



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Neurologinių sutrikimų sukkelto rankų tremoro vertinimas naudojant išmaniųjų įrenginių duomenis

Baigiamasis magistro studijų projektas

Edvinas Litvinas

Projekto autorius

Vyresn. m. d. Mantas Venslauskas

Vadovas

Doc. dr. Asta Baliutė

Vadovė

Kaunas, 2023



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Neurologinių sutrikimų sukkelto rankų tremoro vertinimas naudojant išmaniųjų įrenginių duomenis

Baigiamasis magistro studijų projektas

Didžiųjų verslo duomenų analitika (6213AX001)

Edvinas Litvinas

Projekto autorius

**Vyresn. m. d.
Mantas Venslauskas**

Vadovas

Doc. dr. Mindaugas Šnipas

Recenzentas

**Doc. dr.
Asta Baliutė**

Vadovė

Prof. dr. Jurgita Bruneckienė

Recenzentė

Kaunas, 2023



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Edvinas Litvinas

Neurologinių sutrikimų sukulto rankų tremoro vertinimas naudojant išmaniųjų įrenginių duomenis

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdama(s) kitų asmenų autoriaus ar kitų teisių, laikydamasi(s) Lietuvos Respublikos autorių teisių ir gretutinių teisių įstatymo nuostatų, Kauno technologijos universiteto (toliau – Universitetas) intelektinės nuosavybės valdymo ir perdavimo nuostatų bei Universiteto akademinės etikos kodekse nustatytų etikos reikalavimų;
2. baigiamajame projekte visi pateikti duomenys ir tyrimų rezultatai yra teisingi ir gauti teisėtai, nei viena šio projekto dalis nėra plagijuota nuo jokių spausdintinių ar elektroninių šaltinių, visos baigiamojo projekto tekste pateiktos citatos ir nuorodos yra nurodytos literatūros sąrašė;
3. įstatymų nenumatytų piniginių sumų už baigiamąjį projektą ar jo dalis niekam nesu mokėjęs (-usi);
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalinta(s) iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Edvinas Litvinas

Patvirtinta elektroniniu būdu

Litvinas Edvinas. Neurologinių sutrikimų sukkelto rankų tremoro vertinimas naudojant išmaniųjų įrenginių duomenis. Magistro studijų baigiamasis projektas / vadovas / vyresn. m. d. Mantas Venslauskas; Kauno technologijos universitetas, Matematikos ir gamtos mokslų fakultetas.

Studijų kryptis ir sritis (studijų krypties grupė): Taikomoji matematika (Matematikos mokslai).

Reikšminiai žodžiai: mašininis mokymasis, rankų drebinimas, tremoras, esencialinis tremoras, Parkinsono liga, neurologiniai sutrikimai, išmaniųjų įrenginių duomenys, tremoro kvantavimas, tremoro klasifikacija.

Kaunas, 2023. 50 p.

Santrauka

Rankų tremoru vadinamas nevaldomas, ritmiškas vienos arba abiejų rankų drebinimas, būdingas visai žmonių populiacijai, bet sunkia forma pasireiškiantis kaip įvairių ligų simptomas. Tai dažniausias klinikinėje praktikoje aptinkamas judesio sutrikimas. Su rankų tremoru siejama dešimtys įvairių tipų ligų, tačiau savo paplitimu dominuoja esencialinis tremoras (ET) ir Parkinsono liga (PD). Šiame darbe apžvelgiami tradiciniai ir modernūs tremoro diagnozės ir kvantavimo metodai. Pasiūlomas naujas sprendimas, grįstas mobiliųjų išmaniųjų įrenginių akselerometro ir lietimio jutiklio duomenų suliejimu.

Tremoro kvantavimo problema interpretuojama kaip regresijos problema. Priklausomi kintamieji – dažnių ir laiko srities savybės, o nepriklausomas kintamasis – tremoro stiprumo įvertis skalėje 0 (blogai/ stiprus tremoras) – 10 (gerai/be tremoro). Mobiliąja programėle surinkta 440 akselerometro ir lietimio jutiklio matavimų pavyzdžių porų su tremoro stiprumo įverčiais (ET (241), kontrolės populiacija CP (180) ir PD (19)). Duomenimis treniruoti ir vertinti XGBoost ir daugiasluoksnio perceptrono (MLP) regresijos algoritmai. Gauti rezultatai įvertinti vidutine absoliučia paklaida MAE = 0.58, šaknimi ir vidutinės kvadratinės paklaidos RMSE = 0.79. Diagnozės problema sprendžiama kaip klasifikavimo problema su 3 klasėmis: ET, CP ir PD. Naudojant MLP pavyko pasiekti beveik tobulus rezultatus: diagnozės plotas po TPR/FPR kreive AUC = 1.00, Koheno kappa koeficientas KAP = 0.98, tik 1 klaidingai suprognozuotas pavyzdys. Darbe taip pat sprendžiami iššūkiai apdorojant išmaniųjų įrenginių jutiklių duomenis. Galiausiai įvertintas potencialus sukurtos priemonės efektas ekonomikai.

Litvinas Edvinas. Neurological Disorder-Induced Hand Tremor Assessment Using Smartphone Data. Master's Final Degree Project / supervisor vyresn. m. d. Mantas Venslauskas; Faculty of Mathematics and Natural Sciences, Kaunas University of Technology.

Study field and area (study field group): Applied Mathematics (Mathematical Sciences).

Keywords: machine learning, hand tremor, tremor, essential tremor, Parkinson's disease, neurological disorders, smart device data, tremor quantification, tremor classification.

Kaunas, 2023. 50.

Summary

Hand tremor is a rhythmic shaking of one or both arms that can occur as a symptom of various diseases or as a common occurrence in the general population. It is the most prevalent movement disorder seen in clinical practice. Among the numerous diseases associated with hand tremors, essential tremor (ET) and Parkinson's disease (PD) are the most prevalent. This study examines conventional and contemporary methods for diagnosing and assessing the severity of tremors. Additionally, it proposes an innovative solution that combines accelerometer and touch sensor data from mobile smart devices.

The quantification of tremors is approached as a regression problem, with frequency and time-domain features serving as dependent variables and an estimate of tremor strength ranging from 0 (severe tremor) to 10 (no tremor) as the independent variable. A total of 440 sample pairs of accelerometer and touch sensor measurements and corresponding tremor strength estimates were collected using a mobile application. These samples encompassed individuals with ET (241), a control population (CP) (180), and PD (19). The collected data was used to train and evaluate XGBoost and multilayer perceptron (MLP) regression algorithms. The results yielded a mean absolute error (MAE) of 0.58 and a root mean square error (RMSE) of 0.79.

Furthermore, the diagnosis problem was approached as a classification problem, with three classes: ET, CP, and PD. Using the MLP method led to nearly perfect outcomes, as evidenced by an area under the true positive rate/false positive rate curve (AUC) of 1.00, a Cohen's kappa coefficient (KAP) of 0.98, and only one mispredicted sample. The study also addresses the challenges associated with processing sensor data from smart devices. Lastly, an evaluation of the potential economic impact of the developed tool is presented.

Turinys

Lentelių sąrašas	7
Paveikslų sąrašas	8
Santrumpų ir terminų sąrašas	10
Įvadas.....	11
1. Literatūros apžvalga	13
1.1. Tremoro klasifikacija.....	13
1.1.1. Aktyvacijos sąlygos.....	13
1.1.2. Dažnis	14
1.1.3. Amplitudė	14
1.1.4. Spektrinės savybės.....	14
1.1.5. Laiko savybės	16
1.1.6. Asimetrijos savybės.....	16
1.1.7. Kitos savybės.....	17
1.2. Tremoro vertinimas	17
1.2.1. Tradiciniai vertinimo būdai	17
1.2.2. Vertinimas inerciniais jutikliais.....	18
1.2.3. Vertinimas kitais jutikliais.....	21
1.3. Ekonominiai aspektai	23
1.3.1. Parkinsono ligos ekonominė našta	23
1.3.2. Esencialinio tremoro ekonominė našta.....	26
1.3.3. Ekonominės naštos mažinimas.....	27
1.4. Literatūros apžvalgos apibendrinimas	28
2. Metodai.....	29
2.1. Duomenų rinkimo konceptas.....	29
2.1.1. Jutiklių pasirinkimas.....	29
2.1.2. Išmaniųjų įrenginių ir programinės įrangos pasirinkimas	30
2.1.3. Matavimo metodologija.....	30
2.2. Duomenų rinkinys	32
2.3. Duomenų ruošimas	33
2.3.1. Pirminis apdorojimas.....	33
2.3.2. Savybių vektoriaus sudarymas	40
2.4. Vertinimo modeliai.....	41
2.4.1. XGBoost.....	41
2.4.2. Daugiasluoksnis perceptronas	42
3. Rezultatai.....	44
3.1. Kvantavimo užduotis.....	44
3.1.1. Kvantavimas lietimo jutikliu	44
3.1.2. Kvantavimas akselerometru	49
3.1.3. Kvantavimas abiem jutikliais	50
3.2. Diagnozės užduotis.....	51
3.3. Ekonominio efekto vertinimas	54
Išvados	57
Literatūros sąrašas	59
Priedai.....	63

Lentelių sąrašas

1 lentelė.	Įvairių tremoro vertinimo priemonių palyginimas. Skalė 1 – blogiausia, 3 – geriausia. ..	28
2 lentelė.	Duomenų rinkinys. Čia T – tik testavimui naudojami duomenys.	32
3 lentelė.	XGBoost tinklo paieška - hiperparametrų kombinacijos.	46
4 lentelė.	MLP tinklo paieška - hiperparametrų kombinacijos.	47
5 lentelė.	Kvantavimo užduoties rezultatų apibendrinimas.	51
6 lentelė.	Diagnozės užduoties rezultatų apibendrinimas.	53

Paveikslų sąrašas

1 pav. Įvairių tremorų dažnių, diagnozių ir aktyvacijos sąlygų priklausomybė	14
2 pav. Tremoro tyrimas tradicine poza ir autoriaus siūlomoje pozoje su rankos atramomis [13]	18
3 pav. Tremoro tyrimas specialiu prietaisu [33]	18
4 pav. PD ir ET pacientų tremoras laiko ir dažnių srityse 5s intervale [32]	19
5 pav. Tremoro kvantavimo tyrimas su prie odos tvirtinamu jutikliu ir išmaniuoju laikrodžiu [14]	20
6 pav. Tremoro kvantavimo tyrimas mobiliuoju telefonu ir specialia pirštine [24]	21
7 pav. Pagreičio ir kampinio greičio duomenų spektrinių galių palyginimas [24]	21
8 pav. Archimedo spiralės piešinys (CP – kairėje, EET – dešinėje)[35]	22
9 pav. Archimedo spiralių vertinimas iš nuotraukų (PD, PD, CP)[36]	22
10 pav. PD pacientų išgyvenamumo rodiklis pagal apsilankymą pas neurologą ir pirminės sveikatos priežiūros gydytoją (p.s.p.s.) [37]	23
11 pav. Apytikslis ET paplitimas skirtingose šalyse [50]	27
12 pav. Mobiliosios programėlės SteadyHands piešimo langai	31
13 pav. Mobiliosios programėlės SteadyHands tremoro vertinimas akselerometru	31
14 pav. Tremoro įverčio reikšmių pasiskirstymas	33
15 pav. Akselerometro pagreičio duomenys 3 ašyse (ET) (mėlyna, žalia, geltona: Z, Y, X ašys)..	33
16 pav. Spektrinio nuotėkio iliustracija [41]	34
17 pav. ET tremoro pagreičio signalas pritaikius lango funkcijas. Viršuje – „Kaiser $\beta = 5$ “, apačioje – „Hanning“. Čia mėlyna, žalia, geltona- atitinkamai Z, Y, X koordinačių ašys	35
18 pav. ET tremoro pagreičio suminis signalas dažnių srityje. Viršuje – „Kaiser $\beta = 5$ “, apačioje – be lango	36
19 pav. Lango funkcijos taikymas be persidengimo (viršuje) ir su persidengimu (apačioje) [41] ...	37
20 pav. ET tremoro pagreičio suminis signalas spektrogramos pavidalu	38
21 pav. Akselerometro duomenų fd ir jo standartinis nuokrypio pasiskirstymas	38
22 pav. Poli-faziniu filtravimu grįstas diskretizavimo dažnio keitimas	39
23 pav. Duomenų apdorojimo schema	39
24 pav. MLP architektūros vizualizacija	42
25 pav. Modelių vertinimo sekos schema	44
26 pav. Spiralių piešiniai ties skirtingais tremoro intensyvumo kvantais (CP, ET, PD imtys)	45
27 pav. Reikšmių pasiskirstymo tankio kreivės – bruožai, pasižymintis stipriausia Pearsono koreliacija su tremoro kvantavimo skale (lietimo jutiklis)	45
28 pav. XGBoost modelio savybių svarbumo įvertinimas didžiausio pelno kriterijumi (lietimo jutiklis)	46
29 pav. XGB modelio savybių svarbumo įvertinimas didžiausio pelno kriterijumi (lietimo jutiklis, 10 svarbiausių savybių)	47
30 pav. MLP modelio savybių svarbumo įvertinimas SHAP metodu (lietimo jutiklis, horizontalioji ašis atitinka SHAP vertę)	48
31 pav. MLP modelio savybių svarbumo įvertinimas SHAP metodu (lietimo jutiklis, 10 svarbiausių savybių aibė, horizontalioji ašis atitinka SHAP vertę)	48
32 pav. Geriausius rezultatus pasiekusio MLP modelio architektūros schema (visos savybės)	48
33 pav. Reikšmių pasiskirstymo tankio kreivės – bruožai, pasižymintis stipriausia Pearsono koreliacija su tremoro kvantavimo skale (akselerometras)	49

34 pav. XGB savybių svarbumo įvertinimas didžiausio pelno kriterijumi (akselerometras, visos savybės)	50
35 pav. MLP savybių svarbumo įvertinimas SHAP metodu (akselerometras, visos savybės).....	50
36 pav. Spiralių piešiniai iš skirtingų diagnozių imčių (CP, PD, ET)	51
37 pav. Sumaišymo matrica (0- CP, 1- ET, 2- PD, visos savybės, XGB)	52
38 pav. XGBoost modelio savybių svarbumo įvertinimas didžiausio pelno kriterijumi (abu jutikliai, visos savybės, diagnozės užduotis)	52
39 pav. Sumaišymo matrica (0- CP, 1- ET, 2- PD, visos savybės, MLP)	53
40 pav. MLP savybių svarbumo įvertinimas SHAP metodu (abu jutikliai, diagnozės užduotis)	53
41 pav. Bendra PD sukeliamą ekonominę žalą JAV (2017 m. padėtis ir 2022-2037 prognozė) [5]	54

Santrumpų ir terminų sąrašas

Santrumpos:

AUC – ploto po TPR FPR kreive tikslumo matas (angl. *Area Under Curve*);

CP – kontrolės populiacija;

Doc. – docentas;

ET – Esencialinis tremoras;

FPR – neteisingų prognozių dalis teigiamos klasės prognozėse;

Lekt. – lektorius;

MAE – vidutinį absoliuti paklaida;

PD – Parkinsono liga;

Prof. – profesorius;

QALY– Kokybe koreguoti gyvenimo metai;

RMSE – šaknis iš vidutinės kvadratinės paklaidos;

TPR – teisingų prognozių dalis teigiamos klasės prognozėse;

Vyresn. m. d. – vyresnysis mokslų daktaras;

XGB – „*eXtreme Gradient Boosting*“ algoritmas;

Įvadas

Rankų tremoru vadinamas nevaldomas, ritmiškas vienos arba abiejų rankų drebėjimas, būdingas visai žmonių populiacijai, bet sunkia forma pasireiškiantis kaip įvairių ligų simptomas. Tai dažniausias klinikinėje praktikoje aptinkamas judesio sutrikimas. Su rankų tremoru siejama dešimtys įvairių tipų ligų, tačiau savo paplitimu dominuoja esencialinis tremoras (ET) ir Parkinsono liga (PD) [1, 2, 3].

Pagal 2020 metų duomenis ET sutrikimas būdingas 0.32% bendrosios populiacijos, iš kurių 56% dalį sudaro vyrai. Statistiškai ligos paplitimas didėja kartu su amžiumi ir paliečia 3.48% vyresnių nei 79 metų vyrų ir 2.49% tokio paties amžiaus moterų. PD yra antras pagal dažnumą neurodegeneracinis sutrikimas. Analogiškai ET, ligos paplitimas didėja kartu su amžiumi ir apima ~0.26% vyresnių nei 80 metų amžiaus vyrų ir 0.1% tos pačios amžiaus grupės moterų [4]. Prognozuojama, kad dėl vis senėjančios visuomenės, ateityje ET ir PD paplitimas didės.

Patologinį rankų tremorą turintys asmenys susiduria su sunkumais atliekant paprastas kasdienes užduotis. Nevaldomi judesiai gali trukdyti valgyti, apsirengi, atlikti namų ruošą, naudotis buities ar išmaniaisiais įrenginiais. Kai kurie pacientai susiduria ir su psichosocialinėmis problemomis. Tremoras yra išskiriantis bruožas, dėl kurio gali būti patiriamas gėdos jausmas ar kitos su socialiniu gyvenimu siejamos problemos. Tyrimais įrodyta, kad tremoro įtaka pacientų gyvenimui reikšmingai teigiamai koreliuoja su rankų drebėjimo stiprumu. Šių problemų mastas yra didelis tiek ET, tiek PD atveju. Tai aktuali ir globali šių laikų sveikatos problema [8, 9].

Maždaug pusė ET sindromą turinčių žmonių teigia, kad simptomai labai stipriai veikia jų karjerą. Maždaug ketvirtadaliui pacientų liga sukelia finansinių problemų. Penktadalį sergančiųjų liga priverčia išeiti į pensiją, kai kuriais atvejais anksčiau laiko [8]. Dėl šių priežasčių rankų tremoras yra ne tik individualių asmenų, bet ir globali ekonominė problema. ET ir PD ligos yra siejamos su reikšmingomis perteklinėmis tiesioginėmis medicininėmis išlaidomis, netiesioginiais produktyvumo praradimais, nemedicininėmis išlaidomis ir neįgalumo pajamomis. 2017 metais Jungtinėse Amerikos Valstijose bendra ekonominė PD sukelta našta siekė 51,9 mlrd. JAV dolerių, kurias sudaro 25,4 mlrd. dolerių tiesioginių medicininių išlaidų ir 26,5 mlrd. dolerių netiesioginių ir nemedicininių išlaidų, tokių kaip sumažėjęs darbingumas ar priešlaikinės mirties nuostoliai [5].

Ekonominius ir asmeninius nuostolius galima minimizuoti diagnozavus ligas kuo anksčiau [7]. Deja, net vėlyvoje stadijoje, kai ligų simptomai yra pilnai pasireiškę, diferencijuojant PD ir ET pacientus aptinkama maždaug 25% paklaida [6]. Klaidos gali kilti dėl aukšto ligų neapibrėžtumo lygio ir dėl fakto, kad standartiniai vertinimo metodai yra pripažinti kaip nepakankamai objektyvūs, netikslūs ir nestabilūs [10, 11]. Tai signalizuoja poreikį moderniam rankų tremoro vertinimo įrankiui, kuris, būtų objektyvus, tikslus, stabilus ir lengvai prieinamas.

Šią problemą sprendė įvairūs tyrėjai, tačiau rinkoje iki šiol nėra priemonės, kuri tenkintų tikslumo, objektyvumo, stabilumo poreikius ir tuo pačiu metu būtų prieinama – nereikalaujant papildomos techninės įrangos, būtų paprasta ir intuityvi. Kadangi esami tyrimai pagrindžia, kad populiarių išmaniųjų įrenginių, tokių kaip išmanieji telefonai ar planšetės, funkcionalumas yra pakankamas tremoro vertinimui, šiame darbe iškeltas tikslas tokią priemonę sukurti.

Darbo tikslas - sukurti neurologinių ligų sukulto rankų tremoro vertinimo išmaniųjų įrenginių duomenimis priemonę, sudarytą iš duomenų rinkimo koncepto, kvantavimo ir diagnozės modelių.

Gretutinės studijų krypties tikslas: įvertinti sukurtos rankų tremoro matavimo priemonės potencialų ekonominį poveikį.

Darbo uždaviniai:

1. Apžvelgti esamas tremoro vertinimo priemones.
2. Sukurti duomenų rinkimo konceptą.
3. Sukurti ir įvertinti tremoro kvantavimo modelį.
4. Sukurti ir įvertinti tremoro diagnozės modelį.
5. Įvertinti sukurtos priemonės potencialų ekonominį efektą.
6. Apibendrinti rezultatus.

1. Literatūros apžvalga

1.1. Tremoro klasifikacija

Tarptautinės Parkinsono ir judėjimo sutrikimų draugijos (IPMDS) tremoro darbo grupė 2018 metais pasiūlė tremoro klasifikacijos schemą, pagrįstą dviem ašimis. Pirmoje ašyje pabrėžiami klinikiniai požymiai, istorija ir tremoro savybės. Antroje ašyje - galimos tremoro etiologijos. Pagrindinis schemos sukūrimo tikslas - pateikti atnaujintą, su tremorais susijusių įvairių sindromų, apžvalgą, jų klasifikaciją [12]. Pasak šios publikacijos ir jos atnaujinimui skirtos, 2021 atliktos apžvalgos, egzistuoja bent 28 dažniausiai kartu su tremoru pasitaikančios ligos ir (arba) etiologijos [1, 12]. Šio darbo apibrėžtis ribojasi ties neurologinių ligų sukeltu rankų tremoru, todėl, ligos, kurios veikia kitas kūno dalis arba nepatenka į neurologinių ligų spektrą, gali būti interpretuojamos kaip neaktualios. Be to, atsižvelgiant į tai, kad savo paplitimu dominuoja tik esencialinis tremoras (ET) ir Parkinsono liga (PD), apibrėžtis sumažinama iki šių dviejų ligų sukulto rankų tremoro vertinimo ir tik pirmosios ašies pagal klasifikacijos schemą.

1.1.1. Aktyvacijos sąlygos

Pagal aktyvacijos sąlygas rankų tremoras yra skirstomas į ramybės ir veiksmo tremorus. Ramybės tremoras pasireiškia kai ranka yra neaktyvi – pacientas ilsisi, yra atsipalaidavęs ar nenaudoja rankos veiksmams atlikti. Tokio tipo rankų drebėjimas yra dominuojantys pacientuose su PD. ET atveju ramybės drebėjimas pastebimas, kai liga yra labai pažengusi.

Veiksmo tremoras pasireiškia pacientui rankomis bandant atlikti įvairius veiksmus. Tai dar vadinama kinetiniu tremoru. Veiksmo tremoro pasireiškimas pastebimas ir laikant rankas pozicijoje, kurioje būtina priešintis gravitacijos jėgai, pvz. laikant ranką ištįstą. Tai vadinama poziciniu tremoru. Veiksmo tremoras dalijamas į kelias grupes: paprastąjį, kai tremoras išlieka nekintantis visą judesio laiką, ketinimo (ang. intention), kai tremoro amplitudė didėja rankai artėjant prie vizualiai matomo taikinio, ir užduočiai specifinio tremoro, kai drebėjimo amplitudė didėja atliekant specifinius veiksmus. PD atveju veiksmo tremoras yra labai silpnas arba išvis neegzistuojantis. Amplitudės didėjimas pasireiškia tik esant mentaliniam stresui, vaikstant, atliekant judesius kitomis kūno dalimis arba kitais išskirtiniais atvejais. Tai tarp ET pacientų dominuojantis tremoro tipas.

Aktyvacijos sąlygos yra svarbus rodiklis diferencijuojant ET ir PD. Tačiau, pastebimas aukštas neapibrėžtumo lygis: maždaug 20% pacientų su ET turi ne tik veiksmo, bet ir ramybės tremorą, o 25% PD atvejų neturi veiksmo tremoro [13]. Situaciją apsunkina ir tai, kad riba, skirianti ramybės tremorą ir veiksmo tremorą, iki šiol nėra griežtai apibrėžta. Tai apsunkina ne tik diagnozavimą, bet ir patį duomenų rinkimą. Visgi norint pamatuoti ramybės tremorą, reikia žinoti, kokiose sąlygose jis garantuotai pasireikš. Pastebima, kad kai kuriais atvejais, pacientui gali reikėti papildomų priemonių ramybės tremorui matuoti, pvz. papildomų atramų, kurie atpalaiduoja rankas nuo pasipriešinimo gravitacijos jėgai [12].

Aktyvacijos sąlygos vertinamos gydytojo subjektyvia nuomone ir patirtimi, stebint pacientą ir prašant jo atlikti įvairias užduotis [16, 17]. Literatūroje galima rasti ir daugiau tremoro klasifikavimo pagal aktyvacijos sąlygas grupių, tačiau jos neturi didelės reikšmės projekto tikslui.

1.1.2. Dažnis

Dažnis yra viena populiariausių tremoro savybių. Kone kiekvienai neurologiniai ligai, kurios simptomas siejamas su rankų drebėjimu, yra būdinga unikali dažnių juosta [1, 12]. Šio vieno kriterijaus gali užtekti diferencijuoti tam tikrus sutrikimus. **1 pav.** pavaizduota įvairių tremorų dažnių, diagnozių ir aktyvacijos sąlygų priklausomybė [14].

Diagnozė	Dažnis, Hz															Aktyvacijos sąlygos		
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	Poilsio	Pozicijos	Tikslingų judesių
Fiziologinis tremoras																		
Esencialinis tremoras																		
Vaistų sukeltas / toksinis																		
Neuropatinis tremoras																		
Psichogeninis tremoras																		
Pozicijai specifiniai tremorai																		
Distonija																		
Parkinsono liga																		
Holmsio tremoras																		
Cerebrinis tremoras																		

1 pav. Įvairių tremorų dažnių, diagnozių ir aktyvacijos sąlygų priklausomybė

Didžioji dalis ligų yra asocijuojamos su 4 – 8 Hz dažnių juostos rankų tremoru. Pastebima aukšta variaciją tarp pacientų ir tarp to paties paciento skirtingais laikotarpiais. Dažnis gali kisti nuo dabartinės būsenos, ligos progreso ir kitų kintamųjų. Dėl šių priežasčių vien dažnis klasifikacijai naudojamas tik retais atvejais [1, 12, 13, 14].

ET dažnių juosta ribojasi 4 – 12 Hz juostoje. PD charakterizuojama 4-6 Hz juosta. Egzistuoja 2 Hz persidengimas tarp ligų 4 – 6 Hz juostoje. Šis kriterijus leidžia išskirti ET su vienintele sąlyga, sakančia, kad dažnis yra didesnis nei 6 Hz ir mažesnis nei 12 Hz. Deja, praktikoje pastebima, kad 4 – 6 Hz juosta yra dažniausiai pasitaikanti, todėl dažnis gali būti naudojamas tik kaip vienas iš daugelio, o ne vienintelis kriterijumi ET ir PD diferencijavimui. Be to, pastebima ir išskirtinių atvejų, kai PD pacientų tremoras siekia net 9 Hz [15].

1.1.3. Amplitudė

Interpretuojant rankų drebėjimą kaip dinaminį, periodišką judėjimą koordinačių ašyje, tremoro amplitudę galima apibrėžti kaip didžiausią poslinkį, kurį tremoras pasiekia vieno periodo metu. Tai fundamentali, bet kokiai virpesių analizei svarbi savybė, kurią netiksliai galima įvertinti be papildomų priemonių, stebint pacientą vizualiai. Tuo remiasi daugelis tradicinių tremoro matavimo priemonių [16, 17]. Tačiau dydis negali būti naudojamas kaip pagrindinis atskaitos taškas objektyviam, tiesioginiam vertinimui. Pastebima didžiulė variaciją tiek tarp skirtingų ligų, tiek tarp skirtingų pacientų su ta pačia liga. Net to paties paciento amplitudė gali kisti bėgant laikui, keičiant kūno pozicijas ir bendrai paciento būsenai, pvz. streso lygiui ar nuovargiui [1, 13]. Objektyvus amplitudės matavimas realizuojamas tiek laiko, tiek dažnių srityse.

1.1.4. Spektrinės savybės

Rankų tremoras tiria periodiškų rankų judesių, todėl jo analizavimui gali būti pritaikomi standartinės virpesių analizės metodai, tokie kaip spektrinė analizė. Kompiuterizuoti virpesių analizės

metodai dešimčių ar šimtų hercų dažniu diskretizuoja įvairių jutiklių duomenis ir gautas laiko eilutes konvertuoja į dažnių sritį. Tokiais metodais kaip diskretinė Furjė transformacija (FT) ar labiau optimizuotais metodais, tokiais kaip greitoji Furjė transformacija (FFT), konvertavus laiko eilučių duomenis gaunamas judesio galios spektras, iš kurio aukštu tikslumu išvedamos fundamentalios savybės, tokios kaip dažnis ar amplitudė, bet taip pat ir visa eilė sudėtingesnių, išvestinių savybių [14, 15, 18 - 28]. Dalis jų pateikta žemiau.

Galia – tremoro virpesių galia sutartiniame dažnių ruože, apskaičiuojama greitąja Furjė transformacija (FFT) konvertuojant tremoro duomenis iš laiko srities į dažnių sritį. Dėl savo logiškos interpretacijos, skaičiavimo paprastumo ir istorijos, tai, turbūt, populiariausias tremoro vertinimo parametras. Jis yra pakankamai atsparus triukšmui, nes neaktuali užfiksuotų judesių dalis, tokia kaip tyčiniai rankų judesiai, nepatenka į tipinę tremoro dažnių juostą ir yra ignoruojami. Signalo – triukšmo santykį skaičiuojant galią sumažina baltasis triukšmas, tačiau jį galima išfiltruoti nustatant galios amplitudės pradinę žemutinę ribinę dedamąją – žemutinį limitą. Triukšmo lygį taip pat galima valdyti standartizuotais matavimo metodais, ribojančiais matavimo metu atliekamų veiksmų galimybes, todėl sumažinančias triukšmo dedamųjų pasirodymą aktualioje spektro juostoje [14, 29].

Galia apskaičiuojama naudojant Furjė transformacijos algoritmus. Furjė transformacija yra matematinė procedūra, naudojama signalo suskaidymui į sudedamąsias dažnių dalis. Kitaip tariant, signalo transformavimui iš laiko srities į dažnių sritį. Matematiškai ji išreiškia tolydaus laiko signalą kaip skirtingų dažnių, amplitudžių ir fazių kompleksinių sinusoidžių (arba eksponentinių funkcijų) sumą:

$$X(\omega) = \int_{-\infty}^{\infty} x(t) e^{-i\omega t} dt \quad (1.1)$$

Čia $x(t)$ - tolydaus laiko signalas, $X(\omega)$ – Furjė transformacija, ω - kampinis greitis. Praktikoje tolydūs signalai yra mažiau aktualūs nei diskretiniai. Diskretinio laiko signalų transformavimui iš laiko srities į dažnių sritį naudojamas diskretinė Furjė transformacija [41, 42, 43]. Ji matematiškai apibūdinama kaip:

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-\frac{iz\pi kn}{N}}, \quad 0 \leq k \leq N - 1 \quad (1.2)$$

Čia $X(k)$ - diskretinė Furjė transformacija diskretinio laiko signalui $x(n)$, N - signalo dydis, k – dažnių komponentių indeksas. Modernioje signalų apdorojimo praktikoje naudojamos įvairios mažiau skaičiavimo ir atminties resursų naudojančios diskretinės Furjė transformacijos alternatyvos, vadinamos greitosiomis Furjė transformacijomis (FFT). Jos ir naudojamos įvairiuose rankų tremoro tyrimuose, interpretuojant duomenis dažnių srityje. Tremoro vertinimo kontekste, galia nusako visų dažnių komponentių sumą intervale f_{min} ir f_{max} , kuris nusako tremoro dažnių juostos intervalą, pvz. 4-12 Hz. Čia k_{min} ir k_{max} yra diskretizuoto dažnio komponentių indeksai, P – galia. $X(k)$ yra kompleksinis skaičius, todėl galia vertinama iš jo modulio.

$$P = \sum_{k_{min}}^{k_{max}} |X(k)| \quad (1.3)$$

Centrinis dažnis – dažnis, ties kuriuo galios spektro plotas yra ties reikšme, kurioje žemesnių dažnių spektro suminė galia yra lygi aukštesnių dažnių spektro suminei galiai. Dydis yra aktualus tik tada,

kai pagrindinė tremoro komponentė yra ryškiai išreikšta. Kitu atveju parametro interpretacija netenka prasmės [15].

Dažnio dispersija – dažnių spektro plotis hercais, kuriame kaupiamas sutartinis tremoro galios kiekis, pvz. 66%. Centras yra ties didžiausios spektrinės galios dažniu [14, 15].

Dispersija – aukščiausios viršūnės galios ir visos tremoro galios santykis. Pavyzdžiui, žemiau pateiktoje formulė atitinka galios dispersiją ties viršūnės dažniu ± 0.5 Hz ruože. Čia k_p - diskretizuoto dažnio komponentė atitinkanti dažnį ties didžiausia galia, k_p – komponentė, atitinkanti 0.5 Hz, $P_{max\pm 0.5}$ - aukščiausios viršūnės galia ± 0.5 Hz ruože.

$$D_{0.5} = \frac{P_{max\pm 0.5}}{P} = \frac{\sum_{k_p-k_{0.5}}^{k_p+k_{0.5}} X(k)}{\sum_{k_{min}}^{k_{max}} X(k)} \quad (1.4)$$

Kiti parametrai – bet kokie kiti dydžiai, pvz. vidurkis, standartinis nuokrypis, entropija ir t.t.

Trumpojo laiko spektrinės savybės– spektrinės savybės, skaičiuojamos taikant FFT ne visoje tremoro duomenų imtyje, bet atskirai daugelyje mažesnių imties dalių. Literatūroje ši metodika vadinama trumpojo laiko FFT (STFT). Konvertuoti duomenys analizuojami 3 dimensijų matricomis- spektrogramomis, kurių ašys atitinka laiką, dažnį ir signalo spektrinę amplitudę. Spektrogramos naudojamos kiekybiškai įvertinti tremoro spektrinių savybių kitimą laike. Pavyzdžiui, spektrograma galima rasti ne tik bendrą galią (3), bet ir galios standartinį nuokrypį viso duomenų rinkimo metu:

$$\sigma_P = \sqrt{\frac{1}{N} \sum_{n=1}^N (P_n - P_\mu)^2} \quad (1.5)$$

Čia σ - standartinis nuokrypis, N - dalių, į kurį padalintas signalas kiekis, P_μ - vidutinė galia, P_n galia laiko tarpą, priklausančią n signalo daliai. Ši savybė apibrėžia tremoro galios variaciją.

1.1.5. Laiko savybės

Laiko savybės remiamos standartinėmis laiko srities signalą apibūdinančiomis savybėmis. Tai gali būti tradiciniai parametrai: standartinis nuokrypis, dispersija, vidurkis. Distribucijos parametrai: ekscesas, asimetrija. Taip pat ir judesio signalų formos analizė, kurioje matuojama bangos forma, jos parametrai, kitimas ir t.t.[14].

1.1.6. Asimetrijos savybės

Jei abiejų rankų tremoras savybės statistiškai reikšmingai nesiskiria, jis vadinamas simetrišku. Atvirkščiai – jei toks skirtumas pastebimas, tremoras laikomas asimetrišku. Ankstesniuose tyrimuose PD atveju pastebėta asimetrija ties centrinio dažnio ir dažnio dispersijos parametrais. Su amplitudės susijusioms savybėms būdinga asimetrija tiek ET, tiek PD atveju. Literatūroje galima rasti ir tyrimų, kuriuose naudojama asimetrija tarp drebinimo judesio koordinatinių ašių. Pavyzdžiui, matuojant judesį trijose dimensijose x, y, z, matuojama asimetrija tarp porų (x, y), (x, z), (y, z). Tai nėra labai reikšminga savybė, tačiau tyrimais nustatyta, kad tremoro diferencijavimo kokybė, naudojant šią informaciją, gali pagerėti [14, 15].

1.1.7. Kitos savybės

Egzistuoja ir begalė kitų savybių ar išvestinių indeksų tremorui matuoti. Jų skaičius įvairiuose tyrimuose kinta nuo kelių iki keliasdešimties ir yra ribojamas, atrodo, tik autorių fantazija. Atsižvelgiant į tai, kad iki šiol nėra vienos pripažintos vertinimo priemonės, galima daryti prielaidą, kad toks problemos sprendimo būdas nėra optimalus. Pastarųjų metų proveržiai giliojo reprezentacijų mokymosi srityje suteikia galimybę naudoti tokius metodus, kaip auto-enkoderiai, automatiniam savybių nustatymui atsižvelgiant į nesužymėtus duomens [30, 31]. Jie puikiai tinka aukšto neapibrėžtumo duomenims ir paslėptųjų struktūrų radimui, todėl gali būti taikomi ir rankų tremoro analizei. Šiuo metu minėtas sritis jungiančių tyrimų yra nedaug. Galimai dėl srities naujumo, arba dėl didelio kiekio duomenų reikalavimo. Atsižvelgiant į galimą naudą, reprezentacijų paieška giliuoju mokymusi panaudota ir šiame darbe.

1.2. Tremoro vertinimas

Galima išskirti du pagrindinius tremoro vertinimo priemonių tikslus. Pirmasis tikslas - nustatyti tremoro asociaciją su viena ar kita liga – atlikti diagnozės funkciją (klasifikavimo užduotis). Antrasis tikslas – kiekybiškai nustatyti tremoro simptomų stiprumą, kitais žodžiais, kvantuoti tremorą (regresijos užduotis). Egzistuoja grupė vertinimo priemonių ir kitoms paskirtims, pvz. testai žmogaus gyvenimo kokybės poveikiui nustatyti, realizuojami klausimyno pavidalu. Kadangi didelį kiekį informacijos, įskaitant ir gyvenimo kokybę, galima išvesti vien iš diagnozės ir stiprumo įverčio, šio darbo apibrėžimo sritis ribojama ties šiais aspektais.

1.2.1. Tradiciniai vertinimo būdai

Tradiciniai tremoro vertinimo būdai remiasi subjektyviu gydytojo vertinimu. Paciento prašoma atlikti įvairius judesius ar užduotis. Gydytojas, stebėdamas pacientą, nusprendžia kokio stiprumo tremoras pasireiškia įvairių aktyvacijos sąlygų metu. Toks principas leidžia atlikti įvertinimą be jokių papildomų priemonių. Tai, tradiciškai, patinka gydytojams, todėl literatūroje ir klinikinėje praktikoje randamos įvairios populiarios vertinimo metodologijos.

FTM tremoro vertinimo skalė plačiai naudojama klinikiniuose tyrimuose. Ji vertina pozicinį veiksmo tremorą, kai galūnės ištiesiamos į priekį, kinetinį tremorą, kai atliekama nosies pasiekimo užduotis, ir ramybės tremorą, kai abi viršutinės galūnės atpalaiduotos ant paciento kelių, pacientui sėdint. FTM įvertis tiesiogiai priklauso nuo tremoro amplitudės ir kinta 0 – 4 režyje, kai 0 – mažiausia, o 4 – didžiausia amplitudė. FTM turi įvairių trūkumų. Didžiausias fiksuotina amplitudė yra 4 cm, o to nepakanka labai stipriems atvejams matuoti. Vertinimas turi labai aukštą subjektyvumo laipsnį, yra stipriai priklausomas nuo gydytojo, todėl rezultatai yra pripažinti esantys nenuoseklūs. Dėl šių ir įvairių kitų trūkumų galima teigti, kad skalė nėra geriausias pasirinkimas ET pacientams. Praktikoje, ji dažniausiai naudojama tiriant kitų tipų tremorus [16]. TETRAS yra kita iš pagrindinių amplitudę matuojančių skalių, naudojamų ET tyrimams. ET drebulys nelinkęs pasireikšti ramybės būsenoje, todėl šis kriterijus į vertinimą neįtraukiamas. Aukščiausias stiprumas vertinamas 4 balais. Jis apibūdina 20 cm amplitudės tremorą. Kitaip nei FTM atveju, skalės pakanka net labai stipriems atvejams vertinti pakankamu jautrumu. Nors tai vienas populiariausių klinikinių tyrimų instrumentų, gauti rezultatai, kaip ir FTM, vertinami kaip nepakankamai nuoseklūs [16, 17].

1.2.2. Vertinimas inerciniais jutikliais

Aiškų poreikis objektyviai ir tiksliai vertinimo priemonei atsispindi dideliame skaičiuje pastaraisiais metais pasirodžiusių tyrimų. Didesnė dalis jų remiasi inerciniais jutikliais.

Zhang B. ir kt. [13] 2018 atliktame tyrime „Nauja laikysena geresniam Parkinsono ligos ir Esencialinio tremoro diferencijavimui“ 50 pacientų (24 ET ir 26 PD) laikė rankas autorių išrastoje pozicijoje ir atskaitinėje, tradicinėje pozicijoje.



2 pav. Tremoro tyrimas tradicine poza ir autoriaus siūlomoje pozicijoje su rankos atramomis [13]

300 sekundžių laikotarpyje buvo įrašinėjami rankos pagreičio duomenys. Klasifikavimas į ET ir PD atliktas logistine regresija. Tyrimo kriterijai buvo limituoti ties dažniu ir intensyvumu, apibrėžtu, kaip filtruoto signalo absoliučių reikšmių vidurkiu. Gauti statistiškai reikšmingi rezultatai, diferencijuojant pagal dažnį. Diferencijuojant pagal intensyvumą reikšmingi rezultatai pastebėti tik ties autorių pasiūlyta rankos pozicija. Geriausi rezultatai pasiekti dažnį nustatant iš spektrinio tankio ($AUC = 0.944$, $TPR = 92\%$, $FPR = 0\%$, $ACC = 96\%$). Su ištiesta rankos pozicija rezultatai daug blogesni ($AUC = 0.734$, $TPR = 54\%$, $FPR = 12\%$, $ACC = 72\%$). Autoriai atkreipia dėmesį į aptiktą tikslumo priklausomybę nuo laiko – pastebėta, kad su trumpesniu nei 300 sekundžių duomenų rinkimo langu rezultatai stipriai prastėja. Tai yra šio tyrimo trūkumas – ilgi matavimai nėra praktiški. Šį trūkumą potencialiai galima panaikinti naudojant daugiau savybių ir didesnio pajėgumo klasifikavimo algoritmus.

Sun M. ir kt. [33] atliko panašų tyrimą su 30 PD pacientų, kuriems buvo liepta atlikti tradicinių tremoro vertinimo būdų užduotis. Judesio duomenis fiksavo ant riešo pritaisytas įtaisas su 3 ašių akselerometru ir 3 ašių giroskopu.




3 pav. Tremoro tyrimas specialiu prietaisu [33]

Duomenis padalinus į 1.28 sekundžių intervalus su 0.64 sekundžių persidengimais buvo gauta imtis su 20 226 tremoro mėginiais. Duomenis išreiškus 2 dimensijų matrica su 6 jutiklių reikšmėmis (2 jutikliai 3 ašys) ir 128 laiko reikšmėmis (diskretizavimo dažnis 100 Hz) buvo gautas aukšto tikslumo tremoro kiekybinis vertinimas dvejetainine rezoliucija (0 – nėra tremoro, 1 – tremoras yra). Klasifikavimui panaudotas konvoliucinis neuroninis tinklas (CNN). Gautas PRE = 88.58%, REC = 100%, F1 = 93.5, ACC = 94.29. Šio tyrimo trūkumas yra nepraktiškai maža kvantavimo rezoliucija. Palyginimui, net tradiciniai tremoro vertinimo metodai turi 5 lygių reikšmes. Dvejetainis tremoro kvantavimas labiau pritaikomas specializuotoms paskirtims, pvz. adaptyvios giliosios smegenų stimuliacijos optimizavimui, tačiau verta atkreipti dėmesį į inovatyvų CNN panaudojimą laiko eilučių klasifikacijai. Galima daryti hipotezę, kad išreiškus duomenis kita forma, pvz. spektrograma, arba vietoj tiesioginių duomenų naudojant išvestines savybes, galima pagerinti modelio kokybę ar kvantavimo rezoliuciją.

Wile J. D. ir kt. [32] atliko tyrimą, kuriame 29 paciento (14 ET ir 15 PD) stipriausias simptomais pasižyminčios rankos tremoras buvo matuojamas išmaniuoju laikrodžiu ir analoginiu akselerometru kaip atskaitos taškas. Ištiestų ir ilsėjimosi pozicijoje laikomų rankų duomenis buvo konvertuoti į dažnių sritį su 0.033 Hz rezoliucija. Matavimo trukmė siekė 30 sekundžių, tačiau tyrėjai išskaidė duomenis į 1 sekundės nepersidengiančias atkarpas. Toliau, konvertavę į logaritminės skalės dažnių sritį, apskaičiavo galios spektro vidurkį. Diferencijavimui autoriai naudojo pirmųjų keturių aukščiausios spektro viršūnės harmonikų galios vidurkio slenkstį (1).

$$PD < 2.1834 \log(mg^2) < ET \quad (1.6)$$


Teigiama, kad aukščiausios viršūnės harmonikų galia yra PD ir ET pacientų skiriamasis bruožas. ET pacientų rankų drebėjimas asocijuojamas su didesnės galios harmonikomis, palyginus su PD. Autoriai atkreipia dėmesį į tai, kad logaritminėje skalėje skirtumas tarp harmonikų galios yra aiškesnis ir labiau tinkamas diferencijavimui.



4 pav. PD ir ET pacientų tremoras laiko ir dažnių srityse 5s intervale [32]

Diferencijavimas teisingai klasifikavo 96% imties. $SEN = 90.9\%$, $SPE = 100\%$, $AUC = 0.981$, $K = 0.91$. Reikšmingas skirtumas tarp išmaniojo laikrodžio duomenų ir atskaitinio akselerometro nebuvo rastas. Verta atkreipti dėmesį į tai, kad tyrime 11 pacientų dalyvauti negalėjo, nes matavimų metu tremoras buvo nepakankama išreikštas. Tai nėra sąžininga, nes amplitudės variacija yra neišvengiama. Šis trūkumas ir yra motyvacija ne amplitudė remtų savybių naudojimui. Įtraukus šiuos pacientus gauto modelio tikslumas būtų prastesnis.

Shaven N. ir kt. [14] atliko tremoro kvantavimo tyrimą su išmaniuoju laikrodžiu, turinčiu akselerometrą, ir prie odos tvirtinamu atskaitiniu prietaisu, turinčiu akselerometrą ir giroskopą.



5 pav. Tremoro kvantavimo tyrimas su prie odos tvirtinamu jutikliu ir išmaniuoju laikrodžiu [14]

Jutiklių duomenys buvo įrašomi atliekant įvairius veiksmus rankomis. Kaip atskaitos taškai kvantavimui panaudoti gydytojų tremoro intensyvumo įvertinimai. Klasifikavimas RF modeliu su 50 medžių pasiekė $AUC = 0.77$ dvejetainiam kvantavimui ir $AUC = 0.75$ kvantavimui su 5 lygiu skale. Diskretizavimo dažnis turėjo didelę įtaką AUC , tačiau tik ties ypatingai žemomis reikšmėmis (< 20 Hz). Papildomas jutiklis (giroskopas), lyginant su vieno jutiklio (akselerometro), naudojimu, reikšmingai AUC neįtakojė. Tyrime buvo atlikta kruopšti įvairių savybių ir jų grupių analizė. Kai kuriais atvejais panaudoti net 148 kintamieji, tačiau rezultatai parodė, kad aukštas savybių skaičius yra nebūtinai tiksliai kvantavimui. Verta atkreipti dėmesį į tai, kad imtį sudarė tik 13 asmenų, todėl duomenys greičiausiai menkai atspindi bendrą PD populiaciją.


Nagrinėjant literatūrą pastebimas bendras sutarimas – inerciniai jutikliai gali būti naudojami sėkmingam tremorui vertinimui. Populiariausi iš jų yra akselerometras ir giroskopas. Iki šiol nagrinėtuose tyrimuose dominavo duomenų rinkimas specializuota technine įranga arba išmaniaisiais laikrodžiais, turinčiais minėtus judesio jutiklius. Tačiau tokį pat funkcionalumą galima pasiekti ir labiausiai paplitusiu išmaniuoju įrenginiu – telefonu [23].

Kostikis N. ir kt. [24] studijoje pasiūlė praktišką 5 lygių kvantavimo metodą. 25 PD pacientų ir 20 sveikų žmonių (CT) rankų drebėjimas buvo ištirtas renkant mobiliojo telefono akselerometro ir giroskopo duomenis.



6 pav. Tremoro kvantavimo tyrimas mobiliuoju telefonu ir specialia pirštine [24]

Tyrime naudoti įvairūs mašininio mokymosi metodai, tačiau geriausius rezultatus pasiekė medžiais grįstas algoritmas, teisingai identifikavęs $TP = 82\%$ PD ir $TN = 90\%$ CP imties, $AUC = 0.9435$. Nors rezultatai aukšti, visos naudotos tremoro savybės remiasi amplitude, kuri, kaip jau buvo pastebėta anksčiau, pasižymi labai didele variacija. Autoriai pabrėžia, kad geresni rezultatai pasiekiami su giroskopu surinktais kampinio greičio duomenimis, nei akselerometru fiksuotu pagreičiu, tačiau skirtumas nežymus. Tai pagrindžia ir **7 pav.** pavaizduotas pagreičio ir kampinio greičio duomenų spektrinių galių kreivės, kurios vizualiai atrodo identiškos.




7 pav. Pagreičio ir kampinio greičio duomenų spektrinių galių palyginimas [24]

Apibendrinant, inerciniai jutikliai gali būti naudojami tremoro vertinimui, tačiau, duomenų rinkimui pakanka tiesiog akselerometro. Autoriai neturi bendros nuomonės dėl giroskopo ar kitų inercinių jutiklių suteikiamos naudos. Pastebėta, kad tyrimuose dominuoja mažos imtys, tik nedidelė dalis tyrimų turi kontrolės grupes su sveikais žmonėmis. Dėl šių priežasčių neaišku kokius rezultatus pasiūlytos priemonės pasiektų su tikrą pasaulį atspindinčia ET, PD ir CP populiacija.

1.2.3. Vertinimas kitais jutikliais

Literatūroje dominuoja inerciniai jutikliai, tačiau rezultatais konkuruoja ir kitą duomenų rinkimo kelią pasirinkusių autorių darbai.

Solé-Casals J. ir kt. [35] sukūrė priemonę diferencijavimui tarp ET ir CP naudojant lietimą jutiklį - planšetinį kompiuterį ir jam skirtą rašiklį dviejų ašių koordinatėms fiksuoti. Tyrimo metu 21 CP ir 29 ET pacientai piešė Archimedo spirales. Tai tradicinis tremoro vertinimo metodas, kurio užduotis – kuo tiksliau nubrėžti spiralę.



8 pav. Archimedo spiralės piešinys (CP – kairėje, EET – dešinėje)[35]

Anksčiau analizė buvo atliekama subjektyviu gydytojo vertinimu, pacientui naudojanti rašiklį ir popierių. Tyrimo autoriai modernizavo sprendimą ir perkėlė jį į kompiuterizuotos analizės amžių. Klasifikavimui panaudota linijinio diskriminanto analizės algoritmas (LDA), artimiausių kaimynų (k-NN) ir paramos vektoriaus mašinos (SVM) algoritmai, iš kurių geriausią rezultatą pavyko pasiekti SVM (ACC = 97.96%, SEN = 100%, SPE = 96.42%). Vertinimui naudotos savybės remtos tiek intensyvumu, dažniu ir įvairiais inovatyviais dydžiais, tokiais kaip didžiausias fraktalinis ilgis – absoliučios koordinatinių pokyčio reikšmės sumos logaritmas. Nors darbas ribojasi tik ET ir CP vertinimu, tai geriausius rezultatus pasiekęs tyrimas.

Panašų tyrimą su PD pacientais atliko ir **Damaševičius R. ir kt.** [36]. Čia tyrėjai naudojo ne tik lietimą jutiklio duomenis, bet ir įvairias Archimedo spiralių nuotraukų duomenų bazines. Bendra tyrimui naudota imtis sudarė 296 PD ir 218 CP subjektų. Savybių ekstrakcijai panaudotas SqueezeNet- 18 sluoksnių gilusis dirbtinis neuroninis tinklas optimizuotas mažesniems parametrų skaičiams. Klasifikacijai naudojamas SVM. Gautas diferencijavimo tarp CP ir PD ACC = 91.26%, PRE = 92.00%, REC = 89.85%, F = 0.9067. Rezultatai prastesni nei tie, kuriuos savo tyrime gavo **Solé-Casals J. ir kt.** [35]. Tai galėjo įtakoti 10 kartų didesnis imties dydis (514 ir 50), taip pat konvertavimas iš nuotraukų į normalizuotą ir filtruotą, pilkos spalvos tono spiralę. Konvertavimo metu galėjo dingti dalis naudingos informacijos, padidėti triukšmo lygis. Tai gerai atsispindi ir vizualiai palyginus abiejų tyrimų spirales (**8 pav.** ir **9 pav.**). Įdomu ir tai, kad pacientams piešiant Archimedo spiralę, aktyvacijos sąlygos yra tinkamos tik veiksmo tremorui, o jis labiau būdingas ET pacientams. Kadangi autoriams pavyko pasiekti aukštus rezultatus, galima daryti prielaidą, kad ramybės tremoro matavimas nėra būtina sąlyga kokybiškam diferencijavimui tarp ligų.




9 pav. Archimedo spiralių vertinimas iš nuotraukų (PD, PD, CP)[36]

Zhang, L ir kt. [30] tyrime pavyko tiksliai atlikti 9 ET pacientų tremoro kvantavimą 5 lygiais, panaudojant vien kamera užfiksuotais video duomenimis. Naudojant specialų autoenkoderį gautas ROC = 97% ir $r = 0.91-0.97$ Pearsono koreliacija tarp klinikinių vertinimų ir modelio interpretacijos. Algoritmas išreniruotas naudojant 28 CP subjektų vaizdo įrašus jiems simuliuojant tremorą. Sėkmingi rezultatai įrodo, kad tremoro kvantavimui nebūtina naudoti ET ar PD pacientų duomenis. Sveikų pacientų simuliuota imtis gali būti naudojama kaip augmentacijos priemonė ar net treniravimo duomenų pakaitalas.

1.3. Ekonominiai aspektai

1.3.1. Parkinsono ligos ekonominė našta

Willis A.W. ir kt. [37] duomenimis, net 40 % PD pacientų JAV niekada neapsilanko pas neurologą ar judesių sutrikimų specialistą. Pasak atlikto tyrimo, PD pacientų, kuriems suteikta neurologo priežiūra, išgyvenamumo rodikliai yra didesni, palyginti su pirminės sveikatos priežiūros gydytojo gydomais pacientais. Deja, tik 58 proc. pacientų, sergančių PD, 48 mėnesių tyrimo laikotarpiu, bet kada kreipėsi į neurologą. Likusieji tiriamieji gydėsi pas pirminės sveikatos priežiūros gydytoją (vidaus ligų (18,9 %), šeimos praktikos (11,9 %), geriatrinės medicinos (0,8%). Mažiausiai specialisto priežiūros teko moterims ir tautinėms mažumoms. Duomenys atspindi tik tą populiaciją, kuri bent kartą naudojosi JAV sveikatos draudimo programa „Medicare“.



10 pav. PD pacientų išgyvenamumo rodiklis pagal apsilankymą pas neurologą ir pirminės sveikatos priežiūros gydytoją (p.s.p.s.) [37]

Autoriai, ir susiję tyrimai [5, 38, 46] išskiria kelias galima priežastis, kodėl PD sergantys pacientai nesikreipia į neurologą:

1. Klaidinga diagnozė: bendrosios praktikos ir pirminės sveikatos priežiūros gydytojai gali stokoti kompetencijos ir patirties, kad galėtų tiksliai diagnozuoti PD, todėl diagnozė gali būti nustatyta klaidingai. Visgi, nėra gerai žinomų biologinių žymenų, pagal kuriuos būtų galima nustatyti PD. Diagnostikos testai neduoda galutinių rezultatų, todėl klinikinė diagnozė priklauso nuo bradikinezijos (judesių lėtumo) ir rankų drebėjimo ar kitų simptomų nustatymo. Klinikinėje aplinkoje PD dažnai nepastebima arba diagnozuojama klaidingai, nes simptomai sutampa su įvairiomis ligomis. Tyrimai rodo, kad beveik pusė (47 %) PD diagnozių, nustatytų pirminės sveikatos priežiūros įstaigose, yra neteisingos, o gydytojų, neturinčių specialios patirties judesių

- sutrikimų srityje, klaidų lygis siekia apie 25 %. Tuo tarpu judesių sutrikimų specialistų klaidų lygis yra mažesnis - nuo 6 iki 8 % [46].
2. Galimybė gauti sveikatos priežiūros paslaugas: neurologų stoka žemesnio ekonominio sluoksnio populiacija apgyventose gyvenvietėse ar atokiuose regionuose. Tokiose vietovėse gyvenantiems pacientams tenka keliauti didelius atstumus. Tai ypatingai apsunkina ligos simptomai.
 3. Informacijos stoka: PD nėra gerai žinoma liga, todėl pacientai gali neatpažinti savo simptomų arba nežinoti, kad jie turėtų kreiptis į neurologą. Gali būti nesiryžtama kreiptis į gydytoją dėl stigmos ar baimės..
 4. Finansiniai apribojimai: Net jei pacientai žino apie PD simptomus ir būtinybę kreiptis į neurologą, medicininės priežiūros išlaidos gali sudaryti lemtingą kliūtį.
 5. Pasitikėjimas alternatyviais informacijos šaltiniais: **Riggare S. ir kt.** [38] atliko Švedijoje atliktos internetinės apklausos rezultatų tyrimą, siekiant išsiaiškinti, kaip PD sergantys asmenys įgyja specifinių žinių apie ligą ir įsitraukia į susijusias sveikatos priežiūros paslaugas. Rezultatai parodė, kad PD pacientai daugiausia žinių apie ligą gauna iš internetinių šaltinių. Tai dažniau daroma tarp moterų ir darbingo amžiaus asmenų. Padaryta išvada, kad dauguma PD sergančių asmenų su savo neurologu praleidžia mažiau nei vieną valandą per metus, ir tik pusė asmenų reguliariai bendrauja su kitais sveikatos priežiūros specialistais.

Literatūroje bendrai sutariama, kad didesnis medicinos profesionalų kontaktas su PD pacientais galėtų sumažinti socialinę ir ekonominę PD sukeliama naštą. Ypatingai atsižvelgiant į tai, kad mirtingumo rodiklių padidėjimas asocijuojamas su didele ekonomine žala. Tačiau tai ne vienintelis sprendimas. Tyrimuose stipriai diskutuojama ir apie ankstyvos diagnozės potencialą. Egzistuoja įvairios intervencinės priemonės, kurios ankstyvoje ligos stadijoje gali padėti išsaugoti neuronų funkcionavimą, sumažinti simptomus ar sulėtinti ligos progresavimą. Keli ligos sąnaudų tyrimai parodė, kad dauguma išlaidų, susijusių su PD, patiriama pažengusiose ligos stadijose. Joms būdingi sunkūs simptomai, didesnis poreikis slaugytojų priežiūrai ir sveikatos priežiūros paslaugoms. Nustatyta, kad motorinės komplikacijos, tokios kaip tremoras, prisideda prie didesnių išlaidų, susijusių būtent su PD [46].

Dalyje literatūroje randamų tyrimų siekiama kiekybiškai nustatyti ankstyvosios PD intervencijos ekonominę vertę. Tyrimuose naudojamas kokybės koreguotų gyvenimo metų rodiklis (QALY), kuriame atsižvelgiama į asmens gyvenimo trukmę ir gyvenimo kokybę tuo pačiu metu. Gyvenimo kokybė matuojama skalėje nuo 0 (mirtis) iki 1 (puiki sveikata). QALY gaunamas padauginus gyvenimo kokybės balą iš nugyventų metų skaičiaus. Tai standartizuotas būdas palyginti įvairias sveikatos intervencijas ir nustatyti jų bendrą veiksmingumą bei ekonominį efektyvumą. Taip pat naudojamas ICER rodiklis, apibrėžiamas kaip dviejų galimų intervencijų sąnaudų (C_1 , C_0) skirtumas, padalytas iš jų poveikio (E_1 , E_0) skirtumo.

$$ICER = \frac{C_1 - C_0}{E_1 - E_0} \quad (1.7)$$

Galima išskirti bent 3 aktualius tyrimus iš UK ir JAV, vertinančius PD ankstyvosios intervencijos medicininį ir ekonominį efektyvumą:

1. Jungtinėje Karalystėje atliktas tyrimas parodė, kad ankstyvas PD sergančių pacientų gydymas medikamentais (dopamino agonistu arba MAO-B inhibitoriumi) yra asocijuojamas su teigiamu ekonominiu efektu. Kitas medikamentas (Rasagilinas), palyginti su standartiniu vaistu (Pramipeksoliu), per 5 metus sumažino išlaidas 18 % vienam pacientui, 25 % pailgino L-dopa

vartojimo laiką ir 10 % atitolino diskinezijos pradžią. Rasagilinas, palyginti su pramipeksoliu, taip pat padidino QALY 5 % [46].

2. JAV ekonominio efektyvumo tyrime nustatyta, kad pramipreksolį skiriant ankstyvosios stadijos PD fiksuojami geresnis rezultatai, nei skiriant L-dopa vėlyvesnės stadijos PD. Didėjantis ekonominio efektyvumo santykis buvo ICER = 42 989 JAV dolerių už QALY [46].
3. Kitas JAV atliktas tyrimas parodė, kad ankstyvajam PD skiriamas pramipeksolis, palyginti su kitomis priemonėmis, buvo reikšmingai efektyvesnis. Fiksuotas didėjantis ekonominio efektyvumo santykis ICER = 8 837 JAV dolerių už QALY pacientams, sergantiems ankstyvąja PD, ir ICER = 12 294 JAV dolerių už QALY pacientams, sergantiems pažengusia PD [46].

Literatūroje taip pat pastebima, kad net teisingai ir anksti diagnozavus ligą, ankstyvos intervencijos nauda ekonominės ir gyvenimo kokybės rodikliams nėra garantuota. Pagrindinė to priežastis – gydymosi režimo nesilaikymas.

1. Viename tyrime remiantis draudimo išmokų duomenimis buvo nustatyta, kad 61 % PD pacientų per 12 mėnesių nesilaikė gydymo režimo. Šių subjektų asmenų vidutinės medicininės išlaidos buvo gerokai didesnės (15 826 JAV dolerių ir 9 228 JAV dolerių [46].
2. Kitas JAV atliktas tyrimas atskleidė, kad patenkinamai gydymo plano besilaikančių pacientų hospitalizacijų skaičius dėl PD buvo 39 % mažesnis. Be to, su PD susijusių vaistų išrašyta 9 % daugiau, stacionarinio gydymo išlaidos buvo 47 % mažesnės, o bendros išlaidos - 18 % mažesnės. Bendros medicininės išlaidos, palyginti su gydymo plano nesilaikančiais pacientais, buvo 3 508 JAV doleriais mažesnės [46].
3. Duomenys, gauti iš 2010 m. nacionalinės valdomų priežiūros planų duomenų bazės, parodė, kad gydymo plano nesilaikančiųjų metinių hospitalizacijų, apsilankymų sveikatos priežiūros įstaigose ir bendrų medicininių išlaidų rodikliai buvo gerokai didesni (15 826 JAV doleriai, palyginti su 9 228 JAV doleriais), nepaisant mažesnių išlaidų receptiniams vaistams. Apskritai vaistų nesilaikymas buvo susijęs su 3 451 JAV dolerio metinių medicininių išlaidų padidėjimu [46].
4. Kiti 2013 m. iš JAV gauti duomenys atskleidė, kad PD sergančių pacientų kurie laikėsi gydymo plano bendros vidutinės metinės sveikatos priežiūros išlaidos buvo mažesnės nei pacientų, kurie plano nesilaikė (77 499 JAV dolerių, palyginti su 84 949 JAV doleriais; 59 286 eurai, palyginti su 64 985 eurai) [46].

Pagrindinės gydymo plano nesilaikymo priežastys yra didelis medikamentų kiekis ir griežtas, sudėtingas vartojimo režimas.

Profesionalų priežiūros laiko trūkumas, ankstyvos diagnozės priemonių nebuvimas ir polinkis nesekti gydymo plano apsunkina ne tik atskirų PD pacientų gyvenimus bet ir bendrą medicinos sistemai tenkančią finansinę apkrovą. Dėl savo mastelio PD gali būti interpretuojama kaip svarbų ekonominį svorį turinti problema. Tokią išvadą savo tyrime padarė ir **Yang W. ir kt.** [5]. Tyrimo duomenimis 2017 m. JAV buvo maždaug milijonas asmenų, kuriems diagnozuota PD. Bendra vien šios ligos sukelta ekonominė našta siekė 51,9 mlrd. dolerių. **Tinelli M. ir kt.** [46] atliktoje literatūros analizėje pateikė ir kitų šalių duomenis:

1. PD ekonominė našta Jungtinėje Karalystėje kasmet svyruoja nuo 449 mln. iki 3,3 mlrd. svarų sterlingų. Metinės išlaidos PD sergantiems pacientams Jungtinėje Karalystėje sudarė 13 804 svarus sterlingų vienam pacientui. Formalios priežiūros išlaidos sudarė 20 proc. visų išlaidų, o neformalios priežiūros išlaidos sudarė 80 proc. visos naštos.

2. Italijoje metinės tiesioginės sveikatos priežiūros išlaidos, susijusios su PD, svyravo nuo 4320 eurų lengvos stadijos iki 6175 eurų sunkios stadijos atveju. Apskaičiuota, kad vidutinės išlaidos sudaro 4808 EUR. Į šį tyrimą nebuvo įtrauktos neoficialios priežiūros ar sveikatos priežiūros išlaidos privačiame sektoriuje.
3. Suomijoje bendros metinės išlaidos, susijusios su ambulatoriškai gydomų PD pacientų liga, siekė 131 mln. dolerių, iš kurių 54,7 mln. dolerių sudarė tiesioginės išlaidos. Jos padvigubėjo kaskart didėjant ligos stadijai, o netiesioginės išlaidos tapo reikšmingesnės pažengusiose stadijose.
4. Vokietijoje ligos sunkumas, motorinės komplikacijos ir amžius turėjo įtakos PD išlaidoms. Bendros metinės išlaidos priklausomai nuo ligos stadijos svyravo nuo 18 660 iki 31 660 eurų. Nuo 2000 m. iki 2004 m. išlaidos padidėjo 25-31 %. Bendros išlaidos vienam PD sergančiam pacientui Vokietijoje sudarė 20 860 EUR ir didėjo priklausomai nuo ligos sunkumo. Tiesioginės išlaidos neproporcingai padidėjo pažengusiose ligos stadijose, o netiesioginės išlaidos išliko stabilios.
5. Rusijoje bendros metinės išlaidos vienam PD sergančiam pacientui siekė 5240 eurų, o pagrindinės išlaidas lemiančios priežastys buvo neformali priežiūra ir vaistai. Apskaičiuota, kad nacionalinės išlaidos per metus sudarė 1,1 mlrd. eurų.
6. Čekijoje bendros metinės išlaidos vienam pacientui, sergančiam PD, sudarė 11 020 EUR, iš kurių 60 % sudarė tiesioginės išlaidos, o 40 % - netiesioginės išlaidos. Nustatyta, kad išlaidas lemiantys veiksniai yra ligos sunkumas, motorinės komplikacijos, psichozė ir amžius.

1.3.2. Esencialinio tremoro ekonominė našta

Aptarti socialiniai, medicininiai ir ekonominiai PD aspektai galioja ir ET pacientams. **Dai D. ir kt.[47]** JAV atliktas tyrimas atskleidė, kad pacientams, kuriems diagnozuotas ET, patiriamos didesnės sveikatos priežiūros išlaidos palyginti su sveikais pacientais. Vidutinės bendros sveikatos priežiūros išlaidos vienam pacientui per metus dėl visų priežasčių siekė 17 560 JAV dolerių. Su ET susijusios sveikatos priežiūros išlaidos sudarė 13 proc. visų tiesioginių medicininių išlaidų. Pacientų charakteristikos, tokios kaip gretutinių ligų skaičius, taikyto gydymo tipas, psichikos sutrikimų buvimas, amžius, geografinė padėtis ir gyvenamoji vieta, buvo susijusios su padidėjusiomis sveikatos priežiūros išlaidomis. Didesnės namų ūkio pajamos buvo susijusios su didesnėmis su ET susijusiomis išlaidomis. Pažymėtina, kad invazinis gydymas, kelios gretutinės ligos ir psichikos sutrikimai buvo nustatyti kaip pagrindiniai veiksniai, lemiantys ET sergančių pacientų sveikatos priežiūros išlaidas.


Kapinos K. A. ir kt. [48] kitame JAV tyrime padarė išvadą, kad ET diagnozuoti pacientai, kurie bent kartą lankėsi pas specialistą, kasmet patiria vidutiniškai 1068 JAV papildomų tiesioginių medicininių priežiūros išlaidų, palyginti su panašaus amžiaus gavėjais, kuriems ET nebuvo diagnozuotas. Autoriai apskaičiavo, kad bendros papildomos sveikatos priežiūros išlaidos, susijusios su ET, siekia nuo 1,5 iki 5,4 mlrd. dolerių per metus.

Vetterick C ir kt. [49] studijoje apskaičiavo, kad JAV 2019 metais buvo patvirtinta 213 772 naujų ET atvejų. Galutinei diagnozei patvirtinti vidutiniškai prireikė 18 mėnesių. Dažnu atveju prieš ET diagnozę buvo diagnozuotas kitas judesių sutrikimas: nepatikslintas tremoras (31 % atvejų), kitas tremoras (8 % atvejų), Parkinsono liga (7 % atvejų) ir distonija (1 % atvejų). ET diagnozė paprastai nustatoma praėjus maždaug 1,4-1,8 metų nuo ankstesnės diagnozės nustatymo.

Gupta H. V. ir kt. [39] siekdami išsiaiškinti kiek ET pacientų sulaukia efektyvaus profesionalų teikiamo gydymo atliko ET pacientų internetinės apklausos analizę. Autorių išvados teigia, kad beveik

30% pacientų nesulaukia profesionalų priežiūros. Tik 65 proc. korespondentų diagnozę nustatė neurologas. Tik 42 proc. pacientų sveikatą prižiūri neurologas, 26 proc. - šeimos gydytojas.

Kitų šalių situacijas analizuojančių tyrimų rasti nepavyko. Atsižvelgiant į tai, kad apytikslis ET paplitimas JAV yra vienas didžiausių pasaulyje (~5.5 % bendros populiacijos), galima tikėtis kad problemų mastelis likusiose šalyse yra mažesnis arba panašus [50].



11 pav. Apytikslis ET paplitimas skirtingose šalyse [50]

1.3.3. Ekonominės naštos mažinimas

Apibendrintai, PD ir ET sukelia didelę naštą ekonomikai. Tiek ET, tiek PD atveju ją galima sumažinti didinant pacientų kontaktą su profesionaliais gydytojais, mažinant klaidingų diagnozių skaičių. PD atveju išskiriami papildomi lemiami veiksniai: ankstyva diagnozė ir gydymo programos laikymasis. Problematiką galima spręsti didinant neurologų ir judesio sutrikimų profesionalų prieinamumą: jų skaičių, fizinį pasiekiamumą, mažinant finansinę priežiūros naštą pacientams kompensacijų ar kitais metodais. Tačiau, atsižvelgiant į aukštus profesionalų rengimo kaštus ir į bendrą naštą, kurią PD ir ET jau dabar sukuria ekonomikai, tai nebūtinai tvarus sprendimas. Būtina ieškoti sprendimų, kurie būtų grįsti visai kita perspektyva - mažintų, o ne didintų specialisto svarbą gydymo eigoje. Toks sprendimas galėtų būti diagnozės ir vertinimo funkcijas atliekančios kompiuterizuotos priemonės.

Tiek ET tiek PD išskirtinis bruožas yra rankų tremoras. Juo grindžiama diagnozė, ligos progreso vertinimas. Dėl šios priežasties, ekonominę naštą mažintų priemonė, suteikianti galimybę įvertinti tremoro kilmę (diagnozė) ir eigą (kvantavimas). Tačiau, dėl finansinių ir socialinių rinkos poreikių priemonė turi atitikti šias sąlygas:

1. Nereikalausti papildomos įrangos;
2. Nereikalausti specialių apmokymų ar žinių;
3. Pasižymėti vidutiniam neurologui ar judėjimo sutrikimų specialistui prilygstančiu tikslumu;
4. Būti techniškai prieinama visai populiacijai;

Visus išvardytus reikalavimus tenkintų vien populiarių išmaniųjų įrenginių duomenimis grįsta vertinimo priemonė su paprastu naudojimo principu ir tradicinėmis vertinimo priemonėmis prilygstančiu tikslumu. Tokią priemonę realizavus mobiliosios aplikacijos išmaniesiems telefonams ir planšetėms pavidalu, kokybiškos ligos diagnozės ir progresijos sekimo funkcijos būtų prieinamos tiek pacientams, tiek mažiau šioje srityje specializuotiems pirmosios sveikatos priežiūros gydytojams.

Tai mažintų įvairių sveikatos rodiklių disbalansą tarp asmenų, kuriems suteikiamos kokybiškos neurologų paslaugos ir asmenų, kurie gydosi patys, nesigildo arba lankosi pas šeimos gydytojus (**3 pav.**). Ekonominė tokio sprendimo nauda tiesiogiai priklausytų nuo priemonės savybių ir gali būti apskaičiuojama remiantis nagrinėtų tyrimų duomenimis [5, 37, 38].

1.4. Literatūros apžvalgos apibendrinimas

Rankų drebinimo vertinimui galima naudoti kone kiekvieną populiariausiuose išmaniuosiuose įrenginiuose integruotą jutiklį: akcelerometrą, giroskopą, lietimo jutiklį, video kamerą. **Wang W. Ir kt.** [27] atliko demonstraciją ir įrodė, kad galima naudoti net mikrofoną. Literatūroje rasti sprendimai savo savybėmis lenkia tradicinius tremoro kvantavimo ar diagnozės metodus. Tačiau, rinkoje iki pat šiol nėra prigijusių sprendimų.

Vertinimo priemonių adaptacijai gali trukdyti įvairūs aspektai. Pirmiausia, daugelis išnagrinėtų vertinimo priemonių reikalauja papildomos techninės įrangos, tokios kaip telefono įmaitės, išmaniojo rašiklio planšetės, specializuotų medicininių įrenginių. Bet kokia papildoma techninė įranga padidina PD ir ET pacientams arba klinikinėms įstaigoms tenkamą finansinę naštą. Be to, būtina turėti prieigą prie tokios įrangos pirkimo kanalų, žinoti kaip ja naudotis. Tai bereikalingos komplikacijos potencialiai lemiančios sudėtingą prigijimą rinkoje. Visgi vienas didžiausių tradicinių vertinimo metodų pliusų yra tai, kad jis praktiškai nereikalauja nieko papildomo, tik profesionalo dėmesio.

Kiti įtakos veiksniai yra patikimumas, tikslumas ir prieinamumas. Apžvelgus galimą socialinę – ekonominę tremoro vertinimo įtaką, pastebėta, kad visus poreikius atitiktų išmaniųjų įrenginių duomenimis grįsta vertinimo priemonė, kuri galėtų būti realizuota mobiliosios aplikacijos pavidalu išmaniesiems telefonams ir planšetėms. Tokia priemonė galėtų būti geriausias vertinimo sprendimas rinkoje (**1 lentelė**).

1 lentelė. Įvairių tremoro vertinimo priemonių palyginimas. Skalė 1 – blogiausia, 3 – geriausia.

Ypatybė	Tradicinės priemonės	Specialus įrenginiai	Išmanieji įrenginiai
Tikslumas	1	3	3
Patikimumas	1	3	3
Kaina	3	1	3
Prieinamumas	2	1	3
Viso	8	6	12

Šio darbo metu ir siekiama sukurti visus analizuotus klinikinius ir praktinius poreikius išpildančią priemonę ir kiekybiškai įvertinti jos ekonominį efektą. Darbo tikslų realizavimas vykdomas šių žingsnių seka:

- Efektyvesnės vertinimo priemonės duomenų rinkimo koncepto kūrimas.
- Tremoro kvantavimo modelio kūrimas ir vertinimas – regresijos užduotis.
- Tremoro diagnozės modelio kūrimas ir vertinimas – klasifikacijos užduotis.
- Potencialaus ekonominio efekto įvertinimas.

2. Metodai

2.1. Duomenų rinkimo konceptas

2.1.1. Jutiklių pasirinkimas

Tremorą galima sėkmingai pamatuoti bet kokiais populiariausių išmaniųjų įrenginių jutikliais, tačiau atsižvelgiant į literatūros analizėje padarytas išvagas, verta apsiriboti 2 jutikliais: lietimui jutikliu (lietumui jautriu ekranu) ir akselerometru. Toks sprendimas priimtas remiantis keliomis priežastimis.

Pirmiausia, tiek akselerometro, tiek lietimui jutiklio duomenys yra tiesiogiai susiję su rankos judesiais. Jų signalo – triukšmo santykis teoriškai turėtų būti mažiausias. Palyginimui, vaizdo jutikliai (kameros) ar mikrofonai fiksuoja daug didesnę kiekį nenaudingos informacijos, pvz. kamera fiksuoja ne tik rankos judesius, bet ir aplinkinį vaizdą, šėšėlius. Tokiu atveju signalo-triukšmo santykis yra mažesnis - aplinka daro neigiamą poveikį, kurio, net ir laboratorinėmis sąlygomis, gali būti sunku išvengti. Puikus pavyzdys yra Archimedo spiralių kontūro aiškumo palyginimas (3 ir 2 pav).

Antra, pasirinktas jutiklis įtakoja duomenų apdorojimo sudėtingumo lygį. Vaizdo ir garso duomenys yra didelės apimties. Jų apdorojimo algoritmai tradiciškai pasižymi didesniu kompleksiskumu. Modernūs sprendimai dažnai būna remti giliuoju mokymusi. Dirbtiniai neuroniniai tinklai gali turėti milijonus ar net milijardus parametrų. Tai aktualu, nes išmanieji įrenginiai, turi skaičiavimo ir talpos resursų limitą. Didžiuliai algoritmai, pvz. CNN su 500 milijonų parametrų, negali praktiškai būti talpinami ar apdorojami išmaniuosiuose įrenginiuose. Logiškas sprendimas – debesų technologijos panaudojimas, tačiau tai įtakotų pačio sprendimo sudėtingumą, prieinamumą ir kaštus. Kadangi sprendimas turi būti finansiškai optimalus, algoritmai ir duomenys, reikalaujantys didžiulių resursų yra atmesti.

Trečia, literatūros analizėje padaryta išvada, kad tiek akselerometras, tiek lietimui jutiklis, yra pakankami tiksliai diagnozavimui ar kvantavimui. Jutiklių suliejimas galėtų vertinimo kokybę dar labiau pagerinti. Nuspręsta, kad tik vienu iš jutiklių apsiriboti neverta dėl aukšto ligų neapibrėžtumo ir simptomų variacijos. Judesiai, kuriuos gali pamatuoti abu jutikliai yra labai skirtingi – tai gali padidinti vertinimo modelių bendrinimo (ang. generalization) galimybes.

Galiausiai, abiejų jutiklių normalus diskretizavimo dažnis yra labai artimas reikalingam dažniui. Pagal Naikvisto teoremą, duomenų diskretizavimo dažnis f_d turi būti dvigubai didesnis nei didžiausiais naudingas dažnis f_{max} [29].

$$f_d > 2f_{max} \quad (2.1)$$

Tiriant rankų tremorą, didžiausias pastebimas dažnis yra ne didesnis nei 18 Hz [27]. Vadinasi, šiame kontekste Naikvisto dažnis yra lygus $f_{max} = 36$ Hz [14]. Tipiniai naujuose įrenginiuose integruoti lietimui jautrūs ekranai veikia bent 60 Hz dažniu. Integruoti trijų ašių akselerometrai dirba poros šimtų, tačiau gali pasiekti ir 500 Hz dažnį [26], vadinasi Naikvisto sąlyga yra tenkinama. Naudojant kitus jutiklius, pvz. mikrofoną, kurio diskretizavimo dažnis gali siekti dešimtis tūkstančių hercų, galimai reikėtų papildomų duomenų ruošimo, filtravimo ir kompresijos procedūrų.

2.1.2. Išmaniųjų įrenginių ir programinės įrangos pasirinkimas

Eurostat duomenimis 2021 metais vidutiniškai 81.48% EU gyventojų interneto naršymui naudojo mobiliuosius telefonus, 29.54% planšetinius kompiuterius ir 25.53% kitus išmanius įrenginius: laikrodžius, žiedus, televizorius ir t.t.[40]. Siekiant didžiausio prieinamumo ir mažiausios finansinės naštos, vertinimo įrankis turi būti pritaikytas naudoti mobiliuosiuose telefonuose ir planšetiniuose kompiuteriuose. Tokiu atveju atskiros techninės įrangos įsigijimas ir apmokymas naudotis yra nereikalingas. Nuspręsta įrankį kurti mobiliosios programėlės iOS ir Android operacinėms sistemoms pavidalu.

Programėlės kūrimas neįeina į šio darbo apibrėžimo sritį. Ji sukurta multi platforminiu programinės įrangos kūrimo įrankiu Flutter ir vardu SteadyHands patalpinta nemokamam parsisiuntimui Google Play (Android) ir App Store (iOS) programėlių platinimo kanaluose. Darbe apsiribojama tik matematinių modelių ir algoritmų, programėlės surinktiems duomenims interpretuoti, kūrimu. Žemiau pateikta keletas detalių, aktualių darbo apibrėžimo sričiai:


- Lietimo jutiklis dirba viso ekrano plote didžiausiu leidžiamu diskretizavimo dažniu.
- Akselerometras įrašinėja duomenis 3 ašimis (X, Y, Z) maksimaliu diskretizavimo dažniu.
- Įrašinėjant saugomas laiko žymuo.
- Piešimo lango ir figūrų, pvz. Archimedo spiralės, dydis nekinta nuo ekrano dimensijų.

2.1.3. Matavimo metodologija

Lietimo sensorių nuspręsta panaudoti jau patikrintu ir literatūros analizėje aptartu Archimedo spiralių piešimo metodu [35, 36]. Dėl aukšto tremoro neapibrėžtumo ir variacijos laike, matavimai negali trukti per trumpai. Atsižvelgiant į tai, kad Archimedo spiralę nupiešti trunka tik kelias sekundes, nuspręsta vietoje vienos figūros kiekvienam matavimui naudoti 3: sinusoidę, apskritimą ir Archimedo spiralę. Tai prailgins laiko, kuriame matuojamas tremoras, langą. Taip pat padidins naudingos informacijos kiekį – skirtingos figūros reikalauja atlikti skirtingus judesius. Bendra tremoro vertinimo lietimui jutikliu metodologija linijine seka išdėstoma taip:

1. Ant lygaus paviršiaus padedamas išmanusis įrenginys su įjungta programėle.
2. Pacientas pakelia ranką ir naudodamas rodomąjį pirštą paspaudžia pradėjimo mygtuką.
3. Ekrane pasirodo mėlynos spalvos etaloninė sinusoidės figūra.
4. Pacientas rodomuoju pirštu sekdamas etaloninės figūros kontūrą bando kuo tiksliau nupiešti tokią pat figūrą.
5. Užbaigus piešimą pacientas spaudžia mygtuką „kitas“. Pasirodo apskritimo formos etaloninė figūra ir procedūra kartojama.
6. Užbaigus piešimą pacientas spaudžia mygtuką „kitas“. Pasirodo Archimedo spiralės formos etaloninė figūra ir procedūra kartojama.
7. Užbaigus piešimą pacientas spaudžia mygtuką „kitas“. Duomenys išsaugomi ir analizuojami.

Visų figūrų piešimo procesas mobiliojoje aplikacijoje pavaizduotos **12 pav.** Piešiant figūrą pacientui leidžiama ištrinti užfiksuotus duomenis ir pradėti iš naujo bet kuriuo metu.



12 pav. Mobiliosios programėlės SteadyHands piešimo langai

Tremoro vertinimo akselerometro jutikliu metodologija grįsta tipinėmis literatūros analizėje aptartomis metodologijomis, kai pacientas duomenų įrašinėjimo metu tyčia atlieka sutartinį veiksmą ranka. Literatūroje galima rasti teiginių, kad vieni veiksmai ar pozicijos yra tinkamesni vertinimui už kitus [13]. Tačiau, siekiant naudotimosi paprastumo, nuspręsti naudoti standartinę pozicinę tremorą iššaukiančią poziciją – ištiestą ranką. Visa vertinimo metodologija linijine seka išdėstoma taip:

1. Išmanusis įrenginys paimamas į paciento ranką ir ištiesiamas priešais save (**5 pav.**).
2. Pacientas paspaudžia pradėjimo mygtuką.
3. Pasirodo 30 sekundžių laikmatis. Pacientas stengiasi nedaryti jokių staigių judesių kol baigsis matavimo procesas.
4. Laikmatis pasiekia 0 sekundžių. Matavimas baigtas, duomenys išsaugomi.



13 pav. Mobiliosios programėlės SteadyHands tremoro vertinimas akselerometru

Bet kokia pozicija, reikalaujanti laikyti išmanųjį įrenginį rankoje ar naudotis juo iššaukia veiksmo tremorą, todėl sukurta metodologija ramybės tremoro matuoti negali. Tai prieštarauja tradicinių vertinimo priemonių principams, kurie grindžiami idėja, kad PD pacientai asocijuojami su ramybės tremoru, o ET – su veiksmo tremoru. Remiantis literatūros analize, moderniais metodais tikslų vertinimą galima realizuoti ir nematuojant ramybės tremoro [36]. Dėl šios priežasties sukurta metodologija yra inovatyvi, tačiau neprieštarauja mokslinėje literatūroje pavišintais faktais.

2.2. Duomenų rinkinys

Duomenų rinkinys suskirstytas į 2 dalis: diagnozės ir kvantavimo. Diagnozės užduočiai duomenys surinkti atlikus tyrimą su 15 ET, 10 PD ir 15 CP savanorių grupių. Kiekvienas savanoris buvo paprašytas mobiliąja programėle 2 kartus atlikti tremoro vertinimą. Vienas vertinimas susidėjo iš abiejų metodų: akselerometro (rankos tiesimo) ir lietimio jutiklio (figūrų piešimo). Laiko skirtumas tarp matavimų siekė bent valandą. Keli PD pacientai neatliko antro matavimo, todėl PD grupėje fiksuota tik 19 pavyzdžių. CP grupėje pavyzdžių kiekis siekia 30 (po 2 matavimus iš 15 žmonių). ET grupės pavyzdžių kiekis irgi lygus 30. Bendras diagnozės imties dydis: 79 pavyzdžiai. Fiksuotas 62 metų amžiaus vidurkis. ET ir PD ligos subjektams diagnozuotos seniau nei 3 metai.


Kvantavimo duomenų rinkinys sudarytas savanoriams naudojantis mobiliąja programėle ir kiekybiškai įsivertinant tremoro stiprumą skalėje 0 – prasta savijauta / didžiausias tremoras, 10 – gera savijauta / nėra tremoro. Tokia skalė pasirinkta dėl jos paprastumo ir intuityvumo. Vienas ET savanoris atliko 211 matavimų 4 mėnesių eigoje. Po papildomus 50 matavimų atliko ir 3 CP savanoriai, simuliuojantys įvairaus intensyvumo tremorą. Tokie CP duomenys gali būti naudojami kaip duomenų augmentacijos alternatyva kvantavimo užduočiai. Tai įrodyta literatūros analizėje aptartame tyrime [30]. Į rinkinį įtraukti ir diagnozės rinkinio pacientų pavyzdžiai (30 CP, 30 ET, 19 PD). Viso kvantavimo užduoties imtį sudaro 440 pavyzdžiai iš akselerometro ir lietimio jutiklių duomenų porų.

Nuspręsta diagnozės modelių treniravimui nenaudoti kvantavimo užduočiai skirtų pavyzdžių. Dėl didelės vieno ET paciento įtakos gali pasireikšti perteklinis persimokymas. Be to, diagnozės imtyje jau dominuoja ET ir CP. Norint sukurti diagnozės modelį su aukštu bendrinimo lygiu naudojama imtis negali atspindėti vienos žmogaus tremoro charakteristikų.

2 lentelė. Duomenų rinkinys. Čia T – tik testavimui naudojami duomenys.

Kvantavimo rinkinys	Diagnozės rinkinys
ET (241)	ET (30)
PD (19)	PD (19)
CP (180)	CP (30)
Viso (440)	Viso (79)

Tremoro įverčio reikšmių pasiskirstymas pavaizduotas **14 pav.** grafike. Pastebimas vidutinios disbalansas. Dominuoja reikšmės 5 – 8. Palyginimui, imtyje fiksuojama maždaug trigubai mažiau duomenų ties 1 – 3 ruožu.



14 pav. Tremoro įverčio reikšmių pasiskirstymas


2.3. Duomenų ruošimas

2.3.1. Pirminis apdorojimas

Akselerometro duomenys sudaryti iš 4 dimensijų matricos: pagreičio 3 ašimis $x(n)$, $y(n)$, $z(n)$ ir laiko $t(n)$. Kadangi pagreičio duomenyse atsispindi gravitacija, signale visada pastebima $\sim 9.8 \text{ m/s}^2$ pradinė dedamoji. Ji, priklausomai nuo išmaniojo įrenginio orientacijos žemės atžvilgiu, yra pasiskirsčiusi tarp visų 3 ašių. Ta įtakoja tiesiogiai skaičiuojamus parametrus, pvz. vidurkį.

$$\mu = \frac{1}{n} \sum_{i=1}^n a(n) \geq \sim 9.8 \frac{m}{s^2} \quad (2.2)$$

Gravitacijos įtaka atsispindi ir surinktuose duomenyse (**15 pav.**). Pagreičio galia ties žemais dažnių ruožais gali būti įtakojama ir tyčiniaisiais rankų judesiais, pvz. lėtu telefono sukimu. Dėl šių priežasčių, žemesnį nei 1 Hz dažnio pagreičio signalą galima interpretuoti kaip triukšmą skaičiuojant spektrines savybes. Kadangi gravitacijos pagreitis yra konstanta, skaičiuojant laiko savybes, tokias kaip vidutinis pagreitis, gravitacijos įtaką galima tiesiog ignoruoti.



15 pav. Akselerometro pagreičio duomenys 3 ašyse (ET) (mėlyna, žalia, geltona: Z, Y, X ašys)

Spektrinės savybės skaičiuojamos naudojant FFT ir spektrogramas, dėl šios priežasties duomenys paruošiami spektrinei analizei. Pirmiausia, signalo ilgis sutrumpinamas iki $N = 1024$ reikšmių. Akselerometro diskretizavimo dažnis $f_d = 36$ Hz. Renkant duomenis $t = 30$ sekundžių fiksuojamas $N_{30s} = 1080$ ilgio pagreičio duomenų vektorius.

$$N_{30s} = tN_{30s} = 36 * 30 = 1080 \quad (2.3)$$

Artimiausias 2 kartotinis N_{30s} yra $N = 1024$. Lieka $N_s = 56$ vnt. arba $t_s \approx 1.6$ sek. nenaudojamų duomenų. Duomenų kiekio N_s pašalinimas iš duomenų pradžios nėra prarasta naudinga informacija. Matavimų pradžioje pastebimas didelis triukšmas. Jis gali kilti dėl tyčinių judesių, vartotojui dar ruošiantis matavimo pozai ar per anksti pradėjus duomenų fiksavimą. Tai pastebima ir **15 pav.** Likęs naudingas matavimo laikas $t_N \approx 28.4$ sek. Jei fiksuojama, kad diskretizavimo dažnis duomenyse nukrypo nuo f_d reikšmės, nukirpus signalo pradžią vykdoma diskretizavimo dažnio keitimo procedūra (žiūrėti toliau).


$$N = 2^{10} = 1024 \quad (2.4)$$

$$N_s = N_{30s} - N = 1028 - 1024 = 56 \quad (2.5)$$

$$t_s = \frac{N_s}{f_d} = \frac{56}{36} \approx 1.6 \text{ s.} \quad (2.6)$$

$$t_N = \frac{N}{f_d} = \frac{1024}{36} \approx 28.4 \text{ s.} \quad (2.7)$$


Reikalavimas, kad signalo ilgis būtų 2 kartotinis, kyla dėl FFT konstrukcijoje naudojamos "radix-2" dekompozicijos metodo. Jis veikia apdorojamo signalo duomenų matricos diskretinės Furjė transformacijos (DFT) skaičiavimo matricas padalijus į mažesnius $N_{DFT} = 2$ dydžio DFT. Kiekviename FFT algoritmo etape signalas padalijamas į lyginio ir nelyginio indekso imties taškus. Tada kiekvieno segmento DFT apskaičiuojamas atskirai. Šie N_{DFT} dydžio transformacijos rezultatai sujungiami į galutinę DFT, kitaip tariant, bendrą FFT rezultatą – signalą dažnių srities pavidale. Siekiant užtikrinti efektyvų „radix-2“ metodu remto FFT algoritmo vykdymą, signalo ilgiu pasirenkamas 2 kartotinis (2, 4, 8, 16, 32 ir t. t.). Jei N neatitinka 2 kartotinio, radix-2 algoritmas negali rekursyviai dalinti signalo pusiau, todėl negali būti taikomas [42, 43].



16 pav. Spektrinio nuotėkio iliustracija [41]

Kai signalas analizuojamas naudojant FFT, netiesiogiai daroma prielaida, kad signalas yra periodinis N ribose. Tačiau signalai dažnai būna baigtiniai, jų galiniuose taškuose būna nutrūkimų. Tai pastebimą ir **15 pav.**– signalo pradžia ir pabaiga yra skirtingose vertikaliosios ašies vietose, todėl sujungus signalo galus būtų fiksuojamas staigus pakitimas. Dėl bet kokių staigių pakitimų atsiranda spektrinis nutekėjimas - signalo energijos sklaida iš jo tikrųjų dažnių komponentių į greta esančius ruožus [29, 41]. Šis reiškinys suglotnina arba išskaido spektrą, todėl sunku tiksliai nustatyti tikrąsias signalo komponentių amplitudes ir dažnius – sumažinamas signalo ir triukšmo santykis.

Siekiant sumažinti spektrinį nutekėjimą, prieš taikant FFT signalui taikomos langų funkcijos, tolygiai siaurinančios signalo kraštus link nulio, panaikindama staigius signalo šuolius ir veiksmingai slopindama spektrinį nutekėjimą. Taikant langų funkcijas formuojamas signalas su tolygiu apvalkalu. Žemiau pateiktame paveikslėlyje pateiktas **17 pav.** vaizduotas signalas jam pritaikius „Kaiser 6“ (viršuje) ir „Hanning“ (apačioje) langų funkcijas.



17 pav. ET tremoro pagreičio signalas pritaikius lango funkcijas. Viršuje – „Kaiser $\beta=5$ “, apačioje – „Hanning“. Čia mėlyna, žalia, geltona- atitinkamai Z, Y, X koordinatės ašys

Kiekviena langų funkcija pasižymi skirtingomis savybėmis, kurių pasirinkimas priklauso nuo konkrečių analizės reikalavimų. **Heinzel, G** ir kt. [29] aiškiai išdėstė populiariausius langus ir kompromisus, tenkančius priimti renkantis juos. Šiame darbe spektrinėms savybėms skaičiuoti pasirinktas „Kaiser“ langas su beta parametru $\beta = 5$. Jo pagrindinės dažnių skilties plotis ties -3 dB (~ -0.707 karto silpninimo) riba yra lygus $BW_{-3dB} = 2.1553$ dažnio komponentės k . Komponentės k dydis nusakomas dažnio raiška f_{res} .

$$f_{res} = \frac{f_d}{N} = \frac{36}{1024} \approx 0.035 \text{ Hz} \quad (2.8)$$


Vadinasi dažniu išreikštą BW_{-3dB} galime interpretuoti kaip -3 dB lygio neapibrėžtumą dažnio srities f_{BW-3dB} .

$$f_{BW-3dB} = f_{res} BW_{-3dB} \approx 0.076 \text{ Hz} \quad (2.9)$$

Didžiausia galima sinusoidinio signalo amplitudės įvertinimo paklaida vieno dažnio ribose yra lygi $e_{max} = -0.6403 \text{ dB} \approx -7.1061 \%$. Pasirinkimas grindžiamas tuo, kad tremoro amplitudė yra labai svarbus veiksnys tremoro kvantavimui, todėl logiška paaukoti dažnių neapibrėžtumo, dėl mažesnės amplitudės paklaidos. Kitaip tariant, tremoro kvantavimui svarbesnis BW_{-3dB} nei e_{max} . Plokščiojo viršaus langų nuspręsta nesirinkti, nes su dažniu susijusios ypatybės gali būti svarbios diagnozės užduočiai – visiškai paaukoti BW_{-3dB} negalima.

18 pav. pateiktas **15 pav.**, **16 pav.** ir **17 pav.** pavaizduotas signalas dažniu srityje, susumavus visas ašis (1). Horizontalioji ašis gaunama pagal žemiau pateiktą formulę.

$$f_n = \frac{f_{res}n}{2}, \text{ kai } n = 0, 1, 2, 3, \dots, N - 1 \quad (2.10)$$




18 pav. ET tremoro pagreičio suminis signalas dažnių srityje. Viršuje – „Kaiser $\beta = 5$ “, apačioje – be lango

Spektrogramos skaičiuojama padalinant $N = 1024$ signalą į $N_s = 128$ ilgio dalis su 50% persidengimais. Vadinasi, viena spektrograma bus sudaryta iš $K = 14$ atskirų galios spektrų t_N laiko tarpe.

$$K = \frac{2N}{N_s} - 2 = \frac{2 \cdot 1024}{128} - 2 = 14 \quad (2.11)$$

Persidengimas yra reikalingas dėl lango funkcijoms būdingo galų susiaurėjimo. Atliekant FFT visame N be persidengimo, informacija ties lango funkcijos kraštais būtų prarasta (**19 pav.**). Kraštus perdengiant tarp skirtingų N dalių informacijos praradimas yra kompensuojamas [42, 43].



19 pav. Lango funkcijos taikymas be persidengimo (viršuje) ir su persidengimu (apačioje) [41]

Optimaliomis perdengimo savybėmis pasižymi „Hanning“ langas su 50% persidengimu. Jį nuspręsta naudoti skaičiuojant spektrogramas [29]. „Hanning“, palyginus su „Kaiser $\beta=5$ “, turi daug mažesnę $BW_{-3dB} = 1.4382$, tačiau dvigubai didesnę $e_{max} = -1.4236 \text{ dB} = -15.1174 \%$. Žemiau pateikta „Hanning“ lango koeficientų skaičiavimo funkcija $\omega_h(n)$. Čia n – signalo indeksas sekoje nuo 0 iki N , kai N – signalo ilgis.

$$\omega_h(n) = \frac{1}{2} \left(1 - \cos \left(2\pi \frac{n}{N} \right) \right), 0 \leq n \leq N - 1 \quad (2.12)$$


„Kaiser“ lango koeficientų skaičiavimo funkcija yra šiek tiek sudėtingesnė. Ji pateikta žemiau (signalų ilgis = N). Čia β - koeficientas (darbe $\beta = 5$).

$$\omega_k(n) = \frac{I_0 \left(\pi \beta \sqrt{1 - \left(\frac{2n}{N} - 1 \right)^2} \right)}{I_0(\pi \beta)}, 0 \leq n \leq N - 1 \quad (2.13)$$

I_0 yra nulinės eilės modifikuota pirmojo tipo Beselio funkcija [29].

$$I_0(x) = \sum_{k=0}^{\infty} \left(\frac{\left(\frac{x}{2} \right)^k}{k!} \right)^2 \quad (2.14)$$

Ankstesniuose grafikuose nagrinėtas signalas pavaizduotas spektrogramos pavidalu (**20 pav.**). Čia amplitudė išreikšta decibelais. Grafikas atitinka **18 pav.** rodmenis – didžiausia amplitudė fiksuojama ties ~6 Hz, kitos dedamosios išreikštos nežymiai.




20 pav. ET tremoro pagreičio suminis signalas spektrogramos pavidalu

Pasirinktas diskretizavimo dažnis $F_d = 36$ Hz, todėl laiko tarpas tarp skirtingų duomenų taškų turi būti lygus periodui T_d .

$$T_d = \frac{1}{f_d} = \frac{1}{36} \approx 28 \text{ ms} \quad (2.15)$$


Išmanių įrenginių operacinės sistemos Android ir iOS nesuteikia galimybės rinkti duomenų fiksuotu diskretizavimo dažniu. Jis visada varijuoja ir vidutiniškai yra didesnis nei užsibrėžtas F_d . Pavyzdžiui, akcelerometro duomenų diskretizavimo periodo T_d standartinis nuokrypis vidutiniškai lygus ~1.8 ms. Kai kuriais atvejais pasiekia 3.5 ms (**21 pav.**). Vidutinis lietimio jutiklio $\sigma_{Td} = 1.7$ ms.



21 pav. Akselerometro duomenų f_d ir jo standartinis nuokrypio pasiskirstymas

FFT algoritmo naudojimas reikalauja tolygaus diskretizavimo periodo. Dėl šios priežasties, duomenims pritaikoma diskretizavimo dažnio keitimo procedūra. Ji susideda iš kelių etapų.


Pirmiausia, signalo diskretizavimo dažnis yra padidinamas iki daug aukštesnio F_d kartotinio dažnio. Duomenų vektorius yra prailginamas, o trūkstamos vietos interpoliuojamos poli-faziniu filtru, tuo pačiu metu atsisakant nereikalingų dažnių komponentų. Tada, gautam vektoriui taikoma poli-fazinė decimacija. Jo diskretizavimo dažnis sumažinamas iki F_d . Procedūra pavaizduota **22 pav.** Čia juodi taškai – originalus lietimo sensoriaus duomenų vektorius, pilki taškai – aukštesnio F_d vektorius su tolygiai pasiskirsčiusiu periodu, mėlyna – vektorius su tolygiu diskretizavimo periodu ir reikiamu F_d (36 Hz).



22 pav. Poli-faziniu filtravimu grįstas diskretizavimo dažnio keitimas.

Lietimo jutiklio duomenys apdorojami analogišku procesu. Jie sudaryti iš 3 dimensijų matricos: koordinatinių 2 ašimis $x(n)$, $y(n)$ ir laiko $t(n)$. Kadangi piešimo užduotis sudaryta iš 3 skirtingų figūrų, prieš atliekant skaičiavimus koordinatės yra sudedamos į vieną ilgesnį vektorių.

Apibendrintai, duomenų apdorojimo schema pavaizduota **23 pav.**



23 pav. Duomenų apdorojimo schema

2.3.2. Savybių vektoriaus sudarymas

Savybių vektorius sudaromas grindžiantis standartine virpesių analizės praktika ir literatūros analizėje apžvelgtais tyrimais. Savybių vektorių iš viso sudaro 119 skirtingų kintamųjų. Jie išvardyti **1 priede**. Apibendrintai jį galima išskirstyti į kelias grupes. Jos, kartu su susijusių savybių trumpiniais, išvardytos žemiau:

Spektrinės savybės skaičiuojamos dažnių srityje iš FFT gautos dažnių-galios kreivės. Literatūros analizė giežtos tremoro vertinimui tinkamos dažnių juostos neatskleidė, todėl kai kurios savybės skaičiuojamos 1-18 Hz, 3- 12Hz, 3 -16 Hz ir 4 – 8 Hz dažnių juostose. Į spektrinių savybių grupę įeina:

- Bendra galia (pwr)
- Aukščiausios viršūnės galia (pwr.peak)
- Pirmosios harmonikos galia (pwr.h)
- Vidutinė galia (pwr.mean)
- Galios mediana (pwr.median)
- Galios standartinis nuokrypis (pwr.std)
- Galios entropija (pwr.ent)
- Kosinuso panašumas tarp skirtingų koordinačių ašių spektrų (pwr.cos)
- Dispersija (disp)
- Santykis tarp tremoro dažnių spektro galios (pvz. 3-12 Hz) ir galios, žemesniame dažnių ruože iki nulio (pvz. 0 – 3 Hz) (clarity).
- Aukščiausios viršūnės dažnis (f.peak)
- Centrinis dažnis (f.c)
- Pirmosios harmonikos dažnis (f.h.)

Tam tikros savybės skaičiuojamos ir logaritminiame mastelyje. Prie savybių trumpinio tokiu atveju pridėtas kodas (log).

Laiko savybės skaičiuojamos laiko srityje. Dažniausiai iš koordinačių sumos signalo.

- Vidurkis (mean)
- Standartinis nuokrypis (std)
- Mediana (median)
- Maksimali įgauta reikšmė (max)
- 5 didžiausių reikšmių suma (max.top5)
- 38 didžiausių reikšmių suma (top.fd)
- Išvestinės didžiausia reikšmė (max.diff)
- Išvestinės vidurkis (mean.diff)
- 5 didžiausių išvestinės reikšmių suma (max.top5.diff)
- Pearsono koreliacija tarp ašių (cor.xy ir t.t.)
- Pearsono koreliacijos vidurkis (cor.mean)
- Suma (sum)
- Diferencialo suma (sum.diff)

Trumpojo laiko spektrinės savybės skaičiuojamos iš spektrogramos duomenų. Į jų apibrėžimo sritį įeina dauguma spektrinių ir laikinių savybių ir jų junginių. Savybių sąrašė spektrinės savybės žymimos pridėdant trumpinį (spc).

2.4. Vertinimo modeliai

Kvantavimo užduotis gali būti interpretuota kaip regresijos užduotis, kurios priklausomas kintamasis yra įvertis skalėje 0-10, o nepriklausomi kintamieji – visos apskaičiuotos savybės. Diagnozės užduotis gali būti interpretuota kaip klasifikavimo užduotis su 3 klasėmis: CP, ET, PD.

Nors egzistuoja platus spektras regresijos ir klasifikavimo algoritmų, šio darbo kontekste pasirinkti ekstremalaus gradiento stiprinimo XGBoost (XGB) ir daugiasluoksnio perceptrono (MLP). Jie yra labai stiprūs netiesinių ryšių modeliavime daugiamatėje erdvėje. Galimas taikymas tiek regresijai, tiek klasifikavimui.

2.4.1. XGBoost

XGBoost (XGB) yra populiarus ir galingas algoritmas, skirtas prižiūrimo mokymosi (*ang. supervised learning*) užduotims, įskaitant regresiją ir klasifikavimą. Metodas ypatingai tiksliai veikia dirbant su struktūrizuotais, lentelių tipo duomenimis. Jo veikimo principas grįstas daugelio silpnų modelių kūrimu stiprinimo principu (*ang. boosting*). Stiprinimas - tai ansamblinio mokymosi metodas, kuriuo sujungiamas įvairus kiekis silpnų modelių, pvz. sprendimų medžių. Treniravimo procese silpnieji modeliai yra kuriami eilės tvarka, naujesniame modelyje daugiausia dėmesio skiriant mokymuisi iš ankstesnių modelių liekanų (faktinių ir prognozuojamų verčių skirtumų). Galutinė prognozė gaunama apibendrinant visų atskirų modelių prognozes. XGB naudoja gradientu pagrįstą optimizavimo algoritmą, kuriuo nustatyto svorius, priskiriamus kiekvienam silpnam modeliui per stiprinimo procesą, optimizuojant iš anksto nustatytą tikslo funkciją. Tai leidžia veiksmingai tvarkyti sudėtingus duomenų požymių ryšius ir sąveikas.

XGB pasižymi dideliu jautrių hiperparametrų skaičiumi. Norint išgauti geriausius įmanomus rezultatus, juos būtina derinti. Pagrindiniai hiperparametrai ir jų galimos reikšmės yra:

1. Dalinė imtis („SubSample“). Kiekvienas medis gauna tik tam tikrą procentinę mokymui skirtos imties dalį. Hiperparametro vertė kinta nuo 0 iki 1. Sumažinus šią vertę iki artimos 0, modelyje mažiau dominuoja mokymosi imties poabiai. Tai gali lemti didesnę atsparumą pertekliniam prisitaikymui (*ang. overfitting*).
2. Savybės dalinė imtis („ColSampleByTree“) – analogiška dalinės imties hiperparametrui, tačiau čia limituojamas pasiekiamų savybių skaičius.
3. Didžiausias gylis („MaxDepth“). Didžiausias leistinas XGB silpnųjų modelių, dar vadinamų „sprendimų medžiais“, gylis. Sprendimų medis - tai hierarchinė struktūra, kurioje pagal duomenų rinkinio požymius atliekama keletas dvejetainių skirstinių. Medžio gylis reiškia ilgiausio kelio nuo šakninio mazgo iki bet kurio lapinio mazgo ilgį. Praktikoje žinoma, kad gilesnis medis leidžia išvystyti sudėtingesnius ryšius tarp savybių. Tai gali lemti geresnius rezultatus, tačiau atsiranda perteklinio prisitaikymo rizika. Apribojimas padeda kontroliuoti modelio sudėtingumą ir leidžia kontroliuoti kompromisą tarp perteklinio persimokymo ir sudėtingesnes sąveikas galinčio išvystyti modelio.
4. Mažiausias vaikų svoris ("MinChildWeight"). Mažiausias mokymosi imties pavyzdžių skaičius, reikalingas tolesniam lapinio mazgo skaidymui. Modelis su didesne hiperparametro reikšme

- kiekviename lapiniame mazge turi daugiau imties taškų. Tokiu būdu yra skatinamas konservatyvus medžio augimas. Mažinama perteklinio persimokymo galimybė.
5. Mokymosi greitis („LearningRate“). XGBoost" mokymosi greičio parametras nustato, koku greičiu didinimo algoritmas atnauja modelio koeficientus po kiekvienos iteracijos. Didesnė mokymosi sparta lemia greitesnį konvergavimą, tačiau taip pat gali padidinti optimalaus sprendinio peržengimo riziką ir perteklinio persimokymo lygį. Mažesnė mokymosi sparta apriboja atnaujinimus- mokymasis yra konservatyvesnis, modelio apibendrinimas nematytiems duomenims yra tikėtinesnis
 6. Silpnųjų modelių skaičius („NEstimators“). Modelio atliekamų iteracijų skaičius (sukurtų medžių skaičius).


Kol kas nežinoma, kaip iš anksto apskaičiuoti optimalias hiperparametrų reikšmes. Geriausiems rezultatams pasiekti naudojami įvairūs hiperparametrų reikšmių paieškos metodai. Šiame darbe naudojama standartinė tinklo paieška (*ang. grid search*).

Tinklo paieška apima galimų hiperparametrų verčių aibės sukūrimą, išmėginimą ir įvertinimą. Kiekvienos iteracijos metu modelis mokomas naudojant konkretų hiperparametrų derinį, o jo veikimas vertinamas sutartiniu vertinimo dydžiu, pvz. vidutine kvadratine paklaida (MSE). Šis procesas leidžia sistemingai rasti optimalias hiperparametrų vertes tam tikram modeliui ir duomenų rinkiniui.

Vienas XGB privalumų yra tai, kad sukonstravus medžius įmanoma tiesiogiai įvertinti naudojamų savybių svarbą modeliui. Šiame darbe naudojamas viso pelno įvertis (*ang. total gain*). Tai metrika, apimanti bendrą medžio struktūros ir atskirų savybių įtakos įvertinimą [44].

2.4.2. Daugiasluoksnis perceptronas

Daugiasluoksnis perceptronas (MLP) yra dirbtinio neuroninio tinklo tipas, turintis kelis tarpusavyje sujungtų mazgų sluoksnius. Jis naudoja netiesines aktyvavimo funkcijas ir reguliuojamus svorius sudėtingiems įėjimų ir išėjimų ryšiams modeliuoti. Universalioji aproksimacijos teorema teigia, kad MLP su vienu paslėptuoju sluoksniu (sluoksniu nepriklausančiu įėjimui ir išėjimui) gali labai tiksliai aproksimuoti bet kokią tolydžią funkciją. Taip yra todėl, nes sluoksninė struktūra ir netiesinės aktyvavimo funkcijos leidžia hierarchiškai išgauti požymius ir lanksčiai modeliuoti netiesinius ryšius. Tinkamai atrinkus parametrus, MLP gali funkcionuoti kaip universalus funkcijų aproksimatorius ir prisitaikyti prie sudėtingų užduočių.



24 pav. MLP architektūros vizualizacija

Vienas iš pagrindinių MLP trūkumų yra sudėtinga veikimo interpretacija, didelės apmokymui reikalingos skaičiavimo ir atminties resursų sąnaudos. MLP taip pat yra linkęs pertekliniam persimokymui, pasižymi nykstančiu gradientu ir polinkiu pasilikti ties vietiniais gradiento minimumais. Ypatingai kai bandoma optimizuoti labai nekonvekcinę ir daugiamatę funkciją.

Kitaip nei XGB, MLP būtina normalizuoti naudojamą duomenų imtį. Šiame darbe normalizavimas realizuojamas atimant iš visų savybių vektoriaus vidurkį ir padalijant jį iš standartinio nuokrypio. Tokia manipuliacija užtikrina gradientu pagrįstų optimizavimo algoritmų konvergenciją, nes subalansuoja visų požymių svorių atnaujinimus. Normalizuojant neleidžiama dominuojantiems požymiams užgožti kitų, o tai sumažina perteklinį persimokymą. Galiausiai normalizavimas lemia efektyvesnę optimizavimą, nes pagerina užduoties savybių daugialypės erdvės reljefą – tai padeda konverguoti prie globalaus arba lokalaus minimumo.

Kaip ir XGB atveju, MLP yra jautrus įvairiems hiperparametrų, kurių kol kas negalima iš anksto apskaičiuoti. Vieni pagrindinių hiperparametrų yra šie:

1. Partijos dydis („Batch size“). MLP mokymo metu visas duomenų rinkinys yra padalinamas į mažesnes vienodo dydžio partijas. Partijos dydis lemia kiek pavyzdžių bus paskleista tinkle prieš atnaujinant modelio parametrus. Pavyzdžiui, kai partijos dydis yra 24, tinklas lygiagrečiai apdoroja 24 duomenų taškus ir apskaičiuoja aktualią tikslo funkcijos reikšmę, kuri toliau naudojama parametrų koreguoti taikant tokius metodus kaip atgalinė sklaida (*ang. back propagation*). Naudojant didesnę partijos dydį MLP treniravimo procesas gali būti paskirstytas į lygiagrečias dalis, todėl greitėja. Tačiau, didesnis partijos dydis asocijuojamas su didesne persimokymo galimybe.
2. Mokymosi greitis („Learning rate“) - tai skaliarinis parametras, kurio reikšmė ir kompromisai analogiški to paties vardo XGB hiperparametrui.
3. Iteracijų skaičius („Max Iterations“) nurodo didžiausią epochų skaičių mokymosi proceso metu.
4. Architektūra. Tai yra MLP sluoksnių skaičius ir išdėstymas, aktyvacijos funkcijos tipas ir mazgų skaičius ties kiekvienu sluoksniu.
5. Išmetimas („Dropout“). Kai kur naudojamas virtualaus sluoksnio pavidalu. Išmetimas yra reguliarizavimo metodas, naudojamas kovojant su pertekliniu persimokymu. Matematiškai iškritimą galima suprasti kaip neuronų išėjimų reikšmių dauginimą iš dvejetainės maskavimo funkcijos. Ši funkcija generuojama atsitiktinai kiekvienam mokymui naudojamam pavyzdžiui pagal nustatytą iškritimo tikimybę, pvz. 10%. Mokymo metu mažinant aktyvių neuronų išėjimus, iškritimas veiksmingai sumažina bendrą bet kurio atskiuro neurono įtaką ir skatina kolektyvinę likusių aktyvių vienetų sprendimų priėmimą.


Išvardyti hiperparametrai atlieka lemiamą vaidmenį kontroliuojant mokymosi procesą, nustatant konvergavimo greitį, varijuojant tarp perteklinio persimokymo, apibendrinimo lygio ir skaičiavimo našumo [31]. Kaip ir XGB atveju, MLP gali būti treniruojamas tinklo paieškos principu.

MLP neturi tiesioginio kriterijų svarbumo vertinimo metodo, tačiau mašininio mokymosi praktikoje galima rasti įvairių veiksmingų sprendimų. Vienas tokių – „Shapley“ verčių koncepcija grindžiamas SHAP įvertis, naudojamas bet kokio mašininio mokymosi modelio prognozėms paaiškinti, apskaičiuojant savybių indėlį į prognozavimo modelį remiantis žaidimų teorijos principais [26].

3. Rezultatai

3.1. Kvantavimo užduotis


Vertinimo metodu pasirinkta stratifikuota kryžminė validacija – duomenys atsitiktinai padalinami į 5 dalis, išlaikant tą patį balansą tarp klasių. Viena dalis naudojama algoritmų testavimui, o 4 dalys modelių treniravimui. Darbo rezultatuose fiksuojamas visų testavimo dalių įverčių vidurkis. Algoritmai testuojami visomis tinklo paieškos hiperparametrų kombinacijomis. Aptikus geriausius rezultatus pasiekusią hiperparametrų kombinaciją, fiksuojami rezultatai ir įvertinama savybių svarbumas. Toliau visa seka gali būti kartojama su mažesne savybių aibe. Vizualinė vertinimo sekos schema pavaizduota 25 pav.



25 pav. Modelių vertinimo sekos schema


3.1.1. Kvantavimas lietimo jutikliu

Spiralių piešinių duomenims ties skirtingais tremoro intensyvumo kvantais atlikta vizualinė analizė. Pastebima bendra tendencija- prastesnio įvertinimo piešiniai pasižymi didesniu iškraipymu, aukšto ir žemo dažnio triukšmu, staigiais atotrūkiais nuo taisyklingo kontūro. Geriausio įvertinimo piešiniai beveik tobulai atitinka taisyklingos spiralės kontūrą. Aiškiai išreikštų skirtumų tarp gretimų kvantų nėra.



26 pav. Spiralių piešiniai ties skirtingais tremoro intensyvumo kvantais (CP, ET, PD imtys)

Išmatavus lietimą jutiklio visų bruožų Pearsono koreliaciją su tremoro kvantavimo skale, 4 bruožai pasižymėjo didesne nei 84% koreliacija. Jų reikšmių pasiskirstymo tankio kreivės pavaizduotos **27 pav.** Čia **pwr.mean.3.16.log** – galios vidurkis logaritminėje skalėje (3- 16 Hz), **pwr.median.1.18.log** – galios mediana logaritminėje skalėje (1-18 Hz), **pwr.median.3.16.log** – galios mediana logaritminėje skalėje (3-16 Hz), **pwr.mean.1.18.log** – galios vidurkis logaritminėje skalėje (3- 16 Hz),. Pastebima bendra tendencija – prastesnio įvertinimo tremorai pasižymi didesne galios mediana, vidurkiu ir centriniu dažniu ties (3 – 16 Hz) ir (4 - 8 Hz) dažnių juostomis.



27 pav. Reikšmių pasiskirstymo tankio kreivės – bruožai, pasižymintis stipriausia Pearsono koreliacija su tremoro kvantavimo skale (lietimo jutiklis)

Tinklo paieška sugeneruojamos 1000 XGBoost hiperparametrų kombinacijų. Visos jos išmėginamos ir įvertinamos stratifikuota kryžmine validacija. Naudojant visas savybes pavyko pasiekti MAE =

0.805, RMSE = 1.01, RMSLE = 0.663. Algoritmo tikslo funkcijos matas nustatytas ties RMSLE. Naudojami vien lietimio jutiklio duomenys. RMSLE pasirinktas bandymu metu pastebėjus, kad šis parametras generuoja geriausius rezultatus.


$$RMSLE(y, \hat{y}) = \sqrt{\frac{1}{n} \sum_{i=1}^n (\log(1 + \hat{y}_i) - \log(1 + y_i))^2} \quad (3.1)$$

Čia $\hat{y}_i$ - prognozuojama y reikšmė imties pavyzdžiui i , o y_i - tikroji pavyzdžio reikšmė. Skirtingai nei standartinis RMSE (šaknis iš vidutinės kvadratinės paklaidos), RMSLE yra asimetriškas ir nepakankamai įvertintas prognozes baudžia daug labiau nei pervertintas.

3 lentelė. XGBoost tinklo paieška - hiperparametrų kombinacijos.

Parametras	Vertės	Geriausias modelis
<i>SubSample</i>	0.4, 0.6, 0.8, 0.9, 0.95	0.6
<i>ColsampleByTree</i>	0.4, 0.6, 0.8, 0.92, 0.95	0.92
<i>MaxDepth</i>	1, 2, 3, 4, 5, 6, 7	4
<i>MinChildWeight</i>	1, 2	2
<i>LearningRate</i>	0.03, 0.05, 0.1, 0.2	0.05
<i>NEstimators</i>	iki 300 (ankstyvas sustojimas = 20)	137


Modelio savybių svarbumas įvertinimas didžiausio pelno kriterijumi. Reliatyvus svarbumas pavaizduotas **28 pav.** Svarbiausi kriterijai – pwr.3.16, pwr.mean.4.8, pwr.4.8. Mažiau svarbių savybių reliatyvus įvertinimas drastiškai mažėja.



28 pav. XGBoost modelio savybių svarbumo įvertinimas didžiausio pelno kriterijumi (lietimo jutiklis)

Naudojamų savybių skaičius sumažinamas iki svarbiausių dešimties. Treniravimo ir vertinimo procesas pakartojamas. Fiksuojami šiek tiek prastesni rezultatai (MAE = 0.839, RMSE = 1.09, RMSLE = 0.712). Modelio savybių svarbumas įvertinimas didžiausio pelno kriterijumi.

Reliatyvus svarbumas pavaizduotas **29 pav.** 2 svarbiausi kriterijai nepakito– pwr.4.8, pwr.mean.3.16, tačiau iki trečios vietos pakilo pwr.std.4.8. Naudojamų savybių skaičius sumažinamas iki svarbiausių 4 savybių. Treniravimo ir vertinimo procesas pakartojamas.



29 pav. XGB modelio savybių svarbumo įvertinimas didžiausio pelno kriterijumi (lietimo jutiklis, 10 svarbiausių savybių)

Su 4 svarbiausiais kriterijais XGBoost pasiekė $MAE = 0.908$, $RMSE = 1.22$, $RMSLE = 0.817$. Reliatyvus svarbumas nepasikeitė. Matavimas taip pat atliktas su vien spektrinėmis savybėmis ($MAE = 0.816$, $RMSE = 1.04$, $RMSLE = 0.674$) ir vien su laikinėmis savybėmis ($MAE = 1.56$, $RMSE = 1.94$, $RMSLE = 1.25$).


Analogiškas treniravimo ir rezultatų vertinimo procesas atliekamas su MLP. Tinklo paieškos parametrai pavaizduoti žemiau (**4 lentelė**). Naudotas MLP sudarytas iš 3 paslėptų sluoksnių su „RELU“ aktyvacijos funkcija. Išorinis išėjimo sluoksnis sudarytas iš 1 mazgo be jokios aktyvacijos funkcijos. Naudotas optimizavimo metodas- Adam. Nuostolių funkcija – vidutinė kvadratinė paklaida (MSE). Po kiekvieno tankiojo sluoksnio seka išmetimo sluoksnis.

4 lentelė. MLP tinklo paieška - hiperparametrų kombinacijos.

Parametras	Vertės	Geriausias modelis
Pirmo sluoksnio mazgų skaičius	8, 32, 64, 128	16
Antro sluoksnio mazgų skaičius	8, 16, 32, 64, 128	32
Trečio sluoksnio mazgų skaičius	8, 16, 32, 64, 128	32
Iškritimas po pirmo sluoksnio	0, 0.1	0.1
Iškritimas po antro sluoksnio	0, 0.1	0.1
Iškritimas po trečio sluoksnio	0, 0.1, 0.4, 0.8	0.4
Mokymosi greitis	0.01, 0.001, 0.0001	0.001
Iteracijų skaičius	15, 30, 50, 80, 100	80
Partijos dydis	8, 64	8


Naudojant visus duomenis pasiektas $MAE = 0.81$, $RMSE = 1.08$, $RMSLE = 0.69$.

Savybių svarbumo įvertinimas atliktas SHAP metodu (**30 pav.**). Nei viena savybė savo svarbumu neišsiskiria. Tyrimas tęsiamas naudojant 10 svarbiausių savybių.




30 pav. MLP modelio savybių svarbumo įvertinimas SHAP metodu (lietimo jutiklis, horizontalioji ašis atitinka SHAP vertę)

Su 10 svarbiausių savybių aibe MLP pasiekė $MAE = 0.87$, $RMSE = 1.09$, $RMSLE = 0.71$. Savybių svarbumo įvertinimas pavaizduotas žemiau (**31 pav.**). Pirmosios 3- 4 savybės išsiskiria aukštu svarbumu. Tyrimas tęsiamas naudojant 4 svarbiausių savybių aibę.



31 pav. MLP modelio savybių svarbumo įvertinimas SHAP metodu (lietimo jutiklis, 10 svarbiausių savybių aibė, horizontalioji ašis atitinka SHAP vertę).


Naudojant 4 svarbiausias savybių aibę MLP rezultatai siekia: $MAE = 0.92$, $RMSE = 1.12$, $RMSLE = 0.79$. Geriausius rezultatus pavyko pasiekti naudojant pilną savybių aibę. Šis modelis sudarytas iš 3553 parametų. Pilna architektūros schema pateikta žemiau (**32 pav.**).



32 pav. Geriausius rezultatus pasiekusio MLP modelio architektūros schema (visos savybės).

3.1.2. Kvantavimas akselerometru

Išmatavus akselerometro visų bruožų Pearsono koreliaciją su tremoro kvantavimo skale, 4 bruožai pasižymėjo didesne nei 80% koreliacija. Jų reikšmių pasiskirstymo tankio kreivės pavaizduotos **33 pav.** Čia **pwr.mean.4.8.log** – vidutinė galia logaritminėje skalėje (4-8 Hz), **pwr.median.4.12.log** – galios mediana logaritminėje skalėje (4-8 Hz), **pwr.4.8.log** – galia logaritminėje skalėje (4-8 Hz), **pwr.mean.3.12.log** – vidutinė galia logaritminėje skalėje (3-2 Hz). Pastebima bendra tendencija – prastesnio įvertinimo tremorai pasižymi didesne galia (4 – 8 Hz) ir (3 -12 Hz) dažnių juostose. Prasčiausi įvertinimai (1, 2, 3) fiksuojami ties ekstremaliausiomis pagreičio diferencialo sumos vertėmis.




33 pav. Reikšmių pasiskirstymo tankio kreivės – bruožai, pasižymintys stipriausia Pearsono koreliacija su tremoro kvantavimo skale (akselerometras)

XGboost treniravimui naudojama ta pati tinklo paieška su 1000 hiperparametrų kombinacijų. Naudojant visas savybes pavyko pasiekti $MAE = 0.69$, $RMSE = 1.07$, $RMSLE = 0.67$. Algoritmo tikslo funkcijos matas nustatyta ties RMSLE. Modelio savybių svarbumas įvertinimas didžiausio pelno kriterijumi. Reliatyvus svarbumas pavaizduotas **34 pav.**. Svarbiausi kriterijai – pwr.3.12, pwr.mean.3.12.log. Mažiau svarbių savybių reliatyvus įvertinimas drastiškai mažėja. Svarbių savybių pasiskirstymas drastiškai skiriasi nuo tuo pačiu metodu aptiktu svarbių lietimų jutiklio savybių.


Toliau naudojamų savybių skaičius sumažinamas iki svarbiausių dešimties. Treniravimo ir vertinimo procesas pakartojamas. Fiksuojami prastesni rezultatai ($MAE = 0.71$, $RMSE = 1.07$, $RMSLE = 0.68$). Iš naujo įvertinamas modelio savybių svarbumas ir algoritmui naudojamas poaibis sumažinamas iki svarbiausių 4 savybių. Treniravimo ir vertinimo procesas pakartojamas su 4 svarbiausiais kriterijais ($MAE = 0.77$, $RMSE = 1.09$, $RMSLE = 0.70$).

Šiuo atveju reliatyvus svarbumo įverčio statistika nepasikeitė.



34 pav. XGB savybių svarbumo įvertinimas didžiausio pelno kriterijumi (akselerometras, visos savybės)

Analogiškas treniravimo ir rezultatų vertinimo procesas atliekamas su MLP, naudojant tą pačią architektūrą ir hiperparametrų kombinacijų tinklą, kaip ir anksčiau. Gautas MAE = 0.93, RMSE = 1.26, RMSLE = 0.85. Savybių svarbumo SHAP įverčiai pasiskirstę maždaug tolygiai.



35 pav. MLP savybių svarbumo įvertinimas SHAP metodu (akselerometras, visos savybės)

MLP su 10 savybių pasiekė MAE = 0.94, RMSE = 1.22, RMSLE = 0.64, o su 4 savybėmis MAE = 0.96, RMSE = 1.27, RMSLE = 0.85.

3.1.3. Kvantavimas abiem jutikliais

Akselerometro ir lietimio jutiklio savybių imtys sudedamos į viena bendrą imtį- 238 savybių matricą. Ji naudojama kvantavimo modelių treniravimui ir testavimui ta pačia procedūra. XGBoost su visų savybių aibe pasiekė MAE = 0.58, RMSE = 0.79, RMSLE = 0.51. Beveik identiškas rezultatas


pasiestas ir naudojant tik spektrinių savybių poaibį. Tik čia RMSLE = 0.50. Tai geriausiai įvertintas modelis. Jo hiperparametrai užfiksuoti bendroje lentelėje (**3 lentelė**). Geriausių rezultatų pasiekusio MLP modelio hiperparametrai užfiksuoti **4 lentelėje** (MAE = 0.69, RMSE = 0.95, RMSLE = 0.65)

5 lentelė. Kvantavimo užduoties rezultatų apibendrinimas.

Savybės	Akselerometras			Lietimo jutiklis			Abu jutikliai		
	MAE	RMSE	RMSLE	MAE	RMSE	RMSLE	MAE	RMSE	RMSLE
XGB									
Visos	0.69	1.07	0.67	0.80	1.01	0.66	0.58	0.79	0.51
10 svarbiausių	0.71	1.07	0.68	0.84	1.09	0.71	0.64	0.83	0.52
4 svarbiausios	0.77	1.09	0.70	0.91	1.22	0.82	0.68	1.00	0.65
Visos spektrinės	0.77	1.01	0.62	0.82	1.04	0.67	0.58	0.79	0.50
Ne spektrinės	1.14	1.42	0.89	1.56	1.94	1.25	1.22	1.53	1.00
MLP									
Visos	0.93	1.26	0.85	0.81	1.08	0.69	0.69	0.95	0.65
10 svarbiausių	0.94	1.22	0.64	0.87	1.09	0.71	0.72	0.98	0.66
4 svarbiausios	0.96	1.27	0.85	0.92	1.12	0.79	0.72	1.01	0.67
Visos spektrinės	1.15	1.39	0.85	0.89	1.15	0.75	0.74	1.05	0.66
Ne spektrinės	1.37	1.65	1.04	1.39	1.73	1.10	1.24	1.62	1.06

3.2. Diagnostikos užduotis

Spiralių piešinių duomenims ties skirtingomis diagnostikos klasėmis (CP, PD, ET) atlikta vizualinė analizė. Pastebimas aukštesnio dažnio ir labiau išreikštas iškreipimas ties ET populiacijos piešiniais. PD populiacijai nebūdingas veiksmo tremoras, tačiau piešiniuose vis tiek matomas žemos dažnio triukšmas- lėtas nuokrypis nuo taisyklingo kontūro. CP piešiniai beveik tobulai atitinka taisyklingos spiralės kontūrą.




36 pav. Spiralių piešiniai iš skirtingų diagnostinių imčių (CP, PD, ET)

Gautų duomenų imčių tikslumas vertinamas atliekant XGBoost mokymo ir hiperparametrų atrankos procedūras. Algoritmo tikslo funkcija nustatyta ties „*multiclass softprob*“. Naudojama 5 dalių stratifikuota kryžminė validacija. Lyginant prognozes, labiausiai atsižvelgiama į F1 ir kappa (KAP) matus. Visi kriterijai skaičiuojami „vienas prieš visus“ principu. Naudojant visas savybes ir abiejų jutiklių imtį gautas AUC = 0.98, Koheno kappa koeficientas K = 0.96. Jautrumas atskiroms klasėms CP, ET ir PD fiksuotas tiek TPR = (0.97, 1.0, 0.95), specifiškumas TNR = (0.98, 0.98, 1.00), rodiklis F1 = (0.97, 0.98, 0.97). Modelio vertinimui taip pat naudojama daugiaklasės klasifikavimo paklaidos matas (MER). Jis fiksuoja kokia visos imties N_v dalis buvo klasifikuota klaidingai N_k (procentais).


$$MER = 100 \frac{N_k}{N_v} \quad (3.2)$$

Pilna sumaišymo matrica pateikta **37 pav.** Tik 2 pavyzdžiai įvertinti klaidingai.



37 pav. Sumaišymo matrica (0- CP, 1- ET, 2- PD, visos savybės, XGB)


Modelio savybių svarbumas įvertinimas didžiausio pelno kriterijumi. Reliatyvus svarbumas pavaizduotas **38 pav.**. Svarbiausi kriterijai – spc.pwr.disp.0.25.mean, pwr.entropy.3.12, spc.pwr.max, pwr.entropy.4.8. Mažiau svarbių savybių reliatyvus įvertinimas mažėja. Įdomu tai, kad tik 1 kriterijus buvo atsižvelgtas iš akselerometro duomenų (f.c.1.18 – indikacija pavadavimo pradžios kode „acc“). Toliau naudojamų savybių aibė sumažinama iki svarbiausių 10 ir 4. Duomenys fiksuojami **6 lentelėje**.



38 pav. XGBoost modelio savybių svarbumo įvertinimas didžiausio pelno kriterijumi (abu jutikliai, visos savybės, diagnozės užduotis)


Analogiškas treniravimo ir rezultatų vertinimo procesas atliekamas su MLP. Naudojamos tie patys tinklo paieškos hiperparametrų kombinacijos kaip ir regresijos užduočiai. Naudotas MLP sudarytas iš 3 paslėptų sluoksnių su „RELU“ aktyvacijos funkcija. Išorinis išėjimo sluoksnis sudarytas iš 3 mazgų, atitinkančių skirtinas klases. Naudojama „softmax“ tikslo funkcija. Optimizavimo metodas-Adam. Nuostolių funkcija – kategorinė kryžminė entropija (*ang. categorical cross-entropy*).

Naudojant visas savybes gautas TPR = 1.0, TNR = 0.97, F1 = 0.99, AUC = 1.0, KAP = 0.98. Modelis padarė tik 1 klaidą (MER = 1.3%).



39 pav. Sumaišymo matrica (0- CP, 1- ET, 2- PD, visos savybės, MLP)

Savybių svarbumo įvertinimas atliktas SHAP metodu (**40 pav.**). Nei viena savybė savo svarbumu neišsiskiria. Į dešimtuką pateko tik viena akselerometro duomenų savybė- pwr.1.18. Svarbumas visiškai skirtingas nei XGBoost atveju. Tyrimas tęsiamas naudojant 10 ir 4 svarbiausių savybių (**6 lentelė**).




40 pav. MLP savybių svarbumo įvertinimas SHAP metodu (abu jutikliai, diagnozės užduotis)

6 lentelė. Diagnozės užduoties rezultatų apibendrinimas.

Savybės	XGB			MLP		
	AUC	KAP	MER	AUC	KAP	MER
Visos	0.98	0.96	2.5	1.00	0.98	1.3
10 svarbiausių	0.97	0.96	2.5	0.96	0.88	7.6
4 svarbiausios	0.94	0.90	6.3	0.94	0.84	8.9

3.3. Ekonominio efekto vertinimas

Yang W. Ir kt. [5] duomenimis 2017 m. PD liga diagnozuotų asmenų skaičius JAV siekė 1.04 milijono. Ligos sukelta metinė ekonominė našta JAV siekė 51.9 mlrd. dolerių. Tiesioginės medicininės išlaidos sudarė 25.4 mlrd. dolerių. Prognozuojama, kad ekonominė našta augs ir 2037 m. sieks 79.1 mlrd. dolerių.



41 pav. Bendra PD sukeliamą ekonominę žalą JAV (2017 m. padėtis ir 2022-2037 prognozė) [5]

Darbe pasiūlyta priemonė suteikia galimybę įvertinti tremoro kilmę (diagnozė) ir eigą (stiprumo kvantavimas) be papildomos techninės įrangos ar apmokymų. Dėl šios priežasties sprendimas ekonominių kaštų neturi arba jie absoliučiai minimalūs. Rezultatai parodė, kad geriausias diagnostikos algoritmas (MLP, visos savybės, abu jutikliai) tremorą vertina tiksliau nei vidutinis neurologas. Modelis padarė tik 1 klaidą (MER=1.3%) iš 79 pacientų imties. Tuo pačiu metu judesio sutrikimuose ar neurologijoje besispecializuojantys profesionalai klaidingai diagnozuoja apie 20% atvejų. Dėl šių priežasčių galima teigti, kad sprendimas turi teigiamą ekonominį efektą. Galima išskirti pagrindines tokio efekto pasireiškimo sritis:

1. **Mirtingumo rodiklių mažinimas.** PD pacientų, kuriems suteikta neurologo priežiūra, išgyvenamumo rodikliai ir bendra tikimybė išgyventi yra vidutiniškai 12.75% didesni, palyginti su pirminės sveikatos priežiūros gydytojo gydomais pacientais [37]. Deja, tik nedidelė dalis pacientų reguliariai lankosi pas specialistus, o 40 % PD pacientų JAV iš vis niekada to nedarė. Pasiūlytas sprendimas padidina galimybes gauti profesionalų tremoro vertinimą, todėl ligos mirtingumo rodikliai gali mažėti iki 12.75%. Pirmalaikė mirtis 2017 m. sudarė 2.5 mlrd. dolerių ekonominės PD naštos JAV, todėl 12.75% mirtingumo rodiklio sumažinimas būtų galėjęs sumažinti naštą per 318.75 mln. dolerių. Prognozuojama, kad nuo 2022 iki 2037 pirmalaikė mirtis JAV ekonomikai sukels papildomus 200 milijonų dolerių nuostolių. Pasiūlyta priemonė gali sumažinti šiuos kaštus per 25.5 milijonus dolerių (12.75%). Realiau atveju sumažėjimas gali kisti

bet kur spektre nuo 0 iki 12.75%, priklausomai nuo priemonės adaptacijos rinkoje ir nuo to, kokią dalį profesionalo darbo galima pakeisti arba kompensuoti. Tokie aspektai kaip vaistų priskyrimas vis tiek iškrenta iš apibrėžimo srities, todėl pakeitimas gali būti tik dalinis. Reikia atsižvelgti ir į tai, kad tremoras sudaro tik dalį PD simptomų spektro.

2. **Medicininės apžiūros laiko trumpinimas.** Tradiciniai tremoro vertinimo metodai trunka nuo 10 min. iki valandos [16, 17]. Pasiūlyta priemonė reikalauja 30 sek. laiko vertinimu akselerometru ir 30s. laiko vertinimu lietimui jutikliu. Rezultatai apskaičiuojami akimirksniu, todėl darbo laikas gali būti sutrumpintas nuo 10 iki 60 kartų arba nuo 9 iki 59 minučių. JAV darbo statistikos biuro duomenimis neurologai uždirba vidutiniškai 45 dolerius per valandą [45]. 9 minučių įkainis yra 6.75 dolerių, 59 minučių – 44.25 dolerių. Atsižvelgiant į bendrą 1.04 mln. diagnozuotų pacientų skaičių, laiko sutaupymas būtų sumažinęs tiesioginių medicininių išlaidų naštą nuo 7.02 mln. iki 46.02 mln. dolerių. Prognozuojama, kad nuo 2022 iki 2037 metų JAV PD susirgs papildomi 430 tūkst. žmonių. Vadinas, vien pirmą kartą diagnozuojant PD, per šį laikotarpį fiksuojama potenciali nuo 2.9 mln. iki 19.02 mln. dolerių ekonominė nauda.
3. **Klaidingų diagnozių kiekio mažinimas.** Teigiama, kad nuo 20 iki 30% ET ir PD pacientų yra klaidingai diagnozuoti. Vadinas, tiesioginės su gydymu susijusios išlaidos gali būti nenaudingos. Atsižvelgiant į tai, kad tokios išlaidos 2017 m. sudarė 25.4 mlrd. dolerių, priemonė potencialiai galėjo sumažinti ekonominę naštą 5.06 mlrd. – 7.59 mlrd. dolerių. Prognozuojama, kad tos pačios išlaidos 2037 m. sieks 40.4 mlrd. dolerių. Tai yra 10.8 mlrd. prieaugis nuo 2022 m. Adaptavus priemonę rinkoje dabar, vien klaidingų diagnozių kiekio mažinimas iki 2037 m. JAV ekonomikai galėtų sutaupyti nuo 2.16 mlrd. iki 3.24 mlrd. tiesioginių medicinos išlaidos. Verta paminėti, kad toks skaičiavimo principas tinkamas tik tuo atveju, jei vienos ligos medicininės išlaidos yra visiškai nenaudingos kitos ligos atžvilgiu. Realiose situacijose, gydimuose gali būti persidengimų, pvz. mankštos ar streso mažinimo metodai. Tuo pačiu metu klaidingas gydymas gali sukelti ir papildomą žalą sveikatai, o tuo pačiu metu ir ekonomikai. Visgi, ET ir PD vaistai turi šalutinius simptomus.
4. **Ankstyva diagnozė.** Ekonominio efektyvumo tyrimuose JAV nustatyta, kad skiriant specialius vaistus ankstyvosios stadijos PD pacientams, įvairių simptomų pasireiškimas yra atitolinamas arba sumažinamas. Pastebimas QALY padidėjimas ir ekonominės žalos mažėjimas. Pasiūlyta priemonė suteikia galimybę diagnozuoti PD nesilankant pas medicinos profesionalą. Tam reikalingas tik, pvz. mobilusis telefonas. Galima daryti prielaidą, kad priemonei paplitus tarp sveikų žmonių ir asmenų, dar tik įtariančių pataloginio tremoro turėjimą, atsirastų atvejų, kai liga diagnozuojama dar prieš pirmą apsilankymą pas neurologą ar šeimos gydytoją. Literatūroje teigiama, kad specialių vaistų vartojimas ankstyvoje stadijoje 5 metų laikotarpiu sumažina išlaidas 18 % vienam pacientui [46]. Atsižvelgiant į tai, kad prognozuojamas tiesioginių sveikatos išlaidų padidėjimas nuo 2022 m. iki 2027 siekia 4 mlrd., ekonominė nauda šiuo laikotarpiu galėtų siekti 720 mln. dolerių. Bendrai nuo 2022 m. iki 2037 m. tokia nauda siektų iki 1.94 mlrd. dolerių. Tikroji suminė ekonominė nauda priklauso nuo priemonės populiarumo ir kiekvieno individualaus PD atvejo.

Šis ekonominio efekto vertinimas grindžiamas vien JAV duomenimis. Literatūros analizėje pastebėta, kad esminių skirtumo tarp ligos paplitimo ar ekonominių kaštų tarp šalių nėra. Pagrindiniai įtakos faktoriai yra ekonominio išsivystymo lygis, populiacijos dydis ir bendra sveikatos sistemos sandara. Dėl šių priežasčių JAV rinką ir apskaičiuota teikiama priemonės nauda galima interpretuoti kaip atskaitos tašką.

ET paplitimas yra didesnis nei PD. ET pacientų skaičius vien JAV 2016 m. duomenimis siekė 7 mln. Literatūros analizė parodė, kad ekonominės žalos aspektu liga prilygsta PD. Bendros su ET susijusios papildomos sveikatos priežiūros išlaidos siekia nuo 1,5 iki 5,4 mlrd. dolerių per metus JAV [48]. Vienas pacientas vidutiniškai sveikatai išleidžia 2 810 dolerių per metus. Tai yra 1 068 dolerių daugiau nei sveiko asmens išlaidos. Pasiūlytos vertinimo priemonės ekonominio efekto vertinimas ET atveju yra sudėtingesnis dėl mažesnio kiekio literatūros šaltinių, lyginant su PD. Tačiau, dvi pasireiškimo sritys ET atveju pasikartoja.

1. **Medicininės apžiūros laiko trumpinimas.** Tradiciniai tremoro vertinimo metodai, kaip ir PD atveju, trunka nuo 10 min. iki valandos [16, 17], todėl darbo laikas gali būti sutrumpintas nuo 10 iki 60 kartų arba nuo 9 iki 59 minučių. Atsižvelgiant į 2019 m. apskaičiuotą bendrą 213 722 kasmet diagnozuojamų pacientų skaičių, laiko sutaupymas sumažintų tiesioginių medicininių išlaidų našta nuo 1.44 mln. iki 9.46 mln. dolerių kasmet.
2. **Klaidingų diagnozių kiekio mažinimas.** Skaičiavimai yra analogiški PD atveju. ET atveju galima papildomai išskirti, tai, kad pastebimas 1% pasitaikantis klaidingas ET sumaišymas su distonija [49]. Vidutinės bendros metinės išlaidos vienam distonija sergančiam pacientui Filipinuose buvo 4861 JAV dolerio (2018 metų duomenys) [51]. Darant prielaidą, kad JAV išlaidos panašios, 1% distonija klaidingai diagnozuotų pacientų iš maždaug 213 722 kasmet JAV diagnozuojamų ET asmenų sukuria bereikalingą 10.39 mln. dolerių žalą per metus JAV ekonomikai.

Išvados

1. Literatūros analizė atskleidė, kad egzistuoja 2 pagrindiniai tremoro vertinimo tipai: simptomų stiprumo (kvantavimo) ir diagnozės. Tradiciniai vertinimo metodai remiasi subjektyviu medikų vertinimų, todėl yra netikslūs. Kompiuterizuoti metodai dažniausiai remiasi standartine vibracijų analize dažnių srityje. Egzistuoja platus spektras įvairių laiko ir dažnių srities savybių, tačiau nėra bendro sutarimo kurios iš jų geriausios. Apžvelgti tyrimai atskleidė, kad kokybiškas vertinimas gali būti modernizuotas naudojant kone bet kokią jutiklį, tačiau nei vienas sprendimas netenkina rinkos poreikių. Nepavyko rasti tyrimų, kuriuose būtų naudojamas visiškai skirtingų tipų jutiklių suliejimas.
2. Efektyviausia vertinimo priemonė turi remtis tiesiogiai su rankos judesiais susijusių jutiklių duomenimis. Išmaniuosiuose įrenginiuose šie jutikliai yra 3 ašių akselerometras ir 2 ašių lietimo jutiklis. Nors literatūroje galima rasti įvairių tremoro matavimui akselerometru skirtų rankų pozicijų, pakankamai naudingus duomenis galima gauti ištiestos rankos poza. Ji iššaukia pozicinių tremorą, nereikalauja papildomos įrangos ir yra labai paprasta. Lietimo jutiklis yra tinkamas rankų tremoro duomenims rinkti. Tradiciniuose vertinimo metoduose naudojamas figūrų piešimo metodas yra patvirtintas praktika ir tyrimais, todėl šiuo pratimu gali būti grindžiamas duomenų rinkimo lietimo jutikliu konceptas. Abiejų jutiklių diskretizavimo dažnis yra artimas tremoro dažnių juostai, tačiau išmanieji įrenginiai ne visada suteikia galimybę jį kontroliuoti. Prieš naudojant duomenis būtina atlikti diskretizavimo dažnio keitimo procesą. Tremoro vertinimui pakankamas 36 Hz diskretizavimo dažnis.
3. Sėkmingas tremoro kvantavimas (regresijos užduotis) realizuotas naudojant lietimo jutiklio ir akselerometro duomenų savybes atskirai ir kartu. Modelių treniravimui naudota 440 pavyzdžių imtis, kuri buvo sužymėta 1 ET ir 3 CP pacientų skalėje 0 (blogai / stipriausias tremoras) – 10 (gerai/ nėra tremoro). Vertinimas lietimo jutikliu atskirai davė geresnius rezultatus nei akselerometru atskirai, tačiau geriausius rezultatus pavyko pasiekti suliejus abiejų jutiklių duomenis į bendrą savybių imtį. XGBoost siekė vidutiniškai geresnius rezultatus nei MLP ties tuo pačiu savybių skaičiumi. Didesnis savybių skaičius asocijuojasi su geresniais modelių įverčiais. Dažnių srities savybės yra svarbesnės už laiko srities savybes. Trumpojo laiko spektrinės savybės (*spc*), atsižvelgiant į didžiulį skaičiavimo ir atminties resursų poreikį joms gauti, nepasiteisino – jos svarbumo tyrimuose neužėmė svarbių pozicijų. Svarbiausia savybė – galia 3- 12 Hz ar 3 – 16 Hz juostose. Geriausias modelis: XGBoost su visų savybių aibe (abu jutikliai). Apskaičiuota vidutinė absoliuti paklaida $MAE = 0.58$, šaknis iš vidutinės kvadratinės paklaidos $RMSE = 0.79$.
4. Diagnozės užduotį (klasifikaciją į CP, ET, PD grupes) pavyko pasiekti tiek XGBoost, tiek MLP algoritmais. Geriausias modelis (MLP), naudojant visų savybių abiem jutikliais aibę, padarė tik 1 klaidingą įvertinimą iš 79 pavyzdžių imties. Rezultatai: plotas po TPR/FPR kreive $AUC = 1.00$, Koheno kappa koeficientas $KAP = 0.98$. Nors naudota stratifikuota kryžminė validacija, aukšti rezultatai gali signalizuoti modelių perteklinį persimokymą. Objektiviam įvertinimui būtina didesnė imtis. Pastebėta, kad akselerometro savybės daug mažiau svarbios nei lietimo jutiklio savybės. Dažnių srities savybės svarbesnės už laiko srities savybes. Didesnis savybių kiekis lėmė geresnius rezultatus.
5. Sukurta priemonė turi potencialų teigiamą efektą mažinant ekonominę ET ir PD naštą. PD atveju didžiausia nauda pasireiškia klaidingų diagnozių mažinimo srityje. Ji įvertinta nuo 2.16 mlrd. iki 3.24 mlrd. dolerių. Ankstyvosios diagnozės potencialas įvertintas 1.94 mlrd. dolerių. Taip pat apskaičiuota potenciali nauda mažinant mirtingumo rodiklius (25.5 mln. dolerių iki 2037 m.) ir

optimizuojant medicininės apžiūros darbo laiką (nuo 2.9 mln. iki 19.02 mln.). ET atveju klaidingos diagnozės įvertinimas persidengia su PD, tačiau išskirtas atskiras ET ir distonijos sumaišymo atvejis, įvertintas 10.39 mln. dolerių metams JAV. Medicininės apžiūros laiko optimizavimas ET atveju įvertintas nuo 1.44 mln. iki 9.46 mln. dolerių kasmet. Praktikoje tikroji ekonominė nauda priklauso nuo priemonės adaptacijos rinkoje. Taip pat nuo to, kokią tikrąją dalį medicinos profesionalų darbo galima pakeisti pasiūlytos priemonės funkcionalumu.

Literatūros sąrašas

1. Lenka A and Jankovic J (2021) Tremor Syndromes: An Updated Review. *Front. Neurol.* 12:684835. doi: 10.3389/fneur.2021.684835
2. Thanvi, B., Lo, N., & Robinson, T. (2006). Essential tremor—the most common movement disorder in older people. *Age and Ageing*, 35(4), 344–349. doi:10.1093/ageing/afj072
3. Song P, Zhang Y, ZHa M, Yang Q, Ye X, Yi Q, Rudan I; Global Health Epidemiology Reference Group (GHERG). The global prevalence of essential tremor, with emphasis on age and sex: A meta-analysis. *J Glob Health* 2021;11:04029.
4. Hirsch, L., Jette, N., Frolkis, A., Steeves, T., & Pringsheim, T. (2016). The Incidence of Parkinson's Disease: A Systematic Review and Meta-Analysis. *Neuroepidemiology*, 46(4), 292–300. doi:10.1159/000445751
5. Yang, W., Hamilton, J. L., Kopil, C., Beck, J. C., Tanner, C. M., Albin, R. L., ... Thompson, T. (2020). Current and projected future economic burden of Parkinson's disease in the U.S. *Npj Parkinson's Disease*, 6(1). doi:10.1038/s41531-020-0117-1
6. Rizzo, G., Copetti, M., Arcuti, S., Martino, D., Fontana, A., & Logroscino, G. (2016). Accuracy of clinical diagnosis of Parkinson disease. *Neurology*, 86(6), 566–576. doi:10.1212/wnl.0000000000002350
7. Lew, M. (2007). Overview of Parkinson's Disease. *Pharmacotherapy*, 27(12 Part 2), 155S–160S. doi:10.1592/phco.27.12part2.155s
8. Chandran, V., & Pal, P. (2013). Quality of life and its determinants in essential tremor. *Parkinsonism & Related Disorders*, 19(1), 62-65. doi: 10.1016/j.parkreldis.2012.06.011
9. Louis, E., & Machado, D. (2015). Tremor-related quality of life: A comparison of essential tremor vs. Parkinson's disease patients. *Parkinsonism & Related Disorders*, 21(7), 729-735. doi: 10.1016/j.parkreldis.2015.04.019
10. Ondo, W., Hashem, V., LeWitt, P., Pahwa, R., Shih, L., & Tarsy, D. et al. (2017). Comparison of the Fahn-Tolosa-Marin Clinical Rating Scale and the Essential Tremor Rating Assessment Scale. *Movement Disorders Clinical Practice*, 5(1), 60-65. doi: 10.1002/mdc3.12560.
11. Elble, R., & Ondo, W. (2022). Tremor rating scales and laboratory tools for assessing tremor. *Journal Of The Neurological Sciences*, 435, 120202. doi: 10.1016/j.jns.2022.120202
12. Deuschl, G., Bain, P., & Brin, M. (2008). Consensus Statement of the Movement Disorder Society on Tremor. *Movement Disorders*, 13(S3), 2–23. doi:10.1002/mds.870131303
13. Zhang B, Huang F, Liu J and Zhang D (2018) A Novel Posture for Better Differentiation Between Parkinson's Tremor and Essential Tremor. *Front. Neurosci.* 12:317. doi: 10.3389/fnins.2018.00317
14. Shawen, N., O'Brien, M.K., Venkatesan, S. et al. Role of data measurement characteristics in the accurate detection of Parkinson's disease symptoms using wearable sensors. *J NeuroEngineering Rehabil* 17, 52 (2020). <https://doi.org/10.1186/s12984-020-00684-4>
15. Farkas, Z., Csillik, A., Szirmai, I., & Kamondi, A. (2006). Asymmetry of tremor intensity and frequency in Parkinson's disease and essential tremor. *Parkinsonism & Related Disorders*, 12(1), 49–55. doi:10.1016/j.parkreldis.2005.07.008
16. Ondo, W., Hashem, V., LeWitt, P., Pahwa, R., Shih, L., & Tarsy, D. et al. (2017). Comparison of the Fahn-Tolosa-Marin Clinical Rating Scale and the Essential Tremor Rating Assessment Scale. *Movement Disorders Clinical Practice*, 5(1), 60-65. doi: 10.1002/mdc3.12560.






17. Elble, R., & Ondo, W. (2022). Tremor rating scales and laboratory tools for assessing tremor. *Journal Of The Neurological Sciences*, 435, 120202. doi: 10.1016/j.jns.2022.120202
18. L. di Biase, J.S. Brittain, S.A. Shah, D.J. Pedrosa, H. Cagnan, A. Mathy, C.C. Chen, J.F. Martin-Rodriguez, P. Mir, L. Timmerman, P. Schwingenschuh, K. Bhatia, V. Di Lazzaro, P. Brown, Tremor stability index: a new tool for differential diagnosis in tremor syndromes, *Brain* 140 (7) (2017) 1977-1986, <https://doi.org/10.1093/brain/awx104>.
19. Oktay, A. B., & Kocer, A. (2020). Differential diagnosis of parkinson and essential tremor with convolutional LSTM Networks. *Biomedical Signal Processing and Control*, 56, 101683. <https://doi.org/10.1016/j.bspc.2019.101683>
20. Grimaldi, G., & Manto, M. (2010). Neurological Tremor: Sensors, Signal Processing and Emerging Applications. *Sensors*, 10(2), 1399-1422. doi: 10.3390/s100201399
21. Dai, H., Zhang, P., & Lueth, T. (2015). Quantitative Assessment of Parkinsonian Tremor Based on an Inertial Measurement Unit. *Sensors*, 15(10), 25055-25071. doi: 10.3390/s151025055
22. Rigas, G., Tzallas, A., Tsipouras, M., Bougia, P., Tripoliti, E., & Baga, D. et al. (2012). Assessment of Tremor Activity in the Parkinson's Disease Using a Set of Wearable Sensors. *IEEE Transactions On Information Technology In Biomedicine*, 16(3), 478-487. doi: 10.1109/titb.2011.2182616
23. LeMoyne, R., & Mastroianni, T. (2014). Use of Smartphones and Portable Media Devices for Quantifying Human Movement Characteristics of Gait, Tendon Reflex Response, and Parkinson's Disease Hand Tremor. *Mobile Health Technologies*, 335-358. doi:10.1007/978-1-4939-2172-0_23
24. Kostikis, Nikolaos; Hristu-Varsakelis, Dimitrios; Arnaoutoglou, Marianthi; Kotsavasiloglou, Christos (2015). A Smartphone-based Tool for Assessing Parkinsonian Hand Tremor. *IEEE Journal of Biomedical and Health Informatics*, (), 1-1. doi:10.1109/JBHI.2015.2471093
25. Majumder, S., & Deen, M. J. (2019). Smartphone Sensors for Health Monitoring and Diagnosis. *Sensors*, 19(9), 2164. doi:10.3390/s19092164
26. Scott M. Lundberg and Su-In Lee. 2017. A unified approach to interpreting model predictions. In *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17)*. Curran Associates Inc., Red Hook, NY, USA, 4768-4777.
27. Wang, W., Xie, L., & Wang, X. (2017). Tremor detection using smartphone-based acoustic sensing. *Proceedings of the 2017 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2017 ACM International Symposium on Wearable Computers on - UbiComp '17*. doi:10.1145/3123024.3123168
28. Ba, Zhongjie & Zheng, Tianhang & Zhang, Xinyu & Qin, Zhan & Li, Baochun & Liu, Xue & Ren, Kaili. (2020). Learning-based Practical Smartphone Eavesdropping with Built-in Accelerometer. 10.14722/ndss.2020.24076.
29. Heinzl, G., Rüdiger, A., & Schilling, R. (2002). Spectrum and spectral density estimation by the Discrete Fourier transform (DFT), including a comprehensive list of window functions and some new at-top windows.
30. Zhang, L., Koesmahargyo, V., & Galatzer-Levy, I. (2021). Estimation of Clinical Tremor using Spatio-Temporal Adversarial AutoEncoder. 2020 25th International Conference on Pattern Recognition (ICPR). doi:10.1109/icpr48806.2021.94129
31. Burkov, A. (2019) *The Hundred-Page Machine Learning Book*. 159.








32. Wile, D. J., Ranawaya, R., & Kiss, Z. H. T. (2014). Smart watch accelerometry for analysis and diagnosis of tremor. *Journal of Neuroscience Methods*, 230, 1–4. doi:10.1016/j.jneumeth.2014.04.021
33. Sun, Minglong et al. "TremorSense: Tremor Detection for Parkinson's Disease Using Convolutional Neural Network." 2021 IEEE/ACM Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE) (2021): 1-10.
34. Kuosmanen E, Wolling F, Vega J, Kan V, Nishiyama Y, Harper S, Van Laerhoven K, Hosio S, Ferreira D. Smartphone-Based Monitoring of Parkinson Disease: Quasi-Experimental Study to Quantify Hand Tremor Severity and Medication Effectiveness. *JMIR Mhealth Uhealth*. 2020 Nov 26;8(11):e21543. doi: 10.2196/21543. PMID: 33242017; PMCID: PMC7728543.
35. Solé-Casals J, Anchustegui-Echearte I, Marti-Puig P, Calvo PM, Bergareche A, Sánchez-Méndez JI and Lopez-de-Ipina K (2019) Discrete Cosine Transform for the Analysis of Essential Tremor. *Front. Physiol.* 9:1947. doi: 10.3389/fphys.2018.01947
36. Bernardo, Lucas Salvador, Damaševičius, Robertas, De Albuquerque, Victor Hugo C. and Maskeliūnas, Rytis. "A hybrid two-stage SqueezeNet and support vector machine system for Parkinson's disease detection based on handwritten spiral patterns" *International Journal of Applied Mathematics and Computer Science*, vol.31, no.4, 2021, pp.549-561. <https://doi.org/10.34768/amcs-2021-0037>
37. Willis AW, Schootman M, Evanoff BA, Perlmutter JS, Racette BA. Neurologist care in Parkinson disease: a utilization, outcomes, and survival study. *Neurology*. 2011 Aug 30;77(9):851-7. doi: 10.1212/WNL.0b013e31822c9123. Epub 2011 Aug 10. PMID: 21832214; PMCID: PMC3162639.
38. Riggare S, Höglund PJ, Hvitfeldt Forsberg H, Eftimovska E, Svenningsson P, Hägglund M. Patients are doing it for themselves: A survey on disease-specific knowledge acquisition among people with Parkinson's disease in Sweden. *Health Informatics J*. 2019 Mar;25(1):91-105. doi: 10.1177/1460458217704248. Epub 2017 Apr 23. PMID: 28434277; PMCID: PMC6376604.
39. Gupta, H.V. et al. (2021) "Exploring essential tremor: Results from a large online survey," *Clinical Parkinsonism & Related Disorders*, 5, p. 100101. Available at: <https://doi.org/10.1016/j.prdoa.2021.100101>.
40. Eurostat, the statistical office of the European Union, ICT usage in households and by individuals, G4: Innovation and digitalisation, 2920 Luxembourg, 03/01/2023. Pasiekama per https://ec.europa.eu/eurostat/databrowser/view/ISOC_CI_DEV_I/default/table?lang=en&category=i.soc.isoc_i.isoc_ici.
41. Kovach, Christopher & Gander, Phillip. (2016). The demodulated band transform. *Journal of Neuroscience Methods*. In Press. 10.1016/j.jneumeth.2015.12.004.
42. Proakis, J.G., and Manolakis, D.G. (2007). *Digital Signal Processing: Principles, Algorithms, and Applications*, 4th ed., Prentice Hall, Chap. 6.
43. Oppenheim, A.V., Schaffer, R.W., and Buck, J.R. (1999). *Discrete-time signal processing*, Signal processing series, Prentice-Hall.
44. Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). New York, NY, USA: ACM. <https://doi.org/10.1145/2939672.2939785>
45. U.S. Bureau of Labor Statistics. (2023, April 25). *Neurologists*. U.S. Bureau of Labor Statistics. <https://www.bls.gov/oes/current/oes291217.htm>




46. Tinelli, Michela & Kanavos, Panos & Grimaccia, Federico. (2016). THE VALUE OF EARLY DIAGNOSIS AND TREATMENT IN PARKINSON'S DISEASE.
47. Dai, D., A. Samiian, Fernandes, J., & H. Coetzer. (2022). Multiple Comorbidities, Psychiatric Disorders, Healthcare Resource Utilization and Costs Among Adults with Essential Tremor: A Retrospective Observational Study in a Large US Commercially Insured and Medicare Advantage Population. 9(2). <https://doi.org/10.36469/001c.37307>
48. Kapinos, K. A., & Louis, E. D. (2022). Annual health care costs among Medicare Beneficiaries with essential tremor. 104, 26–29. <https://doi.org/10.1016/j.parkreldis.2022.09.015>
49. Vetterick, C., Lyons, K. E., Matthews, L. G., Pendal, R., & Ravina, B. (2022). The Hidden Burden of Disease and Treatment Experiences of Patients with Essential Tremor: A Retrospective Claims Data Analysis. 39(12), 5546–5567. <https://doi.org/10.1007/s12325-022-02318-8>
50. Welton T, Cardoso F, Carr JA, Chan LL, Deuschl G, Jankovic J, Tan EK. Essential tremor. Nat Rev Dis Primers. 2021 Nov 11;7(1):83. doi: 10.1038/s41572-021-00314-w. PMID: 34764294.
51. De, C., & Dominic, R. (2019). Cost-Analysis of the Different Treatment Modalities in X-Linked Dystonia–Parkinsonism. 10. <https://doi.org/10.3389/fneur.2019.00500>





Priedai





1 priedas. Savybių vektorius (akselerometro duomenys). Rikiavimas mažėjančia eiga pagal Pearsono koreliacijos koeficientą su tikslo kintamuoju „label“ (kvantavimo užduotis). Čia μ (σ) – vidurkis (standartinis nuokrypis), *min.* – minimali vertė, *med.* – mediana, *max.* – maksimali vertė, *IQR* – tarpkvartilinis intervalas, *CV* – variacijos koeficientas.




Nr.	Savybė	Statistika	Pasiskirstymas
1	label	μ (σ): 6.1 (2.4) $\min \leq \text{med} \leq \text{max}$: $1 \leq 6 \leq 10$ <i>IQR</i> (<i>CV</i>): 3 (0.4)	
2	pwr.mean.4.8.log	μ (σ): -1 (1.3) $\min \leq \text{med} \leq \text{max}$: $-5.6 \leq -1.4 \leq 3.7$ <i>IQR</i> (<i>CV</i>): 1.7 (-1.3)	
3	pwr.median.4.8.log	μ (σ): -1 (1.3) $\min \leq \text{med} \leq \text{max}$: $-5.5 \leq -1.3 \leq 3.8$ <i>IQR</i> (<i>CV</i>): 1.6 (-1.3)	
4	pwr.4.8.log	μ (σ): -240.8 (277.2) $\min \leq \text{med} \leq \text{max}$: $-1015.7 \leq -315.5 \leq 673.6$ <i>IQR</i> (<i>CV</i>): 379.3 (-1.2)	
5	pwr.mean.3.12.log	μ (σ): -1.6 (1.3) $\min \leq \text{med} \leq \text{max}$: $-5.6 \leq -1.9 \leq 3$ <i>IQR</i> (<i>CV</i>): 1.5 (-0.8)	
6	pwr.median.3.12.log	μ (σ): -1.6 (1.2) $\min \leq \text{med} \leq \text{max}$: $-5.6 \leq -1.9 \leq 3.1$ <i>IQR</i> (<i>CV</i>): 1.3 (-0.8)	






7	pwr.mean.3.16.log	μ (σ): -2 (1.2) $\min \leq \text{med} \leq \max$: $-5.6 \leq -2.3 \leq 2.5$ IQR (CV): 1.4 (-0.6)	
8	pwr.mean.1.18.log	μ (σ): -2.1 (1.2) $\min \leq \text{med} \leq \max$: $-5.6 \leq -2.4 \leq 2.3$ IQR (CV): 1.3 (-0.6)	
9	pwr.3.12.log	μ (σ): -822.2 (600.4) $\min \leq \text{med} \leq \max$: $-2289.6 \leq -944.4 \leq 1209.2$ IQR (CV): 778.4 (-0.7)	
10	pwr.median.3.16.log	μ (σ): -2 (1.2) $\min \leq \text{med} \leq \max$: $-5.6 \leq -2.3 \leq 2.4$ IQR (CV): 1.4 (-0.6)	
11	pwr.median.1.18.log	μ (σ): -2.1 (1.2) $\min \leq \text{med} \leq \max$: $-5.6 \leq -2.4 \leq 2.2$ IQR (CV): 1.3 (-0.6)	
12	pwr.3.16.log	μ (σ): -1464.7 (849.5) $\min \leq \text{med} \leq \max$: $-3299.6 \leq -1665.7 \leq 1472.9$ IQR (CV): 1083 (-0.6)	
13	pwr.1.18.log	μ (σ): -1995.2 (1080) $\min \leq \text{med} \leq \max$: $-4308 \leq -2246.1 \leq 1761.7$ IQR (CV): 1333.6 (-0.5)	








14	spc.pwr.mean	μ (σ): 27.8 (59.4) $\min \leq \text{med} \leq \max$: $0.4 \leq 8.2 \leq 438.6$ IQR (CV): 17.6 (2.1)	
15	pwr.std.1.18	μ (σ): 1.1 (2.8) $\min \leq \text{med} \leq \max$: $0 \leq 0.2 \leq 22.2$ IQR (CV): 0.7 (2.5)	
16	pwr.std.3.12	μ (σ): 1.3 (3.2) $\min \leq \text{med} \leq \max$: $0 \leq 0.2 \leq 25.2$ IQR (CV): 1 (2.5)	
17	pwr.std.3.16	μ (σ): 1.1 (2.9) $\min \leq \text{med} \leq \max$: $0 \leq 0.2 \leq 24$ IQR (CV): 0.8 (2.5)	
18	mean.abs	μ (σ): 13.2 (5.4) $\min \leq \text{med} \leq \max$: $10.2 \leq 11.7 \leq 47$ IQR (CV): 1.2 (0.4)	
19	std	μ (σ): 2.9 (6.1) $\min \leq \text{med} \leq \max$: $0.2 \leq 1.1 \leq 43.1$ IQR (CV): 1.3 (2.1)	
20	pwr.std.4.8	μ (σ): 1.3 (3.1) $\min \leq \text{med} \leq \max$: $0 \leq 0.3 \leq 26$ IQR (CV): 1.2 (2.4)	








21	pwr.1.18	μ (σ): 649.8 (1647.4) $\min \leq \text{med} \leq \max$: $3.3 \leq 154.4 \leq 14509.4$ IQR (CV): 362.8 (2.5)	
22	spc.pwr.max	μ (σ): 51.8 (110.4) $\min \leq \text{med} \leq \max$: $1.7 \leq 20.6 \leq 966.3$ IQR (CV): 30.6 (2.1)	
23	spc.f.c.min	μ (σ): 5.6 (0.5) $\min \leq \text{med} \leq \max$: $3.5 \leq 5.7 \leq 8.3$ IQR (CV): 0.5 (0.1)	
24	pwr.3.12	μ (σ): 507.4 (1307) $\min \leq \text{med} \leq \max$: $1.7 \leq 111.7 \leq 12172.7$ IQR (CV): 306.1 (2.6)	
25	pwr.3.16	μ (σ): 552.1 (1417.8) $\min \leq \text{med} \leq \max$: $2.5 \leq 125.7 \leq 13065.5$ IQR (CV): 327.1 (2.6)	
26	spc.pwr.min	μ (σ): 12.1 (25.1) $\min \leq \text{med} \leq \max$: $0.1 \leq 4.3 \leq 237.7$ IQR (CV): 7.1 (2.1)	
27	pwr.mean.1.18	μ (σ): 0.8 (2.1) $\min \leq \text{med} \leq \max$: $0 \leq 0.2 \leq 18.9$ IQR (CV): 0.4 (2.7)	








28	pwr.mean.3.12	μ (σ): 1.1 (3.2) $\min \leq \text{med} \leq \max$: $0 \leq 0.2 \leq 29.9$ IQR (CV): 0.6 (2.8)	
29	pwr.mean.3.16	μ (σ): 0.9 (2.4) $\min \leq \text{med} \leq \max$: $0 \leq 0.2 \leq 22.3$ IQR (CV): 0.4 (2.8)	
30	pwr.4.8	μ (σ): 334.5 (859.1) $\min \leq \text{med} \leq \max$: $0.8 \leq 75.2 \leq 8776.3$ IQR (CV): 264.6 (2.6)	
31	max.diff	μ (σ): 12.6 (18.5) $\min \leq \text{med} \leq \max$: $1.2 \leq 7.7 \leq 140.2$ IQR (CV): 3.5 (1.5)	
32	pwr.std.1.18.log	μ (σ): 1 (0.2) $\min \leq \text{med} \leq \max$: $0.5 \leq 1 \leq 1.4$ IQR (CV): 0.3 (0.2)	
33	max	μ (σ): 23.5 (20.9) $\min \leq \text{med} \leq \max$: $11.3 \leq 18.3 \leq 195$ IQR (CV): 5.5 (0.9)	
34	pwr.median.1.18	μ (σ): 0.4 (1.1) $\min \leq \text{med} \leq \max$: $0 \leq 0.1 \leq 8.8$ IQR (CV): 0.2 (2.8)	








35	max.top.5	μ (σ): 108.7 (94.9) $\min \leq \text{med} \leq \max$: $55.1 \leq 84.9 \leq 877.5$ IQR (CV): 24 (0.9)	
36	spc.pwr.disp.0.25.max	μ (σ): 0.3 (0.1) $\min \leq \text{med} \leq \max$: $0.1 \leq 0.3 \leq 0.5$ IQR (CV): 0.2 (0.3)	
37	pwr.entropy.3.12	μ (σ): 5.8 (0.2) $\min \leq \text{med} \leq \max$: $5.1 \leq 5.8 \leq 6.1$ IQR (CV): 0.3 (0)	
38	pwr.median.3.16	μ (σ): 0.5 (1.3) $\min \leq \text{med} \leq \max$: $0 \leq 0.1 \leq 11.2$ IQR (CV): 0.2 (2.9)	
39	pwr.mean.4.8	μ (σ): 1.7 (4.7) $\min \leq \text{med} \leq \max$: $0 \leq 0.3 \leq 48.5$ IQR (CV): 1.1 (2.8)	
40	spc.pwr.std	μ (σ): 12.5 (29.6) $\min \leq \text{med} \leq \max$: $0.6 \leq 5 \leq 285.5$ IQR (CV): 6.8 (2.4)	
41	max.top.fd	μ (σ): 707.1 (655.6) $\min \leq \text{med} \leq \max$: $408.2 \leq 535.2 \leq 5769.1$ IQR (CV): 150.8 (0.9)	




42	f.c.3.16	$\mu (\sigma)$: 6.4 (0.8) $\min \leq \text{med} \leq \max$: $3.9 \leq 6.3 \leq 10.2$ IQR (CV): 0.7 (0.1)	
43	spc.pwr.disp.0.25.mean	$\mu (\sigma)$: 0.2 (0.1) $\min \leq \text{med} \leq \max$: $0.1 \leq 0.2 \leq 0.4$ IQR (CV): 0.1 (0.4)	
44	pwr.median.3.12	$\mu (\sigma)$: 0.7 (2.3) $\min \leq \text{med} \leq \max$: $0 \leq 0.1 \leq 23.3$ IQR (CV): 0.3 (3.1)	
45	pwr.cos.1.18	$\mu (\sigma)$: 0.8 (0.1) $\min \leq \text{med} \leq \max$: $0.6 \leq 0.8 \leq 1$ IQR (CV): 0.1 (0.1)	
46	pwr.median.4.8	$\mu (\sigma)$: 1.3 (4.1) $\min \leq \text{med} \leq \max$: $0 \leq 0.3 \leq 46$ IQR (CV): 0.6 (3.1)	
47	f.c.3.12	$\mu (\sigma)$: 6.1 (0.6) $\min \leq \text{med} \leq \max$: $3.9 \leq 6 \leq 9.1$ IQR (CV): 0.4 (0.1)	
48	disp.0.1	$\mu (\sigma)$: 0.1 (0) $\min \leq \text{med} \leq \max$: $0 \leq 0.1 \leq 0.3$ IQR (CV): 0.1 (0.5)	








49	max.diff.top.5	μ (σ): 35.6 (43) $\min \leq \text{med} \leq \text{max}$: $-379.6 \leq 45.1 \leq 124.5$ IQR (CV): 15.3 (1.2)	
50	pwr.cos.3.16	μ (σ): 0.8 (0.1) $\min \leq \text{med} \leq \text{max}$: $0.7 \leq 0.8 \leq 1$ IQR (CV): 0.1 (0.1)	
51	f.c.1.18	μ (σ): 6 (0.8) $\min \leq \text{med} \leq \text{max}$: $3.3 \leq 6 \leq 10.1$ IQR (CV): 0.5 (0.1)	
52	pwr.std.3.12.log	μ (σ): 0.9 (0.2) $\min \leq \text{med} \leq \text{max}$: $0.6 \leq 0.9 \leq 1.3$ IQR (CV): 0.3 (0.2)	
53	disp.0.25	μ (σ): 0.2 (0.1) $\min \leq \text{med} \leq \text{max}$: $0.1 \leq 0.2 \leq 0.4$ IQR (CV): 0.1 (0.4)	
54	disp.0.5	μ (σ): 0.2 (0.1) $\min \leq \text{med} \leq \text{max}$: $0.1 \leq 0.2 \leq 0.4$ IQR (CV): 0.1 (0.4)	
55	disp.0.1.log	μ (σ): 0 (0) $\min \leq \text{med} \leq \text{max}$: $0 \leq 0 \leq 0.1$ IQR (CV): 0 (0.1)	








56	pwr.cos.3.12	$\mu (\sigma)$: 0.9 (0.1) $\min \leq \text{med} \leq \max$: $0.7 \leq 0.9 \leq 1$ IQR (CV): 0.1 (0.1)	
57	disp.0.03	$\mu (\sigma)$: 0 (0) $\min \leq \text{med} \leq \max$: $0 \leq 0 \leq 0.1$ IQR (CV): 0 (0.5)	
58	pwr.entropy.4.8	$\mu (\sigma)$: 5.1 (0.1) $\min \leq \text{med} \leq \max$: $4.7 \leq 5.2 \leq 5.4$ IQR (CV): 0.2 (0)	
59	spc.pwr.disp.0.25.std	$\mu (\sigma)$: 0.1 (0) $\min \leq \text{med} \leq \max$: $0 \leq 0 \leq 0.1$ IQR (CV): 0 (0.4)	
60	spc.f.peak.mean	$\mu (\sigma)$: 5.8 (0.8) $\min \leq \text{med} \leq \max$: $3.3 \leq 5.7 \leq 10$ IQR (CV): 0.4 (0.1)	
61	spc.pwr.disp.0.25.min	$\mu (\sigma)$: 0.2 (0.1) $\min \leq \text{med} \leq \max$: $0.1 \leq 0.1 \leq 0.4$ IQR (CV): 0.1 (0.4)	
62	pwr.peak.3.16.log	$\mu (\sigma)$: 5.7 (1.1) $\min \leq \text{med} \leq \max$: $3 \leq 5.7 \leq 11.9$ IQR (CV): 0.6 (0.2)	








63	pwr.peak.3.16	μ (σ): 5.7 (1.1) $\min \leq \text{med} \leq \max$: $3 \leq 5.7 \leq 11.9$ IQR (CV): 0.6 (0.2)	
64	f.peak.3.16	μ (σ): 5.7 (1.1) $\min \leq \text{med} \leq \max$: $3 \leq 5.7 \leq 11.9$ IQR (CV): 0.6 (0.2)	
65	f.peak.3.12.log	μ (σ): 5.7 (1.1) $\min \leq \text{med} \leq \max$: $3 \leq 5.7 \leq 11.9$ IQR (CV): 0.6 (0.2)	
66	pwr.peak.1.18.log	μ (σ): 5.7 (1.1) $\min \leq \text{med} \leq \max$: $3 \leq 5.7 \leq 11.9$ IQR (CV): 0.6 (0.2)	
67	pwr.peak.3.12.log	μ (σ): 5.7 (1.1) $\min \leq \text{med} \leq \max$: $3 \leq 5.7 \leq 11.9$ IQR (CV): 0.6 (0.2)	
68	pwr.peak.4.8.log	μ (σ): 5.7 (1.1) $\min \leq \text{med} \leq \max$: $3 \leq 5.7 \leq 11.9$ IQR (CV): 0.6 (0.2)	
69	f.peak.3.12	μ (σ): 5.7 (1.1) $\min \leq \text{med} \leq \max$: $3 \leq 5.7 \leq 11.9$ IQR (CV): 0.6 (0.2)	








70	pwr.peak.1.18	μ (σ): 5.7 (1.1) $\min \leq \text{med} \leq \max$: $3 \leq 5.7 \leq 11.9$ IQR (CV): 0.6 (0.2)	
71	pwr.peak.3.12	μ (σ): 5.7 (1.1) $\min \leq \text{med} \leq \max$: $3 \leq 5.7 \leq 11.9$ IQR (CV): 0.6 (0.2)	
72	pwr.peak.4.8	μ (σ): 5.7 (1.1) $\min \leq \text{med} \leq \max$: $3 \leq 5.7 \leq 11.9$ IQR (CV): 0.6 (0.2)	
73	disp.1.0	μ (σ): 0.5 (0.1) $\min \leq \text{med} \leq \max$: $0.1 \leq 0.4 \leq 0.7$ IQR (CV): 0.2 (0.3)	
74	spc.f.peak.max	μ (σ): 7 (1.4) $\min \leq \text{med} \leq \max$: $4.1 \leq 6.6 \leq 11.9$ IQR (CV): 1 (0.2)	
75	f.h.3.16	μ (σ): 11.5 (2.1) $\min \leq \text{med} \leq \max$: $6.1 \leq 11.5 \leq 22.5$ IQR (CV): 1.2 (0.2)	
76	f.h.3.12	μ (σ): 11.5 (2.1) $\min \leq \text{med} \leq \max$: $6.1 \leq 11.5 \leq 22.5$ IQR (CV): 1.2 (0.2)	






77	pwr.h.3.16	$\mu (\sigma)$: 0.7 (2.9) $\min \leq \text{med} \leq \max$: $0 \leq 0.1 \leq 36.4$ IQR (CV): 0.2 (4.2)	
78	pwr.h.3.12	$\mu (\sigma)$: 0.7 (2.9) $\min \leq \text{med} \leq \max$: $0 \leq 0.1 \leq 36.4$ IQR (CV): 0.2 (4.2)	
79	spc.f.c.max	$\mu (\sigma)$: 6.8 (0.8) $\min \leq \text{med} \leq \max$: $4.8 \leq 6.7 \leq 9.8$ IQR (CV): 0.7 (0.1)	
80	spc.f.c.mean	$\mu (\sigma)$: 6.8 (0.8) $\min \leq \text{med} \leq \max$: $4.8 \leq 6.7 \leq 9.8$ IQR (CV): 0.7 (0.1)	
81	pwr.h.4.8	$\mu (\sigma)$: 0.5 (2.1) $\min \leq \text{med} \leq \max$: $0 \leq 0.1 \leq 36.4$ IQR (CV): 0.2 (4.1)	
82	pwr.std.4.8.log	$\mu (\sigma)$: 0.8 (0.1) $\min \leq \text{med} \leq \max$: $0.4 \leq 0.8 \leq 1.2$ IQR (CV): 0.2 (0.2)	
83	pwr.h.1.18	$\mu (\sigma)$: 0.9 (4.5) $\min \leq \text{med} \leq \max$: $0 \leq 0.1 \leq 66.2$ IQR (CV): 0.2 (4.8)	


84	pwr.cos.4.8	$\mu (\sigma)$: 0.9 (0.1) $\min \leq \text{med} \leq \max$: $0.6 \leq 0.9 \leq 1$ IQR (CV): 0.1 (0.1)	
85	mean	$\mu (\sigma)$: 10.6 (1.6) $\min \leq \text{med} \leq \max$: $-3.1 \leq 10.9 \leq 15.5$ IQR (CV): 0.8 (0.2)	
86	disp.0.25.log	$\mu (\sigma)$: 0.1 (0) $\min \leq \text{med} \leq \max$: $0 \leq 0.1 \leq 0.1$ IQR (CV): 0 (0.1)	
87	disp.0.5.log	$\mu (\sigma)$: 0.1 (0) $\min \leq \text{med} \leq \max$: $0 \leq 0.1 \leq 0.1$ IQR (CV): 0 (0.1)	
88	cor.mean	$\mu (\sigma)$: 0.7 (0.2) $\min \leq \text{med} \leq \max$: $0 \leq 0.7 \leq 1$ IQR (CV): 0.4 (0.3)	
89	cor.xy	$\mu (\sigma)$: 0.7 (0.2) $\min \leq \text{med} \leq \max$: $0 \leq 0.7 \leq 1$ IQR (CV): 0.4 (0.3)	
90	pwr.clarity.1.18	$\mu (\sigma)$: 0.1 (0.1) $\min \leq \text{med} \leq \max$: $0 \leq 0.1 \leq 0.7$ IQR (CV): 0 (0.9)	

91	f.c.4.8	$\mu (\sigma)$: 5.8 (0.3) $\min \leq \text{med} \leq \max$: $4.7 \leq 5.8 \leq 6.6$ IQR (CV): 0.3 (0)	
92	spc.f.peak.std	$\mu (\sigma)$: 0.7 (0.6) $\min \leq \text{med} \leq \max$: $0.1 \leq 0.6 \leq 3.1$ IQR (CV): 0.7 (0.8)	
93	sum	$\mu (\sigma)$: 13065.9 (2474.6) $\min \leq \text{med} \leq \max$: $-4517.9 \leq 12843.1 \leq 27145.6$ IQR (CV): 1514.6 (0.2)	
94	pwr.clarity.3.12	$\mu (\sigma)$: 0.2 (0.2) $\min \leq \text{med} \leq \max$: $0.1 \leq 0.2 \leq 1.3$ IQR (CV): 0.2 (0.6)	
95	f.c.3.16.log	$\mu (\sigma)$: 8.4 (0.4) $\min \leq \text{med} \leq \max$: $7.4 \leq 8.4 \leq 9.5$ IQR (CV): 0.5 (0)	
96	disp.0.03.log	$\mu (\sigma)$: 0 (0) $\min \leq \text{med} \leq \max$: $0 \leq 0 \leq 0$ IQR (CV): 0 (0.2)	
97	pwr.clarity.3.16	$\mu (\sigma)$: 0.2 (0.1) $\min \leq \text{med} \leq \max$: $0 \leq 0.2 \leq 1$ IQR (CV): 0.1 (0.6)	

98	cor.yz	$\mu (\sigma)$: 0.5 (0.2) $\min \leq \text{med} \leq \max$: $0 \leq 0.4 \leq 0.9$ IQR (CV): 0.3 (0.4)	
99	f.c.3.12.log	$\mu (\sigma)$: 7 (0.2) $\min \leq \text{med} \leq \max$: $6.5 \leq 6.9 \leq 7.7$ IQR (CV): 0.2 (0)	
100	f.peak.4.8.log	$\mu (\sigma)$: 5.7 (0.7) $\min \leq \text{med} \leq \max$: $4 \leq 5.8 \leq 7.8$ IQR (CV): 0.6 (0.1)	
101	f.peak.4.8	$\mu (\sigma)$: 5.7 (0.7) $\min \leq \text{med} \leq \max$: $4 \leq 5.8 \leq 7.8$ IQR (CV): 0.6 (0.1)	
102	f.h.4.8	$\mu (\sigma)$: 11.4 (1.3) $\min \leq \text{med} \leq \max$: $8 \leq 11.5 \leq 15.7$ IQR (CV): 1.1 (0.1)	
103	pwr.clarity.3.16.log	$\mu (\sigma)$: 0.2 (0.1) $\min \leq \text{med} \leq \max$: $-1 \leq 0.2 \leq 1.1$ IQR (CV): 0 (0.5)	
104	pwr.clarity.1.18.log	$\mu (\sigma)$: 0 (0) $\min \leq \text{med} \leq \max$: $-0.2 \leq 0 \leq 0.2$ IQR (CV): 0 (0.5)	

105	f.c.4.8.log	μ (σ): 5.9 (0.1) $\min \leq \text{med} \leq \max$: $5.7 \leq 5.9 \leq 6.2$ IQR (CV): 0.1 (0)	
106	disp.1.0.log	μ (σ): 0.3 (0) $\min \leq \text{med} \leq \max$: $0.1 \leq 0.3 \leq 0.4$ IQR (CV): 0 (0.1)	
107	median	μ (σ): 10.6 (1.3) $\min \leq \text{med} \leq \max$: $-2 \leq 10.6 \leq 15.7$ IQR (CV): 0.9 (0.1)	
108	f.c.1.18.log	μ (σ): 7.9 (0.4) $\min \leq \text{med} \leq \max$: $6.9 \leq 7.9 \leq 9.4$ IQR (CV): 0.6 (0.1)	
109	f.peak.1.18.log	μ (σ): 5.4 (1.5) $\min \leq \text{med} \leq \max$: $1 \leq 5.4 \leq 11.9$ IQR (CV): 0.6 (0.3)	
110	f.peak.1.18	μ (σ): 5.4 (1.5) $\min \leq \text{med} \leq \max$: $1 \leq 5.4 \leq 11.9$ IQR (CV): 0.6 (0.3)	
111	cor.xz	μ (σ): 0.2 (0.2) $\min \leq \text{med} \leq \max$: $0 \leq 0.2 \leq 0.8$ IQR (CV): 0.2 (0.7)	

112	f.h.1.18	μ (σ): 10.8 (2.9) $\min \leq \text{med} \leq \max$: $2 \leq 11.5 \leq 22.5$ IQR (CV): 1.3 (0.3)	
113	pwr.clarity.4.8	μ (σ): 0.5 (0.4) $\min \leq \text{med} \leq \max$: $0.1 \leq 0.4 \leq 3.1$ IQR (CV): 0.4 (0.8)	
114	sum.diff	μ (σ): 4.4 (4.1) $\min \leq \text{med} \leq \max$: $-35.9 \leq 4.7 \leq 37.8$ IQR (CV): 2.5 (0.9)	
115	mean.diff	μ (σ): 0 (0) $\min \leq \text{med} \leq \max$: $0 \leq 0 \leq 0$ IQR (CV): 0 (0.8)	
116	sum.diff.diff	μ (σ): -6.5 (3.3) $\min \leq \text{med} \leq \max$: $-23.3 \leq -6.7 \leq 25.2$ IQR (CV): 2.5 (-0.5)	
117	pwr.clarity.3.12.log	μ (σ): 0.1 (6.6) $\min \leq \text{med} \leq \max$: $-138.1 \leq 0.3 \leq 3$ IQR (CV): 0.1 (126.8)	
118	spc.f.c.std	μ (σ): 0.4 (0.2) $\min \leq \text{med} \leq \max$: $0.1 \leq 0.3 \leq 1.3$ IQR (CV): 0.2 (0.6)	

119	spc.f.peak.min	$\mu (\sigma)$: 4.7 (0.9) $\min \leq \text{med} \leq \max$: $2.9 \leq 4.9 \leq 9.1$ IQR (CV): 1.4 (0.2)	
120	pwr.clarity.4.8.log	$\mu (\sigma)$: 1.3 (11.4) $\min \leq \text{med} \leq \max$: $-45.2 \leq 1.1 \leq 192.1$ IQR (CV): 0.6 (9)	