

Neuroniniais tinklais grįstų triukšmo šalinimo EKG signalė metodų eksperimentinis tyrimas

Matas Valatka, Jolita Bernatavičienė

Vilniaus universitetas, Duomenų mokslo ir skaitmeninių technologijų institutas,
Akademijos g. 4, LT-08412 Vilnius
matas.valatka@mif.stud.vu.lt

Santrauka. Širdies ir kraujagyslių ligos yra pagrindinė mirties priežastis pasaulyje, o jų diagnostikai plačiai naudojama elektrokardiograma (EKG), tačiau EKG signalų analizę apsunkina įvairūs triukšmai. Ši problema ypač aktuali nešiojamuose įrenginiuose ar monitoriuose, todėl reikalingas efektyvus signalų apdorojimas. Be to, signalų bangų kaip P, T ir QRS kompleksų segmentavimas be išankstinio triukšmų pašalinimo yra sudėtingas. Neuroninių tinklų tokių kaip DMAM, BiGRU ar CS-TRANS pagalba galima spręsti abi problemas formuojant tinklų junginį, kai vienas modelis pašalina triukšmus, o kitas segmentuoja signalą. Šių modelių mokymui būtini ne tik dideli duomenų kiekiai, bet ir tiksliai suanotuoti signalai. Paminėti modeliai gali pasiekti signalo ir triukšmo santykį iki 20 dB, o segmentuojant išlaikyti atkūrimo metriką visoms bangoms iki 100 %, tačiau preciziškumo matas išlieka mažesnis. Tyrimo metu nustatyta, kad geriausi rezultatai fiksuoti naudojant DMAM modelį apdorojant -3 dB raumenų triukšmą, o segmentuojant apdorotą signalą atkūrimo metrika išliko maksimali visoms bangos ir preciziškumo matas aukštas P ir T bangoms, bet QRS komplekso šiek tiek mažesnis. Gauti rezultatai įrodo, kad praktikoje pritaikius šiuos algoritmus galima ne tik pagerinti EKG signalų diagnostikos tikslumą, bet ir sumažinti medicinos specialistų darbo krūvį bei užtikrinti aukštesnę pacientų priežiūros kokybę.

Raktiniai žodžiai: EKG signalai, neuroniniai tinklai, triukšmų šalinimas, segmentavimas, raumenų triukšmas, GRU, difuzinis modelis, U-Net, CS-TRANS.

1 Įvadas

Širdies ir kraujagyslių ligos yra pagrindinė mirties priežastis pasaulyje, kasmet nusinešanti apie 17,9 milijono gyvybių [1]. Daugiau nei keturi iš penkių atvejų baigiasi mirtimi dėl širdies smūgių ir insultų, o trečdalis šių mirčių įvyksta žmonėms, jaunesniems nei 70 metų. Tuo tarpu elektrokardiograma (EKG) [2] yra vienas pagrindinių diagnostinių įrankių, naudojamų širdies

veiklos sutrikimams nustatyti. Tačiau šio metodo veiksmingumas tiesiogiai priklauso nuo galimybės tiksliai analizuoti EKG signalus, kurie dažnai būna paveikti triukšmų, signalų deformacijų ar kitų trikdžių. Siekiant pagerinti širdies ir kraujagyslių ligų diagnozavimo tikslumą ir efektyvumą, būtina tobulinti EKG signalų apdorojimo metodus, įskaitant triukšmų šalinimą, svarbių segmentų identifikavimą. Šių metodų tyrimai ir optimizavimas ne tik padeda užtikrinti patikimesnę diagnostiką, bet ir leidžia sumažinti medicininio personalo darbo krūvį bei pagerinti pacientų gydymo kokybę.

Vienas iš dažniausiai sutinkamų triukšmų yra raumenų susitraukinėjimas (angl. *muscle artefacts*). Šio tipo triukšmai persidengia su visu elektrokardiogramos dažnių spektru, todėl pašalinti juos yra itin sunku. Įprastomis sąlygomis išvengti šių triukšmų nėra sudėtinga – pacientas turi atsipalaiduoti ir nejudėti. Visgi, jei žmogus kenčia nuo, pavyzdžiui, nevalingų judesių, šių triukšmų išvengti praktiškai neįmanoma.

Triukšmai daugiausiai pasireiškia, kai širdies ritmas matuojamas ne stacionariais, o nešiojamais įrenginiais kaip Holterio monitorius, todėl tokiais atvejais būtinas atitinkamas signalo apdorojimas, kad šis būtų aiškesnis ir neklaidintų specialistų, priimant sprendimus dėl žmogaus sveikatos būklės.

Tiek triukšmų šalinimo, tiek signalo segmentavimo procesai yra pakankamai susiję tarpusavyje, kadangi nešvarų signalą segmentuoti yra praktiškai neįmanoma ir nenaudinga. Tačiau pasitelkus neuroninių tinklų modelius galima gauti neblogus rezultatus sprendžiant tiek triukšmų, tiek segmentavimo uždavinius. Egzistuoja pakankamai nemažai skirtingų modelių, kurie dažnai būna specifiški vienai užduočiai, tačiau sujungus du modelius į vieną bendrą darbo eigą (angl. *workflow*), gauname pilną procesą, kai vienas dedikuotas modelis sprendžia triukšmų šalinimą, o kitas paskirtas segmentavimui. Tokio junginio tikslas ne tik efektyviai šalinti nepageidaujamus triukšmus iš signalo, tačiau ir gebėti tiksliai išskirti pagrindines EKG signalo dalis kaip QRS kompleksas, P ir T bangos.

Neuroninių tinklų modelių mokymui būtini dideli duomenų kiekiai, tačiau kartu su signalais svarbios ir jų anotacijos, nurodančios reikšmingų signalo dalių pradžią, pabaigą ar net viršūnių taškus. Ši informacija leidžia įvertinti modelių integravimo į vieną bendrą junginį efektyvumą ne tik šalinant triukšmus, bet ir segmentuojant signalą. Galiausiai, remiantis pasirinktų metrikų rezultatais, galima daryti išvadą apie neuroninių tinklų gebėjimą spręsti su EKG signalo analize susijusius uždavinius.

2 Duomenys

Tyrime yra naudojami du duomenų rinkiniai - QTDB [3] ir MIT-BIH Noise Stress [4]. Pirmąjį sudaro 105 penkiolikos minučių bei dviejų derivacijų EKG įrašai. Taip pat yra pateikiamos QRS komplekso, P ir T bangų pradžios, viršūnės bei pabaigos žymės. Antrasis rinkinys turi pagrindinius triukšmus, tarp kurių ir raumenų susitraukimo, kuris yra naudojamas norint pasidaryti triukšmingus signalus modelių apmokymui, o vėliau, panaudojant anotacijas iš QTDB duomenų bazės, patikrinti modelio gebėjimą išskirti atkurto signalo svarbias bangas.

Siekiant turėti daugiau duomenų modelio apmokymui, skirtingos derivacijos buvo traktuojamos kaip atskiri signalai, todėl rezultate modeliams naudota 210 EKG įrašų, kurie buvo skirstyti į mokymo, testavimo ir validavimo duomenis santykiu 148/31/31 atitinkamai.

Kadangi tiek QTDB, tiek MIT-BIH Noise Stress duomenų bazių įrašai atitinkamai yra 250 Hz ir 500 Hz dažnių, todėl teko dažnį suvienodinti pasirenkant naudoti 360 Hz dažnį viso tyrimo metu, kad būtų išlaikytas geriausias informacijos vientisumas. Tačiau šis pasirinkimas dar gali būti tikslinamas, atsižvelgiant į analizės rezultatus ateityje, kai būtų tyrinėjama rezultatų priklausomybė nuo dažnio.

Galiausiai, suvienodinus įrašų dažnius, buvo sukurti triukšmingi signalai iš originalaus signalo ir raumenų susitraukimo triukšmo. Šis procesas atliekamas sudėties būdu (2.1), kai triukšmo reikšmė dar papildomai yra kontroliuojama α daugiklio, kurio tikslas prislopinti arba kaip tik padidinti triukšmą.

$$noisy_signal = signal + \alpha * noise \quad (2.1)$$

Be to, MIT-BIH Noise Stress kiekvienam iš triukšmų tipų turi po 2 kanalus, todėl tyrimo metu buvo nuspręsta vieną kanalą išnaudoti tik mokymo, o kitą testavimo duomenų sudarymui. Tokiu būdu yra bandoma patikrinti modelio universalumą, panaudojant skirtingas triukšmų duomenų aibes.

3 Neuroninių tinklų modeliai

Eksperimentiniame tyrime buvo panaudoti trys triukšmo šalinimo modeliai: BiGRU (angl. *bidirectional gated recurrent units (BiGRU)*) [3], DMAM (angl. *diffusion model with self-attention module (DMAM)*) [4], CS-TRANS (angl. *convolutional neural network and stationary wavelet transformation combination*

with transformer (CS-TRANS)) [7], o segmentavimui buvo pasitelktas U-Net [5] modelis. Kiekvienas triukšmo šalinimo algoritmas buvo komponuojamas kartu su segmentavimo modeliu, kad būtų sukurta pilna darbo eiga, t. y. nuo trikdžių šalinimo iki svarbiausių EKG signalo dalių segmentavimo.

BiGRU yra dvikryptis (angl. *bidirectional*) modelis, paremtas GRU (angl. *gated recurrent units*) ląstelėmis, kurios yra rekurentinių neuroninių tinklų (RNN) realizavimo būdas, skirtas sekų analizei. RNN tinklai geba modeliuoti sekų duomenų priklausomybes, nes įtraukia grįžtamuosius ryšius tarp paslėptųjų vienetų, taip išlaikydami ankstesnę informaciją. Kadangi fiziologiniai signalai, tokie kaip EKG, yra laiko eilutės duomenys, RNN leidžia efektyviai modeliuoti jų struktūrą. GRU ląstelių pagrindiniai komponentai – atstatymo (angl. *reset*) ir atnaujinimo (angl. *update*) vartai, kurie reguliuoja informacijos srautą, užtikrindami tinklo gebėjimą išlaikyti būseną ilgalaikėje perspektyvoje.

Difuzinis modelis [6] (DMAM) yra generatyvinis tinklas, kuris remiasi iteratyviu difuzijos procesu, palaipsniui perdirbančiu triukšmingus duomenis į rekonstruotus. Algoritmas yra grindžiamas dviem pagrindiniais etapais: triukšmo pridėjimu, kol gaunamas beveik Gauso baltasis triukšmas, ir triukšmo šalinimu. Mokymo metu modelis išmoksta atkurti duomenų struktūrą, kuri buvo pažeista iteratyviu triukšmu. Po mokymo modelis geba atvirkštine eiga pašalinti triukšmą ir atkurti originalius duomenis iš atsitiktinio triukšmo būsenos. Šis požiūris leidžia modeliui užtikrinti didelį tikslumą net ir dirbant su labai triukšmingais ar fragmentuotais duomenimis. Todėl ši architektūra pasižymi praktiniu efektyvumu ir buvo pradėta taikyti plačiai srityse kaip vaizdų generavimas, garso apdorojimas ar biomedicininų signalų analizė.

Nors pirmiau U-Net modelis buvo pritaikytas nuotraukų apdorojime, tačiau jo panaudojimas vis dažniau pritaikomas ir EKG tyrimuose. Tradicinio U-Net tinklo architektūra susideda iš traukimosi kelio, kuris atitinka tipinio konvoliucijos tinklo struktūrą, ir išsiplėtimo kelio, kuris susideda iš požymių žemėlapių išsiplėtimo. Iš viso tinklą sudaro 23 konvoliuciniai sluoksniai.

Konvoliucinis neuroninis tinklas reikalauja daug duomenų ir nėra kryptingas, todėl buvo pasiūlytas naujas sprendimas CS-TRANS [7], kurio architektūra susideda iš konvoliucinio tinklo ir stacionarios bangelės junginio (CNN-SWT), kuris efektyviai išgauna daugiamačius signalų požymius, o įtrauktas papildomai transformerio mechanizmas pagerina globalių savybių išgavimą. Iš esmės modelis pagrįstas U-Net architektūra, kadangi susideda iš kodavimo ir dekodavimo dalių sujungtų šuolinėmis jungtimis informacijos perdavimui.


Visi atsirinkti modeliai, nors struktūriškai yra skirtingi, tačiau pritaikomi tam pačiam uždaviniui – nagrinėti bei apdoroti EKG signalus, o pagrindinis tikslas išsiaiškinti, kuris modelių junginys geba tiksliausiai susitvarkyti su nešvariais signalais.

4 Eksperimento rezultatai

Atliekant eksperimentinį tyrimą buvo fiksuojamos pasirinktos metrikos, kad modelių gauti rezultatai būtų tinkamai palyginti. Triukšmų šalinime buvo skaičiuotas signalo ir triukšmo santykis (SNR) – triukšmingo (SNR IN), apdoroto (SNR OUT) ir jų skirtumo (SNR IMPR) – šio santykio esmė parodyti triukšmo lygį, kai didesnė reikšmė indikuoja geresnį veiksmingumą, vidutinė kvadratinė paklaida (RMSE), kuri skirta klaidai tarp prognozuotos ir tikrosios reikšmės nustatyti, ir procentinis santykinis nuokrypis (PRD) – tai atstumu pagrįstas panašumo matas, kur mažesnė reikšmė indikuoja geresnius rezultatus [9]. Segmentavimui pasirinkta skaičiuoti atkūrimo ir preciziškumo metrikas [8], kadangi atkūrimo matas parodo, kaip tiksliai modelis klasifikavo teisingą klasę, o preciziškumas naudojamas įvertinti, kiek pavyzdžių, kuriuos modelis prognozavo kaip teigiamus, iš tikrųjų yra neigiami. Tokiu būdu yra siekiama įvertinti bangų ribų tikslumą ir bendrą segmentavimo kokybę, kadangi būtina ne tik nustatyti reikšmingus įvykius, bet ir užtikrinti jų tikslų žymėjimą. Taip pat, segmentuojant pasirinkta laikytis 150 ms standarto tolerancijos ribai [10] nustatant prognozes (1 pav.).

Visų modelių triukšmo šalinimo rezultatai pateikti 1 lentelėje, kur geriausi rezultatai paryškinti išskyrus triukšmingo (SNR IN) ir apdoroto (SNR OUT) signalų metrikas, kadangi yra išvesta bendra šių reikšmių vertė (SNR IMPR) (4.2). Be to, formuojant triukšmingus signalus buvo naudojama triukšmo valdymo funkcija, kurios tikslas kontroliuoti triukšmo lygį, t. y. didinti arba mažinti. Ši funkcija veikia kaip daugiklis paimtam triukšmo segmentui iš MIT-BIH Noise Stress, tai galutinė SNR IN metrikos reikšmė priklauso tiek nuo apdirbamo triukšmo segmento, tiek nuo pasirinktos triukšmo funkcijos reikšmės. Eksperimentui pasirinkta naudoti šias reikšmes: 5, 0 ir -5, kurios generavo nuo -3 iki -19 dB triukšmą. Tokie triukšmo lygiai buvo pasirinkti siekiant įvertinti modelių atsparumą skirtingam triukšmo intensyvumui, kadangi realiose situacijose signalai gali pasitaikyti tiek su mažu triukšmu, tiek stipriai užteršti.

$$SNR_{IMPR} = SNR_{OUT} - SNR_{IN} \quad (4.2)$$



1 pav. Tolerancijos ribos pavyzdys QRS kompleksui, kai modelis tarp šių ribų prognozę laiko teisinga

Rezultatai iš triukšmo šalinimo (1 lentelė) parodė, kad visi modeliai geba šalinti triukšmus, nes didėjant triukšmui, kitaip tariant mažėjant SNR IN metrikai, galutinė signalo ir triukšmo metrika SNR IMPR didėja, tačiau tai dar neįrodo proceso efektyvumo. Iš RMSE metrikos matyti, kad BiGRU ir CS-TRANS modeliai atlieka daugiau klaidų nei DMAM, o iš to galime daryti išvadą, kad DMAM yra labiau patikimesnis. Nagrinėjant PRD metriką iš konteksto išpuola CS-TRANS modelis, kuris fiksuoja dvigubai prastesnius rezultatus nei kiti. Tuo tarpu DMAM ir BiGRU demonstruoja pakankamai neblogus PRD rezultatus, tačiau verta pabrėžti, kad šįkart BiGRU visuomet davė geresnį rezultatą. Visgi, jei žiūrėtume rezultatus su didžiausiu triukšmu, galime daryti išvadą, kad DMAM fiksuoja žymiai mažesnę RMSE rodiklį, o ši metrika labiausiai pabrėžia modelio tikslumą bei efektyvumą ir būtent dėl šios priežasties DMAM modelis turi daugiau potencialo nei likę nagrinėti tinklai.

Segmentavimo rezultatai, jungiant kiekvieną tinklą su U-Net modeliu, pateikti 2 lentelėje.

1 lentelė. Triukšmo šalinimo modelių rezultatai. Rodyklės žymi metrikos pageidautiną vertę.

Modelis (triukšmo formulės reikšmė)	RMSE ↓	PRD ↓	SNR IN ↑	SNR OUT ↑	SNR IMPR ↑
DMAM (5)	0,06 ± 0,04	34,52 ± 15,00	-2,84 ± 5,70	10,89 ± 2,87	13,72 ± 6,24
BiGRU (5)	0,30 ± 0,02	26,23 ± 6,88	-9,07 ± 1,88	12,24 ± 1,97	21,30 ± 2,93
CS-TRANS (5)	0,42 ± 0,38	74,31 ± 40,45	-4,25 ± 5,23	6,04 ± 2,47	10,29 ± 5,81
DMAM (0)	0,08 ± 0,04	43,21 ± 19,52	-7,84 ± 5,70	9,09 ± 2,90	16,93 ± 6,18
BiGRU (0)	0,53 ± 0,03	34,41 ± 9,13	-14,07 ± 1,88	10,08 ± 2,00	24,15 ± 2,59
CS-TRANS (0)	0,76 ± 0,68	91,20 ± 50,32	-9,25 ± 5,23	4,72 ± 2,17	13,97 ± 5,60
DMAM (-5)	0,10 ± 0,06	56,59 ± 28,27	-12,84 ± 5,70	6,81 ± 3,12	19,65 ± 6,20
BiGRU (-5)	0,95 ± 0,05	48,18 ± 12,79	-19,07 ± 1,88	7,44 ± 2,06	26,51 ± 2,28
CS-TRANS (-5)	1,34 ± 1,21	114,91 ± 59,62	-14,25 ± 5,23	2,98 ± 1,93	17,23 ± 5,24

2 lentelė. U-Net modelio segmentavimo rezultatai (%).

Modelis (triukšmo formulės reikšmė)	Preciziškumas pradžios			Atkūrimas pradžios			Preciziškumas pabaigos			Atkūrimas pabaigos		
	P	QRS	T	P	QRS	T	P	QRS	T	P	QRS	T
DMAM (5)	96	71	96	100	100	100	98	83	98	100	100	100
BiGRU (5)	16	76	71	8	54	82	88	95	92	76	83	83
CS-TRANS (5)	34	51	78	40	96	89	81	71	90	77	98	95
DMAM (0)	91	85	98	98	100	100	95	92	99	99	100	100
BiGRU (0)	13	73	67	7	43	76	88	94	90	77	79	82
CS-TRANS (0)	35	61	79	50	99	94	79	79	90	79	94	97
DMAM (-5)	89	71	89	94	100	100	94	83	94	97	100	100
BiGRU (-5)	8	64	62	4	26	68	88	93	88	77	70	81
CS-TRANS (-5)	34	51	78	40	96	89	81	71	90	77	98	95

Iš esmės segmentavimo rezultatai (2 lentelė) patvirtina, kad DMAM modelis yra optimalus pagal atkūrimo ir preciziškumo kriterijus, kadangi beveik visais atvejais, segmentuojant šio modelio apdorotus signalus, gautami geriausi rezultatai, o ten kur išimtinai BiGRU tinklas pranoko DMAM modelį, tai skirtumas sąlyginai nedidelis. Be to, CS-TRANS ir BiGRU tinklams


itin prastai sekėsi fiksuoti P bangų pradžias, bet bendrai paėmus visi modeliai demonstravo geresnius rezultatus prognozuojant visų bangų pabaigas. DMAM modelis itin išsiskiria atkūrimo metrikos rezultatais, kas parodo tinklo gebėjimą teisingai klasifikuoti bangų pradžias ir pabaigas, tačiau būtent QRS bangos preciziškumo matas informuoja, jog ne visuomet prognozės bus tikslios.

Apibendrinant galima teigti, kad visi modeliai demonstravo neblogus rezultatus, tačiau DMAM rezultatai (2 pav.) išsiskyrė labiausiai dėl stabilumo tiek triukšmų šalinime, tiek segmentavime.

5 Išvados

Atlikus tyrimą ir apibendrinus rezultatus, galima teigti, kad iš nagrinėtų modelių DMAM demonstravo geriausius rezultatus tiek šalinant triukšmą, tiek segmentuojant signalą. Tuo tarpu BiGRU ir CS-TRANS tinklai taip pat neblogai atlikdavo signalo valymą nuo trikdžių, tačiau segmentavimo etape pasirodė jų trūkumai, kai U-Net modelis vis prasčiau identifikuodavo bangų pradžias ir pabaigas, ypač P bangos. Nepaisant to, tyrimas parodė, kad galima sukurti patikimus automatizuotus įrankius, skirtus EKG signalų nagrinėjimui. Geriausias tyrimo rezultatas fiksuotas naudojant DMAM (5) modelį, kai šiam teko apdoroti -3 dB raumenų triukšmą, o RMSE metrika buvo 0,06, PRD nustatyta ~35 % ir SNR IMPR parodė pagerėjimą iki ~14. Segmentuojant prieš tai apdorotą signalą gauta atkūrimo metrika maksimali visoms bangos, o preciziškumo matas fiksuotas 96 % ir 98 % P ir T bangų pradžioms bei pabaigoms, o QRS kompleksui pradžia ir pabaiga atitinkamai 71 % ir 83 %. Taigi, rezultatai parodo, kad algoritmai gali būti efektyvūs automatizuoti įrankiai, galintys apdirbti EKG signalas, o jų pritaikymas praktikoje galėtų ne tik sumažinti medikų darbo krūvį, bet ir pagerinti pacientų gydymo kokybę.

Ateiityje planuojama pratęsti eksperimentinį tyrimą įtraukiant daugiau triukšmų tipų ar net jų kombinacijų, kurios leistų dar tiksliau įvertinti modelių efektyvumą bei universalumą, kadangi praktikoje nešiojamuose įrenginiuose pasitaiko ir tokių triukšmų kaip bazinės linijos (angl. *base-line wander*), atsirandantis dėl kvėpavimo ar kitų mechaninių judesių, ar elektros energijos tinklo trikdžiai (angl. *power-line interference*), galintys atsirasti dėl naudojamo prietaiso.



2 pav. DMAM (5) modelio rezultatų grafikai

Padėka. Dėkojame Vilniaus universiteto ITAPC padaliniui už suteiktus IT išteklius (HPC), kurie leido greičiau apmokyti modelius bei supaprastino viso tyrimo atlikimą.

Tyrimas finansuojamas pagal LR Švietimo, mokslo ir sporto ministerijos programą „Universitetų ekselencijos iniciatyvos“ (LR ŠMSM mokslo plėtros programos pažangos priemonė Nr. 12-001-01-01-01 „Gerinti mokslo ir studijų aplinką“).

Literatūra

- [1] „World Health Organization,“ [Online]. Available: https://www.who.int/health-topics/cardiovascular-diseases#tab=tab_1. [Accessed 6 1 2025].
- [2] „Cancer Research UK,“ [Online]. Available: <https://www.cancerresearchuk.org/about-cancer/tests-and-scans/ecg>. [Accessed 6 1 2025].

- [3] Laguna P, Mark RG, Goldberger AL, Moody GB, „A Database for Evaluation of Algorithms for Measurement of QT and Other Waveform Intervals in the ECG,” *Computers in Cardiology*, 1997.
- [4] Moody GB, Muldrow WE, Mark RG, „A noise stress test for arrhythmia detectors,” *Computers in Cardiology*, 1984.
- [5] Mariana Dias, Phillip Probst, Luís Silva, Hugo Gamboa, “Cleaning ECG with Deep Learning: A Denoiser Tested in Industrial,” *SN Computer Science*, 2024.
- [6] Hu, Zheng-Dong and Hong, Yang and Huang, Jia-Yan and Chen, Kai-Hong and Zhao, Wan-Qi and Grau, Antoni and Guerra, Edmundo and Wang, Chuan-Sheng and Zhang, Fu-Quan, “DMAM-ECG: A Diffusion Model with Self-Attention,” *Journal of Network Intelligence*, no. 9, 2024.
- [7] Huyang Peng, Xiaohan Chang, Zhenjie Yao, Donglin Shi, Yongrui Chen, “A deep learning framework for ECG denoising and classification,” *Biomedical Signal Processing and Control*, vol. 94, 2024.
- [8] Ronneberger, O., Fischer, P., & Brox, T, “U-net: Convolutional networks for biomedical image segmentation,” *Medical image computing and computer-assisted intervention*, pp. 234-241, 2015.
- [9] Chatterjee, Shubhojeet and Thakur, Rini Smita and Yadav, Ram Narayan and Gupta, Lalita and Raghuvanshi, Deepak Kumar, “Review of noise removal techniques in ECG signals,” *IET Signal Processing*, vol. 14, no. 9, 2020.
- [10] Testing and reporting performance results of cardiac rhythm and ST segment measurement algorithms, American National Standards Institute/EC57, ANSI/AAMI, 2012.