

Difuziniais modeliais grįsto EKG triukšmo šalinimo palyginamasis vertinimas

**Simonas Šimėnas, Zigmantas Kęstutis Juškevičius,
Jolita Bernatavičienė**

Vilniaus universitetas, Matematikos ir informatikos fakultetas,
Duomenų mokslo ir skaitmeninių technologijų institutas,
Akademijos g. 4, LT-04812 Vilnius, Lietuva
simonas.simenas@mif.stud.vu.lt

Santrauka. Elektrokardiogramos signalai yra svarbūs širdies ritmo sutrikimų nustatymui ir širdies veiklos vertinimui, tačiau šiuos signalus, ypač registruojamus nešiojamaisiais įrenginiais, dažnai iškraipo įvairūs triukšmai, apsunkinantys patikimą kardiogramų analizę. Šiame tyrime nagrinėjama elektrokardiogramų triukšmo šalinimo problema ir lyginami du difuzija grįsti metodai, *DeScOD* ir *DMAM*, bei bazinis giliojo mokymosi metodas *DeepFilter*. Vertinimas atliktas naudojant MIT-BIH aritmijų ir QT duomenų bazes, o signalai buvo užteršti bazinės linijos dreifo, elektrodų judesio ir raumenų artefaktų triukšmu iš MIT-BIH triukšmo atsparumo bandymų duomenų bazės. Nustatyta, kad sunkiausiai pašalinamas elektrodų judesio artefaktų triukšmas, o difuzijos modeliai nuosekliai pranoko *DeepFilter*. Geriausius rezultatus pasiekė *DeScOD*, kurio triukšmo šalinimo kokybė, palyginti su *DeepFilter*, buvo 20–30 % geresnė, o *DMAM* pademonstravo panašų pranašumą.

Raktiniai žodžiai: EKG triukšmo šalinimas, difuzijos modeliai, gilusis mokymasis, signalų kokybės vertinimas, triukšmo filtravimas.

1 Įvadas

Triukšmo šalinimas iš elektrokardiogramos (EKG) yra būtinas patikimai klinicinei interpretacijai užtikrinti, nes tolimesni sprendimai priklauso nuo tiksliai išsaugotos bangos formos ir laiko charakteristikų. Klasikiniai filtravimo metodai dažnai remiasi prielaida, kad širdies dūžio signalas ir triukšmas yra stacionarūs bei spektriškai atskiriami, tačiau ilgalaikio stebėjimo ir dėvimųjų įrenginių įrašuose ši prielaida dažnai pažeidžiama [1].

EKG triukšmo šalinimui plačiai taikyti adaptyvūs bangelių ribinio apdorojimo (angl. *thresholding*) metodai, leidžiantys diferencijuotai slopinti triukšmą skirtinguose lygiuose ir kartu geriau išsaugoti morfologiją [2]. Taip pat taikomi

duomenimis grįsti empirinių modų dekompozicijos (EMD) [3] metodai, kurie signalą išskaido į vidines modų funkcijas (IMF) ir filtruoja pasirinktus signalo komponentus, tačiau yra jautrūs hiperparametrų pasirinkimui, todėl skirtingų triukšmo tipų atvejais stabilus metodų veikimas negali būti užtikrintas.

Giliojo mokymosi metodai suteikia daugiau lankstumo modeliuojant EKG signalus, tačiau jų rezultatai tebėra jautrūs duomenų aibių pokyčiams, nepažįstamiems triukšmams ir paciento atžvilgiu neatskirtų duomenų aibių vertinimo protokolams [4,5]. Naujausi širdies dūžių klasifikavimo tyrimai parodė, kad pacientų atžvilgiu atskirti mokymo ir testavimo rinkiniai leidžia realistiškiau įvertinti modelio generalizaciją [6]. Difuzijos modeliai šiame kontekste yra perspektyvūs, nes jie iteratyviai atkuria švarų signalą ir kartu modeliuoja plačią galimų rekonstrukcijų aibę [7].

Šiame darbe buvo lyginami du difuzija grįsti triukšmo šalinimo metodai, *DeScoD* [8] ir *DMAM* [9], bei bazinis *DeepFilter* [10]. *DeepFilter* šiame tyrime naudotas kaip bazinis, ne difuzinis, giliojo mokymosi metodas, kurio rezultatai pranoko kitus giliojo mokymosi bei klasikinio filtravimo metodus ir todėl sudaro reprezentatyvų atskaitos tašką palyginimui su difuzijos modeliais [10]. Lyginimas atliktas taikant mokymo ir testavimo aibių skaidymo pagal pacientus metodiką su trimis standartizuotais triukšmo tipais: bazinės linijos dreifu (BW), elektrodų judesiu (EM) ir raumenų artefaktais (MA). Vertinimas atliktas naudojant MIT-BIH aritmijų duomenų bazę [11] bei MIT-BIH triukšmo atsparumo bandymų duomenų bazės (NSTDB) [12] triukšmo segmentus, o modelių pritaikomumo naujoms duomenų aibėms vertinimas atliktas pasitelkus QT duomenų bazės [13] įrašus.

Šis darbas išplečia ankstesnę autorių analizę [14], papildydamas ją detalesniu metodikos aprašymu, išplėsta rezultatų analize ir išsamesniu aptarimu.

2 Metodika

Šiame skyriuje aprašomi naudoti duomenys, triukšmingų signalų generavimo metodika, vertinti modeliai, duomenų skaidymas pagal pacientus ir taikytos vertinimo metrikos.

2.1 Triukšmo tipai ir triukšmingų dūžių sintetinis generavimas

Tyrimui naudoti etaloniniai dūžiai iš MIT-BIH aritmijų duomenų bazės [11] ir QT duomenų bazės [13], o triukšmo segmentai buvo gauti iš MIT-BIH

triukšmo atsparumo bandymų duomenų bazės (NSTDB) [12] BW, EM bei MA triukšmo signalų. BW yra žemo dažnio dreifo, kurį sukelia kvėpavimas ir kūno judesiai, rezultatas. Jis gali pakeisti izoelektrinės bazinės linijos formą, taigi ir ST segmento tendenciją. MA įneša plačiajuostę interferenciją, galinčią užgožti mažos amplitudės P ir T bangas. EM generuoja staigius, stipriai nestacionarius, pereinamuosius artefaktus, kurie deformuoja QRS kompleksą aplinką ir gretimas bangas [12].

Triukšmingi dūžiai buvo sintetiškai generuojami dūžio lygmenyje, naudojant nepersidengiančius mokymo ir testavimo triukšmo segmentus, kad būtų išvengta duomenų nutekėjimo tarp aibių ir išlaikytas reprodukuojamas vertinimas [10,12]. Triukšmingi širdies dūžiai formuojami:

$$x_i = b_i + a_i \cdot n_i$$

čia i žymi dūžio indeksą duomenų aibėje, b_i – i -ąjį švarų dūžio segmentą, n_i – jam priskirtą pasirinkto tipo triukšmo segmentą, o x_i – gautą triukšmingą dūžį. Kiekvieną dūžį sudaro $N = 512$ imčių. Triukšmo amplitudė kontroliuojama pagal triukšmo mastelio koeficientą a_i , kuris atsitiktinai parenkamas iš tolydžiojo skirstinio intervalo $U(0,2, 2,0)$.

2.2 Vertinti modeliai

DeScoD [8] yra difuzijos modelis, skirtas EKG morfologijos atkūrimui ir bazinės linijos bei kitų artefaktų slopinimui. *DMAM* [9] išplečia difuzijos modelį taikant dėmesio sutelkimo (angl. *self-attention*) modulį, kuris geriau modeliuoja ilgalaikes priklausomybes visame dūžyje ir yra ypač aktualus stipriai pažeistų segmentų atveju. *DeepFilter* [10] šiame tyrime naudotas kaip bazinis, ne difuzinis metodas, kuris buvo sukurtas bazinės linijos dreifui šalinti ir todėl sudaro reprezentatyvų atskaitos tašką palyginimui su difuzijos modeliais. Bendra difuzinio atkūrimo schema remiasi *DDPM* [7] principu, kai mokoma atvirkštinio triukšmo šalinimo proceso iš laipsniškai užteršto signalo.


2.3 Eksperimentinis protokolas ir vertinimo metrikos

MIT-BIH aritmijų duomenų bazę suskaidžius pagal pacientus buvo sudaryta mokymo aibė iš 84398 dūžių ir testavimo aibė iš 9342 dūžių. Tiek mokymo, tiek testavimo aibės išliko pakankamai reprezentatyvios dėl taikytos proporcingos stratifikacijos širdies dūžių klasių atžvilgiu.

Generalizacijos vertinimui naudotas QT duomenų bazės 14 įrašų poaibis, sekant *DeepFilter* darbe pateiktą metodiką, atitinkantis 87/13 santykį mokymo ir testavimo aibėms dūžių prasme [10]. QT signalai buvo pakartoti-

nai diskretizuoti iš 250 Hz į 360 Hz, kad būtų sumažintas išankstinio apdorojimo neatitikimų poveikis lyginant su MIT-BIH duomenimis [10,13].

Triukšmingų EKG segmentų sudarymo procesas pavaizduotas 1 pav., kuriame parodyta, kaip etaloninis EKG segmentas ir parinktas triukšmo segmentas sujungiami į modelio įėjimo signalą, o modelio išėjime gaunamas segmentas su pašalintu triukšmu.



1 pav. Triukšmingo EKG segmento sudarymo ir triukšmo šalinimo proceso schema.

Triukšmo šalinimas vertintas pagal SSD – kvadratinų paklaidų sumą (angl. *Sum of Squared Differences*) [15], PRD – procentinį santykinį nuokrypį (angl. *Percentage Root mean square Difference*) [16], MAD – maksimalų abso-

liutų nuokrypį (angl. *Maximum Absolute Deviation*) [15], CosSim – morfologinę kosinuso panašumo metriką [16] ir Δ SNR – triukšmo ir signalo santykio pagerėjimą. Kiekvienos metrikos reikšmė pirmiausia apskaičiuojama kiekvienam dūžiui, pasitelkus signalą su pašalintu triukšmu ir etaloninį signalą, o tada pateikiama nurodant vidurkį bei standartinį nuokrypį vertinamoje aibėje.

3 Rezultatai

Šiame skyriuje pateikiami agreguoti triukšmo šalinimo rezultatai, kiekybiškai palyginami vertinti metodai, pateikiamas eksperto vertinimas bei darbo ribojimai ir tolimesni darbai.

3.1 Triukšmo šalinimo rezultatai

1 lentelėje pateikiami triukšmo šalinimo rezultatai, apimantys BW, EM ir MA triukšmo atvejus vienos duomenų bazės vertinime, kai modeliai buvo mokomi ir testuojami naudojant MIT-BIH aritmijų duomenų bazę, taikant pacientų atžvilgiu atskirtas mokymo ir testavimo aibes, o 2 lentelė – rezultatai, apimantys BW atvejį QT generalizacijos vertinime. Žymėjimas A→B reiškia, kad modelis buvo mokytas naudojant A duomenų bazės duomenis, o vertintas naudojant B duomenų bazės duomenis. Taigi MIT→MIT reiškia mokymą ir testavimą toje pačioje duomenų bazėje, bet ne su tais pačiais pacientais ar tais pačiais segmentais. Pateikiamos SSD, PRD, MAD ir CosSim metrikos kartu apibūdina bendrą viso segmento kvadratinę paklaidų sumą, santykinį iškraipymą, didžiausią taškinį nuokrypį ir morfologinį panašumą tarp švaraus ir signalo su pašalintu triukšmu, Δ SNR apibendrina triukšmo ir signalo santykio pagerėjimą. Geriausios kiekvienos metrikos reikšmės paryškintos.

Visiems trimis metodams MIT→MIT scenarijuje EM buvo sunkiausiai pašalinamas triukšmo tipas. Būtent EM atveju pastebimos didžiausios PRD ir mažiausios CosSim reikšmės, rodančios ryškiausią morfologijos iškraipymą ir mažiausią triukšmo šalinimo pagerėjimą pagal Δ SNR. Esant BW, *DeScoD*, lyginant su *DeepFilter*, sumažino SSD nuo 73,76 iki 19,58, tai yra 73,5 %, PRD – nuo 72,28 % iki 41,45 %, tai yra 42,7 %, o Δ SNR padidino nuo 11,62 iki 15,64 dB, tai yra 34,6 %. BW atveju *DeScoD* taip pat išlaikė persvarą prieš *DMAM* – jo SSD buvo 20,3 % mažesnis, o PRD 8,6 % mažesnis. Esant EM, *DeScoD* pasiekė geriausius rezultatus tarp visų lygintų metodų: SSD sumažėjo nuo 85,77 iki 51,48, tai yra 40,0 %, PRD – nuo 97,13 % iki 77,01 %, tai yra

20,7 %, o Δ SNR pagerėjo nuo 7,44 iki 9,30 dB, tai yra 25,0 %. MA scenarijuje *DeScoD* taip pat pasiekė geriausius rezultatus, sumažindamas SSD nuo 65,73 iki 24,25, tai yra 63,1 %, ir PRD nuo 70,97 % iki 44,66 %, tai yra 37,1 %, o Δ SNR padidindamas nuo 7,22 iki 10,91 dB, tai yra 51,1 %. Lyginant su *DMAM*, *DeScoD* ir šiame scenarijuje išlaikė persvarą, nes MA atveju SSD buvo 21,8 % mažesnis, o PRD – 10,3 % mažesnis. *DeepFilter* rezultatai visų trijų triukšmo tipų atvejais buvo akivaizdžiai prastesni už difuziją grįstų metodų rezultatus bei pasižymėjo didesne sklaida, ypač pagal SSD. Svarbu pastebėti, jog dalies metrikų standartinių nuokrypių reikšmės indikuoja nevienodą modelių veikimą skirtingų dūžių ir triukšmo intensyvumo, specifiskai nestacionarių artefaktų atveju.

1 lentelė. Triukšmo šalinimo kokybės rodikliai vienos duomenų bazės vertinimo atveju (vidurkis $\pm$ standartinis nuokrypis). Rodyklės kryptis nurodo geresnį metrikos rezultatą.

Modelis	Mokymas→ Testavimas	Triukš- mas	SSD↓	PRD(%)↓	MAD↓	CosSim↑	Δ SNR↑
DMAM	MIT→MIT	BW	24,57 $\pm$ 61,47	45,36 $\pm$ 33,13	0,42 $\pm$ 0,26	0,90 $\pm$ 0,11	14,68 $\pm$ 6,50
DeScoD	MIT→MIT	BW	19,58 $\pm$ 39,92	41,45 $\pm$ 29,28	0,39 $\pm$ 0,26	0,91 $\pm$ 0,10	15,64 $\pm$ 6,13
DeepFilter	MIT→MIT	BW	73,76 $\pm$ 183,74	72,28 $\pm$ 49,44	0,57 $\pm$ 0,36	0,81 $\pm$ 0,15	11,62 $\pm$ 7,28
DMAM	MIT→MIT	EM	56,19 $\pm$ 102,36	85,67 $\pm$ 59,74	0,77 $\pm$ 0,49	0,79 $\pm$ 0,17	8,59 $\pm$ 5,51
DeScoD	MIT→MIT	EM	51,48 $\pm$ 119,33	77,01 $\pm$ 61,84	0,73 $\pm$ 0,49	0,82 $\pm$ 0,17	9,30 $\pm$ 5,38
DeepFilter	MIT→MIT	EM	85,77 $\pm$ 191,04	97,13 $\pm$ 67,61	0,82 $\pm$ 0,46	0,75 $\pm$ 0,17	7,44 $\pm$ 5,63
DMAM	MIT→MIT	MA	31,01 $\pm$ 67,66	49,81 $\pm$ 37,47	0,57 $\pm$ 0,35	0,89 $\pm$ 0,12	10,00 $\pm$ 6,05
DeScoD	MIT→MIT	MA	24,25 $\pm$ 52,72	44,66 $\pm$ 35,37	0,55 $\pm$ 0,36	0,91 $\pm$ 0,11	10,91 $\pm$ 5,67
DeepFilter	MIT→MIT	MA	65,73 $\pm$ 150,65	70,97 $\pm$ 43,18	0,69 $\pm$ 0,39	0,82 $\pm$ 0,14	7,22 $\pm$ 6,54

Modelių pritaikomumo naujoms duomenų aibėms vertinime (žr. 2 lentelė) difuzija grįsti modeliai nuosekliai pranoko *DeepFilter*, o *DMAM* ir *DeScoD* rezultatai išliko labai artimi. MIT→QT scenarijuje *DeScoD* sumažino PRD nuo 48,63 % iki 39,25 %, o CosSim padidėjo nuo 0,85 iki 0,93. *DMAM* šiame scenarijuje pasiekė labai panašius rezultatus – 40,29 % PRD ir 0,94 CosSim. QT→MIT rezultatai buvo panašūs į MIT→MIT rezultatus esant BW, o tai rodo patiki-

mą bazinės linijos dreifo šalinimo perkėlimą tarp duomenų aibių. Priešingai, QT→MIT scenarijuje *DeepFilter* tikslumas ryškiai suprastėjo: jo PRD siekė 100,30 %, o CosSim sumažėjo iki 0,73, tuo tarpu *DeScoD* tame pačiame scenarijuje pasiekė 41,29 % PRD ir 0,91 CosSim, t. y. sumažino PRD 58,8 % ir SSD 82,1 % lyginant su *DeepFilter*. *DMAM* QT→MIT scenarijuje pasiekė rezultatus artimus *DeScoD* su 45,55 % PRD ir 0,90 CosSim. QT→QT scenarijuje abu difuziniai modeliai taip pat išlaikė geresnes PRD ir ΔSNR reikšmes nei *DeepFilter*.

2 lentelė. Triukšmo šalinimo kokybės rodikliai, vertinant modelių pritaikomumą naujiems duomenims BW atveju (vidurkis ± standartinis nuokrypis). Rodyklės kryptis nurodo geresnį metrikos rezultatą.

Modelis	Mokymas→ Testavimas	Triukš- mas	SSD↓	PRD(%)↓	MAD↓	CosSim↑	ΔSNR↑
DMAM	MIT→QT	BW	3,53 ± 5,89	40,29 ± 24,60	0,33 ± 0,26	0,94 ± 0,07	25,42 ± 7,49
DeScoD	MIT→QT	BW	3,76 ± 6,26	39,25 ± 25,52	0,34 ± 0,27	0,93 ± 0,09	25,32 ± 7,85
DeepFilter	MIT→QT	BW	7,32 ± 9,68	48,63 ± 18,37	0,35 ± 0,21	0,85 ± 0,14	19,14 ± 6,15
DMAM	QT→MIT	BW	24,79 ± 63,64	45,55 ± 34,73	0,41 ± 0,26	0,90 ± 0,11	14,67 ± 6,53
DeScoD	QT→MIT	BW	19,63 ± 42,42	41,29 ± 30,38	0,39 ± 0,26	0,91 ± 0,10	15,63 ± 6,11
DeepFilter	QT→MIT	BW	109,97 ± 291,56	100,30 ± 93,84	0,70 ± 0,44	0,73 ± 0,25	10,44 ± 7,28
DMAM	QT→QT	BW	3,55 ± 5,90	40,39 ± 24,90	0,33 ± 0,26	0,94 ± 0,07	25,40 ± 7,48
DeScoD	QT→QT	BW	3,76 ± 6,10	39,28 ± 25,44	0,34 ± 0,27	0,93 ± 0,09	25,31 ± 7,86
DeepFilter	QT→QT	BW	3,98 ± 7,31	43,88 ± 24,76	0,33 ± 0,21	0,93 ± 0,06	21,99 ± 5,87

Gauti rezultatai (žr. 1 ir 2 lenteles) rodo, kad difuziniai modeliai pasiekia geresnę triukšmo šalinimo kokybę vienos duomenų bazės vertinime ir stabiliau išlaiko triukšmo šalinimo kokybę skirtingų morfologinių bei įrašymo sąlygų atvejais.

Be kiekybinio vertinimo, modelių triukšmo šalinimo rezultatus peržiūrėjo praktikuojantis kardiologas. Klinikiniu požūriu EKG artefaktus dažniausiai sukelia paciento judesiai, raumenų tremoras, netinkamas elektrodų kontaktas, pavyzdžiui, laisvi, išdžiūvę ar netiksliai pritvirtinti elektrodai, ir išoriniai elektriniai trikdžiai. Šie veiksniai į EKG įrašą įneša nekardinių signalų, dėl kurių kreivė deformuojama ir jos interpretavimas tampa sudėtingesnis. Koky-

binis vertinimas atitiko šiame skyriuje pateiktus kiekybinius rezultatus: abu difuzijos modeliai gerai susidorojo su BW ir MA triukšmu, tačiau EM išliko sudėtingiausias. Esant EM triukšmui, QRS morfologija dažniausiai buvo išsaugoma, tačiau P ir T bangų ribų informacija neretai prarasdavo tikslumą. Retais atvejais difuzija grįsti modeliai sugeneruodavo dirbtines morfologijas, nesutampančias su švaria etalonine kreive.

3.2 Tyrimo ribotumai ir rekomendacijos

Šiame darbe modelių triukšmo šalinimas vertintas taikant kontroliuojamo lygio triukšmo pridėjimo metodiką, kuri gali ne iki galo atspindėti realių klinikinių įrašų triukšmo artefaktus. Modelių pritaikomumas kitoms duomenų bazėms vertintas naudojant tik QT duomenų bazę ir tik bazinės linijos dreifo triukšmo tipą. Be to, palyginimui įtrauktas tik vienas nedifuzinis bazinis metodas – *DeepFilter*, todėl papildomų šiuolaikinių alternatyvų įtraukimas leistų išsamiau įvertinti stebimą difuzija grįstų metodų pranašumą. Kadangi kai kurių rezultatų atveju buvo pastebėtos aukštos standartinio nuokrypio reikšmės, tolimesni tyrimai turėtų įtraukti skirtingų dūžių klasių ir triukšmo intensyvumo poveikio analizę.

Tolesniuose tyrimuose numatoma vertinimą išplėsti į realaus pasaulio triukšmo sąlygas, modelių pritaikomumo naujoms duomenų aibėms tyrimus papildyti EM ir MA triukšmo tipais bei į analizę įtraukti daugiau bazinių metodų.

4 Išvados

Taikant duomenų rinkinio skaidymo pagal pacientus metodiką, difuzija grįsti EKG triukšmo šalinimo metodai nuosekliai pranoko bazinį *DeepFilter* metodą tiek vienos duomenų bazės, tiek bazinės linijos dreifo generalizacijos eksperimentuose, pasiekdami 20–30 % geresnę triukšmo šalinimo kokybę. Geriausius triukšmo šalinimo rezultatus pasiekė *DeScod*: MIT→MIT scenarijuje, palyginti su *DeepFilter*, jo PRD buvo 42,7 % mažesnis esant bazinės linijos dreifui, 20,7 % esant elektrodų judesio artefaktams ir 37,1 % esant raumenų artefaktams, o *CosSim* išliko aukščiausias visų trijų triukšmo tipų atvejais.

Rezultatai parodė stiprią modelių efektyvumo priklausomybę nuo triukšmo tipo. Elektrodų judesio artefaktai išliko sunkiausiai šalinamu triukšmo tipu visiems metodams, nes staigūs bei nestacionarūs artefaktai labiausiai deformavo morfologiją ir mažino Δ SNR.

Vertinant modelių pritaikomumą naujiems duomenims (bazinės linijos dreifo atveju) *DeScoD* ir *DMAM* išlaikė artimus ir stabilius rezultatus tarp MIT bei QT duomenų bazių, o *DeepFilter* QT→MIT scenarijuje degradavo ryškiau-siai. QT→MIT scenarijuje *DeScoD* pasiekė 41,29 % PRD ir 0,91 CosSim, kol atitinkamai *DeepFilter* PRD siekė 100,30 %, ir 0,73 CosSim. Šie eksperimentai su skirtingomis duomenų bazėmis parodė, kad difuziniai modeliai geriau perkelia išmoktą triukšmo šalinimo elgseną ir yra atsparesni naujoms įrašymo sąlygoms ir morfologiniams skirstiniams.

Padėka

Finansavimą skyrė Lietuvos mokslo taryba (LMTLT), sutarties Nr. S-ITP-25-9. Autoriai dėkoja Vilniaus universiteto Informacinių technologijų atviros priei-gos centrui už suteiktus didelio našumo skaičiavimo išteklius.

Autoriai taip pat dėkoja Viktor Medvedev, Povilui Treigiui ir Žygimantui Abramikui už reikšmingą indėlį rengiant šį tyrimą.

Literatūra

- [1] Jia, Y., Pei, H., Liang, J., Zhou, Y., Yang, Y., Cui, Y., Xiang, M. (2024). Preprocessing and denoising techniques for electrocardiography and magnetocardiography: A review. *Bio-engineering*, 11(11), 1109. doi:10.3390/bioengineering11111109.
- [2] Awal, M. A., Mostafa, S. S., Ahmad, M., Rashid, M. A. (2014). An adaptive level dependent wavelet thresholding for ECG denoising. *Biocybernetics and Biomedical Engineering*, 34(4), 238-249. doi:10.1016/j.bbe.2014.03.002.
- [3] Boudraa, A. O., Cexus, J. C. (2007). EMD-Based Signal Filtering. *IEEE Transactions on Ins-trumentation and Measurement*, 56(6), 2196–2202. doi: 10.1109/TIM.2007.907967.
- [4] Rahman, S., Pal, S., Yearwood, J., Karmakar, C. (2024). Robustness of deep learning mod-els in electrocardiogram noise detection and classification. *Computer Methods and Pro-grams in Biomedicine*, 253, 108249. doi:10.1016/j.cmpb.2024.108249.
- [5] Venton, J., Harris, P. M., Sundar, A., Smith, N. A. S., Aston, P. J. (2021). Robustness of con-volutional neural networks to physiological electrocardiogram noise. *Philosophical Tran-sactions of the Royal Society A*, 379(2212). doi:10.1098/rsta.2020.0262.
- [6] Malūkaitė, J., Treigys, P., Bernatavičienė, J. (2025). Enhancing arrhythmia detection using an ensemble of transformer models for heartbeat classification. In *Machine Learning, Optimization, and Data Science (LNCS 15509*, pp. 312-322). Springer. doi:10.1007/978-3-031-82484-5_23.
- [7] Ho, J., Jain, A., Abbeel, P. (2020). Denoising diffusion probabilistic models. *Advances in Neural Information Processing Systems*, 33, 6840-6851.
- [8] Li, H., Ditzler, G., Roveda, J., Li, A. (2024). DeScoD-ECG: Deep score-based diffusion model for ECG baseline wander and noise removal. *IEEE Journal of Biomedical and Health Infor-matics*, 28(9), 5081-5091. doi:10.1109/JBHI.2023.3237712.

- [9] Hu, Z.-D., Hong, Y., Huang, J.-Y., Chen, K.-H., Zhao, W.-Q., Grau, A., Guerra, E., Wang, C.-S. (2024). DMAM-ECG: A diffusion model with self-attention module for ECG signal denoising. *Journal of Neural Networks and Information*, 9(3), 1279-1292.
- [10] Romero, F. P., Piñol, D. C., Vázquez-Seisdedos, C. R. (2021). DeepFilter: An ECG baseline wander removal filter using deep learning techniques. *arXiv:2101.03423*. doi:10.48550/arXiv.2101.03423.
- [11] Moody, G. B., Mark, R. G. (2001). The impact of the MIT-BIH Arrhythmia Database. *IEEE Engineering in Medicine and Biology Magazine*, 20(3), 45-50. doi:10.1109/51.932724.
- [12] Moody, G. B., Muldrow, W. E., Mark, R. G. (1984). A noise stress test for arrhythmia detectors. *Computers in Cardiology*, 381-384.
- [13] Laguna, P., Mark, R. G., Goldberg, A., Moody, G. B. (1997). A database for evaluation of algorithms for measurement of QT and other waveform intervals in the ECG. *Computers in Cardiology*, 673-676. doi:10.1109/CIC.1997.648140.
- [14] Šimėnas, S., Klepachevskiy, D., Medvedev, V., Treigys, P., Abramikas, Ž., Bernatavičienė, J. (2026). Inter-Patient Evaluation of Diffusion-Based ECG Denoising Under Standardized Noise Types. 22nd Polish Control Conference (PCC), Poznan University of Technology, Poznanė, Lenkija, 2026 m. liepos 1–3 d. (įteiktas).
- [15] Nygaard, R., Melnikov, G., Katsaggelos, A. K. (2001). A rate distortion optimal ECG coding algorithm. *IEEE Transactions on Biomedical Engineering*, 48(1), 28-40. doi:10.1109/10.900246.
- [16] Manikandan, M. S., Dandapat, S. (2008). ECG distortion measures and their effectiveness. In 1st International Conference on Emerging Trends in Engineering and Technology (pp. 681-686). doi:10.1109/ICETET.2008.248.
- [17] Schütze, H., Manning, C. D., Raghavan, P. (2008). *Introduction to Information Retrieval*. Cambridge University Press.