

Pronalaženje ključnih točaka EKG signala pomoću neuronskih mreža

Sušac, Antonio

Master's thesis / Diplomski rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:200:571762>

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

Download date / Datum preuzimanja: **2024-12-28**

Repository / Repozitorij:

[Faculty of Electrical Engineering, Computer Science and Information Technology Osijek](#)



SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I
INFORMACIJSKIH TEHNOLOGIJA**

Sveučilišni studij

**PRONALAZENJE KLJUČNIH TOČAKA EKG
SIGNALA POMOĆU NEURONSKIH MREŽA**

Diplomski rad

Antonio Sušac

Osijek, 2017.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Obrazac D1: Obrazac za imenovanje Povjerenstva za obranu diplomskog rada

Osijek, 21.09.2017.

Odboru za završne i diplomske ispite

Imenovanje Povjerenstva za obranu diplomskog rada

Ime i prezime studenta:	Antonio Sušac
Studij, smjer:	Diplomski sveučilišni studij Računarstvo, smjer Procesno računarstvo
Mat. br. studenta, godina upisa:	D 728 R, 06.10.2011.
OIB studenta:	65756293691
Mentor:	Izv. prof. dr. sc. Irena Galić
Sumentor:	doc. dr. sc. Dario Galić
Sumentor iz tvrtke:	Dario Galić
Predsjednik Povjerenstva:	Doc.dr.sc. Časlav Livada
Član Povjerenstva:	Krešimir Romić
Naslov diplomskog rada:	Pronalaženje ključnih točaka EKG signala pomoću neuronskih mreža
Znanstvena grana rada:	Obradba informacija (zn. polje računarstvo)
Zadatak diplomskog rada:	U ovom radu potrebno je napraviti analizu traženja pojedinih točaka ili segmenata u EKG-u pomoću neuronskih mreža. Opisati postojeće načine traženja točaka u EKG signalu, a u praktičnom dijelu primjenom neuronskih mreža napraviti detekciju ključnih točaka EKG signala. Sumentor: doc. dr. sc. Dario Galić, Medicinski fakultet Osijek
Prijedlog ocjene pismenog dijela ispita (diplomskog rada):	Izvrstan (5)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 3 bod/boda Postignuti rezultati u odnosu na složenost zadatka: 3 bod/boda Jasnoća pismenog izražavanja: 3 bod/boda Razina samostalnosti: 3 razina
Datum prijedloga ocjene mentora:	21.09.2017.
Potpis mentora za predaju konačne verzije rada u Studentsku službu pri završetku studija:	Potpis:
	Datum:

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK**IZJAVA O ORIGINALNOSTI RADA**

Osijek, 29.09.2017.

Ime i prezime studenta:

Antonio Sušac

Studij:

Diplomski sveučilišni studij Računarstvo, smjer Procesno računarstvo

Mat. br. studenta, godina upisa:

D 728 R, 06.10.2011.

Ephorus podudaranje [%]:

1%

Ovom izjavom izjavljujem da je rad pod nazivom: **Pronalaženje ključnih točaka EKG signala pomoću neuronskih mreža**

izrađen pod vodstvom mentora Izv. prof. dr. sc. Irena Galić

i sumentora doc. dr. sc. Dario Galić

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija.
Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis studenta:

Sadržaj

1. Uvod	1
1.1. Zadatak diplomskog rada	2
2. Srce i EKG.....	3
2.1. Građa srca.....	3
2.2. Električna aktivnost srca	4
2.3. Elektrokardiografija.....	7
2.4. Elektrokardiogramska mreža.....	10
2.5. Karakteristični dijelovi EKG-a.....	11
3. Umjetne neuronske mreže	13
3.1. Povijest umjetnih neuronskih mreža	13
3.2. Biološka i umjetna neuronska mreža.....	14
3.3. Model umjetnog neurona.....	16
3.4. Model umjetne neuronske mreže.....	17
3.5. Prijenosne funkcije neurona	18
3.6. Podjele neuronskih mreža.....	19
3.7. Rad neuronske mreže	21
3.8. Levenberg-Marquardt algoritam učenja	23
3.9. Područja primjene umjetnih neuronskih mreža	26
4. Algoritmi za QRS detekciju	27
4.1. Postojeći pristupi za analizu EKG signala.....	27
4.2. Ocjenjivanje algoritama detekcije QRS kompleksa	28
4.3. MIT-BIH Arrhythmia Database	29
4.4. PhysioNet	30
4.5. Uklanjanje šumova i smetnji	30
4.6. Pan-Tompkinsov algoritam detekcije.....	31
4.7. Ostale metode detekcije.....	34
5. Analiza i pronalaženje ključnih točaka EKG signala uz pomoć umjetnih neuronskih mreža	35
5.1. Programski paket za izradu detektora.....	35
5.2. Učitavanje signala iz MIT-BIH Arrhythmia baze u MATLAB	35
5.3. Izvedba detekcije.....	36
5.4. Ekstrakcija značajki.....	38
5.5. Određivanje željenih izlaza	39
5.6. Kreiranje i trening mreže.....	40
5.7. Rezultati treninga i detekcija QRS kompleksa	46
6. Zaključak	53

Literatura	54
Sažetak	55
Abstract	56
Životopis.....	57
Prilozi	58

1.Uvod

Tema ovoga rada je pronalaženje ključnih točaka EKG signala pomoću umjetnih neuronskih mreža. Početno pitanje je, što zapravo predstavlja kratica EKG. Jednostavnim rječnikom rečeno, EKG ili elektrokardiogram je snimak koji nastaje radom elektrokardiografa odnosno naprave koja zapisuje električnu aktivnost srca u vremenu. Postojanje električne aktivnosti srca uočili su još davne 1856. godine znanstvenici Koelliker i Müller, a A.D.Waller je 1877. godine izvršio na čovjeku prvo snimanje tzv. kapilarnim elektrometrom. Nizozemski liječnik i fiziolog Willem Einthoven je 1903. godine u gradu Leidenu konstruirao puno osjetljiviji uređaj elektrokardiograf. Prvotni elektrokardiograf je zapravo bio galvanometar „na žicu“. Funkcionirao je na način da je između polova elektromagneta vibrirala žica, čija se sjenka reflektirala kroz mikroskop na fotografski papir i na taj način predočavala vremenski tijek akcijskih struja u srcu, odnosno prvotni elektrokardiogram. Einthoven je također prvi identificirao različite valne oblike i dodijelio im slova P, Q, R, S i T, te prvi elaborirao i različita elektrokardiografska obilježja za nekoliko poremećaja krvožilnog sustava. Za svoje otkriće Willem Einthoven je 1924. godine primio Nobelovu nagradu za medicinu. Od vremena prvotnog elektrokardiografa do danas, elektrokardiografija je znatno napredovala te uz pomoć usavršenih elektronskih uređaja omogućila dijagnosticiranje velikog broja srčanih oboljenja i olakšala liječenje istih. Za EKG se može reći da ima najveću dijagnostičku vrijednost jer broj dijagnoza koje se mogu dijagnosticirati znatno je veći nego pri mjerenju svih ostalih napona u organizmu. EKG je koristan u velikom broju slučajeva: pomaže pri dijagnozi srčanih aritmija, te kod dijagnoze poremećaja elektrolita, nalazi EKG-a utječe na terapiju i procjenu rizika kod bolesnika sa sumnjom na akutni infarkt miokarda, a ponekad je koristan i kod nesrčanih oboljenja kao što su plućna embolija i hipotermija. Svaki ciklus na elektrokardiogramu je obilježen valnim oblicima poznatijim kao P-val, QRS kompleks i T-val. Vrijeme između početka i kraja pojedinih valova važno je jer odražava fiziološke procese koji se događaju u srcu. QRS kompleks predstavlja jedan otkucaj srca, a njegovom ispravnom detekcijom stvara se osnova za analizu srčanog ritma. U današnje vrijeme vidljiv je porast uporabe inteligentnih računalnih sustava u svim životnim područjima, samim time i u području medicine. Inteligentni računalni sustavi imaju zadatak olakšati posao i poboljšati kvalitetu liječenja. Jedan od oblika ovih računalnih sustava jesu i umjetne neuronske mreže, koje predstavljaju računalne sustave zasnovane na matematičkim modelima koje za razliku od tradicionalnih računala imaju

strukturu i operacije koje podsjećaju na ljudski mozak. Sastoje se od niza međusobno povezanih elemenata koji podatke obrađuju paralelno. Umjetne neuronske mreže se koriste za rješavanje sve većeg broja problema u stvarnom životu. Rad umjetnih neuronskih mreža se temelji na učenju i iskustvu iz prethodnih unosa podataka. Na osnovu svog prethodnog znanja one mogu odrediti ovisnost tek unesenih podataka. Iako se neuronske mreže u velikoj mjeri koriste za rješavanje raznih inženjerskih problema tek su odnedavno sve zastupljenije u rješavanju zdravstvenih problema, osobito u području kardiologije.

Kroz rad se u prvom poglavlju obrađuju teme vezane uz srce i EKG. Zatim će kroz jedno cijelo poglavlje biti predstavljene umjetne neuronske mreže (podjela, prednosti i nedostaci, vrste, učenje). Dalje će biti opisani i drugi postojeći načini za traženje ključnih točaka EKG signala (QRS detektor algoritmi). U završnom dijelu rada analizirat će se traženje ključnih točaka (QRS kompleksa) pomoću umjetnih neuronskih mreža, a u praktičnom dijelu će se na osnovu stečenog znanja napraviti detekcija QRS kompleksa primjenom neuronskih mreža.


1.1.Zadatak diplomskog rada

U ovom radu potrebno je napraviti analizu traženja pojedinih točaka ili segmenata u EKG-u pomoću neuronskih mreža. Opisati postojeće načine traženja točaka u EKG signalu, a u praktičnom dijelu primjenom neuronskih mreža napraviti detekciju ključnih točaka EKG signala.

2.Srce i EKG

2.1.Građa srca

Srce (*lat. cor*) je dvostruka mišićna pumpa koja tjera krv u krvne žile, a one ju raznose po organizmu [1]. Srce ima oblik trostrane piramide, čije plohe bez izrazitih rubova prelaze jedna u drugu. Na srčanoj piramidi razlikujemo bazu, vrh i tri strane. Prednja strana prislonjena je na prednju prsnu stijenku. Donja strana priliježe uz ošit, a okrenuta je prema straga i dolje. Postranične strane dodiruju plućna krila. Na slici 2.1. prikazan je položaj srca u ljudskom tijelu. Ljudsko srce ima masu od 250 do 350 grama, a u prosjeku je veličine stisnute šake.




Slika 2.1. : Položaj srca u ljudskom tijelu

Na srcu razlikujemo tri sloja koji odgovaraju slojevima stijenke krvnih žila: endokard, miokard i epikard. Vanjska opna koja štiti srce naziva se osrčje ili perikard. Endokard oblaže unutarnju stranu srca dok epikard oblaže površinu srca. Miokard predstavlja najdeblji mišićni sloj srca koji upravlja kontrakcijom srca i prijenosom podražaja te usklađuje rad svih dijelova srca.

Krv koja teče od srca prema određenom organu je bogata kisikom, poznata je kao arterijska krv. Ako krv teče od organa prema srcu, ona je siromašna kisikom i naziva se venska krv. Srce potiskuje krv u aortu, glavnu i najveću arteriju u ljudskom tijelu, iz koje krv odlazi dalje u manje arterije i kapilare. U srčanom radu postoje dvije faze: srčana kontrakcija, sistola, kada se krv izbacuje iz srca, i dijastola, razdoblje opuštenosti srčanog mišića, kada se srce puni krvlju. Srce se dijeli na desno srce, koje pumpa krv malog krvotoka, i lijevo srce, koje pumpa krv velikog krvotoka. Na svakoj se strani nalazi jedna pretklijetka (*lat. atrium*) i klijetka (*lat. ventriculus*).

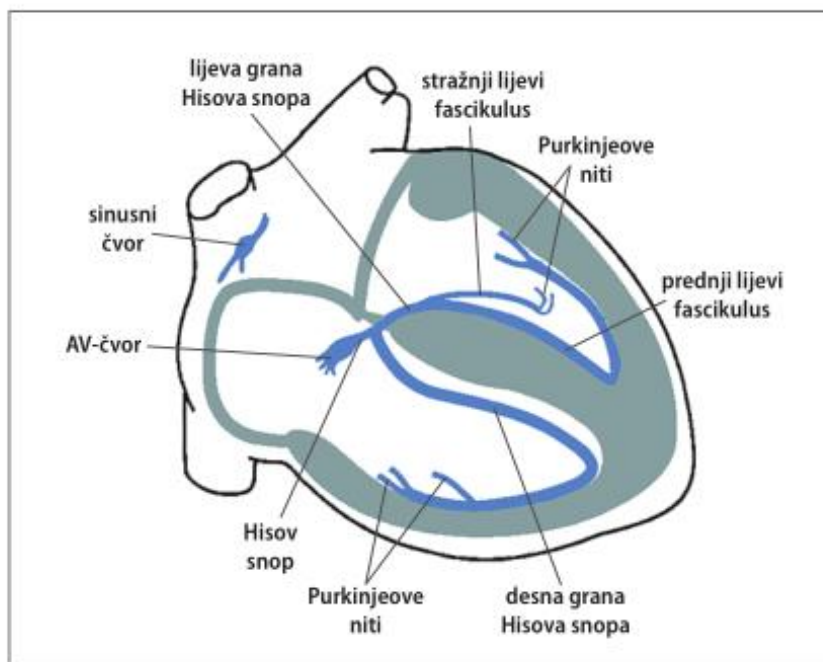
Krv u pretklijetke dovode velike krvne žile, potom krv odlazi u klijetke, a iz klijetki u arterije. Na slici 2.2. prikazan je presjek građe srca.



Slika 2.2. : Presjek građe srca

2.2. Električna aktivnost srca

Prema [2], anatomsku osnovu elektrokardiograma čini provodni sustav srca koji je odgovoran za nastanak i provođenje električnog impulsa. Provodni sustav srca se sastoji od sinusnog čvora (sinus atrijski, SA čvor), atrioventrikularnog čvora (AV čvor), Hisova snopa te njegove desne i lijeve (stražnji lijevi i prednji lijevi fascikulus) grane i Purkinjeovih niti. Na slici 2.3. preuzetoj iz [2] shematski su prikazani elementi provodnog sustava srca.



Slika 2.3. : Shematski prikaz elemenata provodnog sustava srca

Električni impuls se stvara u sinusnom čvoru te se velikom brzinom širi kroz čitav atrij. Impuls se dalje provodi do donjeg desnog dijela atrija gdje se nalazi AV čvor. Pri prolasku kroz AV čvor, električni impuls usporava odnosno opada brzina provođenja. Nakon izlaska iz AV čvora, električni impuls ulazi u Hisov snop. Hisov snop je sačinjen od vlakana specijaliziranih za veoma brzo provođenje impulsa (najveća brzina). Dalje se preko grana Hisova snopa provodi do Purkinjeovih niti. Nakon kojih se provodi do mišićnih stanica ventrikula koje se zatim stežu. Također treba napomenuti da svi dijelovi srca koji su uključeni u stvaranje i prijenos impulsa (SA čvor, AV čvor, Hisov snop, Purkinjeove niti) su zapravo mišići. U srcu ne postoje živci za provođenje električnih impulsa, kod srca tu ulogu preuzimaju specijalizirani mišići.

Prema [2], električna aktivnost srca se smatra temeljnom karakteristikom srca i uvjetom za mehaničku aktivnost srca. Srčani akcijski potencijal predstavlja kratku promjenu napona (membranskog potencijala) preko stanične membrane srčanih stanica. Ta promjena je uzrokovana kretanjem nabijenih iona unutar i izvan stanice kroz ionske kanale. Za razliku od drugih srčani akcijski potencijal nije pokrenut živčanom aktivnošću, kao što je ranije i navedeno. Akcijski potencijal aktivnosti unutar srca može se prikazati pomoću elektrokardiograma, što je vidljivo na slici 2.4. preuzetoj iz [2]. EKG prikazuje PQRST kompleks koji predstavlja depolarizaciju i repolarizaciju akcijskog potencijala. Akcijski potencijal srca ima pet faza u kojima se događa depolarizacija i repolarizacija srčane stanice.

Proces depolarizacije događa se kada podražaj bude dovoljno jak da pređe prag podražaja i na taj način uzrokuje otvaranje ionskih kanala. Pozitivni ioni Na^+ ulaze u srčanu stanicu te na taj način dolazi do promjene električnog potencijala. Repolarizacija nastaje usred promjene električnog naboja unutar stanice te to dovodi do pojave razlikovnog potencijala čime dolazi do izlaznog protoka K^+ iona iz stanice.

Prema [3], ciklus depolarizacije i repolarizacije srčane stanice u pet faza:

- **DEPOLARIZACIJA**

FAZA 0

Nagli ulazak $[\text{Na}]^+$ iona u stanicu radne muskulature ili $[\text{Ca}]^{++}$ u stanicama provodnog sustava stvara unutarstanični električni pozitivitet.

- **REPOLARIZACIJA**

FAZA 1

Brza repolarizacija nastaje zbog izlaska $[\text{K}]^+$ kationa van stanice te se tako smanjuje unutarstanični pozitivitet koji se pojavio u fazi depolarizacije.

FAZA 2

Karakteristični plato. Period relativne električne stabilnosti, kada je izlazak $[\text{Na}]^+$ iz stanice uravnotežen ulaskom $[\text{Ca}]^{++}$. Ulaz $[\text{Ca}]^{++}$ je bitniji kod stanica gdje se pojavljuje električni impuls nego kod radnih stanica mišićnog tkiva srca.


FAZA 3

Završna repolarizacija. Period završne repolarizacije kojeg obilježava $[\text{Na}]^+$ i $[\text{K}]^+$ izlaz iz stanice i $[\text{Ca}]^{++}$ ulaz u stanicu.

- **DIJASTOLA**

FAZA 4

Spontana dijastolička depolarizacija je faza koju imaju samo srčane stanice u kojima se stvaraju električni impulsi u vidu depolarizacijskog vala. Događa se u dijastoli, tako da laganim ulazom $[\text{Na}]^+$ i $[\text{Ca}]^{++}$ u stanicu i u isto vrijeme padom propusnosti za $[\text{K}]^+$ dolazi do postupnog smanjenja transmembranskog potencijala u mirovanju. Kad se dosegne razina praga, tada počinje faza 0. Ova je faza pod utjecajem neurovegetativnog sustava koji je ubrzava ili usporava prema potrebama organizma.



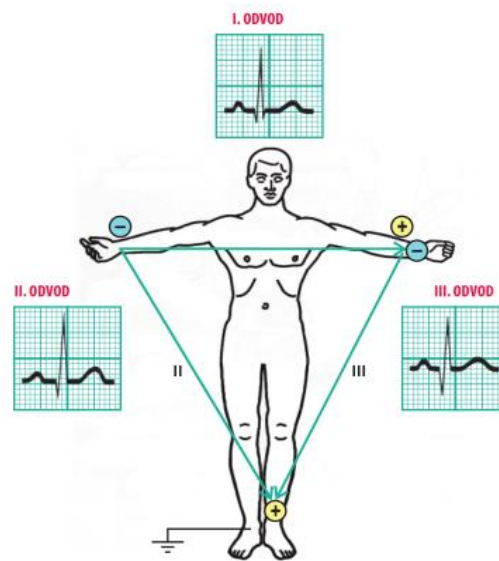
Slika 2.4. : Shematski prikaz osnove za nastanak elektrokardiograma

2.3. Elektrokardiografija

Elektrokardiografija je proces snimanja električne aktivnosti srca tijekom vremena uporabom elektroda koje se postavljaju na kožu. Pomoću elektroda mjeri se razlika električnog potencijala na površini tijela koja nastaje kao uzrok električnih struja kroz srce i okolna provodna tkiva. Upravo elektrokardiografska snimka tih razlika potencijala između elektroda predstavlja elektrokardiografski odvod. Uobičajeni 12-kanalni EKG se dobiva pomoću 10 elektroda koje se stavljaju na pacijentove udove i na površinu prsnog koša. Cjelokupan srčani električni potencijal mjeri se iz 12 različitih kutova u horizontalnoj i vertikalnoj ravnini.

Elektrokardiografski odvodi se mogu svrstati u dvije skupine: periferni odvodi (I, II, III, aVR, aVL, aVF) i prekordijalni odvodi (V1, V2, V3, V4, V5, V6). Periferne odvode čine standardni odvodi (I, II, III) i pojačani odvodi (aVR, aVL, aVF).


Standardni ili bipolarni odvodi (prema Einthovenu) povezuju dvije elektrode koje su postavljene na udovima te svaka jednako snima razlike električnog potencijala na površini tijela. Standardni odvod I predstavlja napon između pozitivne elektrode lijeve ruke i negativne elektrode desne ruke. Standardni odvod II predstavlja napon između pozitivne elektrode lijeve noge i negativne elektrode desne ruke dok kod standardnog odvoda III pozitivna elektroda i dalje ostaje na lijevoj nozi, a negativna elektroda se nalazi na lijevoj ruci. Na desnu nogu se postavlja elektroda koja služi za uzemljenje. Standardni odvodi formiraju tzv. Einthovenov trokut kao što je i prikazano na slici 2.5 preuzetoj iz [2].



Slika 2.5. : Standardni odvodi formiraju Einthovenov trokut

Pojačani ili unipolarni odvodi (prema Goldbergeru¹) su izvedeni iz iste tri elektrode kao standardni odvodi I, II, i III, ali su raspoređeni na način da utjecaj jedne elektrode bude dominantan i amplitude povećane (*a* u nazivu odvoda dolazi od engl. augmented što znači povećan). Tako kod aVR odvoda elektroda desne ruke postaje pozitivna i dominantna, a negativni pol je kombinacija (srednja vrijednost potencijala) elektroda lijeve ruke i lijeve noge. Kod aVL odvoda pozitivna i dominantnog utjecaja postaje elektroda lijeve ruke, a negativni pol je kombinacija elektroda desne ruke i lijeve noge. Dominantna i pozitivna elektroda kod pojačanog aVF odvoda se nalazi na lijevoj nozi dok je negativni pol kombinacija elektroda lijeve i desne ruke. Na slici 2.6. preuzetoj iz [2] prikazani su pojačani odvodi kod kojih jedna elektroda postaje dominantna i pozitivna dok negativni pol nastaje kao kombinacija dvije nasuprotne elektrode.


¹ Dr. Emanuel Goldberger – američki kardiolog



Slika 2.6. : Pojačani (unipolarni) odvodi prema Goldbergeru

Prekordijalni odvodi (prema Wilsonu²) nastaju kao razlike potencijala između prekordijalnih elektroda i Wilsonovog potencijala (izračunati potencijal) koji je približno smješten u središtu prsnog koša. Ranije su već spomenuta dva izraza, a to su bipolarni i unipolarni odvodi. Za perkordijalne odvođe (V1, V2, V3, V4, V5, V6) također kažemo da su unipolarni odvodi makar je taj izraz pogrešan jer za mjerenje potencijala uvijek je nužno imati dvije točke. Kada koristimo izraz unipolarni odvod zapravo se misli o razlici potencijala između elektrode i izračunatog potencijala što je u ovom slučaju Wilsonov potencijal, a ranije kod pojačanih odvoda su to bile kombinacije izračunate prema Goldbergeru. Na slici 2.7. prikazana je pozicija prekordijalnih elektroda.


² Dr. Frank Norman Wilson – američki kardiolog



Slika 2.7. : Prikaz pozicija prekordijalnih elektroda

2.4. Elektrokardiogramska mreža

Uobičajeno je bilježiti EKG pomoću standardnih mjera za amplitudu električnog signala i za brzinu kojom se papir kreće tijekom snimanja. Amplituda ili napon snimljenog električnog signala izražava se na vertikalnoj osi i mjeri se u milivoltima (mV). Na standardnom EKG papiru 1mV predstavlja promjenu od 10 mm. EKG možemo zamisliti kao grafikon, ucrtavajući električnu aktivnost na vertikalnoj osi u odnosu na vrijeme na horizontalnoj osi. Standardizirani EKG papir (milimetarski papir) pomiče se brzinom 25 mm u sekundi tijekom snimanja u stvarnom vremenu. EKG papir označen je mrežom malih i velikih kvadrata. Svaki mali kvadrat predstavlja 40 milisekundi (ms) u vremenu duž horizontalne osi, a svaki veći kvadrat sadrži pet malih kvadrata, što predstavlja 200 ms. Standardne brzine papira i kvadratne oznake omogućuju jednostavno mjerenje vremenskih intervala srca. To omogućuje izračunavanje brzine otkucaja srca i prepoznavanje nepravilne električne provodljivosti unutar srca. Na slici 2.8. prikazana je elektrokardiogramska mreža.



Slika 2.8. : Elektrokardiogramska mreža

2.5. Karakteristični dijelovi EKG-a

Karakteristična struktura EKG zapisa jednog srčanog ciklusa se sastoji od P vala, QRS kompleksa i T vala. EKG zapis se sastoji od valova, kompleksa, segmenata i intervala koji predstavljaju promjenu napona u vremenu. Svaki valni oblik počinje i završava na osnovnoj liniji. Osnovna ili izoelektrična linija je zamišljena linija nestanka električne aktivnosti depolarizacije i repolarizacije srčanog ciklusa i predstavlja periode kad EKG elektrode ne otkrivaju električnu aktivnost. Dva ili više valna oblika zajedno se nazivaju kompleks. Interval je vremenski period koji sadrži val i/ili kompleks povezan sa segmentom. Segment (spojnica) je vremenski interval koji ne sadrži valove niti komplekse nego je prikazan ravnom linijom. Valovi (defleksije) koji se nalaze iznad izoelektrične linije se smatraju pozitivnim, a svi oni koji se nalaze ispod se smatraju negativnim.

P val nastaje prilikom depolarizacije atrijske, odnosno kao posljedica provođenja električnih impulsa kroz atrijske. Normalan P val je pozitivan te se nalazi prije QRS kompleksa. On ne bi trebao trajati više od 0.1 sekunde, niti biti viši od 3 mm (amplituda od 0.25 do 0.3 mV).

PR interval započinje s početkom P vala i završava na početku Q vala. Predstavlja vrijeme od pojave depolarizacije atrijske do pojave depolarizacije ventrikula. Kod prikaza normalnog elektrokardiograma njeno trajanje iznosi od 0.12 do 0.2 sekunde. PR segment započinje sa krajnjom točkom P vala i završava s početkom Q vala. PR segment predstavlja vrijeme provođenja električnog impulsa od AV čvora do miokarda ventrikule. Trajanje PR segmenta iznosi između 0.02 i 0.1 sekunde.

QRS kompleks započinje i završava na osnovnoj liniji. Zapocinje s početkom Q vala i završava sa krajem S vala. Predstavlja depolarizaciju desne i lijeve ventrikule. Signal atrijske repolarizacije je također dio ovog odsječka, ali je prikriven mnogo većim ventrikularnim signalom (QRS kompleksom). Ako obje strane srca ne djeluju ispravno, veličina QRS kompleksa se može povećati. Svaki pozitivni val QRS kompleksa je R zubac. Ako postoje dva R zupca drugi se obilježava sa R'. R zubac koji je niži od uobičajenog obilježava se sa r. Postoji slučaj kada je cijeli ventrikularni kompleks negativan odnosno R zubac uopće ne postoji, tada se kompleks naziva QS. Visina amplitude normalnog QRS kompleksa iznosi između 5 i 30 mm (0.5-3 mV), a trajanja je između 0.06 i 0.1 sekunde.


ST segment započinje sa završetkom QRS kompleksa (točnije u točki J) i završava sa početkom T vala. U periodu vremena koji predstavlja obje su klijetke depolarizirane i tada nema električnih oscilacija te je zato ST segment u osnovnoj liniji. Trajanje ST segmenta je između 0.08 i 0.12 sekundi.

T val nastaje kao rezultat repolarizacije ventrikula i dužeg je trajanje nego QRS kompleks, jer ventrikularna repolarizacija se događa sporije od depolarizacije. Normalni T val ima pozitivno odstupanje od oko 0.5 mV, a trajanje T vala obično iznosi 0.2 sekunde ili manje.

QT interval počinje na početku Q vala i završava u krajnjoj točki T vala, a predstavlja vremenski period od početka ventrikularne depolarizacije do kraja ventrikularne repolarizacije. Normalni QT interval je trajanja oko 0.4 sekunde, a oscilira kod muškarca i žena te sa porastom godina.

Kao opće pravilo, QT interval bi trebao činiti oko 40 posto izmjerenog R-R intervala.

RR interval se mjeri od vrha R zupca do sljedećeg R zupca. Predstavlja vrijeme između dvije uzastopne depolarizacije, a trajanja je između 0.6 i 1.2 sekunde.



Slika 2.9. : Karakteristični dijelovi EKG signala

3. Umjetne neuronske mreže

3.1. Povijest umjetnih neuronskih mreža

Zanimanje za umjetne neuronske mreže pojavilo se još 40-ih godina prošlog stoljeća. Godine 1943. neurofiziolog Warren McCulloch i matematičar Walter Pitts objavili su članak o mogućem načinu rada neurona. Kako bi objasnili na koji način neuroni u mozgu rade, modelirali su jednostavnu neuronsku mrežu pomoću električnih krugova. Ovaj dvojac u svome radu također ukazuje na činjenicu da aktivnost neurona ovisi o određenom pragu vrijednosti (engl. threshold), a sami neuroni mogu biti u stanju pobude ili mirovanja. Važnost njihovog rada tada još nije bila prepoznata jer je to bio period u kojem se računalna tehnologija tek počinjala razvijati.

Donald Olding Hebb je 1949. godine objavio knjigu "Organizacija ponašanja" u kojoj iznosi zakon o sinaptičkom neuronskom učenju. Ovaj zakon, kasnije poznat kao Hebbovo učenje, jedno je od najjednostavnijih pravila za učenje umjetnih neuronskih mreža. Kako su 50-ih godina prošlog stoljeća računala postala naprednija, konačno je bilo moguće simulirati zamišljenu neuronsku mrežu. Prvi korak prema tome učinio je Nathaniel Rochester iz IBM istraživačkih laboratorija. Iako prvi pokušaj da to učini nije uspio, kasniji pokušaji su se pokazali uspješnijim. Tijekom konferencije u Dartmouthu 1956. godine N. Rochester je zajedno sa grupom autora predstavio prvu simulaciju Hebbovog modela koji predstavlja preteču modela neuronskih mreža.

Godinu dana nakon smrti Johna von Neumann, 1958. godine, posthumno je objavljena knjiga "Računalo i mozak". U toj knjizi von Neumann predlaže mnoge radikalne promjene načina modeliranja mozga koje su znanstvenici do tada koristili. Na Sveučilištu Cornell 1958. godine Frank Rosenblatt je razvio neuronsku mrežu poznatiju kao perceptron. Perceptron je linearni sustav koji je koristan za rješavanje problema gdje su ulazni razredi linearno razdvojivi u ulaznom prostoru. Bernard Widrow i Marcian Hoff sa Sveučilišta Stanford 1959. godine razvijaju modele pod nazivom "ADALINE" (Adaptive Linear Neuron ili kasnije Adaptive Linear Element) i "MADALINE" (Multiple Adaptive Linear Elements). Također razvijaju i odgovarajući zakon učenja nazvan Widrow-Hoff pravilo. MADALINE neuronska mreža je zapravo višeslojna ADALINE mreža i prva je neuronska mreža koja je primijenjena u stvarnom svijetu. Predstavlja adaptivni filter koji uklanja jeku na telefonskim linijama. Ova neuronska mreža još uvijek je u komercijalnoj uporabi.

Unatoč ranom uspjehu perceptrona i istraživanja vezanih uz umjetne neuronske mreže, mnogi znanstvenici su smatrali kako u tome svemu postoje određena ograničenja, odnosno kako je potencijal neuronskih mreža preveličan. Među njima su bili Marvin Minsky i Seymour Papert koji su u svojoj knjizi "Perceptrons" iz 1969. godine kao jedno od ograničenja istaknuli činjenicu da perceptron nije mogao klasificirati uzorke koji nisu linearno razdvojivi u ulaznom prostoru, a također kao nedostatak navode i to što računala tada nisu imala dovoljnu procesorsku moć da bi ostvarile učinkovitost koju je rad sa neuronskim mrežama zahtijevao. Nakon iznošenja ovih činjenica dolazi do stagnacije istraživanja vezanih uz umjetne neuronske mreže.


Ključni napredak veže se za 1974. godinu kada Paul Werbos razvija višeslojnu mrežu perceptrona, kao preteča Backpropagation mreže. Višeslojna perceptron mreža ispravlja ograničenja perceptrona uvođenjem učenja u skrivenom sloju. David Rumelhart, Geoffrey Hinton i Stephen Williams 1986. godine izdaju knjigu "Learning Internal Representation by Error Propagation" u kojoj su usavršili Backpropagation algoritam te dokazali njegov veliki potencijal. Backpropagation mreža omogućuje aproksimiranje velikog broja funkcija te rješavanje praktičnih problema. Nakon toga sve više raste zanimanje za neuronske mreže. Razvijen je velik broj algoritama za neuronske mreže, ali i dalje najveću primjenu do danas ima algoritam sa širenjem pogreške unazad (engl. Backpropagation algoritam).

3.2. Biološka i umjetna neuronska mreža

U današnje vrijeme pojam "neuronska mreža" ima dvostruko značenje. Obično se odnosi na biološke neuronske mreže sačinjene od bioloških neurona koji su međusobno povezani u središnji živčani sustav. Biološke neuronske mreže nadahnule su dizajn umjetnih neuronskih mreža. Sveobuhvatno razumijevanje bioloških neuronskih mreža nije potpuno, ali njihova osnovna funkcionalnost koja doprinosi sposobnosti učenja sustava, implementirana je u umjetnim neuronskim mrežama.

Prema [4], ljudski mozak je sačinjen od oko 10^{11} neurona. Postoji više od 100 vrsta neurona koji su na osnovu svoje funkcije raspodijeljeni prema točno određenom rasporedu. Svaki je neuron prosječno povezan s 10^4 drugih neurona. Unatoč velikom broju različitih vrsta neurona, na svakom neuronu možemo raspoznati određene funkcionalno specijalizirane dijelove. Na taj se način može izraditi i shema takozvanog idealiziranog neurona.

Prema [1], temeljni dio neurona jest tijelo neurona ili soma, koje sadržava jezgru. Iz tijela neurona izlaze izdanci neurona, i to jedan akson (neurit) i više dendrita. Akson započinje aksonskim brežuljkom (tu započinje živčani impuls), a glavna mu je uloga provedba živčanog impulsa i kontaktiranje s drugim neuronima. Dendriti sačinjavaju glavnu receptivnu površinu neurona za prihvaćanje impulsa iz drugih neurona. Na kraju, akson se grana u niz aksonskih završetaka (telodendrija) na čijim se krajevima nalaze presinaptički završetci, koji zajedno čine prijenosni ili transmisijski dio neurona. Kontakt sa sljedećim neuronom obavlja se putem sinapse. Sinapse su glavna mjesta interakcije između neurona, a vidljive su tek na razini elektronske mikroskopije. U tijelu neurona zbrajaju se ulazni signali iz susjednih neurona te ako ukupni zbroj nadilazi određeni prag (graničnu vrijednost), neuron "okida" i šalje akcijski potencijal preko aksonskog brežuljka duž aksona. Slika 3.1. prikazuje građu neurona.



Slika 3.1. : Građa neurona


Umjetne neuronske mreže nastaju kao pokušaj modeliranja sustava čije bi karakteristike bile slične najosnovnijim funkcijama ljudskog mozga. Iako većina računala ima mogućnost brže i preciznije obrade podataka, ljudski mozak ima sposobnost učenja iz iskustva, a to opet dovodi do činjenice da može donositi razumne odluke.

Kao što ljudski mozak ima mogućnost generalizirati stvari, tako umjetna neuronska mreža može učiti iz primjera i iskustva te na taj način izvesti različite nelinearne funkcije koje je teško matematički opisati. Umjetne neuronske mreže predstavljaju apstrakciju ljudskog mozga, pa je tako organizacija umjetnog neuronskog sustava vrlo slična onoj bioloških neurona. Iako postoje mnoge sličnosti, valja napomenuti kako sve funkcionalnosti bioloških neuronskih mreža nisu modelirane umjetnim neuronskim mrežama, a isto tako postoje i karakteristike umjetnih neuronskih mreža koje se ne podudaraju sa biološkim neuronskim mrežama.

Prema [4], neuronska mreža predstavlja skup međusobno povezanih jednostavnih procesnih elemenata ili umjetnih neurona, od kojih svaki ima svoju lokalnu memoriju u kojoj pamti podatke koje obrađuje. Osnovni element, umjetni neuron, je model koji se temelji na poznatom ponašanju bioloških neurona. Umjetne neuronske mreže također se mogu opisati kao paralelni distribuirani računalni modeli. Temeljne procesne jedinice, neuroni, su povezani sa težinskim koeficijentima koji se dinamički mijenjaju tijekom procesa učenja.

3.3. Model umjetnog neurona

Umjetni neuron je matematička funkcija zamišljena kao model bioloških neurona. Umjetni neuroni su osnovne jedinice u umjetnoj neuronskoj mreži. Umjetni neuron prima jedan ili više ulaza (predstavljaju dendrite) i zbraja ih kako bi proizveli izlaz (ili aktivaciju) (koji predstavlja akson). Ulazni signali se množe sa težinskim faktorima (koeficijentima) koji opisuju jačinu sinapse. Rezultati koji se dobiju množenjem se zbrajaju (zbrajalo predstavlja tijelo neurona), a zbroj se provodi kroz nelinearnu funkciju poznatu kao aktivacijska funkcija ili funkcija prijenosa. Ako je dobiveni zbroj iznad određenog praga, neuron generira izlazni signal. Funkcije prijenosa obično imaju sigmoidalni oblik, ali mogu imati oblik drugih nelinearnih funkcija, djelomično linearnih funkcija ili funkcija praga. Na slici 3.2. preuzetoj iz [4] prikazan je model umjetnog neurona.

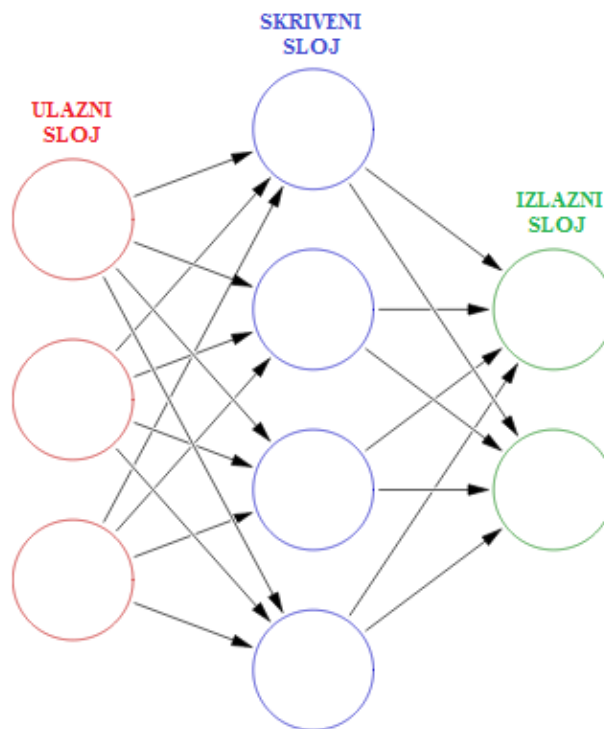


Slika 3.2. : Model umjetnog neurona

3.4. Model umjetne neuronske mreže

Umjetnu neuronsku mrežu sačinjavaju: arhitektura mreže (način povezivanja umjetnih neurona), aktivacijska funkcija te zakoni učenja.

Prema arhitekturi, umjetne neuronske mreže možemo razlikovati po broju slojeva. Uobičajeno svaki sloj prima ulaze iz prethodnog sloja dok svoje izlaze prosljeđuje daljnjem sloju. Prvi sloj se naziva još i ulazni, dok se zadnji naziva izlazni, slojevi između ulaznog i izlaznog sloja se obično nazivaju skriveni slojevi. Mreža sačinjena od tri sloja je jedna od najčešćih arhitektura umjetnih neuronskih mreža. Ulazni sloj je jedini sloj koji prima signale iz okoline. On također prosljeđuje signale sljedećem sloju (skriveni sloj) koji zatim izvršava obradu podatka i izdvaja značajke primljenih signala. Bitni podaci se prosljeđuju izlaznom sloju, posljednjem sloju mreže. Na izlazima posljednjeg sloja se dobivaju završni rezultati obrade. Kod složenijih neuronskih mreža moguć je i veći broj skrivenih slojeva, upotreba povratnih veza i elementa za odgađanje vremena, koji služe da omoguće što učinkovitije izdvajanje važnih značajki sa razine ulaznog sloja. Umjetna neuronska mreža predstavlja međusobno povezanu grupu čvorova, sličnu širokoj mreži neurona u mozgu. Na slici 3.3. svaki kružni čvor predstavlja umjetni neuron, a strelica predstavlja vezu od izlaza jednog neurona na ulaz drugog.



Slika 3.3. : Pojednostavljeni prikaz modela umjetne neuronske mreže

3.5. Prijenosne funkcije neurona


Funkcija prijenosa ili aktivacijska funkcija, kako se obično naziva, je funkcija koja se primjenjuje na težinsku sumu (zbroj umnožaka svih ulaznih signala i težinskih faktora) neurona da bi se dobio konačni izlaz.

Najjednostavnija funkcija dana je formulom:

$$f(\text{net}) = \text{net}$$

Vidljivo je kako je konačni izlaz jednak težinskoj sumi ulaza.


$$f(\text{net}) = \text{net}$$



Slika 3.4. : Linearna funkcija karakteristična za ADALINE model umjetnog neurona [4]

Funkcija praga (Heaviside funkcija) je još jedna jednostavna funkcija. Neuron s ovim tipom aktivacije naziva se McCulloch-Pitts model prema znanstvenicima koji ga prvi uvode i primjenjuju. Koristi se za modeliranje klasičnog "sve ili ništa" ponašanja.


$$f(\text{net}) = \begin{cases} 0 & \text{za } \text{net} < 0 \\ 1 & \text{inace} \end{cases}$$



Slika 3.5. : Funkcija praga [4]

Prijenosna funkcija također može biti linearno definirana po odsječcima, naziva se još i funkcija rampe. Funkcija rampe predstavlja kombinaciju funkcije praga i linearne funkcije.


$$f(\text{net}) = \begin{cases} 0 & \text{za } \text{net} \leq a \\ \text{net} & \text{za } a < \text{net} < b \\ 1 & \text{za } \text{net} \geq b \end{cases}$$



Slika 3.6. : Djelomično linearna prijenosna funkcija [4]

Sigmoidalna funkcija predstavlja najčešći oblik prijenosne funkcije neuronske mreže. Sigmoidalnu funkciju je moguće derivirati, što predstavlja vrlo važno svojstvo pri postupku učenja mreže.

$$f(\text{net}) = \frac{1}{1 + e^{-a \cdot \text{net}}}$$



Slika 3.7. : Sigmoidalna prijenosna funkcija [4]

Parametar a predstavlja parametar nagiba (strmine funkcije). Povećanjem strmine dolazi do smanjenja prostora linearnosti pa stoga treba bit pažljiv pri podešavanju parametra nagiba.

3.6. Podjele neuronskih mreža

Postoji velik broj podjela među umjetnim neuronskim mrežama. Najčešće podjele su prema: topologiji neuronske mreže, načinu učenja neuronske mreže, smjeru prostiranja informacija itd.

Podjela neuronskih mreža prema topologiji (arhitekturi) mreže

Osnovna podjela

- *acikličke*-ne sadrže povratne veze
- *cikličke*-sadrže povratne veze

Prema broju slojeva

- *jednoslojne*-sadrži izlazni sloj (ulazni sloj se ne računa jer nije procesni sloj)
- *višeslojne*-mreže koje sadrže jedan ili više skrivenih slojeva

Prema povezanosti

- *djelomično povezane*-svaki neuron u prvom sloju nije nužno povezan sa svakim neuronom u drugom sloju
- *potpuno povezane*-svaki neuron prethodnog sloja povezan je sa svakim neuronom sljedećeg sloja

Podjela prema učenju

Prema algoritmu učenja

- *Učenje korekcijom pogreške*
 - Backpropagation algoritam
 - Gauss-Newton algoritam
 - Levenberg-Marquardt algoritam
- *Hebbovo učenje*
- *Kompetitivno učenje*
- *Boltzmannovo učenje*
- *Thorndikeovo učenje*

Prema paradigmi učenja

- *Učenje pod nadzorom* (engl. supervised learning)-učenje s učiteljem
- *Učenje podrškom* (engl. reinforcement learning)-pokušaji i pogreške uz ocjenu suca
- *Učenje bez nadzora* (engl. unsupervised learning)-samoorganizirano učenje bez učitelja

Podjela prema smjeru prostiranja informacija

- *Feedforward* (nepovratne)-viši slojevi ne vraćaju informacije nižim slojevima. Signali se prostiru samo od ulaza prema izlazu mreže.
- *Feedback* (povratne)-viši slojevi vraćaju informacije nazad nižim slojevima. Izlaz se vraća u niže slojeve ili u isti sloj.

3.7.Rad neuronske mreže

Rad umjetne neuronske mreže možemo podijeliti u dvije glavne faze:

1. Faza učenja (treniranja) mreže
2. Faza testiranja mreže

Postoji mnogo različitih algoritama koji se mogu koristiti prilikom treninga umjetnih neuronskih mreža. Svaki od njih posjeduje određene prednosti, ali i poneke nedostatke.

Proces učenja unutar umjetnih neuronskih mreža rezultat je izmjena težina mreže, s određenim algoritmom učenja. Cilj je pronaći skup težinskih matrica koje bi prilikom primjene na mrežu, trebale povezati bilo koji ulaz na ispravan izlaz. Kroz ovo poglavlje najviše će se govoriti o učenju pod nadzorom. Ali svakako treba spomenuti sve tri glavne paradigme učenja.

Učenje pod nadzorom (engl. supervised learning)

Algoritam za učenje spada u ovu kategoriju ako je tijekom treninga mreže uz ulaze poznat i željeni izlaz. Pod pretpostavkom da su poznati ulazni i izlazni podaci neuronske mreže moguće je izračunati pogrešku na temelju ciljanog izlaza i stvarnog izlaza. Tu pogrešku moguće je upotrijebiti za ispravke mreže ažuriranjem težina.

Učenje bez nadzora (engl. unsupervised learning)

U ovoj paradigmi neuronskoj mreži je dan samo skup ulaza, te je odgovornost neuronske mreže da pronađe neku vrstu uzorka unutar unesenih ulaza bez ikakve vanjske pomoći. Ova vrsta paradigme učenja često se koristi pri rudarenju podataka, a upotrebljavaju je i mnogi algoritmi preporuka prilikom predviđanja preferencija korisnika na temelju preferencija drugih sličnih korisnika koje je grupirao zajedno.

Učenje podrškom (engl. reinforcement learning)


Učenje podrškom slično je nadziranom učenju u kojem se daju neke povratne informacije, no umjesto pružanja ciljanog izlaza daje se nagrada na temelju uspješnosti izvedbe sustava. Cilj učenja podrškom je da se pomoću metode pokušaja i pogrešaka maksimizira nagrada koju sustav prima. Ta se paradigma snažno odnosi na to kako učenje djeluje u prirodi, primjerice, životinja se sjeća radnji koje je prethodno poduzela kako bi pronašla hranu (nagradu).

Kao što je ranije spomenuto, učenje pod nadzorom je tehnika koja koristi skup ulaznih i izlaznih podataka za treniranje mreže. Ideja je osigurati mrežu sa ulaznim i izlaznim podacima, a onda joj dozvoliti da pronađe funkciju koja će točno povezati te podatke sa točnim izlazima.

Ako je mreža trenirana s dobrim rasponom podataka za trening, te ako je završila učenje, ona bi trebala dati ispravne izlaze za bilo koje nove (u treningu nekorisćene) ulaze. Podaci koji se koriste pri radu neuronske mreže najčešće se dijele u tri skupa, a to su: skup za učenje, skup za testiranje i skup za validaciju (provjeru). U kojem omjeru treba podijeliti ove podatke nigdje nije točno naznačeno, ali preporučeno je da se ipak najveći dio podataka odvoji za trening mreže.

Podešavanje težinskih faktora u mreži karakteristično je za fazu učenje te se odvija u više iteracija (prolaza kroz mrežu). Pojmovi iteracije i epohe blisko se vežu uz pojam učenja mreže. Iteracija tako predstavlja jedan korak u algoritmu postupka za učenje pri kojem se računaju nove težine, a epoha jedno predstavljanje cjelokupnog skupa za učenje. Prema broju primjera pokazanih mreži za vrijeme jedne iteracije učenje može biti pojedinačno (engl. online training) ili grupno (engl. batch training) [4]. Za mrežu je uobičajeno da se trenira u nekoliko tisuća iteracija.

Svakako treba paziti da ne dođe do slučaja da se mreža "pretrenira". Nakon određenog broja iteracija mreža može izgubiti svojstvo da dobro klasificira nepoznate ulaze. Ona tada i dalje dobro obrađuje podatke iz skupa za trening mreže, ali loše obrađuje sve ostale podatke. Tada je potrebno otkriti iteraciju u kojoj će izlaz najmanje odstupati od željenog odziva (slika 3.8 preuzeta iz [4]). To se postiže konstantnim praćenjem izlaza dobivenog iz podataka za testiranje. Na kraju se koristi skup za provjeru (validaciju) kako bi se provjerila točnost i preciznost obrade podataka.



Slika 3.8. : Odstupanje stvarnog izlaza kroz iteracije

Testiranje mreže kao druga glavna faza rada mreže ima važnu ulogu u ocjenjivanju mreže. U fazi testiranja mreža više ne uči odnosno nema više podešavanja težinskih faktora. Mreži se dovode novi ulazni vektori koji nisu korišteni u fazi treninga te se od nje očekuje da za svaki novi ulaz proizvede izlaz. Mreža se ocjenjuje izračunavanjem greške i to način da se usporedi dobiveni izlaz sa željenim izlazom.

3.8. Levenberg-Marquardt algoritam učenja

Postupak koji se koristi za provođenje procesa učenja u neuronskoj mreži naziva se algoritam učenja. Postoji mnogo različitih algoritama učenja s različitim karakteristikama i performansama, a onaj koji će se kroz ovo poglavlje detaljnije razmatrati je Levenberg-Marquardt algoritam učenja. Upravo ovaj algoritam će biti upotrijebljen prilikom učenja naše neuronske mreže.

Algoritam Levenberg-Marquardt, poznat i kao metoda prigušenih najmanjih kvadrata, osmišljen je tako da radi specifično s funkcijama gubitaka koje imaju oblik zbroja kvadratnih pogrešaka. Radi bez računanja točne Hessianove matrice. Umjesto toga, radi sa gradijentnim vektorom i Jacobijevom matricom.

Funkcija gubitka se može izraziti kao zbroj kvadratnih pogrešaka:

$$f = \sum e_i^2, \quad i=0, \dots, m \quad (3.1)$$

Gdje je m je broj primjeraka u skupu podataka.

Jacobijeva matrica funkcije gubitka se može definirati kao ona koja sadrži derivacije pogrešaka s obzirom na parametre,

$$J_{i,j} f(w) = de_i/dw_j \quad (i = 1, \dots, m \ \& \ j = 1, \dots, n) \quad (3.2)$$

gdje m predstavlja broj primjeraka u skupu podataka, a n broj parametara u neuronskoj mreži. Veličina Jacobijeve matrice je $m \cdot n$.

Gradijentni vektor funkcije gubitka može se izračunati kao:

$$\nabla f = 2 J^T \cdot e \quad (3.3)$$

Gdje e predstavlja vektor svih pogrešaka mreže.

Hessianova matrica se približno može opisati sa sljedećim izrazom.

$$Hf \approx 2 J^T \cdot J + \lambda I \quad (3.4)$$

Gdje je λ faktor prigušivanja koji osigurava pozitivnost Hessianove matrice, a I je matrica identiteta.

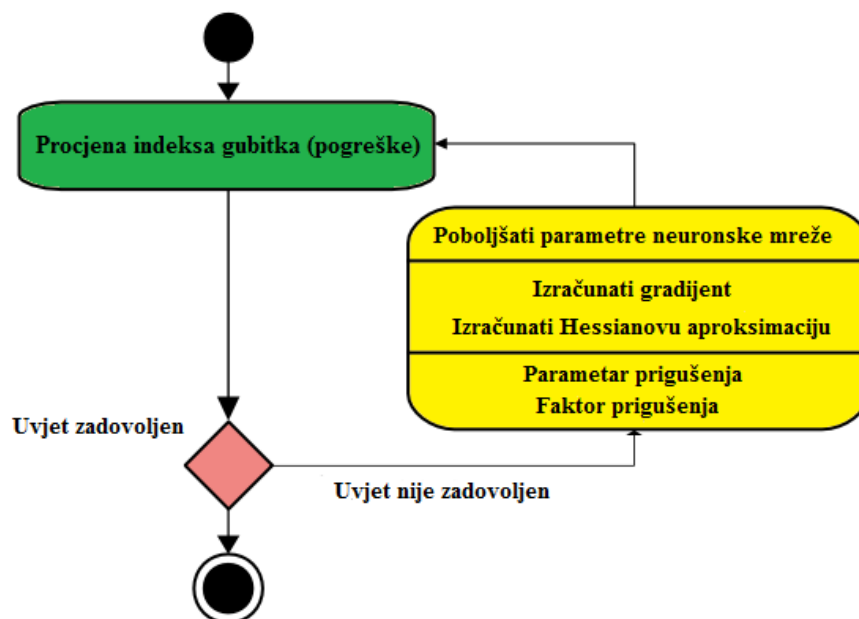
Sljedeći izraz definira proces poboljšanja parametara pomoću Levenberg-Marquardt algoritma.

$$w_{i+1} = w_i - (J_i^T \cdot J_i + \lambda_i I)^{-1} \cdot (2 J_i^T \cdot e_i), \quad i=0,1,\dots \quad (3.5)$$

Kada je parametar prigušivanja λ jednak nuli, to je samo Newtonova metoda, koja koristi približnu Hessianovu matricu. S druge strane, kada je λ velik, to postaje gradijentni spust (najbrži spust) s malom stopom učenja.

Parametar λ je inicijaliziran da bude velik, pa su tako prva ažuriranja mali koraci u smjeru gradijentnog spusta. Ako se dogodi bilo kakva iteracija koja uzrokuje neuspjeh, tada se λ povećava za neki faktor. Inače, kada se gubitak smanjuje, smanjuje se i λ , tako da se Levenberg-Marquardtov algoritam izjednačava sa Newton metodom. Ovaj proces obično ubrzava konvergenciju prema minimumu.


Slika 3.9. predstavlja dijagram stanja za proces učenja neuronske mreže s Levenberg-Marquardtovim algoritmom. Prvi korak je izračunati gubitak, gradijent i Hessianovu aproksimaciju. Zatim se parametar prigušivanja podešava na način da se smanji gubitak na svakoj iteraciji.



Slika 3.9. : Dijagram stanja za proces učenja neuronske mreže s Levenberg-Marquardtovim algoritmom

Levenberg-Marquardtov algoritam je metoda prilagođena funkcijama tipa zbroja kvadratnih pogrešaka. To ga čini vrlo brzim kada se trening neuronske mreže mjeri na takvim pogreškama. Međutim, ovaj algoritam ima i neke nedostatke. Prva je da se ne može primijeniti na funkcije kao što su korijenska srednja kvadratna pogreška ili križna entropijska pogreška. Također, nije kompatibilan u uvjetima regulacije. Za vrlo velike skupove podataka, Jacobijeva matrica postaje ogromna, pa stoga zahtijeva puno memorije. Stoga se Levenberg-Marquardtov algoritam ne preporučuje kada imamo velike skupove podataka.

Slika 3.10 predstavlja graf koji prikazuje odnos brzine i memorije za neke od najčešćih algoritama učenja mreže. Kao što možemo vidjeti, najsporiji algoritam učenja je gradijentni spust, ali isto tako on zahtijeva manje memorije. Za razliku od njega najbrži na prikazu je Levenberg-Marquardt algoritam, ali obično zahtijeva puno veću memoriju. Dobar kompromis među njima može biti kvazi-Newton metoda.



Slika 3.10. : Brzina i zahtijevana memorija algoritama učenja

Na kraju se može zaključiti, da za velike skupove podataka je najbolje koristiti gradijent spusta ili konjugirani gradijent, kako bi se uštedila memorija. Ako je slučaj da je potrebno istrenirati mnogo neuronskih mreža sa samo nekoliko tisuća slučajeva i nekoliko stotina parametara, najbolji bi izbor mogao biti Levenberg-Marquardt algoritam. U ostalim situacija, dobro će raditi i kvazi-Newton metoda.

3.9.Područja primjene umjetnih neuronskih mreža

Umjetne neuronske mreže se danas koriste u raznim područjima rada poput elektrotehnike, ekonomije, medicine, obrazovanja itd.

Neki od primjera primjene su:

- optičko prepoznavanje znakova
- raspoznavanje govora
- pretvaranje teksta u govor
- prepoznavanje oblika
- prepoznavanje rukopisa
- upravljanje sustavima
- primjena u financijskim modelima
- predviđanje kretanja cijena dionica
- predviđanje vremenske prognoze
- ispitivanje biomedicinskih signala
- naftna istraživanja

4. Algoritmi za QRS detekciju

4.1. Postojeći pristupi za analizu EKG signala

Prvi radovi iz područja analize EKG signala objavljeni su još prije pedesetak godina. Krajem 60-ih godina predstavljen je jedan od prvih algoritama za obradu EKG-a. Algoritam je bio uključen u AZTEC programu te je testiran 1974. godine. U tadašnje vrijeme još nisu bile dostupne standardizirane baze za testiranje, pa je testiranje odrađeno kao dio studije provedene na određenom broju pacijenata. Detekcija QRS kompleksa za ovaj algoritam iznosila je čak 99%. Nedostatak ovog algoritma je bio da u slučaju detekcije većeg šuma, detekcija QRS kompleksa nije bila moguća.

Pri samom pogledu na prikaz EKG signala ističe se najviši dio signala, koji se još naziva R zubac. On zajedno sa dva lokalna minimuma koji se nalaze lijevo i desno od njega čini QRS kompleks. QRS kompleks predstavlja najvažniji valni oblik u okviru EKG signala. Kada se pojavljuje te kako izgleda vrlo je važno, jer upravo iz tih podataka možemo puno saznati o trenutnom radu srca. QRS kompleks predstavlja jedan otkucaj srca, a njegova točna detekcija je osnova za analizu ritma rada srca (HRV - engl. heart rate variability analysis).

Detekcija QRS kompleksa nije sasvim jednostavna jer postoje određene stvari koje otežavaju taj postupak. Jedan od problema je što ponekad P i T val mogu imati karakteristike slične QRS kompleksu. Postoje i problemi koji nastaju kao posljedica pri samom snimanju signala, a to su: šum (50/60 Hz) kojeg uzrokuju smetnje mrežnog napajanja, kontaktni šum elektroda, šum nastao zbog mišićne aktivnosti, pomak elektroda, kretnje pacijenta, pomak bazne linije.


Kako QRS detekcija predstavlja glavnu metodu u analizi EKG signala posljednjih nekoliko desetljeća, tako je razvijen i velik broj QRS detektor algoritama. Na osnovu određenih kriterija postoji više podjela, pa tako se mogu razlikovati:

- *hardverski* (analogni) i *softverski* (digitalni)
- *online* (real-time) i *offline* (rade sa snimljenim signalima iz baze)
- *neadaptivni* (filteri, derivacije...) i *adaptivni* (neuronske mreže, matched filteri, adaptivni pragovi...)
- *netransformirajući* (rade sa originalnim signalom) i *transformirajući* (rade na transformiranom signalu, upotreba Wavelet ili Fourierove transformacije)

U određenim literaturama često se spominje i ova podjela:

- metode temeljene na diskretnim derivacijama
- metode temeljene na digitalnom filtriranju
- metode koje se temelje na wavelet prikazu EKG signala
- metode temeljene na neuronskim mrežama
- metode temeljene na adaptivnom filtriranju
- metode temeljene na genetskim algoritmima

Kada se govori o strukturi QRS detektora, ona se može podijeliti u dvije faze: faza predobrade i faza odlučivanja. Faza predobrade obuhvaća linearno i nelinearno filtriranje dok faza odlučivanja sadrži logiku za detekciju te logiku za odlučivanje. Na slici 4.1. dan je prikaz uobičajene strukture QRS detektora.



Slika 4.1. : Uobičajena struktura QRS detektora

4.2. Ocjenjivanje algoritama detekcije QRS kompleksa

Prema ANSI/AAMI EC57 standardu pri ocjenjivanju uspješnosti algoritma za detekciju QRS kompleksa (QRS detektora) koriste se sljedeće relacije:

$$Se(\%) = 1 - \frac{FN}{TP + FN} = \frac{TP}{TP + FN} * 100\% \quad (4.1)$$

$$+P(\%) = 1 - \frac{FP}{TP + FP} = \frac{TP}{TP + FP} * 100\% \quad (4.2)$$

Gdje Se predstavlja osjetljivost algoritma, a $+P$ pozitivnu preciznost algoritma. Oznaka FN (engl. False Negative) označava broj R zubaca koji nisu detektirani (koji su propušteni), zatim oznaka FP (engl. False Positive) označava broj krivo detektiranih R zubaca, a oznaka TP (engl. True Positive) označava broj uspješno detektiranih R zubaca. Iz spomenutih izraza također se može izračunati i omjer šansi pogreške (DER) i općenita točnost algoritma (Acc).

$$DER = \frac{FP + FN}{TP + FP + FN} * 100\% \quad (4.3)$$

$$Acc = \frac{TP}{TP + FP + FN} * 100\% \quad (4.4)$$

Treba svakako znati da usporedba rezultata različitih detektor algoritama ima smisla samo ako je detekcija provedena na uzorcima iz standardne EKG baze. Najčešće korištena baza podataka je MIT-BIH Arrhythmia Database. Web mjesto gdje se nalaze javnosti dostupne baze naziva se Physionet. Rezultati detekcije se mogu podijeliti u tri grupe: pouzdane (detekcija vršena na cjelokupnoj standardnoj EKG bazi), manje pouzdane (detekcija vršena na dijelu standardne baze) i nedovoljno pouzdane (detekcija vršena na nestandardnoj bazi).

4.3. MIT-BIH Arrhythmia Database

Od 1975. godine, laboratoriji u bostonskoj bolnici Beth Israel Hospital i na MIT-u (Massachusetts Institute of Technology) su provodili istraživanja o analizi aritmije i povezanim temama. Jedan od prvih rezultata tog istraživanja bila je MIT-BIH baza podataka, koja je objavljena 1980. godine. Baza podataka bila je prvi javno dostupan skup standardnih test materijala za procjenu detektora aritmija te je korištena i za ostala kardiološka istraživanja. U kolovozu 1989. izrađena je CD-ROM verzija baze podataka.

Baza podataka sadrži 48 polusatnih isječaka bolničkih EKG snimaka sa pretežno dva odvoda, dobivenih od 47 ispitanika (muškaraca i žena) različite starosti. Slučajnim odabirom iz skupa od 4000 24-satnih EKG snimaka odabrane su 23 snimke. Preostalih 25 snimki odabrano je iz istog skupa, ali se gledalo da sadrže klinički značajne aritmije. Snimke su digitalizirane na 360 uzoraka po sekundi po kanalu s 11-bitnom rezolucijom preko 10 mV raspona. Svaki snimak je ocijenjen nezavisno od strane dva ili više kardiologa.

4.4.PhysioNet

PhysioNet nastaje 1999. godine kao zajednički projekt koji je pokrenula raznolika skupina računalnih znanstvenika, fizičara, matematičara, biomedicinskih istraživača, liječnika i predavača sa Beth Israel Deaconess Medical Center, Sveučilišta u Bostonu, Sveučilišta McGill i MIT-a. Glavni cilj ovog projekta je poticanje postojećih i novih istraživanja na području biomedicinskih i fizioloških signala. Na web stranici PhysioNet dostupna je velika i rastuća baza signala koji se koriste u biomedicinskim istraživanjima (PhysioBank), zatim baza programskih alata koji se koriste pri obradi signala (PhysioToolkit), te virtualni laboratorij za unaprjeđenje baza (PhysioNetWorks).

MIT zapise koje možemo pronaći na web stranici PhysioNet-a čine tri datoteke:

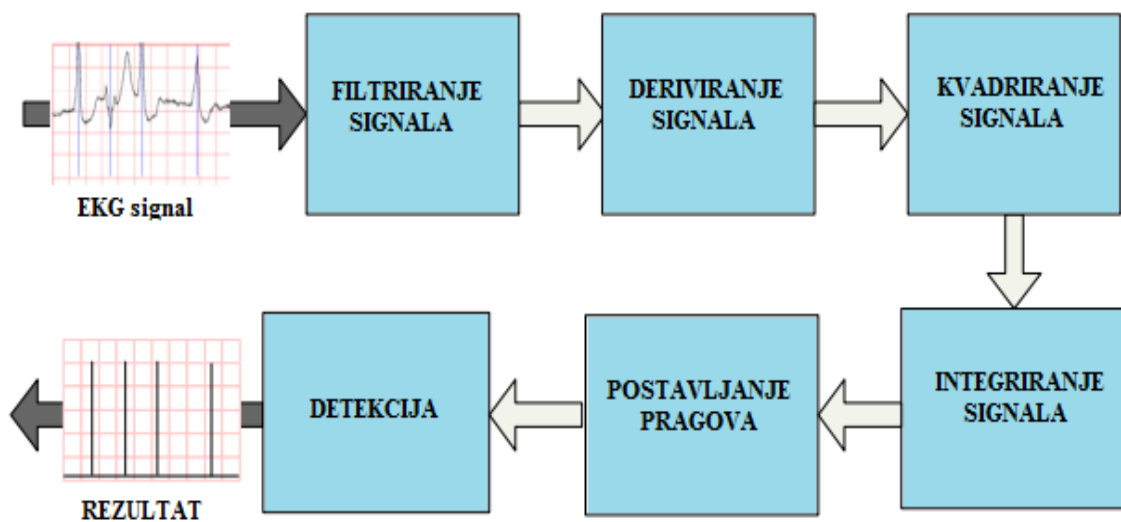
- MIT podatkovne datoteke (.dat) su binarne datoteke koje sadrže uzorke digitaliziranih signala
- MIT datoteke zaglavlja (.hea), kratke su tekstne datoteke koje opisuju sadržaj povezanih datoteka
- MIT zapisničke datoteke (.atr) su binarne datoteke koje sadrže napomene koje se općenito odnose na određene uzorke u pridruženim podatkovnim datotekama

4.5.Uklanjanje šumova i smetnji

Kao što je ranije i spomenuto, predobrada podataka predstavlja važan čimbenik kod detekcije QRS kompleksa. Veoma važan dio predobrade podataka je filtriranje signala. Ono se vrši kako bi se uklonile smetnje i šumovi nastali prilikom samog snimanja. Svakako treba krenuti od činjenice da većina šumova ima periodički karakter (ponavljaju se u određenim vremenskim razmacima) što u velikoj mjeri olakšava njihovo uklanjanje. To se vrši uz pomoć frekvencijskih filtra uz uvjet da je frekvencija šuma poznata. Postoje tako filtri koji će propustiti samo niske frekvencije (nisko-propusni), zatim filtri koji će propustiti samo visoke frekvencije (visoko-propusni), te filtri koji će propustiti samo određeni frekvencijski pojas (pojasno-propusni). Poznati su i oni koji neće propustiti ciljanu frekvenciju (pojasne brane). Za uklanjanje šuma osim metoda koje se temelje na propusnim filtrima, postoje i metode temeljene na wavelet transformacijama, Fourierovim transformacijama itd. Uklanjanje pomaka bazne linije najčešće se rješava pomoću medijan filtra.


4.6. Pan-Tompkinsov algoritam detekcije

QRS detekcijski algoritam predstavljen davne 1985. godine od strane Jiapu Pana i Willis J. Tompkinsa je najčešće korišten i često citirani algoritam za ekstrakciju QRS kompleksa iz elektrokardiograma. Algoritam se temelji na obradi širine, nagiba i amplitude pojedinih dijelova EKG signala. Algoritam možemo svrstati u grupu adaptivnih algoritama jer logika za detekciju sadrži pragove koji se mijenjaju ovisno o signalu koji se obrađuje. Prvi korak je da se EKG signal propušta kroz nisko-propusni i visoko-propusni filter radi uklanjanja šumova. Nakon toga filtrirani signal prolazi kroz faze derivacije, kvadriranja i faze prozorske integracije. Na samome kraju se primjenjuje tehnika određivanja praga i detektiraju se R-zupci.




Slika 4.2. : Prikaz koraka Pan-Tompkins algoritma

Kako bi se smanjio utjecaj šumova koji su nastali zbog mišićne aktivnosti, mrežnog napajanja (50/60 Hz), te smetnje uzrokovane T valom koristi se kaskadna veza nisko-propusnog i visoko-propusnog filtra.




Slika 4.3. : EKG signal nakon filtriranja [5]

Sljedeća faza je faza derivacije, koja predstavlja standardnu tehniku za pronalaženje visokih nagiba po kojima se QRS kompleks razlikuje od drugih dijelova EKG-a. Postupkom deriviranja potiskuju se nisko frekvencijske komponente P i T valova, te pojačavaju visokofrekventne komponente koje proizlaze iz visokih nagiba QRS kompleksa.




Slika 4.4. : EKG signal nakon deriviranja [5]

Kvadriranjem EKG signala dobiva se pozitivan rezultat (svi podaci postaju pozitivni) te se naglašavaju velike razlike koje proizlaze iz QRS kompleksa. Visokofrekventne komponente signala koje su vezane uz QRS kompleks dodatno su izražene dok su komponente vezane uz P i T valove suzbijene.



Slika 4.5. : EKG signal nakon kvadriranja [5]

Nakon kvadriranja signal prolazi fazu prozorske integracije. Integracija se izvodi uz pomoć sume pomaknutih prozorskih funkcija. Bitnu stavku predstavlja odabir broja uzoraka koji ovisi o širini prozorske funkcije. Širina se bira na način da bude otprilike jednaka kao i najširi mogući QRS kompleks. Treba paziti i da ne dolazi do preklapanja QRS kompleksa i T vala, a to je moguće ako je širina preširoka. Također treba paziti i da ne bude preuska jer to dovodi do pojave izraženih vrhova što može uzrokovati poteškoće u kasnijim koracima detekcije.




Slika 4.6. : EKG signal nakon prozorske integracije [5]

U zadnjoj fazi procesa postavljaju se dva praga. Viši od dva praga detektira vrhove signala. Niži prag se koristi kada u određenom vremenskom intervalu nije detektiran vrh od strane višeg praga. U tom slučaju algoritam mora provesti fazu traženja unatrag (engl. search back) za propušteni vrh. Kada je novi vrh pronađen (lokalni maksimum - promjena smjera unutar unaprijed definiranog vremenskog intervala), onda se taj vrh klasificira kao vrh signala ako premašuje visoki prag (ili niski prag ako se radi o propuštenom vrhu) ili u suprotnome slučaju kao šum.

Kako bi se povećala pouzdanost detekcije QRS kompleksa, metoda se provodi na dva signala te se koriste različite vrijednosti za gore navedene pragove. Detekcija se provodi na filtriranom signalu i signalu proizašlom nakon prozorske integracije. Da bi se detektirao kao QRS kompleks, vrh mora biti prepoznat kao QRS na oba signala.

Na slici 4.7. preuzetoj iz [6] prikazan je uzorak EKG signala kroz sve faze algoritma. Tako uzorak označen na slici sa slovom (a) predstavlja originalni signal. Signal nakon filtracije je označen slovom (b), nakon deriviranja slovom (c), nakon kvadriranja slovom (d), a nakon prozorske integracije slovom (e). Slovom (f) označen je završni izlaz nakon detekcije.



Slika 4.7. : Uzorak EKG signala kroz sve faze algoritma

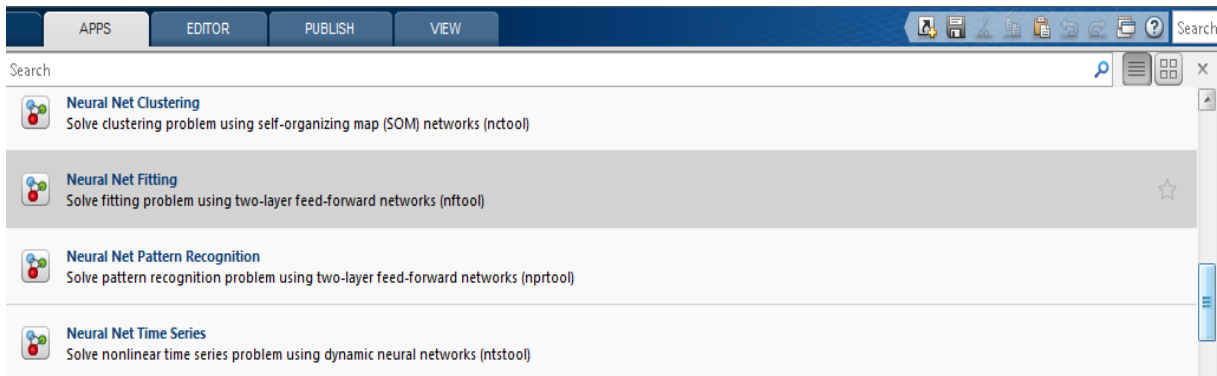
4.7.Ostale metode detekcije

U različitim literaturama opisan je i velik broj ostalih metoda za detekciju QRS kompleksa koje bilježe visoku točnost. Detaljnije je u prethodnom dijelu obrađen Pan-Tompkinsov algoritam dok će u idućem poglavlju detaljnije biti obrađena detekcija pomoću umjetnih neuronskih mreža. Od ostalih metoda uz ranije navedene svakako treba spomenuti metode koje se baziraju na transformacijama (valićne, Hilbertove, kombinacija prethodne dvije...), zatim koje se baziraju na derivacijama signala (Balda, Menard...) u koje spada i gore spomenuti Pan-Tompkins algoritam, metode bazirane na digitalnom filtriranju (Okada), generičke algoritme, stroj s potpornim vektorima (engl. Support Vector Machines), skrivene Markovljeve modele itd.

5. Analiza i pronalaženje ključnih točaka EKG signala uz pomoć umjetnih neuronskih mreža

5.1. Programski paket za izradu detektora

Za izradu programa za detekciju korišten je programski paket MATLAB. MATLAB (skraćeno od MATRIX LABORATORY) je programski paket posebno dizajniran za brze i jednostavne znanstvene izračune. Sadrži velik broj ugrađenih funkcija za širok raspon računanja i mnoge alate dizajnirane za određene istraživačke discipline, uključujući statistiku, optimizaciju, rješenja za parcijalne diferencijalne jednačbe, analizu podataka itd. Jedan od MATLAB-ovih alata korišten je u praktičnom dijelu ovog rada, a naziva se Neural Network Toolbox. Taj alat ima ulogu simulacije rada umjetnih neuronskih mreža i integracije sa ostalim funkcijama MATLAB-a. U osnovi se bazira na nizu gotovih funkcija za kreiranje, trening i testiranje umjetnih neuronskih mreža. MATLAB pruža mogućnost da se izabere jedan od već definiranih modela neuronske mreže. Među njima se nalazi i model Neural Net Fitting korišten u praktičnom dijelu rada. Ovaj model je pogodan za mreže sa jednim izlaznim parametrom te je zbog toga često korišten. Koristi se za pronalaženje relacija između ulaznih podataka i željenih izlaza pomoću "feed-forward" dvoslojne neuronske mreže. Na slici 5.1. mogu se vidjeti i ostali ponuđeni specijalizirani modeli.

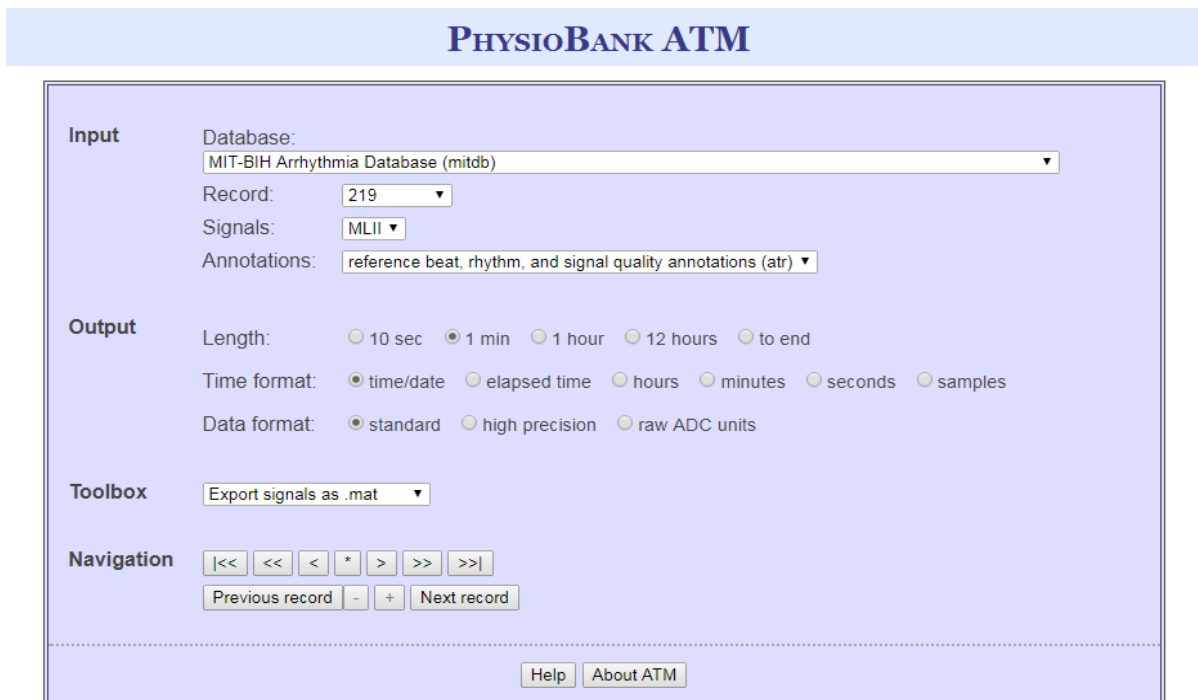


Slika 5.1. : Izbor definiranih modela neuronske mreže

5.2. Učitavanje signala iz MIT-BIH Arrhythmia baze u MATLAB

Na stranicama PhysioNet-a ili točnije putem PhysioBank ATM-a, moguće je preuzeti podatke s kojima je lakše raditi u MATLAB-u. Za početak je potrebno odabrati bazu podataka kroz padajući izbornik, a u ovom slučaju to je *MIT-BIH Arrhythmia Database (mitdb)*.

Nakon toga u padajućem izborniku koji se nalazi uz naziv *Record* odabire se željeni broj signala (postoji 48 zapisa). Zatim u izborniku koji stoji uz naziv *Signals* odabire se MLII (ML2) odvod jer je pogodan za detekciju QRS kompleksa. U radu su korišteni zapisi koji traju jednu minutu, pa je pri izboru potrebno odabrati jednominutne snimke. U padajućem izborniku koji se nalazi uz naziv *Toolbox* potrebno je odabrati opciju *Export signals as .mat*. Na slici 5.2. dan je prikaz na kojem se vidi na koji način je potrebno preuzeti zapis broj 219.



Slika 5.2. : Preuzimanje zapisa broj 219

Nakon što su sve stavke odabrane prema uputama, potrebno je preuzeti dvije datoteke koje će se pojaviti ispod izbornika (*BROJZAPISAm.mat* i *BROJZAPISAm.info*). Preporuča se i preuzimanje datoteke koja se nalazi ispod njih, a to je *plotATM.m*. Funkcija *plotATM.m* se koristi za čitanje gore navedenih datoteke, korekciju bazne linije, skaliranje te prikaz signala. Signal je pohranjen u matricu naziva *val* (u našem slučaju matrica dimenzija 1 x 21600). Dijelovi funkcije *plotATM.m* korišteni su i u praktičnom dijelu ovog rada.

5.3. Izvedba detekcije

Izvedba programa za detekciju sadržana je u glavnoj skripti *DetekcijaQRS.m*. Program se koristi za treniranje umjetne neuronske mreže koja ima ulogu prepoznavanja odnosno detekcije QRS kompleksa u EKG signalu. Za početak se EKG signal učitava u MATLAB radni prostor,

koriste se zapisi preuzeti iz MIT-BIH Arrhythmia baze. Način preuzimanja zapisa opisan je u prethodnom poglavlju. Naziv datoteke moguće je promijeniti kako bi se mogli učitati različiti EKG zapisi. Na slici 5.3. prikazan je dio koda gdje se upisuje broj zapisa (naziv datoteke) na kojem će biti odrađen trening ili kasnije pri testiranju izvršena detekcija.

```
%% Ucitivanje EKG signala


% MIT-BIH arrhythmia database snimak (mozemo izabrati bilo koji dostupan snimak)
% Koristimo samo ML2 (Modified Lead 2) podatke koji su pogodni za detekciju
% QRS kompleksa
Name = '219m'; % ili bilo koji drugi pohranjeni signal

% Koristimo konvertirane podatke sa physionet.org/atm
iName = strcat(Name, '.info');
mName = strcat(Name, '.mat');

% Ucitavanje podataka
load(mName);
```

Slika 5.3. : Odabir zapisa za učitavanje

Nakon što se odabere EKG snimka i pokrene program, pojavljuje se prozor u kojem se nalazi prikaz intervala koji sadrži QRS kompleks. Od korisnika se traži da mišem označi početnu i krajnju točku QRS kompleksa na prikazu. To je omogućeno uporabom naredbe *ginput*. Na slici 5.4. prikazan je prozor u kojem korisnik označava početak i kraj QRS kompleksa.



Slika 5.4. : Označavanje početka i kraja QRS kompleksa

Nakon što korisnik odabere početnu i krajnju točku QRS kompleksa, kompleks se ekstrahira iz EKG signala i pohranjuje za kasniju upotrebu. Dužina QRS kompleksa se također pohranjuje jer se pri pretraživanju cijelog signala koriste uzorci signala koji su jednake dužine kao i QRS kompleks.

Kada je ekstrakcija QRS kompleksa odrađena, vrše se procesi važni za trening mreže, a to su ekstrakcija značajki i određivanje željenih vrijednosti izlaza. Spomenuti procesi detaljnije su obrađeni u poglavljima koja slijede. Nakon što je umjetna neuronska mreža istrenirana primjenjuje se za pronalaženje QRS kompleksa.

5.4. Ekstrakcija značajki

Kako bi se smanjila veličina neuronske mreže, za ulazne podatke neuronske mreže koriste se ekstrahirane značajke. To se postiže funkcijom *ExtractFeatures* čiji su ulazi EKG signal za koji želimo ekstrahirati značajke (matrica *val*), broj koraka potrebnih da se pređe cijeli signal (*TotalSteps*), veličina koraka (*StepSize*), dužina QRS kompleksa (*T*) te dužina signala (*len*). Izlaz funkcije predstavlja matrica značajki (*X*) koja se sastoji od tri reda.


Ideja za ekstrakciju značajki preuzeta je iz izvora [7]. Formule za izračun svakoga reda matrice izlaza (*X*) također su dostupne u navedenom radu. U nastavku su opisane formule za sva tri reda matrice značajki (*X*) koje su prilagođene ovom radu.

Prvi red predstavlja prosječnu amplitudu uzoraka od $n-18$ do $n+18$.

Drugi red predstavlja prosječnu vrijednost izračunatih značajki uzoraka prije n , a to su $n-1$, $n-2$, $n-5$, $n-10$, $n-20$, $n-50$, $n-100$. Značajke se računaju po formuli $(val(n-x)-val(n))/T$. Gdje T predstavlja period uzorkovanja (dužina QRS kompleksa), a $val(n)$ odgovarajuću amplitudu n -tog uzorka. Vrijednost x jednaka je brojevima 1, 2, 5, 10, 20, 50 i 100.

Treći red predstavlja prosječnu vrijednost izračunatih značajki uzoraka poslije n , a to su $n+1$, $n+2$, $n+5$, $n+10$, $n+20$, $n+50$, $n+100$. Značajke se računaju po formuli $(val(n+x)-val(n))/T$. Sve oznake su jednake kao i u drugom redu.


Na slici 5.5 dan je uzorak EKG signala (zapis broj 219). Prikazani uzorak se sastoji od 720 manjih uzoraka. Kreće se od pretpostavke da se uzorak QRS kompleksa koji je izdvojen sastoji od 36 uzoraka, te da je veličina koraka (*StepSize*) jednaka 4. Kreće se od prvog uzorka. U prvom koraku se izračunavaju značajke za uzorke od 1 do 36. U sljedećem koraku se izračunavaju značajke za uzorke od 5 do 40, zatim u trećem koraku računaju se značajke za uzorke od 9 do 44 i tako dalje dok se ne dođe do kraja EKG signala.



Slika 5.5. : Uzorak EKG zapisa broj 219

5.5. Određivanje željenih izlaza

Funkcija *ExtractTargets* se koristi za izračunavanje željenih izlaza (engl. target) za svaki korak ekstrakcije značajki. Željeni izlazi imaju važnu ulogu u treniranju neuronske mreže. Ulazi funkcije su EKG signal (matrica *val*), broj koraka potrebnih da se pređe cijeli signal (*TotalSteps*), veličina koraka (*StepSize*), dužina QRS kompleksa (*T*) te uzorak QRS kompleksa (*SampleQRS*).

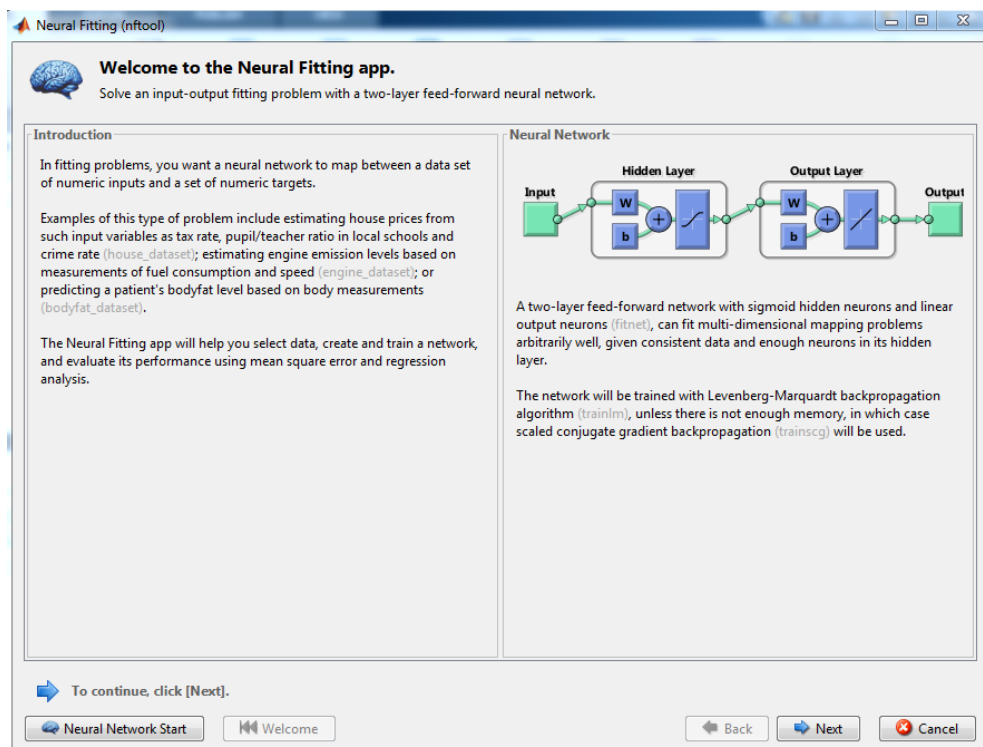


Slika 5.6. : Prikaz postupka određivanja željenog izlaza (množimo uzorak QRS-a sa uzorkom signala)

Ako se krene od prvog koraka to znači da se ekstrahiraju značajke za uzorke od 1 do 36. Kako bi došli do željenih izlaza potrebno je pomnožiti uzorak QRS kompleksa (duljine 36 uzoraka) sa EKG signalom od uzorka 1 do 36, a zatim pronaći normalizirani rezultat. Upravo taj rezultat predstavlja željeni izlaz. Kako je željeni izlaz normaliziran, njegova će vrijednost uvijek biti između 0 i 1. Kako se množi uzorak sa uzorkom, može se zaključiti da što je više preklapanja to je veći konačan rezultat. Najveći umnožak se dobiva kada dolazi do preklapanja sa QRS uzorkom u signalu.

5.6. Kreiranje i trening mreže


Kao što je i ranije navedeno u kreiranju mreže iskorišten je već definiran model mreže *Neural Net Fitting*. Model je pogodan za mreže sa jednim izlaznim parametrom. Na slici 5.7. koja predstavlja početni prozor *Neural Net Fitting* alata, s lijeve strane je vidljiv kratak uvod o neuronskim mrežama dok sa desne strane prozora može se vidjeti struktura mreže koja će biti korištena. Ovaj alat koristi unaprijednu ili "feed-forward" dvoslojnu mrežu, koja u skrivenom sloju sadrži sigmoidne aktivacijske funkcije dok u izlaznom sloju sadrži linearnu aktivacijsku funkciju. Kod procesa učenja mreže korišten je Levenberg-Marquardt algoritam, koji je ranije u poglavlju 3.8 detaljnije opisan.



Slika 5.7. : Početni prozor Neural Net Fitting alata

Kako bi nastavili sa kreiranjem mreže potrebno je kliknuti na polje *Next*, te nam se nakon toga pojavljuje prozor u koji unosimo podatke potrebne za trening mreže.


Potrebno je odrediti ulazne podatke i željene izlaze. U našem slučaju to su ekstrahirane značajke iz matrice značajki X , te željeni izlazi za značajke sadržani u Y . Na slici 5.8. može se vidjeti prozor u kojem se vrši odabir podataka za trening. Na lijevoj strani prozora nalazi se dio gdje se odabiru potrebni podaci iz radnog prostora. Nakon odabira ulaza i željenih izlaza, sa desne strane prozora pojavljuju se informacije o broju uzoraka. Također je potrebno odabrati i prihvatljiv oblik za trening podatke, a u ovom slučaju se odabire opcija *Matrix Rows*.



Slika 5.8. : Odabir podataka za trening mreže

Za nastavak izrade mreže potrebno je kliknuti na polje *Next*. Nakon toga dolazi dio u kojem podatke raspodjeljujemo na trening, validacijske i testne. Ne postoji strogo pravilo o raspodjeli uzoraka jer svaka je mreža različita od ostalih, ali svakako se savjetuje da najveći broj uzoraka bude ostavljen za trening mreže.


Na slici 5.9. prikazan je prozor za raspodjelu uzoraka. U lijevom dijelu prozora se mogu kroz padajuće izbornike odrediti postotci raspodjele dok se u desnom dijelu prozora nalaze kratka objašnjenja o ulogama svakog skupa uzoraka. Prema objašnjenju s desne strane, trening uzorci se predstavljaju mreži tijekom treninga te se ona prilagođava prema njihovim pogreškama. Validacijski uzorci se koriste za mjerenje generalizacije mreže i zaustavljanje treninga kada se generalizacija prestane poboljšavati. Testni podaci nemaju utjecaj na trening te pružaju neovisna mjerenja performansi mreže tijekom i nakon treninga. U našem slučaju određeno je da najveći postotak odlazi na trening uzorke, točnije 60 %, a po 20 % se koristi za validaciju i testiranje.



Slika 5.9. : Raspodjela uzoraka


Nakon raspodjele uzoraka slijedi prozor u kojemu je potrebno odabrati broj neurona skrivenog sloja umjetne neuronske mreže. Na slici 5.10. prikazan je prozor za odabir broja neurona skrivenog sloja umjetne neuronske mreže. Također na dnu prozora može se vidjeti i struktura

mreža te broj slojeva svakog sloja. Kao i kod raspodjele uzoraka tako i kod biranja broja neurona skrivenog sloja, ne postoji strogo pravilo. Preporučljivo je da broj bude manji od broja ulaza, ali kako je u ovom slučaju broj ulaza samo tri, pri izboru je korištena metoda pokušaja i pogreški. Ova mreža sadrži 20 neurona u skrivenom sloju. U desnom dijelu prozora stoji napomena kako se možete vratiti i promijeniti broj neurona ukoliko niste zadovoljni izvedbom mreže nakon treninga.



Slika 5.10. : Odabir broja neurona skrivenog sloja mreže


Nakon odabira broja neurona u skrivenom sloju proces kreiranja mreže je gotov. Klikom na polje *Next* prelazimo u prozor za treniranje mreže. Prije samog treninga mreže potrebno je još odabrati algoritam učenja, a to je Levenberg-Marquardt algoritam kao što je i ranije napomenuto. Na slici 5.11. prikazan je prozor za treniranje neuronske mreže u kojem se nalazi padajući izbornik za izbor algoritma za učenje.



Slika 5.11. : Odabir algoritma za učenje prije samog treniranja

Nakon što je algoritam za učenje odabran potrebno je kliknuti na opciju *Train* kako bi se treniranje započelo. Klikom na *Train* otvara se novi prozor *Neural Network Training* gdje se može pratiti treniranje mreže. Kada je trening odrađen u otvorenom prozoru (slika 5.12.) može se vidjeti kratak sažetak rezultata treniranja. Rezultati treniranja detaljnije će biti prokomentirani u idućem poglavlju.


Na slici 5.12. prikazan je prozor koji prikazuje rezultate nakon treniranja mreža. Prozor se sastoji od više različitih dijelova. Tako je na vrhu još jednom dan prikaz modela neuronske mreže. Ispod njega može se iščitati naziv algoritma za učenje (*Training: Levenberg-Marquardt*) te mjerna jedinica za grešku učenja (*Performance: Mean Squared Error*). Zatim se mogu vidjeti parametri tijekom izvođenja procesa učenja, kao što su: trenutačni broj iteracija/epoha, vrijeme trajanja procesa, trenutačna greška učenja, postignuti gradijent učenja te obavljene validacijske provjere. Ispod toga se nalaze polja za prikaz različitih grafova procesa učenja (treniranja).



Slika 5.12. : Sažetak rezultata treniranja mreže

Nakon što je trening odrađen, u prozoru za treniranje mreže (*Neural Net Fitting* alata) s desne strane vidljivi su rezultati u numeričkom obliku, a ispod njih daje se mogućnost i grafičkog prikaza. U lijevom dijelu prozora na mjestu gdje se nalazilo polje *Train*, sada je predložena opcija *Retrain* ukoliko rezultati treniranja nisu zadovoljavajući. Ako se odabere opcija za dalje u sljedećem prozoru otvara se mogućnost za vrednovanje mreže gdje se opet nude određene stavke za poboljšanje rezultata treniranja.

Klikom na opciju *Next*, dolazi se do završnog prozora ovog alata, a to je prozor za spremanje rezultata mreže. U završnom prozoru preporučuje se opcija generiranja skripte za trening mreže te se vrši spremanje rezultata. Na kraju klikom na opciju *Finish* vrši se spremanje i proces treninga je završen. Na slici 5.13. prikazan je završni prozor za spremanje rezultata mreže.

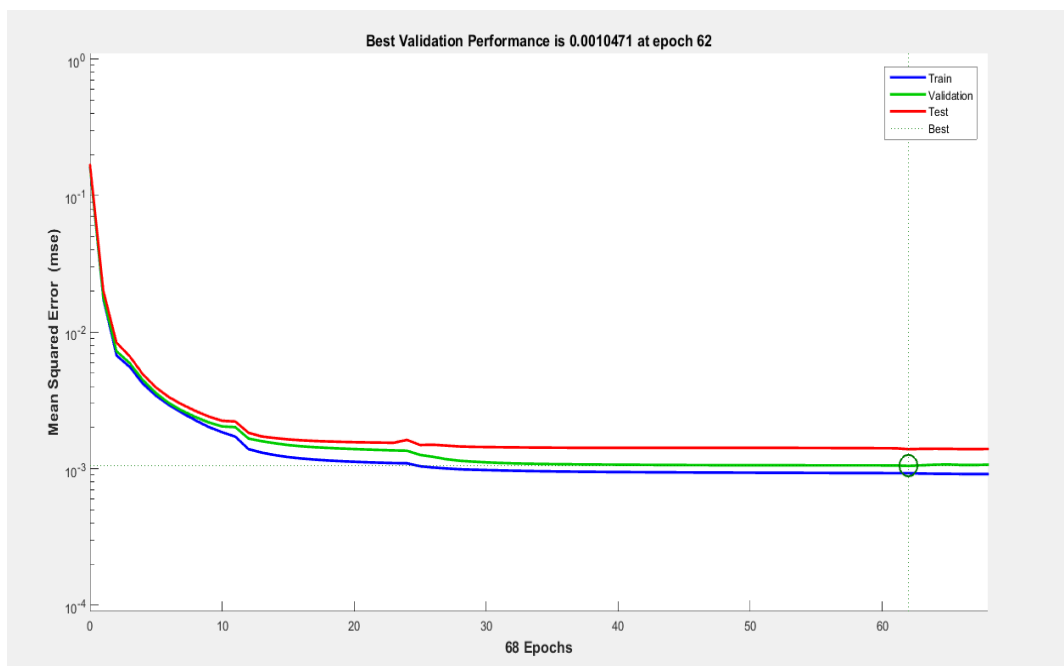


Slika 5.13. : Generiranje skripte i spremanje rezultata mreže

5.7. Rezultati treninga i detekcija QRS kompleksa

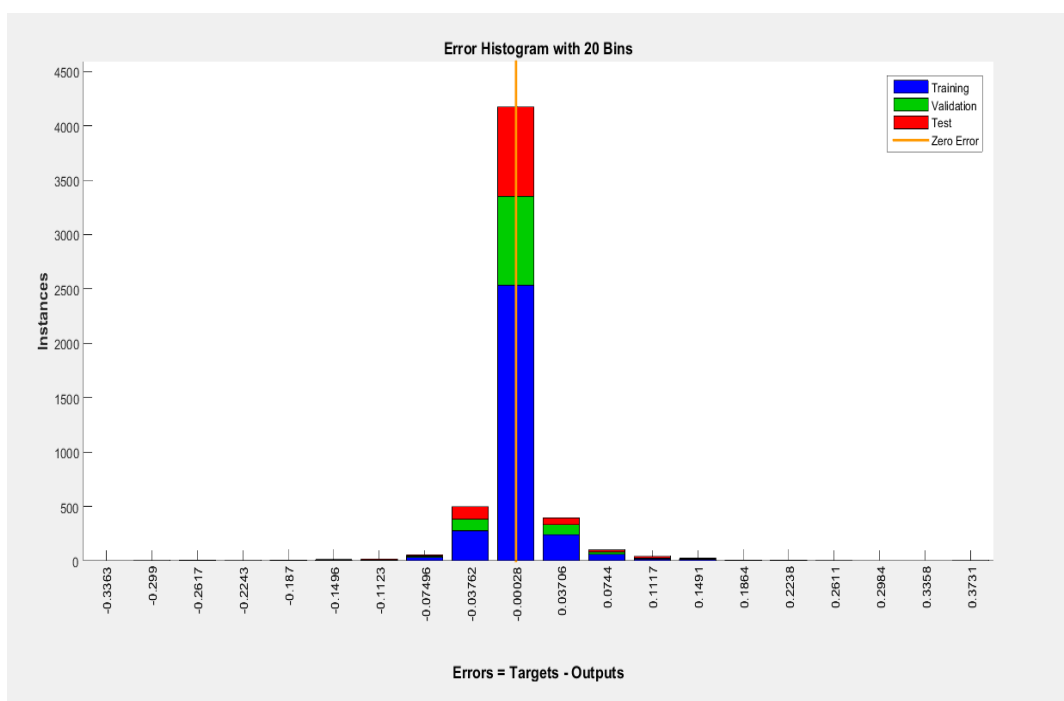
Prozor u kojem možemo pratiti treniranje mreže daje mogućnost pregleda rezultata treninga u grafičkom prikazu. Rezultati su predstavljeni kroz nekoliko grafova koji su detaljnije obrazloženi u nastavku.

Za početak dan je prikaz grafa (slika 5.14.) koji se dobije klikom na opciju *Performance*. Ovaj grafički prikaz pokazuje razliku između naših željenih ili očekivanih izlaza i stvarnih simulacija neuronske mreže. Najbolje performanse pojavljuju se u 62. epohi.




Slika 5.14. : Grafički prikaz greške učenja kroz epohe

Sljedeći prikaz rezultata također pokazuje odstupanja stvarnih izlaza od onih željenih. Prikaz se dobije klikom na opciju *Error Histogram*. Na slici 5.15. nalazi se grafički prikaz u kojem se može vidjeti odnos grešaka učenja (razlika željenog i stvarnog izlaza) i broja slučajeva. Ovaj prikaz daje uvid u raspodjelu uzoraka s obzirom na iznos greške. Na osi apscise nalazi se 20 vrijednosti grešaka te se iz prikaza lako može uočiti oko koje vrijednosti se greška najčešće kreće.



Slika 5.15. : Prikaz broja uzoraka s obzirom na iznos greške


Tijekom procesa učenja težinski koeficijenti se podešavaju uporabom algoritma za učenje. Kroz svaku iteraciju izračunavaju se novi težinski koeficijenti s ciljem smanjenja pogreške mreže. Validacijski skup podataka služi za određenu korekciju težinskih koeficijenata te za izbjegavanje pretreniranosti mreže. Skup testnih podataka koristi se za provjeru ukupne uspješnosti mreže. Za rezultate treninga prikazane na slici 5.16. može se reći da su zadovoljavajući. Koeficijenti korelacije R (odnos između ciljanih i stvarnih izlaza) su vrlo visoki. Za trening iznosi 0.97714 (97.71 %), za validaciju 0.97403 (97.4 %), a kod testiranja 0.97068 (97.1 %). U prosjeku iznosi 0.975 (97.5 %). Grafički prikaz se dobije klikom na opciju *Regression* u prozoru za treniranje mreže.



Slika 5.16. : Prikaz regresije treninga, validacije i testiranja


Nakon treninga mreža je pohranjena te će biti iskorištena prilikom detekcije QRS kompleksa. Prilikom primjene mreže koristimo funkciju *TestNeuralNet* koja nam kao izlaz vraća izlaznu vjerojatnost da je trenutni uzorak upravo QRS kompleks. Što je izlaz veći, veća je i vjerojatnost da se radi o QRS kompleksu. Vrijednost izlaza se kreće između 0 i 1, a izlazi koji imaju vrijednost veću od 0.85 mogu se gledati kao oni koji imaju najveću vjerojatnost da predstavljaju QRS kompleks. Takvi vrhovi će biti locirani pomoću naredbe *findpeaks*. *Findpeaks* naredba vraća indekse onih vrhova signala koji ispunjavaju određene uvjete (prag). Kada se potencijalni QRS kompleksi detektiraju, upotrebom naredbe *rectangle* obilježavaju se pravokutnikom.

Na slici 5.17. vidljiv je uzorak signala (prvih deset sekundi zapisa) sa obilježenim potencijalnim QRS kompleksima. Promatrajući sliku može se zaključiti da je u ovom slučaju detekcija zadovoljavajuće odrađena.




Slika 5.17. : Uzorak signala sa obilježenim QRS kompleksima

Na sljedećim slikama može se vidjeti još par uzoraka signala kojima je mreža testirana. Na slici 5.18. nalazi se uzorak zapisa broj 205 koji predstavlja dobro odrađenu detekciju QRS kompleksa.




Slika 5.18. : Uzorak signala 205 predstavlja primjer dobro odrađene detekcije

Na slici 5.19. nalazi se uzorak signala 105 na kojem se također može vidjeti kako su svi QRS kompleksi uspješno obilježeni.




Slika 5.19. : Uzorak signala 105

Na slici 5.20. vidljivo je kako uz dobro detektirane QRS komplekse postoje i oni koji nisu obilježeni, a trebali bi biti (propušteni kompleksi ili engl. *false negative* – FN).



Slika 5.20. : Uzorak signala 100 (vidljivo je kako su određeni kompleksi propušteni)

Na slici 5.21. dan je prikaz uzorka signala 234 na kojem je vidljivo kako su neki od kompleksa krivo obilježeni (engl. *false positive* – FP).



Slika 5.21. : Uzorak signala 234 (vidljivo je kako su početni kompleksi krivo detektirani)

Kroz testiranje se može zaključiti da su rezultati detekcije u najmanju ruku zadovoljavajući. Za određene signale detekcija je odrađena bez većih grešaka, dok se kod nekih pojavljuje veći broj propuštenih ili pak krivo detektiranih uzoraka. Prostora za unaprjeđenje programa svakako ima jer uspješnost detekcije je moguće još povećati. Kako je testiranje provedeno samo na manjem dijelu standardne baze, rezultate možemo svrstati u manje pouzdane. Kao ideja za poboljšanje uspješnosti predlaže se, da se u trening uključi više signala odnosno da se poveća set podataka za trening. Prije samog treninga potrebno je učitati veći broj signala, ekstrahirati njihove značajke, povezati ih te isto napraviti za željene izlaze. Pretpostavka je da bi se na taj način postigla još bolja uspješnost detekcije.

6. Zaključak

Može se primijetiti kako se sve veći broj inteligentnih računalnih sustava koristi u svim životnim područjima, samim time i u području medicine. Uloga računalnih sustava u medicini je da što više pokušaju poboljšati kvalitetu liječenja. U skupinu inteligentnih računalnih sustava možemo svrstati i umjetne neuronske mreže koje su u ovom radu korištene kao alat pri detekciji QRS kompleksa EKG signala. Potrebno je uspjeti detektirati QRS komplekse kako bi se kasnije mogao odrediti srčani ritam koji predstavlja važan čimbenik u proučavanju srčanih poremećaja. U završnom poglavlju rada objašnjen je postupak same detekcije uz pomoć umjetnih neuronskih mreža. Program je izvršen pomoću MATLAB programskog paketa. Kroz testiranje je vidljivo kako su rezultati same detekcije zadovoljavajući, ali isto tako može se primijetiti kako je program moguće doraditi te tako povećati uspješnost detekcije. Predlaže se da prvi korak u doradi programa bude povećanje seta podataka za trening.

Literatura

- [1] J. Krmpotić-Nemanić, A. Marušić, Anatomija čovjeka, Medicinska naklada, Zagreb, 2007.
- [2] M. Bergovec, Praktična elektrokardiografija, Školska knjiga, Zagreb, 2011.
- [3] J. Mirat, EKG u kliničkoj praksi – uvod u elektrokardiografiju, Medicinski fakultet Osijek i Poliklinika Kardioton, Zagreb, 2014.
- [4] B. Dalbelo Bašić, M. Čupić, J. Šnajder, Umjetne neuronske mreže, Fakultet elektrotehnike i računarstva, 2008.
- [5] M. Kalezić, R. Stojanović, M. Mirković, Komparativna analiza algoritama za detekciju QRS segmenta EKG signala, INFOTEH-JAHORINA Vol. 9, Ref. E1-14, p. 954-958, ožujak 2010.
- [6] C. Pavlatos, A. Dimopoulos, G. Manis, G. Papakonstantinou, Hardware implementation of Pan & Tompkins QRS detection algorithm, European Social Fund, Program “Pened 2003”
- [7] I. Chio In, W. Feng, V. Mang I, M. Peng Un, QRS complex detector using artificial neural network, Faculty of Science and Technology, University of Macau, Macau, China
- [8] J. Pan, W. J. Tompkins, A Real-Time QRS Detection Algorithm, IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING, VOL. BME-32, NO. 3, ožujak 1985.
- [9] B. Puščul, Tehnike ekstrakcije QRS kompleksa iz EKG signala, Elektrotehnički fakultet Sarajevo, Sarajevo, rujan 2016.
- [10] M. Velić, Metoda umjetne inteligencije za rudarenje podacima iz vremenskih serija i implementacija na ljudskom EKG signalu, Fakultet organizacije i informatike, Varaždin, 2014.
- [11] A. Machiedo, Klasifikacija srčanih ritmova neuronskom mrežom, Fakultet elektrotehnike i računarstva, Zagreb, lipanj 2011.
- [12] <https://physionet.org/>

Sažetak

Tema ovoga rada je pronalaženje ključnih točaka EKG signala pomoću umjetnih neuronskih mreža. Analiza i pronalaženje ključnih točaka predstavljaju važan čimbenik za proučavanje rada srca i lakše otkrivanje određenih nepravilnosti u radu srca. Nakon uvodnog dijela rada, obrađene su teme usko vezane za sam EKG i električnu aktivnost srca. Zatim se kroz cijelo poglavlje obrađuje model umjetnih neuronskih mreža. Kroz rad su spomenuti i drugi postojeći načini za detekciju ključnih točaka signala, a u završnom poglavlju napravljena je analiza i pronalaženje ključnih točaka EKG signala pomoću umjetnih neuronskih mreža. Za izvedbu je korišteno MATLAB programsko okruženje i skup alata Neural Network Toolbox.

Ključne riječi: EKG, QRS kompleks, umjetne neuronske mreže

Abstract

In this paper, the topic was detection of key ECG signal points by artificial neural networks. Analyzing and finding key points is an important factor for studying heart function and for easier detection of certain irregularities in cardiac work. After introduction, topics closely related to ECG and electroactive heart activity were processed. Then, through the whole chapter, the model of artificial neural networks was processed. Through this work were also mentioned other existing ways of detecting key point signals, and in the final chapter, analysis and finding key ECG signal points were made using artificial neural networks. The MATLAB programming environment and the set of Neural Network Toolbox tools were used for performance.

Key words: ECG, QRS complex, artificial neural networks

Životopis

Antonio Sušac rođen je 13.07.1991.g. u Vinkovcima. Školovanje započinje u Osnovnoj školi Vladimira Nazora u Vinkovcima. Srednjoškolsko obrazovanje stječe u vinkovačkoj gimnaziji. Preddiplomski studij računarstva na Elektrotehničkom fakultetu u Osijeku završava 2014. godine te iste godine upisuje diplomski studij procesnog računarstva na istom fakultetu. Pored znanja stečenog tokom studija također posjeduje dobro poznavanje engleskog jezika. Kroz osnovnoškolsko i srednjoškolsko školovanje sudjelovao je na mnogim natjecanjima iz predmeta kao što su matematika, geografija, povijest i bilježio vrlo dobre rezultate.

Prilozi

- Rad u .pdf formatu
- Rad u .docx formatu
- Program za detekciju