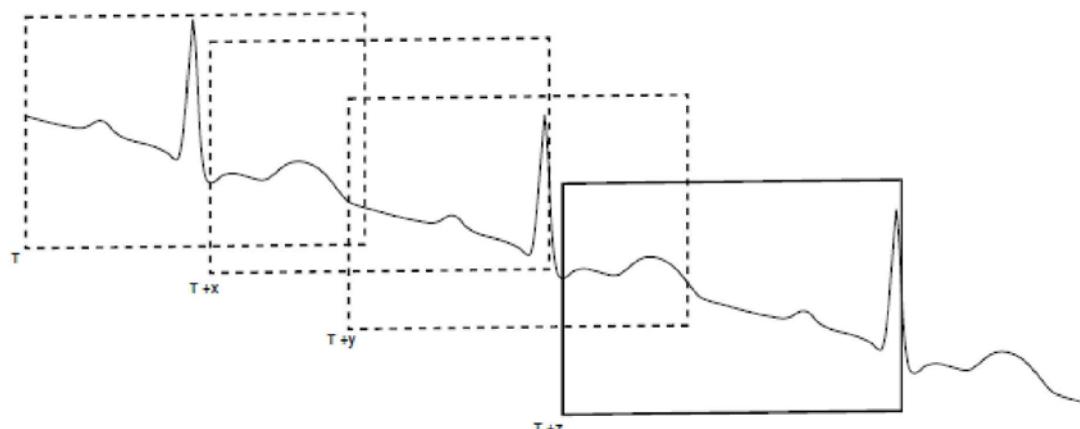
Sl. 5



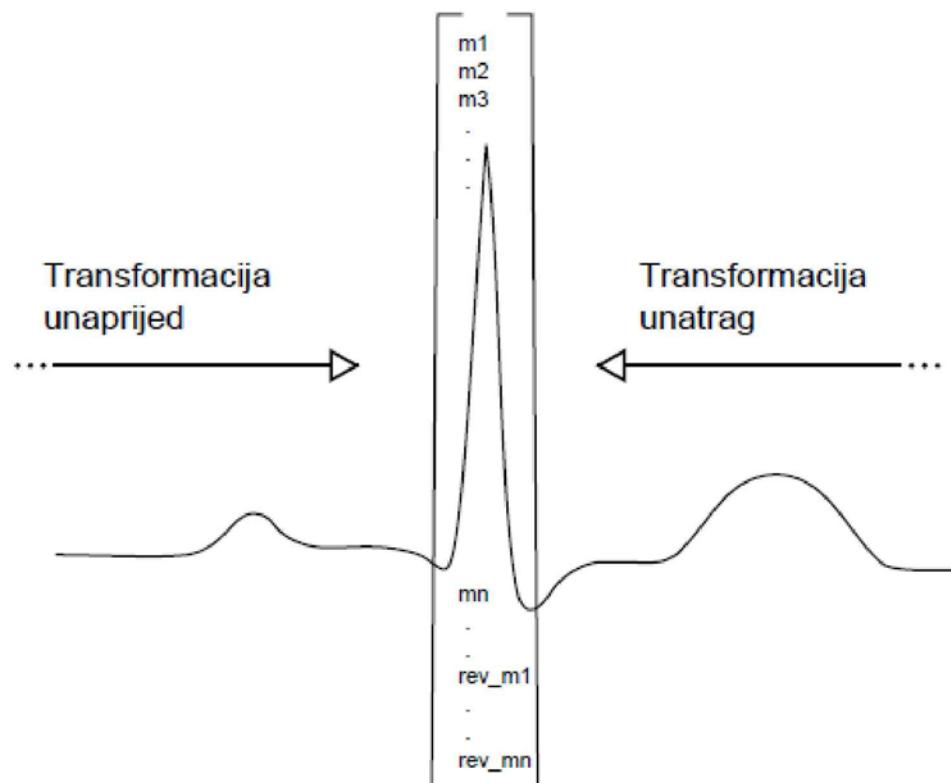
Sl. 6



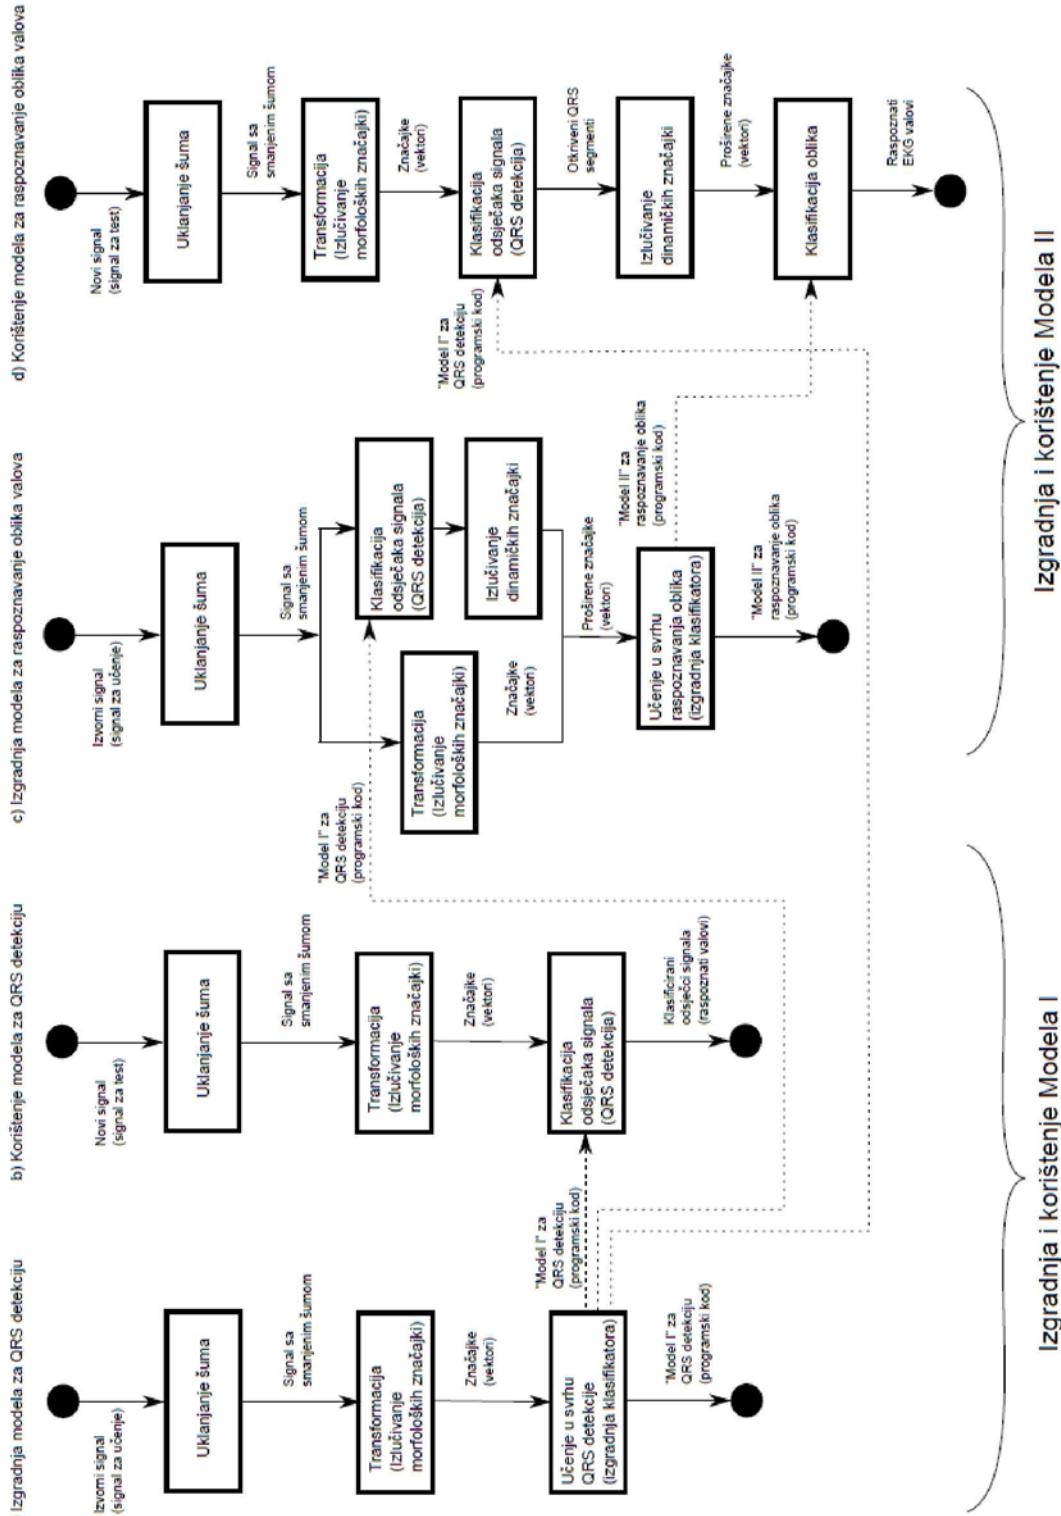
Sl. 7



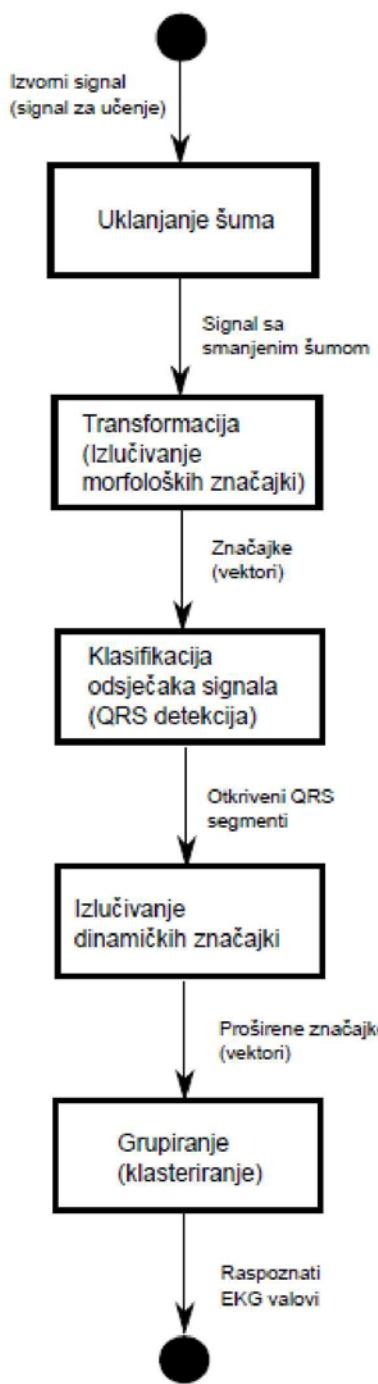
Sl. 8



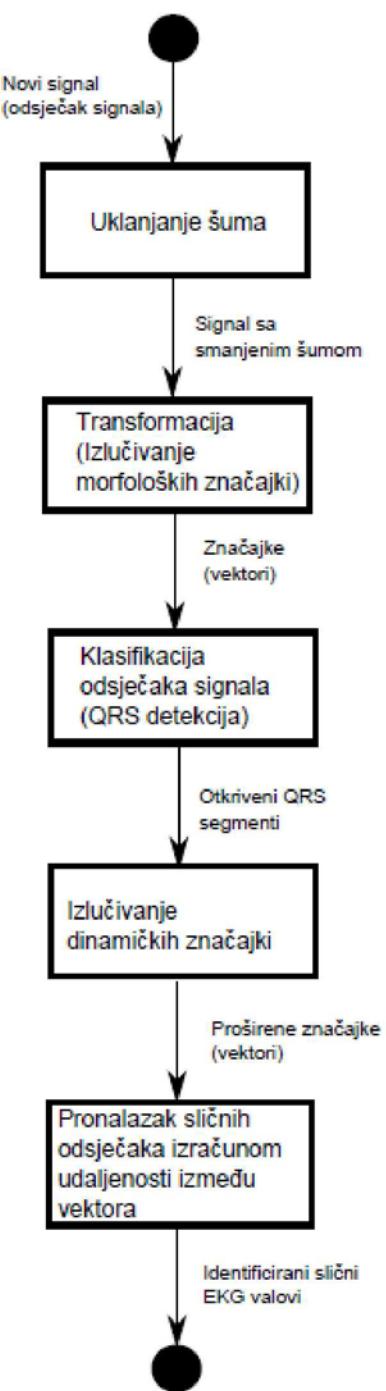
Sl. 9



e) Postupak nenadziranog učenja - grupiranje



f) Postupak nenadziranog učenja - pronađazak sličnih



Sl. 11