

Pregledni rad: Modeli dubokog učenja za detekciju atrijske fibrilacije

Amina Tihak
Univerzitet u Sarajevu
Elektrotehnički fakultet
Sarajevo, Bosnia i Hercegovina
0000-0001-9459-8442

Dusanka Boskovic
Univerzitet u Sarajevu
Elektrotehnički fakultet
Sarajevo, Bosnia i Hercegovina
0000-0002-7535-4693

Samim Konjicija
Univerzitet u Sarajevu
Elektrotehnički fakultet
Sarajevo, Bosnia and Hercegovina
0000-0003-4895-6223

Sažetak – Posljednjih godina primjetan je značajan porast interesovanja u oblasti automatske detekcije srčanih aritmija primjenom modela dubokog učenja. Atrijska fibrilacija je najčešća dugotrajna srčana aritmija u kliničkoj praksi čija detekcija postaje jedna od važnijih zadataka savremene kardiologije. Prilikom implementacije modela dubokog učenja stručnjaci se suočavaju s različitim rješenjima koja donose određene prednosti, ali također nameću i određena ograničenja na njihovu primjenu. Sistematski pregled literature omogućava razumijevanje različitih implementacijskih rješenja i otkrivanje prostora za buduća unapređenja. Početni skup od 370 članaka filtriranih prema ključnim riječima od interesa, sistematski je sužen na 32 članka koja su u fokusu ovog rada. Cilj rada je da opisom: najčešće korištenih baza EKG signala; tehnika pretprocesiranja signala; formata prikaza ulaznih signala u modele dubokog učenja; korištenih arhitektura modela; izbora broja i vrste izlaznih klasa; i postignutih performansi modela; olakša donošenje ključnih odluka za buduća istraživanja.

Ključne riječi - detekcija atrijske fibrilacije, modeli dubokog učenja, sistematski pregled literature, PRISMA.

I. UVOD

Atrijska fibrilacija (engl. *Atrial Fibrillation*, AF) je najčešća dugotrajna srčana aritmija (Hindricks et al, 2021, pp. 373-498). Predstavlja ozbiljan zdravstveni problem, u smislu povećanog rizika od razvoja moždanog udara, sistemске embolije i zatajenja srca (Dai et al, 2017, pp. 574-582). AF je povezana sa pterostrukim povećanjem rizika obolijevanja od moždanog udara (Rowan et al, 2021), što je drugi vodeći uzročnik smrti i treći vodeći uzrok smrti i invaliditeta u kombinaciji u svijetu (Feigin et al, 2022, pp. 18-29). AF je također povezana s trostrukim povećanjem rizika od zatajenja srca, dvostrukim povećanjem rizika od razvoja demencije i smrtnosti svih uzročnika (Rowan et al, 2021), kao i u mjerljivo smanjenju kvalitete života (Wu et al, 2022, p. 100386). S obzirom na to da je vodeći uzročnik morbiditeta i mortaliteta, predstavlja značajan teret za pacijente, društveno zdravlje i zdravstvenu ekonomiju (Hindricks et al, 2021, pp. 373-498).

Incidenca i prevalenca obolijevanja od AF raste širom svijeta, što opravdava naziv globalne epidemije 21. stoljeća. Starosna dob je najvažniji faktor rizika za obolijevanje od AF u općoj populaciji i očekuje se kontinuirani porast incidence i prevalence kao posljedice kontinuiranog povećanja očekivanog životnog vijeka širom svijeta i poboljšanja u liječenju akutnih srčanih stanja (Lippi, Sanchis-Gomar and Cervellin, 2021, pp. 217-221). Prevalenca obolijevanja se povećala 3 puta u posljednjih 50 godina (Kornej et al, 2020, pp. 4-20). Prema procjenama iz 2019.g. kod ukupno 59.7 miliona ljudi širom svijeta dijagnostificirano je AF oboljenje,

što je dvostruko više u odnosu na procjenu iz 1990.g. (Kornej, Benjamin and Magnani, 2021, pp. 516-518). Prema predviđanjima, broj oboljelih će u Sjedinjenim Američkim Državama doseći vrijednost od 6 do 16 miliona do kraja 2050.g. dok se u Evropi taj broj procjenjuje na vrijednost od 14 miliona do kraja 2060.g. (Kornej et al, 2020, pp. 4-20). U Aziji se do kraja 2050.g. očekuje veliki porast broja oboljelih do čak 72 miliona (Kornej et al, 2020, pp. 4-20). Vjerojatnost razvoja AF oboljenja je složena i pod utjecajem bioloških faktora, okolišnih faktora, genetike, epigenetike i društvene determinante (DeLago et al, 2021, pp. 78-83). Alarmantna epidemiološka predviđanja najavljuju daljnji porast ovog stanja tijekom sljedećih nekoliko desetljeća (Saglieetto et al, 2022, p. 361).

Cilj ovog rada je na sistematski način istražiti članke koji se bave problemom AF detekcije i klasifikacije korištenjem koncepata dubokog učenja. Posljednjih godina dogodila se ekspanzija publiciranja u ovoj oblasti što navodi na zaključak da je barem jednom godišnje potrebno dati pregled stanja u oblasti kako bi se sumirali postignuti rezultati te otkrio prostor za buduća unapređenja. U radu je pojašnjen sistematski pristup pretraživanju članaka iz ove oblasti zajedno sa kriterijima koji su korišteni u njihovoj selekciji. Sistematski pregled članaka objavljenih u internacionalnim žurnalima izvršen je pretraživanjem bibliografske baze podataka Web of Science (WoS).

Nakon detaljne analize sadržaja članaka, konstruiran je opći pristup njihovoj analizi koji će omogućiti njihov sistematski pregled i analizu. Usporedbe performansi napravljene su uzimajući u obzir skupove podataka, formate ulaza, modele dubokog učenja i pristupe klasifikacije korištene u ovim studijama. Također dat je pregled i ograničenja modela dubokog učenja zajedno sa prijedlozima za buduću rad u ovoj oblasti.

II. MOTIVACIJA

Normalni srčani ritam započinje pravilnu inicijaciju ritma generisanjem električnog impulsa u sinusatrijalnom čvoru, nakon čega slijedi atrijska, a zatim ventrikularna aktivacija (Wakili et al, 2011, pp. 2955-2968). AF je poremećaj srčanog ritma koji nastaje kao posljedica pojačanog ili abnormalnog formiranja impulsa (tj. žarišne aktivnosti), poremećaja provođenja (tj. ponovnog ulaska) ili abnormalnog pokretanja ili širenja električnih pobudnih impulsa unutar srca koji dovode do srčanog zastoja (Bukata et al, 2022, pp. 210-219). Kretanje brzih, nepravilnih i nekoordiniranih električnih impulsa po atrijumu izaziva njegove kontrakcije koje zbog prirode mehanizma rada srca ne mogu biti popraćene kontrakcijom ventrikula pa nastaje mehanička disfunkcija

atrija. Nesinhronizirane kontrakcije atrijske i ventrikularne, dovode do zadržavanja krvi u atrijskoj šupljini što posljedično dovodi do stvaranja krvnih ugrušaka, koji mogu dovesti do ozbiljnih komplikacija poput moždanog udara ili smrti. Uzrok nastanka AF se može tražiti u pretkomorskoj fibrozi, hipokontraktilnosti, masnoj infiltraciji, inflamatornom procesu, vaskularnom remodeliranju, ishemiji, disfunkciji jonskih kanala (Cha, 2018, pp. 170-172), kao i arterijskoj hipertenziji, hipertrofiji srčanog mišića, obolijevanju mitralne i trikuspidalne valvule, disfunkciji miokarda lijeve ili desne komore ili postojanju urođene srčane anomalije.

AF se klasificira kao prva dijagnosticirana kod prve pojave AF epizoda prilikom dijagnosticiranja, bez obzira na trajanje, prisustvo i ozbiljnost simptoma povezanih sa ovim oboljenjem (Hindricks et al, 2021, pp. 373-498). Nekada pojava prvih AF epizoda uopće ne mora biti popraćena simptomima, što rano otkrivanje takvih epizoda čini gotovo nemogućim korištenjem konvencionalnih, odnosno ambulantnih uređaja za praćenje rada srca. Parokzimalna AF prestaje spontano ili uz intervenciju unutar sedam dana od trenutka pojave (Hindricks et al, 2021, pp. 373-498). Obično nestaje unutar 24 do 48 sati, a razlog njenog nastanka obično nije poznat. Zbog svoje prirode, otkrivanje parokzimalne AF je također dosta teško. Međutim njena detekcija u ovoj fazi od izuzetnog je značaja budući da su izgledi za izlječenje, korištenjem odgovarajuće terapije, u ovoj fazi vrlo visoki. Ako se AF epizoda produži više od sedam dana, uključujući i epizode prekinute kardioverzijom, a što uključuje korištenje određenih lijekova ili primjenu električne kardioverzije, AF se počinje klasificirati kao perzistentna AF. Kod ovakvih AF epizoda malo je vjerovatno da će se same zaustaviti, pa je potrebna primjena odgovarajuće terapije. U ovakvim slučajevima većinom je pacijentima od ranije dijagnosticirana AF i uzimaju odgovarajuću terapiju. Ukoliko se njeno trajanje produži na više od 12 mjeseci, onda se AF klasificira kao dugotrajna perzistentna AF. U tom slučaju usvaja se strategija kontrole srčanog ritma. Ukoliko tretman lijekovima, kardioverzija ili hirurški zahvati ne daju očekivane rezultate, onda se AF klasificira kao permanentna. U ovoj fazi se dalje na dogovor ljekara i pacijenta ne poduzima nikakav dalji pokušaj vraćanja i održavanja normalnog sinusnog srčanog ritma. U ovoj fazi AF epizode se ne završavaju, a njihovo trajanje je doživotno.

Prema dogovoru, AF epizoda trajanja najmanje 30 sekundi može se dijagnosticirati kao klinička AF. Dijagnostički se verificira elektrokardiografskim (EKG) zapisom, a zapis se korelira sa ehokardiografijom, odnosno 24-satnim EKG Holter monitoringom, kojim se kontinuirano tokom 24 sata prati elektrokardiografski zapis pacijenta (Kirchhof et al, 2017, pp. 373-498.). Evropsko kardiološko udruženje u saradnji sa Evropskim udruženjem kardiotorakalne hirurgije izdali su preporuku kojom se definira da se za dijagnosticiranje AF oboljenja može koristiti EKG signal sa 12 odvoda ili signal sniman sa jednog odvoda ali trajanja minimalno 30 s (Hindricks et al, 2021, pp. 373-498).

EKG zapis praćen AF epizodama odlikuje se izobličenom izoelektričnom linijom, RR intervalima vremenski nejednakog trajanja i izobličanim ili upotpunosti odsutnim P talasima (Hindricks et al, 2021, pp. 373-498). Zbog poremećaja u prenosu i ponovnom ulasku generisanih električnih impulsa kroz provodna tkiva atrijske, atrijske se kontinuirano kontrahira izazivajući vrlo brzu, kontinuiranu, nepravilnu i haotičnu aktivnost koja se u EKG signalu može

prepoznati kao aktivnost fibrilatornih talasa. Sistemi automatskog prepoznavanja AF oboljenja oslanjaju se na dvije ključne značajke u signalu: izobličeni ili potpuno odsutni P talasi i/ili nepravilni obrazac pojavljivanja RR intervala u signalu (Murat et al, 2021, p. 11302). Mala vrijednost amplitude P talasa uz izobličenu izoelektričnu liniju i prisutne šumove u signalu, otežava pouzdanu detekciju P talasa u signalu što posljedično dovodi do degradiranja performansi algoritama utemeljenih na prepoznavanju P talasa. S obzirom na to da je amplituda R talasa dominantna, nerijetko algoritmi za detekciju P talasa prvo pronalaze R talas a onda u njegovoj neposrednoj blizini traže vrh P talasa. Mnogi algoritmi oslanjaju se samo na detekciju nepravilnih RR intervala za detekciju AF oboljenja (Murat et al, 2021, p. 11302). Detekcija nepravilnih obrazaca pojavljivanja RR intervala u signalu je jednostavna metoda, ali ne i dovoljna za uspostavljanje same dijagnoze AF oboljenja. Dodatno, neki pacijenti možda neće imati nepravilne obrasce pojavljivanja RR intervala u signalu tokom početka tretmana liječenja (Chen et al, 2021, p. 106009). Eksperti iz oblasti su saglasni u tome da za detekciju AF oboljenja nije dovoljno poznavati trajanje RR intervala, već i valne karakteristike P talasa. Zbog prirode EKG signala koji je nelinearan i niske amplitude, može doći do zanemarivanja malih promjena u signalu od strane kardiologa. Osim toga, uspostavljanje dijagnoze AF oboljenja nepotpomognute od strane sistema za automatsku klasifikaciju, je dugotrajan i iscrpan proces zbog toga što se EKG signali snimaju tokom dugih vremenskih razdoblja (Kim et al, 2022, pp. 1-17). Kako bi se prevazišli ovi problemi, predloženi su brojni algoritmi učenja za potrebe poboljšanja tačnosti u procesu dijagnostike AF oboljenja.

Posljednjih desetljeća došlo je do značajnog porasta interesa u oblasti automatske klasifikacije različitih srčanih aritmija na osnovu EKG signala (Petmezas et al, 2021, p. 102194). Većina ovih algoritama zahtijeva pretprocesiranje signala sa ciljem minimizacije izobličivosti izoelektrične linije i uklanjanja artefakata u signalu, a koji posljedično mogu uzrokovati probleme u izdvajanju značajki iz EKG signala. Izdvajanje i selekcija značajki predstavljaju najosjetljiviji dio procesa detekcije srčanih aritmija (Sahoo et al, 2020, pp. 551-561). Izdvajanje značajki predstavlja proces odabiranja najizrazitijih značajki prisutnih u signalu a koje se koriste za njegov opis i predstavljanje (Salau and Jain, 2019, pp. 158-164). Najčešće korištene značajke za detekciju srčanih aritmija su morfološke značajke EKG signala izdvojene iz vremenskog, frekventnog i vremensko-frekventnog domena, kao i složeni prikazi srčanih otkucaja (Alfaras, Soriano and Ortín, 2019, p. 103) te entropija (Zhang et al, 2021, pp. 165-173). Selekcija značajki je proces dobijanja podskupa iz izvornog skupa izdvojenih značajki signala prema određenom kriteriju za njihovo odabiranje, a koji za cilj ima odabrati relevantne značajke signala, uklanjanjem onih nebitnih i suvišnih (Cai et al, 2018, pp. 70-79). Selekcija značajki za detekciju srčanih aritmija najčešće je zasnovana na upotrebi tehnika filtriranja, omotačkih i ugrađenih tehnika (Alfaras, Soriano and Ortín, 2019, p. 103). Izdvajanje i selekcija značajki vrši se na osnovu uputa datih od strane eksperata iz oblasti ili iz sistematskih pregleda literature. Ovako izdvojeni i selektovani skup značajki signala predstavlja ulazni skup za različite algoritme mašinskog učenja. Neki od najčešće korištenih algoritama mašinskog učenja su: naivni Bayesov klasifikator, linearna diskriminantna analiza, K najbližih susjeda, skriveni

Markovljevi model, logička regresija, metoda potpornih vektora, stabla odlučivanja, algoritmi sekvencijalnih sličnosti, algoritmi teorije grafova i klasifikacija temeljena na znanju (Rizwan et al, 2020, pp. 219-239). Iako postoje brojna rješenja za detekciju srčanih aritmija, svako od njih ima jedno ili više ograničenja: 1) dobre performanse na pažljivo odabranim EKG signalima, 2) gubitak srčanih otkucaja u procesu filtriranja šuma ili izdvajanja značajki iz signala, 3) ograničen broj snimaka EKG signala za različite tipove aritmija (Jun et al, 2018) 4) nedostatak objašnjivosti za patofiziološke osnove ishoda klasifikacije (Sager et al, 2021, p. e0261571).

U odnosu na tradicionalne algoritme mašinskog učenja koji zahtijevaju pretprocesiranje signala te ručno izdvajanje i selekciju značajki sa ciljem klasifikacije srčanih aritmija, razvijeni su algoritmi dubokog učenja sa ciljem prevazilaženja prethodno pomenutih poteškoća i postizanjem boljih performansi. Dok se, kako je ranije pomenuto, algoritmi mašinskog učenja oslanjaju na ručno izdvajanje i selekciju značajki iz signala karakterističnih za određena oboljenja i klinička stanja, algoritmi dubokog učenja imaju mogućnost direktnog učenja značajki iz signala. Algoritmi temeljeni na dubokom učenju su jedinstvenim hijerarhijskim strukturama samostalno izdvajaju značajke duboke razine iz signala i svakim danom se sve više nameću kao nova rješenja za analizu različitih bioloških signala. Ovi algoritmi imaju potencijal naučiti i izdvojiti sve važne značajke signala koje bi i procesu ručnog izdvajanja bile izdvojene, ali su u stanju izdvojiti i prethodno nepoznate značajke iz signala (Murat et al, 2020, p. 103726). Istraživanja su pokazala da se upotrebom nekih ručno izdvojenih vremenskih značajki u kombinaciji s neobrađenim signalima poboljšava performansa dubokih mreža (Murat et al, 2021, p. 11302). Kako je u posljednje vrijeme primjetan porast interesovanja u istraživanju ovog pristupa za otkrivanje AF oboljenja (Zhang et al, 2021, pp. 165-173), u radu je dat pregled različitih modela dubokog učenja. Neki pristupi dubokog učenja i dalje vrše pretprocesiranje signala što omogućava minimizaciju izobličenosti izoelektrične linije i uklanjanje artefakata u signalu, kao i poduzorkovanje i normalizaciju vrijednosti signala sa ciljem boljeg izdvajanja morfoloških osobina signala, poboljšanja performansi modela, ali i smanjenja vremenske i dimenzijske složenosti modela. S druge strane postoje pristupi u kojima se koristi isključivo sirovi signal, bez prethodnog pretprocesiranja, ali i pristupi u kojima se ručno izdvojene značajke signala kombiniraju sa sirovim signalom.

Odabir parametara sloja i hiperparametara predstavljaju važan optimizacijski problem prilikom odabira arhitekture modela dubokog učenja. Stoga cilj ovog rada je ukazati na prednosti ovog pristupa za potrebe detekcije AF oboljenja, ali i identificirati poteškoće sa kojima se istraživači susreću u ovoj oblasti te otkriti prostor za buduća unapređenja.

III. MATERIJALI I METODE

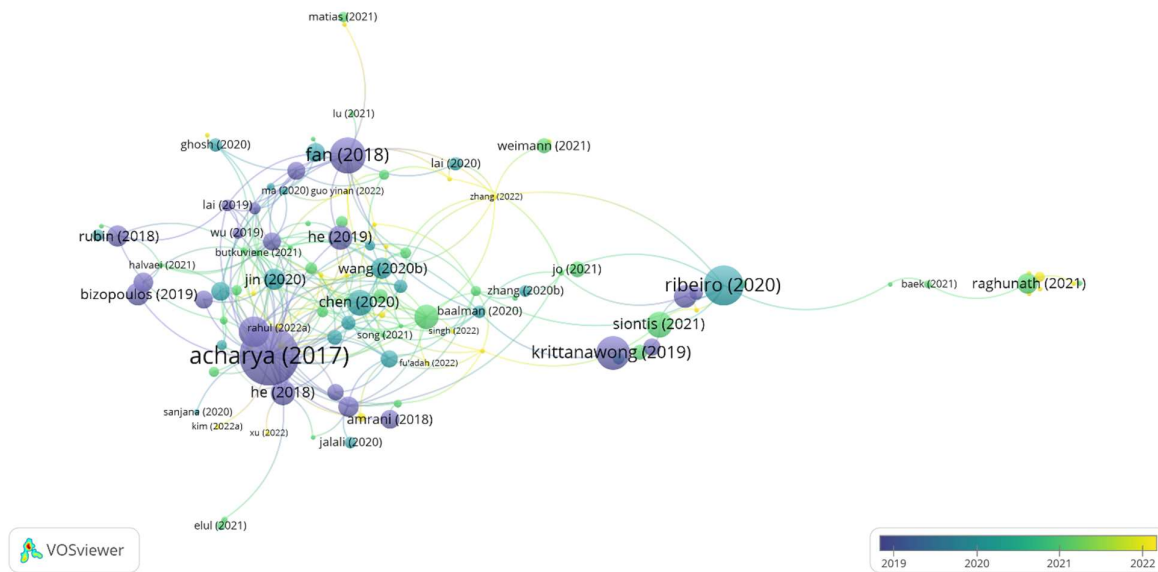
Posljednjih godina značajno raste broj publikacija u oblasti detekcije i klasifikacije srčanih aritmija korištenjem različitih pristupa počevši od statističke analize, mašinskog učenja do dubokog učenja. Zbog navednog, istraživačima postaje sve veći izazov ostati u toku sa svim najnovijim otkrićima u ovoj oblasti. Sistematski pregled literature pored toga što omogućava sumiranje postignutih rezultata u oblasti

a iz kojih se mogu identificirati budući istraživački prioriteti, omogućava i da se identificiraju pitanja na koja provedba pojedinačnih studija ne bi mogla odgovoriti, identificiraju problemi u primarnom istraživanju koje bi trebalo ispraviti u budućim studijama, i evaluiraju teorije o tome kako ili zašto se javljaju određeni fenomeni (Page et al, 2021, p. 105906). Sistematski pregled literature predstavlja pregled u kojem se formuliraju pitanja i koriste sistematske i eksplicitne procedure za pronalaženje, odabir i kritičku procjenu relevantnog istraživanja kako bi se prikupili i ocijenili podaci iz studija uključenih u pregled (Ahsan and Siddique, 2022, p. 102289). Sistematski pregled literature izvještava se u skladu sa preporučenim smjernicama za izvještavanje u sistematskim pregledima i meta-analizama (engl. *Preferred Reporting Information for Systematic Reviews and Meta-Analysis*, PRISMA).

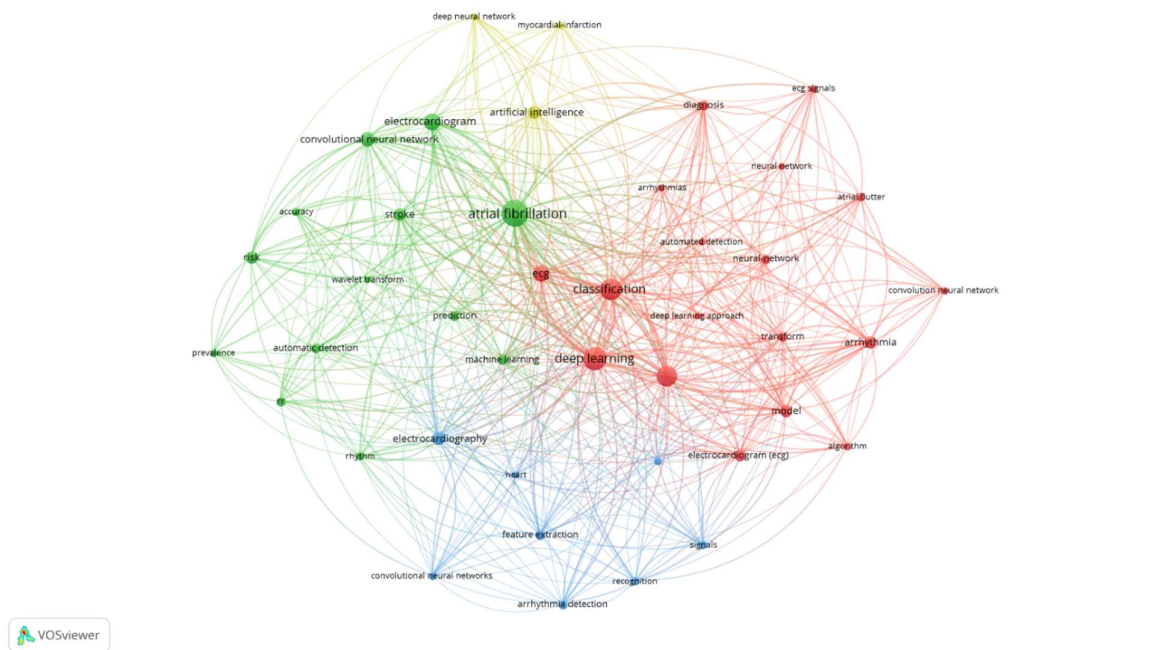
Opis rezultata postupka pretraživanja i odabira, od broja članaka identificiranih u pretraživanju do broja istraživanja uključenih u sistematski pregled, po mogućnosti se predstavlja dijagramom toka (Page et al, 2021, p. 105906). Sistematski pregled literature započinje odabirom bibliografskih baza podataka u kojima će članci biti pretraživani, a u ovom radu korištena je baza Web of Science (WoS). Sistematski pregled literature zahtijeva razvoj strategije pretraživanja korištenjem ključnih riječi. Nakon pregleda brojnih članaka objavljenih u posljednje vrijeme a koji se bave problemom detekcije AF oboljenja korištenjem DL modela izdvojene su ključne riječi. Pretraživanje je izvršeno po ključnim riječima: "atrijalna fibrilacija" I "duboko učenje" ILI puni ili skraćeni naziv specifičnog DL modela, koje se mogu pominjati bilo gdje unutar samog teksta članka. Pretraživanje se može izvršiti i pretraživanjem ključnih riječi samo unutar određenih dijelova teksta poput naslova, sadržaja ili ključnih riječi izdvojenih od strane autora, što predstavlja jedan od najjednostavnijih pristupa pretraživanja ali se takvim pristupom mogu eliminisati i članci od izuzetnog značaja za istraživanje.

Pretraživanjem po ključnim riječima unutar cijelog teksta članka pronađeno je ukupno 146 relevantnih članaka. Bibliometrijska analiza postala je važan alat za kvalitativno sažimanje razvoja neke akademske oblasti i otkrivanja njenih budućih istraživačkih trendova (Tao, 2022). U bibliometriji, distribucija autora članaka i distribucija učestanosti riječi osnovni su sadržaj analize (Tao, 2022). U ovom radu su korišteni CiteSpace i VOSviewer bibliometrijski softveri za pomenutu analizu, pri čemu je razmatrano 146 članaka iz WoS baze. Na slici 1. prikazana je analiza distribucije autora članaka koja može otkriti odnose između autora i njihovih radova. Analiza distribucije učestanosti riječi koristi se za određivanje žarišta istraživanja i trendova u oblasti (Tao, 2022). Na slici 2. prikazana je analiza distribucije učestanosti riječi odabrane referentne literature.

Kako bi se u razmatranju uvažile analize distribucije autora i učestanosti riječi, sistematski pregled literature je proširen na ukupno 370 članaka. Pored 146 članaka izdvojenih iz WoS baze, u razmatranje su uključena i 224 članka na osnovu pretraživanja referenci prethodno izdvojenih članaka. Nakon toga se pristupilo procesu isključivanja članaka. Na osnovu naslova isključeno je 197 članaka, dok je na osnovu sažetka isključeno njih 88. Preostali članci su isključeni na osnovu čitanja cjelokupnog teksta, njih ukupno 52.



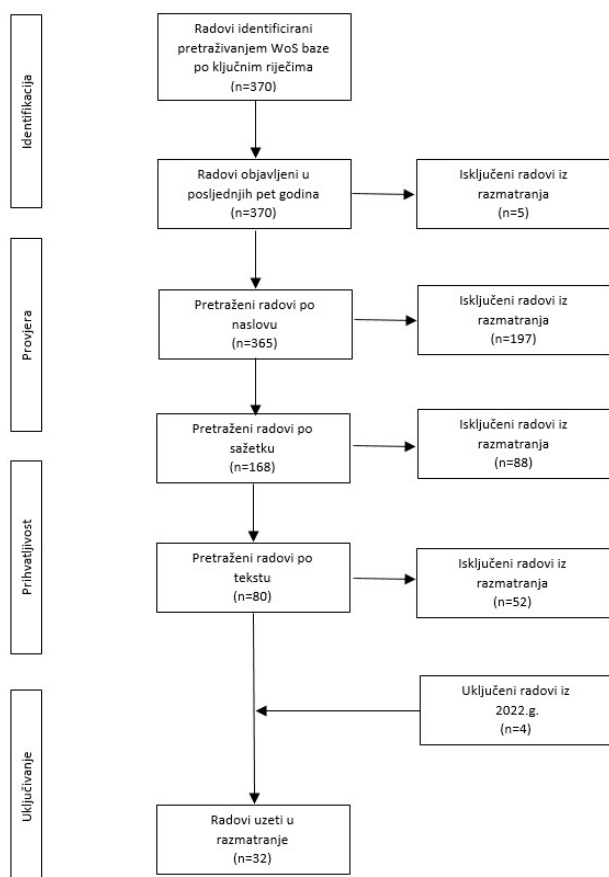
Slika 1. Analiza distribucije autora odabrane referentne literature (generisana od strane VOSviewer softvera).



Slika 2. Analiza distribucije učestanosti riječi odabrane referentne literature (generisana od strane VOSviewer softvera).

Za prikaz cjelokupnog procesa odbacivanja članaka i naznaku glavnih uzroka njihovog odbacivanja, u skladu sa PRISMA načinom izvještavanja preporučeno je koristiti dijagram toka. U ovom sistematskom pregledu literature uzroci za odbacivanje članaka su: 1) članci u kojima fokus nije detekcija i klasifikacija AF, već različite srčane aritmije pa između ostalog i AF, 2) članci u kojima nisu korišteni EKG signali snimani korištenjem ambulatornih uređaja poput elektrokardiografa i Holter uređaja, 3) članci objavljeni prije 2017.g., 4) članci koji nisu prevedeni na engleski jezik. U analizu su dodatno uključena četiri članka objavljena u 2022.g. Kompletan proces identifikacije članaka, te njihovog

pregleda, procjene prihvatljivosti, te isključenja određenog broja članaka ili naknadno uključivanje pojedinih članaka prikazan je na PRISMA dijagramu toka na slici 3.



Slika 3. PRISMA dijagram toka sistemskog pregleda literature modela dubokog učenja za detekciju atrijalne fibrilacije

A. Baze signala

Većina istraživača za potrebe detekcije i klasifikacije AF oboljenja koristi standardne baze signala koje su opće poznate u ovoj oblasti, lahko dostupne i nemaju problem sa nebalansiranim podacima. Međutim ostaje nepoznanica kakve performanse bi predloženi DL modeli imali da se primijene na signalima iz relanog svijeta koji evidentno sadržavaju više šumova. Većina DL modela trenira se nad jednom bazom signala, dok se njihovo testiranje provodi metodom unakrsne validacije. S obzirom na to da se i treniranje i testiranje DL modela vrši nad istom bazom signala, teško je procijeniti koliko je pouzdana izvedba unakrsne validacije (Zhang et al, 2021, pp. 165-173). Drugim riječima, postoji mogućnost pojave pretreniranosti DL modela koji ima zadovoljavajuće performanse nad podacima koji su mu od ranije poznati, dok nad neviđenim podacima ima znatno lošije performanse. Do pretreniranosti modela obično dolazi zbog: 1) intraindividualne sličnosti između više različitih EKG signala koji su snimani na manjem broju ispitanika, a koji mogu dovesti do toga da DL model nauči određene osobne značajke iz signala karakteristične za ispitanika a ne za samo AF oboljenje, 2) interindividualne razlike između različitih ispitanika, a koje mogu dovesti do opadanja performansi kada se DL model testira nad neviđenim podacima (Zhang et al, 2021, pp. 165-173). Sa ciljem povećanja generalizacije DL modela i smanjenja problema njegove pretreniranosti, u tabeli I dat je pregled svih korištenih baza AF signala u sistematski odabranim člancima za dalju analizu.

TABELA I EKG BAZE SIGNALA KORIŠTENE U ČLANCIMA ZA DETEKCIJU I KLASIFIKACIJU ATRIJALNE FIBRILACIJE UTEMELJENA NA MODELIMA DUBOKOG UČENJA

Baza signala	Broj snimaka	Osobine signala (trajanje, frekvencija uzorkovanja, broj odvoda)	Anotacije u signalu
MIT-BIH Atrial Fibrillation (afdb)	25	10 h, 250 Hz, 2	anotacije otkucaja i ritma
MIT-BIH Arrhythmia (mitdb)	48	30 min, 360 Hz, 2	anotacije otkucaja, ritma i kvalitete signala
MIT-BIH Normal Sinus Rhythm Database (nsrdb)	18	24 h, 128 Hz, 2	anotacije otkucaja
Long-Term AF Database (ltafdb)	84	24 h, 128 Hz, 2	anotacije otkucaja
AF Termination Challenge Database (aftdb)	30	1 min, 128 Hz, 2	anotacije otkucaja
PhysioNet/CinC Challenge 2017	8528	9 – 61 s, 300 Hz, 1	anotacije otkucaja, ritma i kvalitete signala
Paroxysmal AF Prediction Challenge Database (PAFDB)	100	30 min, 128 Hz, 2	anotacije otkucaja
Fantasia Database (fantasia)	40	2 h, 250 Hz, 1	anotacije otkucaja
BIDMC Congestive Heart Failure database	15	20 h, 250 Hz, 2	anotacije otkucaja
China Physiological Signal Challenge (CPSC) 2018	9831	6 – 60 s, 500 Hz, 12	anotacije ritma
Shaoxing People's Hospital Database	45152	10 s, 500 Hz, 12	anotacije otkucaja
Sejong EKG baza signala prikupljenih iz Mediplex Sejong Hospital (MSH)	-	10 s, 500 Hz, 12	anotacije otkucaja i ritma
Sejong EKG baza signala prikupljenih iz Sejong General Hospital (SGH)	-	10 s, 500 Hz, 12	anotacije otkucaja i ritma
PTB-XL ECG dataset	21837	10 s, 400 Hz, 12	anotacije otkucaja i ritma
Chapman ECG dataset	10605	10 s, 500 Hz, 12	anotacije otkucaja
Indonesian Hospital dataset	51 13	10 s, 500 Hz, 2 10 s, 400 Hz, 2	-
Druge interne baze signala	Detalji su dostupni u pojedinačnim radovima		-

B. Pretprocesiranje signala

Pretprocesiranje signala može da obuhvati jednu ili više faza obrade signala a koje se uobičajeno sastoji iz izdvajanja šuma iz korisnog signala, normalizacije vrijednosti amplitude i poduzorkovanja signala. Faza pretprocesiranja signala u proces implementacije može biti i izostavljena ali većina članaka, koji su izdvojeni u sklopu sistematskog pregleda literature u ovoj oblasti, i dalje naglašavaju njen značaj i daju preporuku za njeno korištenje.

EKG signali, pored korisnog signala, sadržavaju i različite šumove koji se manifestuju kroz sličnu morfologiju u odnosu na korisni signal pa samim tim u značajnoj mjeri otežavaju njegovo tumačenje. Šumovi se s obzirom na njihovo porijeklo mogu klasificirati u dvije skupine šumova, nefiziološke i fiziološke prirode. Šumovi nefiziološke prirode su: 1) šumovi koje proizvodi sama oprema koja se koristi za snimanje i obradu signala, 2) šumovi koji potiču od druge prisutne medicinske opreme, 3) šumovi koji nastaju zbog interferencije elektroenergetskih sistema, 4) šumovi elektrodskih kontakata koji nastaju kao posljedica gubitka kontakta između elektroda i kontaktne površine kože. Šumovi fiziološke prirode su: 1) šumovi izazvani pacijentovim kretanjima koji nastaju kao posljedica pomijeranja elektroda u odnosu na kontaktnu površinu kože i dovode do varijacija impedanse između elektrode i kože, izazivajući tako promjene potencijala kod EKG signala, 2) elektromiografski šum koji potiče od električne aktivnosti izazvane mišićnim kontrakcijama, 3) šum izobličene izoelektrične linije signala u većini slučajeva prouzorokovana ritmičnim kretanjima grudnog koša uslijed disanja (Kalezić, Stojanović and Mirković, 2010, p. 954-958). Izobličena izoelektrična linija signala kod AF oboljenja, uzrokovana je i pretkomorskim treperenjem koje se manifestuje kroz talasanje osnovne linije signala. Filtriranje signala ima za cilj ublažiti prisustvo komponenti šuma u korisnom signalu za potrebe identifikacije i izdvajanja morfoloških komponenti signala. Sa ciljem ublažavanja komponenti šumova prisutnih u korisnom signalu, mogu se primijeniti različite metode filtriranja signala, a u nastavku teksta dat je kratki pregled metoda korištenih u izdvojenim člancima.

U člancima (Petmezas et al, 2021, p. 102194; Salinas-Martínez et al, 2020, pp. 1-4) predloženo je korištenje Butervortovog visokopropusnog filtera 7. reda sa graničnom frekvencijom 0.5 Hz za eliminaciju talasanja izoelektrične linije signala dok je za eliminaciju interferencije elektroenergetskih sistema i visokofrekventnog šuma predloženo Butervortov niskopropusni filter 6. reda. U članku (Wang, 2020a, pp. 670-679) za eliminaciju interferencije mreže predloženo je korištenje notch filtera granične frekvencije 50 Hz, dok je u članku (Lai et al, 2019, pp. 130074-130084) za eliminaciju istog šuma predloženo korištenje kliznog filtera. U članku (Lai et al, 2019, pp. 130074-130084) predloženo je korištenje medijan filtera i pojasno-propusnog filtera u opsegu frekvencija od 0.5 do 100 Hz za razliku od članka (Wang, 2021, pp. 320-332) gdje je predložen uži opseg frekvencija od 0.5 do 30 Hz za eliminaciju problema talasanja izoelektrične linije signala i izdvajanja visokofrekventnog šuma. Za eliminaciju talasanja izoelektrične linije signala u članku (Rubin et al, 2018, pp. S18-S21) predložen je filter pomične srednje vrijednosti sa dužinom prozorske funkcije od 0.3 s, dok je u članku (Rahul and Sharma, 2022, p. 103270) predložen medijan filter sa različitim dužinama prozorske funkcije. U člancima (Acharya et al, 2017, pp. 81-90; Cao et al, 2020, p. 101675; Feng and Fan, 2022, p. 103663; He et al, 2018, p. 1206; Jin et al, 2020, p. 105460; Nurmaini et al, 2020, pp. 304-317; Wang, 2020a, pp. 670-679) korištena je wavelet transformacija signala za uklanjanje šumova prisutnih u signalu. U članku (Erdenebayar et al, 2019) korištena je

kombinacija pojasno-propusnog filtera i diskretne wavelet transformacije za eliminaciju talasanja izoelektrične linije i visokofrekventnih komponenti u signalu.

Baze signala sadržavaju signale različitih frekvencija uzrokovanja, te ukoliko se žele koristiti signali iz više takvih baza, neophodno ih je reuzorkovati na zajedničku ciljnu frekvenciju, koja može biti frekvencija uzorkovanja signala jedne od baza, obično ona najniže vrijednosti, ili može biti odabrana potpuno nova vrijednost. Frekvencija uzorkovanja signala direktno utiče na kvalitetu signala u smislu vidljivosti morfoloških karakteristika signala. Nepogodno odabrana frekvencija uzorkovanja signala dovodi do narušavanja kvaliteta signala, što direktno utiče na performanse automatske analize EKG signala. Odabir frekvencije uzorkovanja signala utiče na sposobnost generalizacije modela i njegovu složenost (Habib, Karmakar and Yearwood, 2020). U praksi se pokazalo da modeli koji koriste signale uzorkovane nižim frekvencijama (od 100 Hz do 250 Hz) pokazuju bolja svojstva generalizacije u odnosu na modele koji koriste signale uzorkovane višim frekvencijama (2000 Hz) (Habib, Karmakar and Yearwood, 2020). U člancima (Acharya et al, 2017, pp. 81-90; Wang, 2021, pp. 320-332; Wang, 2020b, p. 105446) ulazni signali su poduzorkovani sa 360 Hz na 250 Hz, u (Fan et al, 2018, pp. 1744-1753) sa 300 Hz na 120 Hz, u (Rahul and Sharma, 2022, p. 103270) sa 250 Hz na 128 Hz, u (Seo et al, 2021, pp. 1-8) sa 360 Hz, 250 Hz i 128 Hz na 128Hz.

Prilikom snimanja EKG signala primjetne su varijacije u vrijednostima amplituda signala kod različitih ispitanika, ali i kod istih ispitanika sa različitim pozicioniranjem elektroda (Fan et al, 2018, pp. 1744-1753). Pomenute varijacije moguće je eliminirati korištenjem brojnih metoda normalizacije vrijednosti. U člancima (Acharya et al, 2017, pp. 81-90; Cao et al, 2020, p. 101675; Feng and Fan, 2022, p. 103663; Wang, 2020a, pp. 670-679; Lai et al, 2019, pp. 130074-130084; Wang, 2021, pp. 320-332; Rahul and Sharma, 2022, p. 103270; Fan et al, 2018, pp. 1744-1753; Wang, 2020b, p. 105446; Seo et al, 2021, pp. 1-8; Dang et al, 2019, pp. 75577-75590) korištena je z-score normalizacija vrijednosti amplitude signala. Kod pomenute metode srednja vrijednost i standardna devijacija koriste se kao mjere za skaliranje vrijednosti amplitude signala. U člancima (Nurmaini et al, 2020, pp. 304-317; Rahul and Sharma, 2022, p. 103270), predložena je metoda min-max normalizacija vrijednosti amplitude signala sa skaliranjem na opseg vrijednosti od 0 do 1. Kao mjera za skaliranje vrijednosti amplitude signala koriste se predefimirane vrijednosti gornje i donje granice opsega i karakteristična je po tome što predstavlja linearnu transformaciju vrijednosti.

U člancima (Fu'adahand Lim, 2022, p. 2456; Fujita and Cimr, 2019a, pp. 3383-3391; Ma et al, 2020, pp. 1-9; Nguyen et al, 2021, p. 102672; Tutuko et al, 2021, pp. 1-17) korišteni su neobrađeni signali iz kojih nisu izdvajani šumovi iz korisnog signala, niti je vršena normalizacija vrijednosti amplitude niti poduzorkovanje signala.

C. Izvori EKG signala

U člancima (Cao, Yao and Chen, 2019, pp. 89152-89161; Cao et al, 2020, p. 101675; Chen et al, 2021, p. 106009; Fan

et al, 2018, pp. 1744-1753; Fu'adahand Lim, 2022, p. 2456; Nguyen et al, 2021, p. 102672; Nurmaini et al, 2020, pp. 304-317; Rubin et al, 2018, pp. S18-S21; Tutuko et al, 2021, pp. 1-17; Xu et al, 2018; Lai et al, 2019, pp. 130074-130084; Jo et al, 2021, pp. 104-110) korišteni su EKG signali snimani sa pojedinačnih odvoda. Za slučaj kada su signali snimani sa više odvoda, najčešće je korišten signal sniman sa II odvoda kao u člancima (Fujita and Cimr, 2019a, pp. 3383-3391; Fujita and Cimr, 2019b, pp. 231-239; Acharya et al, 2017, pp. 81-90) dok je u članku (Ma et al, 2021, pp. 1-10) korišten signal sniman sa I odvoda. U članku (He et al, 2018, p. 1206) navedeno je da je korišten signal sniman sa prvog, od ukupno dva odvoda koji su korišteni prilikom snimanja signala, bez navođenja njihovih oznaka. Također u članku (Singh et al, 2022, pp. 208-217) korišten je Holter signal sniman sa jednog odvoda. Korištenje signala snimanog samo sa jednog odvoda, u posljednje vrijeme postaje sve veći ograničavajući faktor za sisteme automatske klasifikacije AF oboljenja. Svaki odvod mjeri različite projekcije polarizacijskog vektora i sadrži različite informacije o srčanog aktivnosti koje ne moraju biti sadržane u signalima snimanim sa drugih odvoda (Fujita and Cimr, 2019b, pp. 231-239). Stoga se u posljednje vrijeme sve više preporučuje korištenje signala snimanih sa više odvoda. Članci u kojima su korišteni signali snimani sa više odvoda su: (Jo et al, 2021, pp. 104-110) sa 6 i 12, (Smith et al, 2019, p. 100423) sa 12 i (Salinas-Martínez et al, 2020, pp. 1-4) sa 18, 25 i 84 odvoda. U člancima (Dang et al, 2019, pp. 75577-75590; Erdenebayar et al, 2019; Feng and Fan, 2022, p. 103663; Jin et al, 2020, p. 105460; Petmezas et al, 2021, p. 102194; Rahul and Sharma, 2022, p. 103270; Sun et al, 2020, pp. 1-7; Wang, 2020a, pp. 670-679; Wang, 2020b, p. 105446; Wang, 2021, pp. 320-332) nije naznačeno sa kojih odvoda su snimani EKG signali. Signali se izdjeljuju na segmente različitih dužina trajanja po osnovu trajanja srčanih ciklusa ili karakterističnih segmenata i intervala EKG signala ili po osnovu fiksnog vremenskog trajanja.

Većina baza sadržava nebalansirane skupove EKG signala, u kojima su signali različitih oboljenja zastupljeni u manjem procentu u odnosu na zdrave signale. Ukoliko baza signala sadrži 98 % zdravih signala, a samo 2 % signala nekog od oboljenja, klasifikacijski modeli mogu postići tačnost od 98 % na način da klasificiraju sve signale kao normalne događaje tretirajući abnormalne ulazne signale šumom i eliminišući ih. Problem pretreniranosti modela, kao u gore pomenutom slučaju, dovodi do toga da klasifikacijski model bez pogreške klasificira podatke koji se koriste u fazi treniranja a nije u mogućnosti klasificirati nevidene podatke (Petmezas et al, 2021, p. 102194). Stoga se za proces treniranja klasifikacijskog modela trebaju obezbijediti balansirani setovi podataka iz kojih model uči. Postoje brojni načini za rješavanje problema nebalansiranih setova podataka koji imaju problem rijetko zastupljenih klasa. Jedan od načina je kreiranje novog seta podataka koji pored podataka iz nebalansiranog seta podataka sadrži i podatke koji su preuzeti iz drugih baza. U članku (Rubin et al, 2018, pp. S18-S21) unutar nebalansiranog seta signala su dodani EKG segmenti signala AF oboljenja trajanja 30 s prikupljeni iz različitih izvora uključujući i ambulantne signale snimane sa Holter monitora. Ovim je povećan broj signala AF oboljenja u setovima signala za treniranje i validaciju. U člancima (Cao et al, 2020, p. 101675; Xu et al, 2018) balansiranje polaznog

seta signala izvršeno je nasumičnim uklanjanjem signala iz većinski zastupljenih kategorija, što predstavlja poduzorkovanje polaznog seta signala. Suprotno, balansiranje se može postići i vještačkim umnožavanjem rijetko zastupljenih signala iz manjinski zastupljenih klasa, što predstavlja naduzorkovanje polaznog seta signala. Posljednjih godina vlada veliki interes za rješavanje problema nebalansiranih setova podataka, uglavnom korištenjem različitih tehnika naduzorkovanja od čega su najčešće korištene tehnika slučajnog naduzorkovanja i sintetička tehnika naduzorkovanja manjinski zastupljenih klasa. U članku (Petmezas et al, 2021, p. 102194) predložen je hibridni model mreže dubokog učenja koji koristi fokalni gubitak, poboljšanu verziju unakrsnog entropijskog gubitka, sa ciljem prevazilaženja problema nebalansiranog seta signala. U članku (Fan et al, 2018, pp. 1744-1753) problem nebalansiranog seta signala za treniranje prevaziđen je repliciranjem signala AF oboljenja tri puta u odnosu na polazni set signala. Međutim povećanjem zastupljenosti manjinski zastupljenih klasa, ne povećava se količina novih informacija na kojima model u procesu treniranja uči, što može dovesti do problema pretreniranosti modela. Problem nebalansiranog broja signala po klasama može se prevazići upotrebom k-struke unakrsne validacije kao u članku (Nurmaini et al, 2020, pp. 304-317).

D. Format ulaznih podataka

Ulazni signal se može predstaviti u formatu jednodimenzionalne vremenske sekvence uzoraka signala ili u formatu dvodimenzionalnog signala, najčešće slike. Oba formata mogu nositi informacije o signalu u vremenskom i/ili frekventnom domenu. U izdvojenim člancima, signali su najčešće predstavljeni u formatu vremenske sekvence uzoraka. Također signal može biti predstavljen i sekvencom uzoraka izdvojenih RR intervala i karakterističnih intervala i segmenata EKG signala određenih morfološkim osobinama signala poput P talasa, QRS kompleksa i T talasa, kao u članku (Dang et al, 2019, pp. 75577-75590). U članku (Salinas-Martínez et al, 2020, pp. 1-4) signal je predstavljen dvodimenzionalnom elektrokardiografskom matricom koeficijenata. Vremensko-frekventni prikaz signala u formatu skalogramata signala, omogućen je primjenom prozorske Furijerove transformacije (engl. *Short-Term Fourier Transform*, STFT) (Rahul and Sharma, 2022, p. 103270; Rubin et al, 2018, pp. S18-S21), kontinualne wavelet transformacije (engl. *Continuous Wavelet Transform*, CWT) (Fujita and Cimr, 2019a, pp. 3383-3391; He et al, 2018, p. 1206; Jin et al, 2020, p. 105460) ili modifikovane frekventne wavelet transformacije (engl. *Modified Frequency Wavelet Transform*, MFWT) (Ma et al, 2021, pp. 1-10; Xu et al, 2018).

E. Modeli dubokog učenja

Mašinsko učenje zasniva se na automatskoj analizi velike količine ulaznih podataka. Izdvajanje značajki zasnovano je na uputama datim od strane eksperata iz oblasti ili na sistematskim pregledima relevantne literature u oblasti što predstavlja jedan od izazova u oblasti mašinskog učenja s obzirom da ovaj proces produžava vrijeme te povećava troškove u procesu uspostavljanja dijagnoze i odgovarajuće terapije. Odabiranje značajki omogućava eliminaciju irelevantnih i redundantnih značajki u inicijalno izdvojenom skupu značajki čime se smanjuje kompleksnost a, u većini slučajeva, i poboljšavaju performanse modela. Dok se modeli mašinskog učenja oslanjaju na ručno izdvajanje i odabiranje

značajki iz ulaznih setova podataka karakterističnih za određena oboljenja i klinička stanja, modeli dubokog učenja imaju mogućnost direktnog učenja značajki iz velikih i označenih skupova. Interes za primjenu modela dubokog učenja u različitim oblastima medicine je značajno porastao u prethodnom desetljeću zbog visokih performansi koje su modeli ostvarili u poljima detekcije, segmentacije, klasifikacije, praćenja i predviđanja (Montagnon et al, 2020, pp. 1-15). U nastavku teksta dat je pregled i kratki opis modela dubokog učenja koji su korišteni od strane autora u izdvojenim člancima od interesa.

Na osnovu pregleda moguće je uočiti da je najčešće kao korišteni model dubokog učenja u izdvojenim člancima korišten model konvolucione neuronske mreže (engl. *Convolutional Neural Network*, CNN). Mogu se primijeniti i nad jednodimenzionalnim vremenskim sekvencama uzoraka signala (1D CNN) kao i nad dvodimenzionalnim signalima u formatu matričnog prikaza ili slike (2D CNN). Konvolucionni slojevi unutar modela duboke neuronske mreže specijaliziraju se za izdvajanje i odabiranje hijerarhijskih značajki iz signala od onih jednostavnijih do onih složenijih, korištenjem konvolucije i primjenom visokodimenzionalnih filtera na ulazne podatke čime upotpunosti eliminišu potrebu za ručnim izdvajanjem značajki iz signala. Tradicionalne konvolucione mreže sastoje se od ulaznog i izlaznog sloja, kao i od više skrivenih slojeva koji se obično sastoje od konvolucionih slojeva, slojeva za udruživanje i potpuno povezanih slojeva (He et al, 2018, p. 1206). CNN je povezan sa ulaznim slojem preko konvolucijske jezgre. Konvolucijska jezgra izvodi množenje korištenjem kliznog prozora različite veličine i različitog pomaka kako bi se postiglo višerazmjerno izdvajanje značajki. Istovremeno, mehanizam dijeljenja težine konvolucijskog sloja čini ga učinkovitijim za izdvajanje značajki, uveliko smanjujući broj slobodnih varijabli koje je potrebno naučiti (Ma et al, 2020, pp. 1-9). Prilikom određivanja arhitekture CNN modela potrebno je uzeti u obzir broj filtera i dubinu modela. Ovi parametri utječu na mape značajki kao i na složenost modela. Ako je model previše jednostavan, neće moći izdvojiti jedinstvene značajke. S druge strane, ako je model predubok, to će povećati složenost modela i usporiti proces treniranja (Fu'adahand Lim, 2022, p. 2456).

Sa ciljem pronalaženja optimalne arhitekture CNN modela u članku (Erdenebayar et al, 2019) dizajnirano je ukupno šest arhitektura modela koje su se sastojale iz različitog broja konvolucionih slojeva, slojeva udruživanja i višeslojnog perceptrona. Prema rezultatima eksperimenata za odabir optimalne arhitekture, CNN model pokazuje bolje performanse u dubljoj arhitekturi. Optimalna 7-slojna arhitektura predloženog CNN modela odabrana je u pomenutom članku. U članku (Fu'adahand Lim, 2022, p. 2456) razmatrane su četiri arhitekture s različitim dubinama konvolucionih slojeva, a optimalnom se pokazala 6-slojna arhitektura. Kao ulaz u model korištene su vremenske sekvence uzoraka signala različitog trajanja. U članku (Fujita and Cimr, 2019b, pp. 231-239) korištena je 8-slojna arhitektura CNN modela s ciljem detekcije AF, aritmije koja je usko povezana sa fibrilatornim pojavama u atriju i atrijalnoj flatera. Autori članka (Tutuko et al, 2021, pp. 1-17) u radu su koristili arhitekturu 1D CNN modela koju su predložili u jednom od svojih prethodnih radova a koja se sastoji iz trinaest konvolucijskih slojeva i pet slojeva maksimalnog udruživanja za problem binarne i višeklasne klasifikacije. U ovom članku poboljšanje generalizacije i robusnosti prethodno predloženog

modela postignuto je korištenjem ulazih signala različite dužine i snimanih sa različitim frekvencijama uzorkovanja i korištenjem nekoliko različitih uređaja.

U članku (Chen et al, 2021, p. 106009) predložena je metoda glasanja koja u procesu odlučivanja koristi dva CNN modela kako bi se izdvojio što veći broj značajki i poboljšala performansa cjelokupnog modela za otkrivanje AF. Svaki od predloženih CNN modela sastoji se od ulaznog sloja, dva konvoluciona sloja i sloja za udruživanje te izlaznog sloja. U članku (Wang, 2020b, p. 105446) predložena su tri različita 11-slojna hibridna modela za detekciju AF oboljenja. Među hibridnim modelima predložena je kombinacija CNN modela i višeslojnog perceptrona, zatim CNN modela i Elmanove neuronske mreže, te CNN modela i poboljšane verzije Elmanove neuronske mreže. Najbolje performanse imao je hibridni model CNN modela sa poboljšanom Elmanovom neuronskom mrežom. Kasnije u članku (Wang, 2020a, pp. 670-679) predložen je novi hibridni model koji kombinira CNN model sa modifikovanom Elmanovom neuronskom mrežom čime su se poboljšale performanse modela u odnosu na performanse postignute u prethodnom objavljenom članku. U članku (Fan et al, 2018, pp. 1744-1753) predložena je multiskalarna fuzija duboke konvolucione neuronske mreže za izdvajanje AF signala iz kratkoročnih EKG signala snimanih sa pojedinačnih odvoda sa različitim veličinama filtera za izdvajanje značajki različitih skala. Ovaj hibridni model sastoji se iz dva CNN modela sa trinaest konvolucionih slojeva, pet slojeva sažimanja maksimalnog udruživanja i tri potpuno povezana sloja. Pojednostavljeni CNN model predložen u članku (Lai et al, 2019, pp. 130074-130084) sastoji se iz dva 8-slojna CNN modela pri čemu su ulazi u prvi model izdvojeni RR intervali, a u drugi model spektar F talasa. Svaki od modela sastoji se iz dva konvolucijska sloja, dva sloja udruživanja, jednog sloja grupne normalizacije i jednog potpuno povezanog sloja ako izuzmemo ulazni i izlazni sloj. Za svaki od dizajniranih CNN modela, ili izdvojeni RR intervali ili izdvojeni frekventni spektar F talasa iz izvornog EKG segmenta signala, koriste se kao zasebni ulazni skupovi podataka. Nakon potpuno povezanog sloja, oba CNN modela mogu pojedinačno razlikovati zdrave segmente EKG signala od onih u kojima su prisutne AF epizode i na izlazu dati vjerovatnoću detekcije AF oboljenja. Ove dvije vjerovatnoće detekcije AF oboljenja, koje se dobijaju kao izlazne vrijednosti iz dva CNN modela, se kombiniraju kako bi se konačno donijela odluka da li je u posmatranom segmentu EKG signala prisutna AF epizoda ili ne, a sve to korištenjem procentualnog parametra praga. U članku (Nurmaini et al, 2020, pp. 304-317) predložen je 1D CNN model s dvije vrste slojeva: 1) slojevi za učenje značajki s jednodimenzionalnim konvolucijama i poduzorkovanjem; i 2) potpuno povezani slojevi kao klasifikatori koji su slični slojevima tipičnog višeslojnog perceptrona. Sa ciljem postizanja što boljih performansi isprobane su različite kombinacije konvolucijskih slojeva i slojeva udruživanja. Utvrđeno je da 13-slojni 1D CNN model ima najbolje performanse.

Segmenti signala trajanja 15 s predstavljaju ulaz u primarni CNN model, dok kraći segmenti trajanja 9 s predstavljaju ulaz u sekundarni CNN model u članku (Rubin et al, 2018, pp. S18-S21). Ukoliko se izračunavanjem indeksa kvalitete signala utvrdi da je neki od segmenata niske kvalitete, ti segmenti se odmah klasificiraju kao šumovi, dok se u suprotnom za segmente visoke kvalitete vrši transformacija u vremensko-frekventni prikaz koji se dalje koriste kao ulazi u CNN model. Arhitektura CNN modela u

članku (Fujita and Cimr, 2019a, pp. 3383-3391) određena je eksperimentalnim putem, a 6-slojna arhitektura odabrana je kao optimalna s dva konvolucijska sloja, dva sloja maksimalnog udruživanja i dva potpuno povezana sloja. Ulaz u mrežu je skalogram segmenta signala trajanja 2 s dobijen CWT transformacijom i predstavljen u obliku slike širine 50 i visine 30 piksela čime se garantuje optimalan izbor ulaza u 2D CNN model bez potrebe za bilo kakvim poduzorkovanjem, naduzorkovanjem ili normalizacijom vrijednosti amplitude signala. I u članku (Fujita and Cimr, 2019a, pp. 3383-3391) korištena je CWT transformacija ali sada na segmentima signala dužine pet srčanih ciklusa. Predložena arhitektura ovog CNN modela sastoji se iz četiri konvolucijska sloja, tri potpuno nepovezana sloja, dva sloja maksimalnog udruživanja, dva potpuno povezana sloja i jednog ravnog sloja. Skalogram signala moguće je dobiti i primjenom MFSWT transformacije. Za automatsku identifikaciju otkucanja karakterističnih za pojavu fibrilacija u aatriju, u članku (Xu et al, 2018) predložena je transformacija segmenata signala trajanja 1 s MFSWT metodom koji tako transformisani predstavljaju ulaz u 12-slojni CNN model koji se bavi problemom binarne klasifikacije. U članku (Ma et al, 2021, pp. 1-10) predložena su tri različita modela za klasifikaciju AF oboljenja: 1) CNN model treniran nad segmentima signala trajanja 10 s i 30 s predstavljenih u obliku skalograma signala primjenom MFSWT transformacije, 2) SVM model treniran nad izdvojenim značajkama RR intervala i 3) prošireni SVM model treniran nad kombinacijom izdvojenih značajki RR intervala i prediktivne vjerovatnoće iz CNN modela. Zaključeno je da korištenje prediktivne vjerovatnoće za kao nove značajke može korigovati rad SVM klasifikatora treniranog nad značajkama RR intervala, što ne samo da poboljšava tačnost detekcije modela, već i sposobnost generalizacije modela. U članku (Nguyen et al, 2021, p. 102672) također je predložen kombiniran model CNN arhitekture koji se koristi za izdvajanje dubokih značajkih iz segmenata EKG signala i SVM klasifikatora.

U brojnim člancima koji se bave klasifikacijom srčanih aritmija nerijetko se koristi i model rezidualne konvolucione neuronske mreže (engl. *Residual Network*, ResNet) koji pokazuje dobre performanse jer se ne susreće sa problemom nedostajućeg gradijenta. U članku (Seo et al, 2021, pp. 1-8) korišteni su ResNet 18, 34, 50 i 152 nad sirovim segmentima EKG signala trajanja 10 s. Model brzo poduzorkovane ResNet mreže (engl. *Fast Downsampling ResNet*, FDResNet) predložen u članku (Cao, Yao and Chen, 2019, pp. 89152-89161) unaprijeđen je dekompozicijom u više skala. Ovakvi modeli se sastoje iz više modula: 1) modula za brzo poduzorkovanje, 2) modula rezidualne konvolucije i 3) modula za klasifikaciju. Također u istom članku predložen je i ResNet model sa više skala (engl. *Multi-Scale ResNet*, MSResNet). MSResNet sastoji se iz tri paralelna modela FDResNet mreže međusobno povezanih malom neuronskom mrežom. Tri modela FDResNet mreže imaju istu arhitekturu, ali se neovisno treniraju pomoću rekonstruiranih uzoraka različitih skala. Istrenirana matrica težina izravno se prenosi u MSResNet. Svaki od modela podmreže naučio je različite značajke, a svaki od modela ima i različite mogućnosti neovisne klasifikacije. Nakon što se vektori predviđanja sve tri modela podmreža povežu u jedan vektor značajki, mala neuronska mreža nad njima uči izdvajajući i odabirući odgovarajuće značajke čime se može postići veća tačnost prepoznavanja AF oboljenja.

Drugi najčešće korišteni model u člancima je mreža dugog kratkoročnog pamćenja (engl. *Long Short-Term Memory*, LSTM). U članku (Cao et al, 2020, p. 101675) korišten je model 2-slojne LSTM mreže koji je treniran nad javno dostupnom bazom EKG signala. Na osnovu postignutih performansi modela, bolji rezultati su postignuti za slučaj sa augmentacijom podataka, nego bez. U člancima (Feng and Fan, 2022, p. 103663; Rahul and Sharma, 2022, p. 103270; Wang, 2021, pp. 320-332) korišten je model dvosmjerne LSTM mreže (engl. *Bidirectional LSTM*, BiLSTM). Standardni BiLSTM blok sastoji se iz ulaznog sloja, prednjeg sloja, povratnog sloja i izlaznog sloj, koji ostvaruje funkciju obrade podataka u oba smjera u dva odvojena skrivena sloja i zatim to spaja u isti izlazni sloj. Učenjem u oba smjera može se dobiti tačniji rezultat predviđanja (Dang et al, 2019, pp. 75577-75590). U članku (Rahul and Sharma, 2022, p. 103270) korištena su dva različita formata predstavljanja ulaza. Jedan od formata ulaza u BiLSTM model je bila vremenska sekvenca uzoraka signala trajanja 4 s koji su prethodno pretprocesirani, a drugi je bio skalogram signala. U oba slučaja arhitektura modela se sastojala iz sto skrivenih slojeva i dva potpuno povezana sloja. Performanse modela u oba slučaja pokazale su uporedive rezultate. Na temelju postojeće arhitekture BiLSTM modela, u arhitekturu poboljšanog BiLSTM (engl. *Improved BiLSTM*, IBiLSTM) modela ugrađen je faktor skaliranja koji omogućava učinkovitu preraspodjelu prikaza informacija i stoga takvi modeli mogu ostvariti bolje performanse prilikom učenja. Predloženi model u članku (Feng and Fan, 2022, p. 103663) ostvario je bolje performanse od modela koji su obrađeni u pregledu literature u pomenutom članku.

U članku (Petmezas et al, 2021, p. 102194) predložen je hibridni model koji se sastoji iz CNN i LSTM modela. Arhitektura CNN modela koja se sastoji iz slojeva konvolucije i slojeva maksimalnog udruživanja omogućila je izdvajanje morfološki značajki iz pojedinačnih srčanih ciklusa. Izlazi iz CNN modela predstavljaju ulaz u LSTM model koji može pamtiti dugoročne ovisnosti između izdvojenih značajki. U članku (Dang et al, 2019, pp. 75577-75590) korišten je također hibridni model koji se sastoji iz CNN i BiLSTM modela. Izdvajanje karakterističnih morfoloških osobina iz EKG signala otežano je zbog njihove male amplitude i kratkog trajanja, pa je stoga u tu svrhu izdvajanja predložen hibridni model. Model se sastoji iz četiri konvoluciona sloja: dva BiLSTM sloja i dva potpuno povezana sloja. Eksperimentalni rezultati su potvrdili da se predloženi model može efektivno koristiti za detekciju AF oboljenja bez da se koriste ručno izdvojene značajke EKG signala ili ekspertsko znanje u oblasti.

Modeli dubokog učenja, u najvećem broju slučajeva, nemaju svojstvo interpretabilnosti što otežava uspostavljanje odnosa između ulaza i rezultata predikcije modela. Kako bi se prevazišao pomenuti problem, u članku (Jin et al, 2020, p. 105460) predložen je model konvolucione LSTM mreže dualne pažnje (engl. *Twin Attention Convolutional LSTM*, TAC-LSTM). Rezultati su pokazali da predloženi model ne samo da može izdvojiti više informativnih dubokih značajki i selektivno ih naglasiti, te time povećati tačnost modela, već može i istražiti odnos između ulaznih segmenata EKG signala i rezultata predviđanja.

IV. DISKUSIJA

Tokom prošlog desetljeća, duboko učenje pokazalo je superiorne performanse u rješavanju mnogih problema u

raznim područjima medicine u uporedbi s drugim metodama mašinskog učenja (Jang and Cho, 2019, pp. 492-504). Ipak postoji nekoliko prepreka u primjeni dubokog učenja koje se moraju prevladati da bi se njegov potencijal mogao značajnije iskoristiti u medicinskoj praksi. Preduslov za primjenu dubokog učenja su ogromni setovi dobro označenih i standardiziranih medicinskih podataka. Iako se digitalizacija medicinskih podataka snažno podstiče u bolnicama, sadašnji oblici digitaliziranih podataka nisu standardizirani za primjenu dubokog učenja, koje zahtijeva vrlo specifično i precizno označene podatke (Jang and Cho, 2019, pp. 492-504). Stoga je neophodno da eksperti iz različitih oblasti medicine ponovno pregledaju i označe velike količine medicinskih podataka kako bi ih učinili prikladnim za primjenu dubokog učenja. Proces analize podataka, učenja i načina donošenja odluka je teško razumljiv i predstavlja

značajnu prepreku u praktičnoj primjeni računarski potpomognutih dijagnostičkih sistema utemeljenih na dubokom učenju. S obzirom na to da ljekari preuzimaju odgovornost prilikom uspostavljanja dijagnoza, prilikom korištenja ovih sistema, neophodno je obezbijediti objašnjivost, odnosno interpretabilnost njihovih rezultata. U posljednje vrijeme sve više pažnje se posvećuje problemu objašnjivosti rezultata kako bi se nova ekspertna znanja iz podataka mogla predstaviti na jasan i razumljiv način.

U tabeli II dat je pregled svih korištenih modela zajedno sa ostvarenim performansama istih u pogledu specifičnosti, senzitivnosti i tačnosti.

TABELA II. MODELI DUBOKOG UČENJA ZA DETEKCIJU ATRIJALNE FIBRILACIJE

Autori, Godine	Baze signala	Signal	DL model	Klase	Performanse (%)		
					Spec.	Sen.	Tačn.
Acharya et al., 2017	MIT-BIH Atrial Fibrillation (afdb), MIT-BIH Arrhythmia (mitdb), Creighton University Ventricular Tachyarrhythmia (cudb)	8636 EKG segmenata trajanja 2 s i 5 s	11-slojni CNN	NSR, AF, AFL, i VF	81.44	99.13	94.50
Cao et al., 2019	PhysioNet/CinC Challenge 2017	od 8528 EKG segmenata trajanja 9 - 61 s načinjen je skup od 19188 EKG segmenata trajanja 9 s	FDResNet MSResNet	NSR, AF, O, i NO	-	-	92.1
Cao et al., 2019	PhysioNet/CinC Challenge 2017	8528 EKG segmenata trajanja 9 - 61 s sa i bez balansiranja podataka	2-slojna LSTM	NSR, AF, O, i NO	-	-	82.95
Chen et al., 2019	MIT-BIH Arrhythmia (mitdb)	48 EKG segmenata trajanja 30 min segmentirani na trajanja pojedinačnog srčanog otkucaja	izdvajanje više značajki + CNN	NSR, AF	97.04	97.19	98.92
Dang et al., 2019	MIT-BIH Atrial Fibrillation (afdb)	Set podataka A: izdvojeni RR intervali sačinjavaju segmente dužine 100 uzoraka. Set podataka B: izdvojeni P talasi, QRS kompleksi i T talasi u blizini R vrha sačinjavaju segmente dužine 500 uzoraka	CNN-BiLSTM	AF, Ne-AF	97.03	99.93	96.59
Erdenebayar et al., 2019	MIT-BIH Atrial Fibrillation (afdb), MIT-BIH Normal Sinus Rhythm Database (nsrdb), Paroxysmal AF Prediction Challenge Database (PAFDB)	19,804 EKG segmenata trajanja 30 s	7-slojna CNN	NSR, AF	98.7	98.6	98.7
Fan et al., 2018	PhysioNet/CinC Challenge 2017	8528 EKG snimaka trajanja 9 - 61 s podijeljeni su na EKG segmente trajanja 5 s, 10 s, 20 s i 30 s	MS-CNN	NSR, AF	98.77	93.77	98.13
Feng et al., 2022	MIT-BIH Atrial Fibrillation (afdb), MIT-BIH Arrhythmia (mitdb)	EKG segmenti trajanja 2 s	BiLSTM	NSR, AF	98.0	98.4	98.2
Fu'adah et al., 2022	MIT-BIH Atrial Fibrillation (afdb), BIDMC Congestive Heart Failure database, MIT-BIH Normal Sinus Rhythm Database (nsrdb)	5600 EKG segmenta snimanih sa 56 ispitanika	1D CNN	NSR, AF, CHF	-	-	99.643
Fujita et al., 2018	MIT-BIH Atrial Fibrillation (afdb), MIT-BIH Arrhythmia (mitdb), MIT-BIH malignant ventricular arrhythmia database (vfdb)	25287 EKG segmenata trajanja 2 s	8-slojna CNN	NSR, AF, AFL, VF	99.72	99.87	98.45
Fujita et al., 2019	MIT-BIH Atrial Fibrillation (afdb), MIT-BIH Arrhythmia (mitdb), MIT-BIH malignant ventricular arrhythmia database (vfdb)	25459 EKG segmenata trajanja 2 s u obliku skalograma signala	CWT + 6-slojna CNN	NSR, AF, AFL, VF	98.82	99.76	97.78
He et al., 2018	MIT-BIH Atrial Fibrillation (afdb)	EKG segmenti trajanja 1.2 s u obliku skalograma signala	CWT + 2D CNN	NSR, AF	98.91	99.41	99.23
Henry et al., 2022	Interni set signala za trening i eksterni za testiranje	267144 Holter snimaka	CNN + MHA	ocjena rizika	58	78	-
Jin et al., 2018	MIT-BIH Atrial Fibrillation (afdb)	EKG segmenti trajanja 5 s u obliku vremenske sekvence uzoraka i skalograma signala	TAC-LSTM	AF, Ne-AF	98.76	98.14	98.51
Jo et al., 2018	Sejong EKG baza signala prikupljenih iz Sejong General Hospital (SGH) i Mediplex Sejong Hospital (MSH)	EKG segmenti trajanja 5 s	DLM	AF, Ne-AF	99.5	92.8	94.8

Normalni sinusni srčani ritam (engl. *Normal Sinus Rhythm*, NSR); atrijalna fibrilacija (engl. *Atrial Fibrillation*, AF); atrijalni flater (engl. *Atrial Flutter*, AFL); ventrikularna fibrilacija (engl. *Ventricular Fibrillation*, VF); ostali (engl. *Other*, O); zašumljen (engl. *Noisy*, NO); kongestivno zatajenje srca (engl. *Congestive*

Lai et al., 2018	MIT-BIH Atrial Fibrillation (afdb)	EKG segmenti trajanja 10 s u obliku vremenske serije RR intervala i spektra f talasa	Težeinski olakšana CNN	NSR, AF	97.2	97.8	97.5
Ma et al., 2018	MIT-BIH Atrial Fibrillation (afdb)	96000 EKG segmenata trajanja 10 s i 30 s u obliku skalograma signala	MFSWT+ CNN + SVM	AF, Ne-AF	99.5	97.67	98.61
Nguyen et al., 2021	PhysioNet/CinC Challenge 2017	EKG segmenti fiksne dužine	Stacking segment-based CNN + SVM	NSR, AF, O, i NO	-	-	-
Nurmaini et al., 2020	MIT-BIH Atrial Fibrillation (afdb), MIT-BIH Malignant Ventricular Ectopy (vfdb) and Internal dataset	EKG segmenti trajanja 9 s	DWT + 1D CNN	NSR, AF, Non-AF	99.17	98.90	99.17
Petmezas et al., 2021	MIT-BIH Atrial Fibrillation (afdb)	EKG segmenti trajanja približno 0.75 s (srčani ciklus)	Hibridna CNN-LSTM sa fokalnim gubitkom	NSR, AF, AFL, i J	99.29	97.87	97.87
Rahul et al., 2022	MIT-BIH Atrial Fibrillation (afdb), MIT-BIH Normal Sinus Rhythm Database (nsrdb)	EKG segmenti trajanja 4s u obliku skalograma signala	BiLSTM	NSR, AF	100	99.7	99.84
Rubin et al., 2018	PhysioNet/CinC Challenge 2017	EKG segmenti trajanja 9 s i 15 s u obliku skalograma signala	CNN	NSR, AF, O, NO	-	-	-
Salinas-Martinez et al., 2021	MIT-BIH Normal Sinus Rhythm Database (nsrdb), MIT-BIH Atrial Fibrillation (afdb), Long-Term AF Database (ltafdb)	EKG segmenti trajanja 10 srčanih ciklusa u obliku elektrokardiomatrice signala	CNN	AF, Ne-AF	91.22	78.26	85.08
Seo et al., 2021	MIT-BIH Atrial Fibrillation (afdb), Long-Term AF Database (ltafdb), MIT-BIH Arrhythmia (mitdb)	EKG segmenti trajanja 10 s	ResNet 18, 34, 50 i 152	AF, Ne-AF	-	-	-
Smith et al., 2019	Interni set signala	Slučajno odabranih 500 EKG segmenata	CNN (Cardiologs)	AF, Ne-AF	99.5	92	91.2
Sun et al., 2021	Long-Term AF Database (ltafdb), AF Termination Challenge Database (aftdb)	EKG segmenti trajanja 1-2 min	Stacked LSTM	AF, Ne-AF	-	-	92
Tutuko et al., 2021	MIT-BIH Atrial Fibrillation (afdb), PhysioNet/CinC Challenge 2017, China Physiological Signal Challenge (CPSC) 2018, Chapman ECG dataset, Shaoxing People's Hospital Database and Indonesian Hospital dataset	EKG segmenti trajanja 2700 uzoraka koji sadržavaju minimalno dva RR intervala ili tri srčana ciklusa	1D CNN	NSR, AF	99.8	99.8	99.8
Wang et al., 2019	MIT-BIH Atrial Fibrillation (afdb), MIT-BIH Arrhythmia (mitdb)	EKG segmenti trajanja 4 s	11-slojna CNN-IENN	NSR, AF	98.6	98.9	98.9
Wang et al., 2020	MIT-BIH Atrial Fibrillation (afdb),	EKG segmenti trajanja 4 s	11-slojna CNN-MENN	NSR, AF	97.1	97.9	97.4
Wang et al., 2021	MIT-BIH Atrial Fibrillation (afdb), MIT-BIH Arrhythmia (mitdb)	EKG segmenti trajanja 2 s	MBiLSTM	NSR, AF, AFL	99.2	98.7	99.0
Xu et al., 2018	MIT-BIH Atrial Fibrillation (afdb)	EKG segmenti trajanja 1 s u obliku skalograma signala	MFSWT + CNN	AF, Ne-AF	89.99	79.05	88.45

Heart Failure, CHF); spojni ritam (engl. *Junctional Rhythm*, J); konvoluciona neuronska mreža (engl. *Convolutional Neural Network*, CNN); rezidualna mreža (engl. *Residual Neural Network*, ResNet); brza poduzorkovana rezidualna konvoluciona mreža (engl. *Fast Down-Sampling Residual Convolutional Neural Network*, FDResNet); multi-skalarna rezidualna mreža (engl. *Multi-Scale Residual Neural Network*, MSResNet); mreža dugog kratkoročnog pamćenja (engl. *Long Short-Term Memory Networks*, LSTM); dvosmjerna mreža dugog kratkoročnog pamćenja (engl. *Bidirectional Long Short-Term Memory Networks*, BiLSTM); modificirana dvosmjerna mreža dugog kratkoročnog pamćenja (engl. *Modified Bidirectional Long Short-Term Memory Networks*, MBiLSTM); multi-skalarna fuzija dubokih konvolucionih neuronskih mreža (engl. *Multi-Scaled fusion of Deep Convolutional Neural Network*, MS-CNN); unaprijeđena dvosmjerna mreža dugog kratkoročnog pamćenja (engl. *Improved Bidirectional Long Short-Term Memory Networks*, IBiLSTM); kontinualna wavelet transformacija (engl. *Continuous Wavelet Transform*, CWT); diskretna wavelet transformacija (engl. *Discrete Wavelet Transform*, DWT); modificirana frekventna wavelet transformacija (engl. *Modified Frequency Slice Wavelet Transform*, MFSWT); mreže višestruke pažnje (engl. *Multi-Headed Attention*, MHA); konvoluciona LSTM dualne pažnje (engl. *Twin-Attentional Convolutional Long Short-Term Memory Neural Network*, TAC-LSTM); različiti modeli dubokog učenja (engl. *Diverse Deep Learning Models*, DLM); težinski olakšana konvoluciona neuronska mreža (engl. *Lightweight Convolutional Neural Network*); metoda potpornih vektora (engl. *Support Vector Machine*, SVM); naslagana CNN (engl. *Stacking segment-based Convolutional Neural Network*); naslagana LSTM (engl. *Stacked Long Short-Term Memory Network*); poboljšana Elmanova neuronska mreža (engl. *Improved Elman Neural Network*, IENN); modificirana Elmanova neuronska mreža (engl. *Modified Elman Neural Network*, MENN).

Klasa kojoj pripada ulazni EKG signal određuje se u završnim slojevima DL modela. Zavisno od broja klasa razlikujemo binarnu i višeklasnu klasifikaciju. Binarna klasifikacija ulazne instance razvrstava u jednu od dvije klase, dok višeklasna klasifikacija ulazne instance razvrstava u tri ili više klasa.

Članci koji su se bavili problemom binarne klasifikacije ulazne EKG signale klasificiraju u jednu od dvije klase: 1)

NSR¹ i AF (Chen et al, 2021, p. 106009; Erdenebayar et al, 2019; Fan et al, 2018, pp. 1744-1753; Feng and Fan, 2022, p. 103663; He et al, 2018, p. 1206; Lai et al, 2019, pp. 130074-130084; Rahul and Sharma, 2022, p. 103270; Tutuko et al, 2021, pp. 1-17), 2) AF i Ne-AF (Salinas-Martinez et al, 2020, pp. 1-4; Rahul and Sharma, 2022, p. 103270; Ma et al, 2021, pp. 1-10; Xu et al, 2018), i 3) AF i O² (Fan et al, 2018, pp. 1744-1753). Članci koji su se bavili problemom višeklasne

¹ Normalni srčani ritam (engl. *Normal Sinus Rhythm*, NSR)

² Ostali (engl. *Other*, O)

³ Atrijalni falter (engl. *Atrial Flutter*, AFL)

⁴ Kongestivno zatajenje srca (engl. *Congestive Heart Failure*, CHF)

⁵ Zašumljen (engl. *Noisy*, NO)

⁶ Ventrikulama fibrilacija (engl. *Ventricular Fibrillation*, VF)

klasifikacije ulazne EKG signale klasificiraju u jednu od više više klasa: 1) NSR, AF i AFL³ (Wang, 2021, pp. 320-332), 2) NSR, AF i Ne-AF (Tutuko et al, 2021, pp. 1-17), 3) NSR, AF i CHF⁴ (Fu'adahand Lim, 2022, p. 2456), 4) NSR, AF, O i NO⁵ (; Cao et al, 2020, p. 101675; Rubin et al, 2018, pp. S18-S21; Nguyen et al, 2021, p. 102672), 5) NSR, AF, AFL i VF⁶ (Acharya et al, 2017, pp. 81-90; Fujita and Cimr, 2019a, pp. 3383-3391; Fujita and Cimr, 2019b, pp. 231-239), i (6) NSR, AF, AFL i J⁷ (Petmezas et al, 2021, p. 102194).

V. ZAKLJUČAK

Srčane aritmije su poremećaji srčanog ritma koji predstavljaju važan epidemiološki i javno zdravstveni problem (Murakoshi and Aonuma, 2013, pp. 2419-2431). Atrijalna fibrilacija je najčešća dugotrajna srčana aritmija (Hindricks et al, 2021, pp. 373-498) u kliničkoj praksi koja je okarakterizirana brзом i nekoordiniranom aktivnošću atriya što posljedično može dovesti do slabljenja ili potpunog gubitka kontrakcije atriya. S porastom incidence i prevalence širom svijeta, atrijalna fibrilacija poprima razmjere epidemije srčanih oboljenja. Razvoj sistema za automatsku detekciju srčanih oboljenja ima važan klinički i društveni značaj koji se ogleda u uspostavljanju dijagnoze u ranim fazama razvoja bolesti, poboljšanju planova liječenja pacijenata i poboljšanju medicinske skrbi pacijenta (Chen et al, 2021, p. 106009). Posljednjih godina, primijetan je porast u interesovanju i implementaciji sistema automatske detekcije srčanih oboljenja zasnovanih na konceptima dubokog učenja. U procesu implementacije, istraživači se suočavaju sa različitim izborima koji donose određene prednosti, ali također nameću i određena ograničenja na njihovu primjenu. Sistematski pregled literature na bazi pregleda različitih pristupa u implementaciji zajedno sa postignutim rezultatima uspješnosti primjene istih omogućava otkrivanje prostora za buduća unapređenja. Sistematski pregled literature unutar bibliografske baze podataka u skladu sa preporučenim smjernicama za izvještavanje u sistematskim pregledima i meta-analizama omogućio je konstrukciju sveobuhvatnog pristupa za analizu implementacijskih rješenja.

U ovom radu je predstavljen sistematski pregled literature na temu automatske detekcije AF korištenjem modela dubokog učenja sa osvrtom na njihovu implementaciju od odabira ulaznog seta podataka, preko odabira arhitekture i hiperparametara modela. U radu je dat pregled korištenih baza EKG signala sa detaljima o broju dostupnih snimaka signala, kao i osobinama i anotacijama signala. Nedostatak dosadašnjih istraživanja je u prikazu postignutih performansi modela samo na skupu za testiranje, a koji je u velikom broju slučajeva uzet iz iste baze signala kao i skup za učenje. S ciljem poboljšanja generalizacije modela neophodno je pri testiranju koristiti signale iz drugih baza. Manji broj modela radi nad sirovim ulaznim signalima, dok većina modela radi nad ulaznim signalima koji su prošli kroz jednu ili više faza pretprocesiranja signala. Pretprocesiranje obuhvata uklanjanje šumova, normalizaciju vrijednosti amplitude signala i poduzorkovanje signala. Nad sirovim ili pretprocesiranim ulaznim signalima izdvajaju se segmenti različitih trajanja i predstavljaju se u formate iz kojih će modeli učiti značajke

prisutne u signalima. U većini analiziranih implementacijskih rješenja, ulazni signali predstavljeni su u formatu vremenske sekvence uzoraka signala, dok su u manjem broju predstavljeni u formatu matrice ili skalograma signala. U radu je dat osvrt na problem nebalansiranih skupova signala sa preporukama za prevazilaženje istog. Poređenje performansi različitih modela zasnovano je na bazi korištenih signala, arhitekturi modela i broju klasifikacijskih grupa.

Uz stalno poboljšanje medicinskih standarda, postavljeni su strožiji zahtjevi na tačnost, robusnost i sposobnost generalizacije modela za automatsku detekciju oboljenja atrijalne fibrilacije (Chen et al, 2021, p. 106009). Modeli će morati prevazići izazove u korištenju signala sa većeg broja odvoda, sa lošijom kvalitetom i većim brojem šumova prisutnih u signalima. Većina implementacijskih rješenja koristi signal samo sa jednog odvoda, zanemarujući signale sa drugih odvoda. Karakteristične značajke oboljenja na signalima snimanim sa različitih odvoda mogu se različito manifestovati tako da u nekim mogu biti upotpunosti neuočljivi. Stoga je bolje koristiti signale snimane sa više od jednog odvoda. Također prilikom implementacije se pored signala snimanih u ambulatornim uslovima, a koji su bolje kvalitete i sadržavaju manji broj šumova, mogu koristiti i signali snimani sa pametnih satova i narukvica kako bi se povećala robusnost modela. Potreban je razvoj standardiziranih pristupa za provjeru performansi modela i njihove valjanosti, kao i poboljšanje interpretabilnosti rezultata koje ostvaruju ti modeli. S obzirom na to da je značajan broj implementacijskih rješenja zasnovan na prepoznavanje signala pacijenata sa određenim oboljenjem u odnosu na signale zdrave kontrolne skupine ispitanika, proširenje istraživanja može uključivati klasifikaciju većeg broja oboljenja i njihovo međusobno prepoznavanje.

Zadatak daljih istraživanja treba biti u odabiru odgovarajućeg skupa osobina i formata ulaznih podataka, tako da se postigne unaprijeđenje performansi u odnosu na postojeća rješenja, a i da se omogući razumijevanje uticaja izdvojenih osobina na rezultat klasifikacije.

REFERENCE

- [1] Acharya, U.R., Fujita, H., Lih, O.S., Hagiwara, Y., Tan, J.H. and Adam, M., 2017. Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network. *Information sciences*, 405, pp.81-90.
- [2] Ahsan, M.M. and Siddique, Z., 2022. Machine learning-based heart disease diagnosis: A systematic literature review. *Artificial Intelligence in Medicine*, p.102289.
- [3] Alfaras, M., Soriano, M.C. and Ortín, S., 2019. A fast machine learning model for ECG-based heartbeat classification and arrhythmia detection. *Frontiers in Physics*, p.103.
- [4] Bukata, I.T., Tegene, E., Gobena, T. and Woldeesenbet, Y.M., 2022. Prevalence and determinants of cardiac arrhythmias and conduction anomalies in adults aged ≥ 40 years in Jimma Town, Southwest of Ethiopia: a cross-sectional study. *African health sciences*, 22(1), pp.210-9.
- [5] Cai, J., Luo, J., Wang, S. and Yang, S., 2018. Feature selection in machine learning: A new perspective. *Neurocomputing*, 300, pp.70-79.
- [6] Cao, X.C., Yao, B. and Chen, B.Q., 2019. Atrial fibrillation detection using an improved multi-scale decomposition enhanced residual convolutional neural network. *IEEE Access*, 7, pp.89152-89161.

⁷ Spojni ritam (engl. *Junctional Rhythm*, J)

- [7] Cao, P., Li, X., Mao, K., Lu, F., Ning, G., Fang, L. and Pan, Q., 2020. A novel data augmentation method to enhance deep neural networks for detection of atrial fibrillation. *Biomedical Signal Processing and Control*, 56, p.101675.
- [8] Cha, M.J., 2018. Current Understanding on Mechanisms Leading to Atrial Fibrillation. *Korean circulation journal*, 48(2), pp.170-172.
- [9] Chen, X., Cheng, Z., Wang, S., Lu, G., Xv, G., Liu, Q. and Zhu, X., 2021. Atrial fibrillation detection based on multi-feature extraction and convolutional neural network for processing ECG signals. *Computer Methods and Programs in Biomedicine*, 202, p.106009.
- [10] Dai, H., Zhang, Q., Much, A.A., Maor, E., Segev, A., Beinart, R., Adawi, S., Lu, Y., Bragazzi, N.L. and Wu, J., 2021. Global, regional, and national prevalence, incidence, mortality, and risk factors for atrial fibrillation, 1990–2017: results from the Global Burden of Disease Study 2017. *European Heart Journal-Quality of Care and Clinical Outcomes*, 7(6), pp.574-582.
- [11] Dang, H., Sun, M., Zhang, G., Qi, X., Zhou, X. and Chang, Q., 2019. A novel deep arrhythmia-diagnosis network for atrial fibrillation classification using electrocardiogram signals. *IEEE Access*, 7, pp.75577-75590.
- [12] DeLago, A.J., Essa, M., Ghajar, A., Hammond-Haley, M., Parvez, A., Nawaz, I., Shalhoub, J., Marshall, D.C., Nazarian, S., Calkins, H. and Saliccioli, J.D., 2021. Incidence and mortality trends of atrial fibrillation/atrial flutter in the United States 1990 to 2017. *The American journal of cardiology*, 148, pp.78-83.
- [13] Erdenebayar, U., Kim, H., Park, J.U., Kang, D. and Lee, K.J., 2019. Automatic prediction of atrial fibrillation based on convolutional neural network using a short-term normal electrocardiogram signal. *Journal of Korean medical science*, 34(7).
- [14] Fan, X., Yao, Q., Cai, Y., Miao, F., Sun, F. and Li, Y., 2018. Multiscaled fusion of deep convolutional neural networks for screening atrial fibrillation from single lead short ECG recordings. *IEEE journal of biomedical and health informatics*, 22(6), pp.1744-1753.
- [15] Feigin, V.L., Brainin, M., Norrving, B., Martins, S., Sacco, R.L., Hacke, W., Fisher, M., Pandian, J. and Lindsay, P., 2022. World Stroke Organization (WSO): global stroke fact sheet 2022. *International Journal of Stroke*, 17(1), pp.18-29.
- [16] Feng, K. and Fan, Z., 2022. A novel bidirectional LSTM network based on scale factor for atrial fibrillation signals classification. *Biomedical Signal Processing and Control*, 76, p.103663.
- [17] Fujita, H. and Cimr, D., 2019. Computer aided detection for fibrillations and flutters using deep convolutional neural network. *Information Sciences*, 486, pp.231-239.
- [18] Fujita, H. and Cimr, D., 2019. Decision support system for arrhythmia prediction using convolutional neural network structure without preprocessing. *Applied Intelligence*, 49, pp.3383-3391.
- [19] Fu'adah, Y.N. and Lim, K.M., 2022. Classification of Atrial Fibrillation and Congestive Heart Failure Using Convolutional Neural Network with Electrocardiogram. *Electronics*, 11(15), p.2456.
- [20] Habib, A., Karmakar, C. and Yearwood, J., 2020. Choosing a sampling frequency for ECG QRS detection using convolutional networks. *arXiv preprint arXiv:2007.02052*.
- [21] Hindricks, G., Potpara, T., Dagres, N., Arbelo, E., Bax, J.J., Blomström-Lundqvist, C., Boriani, G., Castella, M., Dan, G.A., Dilaveris, P.E. and Fauchier, L., 2021. 2020 ESC Guidelines for the diagnosis and management of atrial fibrillation developed in collaboration with the European Association for Cardio-Thoracic Surgery (EACTS) The Task Force for the diagnosis and management of atrial fibrillation of the European Society of Cardiology (ESC) Developed with the special contribution of the European Heart Rhythm Association (EHRA) of the ESC. *European heart journal*, 42(5), pp.373-498.
- [22] He, R., Wang, K., Zhao, N., Liu, Y., Yuan, Y., Li, Q. and Zhang, H., 2018. Automatic detection of atrial fibrillation based on continuous wavelet transform and 2D convolutional neural networks. *Frontiers in physiology*, 9, p.1206.
- [23] Jang, H.J. and Cho, K.O., 2019. Applications of deep learning for the analysis of medical data. *Archives of pharmacal research*, 42, pp.492-504.
- [24] Jin, Y., Qin, C., Huang, Y., Zhao, W. and Liu, C., 2020. Multi-domain modeling of atrial fibrillation detection with twin attentional convolutional long short-term memory neural networks. *Knowledge-Based Systems*, 193, p.105460.
- [25] Jo, Y.Y., Cho, Y., Lee, S.Y., Kwon, J.M., Kim, K.H., Jeon, K.H., Cho, S., Park, J. and Oh, B.H., 2021. Explainable artificial intelligence to detect atrial fibrillation using electrocardiogram. *International Journal of Cardiology*, 328, pp.104-110.
- [26] Jun, T.J., Nguyen, H.M., Kang, D., Kim, D., Kim, D. and Kim, Y.H., 2018. ECG arrhythmia classification using a 2-D convolutional neural network. *arXiv preprint arXiv:1804.06812*.
- [27] Kalezić, M., Stojanović, R., Mirković, M., 2010. Comparative analysis of algorithms for detecting QRS segment of ECG. In *INFOTEH-JAHORINA*, 9, (p. 954-958).
- [28] Kim, Y.K., Lee, M., Song, H.S. and Lee, S.W., 2022. Automatic cardiac arrhythmia classification using residual network combined with long short-term memory. *IEEE Transactions on Instrumentation and Measurement*, 71, pp.1-17.
- [29] Kirchhof, P., Benussi, S., Kotecha, D., Ahlsson, A., Atar, D., Casadei, B., Castella, M., Diener, H.C., Heidbuchel, H., Hendriks, J. and Hindricks, G., 2016. 2016 ESC Guidelines for the management of atrial fibrillation developed in collaboration with EACTS. *European journal of cardio-thoracic surgery*, 50(5).
- [30] Kornej, J., Börschel, C.S., Benjamin, E.J. and Schnabel, R.B., 2020. Epidemiology of atrial fibrillation in the 21st century: novel methods and new insights. *Circulation research*, 127(1), pp.4-20.
- [31] Kornej, J., Benjamin, E.J. and Magnani, J.W., 2021. Atrial fibrillation: global burdens and global opportunities. *Heart*, 107(7), pp.516-518.
- [32] Lai, D., Zhang, X., Bu, Y., Su, Y. and Ma, C.S., 2019. An automatic system for real-time identifying atrial fibrillation by using a lightweight convolutional neural network. *IEEE access*, 7, pp.130074-130084.
- [33] Lippi, G., Sanchis-Gomar, F. and Cervellin, G., 2021. Global epidemiology of atrial fibrillation: an increasing epidemic and public health challenge. *International Journal of Stroke*, 16(2), pp.217-221.
- [34] Ma, F., Zhang, J., Chen, W., Liang, W. and Yang, W., 2020. An automatic system for atrial fibrillation by using a CNN-LSTM Model. *Discrete Dynamics in Nature and Society*, 2020, pp.1-9.
- [35] Ma, C., Wei, S., Chen, T., Zhong, J., Liu, Z. and Liu, C., 2020. Integration of results from convolutional neural network in a support vector machine for the detection of atrial fibrillation. *IEEE Transactions on Instrumentation and Measurement*, 70, pp.1-10.
- [36] Montagnon, E., Cerny, M., Cadrin-Chênevert, A., Hamilton, V., Derennes, T., Ilinca, A., Vandenbroucke-Menu, F., Turcotte, S., Kadoury, S. and Tang, A., 2020. Deep learning workflow in radiology: a primer. *Insights into imaging*, 11, pp.1-15.
- [37] Murakoshi, N. and Aonuma, K., 2013. Epidemiology of arrhythmias and sudden cardiac death in Asia. *Circulation Journal*, 77(10), pp.2419-2431.
- [38] Murat, F., Yildirim, O., Talo, M., Baloglu, U.B., Demir, Y. and Acharya, U.R., 2020. Application of deep learning techniques for heartbeats detection using ECG signals-analysis and review. *Computers in biology and medicine*, 120, p.103726.
- [39] Murat, F., Sadak, F., Yildirim, O., Talo, M., Murat, E., Karabatak, M., Demir, Y., Tan, R.S. and Acharya, U.R., 2021. Review of deep learning-based atrial fibrillation detection studies. *International journal of environmental research and public health*, 18(21), p.11302.
- [40] Nguyen, Q.H., Nguyen, B.P., Nguyen, T.B., Do, T.T., Mbinta, J.F. and Simpson, C.R., 2021. Stacking segment-based CNN with SVM for recognition of atrial fibrillation from single-lead ECG recordings. *Biomedical Signal Processing and Control*, 68, p.102672.
- [41] Nurmainsi, S., Tondas, A.E., Darmawahyuni, A., Rachmatullah, M.N., Partan, R.U., Firdaus, F., Tutuko, B., Pratiwi, F., Juliano, A.H. and Khoirani, R., 2020. Robust detection of atrial fibrillation from short-term electrocardiogram using convolutional neural networks. *Future Generation Computer Systems*, 113, pp.304-317.
- [42] Page, M.J., McKenzie, J.E., Bossuyt, P.M., Boutron, I., Hoffmann, T.C., Mulrow, C.D., Shamseer, L., Tetzlaff, J.M., Akl, E.A., Brennan, S.E. and Chou, R., 2021. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *International journal of surgery*, 88, p.105906.
- [43] Petmezas, G., Haris, K., Stefanopoulos, L., Kilintzis, V., Tzavelis, A., Rogers, J.A., Katsaggelos, A.K. and Maglaveras, N., 2021. Automated atrial fibrillation detection using a hybrid CNN-LSTM network on imbalanced ECG datasets. *Biomedical Signal Processing and Control*, 63, p.102194.
- [44] Rahul, J. and Sharma, L.D., 2022. Artificial intelligence-based approach for atrial fibrillation detection using normalised and short-

- duration time-frequency ECG. *Biomedical Signal Processing and Control*, 71, p.103270.
- [45] Rizwan, A., Zoha, A., Mabrouk, I.B., Sabbour, H.M., Al-Sumaiti, A.S., Alomaiy, A., Imran, M.A. and Abbasi, Q.H., 2020. A review on the state of the art in atrial fibrillation detection enabled by machine learning. *IEEE reviews in biomedical engineering*, 14, pp.219-239.
- [46] Rowan, C.J., Eskander, M.A., Seabright, E., Rodriguez, D.E., Linares, E.C., Gutierrez, R.Q., Adrian, J.C., Cummings, D., Beheim, B., Tolstrup, K. and Achrekar, A., 2021. Very low prevalence and incidence of atrial fibrillation among Bolivian forager-farmers. *Annals of global health*, 87(1).
- [47] Rubin, J., Parvaneh, S., Rahman, A., Conroy, B. and Babaeizadeh, S., 2018. Densely connected convolutional networks for detection of atrial fibrillation from short single-lead ECG recordings. *Journal of electrocardiology*, 51(6), pp.S18-S21.
- [48] Sager, S., Bemhardt, F., Kehrlé, F., Merkert, M., Potschka, A., Meder, B., Katus, H. and Scholz, E., 2021. Expert-enhanced machine learning for cardiac arrhythmia classification. *PloS one*, 16(12), p.e0261571.
- [49] Salinas-Martínez, R., De Bie, J., Marzocchi, N. and Sandberg, F., 2020, September. Automatic detection of atrial fibrillation using electrocardiogram and convolutional neural network. In *2020 Computing in Cardiology* (pp. 1-4). IEEE.
- [50] Saglietto, A., Ballatore, A., Xhakupi, H., De Ferrari, G.M. and Anselmino, M., 2022. Atrial Fibrillation and dementia: Epidemiological insights on an undervalued association. *Medicina*, 58(3), p.361.
- [51] Sahoo, S., Subudhi, A., Dash, M. and Sabut, S., 2020. Automatic classification of cardiac arrhythmias based on hybrid features and decision tree algorithm. *International Journal of Automation and Computing*, 17(4), pp.551-561.
- [52] Salau, A.O. and Jain, S., 2019, March. Feature extraction: a survey of the types, techniques, applications. In *2019 international conference on signal processing and communication (ICSC)* (pp. 158-164). IEEE.
- [53] Seo, H.C., Oh, S., Kim, H. and Joo, S., 2021. ECG data dependency for atrial fibrillation detection based on residual networks. *Scientific Reports*, 11(1), pp.1-8.
- [54] Singh, J.P., Fontanarava, J., de Massé, G., Carbonati, T., Li, J., Henry, C. and Fiorina, L., 2022. Short-term prediction of atrial fibrillation from ambulatory monitoring ECG using a deep neural network. *European Heart Journal-Digital Health*, 3(2), pp.208-217.
- [55] Smith, S.W., Rapin, J., Li, J., Fleureau, Y., Fennell, W., Walsh, B.M., Rosier, A., Fiorina, L. and Gardella, C., 2019. A deep neural network for 12-lead electrocardiogram interpretation outperforms a conventional algorithm, and its physician override, in the diagnosis of atrial fibrillation. *IJC Heart & Vasculature*, 25, p.100423.
- [56] Sun, L., Wang, Y., He, J., Li, H., Peng, D. and Wang, Y., 2020. A stacked LSTM for atrial fibrillation prediction based on multivariate ECGs. *Health information science and systems*, 8, pp.1-7.
- [57] Tao, W., 2022. Progress and Reflections of International Cartographic Education: A Bibliometric Analysis of ICCs Literatures Since 2000. *Cartography & Geoinformation*, 21.
- [58] Tutuko, B., Nurmaini, S., Tondas, A.E., Rachmatullah, M.N., Darmawahyuni, A., Esafri, R., Firdaus, F. and Sapitri, A.I., 2021. AFibNet: an implementation of atrial fibrillation detection with convolutional neural network. *BMC Medical Informatics and Decision Making*, 21, pp.1-17.
- [59] Wakili, R., Voigt, N., Käbb, S., Dobrev, D. and Nattel, S., 2011. Recent advances in the molecular pathophysiology of atrial fibrillation. *The Journal of clinical investigation*, 121(8), pp.2955-2968.
- [60] Wang, J., 2020. Automated detection of atrial fibrillation and atrial flutter in ECG signals based on convolutional and improved Elman neural network. *Knowledge-Based Systems*, 193, p.105446.
- [61] Wang, J., 2020. A deep learning approach for atrial fibrillation signals classification based on convolutional and modified Elman neural network. *Future Generation Computer Systems*, 102, pp.670-679.
- [62] Wang, J., 2021. An intelligent computer-aided approach for atrial fibrillation and atrial flutter signals classification using modified bidirectional LSTM network. *Information Sciences*, 574, pp.320-332.
- [63] Wu, J., Nadarajah, R., Nakao, Y.M., Nakao, K., Wilkinson, C., Mamas, M.A., Camm, A.J. and Gale, C.P., 2022. Temporal trends and patterns in atrial fibrillation incidence: a population-based study of 3·4 million individuals. *The Lancet Regional Health-Europe*, 17, p.100386.
- [64] Xu, X., Wei, S., Ma, C., Luo, K., Zhang, L. and Liu, C., 2018. Atrial fibrillation beat identification using the combination of modified frequency slice wavelet transform and convolutional neural networks. *Journal of healthcare engineering*, 2018.
- [65] Zhang, X., Li, J., Cai, Z., Zhang, L., Chen, Z. and Liu, C., 2021. Overfitting suppression training strategies for deep learning-based atrial fibrillation detection. *Medical & Biological Engineering & Computing*, 59, pp.165-173.