

Pronalaženje ili prepoznavanje R-vrha u EKG-u

Marek, Ana

Master's thesis / Diplomski rad

2024

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:200:786897>

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

Download date / Datum preuzimanja: **2025-02-27**

Repository / Repozitorij:

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



SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I

INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Sveučilišni diplomski studij Računarstvo

PRONALAZENJE ILI PREPOZNAVANJE R-VRHA U

EKG-U

Diplomski rad

Ana Marek

Osijek, 2024.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMATIJSKIH TEHNOLOGIJA OSIJEK**Obrazac D1: Obrazac za ocjenu diplomskog rada na sveučilišnom diplomskom studiju****Ocjena diplomskog rada na sveučilišnom diplomskom studiju**

Ime i prezime pristupnika:	Ana Marek
Studij, smjer:	Sveučilišni diplomski studij Računarstvo
Mat. br. pristupnika, god.	D1304R, 07.10.2022.
JMBAG:	0165075150
Mentor:	prof. dr. sc. Krešimir Nenadić
Sumentor:	
Sumentor iz tvrtke:	izv. prof. dr. sc. Dario Galić
Predsjednik Povjerenstva:	doc. dr. sc. Krešimir Romić
Član Povjerenstva 1:	prof. dr. sc. Krešimir Nenadić
Član Povjerenstva 2:	izv. prof. dr. sc. Ivica Lukić
Naslov diplomskog rada:	Pronalaženje ili prepoznavanje R-vrha u EKG-u
Znanstvena grana diplomskog rada:	Obradba informacija (zn. polje računarstvo)
Zadatak diplomskog rada:	Opisati svojstva EKG dijagrama. Dati pregled postojećih metoda pronalaženja i prepoznavanja R-vrha u EKG dijagramu. Zadatak rada je napraviti aplikaciju za bilo koju platformu koja pronalazi ili prepoznaje točku R koja je najsvojstvenija točka u EKG-u. Metode pronalaska i/ili prepoznavanja mogu biti: strojno učenje/neuronske mreže, waveleti, fraktali, prag, uvjet šiljatosti ili neka druga poznata metoda. Postoji mogućnost dodatnih tema čiji bi zadatak bio pronalaženje ili prepoznavanje QRS kompleksa (druga tema), P vala (treća tema) te T vala (četvrta tema).
Datum ocjene pismenog dijela diplomskog rada od strane mentora:	02.12.2024.
Ocjena pismenog dijela diplomskog rada od strane mentora:	Izvrstan (5)
Datum obrane diplomskog rada:	10.12.2024.
Ocjena usmenog dijela diplomskog rada (obrane):	Izvrstan (5)
Ukupna ocjena diplomskog rada:	Izvrstan (5)
Datum potvrde mentora o predaji konačne verzije diplomskog rada čime je pristupnik završio sveučilišni diplomski studij:	10.12.2024.



FERIT

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

IZJAVA O IZVORNOSTI RADA

Osijek, 10.12.2024.

Ime i prezime Pristupnika:

Ana Marek

Studij:

Sveučilišni diplomski studij Računarstvo

Mat. br. Pristupnika, godina upisa:

D1304R, 07.10.2022.

Turnitin podudaranje [%]:

4

Ovom izjavom izjavljujem da je rad pod nazivom: **Pronalaženje ili prepoznavanje R-vrha u EKG-u**

izrađen pod vodstvom mentora prof. dr. sc. Krešimir Nenadić

i sumentora

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 pristupnika:

SADRŽAJ

1. UVOD	1
1.1. Zadatak diplomskog rada.....	2
2. ELEKTROKARDIOGRAFIJA	3
2.1. Anatomija srca	4
2.2. Električna aktivnost srca.....	5
2.3. Elektrode i vodovi	6
2.4. Komponente EKG signala	8
2.5. Svojstva EKG signala.....	8
2.6. Interpretacija EKG signala	9
3. PREGLED POSTOJEĆIH METODA ZA PRONALAZENJE I PREPOZNAVANJE R-VRHA U EKG DIJAGRAMU	12
3.1. Pan–Tompkinsov algoritam.....	12
3.2. Wavelet transformacija	14
3.2. Neuronske mreže	16
4. IMPLEMENTACIJA APLIKACIJE	22
4.1. Baza podataka.....	22
4.2. Korištene tehnologije.....	22
4.3. Izrada aplikacije.....	23
5. ZAKLJUČAK	31
LITERATURA.....	32
SAŽETAK	34
ABSTRACT	35

1. UVOD

Tema ovog rada je pronalaženje ili prepoznavanje R-vrha u elektrokardiogramu. Elektrokardiogram (EKG) predstavlja grafički prikaz električne aktivnosti srca te je jedan od najvažnijih alata u dijagnostici srčanih oboljenja.

Znanstvenici Kölliker i Müller, 1856. godine, prvi su zamijetili postojanje električne aktivnosti srca [1]. Nakon toga, 1887. godine, A. D. Waller izveo je prvo snimanje na čovjeku pomoću kapilarnog elektrometra [2]. Zatim je, 1903. godine, Willem Einthoven osmislio znatno precizniji uređaj – elektrokardiograf [3]. Izvorni elektrokardiograf funkcionirao je na principu galvanometra s oscilirajućoj žicom. Žica se kretala između elektromagnetnih polova, a njezino gibanje stvaralo je sjenu koja se projicirala kroz mikroskop na fotografski papir. Ova projekcija bilježila je grafički prikaz promjena električnih potencijala srca kroz vrijeme, stvarajući prvi EKG zapis. Uz to, Willem je i prvi koji je identificirao različite oblike valova te im pridružio slova P, T, Q, R i S, koja se i danas koriste za označavanje ključnih komponenti srčanog ciklusa. Za svoj doprinos, 1924. godine, Willem Einthoven dobio je Nobelovu nagradu za medicinu.

Današnja elektrokardiografija uvelike je napredovala zahvaljujući usavršenijim i složenijim elektroničkim uređajima koji omogućavaju precizniju dijagnostiku. Bilježenjem električnih impulsa srca, medicinski stručnjaci mogu identificirati abnormalnosti poput nepravilnog srčanog ritma, srčanog udara i drugih srčanih problema. Električna aktivnost srca prikazana je na EKG-u kroz valove i elemente, od kojih su najvažniji P-val, T-val i QRS-kompleks. R-vrh predstavlja najvišu točku QRS kompleksa te prikazuje ventrikule srca koje prolaze kroz depolarizaciju. Precizno prepoznavanje i detekcija R-vrha ključni su za analizu srčanog ritma i mjerenje vremena između otkucaja srca, poznatog kao RR-interval.

Razvoj tehnologije pridonio je i napretku u području medicine. Primjena tehnologije u znanstvenim istraživanjima i svakodnevnoj medicinskoj praksi olakšava dijagnosticiranje bolesti i poremećaja, praćenje stanja pacijenata te poboljšava kvalitetu liječenja.

Praktični dio rada razvijen je korištenjem programskog jezika Python, za implementaciju algoritama, analizu podataka i vizualizaciju, unutar Visual Studio Code okruženja. Python je izabran zbog brojnih biblioteka koje su omogućile jednostavnu izradu grafičkog korisničkog sučelja te analizu i obradu signala.

U drugom poglavlju, detaljnije je pojašnjeno što je elektrokardiografija, građa srca, električna aktivnost srca, elektrode i vodovi te svojstva i komponente elektrokardiograma. Navedeni


pojmovi važni su za daljnje razumijevanje, analizu i izradu zadatka diplomskog rada. Treće poglavlje daje pregled nekih od najpoznatijih metoda za pronalaženje R-vrhova u elektrokardiogramu; obrađene metode su Pan-Tompkinsov algoritam, wavelet transformacija i neuronske mreže. Nakon teorijskog dijela, slijedi praktični dio, koji je opisan u četvrtom poglavlju. Prilikom izrade aplikacije odabrana metoda za detekciju je Pan-Tompkinsov algoritam te su prikazane linije koda i rezultat. Zadnje poglavlje, zaključak, pruža osvrt na postavljene ciljeve te analizira postignute rezultate.

1.1. Zadatak diplomskog rada

Opisati svojstva EKG dijagrama. Dati pregled postojećih metoda pronalaženja i prepoznavanja R-vrha u EKG dijagramu. Zadatak rada je napraviti aplikaciju za bilo koju platformu koja pronalazi ili prepoznaje točku R koja je najsvojstvenija točka u EKG-u. Metode pronalaska i/ili prepoznavanja mogu biti: strojno učenje/neuronske mreže, waveleti, fraktali, prag, uvjet šiljatosti ili neka druga poznata metoda.

2. ELEKTROKARDIOGRAFIJA

Elektrokardiografija je dijagnostička metoda koja ne zahtijeva invazivne postupke, a koristi se za praćenje električnih potencijala koji nastaju tijekom rada srca [4]. Električni impulsi koji izazivaju kontrakciju srčanog mišića proizvode male promjene u električnom potencijalu, a mogu se detektirati na površini kože pomoću elektroda postavljenih na prsni koš i udove. Srčani električni potencijali, koji uzrokuju struje vrlo male jakosti, šire se tijelom u zavisnosti o provodljivosti određenih tkiva. Elektrokardiograf pojačava detektirane signale sa senzora te ih prenosi na milimetarski papir stvarajući elektrokardiogram, odnosno EKG krivulju. Prema slici 2.1. standardni EKG zapis sastoji se od 12 različitih vektorskih prikaza koji prikazuju razlike potencijala između negativne i pozitivne elektrode [4].




Slika 2.1. Prikaz normalnog EKG zapisa [8]

2.1. Anatomija srca

Srce je organ koji omogućava cirkulaciju krvi kroz tijelo putem krvnih žila. Masa ljudskog srca uobičajeno je između 200 i 425 grama, a prosječna veličina odgovara veličini stisnute šake. Osrčje je vanjska opna koja štiti i obavija srce i početke velikih krvnih žila. Srce se dijeli na lijevu i desnu stranu, a one su razdvojene srčanom pregradom (lat. *septum cordis*) koja sprječava miješanje venske i arterijske krvi. Svaka strana srca sastoji se od dva dijela: gornja pretkljetka i donja kljetka. Između pretkljetki (lat. *atrium*) i kljetki (lat. *ventriculus*) nalaze se srčani zalisci koji omogućuju jednosmjerni prolaz krvi. Slika 2.2 prikazuje presjek građe srca. Srčani zalisci funkcioniraju poput ventila – propuštaju krv iz pretkljetke u kljetku te se zatvaraju kako bi spriječili njen povratak. Ljudsko srce sastoji od ukupno četiri odjeljka: dvije pretkljetke i dvije kljetke [5]. U medicinskoj terminologiji često se koriste pojmovi "lijevo" i "desno" srce kako bi se razlikovala funkcionalna podjela.

Desna pretkljetka prima vensku krv iz ostatka tijela i prosljeđuje je u desnu kljetku, koja zatim krv pumpa prema plućima. Plućna arterija prenosi vensku krv iz desnog srca do pluća, gdje se krv oslobađa ugljičnog dioksida i obogaćuje kisikom. Takva arterijska krv potom se vraća u lijevu pretkljetku plućnim venama, nakon čega prelazi u lijevu kljetku, odakle se putem aorte širi po cijelom tijelu. S obzirom na to da lijeva strana srca pumpa krv pod puno većim tlakom kako bi opskrbila cijelo tijelo, njezine stijenke su deblje i snažnije od desne strane, koja pumpa krv samo u pluća. Rad srca obuhvaća dvije osnovne faze: sistola, u kojoj se srce kontrahira i ispumpava krv, i dijastola, kada se opušta i puni krvlju [7]. Otkucaji srca mogu se osjetiti kao puls na različitim mjestima, poput vrata ili zapešća.




Slika 2.2. Presjek građe srca [8]

2.2. Električna aktivnost srca

Električna aktivnost srca uvjet za mehaničku funkciju srca, odnosno njegov rad. Srčani akcijski potencijal odnosi se na kratkotrajnu promjenu električnog naboja unutar srčanih stanica, koja nastaje zbog kretanja iona kroz ionske kanale u staničnoj membrani. Kretanje nabijenih iona, unutar i izvan stanica, dovodi do promjene u električnom potencijalu, što omogućuje prijenos električkih impulsa potrebnih za srčanu kontrakciju i regulaciju ritma. Stanice srca u stanju mirovanja imaju električnu polarizaciju, što znači da je unutrašnjost stanice negativno nabijena u odnosu na vanjsko okruženje.

Polarizacija se održava pomoću membranskih pumpi koje reguliraju raspodjelu iona kako bi se očuvala elektronegativnost unutar stanice. Depolarizacija se događa kada podražaj postane dovoljno jak da premaši prag podražaja, što rezultira otvaranjem ionskih kanala. U tom trenutku, pozitivno nabijeni Na^+ ioni ulaze u stanicu, što mijenja njen električni potencijal. S druge strane, repolarizacija nastupa kada dođe do promjene električnog naboja unutar stanice, uzrokovane izlaskom K^+ iona, što dovodi do razlikovnog potencijala.

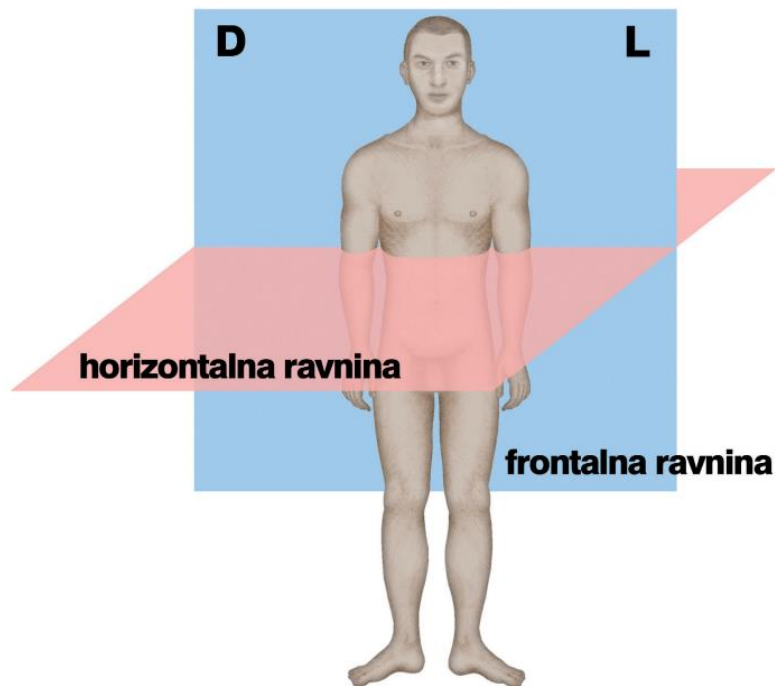
Ova električna aktivnost srca može se grafički prikazati pomoću elektrokardiograma (EKG). Prema slici 2.3. PQRST kompleks prikazan na EKG signalu, odražava faze depolarizacije i repolarizacije srčanog akcijskog potencijala [9]. Proces se mjeri elektrodama postavljenim na tijelo pacijenta.



Slika 2.3 PQRST kompleks i njegove oscilacije [9]


2.3. Elektrode i vodovi

Elektrokardiografski odvodi nastaju postavljanjem elektroda na unaprijed određene lokacije na tijelu. Elektrode mjere razlike u električnom potencijalu između točaka, a vremenski slijed tih promjena omogućuje stvaranje EKG zapisa. Standardni elektrokardiogram koristi 10 elektroda koje stvaraju 12 različitih odvoda. Odvodi su podijeljeni na šest perifernih i šest prekordijalnih odvoda. Periferni odvodi bilježe električnu aktivnost srca u frontalnoj ravnini, dok prekordijalni odvodi prate zbivanja električne aktivnosti u horizontalnoj ravnini [9]. Ravnine su prikazane na slici 2.4.



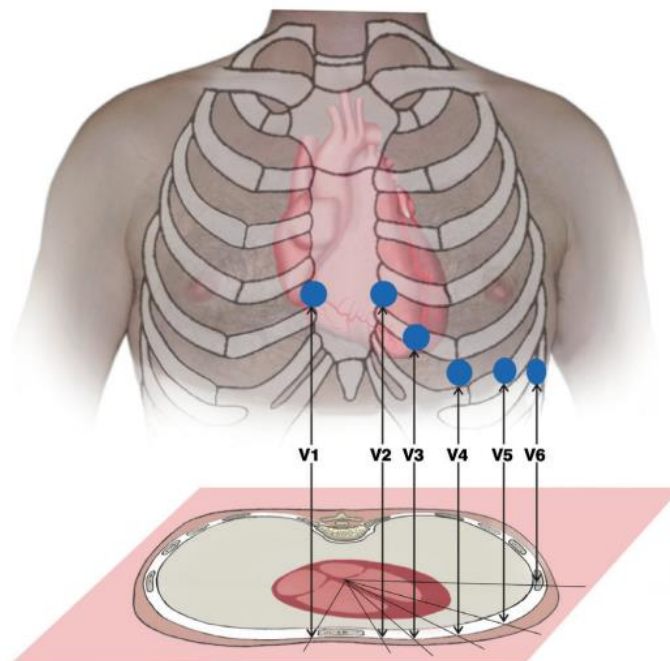
Slika 2.4. Horizontalna i frontalna ravnina [9]

Periferni odvodi, koji uključuju I, II, III, aVR, aVL i aVF, dobivaju se pozicioniranjem tri elektrode na određene položaje na ekstremitetima, dok četvrta elektroda omogućava uzemljenje. Na slici 2.5. prikazani su položaji pravilno postavljenih elektroda; crvena elektroda na zapešću desne ruke, žuta na zapešću lijeve ruke, zelena na lijevoj nozi i crna elektroda postavljena na desnoj nozi, koja služi kao uzemljenje [9][10].



Slika 2.5. Položaj perifernih elektroda

Prekordijalni odvodi, označeni kao V1, V2, V3, V4, V5 i V6, dobivaju se postavljanjem šest elektroda na lijevu stranu prsnog koša. Na slici 2.6. prikazan je položaj prekoridijalnih elektroda.




Slika 2.6. Položaj prekoridijalnih elektroda [9]

2.4. Komponente EKG signala

Tipičan oblik elektrokardiograma prikazuje ritmičan proces depolarizacije i repolarizacije pretklijetki i klijetki, a sastoji se od sljedećih elemenata, koji su prikazani na slici 2.7.:

- P-val → predstavlja depolarizaciju atrija, što je proces aktivacije atrija
- PR-interval → označava vrijeme između početka depolarizacije atrija i početka depolarizacije ventrikula
- QRS-kompleks → ukazuje na ventrikularnu depolarizaciju i sastoji se od Q-, R- i S-zubaca
- QT-interval → razdoblje između početka ventrikularne depolarizacije i kraja ventrikularne repolarizacije
- RR-interval → vrijeme između dva QRS-kompleksa
- T-val → predstavlja repolarizaciju ventrikula
- ST-segment i T-val (ST-T) → zajedno pokazuju repolarizaciju ventrikula
- U-val → moguće ukazuje na naknadnu depolarizaciju (relaksaciju) ventrikula [4]



Slika 2.7. Elementi EKG dijagrama [4]

2.5. Svojstva EKG signala

Elektrokardiogram ima nekoliko važnih svojstava koja omogućavaju analizu srčane aktivnosti. Svojstva uključuju amplitudu, trajanje, oblik valova, frekvenciju i intervale između različitih dijelova EKG signala [4].

Amplituda predstavlja visinu valova, mjeri se u milivoltima (mV), a različiti valovi u EKG-u imaju svoje karakteristične amplitude:

- P – val: obično ima amplitudu između 0.1 i 0.2 mV
- QRS – kompleks: najviši dio EKG signala, gdje R-vrh ima amplitudu do 1.5 mV ili više, ovisno o pojedinačnim varijacijama
- T – val: amplituda može varirati, ali uobičajeno je niža od R-vrha, često između 0.1 i 0.5 mV

Trajanje EKG valova i intervala mjeri se u milisekundama (ms) i daje informacije o vremenskoj dinamici srčane aktivnosti.

- P – val: traje između 80 i 100 ms
- PR – interval: vrijeme između početka P-vala i početka QRS-kompleksa, traje između 120 i 200 ms
- QRS – kompleks: uobičajeno trajanje je između 80 i 100 ms
- QT – interval: razdoblje između pojave QRS-kompleksa i kraja T-vala, koje ovisi o srčanoj frekvenciji, ali u prosjeku traje između 350 i 450 ms

Oblik valova u EKG signalu daje kliničke informacije o električnoj aktivnosti srca.

- P – val: obično gladak i zaobljen, ukazuje na normalnu depolarizaciju atrija
- QRS – kompleks: oštar i visoko definiran, što odražava brzo širenje depolarizacije kroz ventrikule
- T – val: asimetričan i zaobljen, odražava repolarizaciju ventrikula

Frekvencija EKG signala definirana je brojem otkucaja srca u minuti (engl. *beats per minute*). Normalna srčana frekvencija za odrasle u mirovanju je između 60 i 100 bpm. Frekvencija se određuje mjerenjem RR-intervalu.

Intervali i segmenti u EKG signalu pružaju važne informacije o vremenskoj koordinaciji različitih faza srčanog ciklusa.

2.6. Interpretacija EKG signala

Interpretacija predstavlja završnu fazu cjelokupnog procesa obrade EKG signala. Cilj je razumjeti rezultate kako bi se omogućila ispravna dijagnoza i razmotrila daljnja testiranja.

Prilikom očitavanja elektrokardiograma preporuka je držati se odgovarajućeg redoslijeda. Analiza rezultata započinje određivanjem ritma i frekvencije atrija i ventrikula. Zatim je potrebno utvrditi pravilnosti PP razmaka i RR razmaka, odnos između P-vala i QRS-kompleksa te pojavu aritmija. Nakon toga slijedi mjerenje važnih elektrokardiografskih intervala, a potom i određivanje električne osi QRS-kompleksa.

Očitavanje elektrokardiograma provodi kardiolog, koji je specijalizirani liječnik za dijagnosticiranje i liječenje kardiovaskularnih bolesti i stanja koja zahvaćaju srce i krvne žile. Medicinske sestre i tehničari također su dužni znati osnovne elemente EKG-a te prepoznati i razlikovati osnovna patološka stanja od normalnih. Patološka stanja očituju se pojavom aritmija, koje karakteriziraju nepravilan srčani ritam.

Neke od najčešćih aritmija su ekstrasistolija, fibrilacija atrija, fibrilacija ventrikula, sinusna bradikardija, sinusna tahikardija, supraventrikularna paroksizmalna tahikardija i srčani blokovi [9]. Ekstrasistolija, prikazana na slici 2.8., označava preuranjene kontrakcije srca.




Slika 2.8. *Ekstrasistolije* [10]

Fibrilacija atrija uzrokovana je izuzetnom brzim električnim impulsima u atrijima, što dovodi i do izrazito brzih kontrakcija. Fibrilacija atrija prikazana je na slici 2.9.




Slika 2.9. *Fibrilacija atrija* [10]

Fibrilacija ventrikula je ozbiljan srčani problem, a ukoliko se ne liječi može biti smrtonosna. Prema slici 2.10. karakteriziraju je nepravilni i brzi otkucaji srca, gdje klijetke samo trepere, umjesto da pumpaju krv u krvotok, što dovodi do zastoja.




Slika 2.10. *Fibrilacija ventrikula* [10]

Sinusna bradikardija predstavlja usporavanje, odnosno smanjenje broja otkucaja srca na manje od 50 otkucaja u minuti, a prikazana je na slici 2.11.




Slika 2.11. *Sinusna bradikardija* [10]

Sinusna tahikardija, suprotno bradikardiji, je povećanje broja otkucaja srca, uobičajeno više od 100 otkucaja u minuti. Slika 2.11. prikazuje sinusnu tahikardiju.




Slika 2.12. *Sinusna tahikardija* [10]

Supraventrikularna paroksizmalna tahikardija je nagla pojava tahikardije, odnosno broj otkucaja srca je između 160 i 200 u minuti, a njen prikaz nalazi se na slici 2.13.



Slika 2.13. *Supraventrikularna paroksizmalna tahikardija* [10]

Prema slici 2.14. asistolija prikazuje ravnu crtu, a označava potpuni prestanak srčane aktivnosti. Ovo stanje predstavlja jedan od kriterija za proglašenje smrti.



Slika 2.14. *Asistolija* [10]

3. PREGLED POSTOJEĆIH METODA ZA PRONALAZENJE I PREPOZNAVANJE R-VRHA U EKG DIJAGRAMU


Pronalaženje i prepoznavanje R-vrha u EKG dijagramu ključno je za analizu rada srca, posebno za određivanje srčane frekvencije i otkrivanje mogućih nepravilnosti u srčanom ritmu. R-vrh predstavlja najistaknutiji dio QRS-kompleksa, koji je karakterističan za depolarizaciju ventrikula i signalizira glavnu kontrakciju srca.

Zbog svoje važnosti, razvijene su različite metode za detekciju R-vrha u EKG dijagramu, a neke od najpoznatijih opisane su u ovom poglavlju. Za preciznije rezultate moguće je kombinirati više metoda.

3.1. Pan–Tompkinsov algoritam

Ovaj algoritam su 1985. godine prvi predstavili Jiapu Pan i Wills J. Tompkins u časopisu IEEE Transactions on Biomedical Engineering [11]. Učinkovitost metode ocijenjena je impresivnom točnošću detekcije od 99,3%. Pan-Tompkinsov algoritam jedan je od najčešće korištenih pristupa za preciznu detekciju QRS-kompleksa unutar EKG signala.

QRS-kompleks je pokazatelj ventrikularne depolarizacije i predstavlja najistaknutiju značajku opaženu u EKG valnom obliku. QRS-kompleks sastoji se od tri različite komponente: otklon prema dolje poznat kao Q-val, izraženi otklon prema gore koji se naziva R-val i konačni otklon prema dolje identificiran kao S-val. Dakle, iz QRS-kompleksa moguće je izdvojiti detekciju R- vrha u elektrokardiogramu. Ovaj pristup koristi nagib, amplitudu i širinu integriranog prozora. Na slici 3.1. prikazani su koraci primjene Pan-Tompkinsovog algoritma, a to su filtriranje signala, deriviranje signala, kvadriranje signala, integriranje signala, postavljanje pragova i detekcija [11].



Slika 3.1. Koraci Pan-Tompkinsovog algoritma

Filtriranje signala provodi se pomoću nisko-propusnih i visoko-propusnih filtara koji služe za uklanjanje pozadinske buke, odnosno raznih šumova nastalih kao posljedica mišićne kontrakcije, pokreta tijela, disanja, kontakta s elektrodama i sl. Nakon filtriranja, signal prolazi proces derivacije kako bi se dobile informacije o nagibu. U postupku derivacije, niskofrekventni P i T valovi su potisnuti kako bi se dobili visokofrekventni valovi prisutni u strmijim nagibima QRS-kompleksa. Dakle, derivacija signala ističe nagle promjene u amplitudi signala, poput oštrih uspona R-vrhova. Sljedeći korak je kvadriranje signala. U ovom dijelu procesa signal se kvadrira točku po točku i sve negativne vrijednosti pretvaraju se u pozitivne. Kvadriranjem se smanjuju tipične veće amplitude T-vala koje mogu dovesti do lažnih detekcija. Također, kvadriranje služi za pojačanje kontrasta između R-vrha i ostatka signala. Povećanjem kontrasta vrhovi postaju znatno izraženiji, što dodatno pomaže u procesu detekcije. Zatim, obrađeni signal prolazi kroz integraciju s pomičnim prozorom (engl. *moving window integration*). Širina prozora treba biti jednaka najširem mogućem QRS-kompleksu. Sljedeća faza obrade signala je faza postavljanja pragova. Kako bi se osiguralo da je ispravan vrh detektiran, primjenjuju se dva praga. Prva analiza signala provodi se korištenjem višeg od dva praga. Ukoliko se QRS-kompleks ne pronađe primjenjuje se niži prag [11][12]. Pragove je potrebno prilagođavati kako bi se optimiziralo prepoznavanje QRS-kompleksa, a oni se izračunavaju prema jednadžbama (3-1), (3-2), (3-3), (3-4):

$$SignalLevel = 0.125 PEAK + 0.875 SignalLevel \quad (3-1)$$

$$NoiseLevel = 0.125 PEAK + 0.875 NoiseLevel \quad (3-2)$$

$$Threshold_1 = NoiseLevel + 0.25(SignalLevel - NoiseLevel) \quad (3-3)$$

$$Threshold_2 = 0.5 Threshold_1, \quad (3-4)$$

gdje je *SignalLevel* tekuća procjena razine signala, *NoiseLevel* tekuća procjena razine šuma, *PEAK* vršni signal, *Threshold₁* viši prag, a *Threshold₂* niži prag.


Prag mora biti dovoljno precizan da otkrije R-vrhove bez detekcije lažnih vrhova ili propuštanja stvarnih R-vrhova. Konačna detekcija R-vrhova omogućava izračunavanje RR-intervalu, koji je ključan za određivanje srčane frekvencije i prepoznavanje abnormalnosti u srčanom ritmu, poput aritmija.

Učinkovitost (engl. *efficiency*) detekcije Pan-Tompkinsovog algoritma moguće je izračunati pomoću osjetljivosti (engl. *sensitivity*). Osjetljivost (stvarna pozitivna stopa) je vjerojatnost

pozitivnog rezultata testa, u ovom slučaju ispravne detekcije. Formula (3-5) je formula za izračun osjetljivosti:

$$S_e = \left(\frac{TP}{TP+FN} \right) * 100, \quad (3-5)$$

gdje S_e predstavlja osjetljivost, TP (engl. *True Positive*) predstavlja ispravno pozitivno detektirane vrhove, a FN (engl. *False Negative*) lažno negativno detektirane vrhove. Na slici 3.2. prikazan je signal kroz faze Pan-Tompkinsovog algoritma.



Slika 3.2. Pan-Tompkins algoritam; (a) izvorni signal, (b) signal nakon filtriranja i deriviranja, (c) signal nakon kvadriranja, (d) integracija i detekcija [13]

3.2. Wavelet transformacija


Primjena wavelet (valićne) transformacije u znanosti i inženjerstvu doživjela je zamah početkom 1990-ih. Danas se koriste dva različita tipa: diskretna wavelet transformacija i kontinuirana wavelet transformacija. Općenito, wavelet transformacija omogućuje više-rezolucijsku reprezentaciju signala te pruža istovremeni prikaz signala u vremenskoj i

frekvencijskoj domeni. Wavelet transformacija nastoji prikazati signal kao zbroj specifičnih valnih oblika, odnosno malih valova, poznatih kao „valići“.

Kontinuirana wavelet transformacija (engl. *Continuos Wavelet Transform - CWT*) korisna je metoda u analizi EKG signala jer pruža detaljnu vremensko-frekvencijsku analizu te omogućuje detekciju prijelaznih karakteristika, u ovom slučaju R-vrhova, koji su usko povezani s naglim promjenama u signalu. QRS-kompleks, a posebno R-vrh, ima visoku amplitudu i oštar prijelaz u vremenskoj domeni, što se može jasno identificirati na višim frekvencijama analiziranim pomoću CWT-a. Kontinuirana wavelet transformacija definirana je izrazom (3-6):

$$CWT(\tau, s) = \frac{1}{\sqrt{|s|}} x(t) \psi^*\left(\frac{t-\tau}{s}\right) dt \quad (3-6)$$

Funkcija $\psi(t)$ naziva se matična wavelet funkcija (engl. *mother wavelet*). Ona predstavlja jezgru wavelet transformacije, odnosno početni valić na kojemu se temelji transformacija. Funkcija sadrži dva parametra – pomak τ i skalu s . Parametar s omogućava rastezanje ili stezanje funkcije $\psi(t/s)$ duž vremenske osi, odnosno skaliranje. Zbog toga rezultat wavelet transformacije postaje funkcija dviju varijabli – pomaka i skale, a konačan rezultat ovisi i o izboru matične funkcije [14][15]. Oblik matične funkcije, odnosno početnog valića odabire se iz obitelji wavelet funkcija, a neki od najčešće korišteni prikazani su na slici 3.3.




Slika 3.3. Prikaz obitelji wavelet funkcija i njihovi nazivi [16]

Proces računanja wavelet transformacije započinje odabirom skale i pomaka. Odabrani parametri koriste se kod množenja matične funkcije s početnim signalom $x(t)$. Nakon toga, vrijednost pomaka τ potrebno je promijeniti za vrlo malen iznos te ponoviti postupak. Kada se izvrši izračun za sve vrijednosti pomaka τ , mijenja se iznos skale s , također za vrlo malen iznos.

Za novu vrijednost skale s vrši se novi izračun za sve vrijednosti pomaka τ . Konačna wavelet transformacija izračunata je kada su iskorištene i sve vrijednosti parametra skale s . Transformacija se u praksi ne računa analitički, već se koristi numerička aproksimacija s ograničenim brojem pomaka i skala. Za razumijevanje fizikalnog značenja rezultata ove transformacije, potreban je osvrt na koncept korelacije između $x_1(t)$ i $x_2(t)$ signala, definiran formulom (3-7):

$$R_{x_1, x_2} = \int_{-\infty}^{\infty} x_1(t)x_2(t + \tau)dt \quad (3-7)$$

Korelacija mjeri stupanj sličnosti između dva signala, što se može povezati s konceptom wavelet transformacije, koja nastoji signal prikazati kao zbroj valića (waveleta) različitih vremenskih pomaka i skala. Kako bi se utvrdilo koliko je pojedinih valića prisutno u analiziranom signalu, potrebno je izračunati korelaciju tog signala i svih mogućih waveleta, koji nastaju skaliranjem i vremenskim pomicanjem matičnog waveleta, omogućujući detaljnu analizu signala u različitim vremenskim i frekvencijskim domenama. Konačni rezultat kontinuirane wavelet transformacije je prikaz udjela različitih waveleta u izvornom signalu. Grafički, ovaj rezultat se prikazuje kao ploha u prostoru, gdje amplituda predstavlja udio određenih waveleta. Na slici 3.4. prikazani su signali prije i poslije wavelet transformacije.




Slika 3.4. Prikaz signala prije i nakon wavelet transformacije [17]

3.2. Neuronske mreže

Razvoj umjetnih neuronskih mreža inspiriran je mrežama bioloških neurona međusobno povezanih u središnjem živčanom sustavu. Biološke neuronske mreže još uvijek nisu u potpunosti shvaćene, ali njihova ključna karakteristika, odnosno sposobnost učenja, poslužila je kao temelj za razvoj umjetnih neuronskih mreža. Ova analogija omogućila je istraživačima razvijanje sustava koji oponašaju sposobnost prilagođavanja i učenja iz podataka, što je rezultiralo širokom primjenom umjetnih neuronskih mreža u rješavanju složenih problema poput prepoznavanja uzoraka, klasifikacije i predviđanja u brojnim područjima znanosti i tehnologije [18]. Dok su računalni sustavi sposobni za obradu podataka većom brzinom i preciznošću, ljudski mozak posjeduje jedinstven kapacitet za učenje iz iskustva, što pridonosi

donošenju informiranih i racionalnih odluka. Iako umjetne neuronske mreže služe kao pojednostavljeni model živčanog sustava, u stvarnosti, brojni fenomeni živčanog sustava nisu obuhvaćeni ovim modelom. Osim toga, umjetne neuronske mreže posjeduju karakteristike koje se ne podudaraju u potpunosti s funkcijama biološkog sustava.

Umjetna neuronska mreža može se okarakterizirati kao skup međusobno povezanih elementarnih jedinica, nazvanih umjetni neuroni, koja je sposobna za paralelnu obradu. Svaki umjetni neuron ima vlastiti prostor za pohranu koji koristi za čuvanje i obradu podataka, poput težina i pragova, koji su mu potrebni tijekom rada. Obradna snaga neuronske mreže leži u težinama koje povezuju neurone. Težine se prilagođavaju tijekom procesa učenja, pri čemu mreža koristi primjere iz skupa podataka za obuku. Kroz ovaj proces prilagodbe težina, mreža uči prepoznavati obrasce i pravila u podacima, poboljšavajući svoju sposobnost obrade novih informacija. Na taj način mreža razvija sposobnost učenja iz podataka te optimizira svoj rad kako bi točnije predviđala ili klasificirala buduće podatke. Obrada podataka unutar neuronske mreže provodi se distribuiranim i paralelnim radom njenih čvorova, omogućujući joj učinkovitost i fleksibilnost. Jedna od najvažnijih karakteristika neuronskih mreža je njihova sposobnost učenja iz iskustva, što im omogućuje stjecanje znanja na temelju analize brojnih primjera. Umjetni neuron, prikazan na slici 3.5., temeljni je dio umjetne neuronske mreže, a djeluje na način da prihvaća jedan ili više ulaznih signala (x_1, x_2, \dots, x_n), koji predstavljaju podatke koje treba obraditi.



Slika 3.5. Model umjetnog neurona


Svaki ulaz se množi odgovarajućim težinskim faktorom (w_1, w_2, \dots, w_n), koji definira važnost tog ulaza u ukupnom izračunu. Nakon množenja ulaznih signala njihovim težinama, neuron zbraja sve te vrijednosti i dodaje vrijednost praga θ . Rezultat sumiranja je vrijednost *net*, koja

se potom prosljeđuje putem nelinearne funkcije poznate kao aktivacijska funkcija. Ukoliko izlaz aktivacijske funkcije premaši unaprijed definiran prag, neuron se aktivira. Aktivirani neuron šalje izlazni signal y dalje kroz mrežu. Izlaz y predstavlja obradu podataka unutar neurona i koristi se kao ulaz za druge neurone u sljedećem sloju ili kao konačni rezultat mreže. Najjednostavniji oblik aktivacijske funkcije definiran je izrazom (3-3):

$$f(net) = net \quad (3-3)$$


Ova funkcija karakteristična je za ADALINE (Adaptive Linear Element) model umjetnog neurona [18]. Izlaz ovog modela temelji se na težinskom zbroju svih ulaza, što znači da izlaz izravno odgovara linearnoj kombinaciji ulaznih podataka s pripadajućim težinama.

Druga često korištena aktivacijska funkcija je funkcija praga/skoka, kojom se dobiva procesna jedinica koja proizvodi Booleov izlaz, a prikazana je na slici 3.6.




Slika 3.6. *Funkcija praga/skoka*

Prema slici 3.7. aktivacijska funkcija može biti i kombinacija linearne funkcije i funkcije praga, takva funkcija naziva se funkcija rampe.




Slika 3.7. *Funkcija rampe*

Sigmoidalna funkcija, na slici 3.8., također je jedan od najčešćih oblika aktivacijske funkcije. Važnost ove funkcije je to što je derivabilna [18].



Slika 3.8. Sigmoidalna funkcija

Prema slici 3.9. sastavni dijelovi umjetne neuronske mreže su ulazni sloj, skriveni sloj i izlazni sloj. Ulazni sloj je početna točka obrade. Ne sadrži nikakve izračune, već služi za primanje ulaznih podataka koji se prosljeđuju kroz mrežu. Unutar skrivenog sloja podaci se obrađuju kroz međusobno povezane neurone. Svaki neuron prima ulaze iz prethodnog sloja, a nakon izračuna primjenjuje aktivacijsku funkciju kako bi generirao izlaz. Broj i veličina skrivenih slojeva ovisi o složenosti zadatka, a dodavanje više slojeva omogućuje mreži da modelira složenije obrasce. Izlazni sloj daje konačni rezultat obrade mreže, koji može biti klasifikacija, predviđanje ili neki drugi tip rezultata ovisno o ciljevima mreže.




Slika 3.9. Model umjetne neuronske mreže [19]

Dvije temeljne faze rada umjetnih neuronskih mreža su faza treniranja (učenja) i faza testiranja mreže. Podaci koji se koriste prilikom rada neuronskih mreža obično se kategoriziraju u tri

različita podskupa, a to su skup za učenje, skup za testiranje i skup za provjeru [20]. Iako ne postoji strogo pravilo o omjerima za ovu podjelu, preporuka je da većina podataka bude namijenjena za treniranje mreže.

Osnovna podjela učenja je nadzirano (engl. *supervised*) i nenadzirano (engl. *unsupervised*) učenje. Kod nadziranog učenja, modeli se treniraju koristeći unaprijed poznate ulazne i izlazne podatke, što im omogućuje učenje obrazaca koji se koriste za predviđanje budućih izlaza. Zadatak nenadziranog učenja je na temelju ulaznih podataka detektirati skrivene uzorke i inherentne strukture, a da pri tome izlazni podaci nisu poznati.

Općenito, učenje unutar umjetnih neuronskih mreža temelji se na prilagodbi težina mreže pomoću određenog algoritma učenja. Cilj ovog procesa je identificirati skup težinskih matrica koje omogućuju mreži pravilno povezati bilo koji ulaz s odgovarajućim izlazom. Ukoliko je mreža trenirana na raznovrsnom skupu podataka i dovršila je proces učenja, trebala bi biti sposobna pružiti točne izlaze za nove ulaze koji nisu bili korišteni tijekom treninga. Podešavanje težinskih parametara unutar neuronske mreže događa se tijekom faze učenja i izvodi se kroz više iteracija, odnosno prolazaka kroz mrežu. Pojmovi iteracija i epoha sastavni su dio razumijevanja procesa učenja [18]. Iteracija predstavlja jedan korak unutar algoritma učenja u kojem se vrše prilagodbe težina, dok epoha označava potpuni obilazak cijelog skupa podataka za učenje. Podaci iz skupa za provjeru koriste se za procjenu učinkovitosti mreže tijekom procesa učenja. Ovi podaci omogućuju validaciju mreže s trenutnim težinskim faktorima i pomažu identificirati trenutak kada mreža počne gubiti sposobnost generalizacije. Naime, neuronska mreža može postati „pretrenirana“, što znači da nakon velikog broja iteracija gubi sposobnost generalizacije. Umjesto da prepoznaje opće uzorke u podacima, mreža se počinje prilagođavati specifičnostima skupa za učenje, što rezultira lošijim učinkom na novim podacima. Ovaj problem „pretreniranja“ dovodi do smanjenja točnosti pri radu s nepoznatim ulazima, čime se smanjuje sposobnost mreže ispravno obrađivati nove ili drugačije podatke, a graf odstupanja prikazan je na slici 3.10. Kontinuirano praćenje izlaza mreže, koji su dobivenih iz skupa za učenje, omogućava otkrivanje iteracija pri kojima izlazi najmanje odstupaju od željenog. Konačna provjera točnosti i preciznosti obrađenih podataka provodi se na skupu za provjeru/validaciju.



Slika 3.10. Graf odstupanja kroz iteracije

Zbog svoje sposobnosti prepoznavanja složenih obrazaca i prilagodbe nelinearnim karakteristikama signala, umjetne neuronske mreže pokazale su se kao moćan alat za detekciju R-vrhova u EKG signalima.

4. IMPLEMENTACIJA APLIKACIJE

U praktičnom dijelu zadatka izrađena je desktop aplikacija. Aplikacija je razvijena kao alat za analizu EKG signala, a korisnicima omogućuje učitavanje EKG zapisa, koji se potom vizualiziraju s označenim R-vrhovima.

4.1. Baza podataka

Korištena baza podataka je MIT-BIH Arrhythmia Database [21]. U bazi podataka nalazi se 48 isječaka dvo-kanalnih elektrokardiograma prikupljenih od 47 ispitanika (zapisi 201 i 202 su od istog pacijenta), u trajanju od trideset minuta. Zapisi su digitalizirani s 360 uzoraka u sekundi po kanalu s 11-bitnom razlučivosti unutar raspona od 10 mV. Naziv svake datoteke je ID pacijenta, a svaka od njih sadrži stupce koji označavaju indeks, izračunato proteklo vrijeme u milisekundama, prvi odvod i drugi odvod. Prvi odvod je periferni odvod MLII, dok je drugi prekordijalni odvod V1, V2 ili V5. Proteklo vrijeme izračunato je prema formuli:

$$t = \frac{\text{indeks}}{360 \cdot 1000} \quad (4-1)$$

4.2. Korištene tehnologije

Aplikacija je izrađena korištenjem programskog jezika Python u okruženju Visual Studio Code. Python je izabran zbog svoje jednostavnosti i bogate zbirke biblioteka koje olakšavaju analizu i obradu signala.

U nastavku slijedi opis korištenih biblioteka i paketa.

- NumPy – osnovna biblioteka za znanstveno računarstvo u Pythonu; koristi se za numeričke izračune i operacije nad podacima.
- Pandas – biblioteka za rad s podacima, služi za učitavanje, obradu i pohranu podataka.
- SciPy – biblioteka s različitim modulima, od kojih su moduli *find_peaks*, *butter* i *filtfilt* korišteni za filtriranje EKG signala i detekciju vrhova jer omogućuju uklanjanje šuma iz signala i preciznu identifikaciju R-vrhova.
- Tkinter – Pythonov standardni paket za izradu grafičkog korisničkog sučelja (GUI); korišten je za izradu jednostavnog i interaktivnog sučelja koje omogućuje korisniku odabir datoteka, pregled signala i prikaz rezultata analize.

- Matplotlib – biblioteka za vizualizaciju podataka; korištena je za grafički prikaz EKG signala i detektiranih R-vrhova.

4.3. Izrada aplikacije

Odabrana metoda za pronalazak, odnosno prepoznavanje R-vrhova u EKG signalima je Pan-Tompkinsov algoritam. Ovaj algoritam detaljnije je opisan u prethodnom poglavlju. Prednosti ovog algoritma su brza i jednostavna implementacija, zato što koristi osnovne matematičke operacije te ne zahtijeva veliku računalnu snagu ili memoriju.

Funkcija *load_file*, prikazana na slici 4.1., služi za učitavanje EKG signala iz CSV datoteke. Odabrana datoteka prosljeđuje se funkciji *load_ecg*, a očekuje da CSV datoteka sadrži stupce *index*, *time_ms*, *MLII* i *V1*.

```
def load_file(self):
    file_path = filedialog.askopenfilename(filetypes=[("CSV files", "*.csv")])

    if file_path:
        self.file_label.config(text=f"Loaded File: {file_path.split('/')[-1]}")
        ecg_data = self.load_ecg(file_path)

        if ecg_data is not None:
            self.detect_r_peaks(ecg_data)
            self.start_idx = 0
            self.scrollbar.set(0, self.plot_window / len(ecg_data))

def load_ecg(self, file_path):
    try:
        self.ecg_df = pd.read_csv(file_path, skiprows=1, names=["index", "time_ms", "MLII", "V1"])
        self.ecg_df["MLII"] = pd.to_numeric(self.ecg_df["MLII"], errors='coerce')
        ecg_signal_mLII = self.ecg_df["MLII"].dropna().values
        return ecg_signal_mLII

    except Exception as e:
        print(f"Error loading ECG file: {e}")
        return None
```

Slika 4.1. Funkcija *load_ecg*

Na slici 4.2. prikazan je kod funkcije *bandpass_filter*, koja se koristi se filtriranje signala primjenom band-pass filtra. Ovaj tip filtra propušta frekvencije unutar određenog raspona (od *lowcut* do *highcut*), dok prigušuje sve frekvencije izvan tog raspona. Ova funkcija se koristi za uklanjanje šuma ili smetnji u signalu koji su izvan relevantnog frekvencijskog raspona. U slučaju analize srčanih signala, donja granica frekvencijskog pojasa je 5 Hz, dok je gornja

granica frekvencijskog pojasa 40 Hz, što znači da će vrijednosti ispod donje granice i iznad gornje granice biti uklonjene. Prema Nyquist-Shannovom teorem, u danom izrazu (4-2):

$$f_s \geq 2 * f_o \quad (4-2)$$

frekvencija uzorkovanja f_s , često nazivana i Nyquistova frekvencija uzorkovanja, treba biti veća ili jednaka od dva puta frekvencije signala f_o koji se uzorkuje. Važno je razlikovati Nyquistovu frekvenciju od Nyquistove frekvencije uzorkovanja. Nyquistova frekvencija f_N je pola frekvencije uzorkovanja, a definirana je izrazom (4-3):

$$f_N = \frac{f_s}{2} \quad (4-3)$$

Dakle, frekvencija uzorkovanja je 360 Hz, a *nyquist* frekvencija je pola frekvencije uzorkovanja, odnosno 180 Hz. Filtri se obično definiraju u odnosu na Nyquistovu frekvenciju kako bi se ispravno postavili frekvencijski pojasevi. Korišten je *bandpass* filter reda dva (engl. second-order bandpass filter), koji određuje strmost prijelaza između frekvencijskih pojaseva. Normalizacija graničnih frekvencija *lowcut* i *highcut* dobiva se dijeljenjem s Nyquistovom frekvencijom, a rezultat su relativne frekvencije u opsegu 0 i 1. Kako je važno zadržati oblik signala, korišten je Butterworthov filter (*butter*). Dvostruko filtriranje provedeno je pomoću *filtfilt* funkcije, gdje je filter primijenjen jednom naprijed i jednom unatrag; na taj način uklanjaju se fazne distorzije koje bi se pojavile kada bi se filter primjenio samo jedanput. Konačni rezultat *preprocess_signal* metode je filtrirani signal koji se vraća za daljnu analizu, a sada sadrži samo relevantne frekvencije za EKG signal.

```
def bandpass_filter(self, signal, lowcut=0.5, highcut=40.0, order=2):
    nyquist = 0.5 * self.fs
    low = lowcut / nyquist
    high = highcut / nyquist

    b, a = butter(order, [low, high], btype='band')

    filtered_signal = filtfilt(b, a, signal)
    return filtered_signal
```

Slika 4.2. Funkcija *bandpass_filter*

Iduća funkcija u kodu je funkcija *pan_tompkins*, prikazana na slici 4.3. Funkcija implementira Pan-Tompkins algoritam za detekciju R-vrhova u EKG signalima unutar QRS-kompleksa. Algoritam se temelji na nizu koraka poput filtriranja, derivacije, kvadriranja i integracije. Nakon filtriranja signala, gdje se uklanjaju šumovi i smetnje, računa se prva derivacija

filtriranog signala. Upotreba `np.diff(filtered_signal)` računa razlike između susjednih uzoraka signala i pruža aproksimaciju brzine promjene signala, što je važno jer je brzina promjene najizraženija tijekom QRS-kompleksa. Svaki uzorak deriviranog signala se potom kvadrira, kako bi se svi negativni uzorci pretvorili u pozitivne, čime se dodatno naglašavaju varijacije u signalu. U koraku integracije, definirana veličina pokretnog prozora je 120 ms, što odgovara tipičnom trajanju QRS-kompleksa. Normalizacija olakšava postavljanje dinamičkog praga za detekciju R-vrhova u sljedećim koracima, jer su sve vrijednosti u istoj skali.

```
def pan_tompkins(self, ecg_signal):  
  
    filtered_signal = self.bandpass_filter(ecg_signal)  
  
    diff_signal = np.diff(filtered_signal)  
    squared_signal = diff_signal ** 2  
  
    window_size = int(0.12 * self.fs)  
    integrator = np.convolve(squared_signal, np.ones(window_size)/window_size, mode='same')  
  
    normalized_signal = integrator / np.max(integrator)  
  
    return normalized_signal
```

Slika 4.3. Funkcija `pan_tompkins`

Funkcija `detect_r_peaks`, osmišljena je kako bi detektirala R-vrhove u EKG signalu pomoću Pan-Tompkins algoritma. Prema slici 4.4. nakon poziva `pan_tompkins` funkcije, slijedi postavljanje praga i pronalaženje vrhova. Prag (*threshold*) je postavljen kao dinamički prag, a definiran je kao polovica srednje vrijednosti procesuiranog signala (*processed_signal*), što pomaže eliminirati manje promjene koje nisu QRS kompleksi. Iz SciPy biblioteke, koristi se funkcija `find_peaks`, koja detektira vrhove u procesuiranom signalu na osnovu nekoliko kriterija. Prvi kriterij je da vrhovi moraju biti viši od praga kako bi bili detektirani, a drugi kriterij je da razmak između dva detektirana vrha mora biti barem 0.25 sekundi, što odgovara broju otkucaju srca od maksimalno 240 BPM (engl. *beats per minute*).

```
threshold = 0.5 * np.mean(processed_signal)  
peaks, _ = find_peaks(processed_signal, height=threshold, distance=int(0.25 * self.fs))
```

Slika 4.4. Postavljanje praga (*threshold*) i poziv `find_peaks` funkcije

Kako bi se osigurala točnost, nakon detekcije vrhova, potrebno je dodatno provjeriti pozicije vrhova unutar filtriranog EKG signala. Za svaki detektirani vrh, uzima se mali segment signala. Prikazano na slici 4.5. početak segmenta obuhvaća 50 ms prije i 50 ms nakon detektiranog vrha,

dok je kraj segmenta ograničen na duljinu signala. Dakle, uzima se segment signala koji je 100 ms oko detektiranog vrha. Ako segment ima pozitivne vrijednosti, traži se najviša koristeći `np.argmax(segment)`, koji definira poziciju maksimalne amplitude unutar segmenta. Ukoliko su vrijednosti u segmentu negativne, traži se vrijednost najbliža nuli.

```
refined_peaks = []
for peak in peaks:
    start = max(0, peak - int(0.05 * self.fs))
    end = min(len(ecg_signal_mIII), peak + int(0.05 * self.fs))
    segment = ecg_signal_mIII[start:end]

    if np.max(segment) > 0:
        r_peak = np.argmax(segment) + start
    else:
        r_peak = np.argmin(np.abs(segment)) + start

    refined_peaks.append(r_peak)
```

Slika 4.5. Provjera pozicija vrhova unutar EKG signala

Još jedna provjera, koja služi za uklanjanje lažno pozitivnih R-vrhova je filtriranje prema minimalnom RR-intervalu. Na slici 4.6. minimalan RR-interval je postavljen na 0.3 sekundi, što odgovara brzini srca od 200 otkucaja u minuti. Ako je razmak između trenutnog i prethodno detektiranog vrha veći od definiranog intervala, vrh se dodaje u listu `final_peaks`. Cilj provjere je spriječiti višestruku detekciju unutar istog QRS signala ili detekciju neprirodno bliskih vrhova, koji ne predstavljaju stvarne otkucaje srca.

```
self.final_peaks = []
min_rr_interval = 0.3 * self.fs

for i in range(len(refined_peaks)):
    if i == 0 or (refined_peaks[i] - self.final_peaks[-1]) >= min_rr_interval:
        self.final_peaks.append(refined_peaks[i])
```

Slika 4.6. Filtriranje vrhova prema RR intervalu

Funkcija `scroll_signal`, prikazana na slici 4.7., omogućuje pomicanje prikazanog EKG signala. Zbog preglednosti, maksimalan broj uzoraka prikazanih na grafu postavljen je na 2000.

```

def scroll_signal(self, *args):
    if self.ecg_signal is not None:
        if args[0] == 'moveto':
            self.start_idx = int(float(args[1]) * (len(self.ecg_signal) - self.plot_window))
        elif args[0] == 'scroll':
            step = int(args[1]) * self.plot_window // 10
            self.start_idx = max(0, min(len(self.ecg_signal) - self.plot_window, self.start_idx + step))
        self.update_plot()

```

Slika 4.7. Funkcija *scroll_signal*

Zatim se poziva funkcija *update_plot*, čiji je kod prikazan na slici 4.8., a rezultat ova funkcije je vizualni prikaz EKG signala zajedno s detektiranim R-vrhovima. Prilikom vizualizacije, važno je ukloniti prethodne podatke, odnosno „očistiti“ prozor za prikaz kako bi se spriječilo preklapanje novog i starog grafičkog prikaza. Apscisa prikazuje vrijeme u sekundama, dok ordinata prikazuje vrijednosti amplituda. Vremenska os kreira se tako što se vrijednost *time_ms* dijeli s 1000, kako bi vrijeme u milisekundama bilo preračunato u sekunde. Kako je broj uzoraka koji se prikazuju ograničen, *valid_peaks* sprema samo one vrhove koji su unutar trenutno vidljivog dijela signala. Naslov grafa, oznake na osima, legenda te „x“ simboli crvene boje, pružaju korisniku jasan i razumljiv prikaz EKG signala i pripadajućih R-vrhova.

```

def update_plot(self):
    if self.ecg_signal is not None:
        end_idx = min(self.start_idx + self.plot_window, len(self.ecg_signal))
        time_axis = self.ecg_df["time_ms"].values[:len(self.ecg_signal)] / 1000

        self.ax.clear()
        self.ax.plot(time_axis[self.start_idx:end_idx], self.ecg_signal[self.start_idx:end_idx], label='ECG Signal')

        valid_peaks = [p for p in self.final_peaks if self.start_idx <= p < end_idx]
        peak_times = np.array(valid_peaks) / self.fs
        self.ax.plot(peak_times, self.ecg_signal[valid_peaks], 'rx', label='R-peaks')

        self.ax.set_title('ECG Signal with Detected R-peaks')
        self.ax.set_xlabel('Time (seconds)')
        self.ax.set_ylabel('Amplitude')
        self.ax.grid(True)
        self.ax.legend(loc='lower right')

        self.fig.tight_layout()
        self.canvas.draw()

```


Slika 4.8. Funkcija *update_plot*

Korisničko sučelje, prikazano na slici 4.9., vrlo je jednostavno i intuitivno; sastoji se od gumba za učitavanje podataka, teksta koji označava naziv učitane datoteke i prozora za prikaz. Gumb ima oznaku „Load ECG File“, koja korisniku sugerira da pritisne na gumb kako bi učitao EKG datoteku. Pritiskom gumba, otvara se dijaloški okvir za odabir CSV datoteke. Ako se datoteka uspješno učita, signal se prikazuje u prozoru za prikaz.




Slika 4.9. Korisničko sučelje prije učitavanja datoteke

U nastavku slijede grafički prikazi nekoliko EKG zapisa s detektiranim R-vrhovima. Slika 4.10. prikazuje EKG signal koji ima pravilan ritam s prepoznatljivim R-vrhovima, što sugerira stabilnu srčanu aktivnost. Redoviti intervali između R-vrhova upućuju na normalan sinusni ritam, bez očitih znakova aritmija.




Slika 4.10. EKG zapis pacijenta ID100

Na slici 4.11. moguće je uočiti promjenu u obliku QRS kompleksa oko vremenskog intervala od 4 sekunde. Moguća je prisutnost ekstrasistolije, no za konačnu analizu potrebna je daljnja klinička procjena.



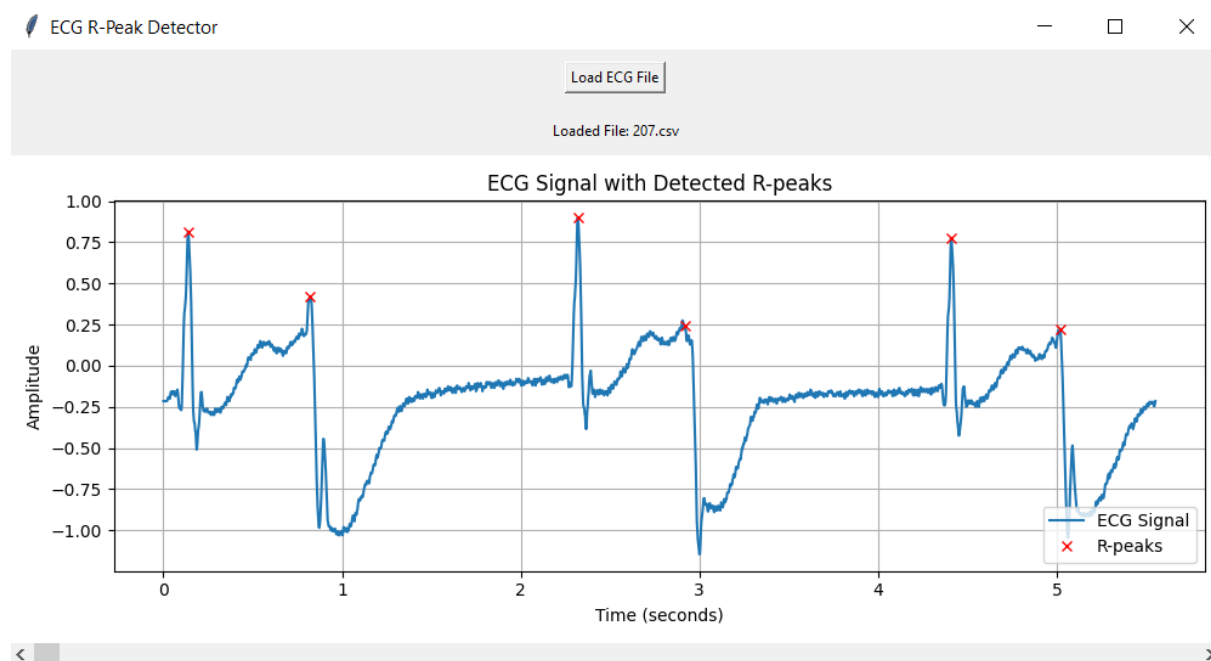
Slika 4.11. EKG zapis pacijenta ID104

Prema slici 4.12. na prikazanom EKG signalu vidljiva je značajna promjena amplitude između 1 i 2 sekunde, što može ukazivati na ekstrasistolu, ali i moguće druge abnormalnosti. Preporučuje se daljnja analiza kako bi se razjasnilo točno stanje.



Slika 4.12. EKG zapis pacijenta ID119

EKG zapis, prikazan na slici 4.13., prikazuje očite promjene u amplitudama i intervalima, što može ukazivati na nekoliko srčanih nepravilnosti. Primjećuje se nepravilan ritam otkucaja, s dužim pauzama između nekih QRS-kompleksa. Moguće interpretacije ovog zapisa uključuju sinusnu bradikardiju, a potencijalno i poremećaji poput ekstrasistola. Ovakvi nepravilni intervali između otkucaja mogu ukazivati na srčane aritmije, što treba potvrditi dodatnom dijagnostičkom analizom.



Slika 4.13. EKG zapis pacijenta ID207

5. ZAKLJUČAK

Opći cilj elektrokardiografije je mjerenje i bilježenje električne aktivnosti srca. Pomoću elektrokardiograma (EKG-a), liječnici mogu analizirati električne impulse koje proizvodi srce tijekom rada. Ovi impulsi prikazuju se kao valovi na grafu, od kojih svaki predstavlja različite faze srčanog ciklusa, poput depolarizacije i repolarizacije srčanog mišića. Elektrokardiografija je ključna u prepoznavanju srčanih nepravilnosti poput aritmija, srčanih udara i drugih stanja koja mogu utjecati na rad srca.

Razvoj tehnologije stekao je važnu ulogu u području medicine, kako u svakodnevnoj praksi, tako i u znanstvenim istraživanjima. Primjena tehnologije dovodi do poboljšanja kvalitete zdravstvene skrbi, čime se povećava učinkovitost u liječenju pacijenata te omogućuje preciznija dijagnostika i praćenje zdravstvenih stanja.

Zadatak rada bio je proučiti i analizirati karakteristike EKG signala, razmotriti dostupne metode za pronalazak i prepoznavanje R-vrhova te razviti aplikaciju koja može precizno prepoznati te vrhove. R-vrh, kao najvažniji segment EKG-a, igra ključnu ulogu u procjeni srčane aktivnosti, a fokus rada je na implementaciji algoritma za učinkovito prepoznavanje R-vrhova.

Pan-Tompkinsov algoritam jedna je od najpoznatijih metoda za detekciju R-vrhova u EKG signalima. Temelji se na obradi signala kroz nekoliko koraka, uključujući filtriranje, deriviranje, kvadriranje, integraciju, postavljanje pragova te detekciju. Filtriranje uklanja šumove i ostale smetnje, dok kvadriranje i deriviranje naglašavaju QRS kompleks, osobito R-vrhove.

Rezultat izrade aplikacije je grafičko korisničko sučelje koje prikazuje detektirane R-vrhove u EKG signalu. Cilj ove aplikacije je služiti kao alat, koji liječnicima olakšava analizu i pomaže pri donošenju dijagnoza. U daljnjem razvoju ovog područja moguća su poboljšanja kombinacijom naprednijih i složenijih metoda. Također, za bolje rezultate, korisno je identificirati ne samo R-vrhove već i ostale dijelove EKG signala te analizirati važne podatke o pacijentu poput godina, građe tijela, lijekova i ostalih bolesti, koji utječu na dijagnozu.

LITERATURA

- [1] R. A. von Kölliker, H. Müller, Nachweis der negativen Schwankung des Muskelstroms am natürlich sich contrahirenden Muskel, Njemačka 1856.
- [2] A. D. Waller, A Demonstration on Man of Electromotive Changes accompanying the Heart's Beat, No. 5, Vol. 8, str (229-234), listopad 1887.
- [3] W. Einthoven, Ein neues Galvanometer, No. 13, Vol. 317. str. (1059-1071), lipanj 1903.
- [4] M. J. Shea, Elektrokardiografija, Hrvatska elektronička medicinska edukacija, HeMED.hr, dostupno na: <https://hemed.hr/Default.aspx?sid=15083>
- [5] „Prikaz normlanog EKG-a“, Wikipedia, dostupno na: <https://hr.wikipedia.org/wiki/Elektrokardiogram>
- [6] J. Krmpotić-Nemanić, A. Marušić, Anatomija čovjeka, Medicinska naklada, Zagreb, 2007.
- [7] J. I. Gupta, M. J. Shea, Biologija srca, Hrvatska elektronička medicinska edukacija, HeMED.hr, dostupno na: <https://hemed.hr/Default.aspx?sid=18416>
- [8] „Presjek građe srca“, Wikipedia, dostupno na: <https://hr.wikipedia.org/wiki/Srce>
- [9] J. Mirat, EKG u kliničkoj praksi, Uvod u elektrokardiografiju, Osijek 2014.
- [10] I. Pišćenec, M. Trnčević, Elektrokardiografija, IZZI, dostupno na: <https://hr.izzi.digital/DOS/92887/92910.html>
- [11] J. Pan, W. J. Tompkins; Tompkins, A Real-Time QRS Detection Algorithm, IEEE Transactions on Biomedical Engineering, No. 3, Vol. BME-32, str. (230–236), ožujak, 1985.
- [12] N. Imtiaz, N. Khan, Pan-Tompkins++: A Robust Approach to Detect R-peaks in ECG Signals, Toronto 2022.
- [13] H. Dubey, Fog Computing in Medical Internet-of-Things: Architecture, Implementation and Applications, 2017.
- [14] P. S. Addison, Wavelet transforms and the ECG: a review, Physiological Measurement, Institute of Physics Publishing, No. 5, Vol. 26., kolovoz, 2005.
- [15] C. Saritha, V. Sukanya, Y. Narasimha Murthy, ECG Signal Analysis Using Wavelet Transforms, Bulg. J. Phys. No. 1, Vol. 35, str. (68-77), veljača 2008.
- [16] S. Jyothi, K. Vanisree, Automatic Detection of ECG R-R Interval using Discrete Wavelet Transformation, No. 4, Vol. 3., travanj 2011., India
- [17] math.e, Hrvatski matematički elektronički časopis, dostupno na: <http://e.math.hr/category/klju-ne-rije-i/kompresija-slike>

- [18] B. Dalbelo Bašić, M. Čupić, J. Šnajder, Umjetne neuronske mreže, Fakultet elektrotehnike i računarstva, svibanj, 2008., dostupno na: https://www.fer.unizg.hr/_download/repository/UmjetneNeuronskeMreze.pdf
- [19] P. Nwankwo, K.A. Akpado, C. Okezie, Development of an Advanced Neuro-Fuzzy Algorithm for Intelligent Temperature Control System, No. 9, Vol. 6, str. (771)
- [20] A. D. Dongare, R. R. Kharde, A. D. Kachare, Introduction to Artificial Neural Network, International Journal of Engineering and Innovative Technology, No. 1, Vol. 2, str. (189-194), srpanj, 2012.
- [21] Moody GB, Mark RG. The impact of the MIT-BIH Arrhythmia Database. IEEE Eng in Med and Biol 20(3):45-50 (May-June 2001). (PMID: 11446209), dostupno na: <https://www.physionet.org/content/mitdb/1.0.0/>

SAŽETAK

Ovaj rad proučava ključne pojmove elektrokardiografije, uključujući građu srca, elektode, vodove, sastavne elemente EKG signala te interpretaciju elektrokardiograma. Navedeni pojmovi pružaju temelj za daljnje razumijevanje i izradu aplikacije. Zadatak rada je pronaći ili prepoznati R-vrhove unutar EKG signala, a neke od postojećih metoda su Pan-Tompkinsov algoritam, wavelet transformacija te neuronske mreže. Aplikacija za detekciju R-vrhova u EKG signalima razvijena je pomoću Pan-Tompkinsovog algoritma. Glavni koraci ovog algoritma za obradu signala su filtriranje, derivacija signala, kvadriranje i integracija. Implementacija aplikacije rezultirala je preciznom detekcijom R-vrhova te njihovom vizualizacijom unutar EKG signala. Aplikacija je testirana na različitim zapisima iz MIT-BIH Arrhythmia baze podataka i pokazala je visoku točnost u detekciji R-vrhova. Međutim, određeni šumovi i smetnje mogu utjecati na preciznost detekcije, što ukazuje na važnost daljnje optimizacije algoritma kako bi se smanjio broj lažno pozitivnih i lažno negativnih detekcija. Ovaj rad prikazuje kako suvremeni alati i tehnike obrade signala mogu značajno unaprijediti procese u medicinskoj dijagnostici, omogućujući bržu i precizniju analizu EKG signala.

Ključne riječi: elektrokardiografija, neuronske mreže, Pan-Tompkinsov algoritam, R-vrhovi, wavelet transformacija.

ABSTRACT

Finding or recognizing the R-peak in the ECG

This paper examines key concepts of electrocardiography, including heart structure, electrodes, leads, components of ECG signals and interpretation of electrocardiograms. These concepts provide the basis for further understanding and creation of the application. The task of this paper is to find or recognize R-peaks within the ECG signal, and some of the existing methods are Pan-Tompkins algorithm, wavelet transformation and neural network. The R-peak detection application in ECG signals was developed using the Pan-Tompkins algorithm. The main steps of this algorithm are filtering, signal derivation, squaring and integration. Implementation of the application resulted in accurate detection of R-peaks and their visualization within the ECG signal. The application was tested on various records from the MIT-BIH Arrhythmia database and showed high accuracy in R-peak detection. However, certain noise and disturbances may affect the accuracy of detection, indicating the importance of further optimization of the algorithm in order to reduce the number of false positive and false negative detections. This paper shows that modern tools and techniques for signal processing can significantly improve processes in medical diagnostics, enabling faster and more precise analysis of ECG signals.

Keywords: electrocardiography, neural networks, Pan-Tompkins algorithm, R-peaks, wavelet transformation.