



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Personalizuoto epilepsijos stebėsenos metodo sukūrimas ir tyrimas

Baigiamasis magistro projektas

Tomas Stanaitis

Projekto autorius

Dr. Andrius Petrėnas

Vadovas

Kaunas, 2020



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Personalizuoto epilepsijos stebėsenos metodo sukūrimas ir tyrimas

Baigiamasis magistro projektas

Biomedicininė inžinerija (6211EX002)

Tomas Stanaitis

Projekto autorius

Dr. Andrius Petrėnas

Vadovas

Birutė Paliakaitė

Recenzentė

Kaunas, 2020



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Tomas Stanaitis

Personalizuoto epilepsijos stebėsenos metodo sukūrimas ir tyrimas

Akademinio sąžiningumo deklaracija

Patvirtinu, kad mano, Tomo Stanaičio, baigiamasis projektas tema „personalizuoto epilepsijos stebėsenos metodo sukūrimas ir tyrimas“ yra parašytas visiškai savarankiškai ir visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs.

Aš suprantu, kad išaiškėjus nesąžiningumo faktui, man bus taikomos nuobaudos, remiantis Kauno technologijos universitete galiojančia tvarka.

Tomas Stanaitis

(vardas, pavardė)

(parašas)

Stanaitis, Tomas. Personalizuoto epilepsijos stebėsenos metodo sukūrimas ir tyrimas. Magistro baigiamasis projektas / vadovas dr. Andrius Petrėnas; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

Studijų kryptis ir sritis: Bioinžinerija, Inžinerijos mokslai.

Reikšminiai žodžiai: epilepsijos aptikimas, rezervuarinis skaičiavimas, aido būsenos dirbtinis neuroninis tinklas, mašininis mokymas, elektroencefalografija.

Kaunas, 2020. 47 p.

Santrauka

Epilepsija viena iš labiausiai paplitusių neurologinių ligų. Tarptautinė lyga prieš epilepsiją šią ligą apibrėžia kaip trumpalaikius simptomus ar požymius, pasireiškiančius dėl nenormalaus, perdėto ar sinchroniško galvos smegenų neuronų aktyvumo. Sergančiųjų gyvenimo kokybė gali būti pagerinta personalizuojant gydymą, tačiau tam reikia objektyviai ir kiekybiškai įvertinti priepuolių pasireiškimą ir organizmo atsaką į gydymą. Epilepsijos aptikimo prietaisai įgalintų tikslesnį kiekybinį priepuolių vertinimą, leidžiantį gydytojams objektyviau pritaikyti bei vertinti gydymo efektyvumą. Dėl tokių priežasčių atsiranda personalizuotos sistemos poreikis, kuri specifiskai pagal paciento simptomus apsimokytų ir galėtų aptikti epilepsijos priepuolius. Besiplečianti implantuojamų prietaisų sritis bei tobulėjanti aparatinė įranga atveria galimybes tokią sistemą įgyvendinti ir reikalauja naujų energetiskai efektyvių metodų. Šiame darbe pristatomas personalizuotas epilepsijos aptikimo iš elektroencefalografinių (EEG) signalų metodas, potencialiai tinkamas diegti į implantuojamus prietaisus. Metodą sudaro aido būsenos dirbtinis neuroninis tinklas ir kanalų skaičiaus mažinimo metodika, naudojant EEG signalo galią, linijos ilgį ir netiesinę energiją. Skaičiavimo resursų atžvilgiu efektyviu epilepsijos aptikimo metodu pasiektas 92,02 % diagnostinis tikslumas, 88,68 % jautrumas ir 95,40 % specifiskumas.

Stanaitis, Tomas. Development and research of a personalized epilepsy monitoring method. Master's Final Degree Project / supervisor Dr. Andrius Petrėnas; Faculty of Electrical and Electronics Engineering, Kaunas University of Technology.

Study field and area: Bioengineering, Engineering Science.

Keywords: epilepsy detection, reservoir computing, echo state neural network, machine learning, electroencephalography.

Kaunas, 2020. 47 pages.

Summary

Epilepsy is one of the most prevalent neurological disorder. The International League against Epilepsy defines this phenomenon as transient symptoms or signs resulting from abnormal, excessive, or synchronous activity of brain neurons. Quality of life can be improved by personalizing treatment, requiring an objective and quantitative assessment of the onset of the seizures and the body's response to treatment. Devices capable of detecting epilepsy would enable quantitative assessment of seizures, allowing physicians more objectively tailor and evaluate treatment efficiency. For such reasons, there is a need for a personalized system that is specific to the patient's symptoms and could detect epilepsy episodes. An expanding field of implantable devices and the evolving hardware open opportunities to consider the implementation of such a system and require new energy-efficient methods. This work introduces a personalized method for the detection of epilepsy from electroencephalographic (EEG) signals, potentially suitable for use in implantable devices. The method consists of an echo-state artificial neural network and a methodology to reduce the number of channels based on EEG signal power, line length, and nonlinear energy. This computationally time-efficient method for epileptic seizure detection shows diagnostic accuracy of 92,02 %, sensitivity of 88,68 % and specificity of 95,40 %.

Turinys

Paveikslų sąrašas	8
Santrumpų sąrašas	10
Įvadas.....	11
1. Epilepsijos priepuolių atpažinimo problemos analizė.....	12
1.1. Epilepsijos priepuolių tipai.....	12
1.2. Epilepsijos priepuolio fiziologija	12
1.3. Epilepsijos priepuoliui aptikti naudojamų metodų analizė	13
1.3.1. Laiko srities metodai	13
1.3.2. Dažnių srities metodai	14
1.3.3. Kombinuoti laiko ir dažnių srities metodai.....	14
1.3.4. Modeliu grįsti metodai	15
1.4. Alternatyvūs metodai.....	15
1.5. Dirbtiniai neuroniniai tinklai	15
1.6. Skyriaus išvados	16
2. Personalizuoto epilepsijos stebėsenos metodo kūrimas	17
2.1. Duomenų bazės su epilepsijos priepuoliais.....	17
2.1.1. Vaikų duomenų bazė	17
2.1.2. Naujagimių duomenų bazė	18
2.2. Personalizuota kanalų atrankos ir skaičiaus mažinimo metodika	20
2.3. Pirmojo epilepsijos priepuolio atpažinimo galimybių tyrimas.....	23
2.4. Pirminis duomenų bazių signalų apdorojimas.....	25
2.5. Aido būsenos dirbtinio neuroninio tinklo inicializavimas.....	26
2.6. Skyriaus išvados	27
3. Personalizuoto epilepsijos stebėsenos metodo parametrų parinkimo tyrimas.....	28
3.1. Parametrų parinkimo kriterijai	28
3.2. Neuronų skaičiaus įtakos tyrimas	29
3.3. Kanalų skaičiaus įtakos tyrimas	30
3.4. Apmokymo signalų trukmės įtakos tyrimas	31
3.5. Spektrinio spindulio įtakos tyrimas	32
3.6. Neuronų pralaidumo koeficiento įtakos tyrimas	33
3.7. Kitų aido būsenos dirbtinio neuroninio tinklo parametrų tyrimas.....	33
3.8. Skyriaus išvados	33
4. Personalizuoto epilepsijos stebėsenos metodo tyrimas su klinikiniais signalais.....	34
4.1. Aido būsenos dirbtinio neuroninio tinklo tyrimo su klinikiniais signalais kriterijai.....	34
4.2. Tyrimas su klinikiniais vaikų duomenų bazės signalais.....	35
4.3. Tyrimas su klinikiniais naujagimių duomenų bazės signalais	36
5. Diskusija	37
5.1. Aido būsenos dirbtinio neuroninio tinklo atsitiktinio inicializavimo įtaka	37
5.2. Energetinių sąnaudų aptarimas	38
5.3. Tolimesnis projekto vystymas	39
Išvados	40
Literatūros sąrašas	41
Priedai.....	43
1 priedas. Metoduose naudotos vaikų duomenų bazės aprašas.....	43

2	priedas. Metoduose naudotos naujagimių duomenų bazės aprašas.....	44
3	priedas. Metodo rezultatai, naudojant vaikų duomenų bazę.	45
4	priedas. Priepuolių skaičiaus, trukmės ir diagnostinio tikslumo priklausomybės.....	46
5	priedas. Metodo rezultatai, naudojant naujagimių duomenų bazę.	47

Paveikslų sąrašas

1.1 pav. Epilepsijos priepuolio susidarymo aiškinamoji schema [9].	13
2.1 pav. Personalizuoto epilepsijos priepuolių atpažinimo metodo kūrimo seka.	17
2.2 pav. Vaikų duomenų bazės EEG kanalų išdėstymas ir žymėjimas.	18
2.3 pav. Naujagimių duomenų bazės EEG kanalų išdėstymas ir žymėjimas. Kanalas Nr.1 atitinka FP1–F7.	19
2.4 pav. Trijų anotuotojų anotacijų nesutapimo pavyzdžiai, a) pacientas Nr.1, kur pirmojo ir antrojo anotuotojo nesutapimas 0,533, pirmojo ir trečiojo 0,467, antrojo ir trečiojo 0,282 ir b) pacientas Nr. 79, su atitinkamomis nesutapimų reikšmėmis 0,556, 0,769 ir 0,683.	19
2.5 pav. EEG Signalo „chb01_21_01“ T8–P8 kanalo spektrograma. Raudonas rėmelis žymi epilepsijos dominavimo sritį, kuri pasireiškia visame nagrinėjamame dažnių ruože.	20
2.6 pav. Pacientų a) „chb01_21.edf“ ir b) „chb03_03.edf“ 18 EEG kanalų laiko srityje. Raudona linija žymi epilepsijos epizodo pradžią ir pabaigą. Raudoni intervalai žymi atkarpas, kuriuose skaičiuojamas GST.	21
2.7 pav. Raudona spalva žymi 18 GST apskaičiuotų epilepsijos intervale kiekvienam kanalui, atvejui „chb01_21.edf“. Juoda spalva žymi to paties atvejo 18 GST kreivių apskaičiuotų iš intervalo prieš pat prasidedant epilepsijos epizodui.	21
2.8 pav. a) Lokalių minimumų ir b) maksimumų parametrai apskaičiuoti 18 kanalų prieš priepuolį esančiuose epizoduose ir epilepsijos priepuolio metu.	22
2.9 pav. a) RMS ir b) linijos ilgio parametrai apskaičiuoti 18 kanalų prieš priepuolį esančiuose epizoduose ir epilepsijos priepuolio metu.	23
2.10 pav. Netiesinės energijos parametrai apskaičiuoti 18 kanalų prieš priepuolį esančiuose epizoduose ir epilepsijos priepuolio metu.	23
2.11 pav. a) Linijos ilgio ir b) netiesinės energijos parametrai vienos valandos trukmės EEG signale visiems 18 kanalų. Raudona linija apačioje žymi epilepsijos pradžią ir pabaigą.	24
2.12 pav. RMS parametrai vienos valandos trukmės EEG signale visiems 18 kanalų. Raudona linija apačioje žymi epilepsijos pradžią ir pabaigą.	24
2.13 pav. Apmokymo duomenų paruošimo schema, kur raudonai pažymėta nenaudojamo signalo atkarpa.	25
2.14 pav. Paciento Nr. 1 „chb01_21.edf“ EEG signalai paruošti apmokyti ABDNT.	25
2.15 pav. Personalizuoto epilepsijos priepuolių atpažinimo metodo, panaudojant ABDNT, schema.	26
3.1 pav. A: paciento Nr. 1 NRMSE skaičiavimo pavyzdys ABDNT mokymo rezultatams, kur a) pilka spalva- ABDNT išėjimo signalas, mėlyna spalva - medianos filtru filtruotas ABDNT išėjimo signalas b) anotuotas signalas. B: paciento Nr. 6 NRMSE skaičiavimo pavyzdys.	28
3.2 pav. ABDNT dinaminio rezervuaro neuronų skaičiaus įtakos tyrimo rezultatai. a) NRMSE paklaidos priklausomybė nuo neuronų skaičiaus ir b) vienos minutės trukmės EEG signalo skaičiavimo laiko priklausomybė nuo neuronų skaičiaus.	29
3.3 pav. Paciento #1 dinaminio rezervuaro neuronų skaičiaus įtakos tyrimo rezultatai.	30
3.4 pav. Kanalų skaičiaus įtakos NRMSE paklaidai tyrimo rezultatai. a) kanalų skaičiaus įtaka NRMSE ir b) vienos minutės EEG signalo ilgio skaičiavimo laiko priklausomybė nuo kanalų skaičiaus.	30
3.5 pav. Paciento #1 kanalų skaičiaus įtakos NRMSE paklaidai tyrimo rezultatai.	31
3.6 pav. EEG signalų kitimo įvertinimas esant skirtingam kanalų skaičiui, atliekant pagrindinių komponentų analizę.	31

3.7 pav. Apmokymo EEG signalų trukmės įtakos NRMSE paklaidai rezultatai. Rezultatai pateikti naudojant stačiakampę diagramą, kur mediana ir kvartilai skaičiuojami visai vaikų duomenų bazei.	32
3.8 pav. Spektrinio spindulio įtakos tyrimo rezultatai, atvaizduojant NRMSE paklaidos priklausomybę nuo spektrinio spindulio [0:1] ribose.	32
3.9 pav. Neuronų pralaidumo koeficiento įtakos tyrimo rezultatai, atvaizduojant pralaidumo koeficiento [0:1] ribose įtaką NRMSE paklaidai.	33
4.1 pav. Paciento Nr. 1 ROC kreivės pavyzdys, kur slenksčio vertė nustatoma remiantis <i>Youdeno</i> indeksu.	34
4.2 pav. Paciento Nr. 1 diagnostinio tikslumo, jautrumo ir specifiškumo skaičiavimo pavyzdys ABDNT rezultatams, kur a) ABDNT išėjimo signalas b) apdorotas išėjimo signalas ir c) anotuotas signalas. Diagnostinis tikslumas 96,96 %, jautrumas 95,92 % ir specifiškumas 97,95 %	35
4.3 pav. Metodo rezultatai, testavime naudojant vaikų duomenų bazę, pateikti radaro tipo grafiku. Rezultatai išrikiuoti diagnostinio tikslumo mažėjimo tvarka.	35
4.4 pav. Įgyvendinto metodo rezultatai, testavime naudojant naujagimių duomenų bazę, pateikiami radaro tipo grafiku. Rezultatai išrikiuoti diagnostinio tikslumo mažėjimo tvarka.	36
5.1 pav. Atsitiktinio inicializavimo įtaka, kai ABDNT rezervuaro dydis: a) 400 neuronų ir b) 1000 neuronų.	38
5.2 pav. Kairėje: slopinamoji sinapsė. Dešinėje: jaudinamoji sinapsė [35].	39
5.3 pav. Dirbtinio neurono aparatinis įgyvendinimas [35].	39

Santrumpų sąrašas

ABDNT	Aido būsenos dirbtinis neuroninis tinklas
EEG	Elektroencefalografija
NRMSE	Normalizuota vidutinė kvadratinė paklaida
SGT	Spektrinis galios tankis
RMS	Efektinė signalo vertė
ROC	Operatoriaus charakteringoji kreivė

Įvadas

Epilepsija viena iš labiausiai paplitusių neurologinių ligų, diagnozuota maždaug 1 % populiacijos [1]. Tarptautinė lyga prieš epilepsiją ligą apibrėžia kaip trumpalaikius simptomus ar požymius, pasireiškiančius dėl nenormalaus, perdėto ar sinchroniško galvos smegenų neuronų aktyvumo, kur simptomų pasireiškimo laikotarpis vadinamas priepuoliu [9]. Epilepsijos priepuoliai gali būti įvairūs ir priklauso nuo smegenų žievės vietos, kurioje įvyksta nenormalus elektrinis aktyvumas. Jei priepuolis židininės pradžios jis gali pasireikšti trumpalaikiu motorinių funkcijų sutrikimu, tačiau jei priepuolio pradžia generalizuota, epilepsija dažniausiai pasireiškia stiprių traukulių ir sąmonės netekimo forma. Po medikamentinio gydymo apie 47 % sergančių nebepatiria priepuolių. Dar 14 % pasveiksta parinkus tinkamą vaistų tipą ir dozę [2]. Vaistų parinkimo problema ypač aktuali, nes vaistai toksiški ir ilgainiai gali sukelti kitų organizmo problemų, o tai svarbu sunkios epilepsijos atveju. Net ir taikant medikamentinį gydymą maždaug 20–30 % pacientų patiria epilepsijos priepuolius, iš kurių net 8 % juos patiria kasdien [3]. Tokiu epilepsijos tipu sergančių pacientų mirtingumo tikimybė yra 4–5 kartus didesnė [4]. Su epilepsija susijęs mirtingumas išliko stabilus per pastaruosius 50 metų, nepaisant tobulėjančių medicinos metodų [5]. Priepuolių nuspėjamumas ir negalėjimas jiems pasiruošti pablogina gyvenimo kokybę tiek pačiam sergančiajam, tiek jo šeimai [6]. Gyvenimo kokybė gali būti pagerinta personalizuojant gydymą, tačiau tam reikia objektyviai ir kiekybiškai įvertinti priepuolių pasireiškimą ir organizmo atsaką į gydymą.

Šiuo metu, prieš skiriant gydymą, epilepsija įvertinama šeimai ir pačiam pacientui subjektyviai apibūdinant priepuolius. Įvertinimas atliekamas budrumo lygio priepuolio metu bei detalių prisiminimo po priepuolio nustatymu. Tokia vertinimo metodika neobjektyvi ir priklauso nuo paciento požiūrio. Tyrimai rodo, kad pacientai linkę pranešti tik apie pusę patirtų priepuolių [7],[8]. Taip pat egzistuoja ir priešinga situacija, kai pacientai meluoja apie patirtus priepuolius. Priepuolių įvertinimas ligoninėje atliekamas pagal užregistruotus elektroencefalografinius (EEG) signalus, gydytojams rankiniu būdu peržiūrint įrašus, tačiau šis būdas nėra tinkamas ilgalaikiai stebėsenai.

Epilepsijos aptikimo prietaisai įgalintų tikslesnį kiekybinį priepuolių vertinimą, leidžiantį gydytojams objektyviau vertinti gydymo efektyvumą ir eigą. Taip pat priepuolių prognozavimo įranga leistų įspėti pacientą apie artėjančią priepuolį. Tokia prognozės įranga galėtų potencialiai sumažinti sergamumą ir mirštamumą [2]. Didžiausia problema, kad joks šiuo metu egzistuojantis prietaisas negali aptikti visų epilepsijos tipų ir turi būti personalizuotas pagal žinomą epilepsijos tipą. Negana to, tokie metodai yra nepatogūs ir įgalinami tik ligoninėje ilgalaikės stebėsenos metu. Dėl tokių priežasčių atsiranda personalizuoto metodo poreikis, kuris specifiškai pagal paciento simptomus apsimokytų ir galėtų diagnozuoti pacientui būdingą epilepsijos formą. Besiplečianti implantuojamų prietaisų sritis bei tobulėjanti aparatinė įranga atveria galimybes svarstyti tokio metodo įgyvendinimą ir reikalauja naujų energetiškai efektyvių sprendimų.

Šis darbas glaustai siejasi su projekto (Nr. J05-LVPA-K-03-0101) vykdomomis MTEP veiklomis, kur siekiama sukurti epilepsijos atpažinimo metodą, tinkamą integruoti į kaukolės implantus.

Darbo tikslas – sukurti ir iširti personalizuotą epilepsijos aptikimo metodą, potencialiai tinkamą diegti į implantuojamus prietaisus. Darbo tikslui įgyvendinti išsikelti šie darbo uždaviniai:

1. Išanalizuoti esamų epilepsijos aptikimo metodų privalumus ir trūkumus.
2. Sukurti personalizuotą metodą, gebantį aptikti epilepsijos priepuolius EEG signaluose.
3. Optimizuoti pasiūlytą metodą, siekiant padidinti energetinį efektyvumą.
4. Iširti sukurto metodo savybes su epilepsijos priepuolių turinčiomis duomenų bazėmis.

1. Epilepsijos priepuolių atpažinimo problemos analizė

1.1. Epilepsijos priepuolių tipai

Epilepsijos tipų daug, todėl juos sunku klasifikuoti. Pats priepuolis apibrėžiamas kaip praeinantys požymiai ir simptomai, kuriuos lemia perteklinė ar hipersinchronizuota galvos smegenų neuronų veikla. Priklausomai nuo hipersinchronizacijos lokacijos smegenų žievėje, epilepsija klasifikuojama į tris pagrindines grupes: generalizuotos, židininės ir nežinomos pradžios. Pagal trumpalaikius motorinius bei suvokimo sutrikimus epilepsijos priepuoliai klasifikuojami į subkategorijas, kurios pateiktos 1.1 lentelėje.

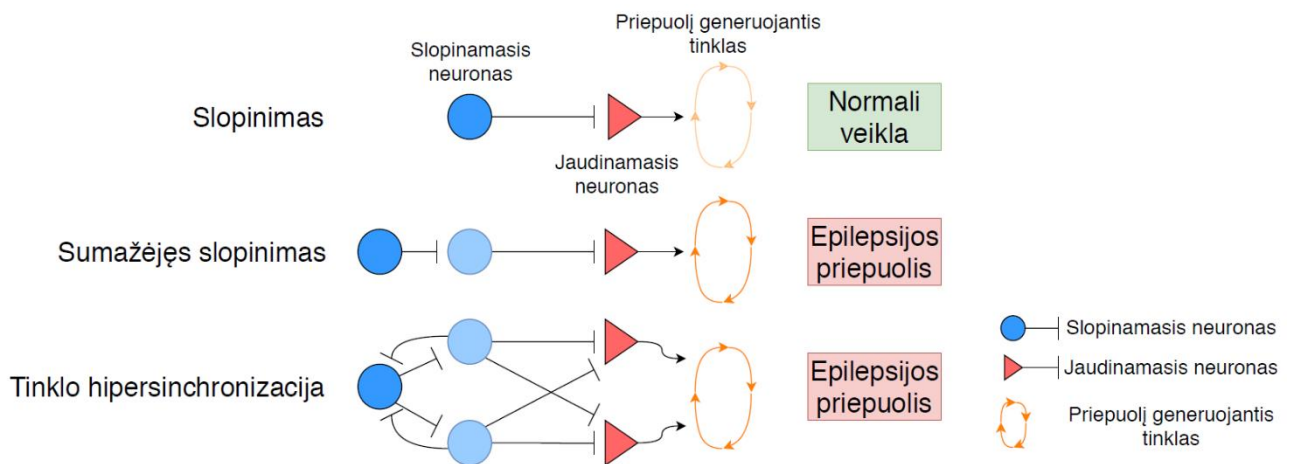
1.1 lentelė. Epilepsijos priepuolių klasifikavimas [9].

Generalizuotos pradžios	Židininės pradžios	Nežinomos pradžios
Motoriniai <ul style="list-style-type: none">• toniniai–kloniniai• kloniniai• toniniai• miokloniniai• miokloniniai–toniniai–kloniniai	Be suvokimo sutrikimo <ul style="list-style-type: none">• atoniniai• kloniniai• epilepsiniai spazmai• hiperkinetiniai• miokloniniai• toniniai Su suvokimo sutrikimu <ul style="list-style-type: none">• autonominiai• veiklos sustojimas• kognityviniai• emociniai• sensoriniai	Motoriniai <ul style="list-style-type: none">• toniniai–kloniniai• epilepsiniai spazmai Nemotoriniai <ul style="list-style-type: none">• veiklos sustojimas
Nemotoriniai <ul style="list-style-type: none">• tipiniai atipiniai• miokloniniai• akių vokų mioklonijos	Nemotorinės pradžios <ul style="list-style-type: none">• autonominiai• veiklos sustojimas• kognityviniai• emociniai• sensoriniai Židiniai, išplintantys į abipusius toninius–kloninius traukulius	Neklasifikuojami

Toninis–kloninis epilepsijos tipas pasižymi intensyviausiais raumenų traukuliais. Kitų tipų epilepsijos gali pasižymėti tik suvokimo sutrikimu, ar neintensyviu motorinių funkcijų sutrikimu.

1.2. Epilepsijos priepuolio fiziologija

Epilepsijos priepuolis įvyksta dėl laikinos nenormalios smegenų neuronų sinchronizacijos, kuri sutrikdo normalius neuronų komunikacijos kelius. Šie pokyčiai matomi EEG signale. Židininės epilepsijos atveju pokyčiai įvyksta tik tuose elektrodų EEG signaluose, kurie yra arčiau židinio. Tolimesnių elektrodų EEG signaluose registruojama normali smegenų veikla. Generalizuotos epilepsijos atveju pokyčiai registruojami visuose elektroduose nepriklausomai nuo jų pozicijos. Tokie smegenų elektrinės veiklos sutrikimai gali sukelti įvairius požymius, kurie priklauso nuo priepuolio židinio ir jo plitimo krypties. Atsižvelgiant į epilepsijos židinį manoma, kad priepuoliai dažniausiai įvyksta dėl padidėjusio neuronų jaudinimo arba sumažėjusio slopinimo. Tai gali būti paaiškinama dviejų tarpusavio neuronų ryšio modeliu. Toks modelis pateikiamas 1.1 pav., kuriame parodyta priepuolius generuojančio neuroninio tinklo priklausomybė nuo slopinimo.



1.1 pav. Epilepsijos priepuolio susidarymo aiškinamoji schema [9].

Neuroninių tinklų dariniai (pavaizduoti oranžinės spalvos ovalu) gali būti įvairiuose smegenų regionuose ir susideda iš skirtingų vidinių sąveikų tarp skirtingų ląstelių tipų. Esant normaliai smegenų veiklai (viršutinė eilutė) tinklus kontroliuoja slopinantieji neuronai (mėlynos spalvos apvalūs neuronai) užtikrinantys stabilią funkcinę veiklą. Jei slopinamieji neuronai pradeda per mažai slopinti jaudinamąjį neuroną tai tinklas gali tapti per mažai nuslopintas ir sukelti priepuolį (vidurinė eilutė). Daugialypė vidinė sąveika tarp slopinamųjų ir jaudinamųjų neuronų įsiterpiančiam gretutiniams neuronams gali sukelti patologinę neuronų hypersinchronizaciją ir priepuolį (apatinė eilutė). Per mažas slopinimas gali nutikti ne tik įsiterpus patologiškoms neuronų ląstelėms bet ir gaba–amino butirinės rūgšties neurotransmiterių disbalanso metu arba turint genetinių šių neurotransmiterių receptorių mutacijų [9]. Epilepsija gydoma trimis būdais: vaistais, neurostimuliaciniais ir chirurgine intervencija suardant priepuolį sukeliančius židinius. Paskutiniais dviem atvejais būtina lokalizuoti epilepsijos priepuolio židinį.

1.3. Epilepsijos priepuoliui aptikti naudojamų metodų analizė

EEG duomenys yra vieni iš svarbiausių neurologiniuose tyrinėjimuose bei epilepsijos aptikime, jie laikomi „aukso standartu“. Didžioji dalis literatūroje randamų studijų remiasi būtent EEG signalų analize [13], todėl šiame darbe nagrinėjami tik tokio tipo EEG. Epilepsijos priepuolių aptikimo metodai priklauso nuo signalų apdorojimo matematinių bei statistinių įrankių skirtų apdoroti pradinis EEG signalus. Pagal charakteristikų skaičių metodai gali būti skirstomi į vieno kintamojo ir keleto kintamųjų. Aptikimo metodai paprastai skirstomi į keturias grupes [14].

1.3.1. Laiko srities metodai

Laiko srities metoduose EEG signalo charakteristikos randamos naudojant laiko srities signalus. Apskaičiuotos charakteristikos dažniausiai atspindi amplitudės, variabilumo bei sinchronizacijos parametrus.

Eftekhar'o et al. naudoja modeliu grįstą atpažinimą, kuris kombinuoja simbolinę dinamiką su N–gramų algoritmu. Šiame metode EEG signalas pirmiausia filtruojamas su ketvirtos eilės *Buttervorto* užtvariniu filtru. Likusiems artefaktams panaikinti naudojamas *Savitzky–Golay* filtras. Nufiltruotas EEG signalas segmentuojamas naudojant vienos minutės langą. Tada N–gramų algoritmas iteratyviai ieško pasikartojančių modelių naudojant inversinį *Hamingo* atstumą. Pasikartojantys modeliai sumuojami ir sekami naudojant fiksuotą bei dinaminį slenkstį. Aliarmas skelbiamas reikšmei viršinus slenkstį. Slenkstinės vertės parenkamos per apmokymo procedūrą, kur naudojamas kiekvieno

paciento vienas priepuolis ir valanda priešepilepsinio EEG. Nors duomenų bazė sudaryta iš šešių duomenų kanalų, apmokyti naudojami tik trys EEG kanalai. Tokiu metodu pasiektas 67 % jautrumas, kur klaidingų aliarmų skaičius 0,04 per valandą. Padidinus apmokyti naudotų epilepsijos epizodų skaičių metodas pasiekė 93,81 % jautrumą, kur klaidingų aliarmų skaičius siekė 0,06/h. Verta paminėti, kad metodas naudojo nedaug skaičiavimo resursų [14],[15].

Zheng 'o et al. metodas remiasi fazės sinchronizacijos informacija, kuri išgaunama naudojantis dviejų kintamųjų empirine dekompozicija. Pirmiausia duomenys filtruojami 50 Hz užtvariniu filtru. Filtruoti duomenys segmentuojami su 20 % langų persidengimu. Tuomet skaičiuojama fazės sinchronizacija tarp visų galimų kanalų. Panaudojant *Hilberto* transformaciją gaunama vidutinė fazės koherencija. Trys didžiausius pokyčius rodantys vidutinės fazės EEG signalai išrenkami tolimesnei prognozei. Šiame metode keturi epilepsijos epizodai skirti apmokymams ir tik vienas testavimams. Metodu pasiektas 70 % jautrumas, kur klaidingų aliarmų skaičius 0,15/h. Taip pat naudoti 6 EEG kanalai. Metodo kompleksiskumas didesnis nei prieš tai nagrinėtu atveju [14],[10].

1.3.2. Dažnių srities metodai

Tokiuose metoduose laiko srities EEG signalai turi būti transformuoti į spektrą, iš kurio galima apskaičiuoti dažnines charakteristikas. Čia dažniausiai naudojamas spektrinis galios tankis. Jis apibrėžiamas kaip statistinis signalo galios įvertis kiekvienoje dažnių juostoje. Tuo tarpu laiko–dažnio analizei skaičiuojamos charakteristikos susijusios su laikiniais dažnių pokyčiais. Tokiai užduočiai įgyvendinti dažniausiai naudojama vilnelių transformacija [14].

Bandarabad 'o et al. metode lyginami laikini spektriniai pokyčiai tarp visų įmanomų kanalų. Taip išgaunama informacija apie laipsniškus pokyčius, kurie seka prieš epilepsijos priepuolį. Pirmiausiai neapdoroti EEG signalai suskirstomi į 5 s trukmės langus. Tuomet nufiltruojami neribotos impulsinės reakcijos priekinės – atgalinės sklaidos 50 Hz *Buttervorto* užtvariniu filtru. Tada skaičiuojamas normalizuotas galios spektras. Galiausiai surandami visų kanalų spektrų santykiai, kur iš viso gaunami 435 parametrai. Pirmi trys epilepsijos priepuoliai naudoti apmokyti, o likusieji tikrinti. Metodu pasiektas 73,98 % jautrumas ir 0,06/h klaidingų aliarmų skaičius [14],[16].

Gadhoumi 's et al. pasiūlė metodą, kuris matuoja panašumą tarp epilepsijos metu ir prieš epilepsiją dominuojančio EEG spektro, panaudojant vilnelių transformaciją. Pokyčiai nagrinėjami keturiuose dažnių ruožuose (50–150 Hz; 150–250 Hz; 250–350 Hz ir 350–450 Hz). Tuomet apskaičiuojami trys parametrai: įtraukimas, užsitęsimas ir atstumas, išreiškiant EEG segmentų panašumą. Apmokyti naudojamas kryžminės validacijos procesas. Šiuo metodu pasiektas 85% jautrumas ir 0,35/h klaidingų aliarmų skaičius [14],[17].

1.3.3. Kombinuoti laiko ir dažnių srities metodai.

Kartais atskiri laikiniai ar dažniniai EEG signalų parametrai nesuteikia reikiamų rezultatų, todėl bandoma įgyvendinti metodus iš parametų kombinacijų. Neretai paaiškėja, kad pavienių didelės naudos nenešančių parametų kombinacija leidžia metodams pasiekti geresnius rezultatus nei naudojant parametrus atskirai [14].

Moghim 'as et al. pasiūlė panaudoti pavienius parametrus mašiniame mokyme. Autoriai naudoja 34 nepriklausomus parametrus pagrįstus energija ir netiesine dinamika (*Liapunovo* eksponentė, koreliacija ir t.t.). Metodas tiriamas su kryžminės validacijos algoritmu, kur 70 % duomenų

naudojami apmokyti ir 30 % testuoti. Metodu pasiektas 99 % specifiškumas, tuo tarpu jautrumas yra tarp 89 % ir 93,5 %. Didžiausias trūkumas, kad šie parametrai varijuoja tarp tiriamųjų ir tinkantys vieniems, gali visiškai netikti kitiems [14],[18].

1.3.4. Modeliu grįsti metodai

Žmogaus neuronų tinklas yra kompleksiška sistema, todėl naudojant matematinių modelių principą galima sudaryti ir epilepsijos modelį. Vietoj matematinio analitinio problemos sprendimo, atliekamas eksperimentas su modeliu koreguojant modelio parametrus ir tiriant eksperimentų rezultatų skirtumus [14].

Aarabi's et al. pasiūlė epilepsijos modelį, kuris sudaromas iš žmogaus epilepsijos EEG signalų. Čia pirmiausia EEG nufiltruojamas juostiniu filtru (pjūvio dažniai: 0,5 Hz ir 100 Hz). Tuomet naudojama *Bayesiano* interferencija, kad modelis atitiktų EEG segmentų spektrus. Po to, apskaičiuojami 12 parametrai, kurie įvertina modelio atitikimą. Metodas apmokomas naudojant 50 minučių priešepilepsinių duomenų ir 4 valandomis tarpepilepsinių duomenų, kiekvienam tiriamajam atskirai. Šiuo metodu pasiektas 92,6 % jautrumas, kur klaidingų aliarmų skaičius siekia 0,15/h. Autoriai taip pat teigia, kad tokį metodą realistiška įgyvendinti ilgalaikės stebėsenos sistemoje [14],[19].

Didžioji dalis nagrinėtų metodų apmokyti bei testuoti naudojant laisvai prieinamą *Freiburg*¹ duomenų bazę, kuri šiuo metu yra mokama Europos epilepsijos duomenų bazės² dalis.

1.4. Alternatyvūs metodai

Dėl didelio epilepsijos tipų skaičiaus bei skirtingų pataloginių požymių priepuolio metu sutinkami įvairūs aptikimo metodai ir juose naudojami signalai. Vienas iš būdų aptikti epilepsiją yra sekti širdies ritmo variabilumą elektrokardiografiniuose signaluose. Tokių metodų trūkumas, kad širdies ritmo variabilumas kinta ir dėl gretutinių ligų ar intensyvesnio fizinio aktyvumo, todėl tokie metodai turi didelį klaidingų aliarmų skaičių. Reikia atkreipti dėmesį, kad klaidingų aliarmų skaičius priepuolių prognozės sistemose yra svarbus parametras. Net nedidelį klaidingų aliarmų skaičių turinti sistema gali tapti nebenaudojama, nes dingsta paciento pasitikėjimas [10]. Toniniai–kloniniai priepuoliai dėl motorinių funkcijų sutrikdymo gali būti aptinkami panaudojant judesio akcelerometrinius signalus. Čia didžiausi sunkumai atskirti paprastus dienos eigos paciento judesio požymius nuo tų, kurie vyksta priepuolio metu. Paviršiaus elektromiografija taip pat naudinga aptinkant motorinius priepuolius, tačiau reikia užtikrinti gerą jutiklio kontaktą su oda, dėl to yra stebimas odos dirginimo efektas. Elektroderminio aktyvumo registravimas taip pat gali būti naudojamas, tačiau jis yra jautrus judesio artefaktams ir gali aptikti tik toninius–kloninius priepuolius. Be jau išvardintų literatūroje sutinkami ir kvėpavimo, deguonies prisotinimo, akių judesių, kraujo spaudimo ar artimojo infraraudoniesiems spinduliams diapazono spektroskopijos metodai ir atitinkami signalai, tačiau kol kas jie rodo aukštą klaidingų aliarmų skaičių [2], [11], [12].

1.5. Dirbtiniai neuroniniai tinklai

Praktikoje paprastai sutinkami dviejų rūšių dirbtiniai neuroniniai tinklai, tinkami analizuoti laikinius signalus: konvoliuciniai ir rekurentiniai. Konvoliuciniai dirbtiniai neuroniniai tinklai pasižymi sudėtingu ir ilgu apmokymo procesu. Tokiems tinklams reikia didelio kiekio duomenų [20]. Tokie

¹ <http://epilepsy.uni-freiburg.de/freiburg-seizure-prediction-project/eeg-database>

² http://www.epilepsiae.eu/project_outputs/european_database_on_epilepsy

tinklai potencialiai gali pasiekti gerus rezultatus, tačiau dėl duomenų trūkumo atskiriems pacientams tinklas negali būti apmokytas personalizuotai. Užregistruoti didelį duomenų kiekį vienam pacientui, kuris galėtų būti panaudotas apmokyti konvoliucinį dirbtinį neuroninį tinklą, yra brangus ir laikui imlus procesas. Dėl tokių priežasčių tokie tinklai šiame darbe toliau nėra nagrinėjami.


Rekurentiniai dirbtiniai neuroniniai tinklai dėl grįžtamųjų ryšių pasižymi sunkiu apmokymo procesu, net ir prie nedidelio neuronų skaičiaus [21]. Taip pat tokie tinklai dėl grįžtamųjų ryšių gali tapti nestabilūs. Atsiradusi apmokymo metodika, kuri remiasi dinamiu rezervuaru, sudarytu klasikinio rekurentinio dirbtinio neuroninio tinklo pagrindu, ženkliai paspartina apmokymo procesą. Svarbiausia tokio tinklo ypatybė yra ta, kad tinklui apmokyti naudojamas nebe visas dirbtinis neuroninis tinklas kaip rekurentinio dirbtinio neuroninio tinklo atveju, o tik išėjimo sluoksnis. Naujiems rezervuariniams dirbtiniams neuroniniams tinklams apmokyti pakanka išspręsti tiesinės regresijos lygtį, pvz. *Vynario–Hopfo*, dėl ko ypač pagreitėja apmokymo procesas. Toks apmokytas tinklas dėl mažo jungčių skaičiaus reikalauja nedaug energijos resursų. Rekurentinių dirbtinių neuroninių tinklų su dinaminio rezervuaro apmokymo pagrindu galima sutikti keletą rūšių: aido būsenos, skystos būsenos, šuolinius, kur laiko srities signalų nagrinėjimui tinkamiausi aido būsenos dirbtiniai neuroniniai tinklai (ABDNT). Maždaug 40 % dirbtinių neuroninių tinklų metodų naudoja normalizuotus laikinius signalus užuot kitaip juos transformavę [22], [25].

1.6. Skyriaus išvados

1. Epilepsijos aptikimo metodų analizė rodo, kad didžioji dalis mokslinių studijų remiasi EEG signalų analize, tačiau nėra vieningo metodo kuris būtų patikimas aptinkant skirtingus epilepsijos tipus.
2. Atsižvelgiant į tai, kad EEG signalų skaičius vienam pacientui ribotas, realiomis sąlygomis personalizuotam metodui reikėtų apsimokyti iš vieno priepuolio signalų. Galime daryti prielaidą, kad ABDNT tinkamas pasirinkimas, nes jo apmokymas paprastas ir potencialiai užtenka nedidelio kiekio EEG signalų.

2. Personalizuoto epilepsijos stebėsenos metodo kūrimas

Darbas susideda iš trijų pagrindinių dalių: personalizuotos metodikos sukūrimo, ABDNT parametru parinkimo ir tyrimo su klinikiniais EEG signalais (žr. 2.1 pav.).



2.1 pav. Personalizuoto epilepsijos priepuolių atpažinimo metodo kūrimo seka.

Personalizuotos metodikos sukūrimo dalyje kuriami kanalų skaičiaus mažinimo metodai ir sudaromos apmokymo EEG signalų kombinacijos. Pagrindinis principas apmokyti ABDNT naudojant tik EEG signalus papildomai neišskiriant parametru. Taip pat siekiama, kad šie EEG signalai būtų kuo mažiau tarpusavyje koreliuoti ir suteiktų kuo didesnę dimensiją.

Parametru parinkimo dalyje ABDNT parametrai parenkami energetinio efektyvumo atžvilgiu. Parametru nemažai, todėl būtina ištirti kiekvieno iš jų įtaką (aktyvacijos funkcijos, neuronų skaičiaus, spektrinio spindulio ir t.t.).

Tyrimo su klinikiniais EEG signalais dalyje sukurtas metodas tiriamas su dviejų klinikinių duomenų bazių signalais. Klasifikatorius parenkamas naudojantis ROC kreivėmis ir nustatomi optimalūs klasifikavimo slenksčiai (kiekvienam pacientui individualūs). Pagal gautus slenksčius skaičiuojamas diagnostinis tikslumas, jautrumas ir specifiškumas.

Metodas turi būti personalizuotas, dėl epilepsijos tipų, kurie individualūs kiekvienam žmogui. Taip pat projekte numatyta tokio tipo metodą potencialiai naudoti implantavimui, todėl reikia, kad metodas sugebėtų išsirinkti geriausiai reprezentuojančius kanalus ir naudotų mažą skaičiavimo resursų kiekį.

2.1. Duomenų bazės su epilepsijos priepuoliais


Vystant ir testuojant metodą naudojamos dvi klinikinės duomenų bazės su epilepsijos priepuoliais: vaikų ir naujagimių. Vaikų duomenų bazė naudojama parinkti ABDNT parametrus ir tirti metodą. Tuo tarpu naujagimių duomenų bazė naudojama tirti metodą su ABDNT parametru parinkime nenaudotais EEG signalais.

2.1.1. Vaikų duomenų bazė

Šiame darbe naudojama laisvai prieinama neinvazinė vaikų EEG duomenų bazė³ [26]. EEG signalai užregistruoti 23 vaikams, kurie turi vaistais nepagydomos epilepsijos formas (17 moteriškos lyties, kurių amžius buvo nuo 1,5 iki 19 metų ir 5 vyriškos lyties, kurių amžius nuo 3 iki 22 metų bei 1 atvejis be nurodyto amžiaus ir lyties). Šie EEG registruoti Bostono vaikų ligoninėje norint įvertinti konkretų atvejį ir pasiruošti chirurginei intervencijai. EEG užregistruoti 256 Hz diskretizavimo dažniu su 16 bitų skiriamąja geba pagal 10–20 tarptautinį elektrodų išdėstymo standartą. Daugumos pacientų EEG signalai padalinti į vienos valandos trukmės intervalus, tačiau kai kurie atvejai turi ir 2–4 valandų trukmės intervalus. Bendra visų įrašų trukmė siekia 983 valandas. Įrašai, kuriuose yra epilepsijos priepuoliai, buvo rankiniu būdu anotuoti neurologo eksperto nurodant priepuolio pradžios

³ <https://physionet.org/content/chbmit/1.0.0/>

ir pabaigos laiko žymes. Iš viso duomenų bazėje yra 198 anotuoti epilepsijos epizodai. Daugiau informacijos apie kiekvieną įrašą atskirai galima rasti 1 priede. Prie duomenų bazės taip pat pateikiama kanalų išdėstymo tvarka įrašuose, kuri neretai kinta netgi tarp to paties paciento atskirų įrašų. Taip pat kai kurie kanalai pridedami arba pašalinami kintant įrašams. Norint užtikrinti metodo atkartojamumą ir duomenų vienalytiškumą nuspręsta analizei parinkti tik tuos kanalus, kurie yra bendri ir nekintantys visiems pacientams visuose įrašuose. Iš viso atrinkti 18 bendrų kanalų visiems 24 pacientams įtraukiant: FP1–F7, F7–T7, T7–P7, P7–O1, FP1–F3, F3–C3, C3–P3, P3–O1, FP2–F4, F4–C4, C4–P4, P4–O2, FP2–F8, F8–T8, T8–P8, P8–O2, FZ–CZ ir CZ–PZ kanalus, kur kanalas Nr. 1 reiškia įtampos skirtumą tarp elektrodų FP1 ir F7.



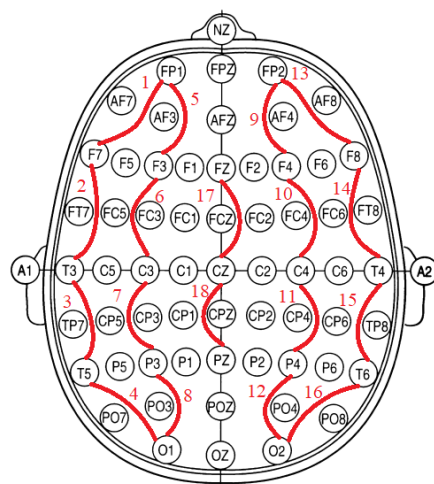
2.2 pav. Vaikų duomenų bazės EEG kanalų išdėstymas ir žymėjimas.

Dėl tokio kanalų parinkimo iš duomenų bazės pašalinti tik trys intervalai iš paciento Nr. 12 (įrašai „chb12 27–29.edf“), nes neturėjo nei vieno iš anksčiau išvardintų kanalų. Sutvarkyta duomenų bazė susideda iš 980 valandų EEG signalų su 185 epilepsijos epizodais priklausančiais 24 pacientams.

2.1.2. Naujagimių duomenų bazė

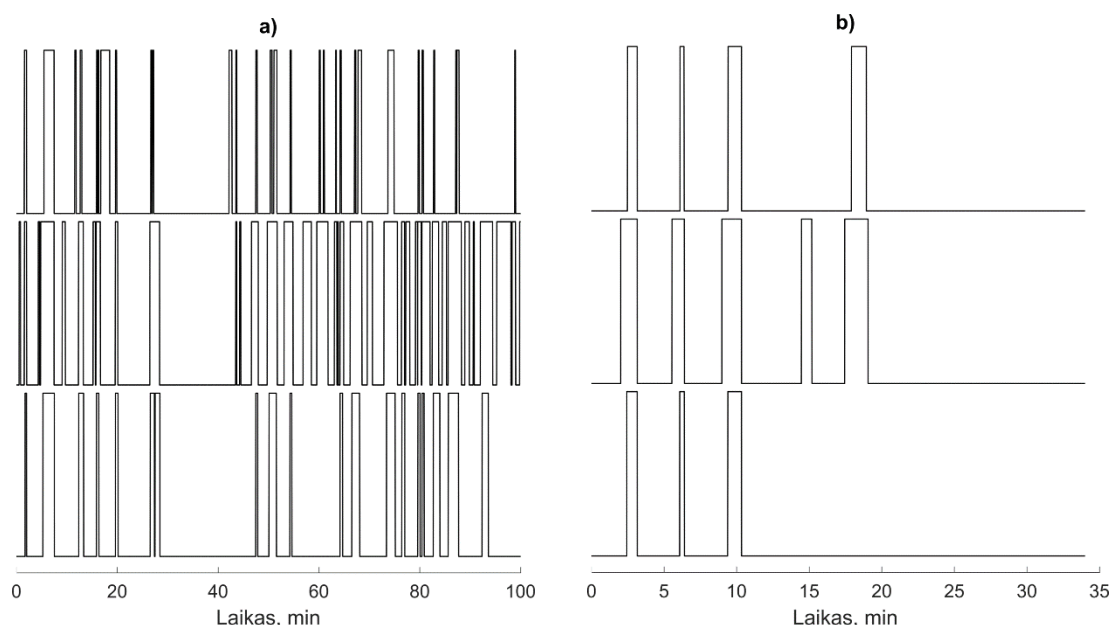
Antroji darbe naudojama Helsinkio universitetinėje ligoninėje užregistruota neinvazinė naujagimių EEG duomenų bazė⁴ [27]. EEG signalai užregistruoti iš 79 naujagimių, esančių intensyvios terapijos skyriuje įtariant epilepsijos priepuolius (24 moteriškos lyties, kurių išnešiojimo amžius buvo nuo 36 iki 44 savaičių ir 15 vyriškos lyties, kurių išnešiojimo amžius buvo nuo 35 iki 42 savaičių bei 2 atvejai be nurodytos lyties 39 ir 40 savaičių amžiaus). EEG užregistruoti 256 Hz dažniu su 16 bitų skiriamąja geba 79 pacientams pagal 10–20 tarptautinį elektrodų išdėstymo standartą ir suskirstyti į 79 įrašus. Darbe naudota dvipolė elektrodų sistema, todėl iš 19 monopolinių kanalų sudaryti 18 dvipolių kanalų, kurie nekito ir buvo bendri visiems pacientams: FP1–F7, F7–T3, T3–T5, T5–O1, FP1–F3, F3–C3, C3–P3, P3–O1, FP2–F4, F4–C4, C4–P4, P4–O2, FP2–F8, F8–T4, T4–T6, T6–O2, FZ–CZ, CZ–PZ.

⁴ <https://zenodo.org/record/2547147#.XnMVyKgzaHu>



2.3 pav. Naujagimių duomenų bazės EEG kanalų išdėstymas ir žymėjimas. Kanalas Nr.1 atitinka FP1–F7.

Visuose atvejuose EEG signalai padalinti į vienos valandos trukmės įrašus, tačiau šešių pacientų įrašai yra 2–4 valandų trukmės. Bendra visų įrašų trukmė siekia 112 valandų, kur vidutinis EEG signalo ilgis 85 minutės. Įrašai rankiniu būdu anotuoti trijų nepriklausomų neurologų turinčių daugiau kaip dešimties metų patirtį. Iš viso, duomenų bazėje anotuoti 1379 epilepsijos epizodai. Anotacijos atliktos su vienos sekundės skiriamąja geba nustatant epilepsijos pradžią ir pabaigą. Anotacijos atliekamos remiantis EEG signalais ir vienu elektrokardiogramos kanalu. Papildoma vaizdo ar kitokia informacija nebuvo pateikiama. Vidutiniškai vienas neurologas duomenų bazėje aptiko 460 priepuolių. Iš 1379 surastų epilepsijos priepuolių 889 (65 %) buvo anotuoti visų trijų, 295 (21 %) dviejų ir 195 (14 %) vieno anotuotojo. Anotuotojų tarpusavio sutapimas įvertintas naudojant *Fleiss* kapą κ , kur atitinkamai gautas dydis 0,777 (95 % PI: 0,659 – 0,830) [28]. Didžiausia problema, kad atvejai kaip pvz.: Nr. 1 ir Nr. 79, turi skirtingus anotacijos intervalus (žr. 2.4 pav.), kas savo ruožtu gali daryti neigiamą įtaką ABDNT apmokymui. Kai kurie atvejai neanotuoti arba turi mažesnę nei trijų anotuotų priepuolių skaičių, todėl pašalinami iš duomenų bazės ir nenaudojami tolimesniame darbe. Daugiau informacijos apie kiekvieną naudojamą duomenų bazės atvejį galima rasti 2 priede.




2.4 pav. Trijų anotuotojų anotacijų nesutapimo pavyzdžiai, a) pacientas Nr.1, kur pirmojo ir antrojo anotuotojo nesutapimas 0,533, pirmojo ir trečiojo 0,467, antrojo ir trečiojo 0,282 ir b) pacientas Nr. 79, su atitinkamomis nesutapimų reikšmėmis 0,556, 0,769 ir 0,683.

2.2. Personalizuota kanalų atrankos ir skaičiaus mažinimo metodika

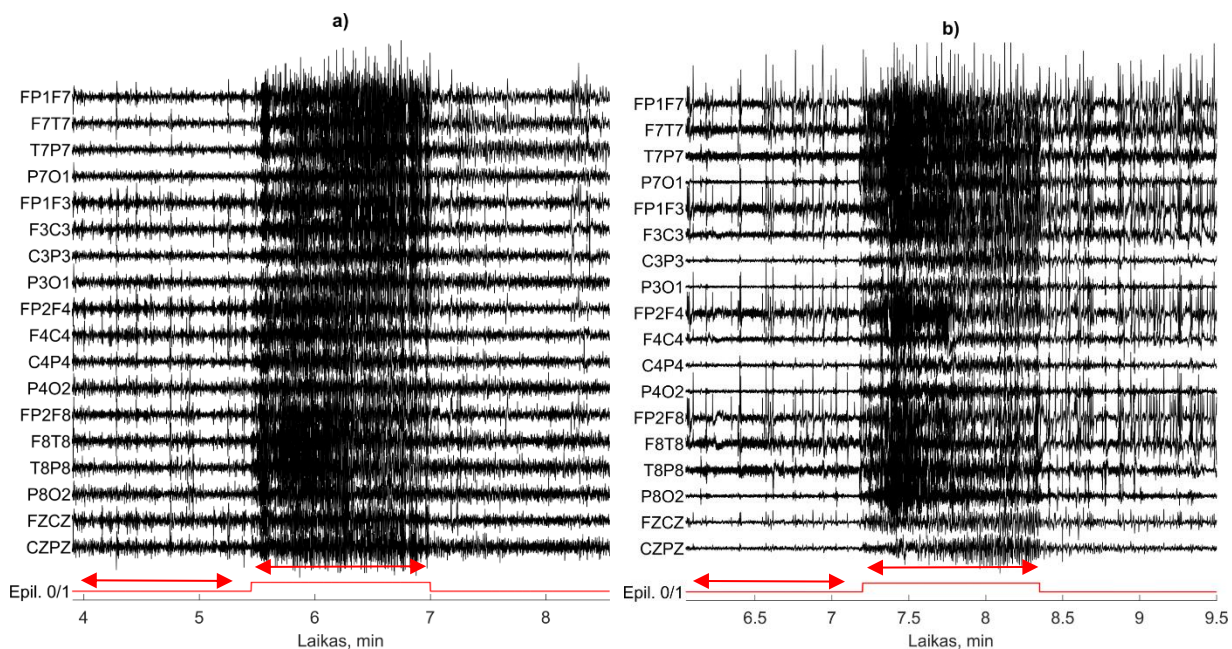
Dažnių srities parametrų skaičiavimas lyginant su laiko srities parametrų skaičiavimu reikalauja daugiau energijos ir yra ilgesnis procesas. Epilepsijos aptikimo metodų apžvalga [22] rodo, kad apmokyti dirbtinį neuroninį tinklą efektyviau su signalais o ne juos charakterizuojančiais parametrais, nes šie gali žymiai skirtis tarp pacientų. EEG signalai dėl mažos amplitudės užteršti triukšmu, todėl signalus rekomenduojama nufiltruoti juostiniu filtru pagal medicininį standartą [29]. Maždaug 40 % literatūroje pateikiamų epilepsijos atpažinimo metodų naudoja tik juostiniu filtru filtruotus signalus, kur dažniausiai naudojama 0,3 – 40 Hz dažnių juosta [22]. Šiuo atveju naudojamas neribotos impulsinės reakcijos *Kaizerio* 25 eilės juostinis filtras su atitinkamais pjūvio dažniais: 0,16 ir 50 Hz.

Visų pirma įvertinama dažninė kiekvieno kanalo struktūra, norint išsiaiškinti kokiuose dažniuose epilepsijos įtaka didžiausia. Kaip pavyzdys pateikiama EEG signalo „chb01_21_01“ T8–P8 kanalo spektrograma.




2.5 pav. EEG Signalo „chb01_21_01“ T8–P8 kanalo spektrograma. Raudonas rėmelis žymi epilepsijos dominavimo sritį, kuri pasireiškia visame nagrinėjamame dažnių ruože.

Čia akivaizdžiai matoma epilepsijos įtaka visuose dažnių ruožuose (0,16 – 50 Hz). Tokia situacija matoma visuose EEG, kurie turi epilepsijos priepuolius. Norint plačiau išnagrinėti kiekvieno kanalo dažninę struktūrą skaičiuojamas galios spektrinis tankis (GST) dviem EEG signalo atkarpoms. Pirmajai atkarpai priskiriamas visas epilepsijos epizodas. Antrajai atkarpai priskiriamas tokio paties ilgio EEG signalas einantis prieš epilepsijos epizodą žr. 2.6 pav.



2.6 pav. Pacientų a) „chb01_21.edf“ ir b) „chb03_03.edf“ 18 EEG kanalų laiko srityje. Raudona linija žymi epilepsijos epizodo pradžią ir pabaigą. Raudoni intervalai žymi atkarpas, kuriuose skaičiuojamas GST.

Tokia procedūra atliekama kiekvieno paciento pirmajam epilepsijos priepuoliui. Gautiems langams apskaičiuojami GST. Vieną langą sudaro 18 kanalų, todėl 2.7 pav. pateiktame paveiksle matosi 18 raudonų linijų reiškiančių spektrinę galios tankį epilepsijos lange ir 18 juodų linijų reiškiančių spektrinę galios tankį prieš epilepsijos priepuolį einančiame lange.



2.7 pav. Raudona spalva žymi 18 GST apskaičiuotų epilepsijos intervale kiekvienam kanalui, pacientui „chb01_21.edf“. Juoda spalva žymi to paties paciento 18 GST kreivių apskaičiuotų iš intervalo prieš pat prasidedant epilepsijos epizodui.

Toks EEG signalų įvertinimas rodo, kad kai kurie kanalai neturi reikšmingesnių pokyčių dažnių srityje epilepsijos metu. Prieš epilepsijos priepuolį esančiame intervale (juoda spalva) matomas neryškus energijos varijavimas tarp kanalų, tačiau epilepsijos intervale matomas aukštas varijavimas. Taip pat pastebėta, kad kanalai su didžiausiais pokyčiais yra skirtingi tarp pacientų, tačiau ne tokie skirtingi to paties paciento epilepsijos epizoduose. Energijos varijavimo tarp kanalų teiginį pagrindžia literatūroje aprašyti epilepsijos tipai, nes židininės epilepsijos atveju pokyčiai gali būti stebimi tik arčiausiai židinio esančiuose kanaluose, tuo tarpu kituose kanaluose registruojama normali EEG

veikla (žr. 1.1 skyrių). Jei apmokyti ABDNT bus naudojami EEG, kuriuose nėra pokyčių epilepsijos epizode, toks tinklas negalės tinkamai konverguoti ir išmokti atpažinti epilepsiją. Tam, kad galėtume išrinkti didžiausius pokyčius reprezentuojančius kanalus atliekamas resursų atžvilgiu neimlių parametrų radimas. Randami penki parametrai remiantis Patel'o et al. [30] metodika: efektinė signalo vertė (RMS), netiesinė energija, minimumų ir maksimumų skaičius bei linijos ilgis. Šie parametrai randami epilepsijos epizodui ir tokio paties ilgio epizodui prieš prasidedant epilepsijai. Netiesinė energija (η), N atskaitų imties intervale apskaičiuojama kiekvienam kanalui k atskirai pagal formulę:

$$\eta(k) = \left(\sum_{i=1}^N [x^2(i, k) - x(i+1, k)x(i-1, k)] \right) / N \quad (2.1)$$

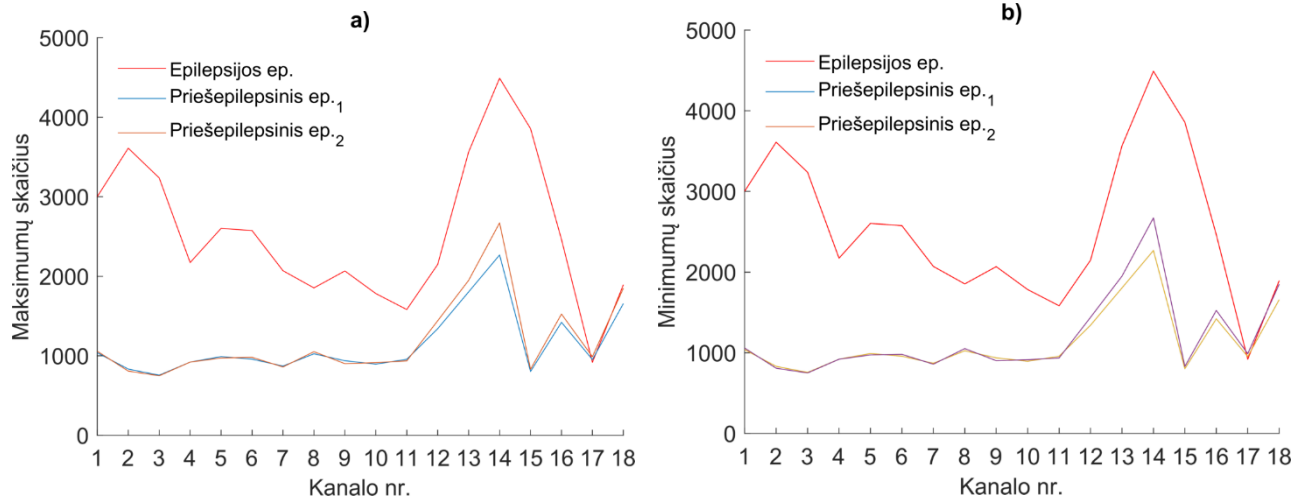
Efektinė EEG signalo vertė (γ), N atskaitų intervale k kanalams apskaičiuojama:

$$\gamma(k) = \sqrt{\left(\sum_{i=1}^N [x(i, k)^2] \right) / N} \quad (2.2)$$

Linijos ilgis (l) N atskaitų intervale k kanalams apskaičiuojamas:

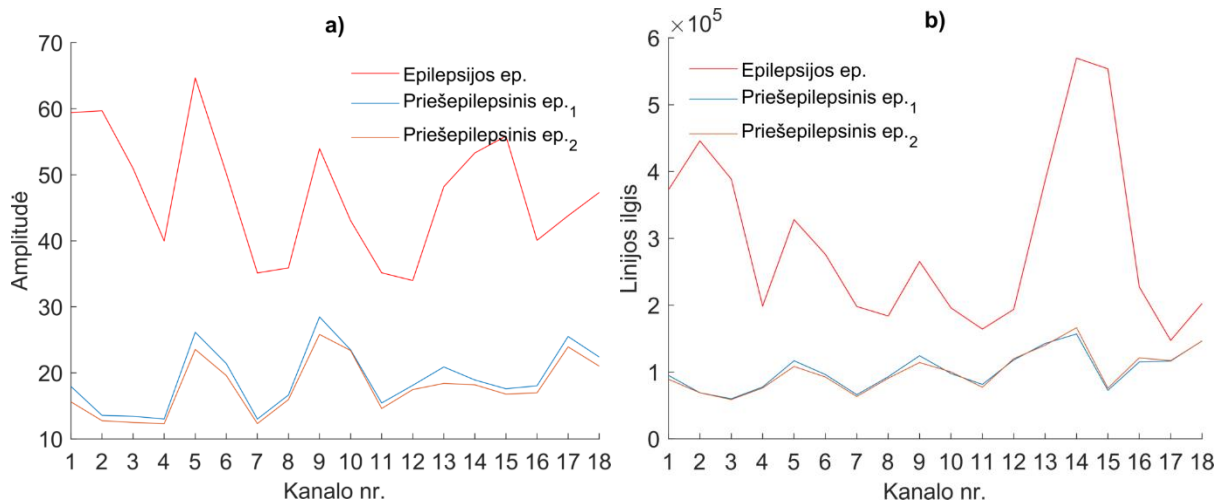
$$l(k) = \sqrt{\left(\sum_{i=1}^N |x(i-1, k) - x(i)| \right)} \quad (2.3)$$

Lokalūs EEG signalo amplitudės minimumai ir maksimumai randami susumuojant lokalių pikų skaičių nagrinėjamame lange. Lokalių minimumų ir maksimumų skaičius pateikiamas 2.8 pav.



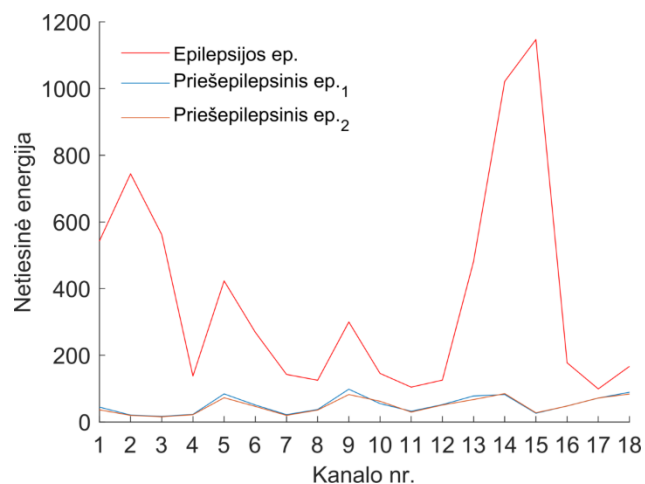
2.8 pav. a) Lokalių minimumų ir b) maksimumų parametrai apskaičiuoti 18 kanalų prieš priepuolį esančiuose epizoduose ir epilepsijos priepuolio metu.

Analizuojant gautus rezultatus matome, kad priešepilepsiniame epizode Nr. 1 bei priešepilepsiniame epizode Nr. 2 skirtumai nežymūs. Nagrinėjant skirtumus tarp epilepsijos ir neepilepsijos intervalų matome, kad kanalai Nr. 15, 13, 2 ir 3 turi didelius skirtumus. Tuo tarpu kanalai Nr. 17 ir 18 turi nežymius pokyčius ir panaudojus juos ABDNT apmokyme galima tikėtis, kad tinklas nesugebės atpažinti epilepsiją. Taip pat pastebime, kad maksimumų skaičius tiesiogiai koreliuoja su minimumų skaičiumi ir suteikia identiškus rezultatus. 2.9 pav. pateikiami apskaičiuoti efektinės EEG signalo vertės bei linijos ilgio parametrai.



2.9 pav. a) RMS ir b) linijos ilgio parametrai apskaičiuoti 18 kanalų prieš priepuolį esančiuose epizoduose ir epilepsijos priepuolio metu.

Kanalai su maksimaliais skirtumais koreliuoja su 2.8 pav. nagrinėtais maksimumų ir minimumų parametrais. Linijos ilgio parametras rodo aukštą santykinį skirtumą kanalui Nr. 14 ir 15. 2.10 pav. pateikiami netiesinės energijos apskaičiuoti parametrai.



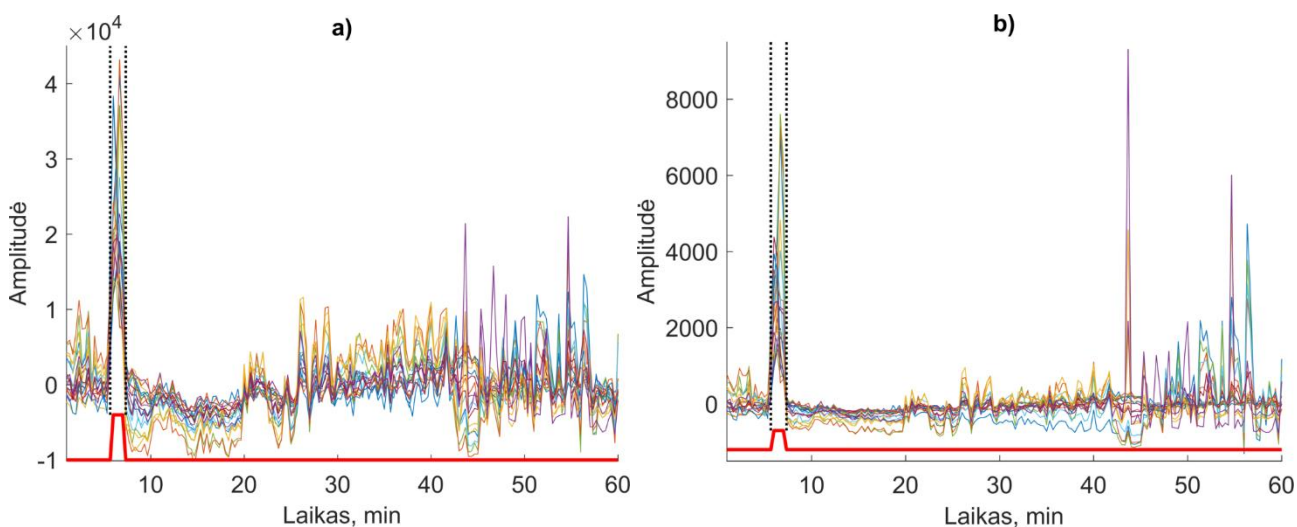
2.10 pav. Netiesinės energijos parametrai apskaičiuoti 18 kanalų prieš priepuolį esančiuose epizoduose ir epilepsijos priepuolio metu.

Matome, kad netiesinės energijos parametro rezultatuose kanalai su maksimaliais pokyčiais taip pat koreliuoja su linijos ilgio bei lokalių minimumų/maksimumų kanalų skirtumų rezultatais. Iš gautų rezultatų galime daryti prielaidą, kad naudojant netiesinės energijos, linijos ilgio bei efektinės EEG signalo vertės parametrus galima išrinkti didžiausius skirtumus turinčius kanalus. Lokalių minimumų ir maksimumų parametrai atmetami iš tolimesnės studijos dėl jų neatsparumo EEG esančiam triukšmui.

2.3. Pirmojo epilepsijos priepuolio atpažinimo galimybių tyrimas

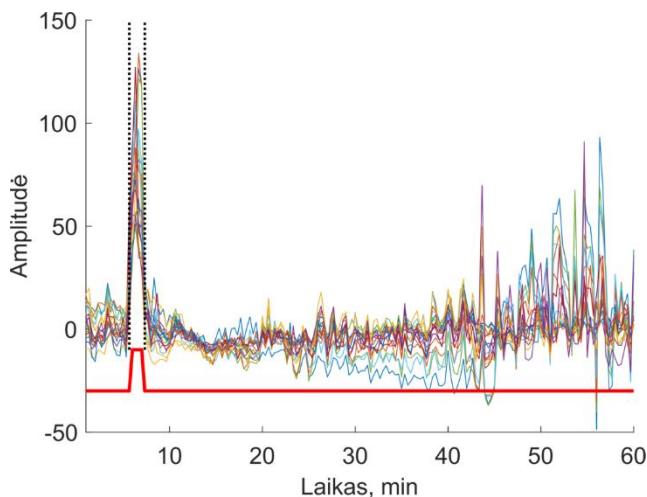
Tam, kad ABDNT būtų apmokytas visų pirma reikia žinoti tikslias priepuolio pradžios ir pabaigos laiko žymes. Idealiu atveju, naudojant anotuotas duomenų bazes, tokia informacija pateikiama, nors ji ir skiriasi tarp nepriklausomų anotuotojų (žr. 2.4 pav.). Kuriant metodą, užregistruoti ir anotuoti individualaus paciento epilepsijos priepuolius yra brangus ir laikui imlus procesas. Būtent dėl šių priežasčių būtina išstudijuoti pirmojo epilepsijos priepuolio aptikimo galimybes nenaudojant siūlomo metodo. Suradus pirmojo priepuolio pradžios ir pabaigos laiko žymes galima apmokyti ABDNT ir

tolimesniame priepuolių atpažinime naudoti tik jį. Naudojant metodiką aprašytą 2.2 skyriuje linijos ilgio, efektinės EEG signalo vertės ir netiesinės energijos parametrus taip pat galima pritaikyti atpažinti pirmąjį epilepsijos priepuolį. Tokių parametrų skaičiavimo laike rezultatai pateikiami 2.11 pav. ir 2.12 pav.



2.11 pav. a) Linijos ilgio ir b) netiesinės energijos parametrai vienos valandos trukmės EEG signale visiems 18 kanalų. Raudona linija apačioje žymi epilepsijos pradžią ir pabaigą.

Pateiktuose paveiksluose galime pastebėti, kad tiek netiesinės energijos, tiek linijos ilgio parametrai geba atskirti epilepsijos epizodą, kuris tęsiasi nuo 8 iki 9 minutės. Taip pat matome, kad ties 45 minute netiesinės energijos parametras padidėja, tačiau tokia triukšmo įtaka stebima tik dviejuose kanaluose. Tuo tarpu epilepsijos metu parametras padidėja visiems kanalams.




2.12 pav. RMS parametrai vienos valandos trukmės EEG signale visiems 18 kanalų. Raudona linija apačioje žymi epilepsijos pradžią ir pabaigą.

Efektinės EEG signalo vertės parametras taip pat rodo skirtumus epilepsijos metu, nors šie skirtumai ir yra santykinai mažesni už linijos ilgio ir netiesinės energijos. Remiantis apskaičiuotais parametrais galima daryti prielaidą, kad pirmą epilepsijos epizodą galima atpažinti naudojant RMS, netiesinę energiją ir linijos ilgį. Šiuo skyriumi pademonstruota potencialiai tinkama metodika atpažinti pirmą epilepsijos priepuolį. Toliau ABDNT apmokyti naudojamos anotuotos priepuolio pradžios ir pabaigos laiko žymės tam, kad būtų išsiaiškintas ABDNT tinkamumas atpažinti epilepsiją ir tam įtakos neturėtų epilepsijos pradžios ir pabaigos suradimo galimi netikslumai.


2.4. Pirminis duomenų bazių signalų apdorojimas

Remiantis personalizuotos kanalų atrankos ir skaičiaus mažinimo metodikos rezultatais, lokalių minimumų ir maksimumų parametrai atmetami, dėl prasto epilepsijos epizodų reprezentavimo ir neatsparumo triukšmui. Tuo tarpu RMS, netiesinės energijos ir linijos ilgio parametrai naudojami kanalų atrankos ir skaičiaus mažinimo metodikoje. Kanalai išrikiuojami pagal didžiausius parametru skirtumus lyginant epilepsijos ir prieš epilepsijos epizodą esantį EEG signalą. Išrikiavimas taikomas kiekvienam parametrai atskirai, išgaunant tris sąrašus (viso trys parametrai). Šiuose sąrašuose surašyti kanalų pavadinimai mažėjimo tvarka remiantis apskaičiuotais skirtumais tarp dviejų minėtų intervalų. Galiausiai kiekvieno sąrašo kanalų pavadinimams priskiriami reitingo taškai, kurie priklausomai nuo pozicijos reitinge suteikia daugiau taškų. Pavyzdžiui, jei kanalas Nr. 1 rodo didžiausią skirtumą, tai jam priskiriama 18 reitingo taškų. Tokia procedūra tęsiama priskiriant vis mažiau taškų kol mažiausius skirtumus turinčiam kanalui priskiriamas 1 reitingo taškas. Tuomet kiekvieno sąrašo taškai susumuojami taip sudarant vieną sąrašą, kur bendri reitingo taškai išsirikiuoja kanalus atsižvelgiant į visų trijų parametru skirtumus. Po tokio kanalų išrikiavimo ABDNT apmokytą ir testuoti naudojami tik keli didžiausius skirtumus (reitingo taškus) turintys kanalai. Tokia kanalų atrinkimo metodika naudojama kiekvienam pacientui personalizuotai panaudojant jo pirmojo epilepsijos priepuolio duomenis. Atlikus pradinį filtravimą neribotos impulsinės reakcijos *Kaizerio* 25 eilės juostiniu filtru su atitinkamais pjūvio dažniais: 0,16 ir 50 Hz, ir kanalų mažinimo metodiką EEG duomenys suformuojami į ABDNT apmokymo epizodus (žr. 2.13 pav.), kur artimiausias intervalas prieš epilepsiją (2) pašalinamas su tikslu turėti staigesnius pokyčius tarp epilepsijos epizodo ir EEG signalo be epilepsijos.



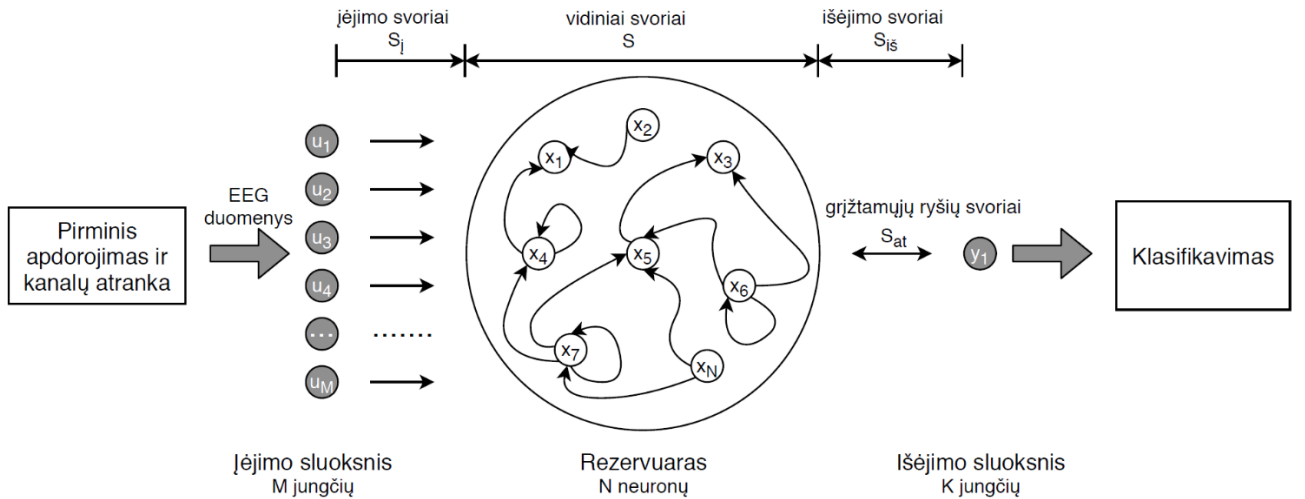
2.13 pav. Apmokymo duomenų paruošimo schema, kur raudonai pažymėta nenaudojamo signalo atkarpa.

Prieš paduodant EEG signalus į ABDNT įėjimus, signalai normalizuojami intervalo [0; 1] ribose. Filtruoti ir atrinkti paciento Nr. 1 „chb01_21.edf“ priepuolio EEG signalai pateikiami 2.14 pav.



2.14 pav. Paciento Nr. 1 „chb01_21.edf“ EEG signalai paruošti apmokyti ABDNT.

2.5. Aido būsenos dirbtinio neuroninio tinklo inicializavimas



2.15 pav. Personalizuoto epilepsijos priepuolių atpažinimo metodo, panaudojant ABDNT, schema.

ABDNT sudaro įėjimo sluoksnis, dinaminis rezervuaras ir išėjimo sluoksnis, kaip pavaizduota 2.15 pav. Rezervuarą sudaro retai ir atsitiktinai sujungtų neuronų tinklas [31]. Darant prielaidą, kad nagrinėjamas ABDNT turi M įėjimo jungčių, N rezervuaro neuronų bei K išėjimo jungčių, ABDNT rezervuarų būsenos atnaujinimas išreiškiamas (2.4) ir (2.5) lygtimis:

$$x(k) = f(S_1 u(k) + Sx(k-1) + S_{at}y(k-1)), \quad (2.4)$$

$$y(k) = f_{is}(S_{is}(u(k), x(k))). \quad (2.5)$$

Ties kiekvienu EEG signalo įėjimu k , įėjimo vektorius $u(k)$, dinaminio rezervuaro būsenos $x(k)$ ir išėjimo vektorius $y(k)$ lygus:

$$u(k) = [u_1(k), u_2(k), \dots, u_M(k)]^T, \quad (2.6)$$

$$x(k) = [x_1(k), x_2(k), \dots, x_N(k)]^T, \quad (2.7)$$

$$y(k) = [y_1(k), y_2(k), \dots, y_K(k)]^T. \quad (2.8)$$

Tuo tarpu kintamasis S_1 žymi įėjimo svorių matricą tarp įėjimo ir rezervuaro sluoksnių sujungimų. S yra vidinių rezervuaro jungčių svorių matrica. Norint užtikrinti energetinį efektyvumą, būtina jungčių kiekį laikyti 1 % – 5 % su spektriniu spinduliu mažesniu nei 1. Dydis S_{at} yra grįžtamųjų ryšių svorių matrica tarp išėjimo ir rezervuaro sluoksnių. S_{is} žymi išėjimo sluoksnio svorių koeficientų matricą. Dydis $f(\cdot)$ nustato vidinių neuronų aktyvacijos funkciją, o $f_{is}(\cdot)$ tinklo išėjimo mazgo aktyvacijos funkciją. Tinklo inicializavimo pradžioje sugeneruojamos trys matricos: įėjimo svorių matrica S_1 , vidinė svorių matrica S ir grįžtamųjų ryšių matrica S_{at} . Šių matricų vertės nekeičiamos ir išlieka tokios pat viso apmokymo ir testavimo metu. Apmokymo metu keičiamos tik išėjimo svorių matricos vertės S_{is} . Taigi, ABDNT apmokymas yra išėjimo svorių matricos skaičiavimas, kuris gali būti atliekamas *Vynerio–Hopfo* lygtimi:

$$S_{is} = M^{-1}T, \quad (2.9)$$

kur M yra įėjimo ir rezervuaro būsenų matrica:

$$M = [x(T_0)^T, x(T_0 + 1)^T, \dots, x(T)^T]^T, \quad (2.10)$$

ir T yra mokymo idealių verčių matrica:

$$T = [y(T_0), y(T_0 + 1), \dots, y(T)]^T, \quad (2.11)$$

kur T_0 ($T_0 < T$) yra pradinis tinklo laikas.

2.6. Skyriaus išvados

1. Naujagimių duomenų bazės anotacijų sutapimas yra žemas (*Fleiss* $\kappa=0,777$), o tai gali daryti neigiamą įtaką apmokant ABDNT. Tuo tarpu vaikų duomenų bazėje pateiktos tik vieno anotuotojo anotacijos, todėl negalima įvertinti anotacijų sutapimo.
2. Jei ABDNT apmokyti naudojami EEG signalai, kuriuose neįvyksta esminių pokyčių epilepsijos metu, toks tinklas negali tinkamai atpažinti epilepsijos priepuolių. Pokyčiams aptikti ir atrinkti EEG signalus su didžiausiais pokyčiais geriausiai tinka RMS, netiesinės energijos ir linijos ilgio parametrai.
3. Lokalių minimumų ir maksimumų parametrai neįtraukiami į tolimesnius tyrimus dėl jų neatsparumo EEG signale esantiems triukšmams.
4. Pirmojo epilepsijos priepuolio atpažinimo galimybių tyrimas nenaudojant ABDNT parodė, kad priepuolio pradžia ir pabaiga gali būti aptinkama naudojant linijos ilgio, netiesinės energijos ir RMS parametrus.

3. Personalizuoto epilepsijos stebėsenos metodo parametrų parinkimo tyrimas

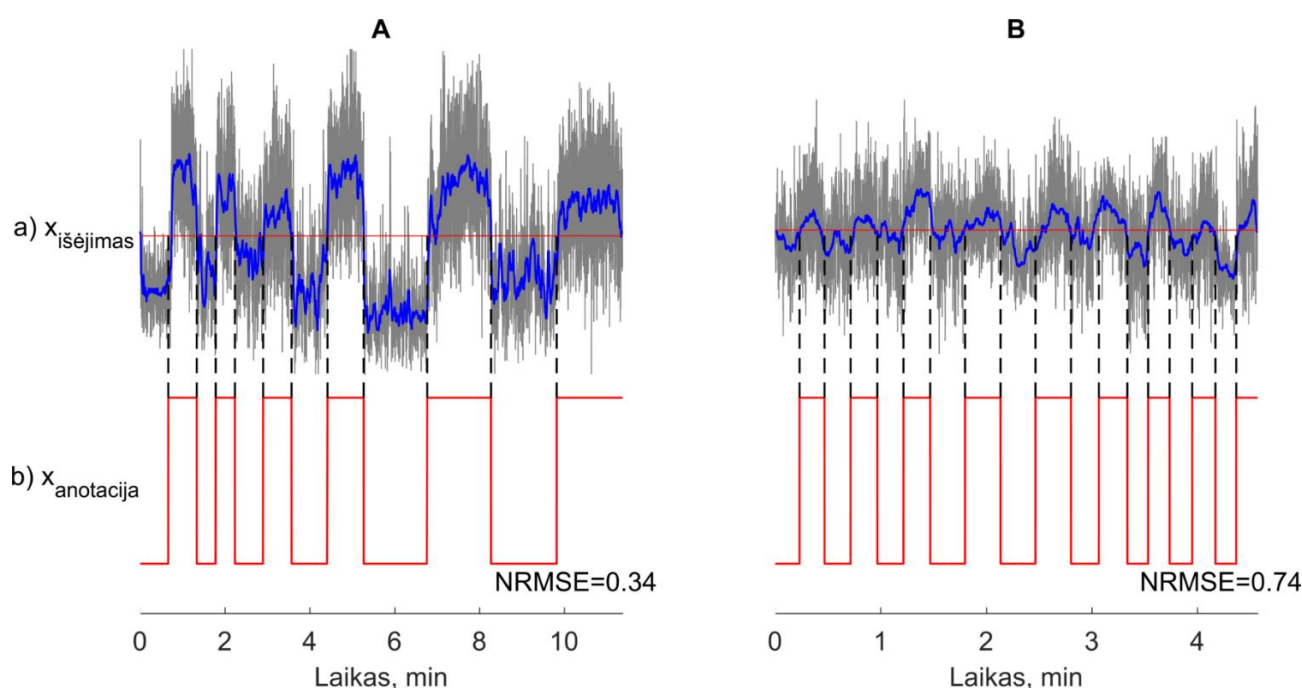
ABDNT, kaip ir visų kitų neuroninių tinklų, veikimas priklauso nuo tinklo parametrų rinkinio. Šio skyriaus tyrimų pagrindinė užduotis - rasti parametrų kombinaciją, kuri leidžia pasiekti geriausius rezultatus atsižvelgiant į skaičiavimams naudojamus energetinius resursus.

3.1. Parametrų parinkimo kriterijai

Parametrų parinkimas atliekamas atsižvelgiant į skaičiavimo resursus ir minimizuojant normalizuotą vidutinę kvadratinę paklaidą (NRMSE), kuri skaičiuojama pagal išraišką:

$$NRMSE = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (x_{išėjimas} - x_{anotacija})^2}}{x_{max} - x_{min}}, \quad (3.1)$$

kur $x_{išėjimas}$ yra ABDNT išėjimas ir $x_{anotacija}$ yra anotuotojo pateikta anotacija tai pačiai EEG signalo atkarpai. Atitinkamai x_{max} ir x_{min} reiškia $x_{išėjimas}$ EEG signalo maksimalią ir minimalią reikšmę, tuo tarpu dydis N reiškia atskaitų skaičių. NRMSE paklaidos skaičiavimo pavyzdys pateiktas 3.1 pav.



3.1 pav. A: paciento Nr. 1 NRMSE skaičiavimo pavyzdys ABDNT mokymo rezultatams, kur a) pilka spalva- ABDNT išėjimo signalas, mėlyna spalva - medianos filtruotas ABDNT išėjimo signalas b) anotuotas signalas. B: paciento Nr. 6 NRMSE skaičiavimo pavyzdys.

Keičiant tinklo parametrus kiekvienu atveju skaičiuojama NRMSE, kur siekiamybė yra mažesnė reikšmė, reiškianti mažesnį skirtumą tarp anotacijos ir ABDNT išėjimo. Parametrų parinkimo metu didelis dėmesys kreipiamas ir į skaičiavimo laiką, kuris itin svarbus stengiantis įvertinti energetinį efektyvumą. Parametrų parinkimo metu nekeičiami šie parametrai: rezervuaro neuronų aktyvacijos funkcija, išėjimų skalės daugiklis, grįžtamojo ryšio svoriniai koeficientai, tinklo tarpusavio jungčių kiekis. Tinklo grįžtamojo ryšio svoriniai koeficientai iš išėjimo sluoksnio į rezervuarą prilyginami 0. Tarpusavio jungčių kiekis priklauso nuo rezervuaro neuronų skaičiaus ir parenkamas pagal:


$$j = \min ([10/N \ 1]), \quad (3.2)$$

tačiau neviršina 1 %. Išėjimų skalės daugiklis fiksuojamas ir prilyginamas 1. Mažesnė išėjimų skalės daugiklio reikšmė atitinkamai mažina išėjimo signalo amplitudę. Kiti ABDNT parametrai keičiami

kiekvieno eksperimento metu: neuronų skaičius, apmokymo duomenų santykis, įėjimų į ABDNT kiekis (kanalų skaičius), spektrinis spindulys, neuronų pralaidumo koeficientas (angl. leakage), rezervuaro triukšmo lygis, įėjimų skalės daugiklis ir išėjimo neuronų aktyvacijos funkcijos tipas. Šie parametrai parenkami bendrai visam ABDNT nepriklausomai nuo konkretaus paciento.

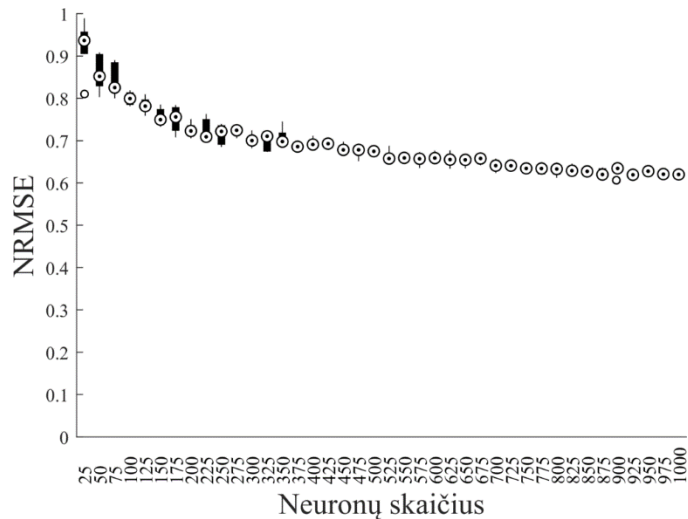
3.2. Neuronų skaičiaus įtakos tyrimas

ABDNT neuronų skaičiaus įtakos tyrimas atliekamas siekiant nustatyti reikiamą rezervuaro neuronų skaičių N , prie kurio metodas veikia efektyviausiai NRSME ir energetinio efektyvumo atžvilgiu apdorojant vaikų duomenų bazės EEG signalus. Neuronų skaičius didinamas nuo 25 iki 1000, 25 neuronų žingsneliu. Parenkami tokie pradiniai ABDNT parametrai: rezervuaro spektrinis spindulys $\rho = 1$, įėjimų skalės daugiklis $\gamma = 1$, įėjimų į ABDNT kiekis $M = 18$, rezervuaro triukšmo lygis $\mu = 0,001$, išėjimo neuronų aktyvacijos funkcija – tiesinė, neuronų pralaidumo koeficientas $l = 0,8$. ABDNT apmokomas kiekvieno paciento visais epilepsijos priepuoliais, išskyrus paskutinį, kuris naudojamas tinklui testuoti. Tyrimo metu skaičiuojama NRSME paklaida ir laikas, sugaištas atlikti skaičiavimus vienai minūtei EEG signalo. 3.2 pav. pateikti tyrimo rezultatai naudojant stačiakampę diagramą, kur mediana ir kvartilai skaičiuoti visai vaikų duomenų bazei.



3.2 pav. ABDNT dinaminio rezervuaro neuronų skaičiaus įtakos tyrimo rezultatai. a) NRMSE paklaidos priklausomybė nuo neuronų skaičiaus ir b) vienos minutės trukmės EEG signalo skaičiavimo laiko priklausomybė nuo neuronų skaičiaus.

NRMSE mažėja didėjant neuronų skaičiui, tačiau mažėjimo tendencija darosi vis labiau plokščia. Atvaizduojant visos duomenų bazės NRMSE sunku išvelgti atskirų pacientų NRMSE išsibarstymo įtaką, nes vertės skiriasi tarpusavyje. Atsižvelgiant į paciento Nr.1, kuris gerai reprezentuoja atskirų pacientų tyrimo rezultatus 3.3 pav. galime pastebėti, kad paklaidos kitimo tendencija analogiška, tačiau esant didesniai neuronų skaičiui, mažėja NRMSE išsibarstymas. Tai ypač aiškiai matosi neuronų skaičiui esant didesniai nei 375.




3.3 pav. Paciento #1 dinaminio rezervuaro neuronų skaičiaus įtakos tyrimo rezultatai.

Atsižvelgiant į gautus rezultatus bei stengiantis minimizuoti naudojamus metodo resursus darome prielaidą, kad 400 neuronų yra tinkamas pasirinkimas, kuris užtikrina sumažėjusį NRMSE išsibarstymą ir turi santykinai mažą 5,8 ms vienos minutės trukmės EEG signalo skaičiavimo laiką.


3.3. Kanalų skaičiaus įtakos tyrimas

Taip pat svarbu įvertinti epilepsijos priepuoliams aptikti naudojamų kanalų skaičių, kuris gali būti keičiamas pasitelkiant personalizuotą kanalų atrankos ir skaičiaus mažinimo metodiką. Čia atliekamas tyrimas su vaikų duomenų bazės EEG signalais, keičiant kanalų skaičių nuo 1 iki 10. Dėl didelių skaičiavimams reikalingų energijos resursų sąnaudų didesnio kanalų skaičiaus įtaka nėra tiriama. Kiekvienu atveju ABDNT apmokyti naudojami didžiausius skirtumus (reitingo taškus) turintys kanalai, pagal personalizuotą kanalų atrankos ir skaičiaus mažinimo metodiką (žr. 2.5 skyrių). Parenkami tokie pradiniai ABDNT parametrai: rezervuaro spektrinis spindulys $\rho = 1$, įėjimų skalės daugiklis $\gamma = 1$, rezervuaro triukšmo lygis $\mu = 0,001$, išėjimo neuronų aktyvacijos funkcija – tiesinė, neuronų pralaidumo koeficientas $l = 0,8$, neuronų skaičius $N = 400$. Tyrimo metu skaičiuojama NRMSE ir laikas, sugaištas vienos minutės ilgio EEG signalo skaičiavimams. 3.4 pav. pateikti tyrimo rezultatai naudojant stačiakampę diagramą.



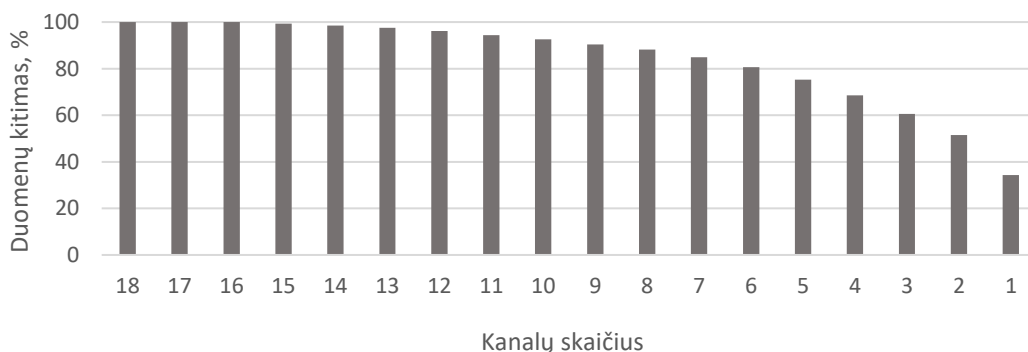
3.4 pav. Kanalų skaičiaus įtakos NRMSE paklaidai tyrimo rezultatai. a) kanalų skaičiaus įtaka NRMSE ir b) vienos minutės EEG signalo ilgio skaičiavimo laiko priklausomybė nuo kanalų skaičiaus.

Matome, kad NRMSE mažėja didėjant kanalų skaičiui nuo 1 iki 3. Tačiau kai kanalų skaičius tampa didesnis nei 3 apmokymo paklaida beveik nemažėja. Tokie rezultatai patvirtina kanalų atrankos metodo logiškumą ir įrodo, kad didesnis kanalų skaičius gali bloginti ABDNT apmokymo procesą. Lyginant sugaištą laiką ties 3 ir 10 kanalų matome, kad jis skiriasi nežymiai 1,13 karto (1,62 ir 1,85 μ s). Atsižvelgiant į atskirų pacientų tyrimo rezultatus 3.5 pav. galime pastebėti, kad paklaidos kitimo tendencija analogiška kur aiškiai matosi, kaip didesnis kanalų skaičius padidina NRMSE, ir pablogina metodo apmokymą.



3.5 pav. Paciento #1 kanalų skaičiaus įtakos NRMSE paklaidai tyrimo rezultatai.

Siekiant dar labiau išsiaiškinti tinkamą kanalų skaičių, atliekama pagrindinių komponentių analizė. Iš gautų rezultatų aiškiai matosi, kad apie 75 % duomenų kitimo sutelkta 5 kanaluose.

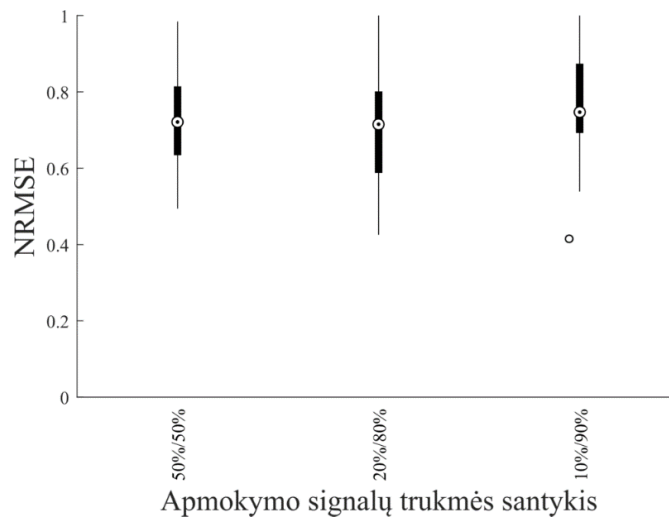


3.6 pav. EEG signalų kitimo įvertinimas esant skirtingam kanalų skaičiui, atliekant pagrindinių komponentių analizę.

Atlikti bandymai su skirtingu kanalų skaičiumi parodė, kad 5 kanalai yra tinkamas variantas skaičiavimo efektyvumo ir metodo našumo aspektais.

3.4. Apmokymo signalų trukmės įtakos tyrimas

Naudojama skirtinga EEG signalų trukmė apmokyti ABDNT gali turėti skirtingą įtaką, todėl nagrinėjami tokie signalų trukmės santykiai: 50% ir 50%, 20% ir 80%, 10% ir 90%. Šis santykis išreiškiamas epilepsijos epizodo trukmės ir prieš epilepsiją esančio EEG signalo trukmės santykiu. Tyrimas atliekamas su vaikų duomenų bazės EEG signalais. Parenkami tokie pradiniai ABDNT parametrai: rezervuaro spektrinis spindulys $\rho = 1$, įėjimų skalės daugiklis $\gamma = 1$, įėjimų į ABDNT kiekis $M = 5$, rezervuaro triukšmo lygis $\mu = 0,001$, išėjimo neuronų aktyvacijos funkcija – tiesinė, neuronų pralaidumo koeficientas $l = 0,8$, neuronų skaičius $N = 400$. Tyrimo metu skaičiuojama NRMSE paklaida.

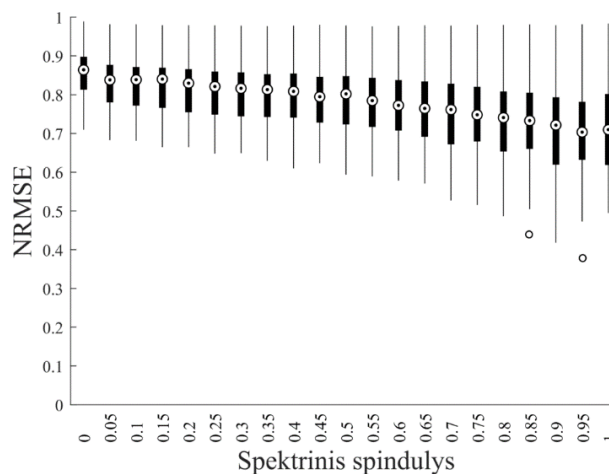


3.7 pav. Apmokymo EEG signalų trukmės įtakos NRMSE paklaidai rezultatai. Rezultatai pateikti naudojant stačiakampę diagramą, kur mediana ir kvartiliai skaičiuojami visai vaikų duomenų bazei.

Matome, kad NRMSE nesikeičia keičiant epilepsijos epizodo trukmės ir prieš epilepsiją esančio EEG signalo trukmės santykį. Pastebimas netgi priešingas efektas, esant didesniai santykiui didėja NRMSE sklaida. Tai gali nutikti dėl apmokymo duomenų disbalanso, nes didėjant EEG signalo ilgiui, kuris atspindi ne epilepsijos epizodą, ABDNT gerai apsimoko su tokiais duomenimis ir ne taip jautriai reaguoja į epilepsijos signalą. Tokie rezultatai rodo, kad apmokyti ABDNT reikia naudojant duomenų santykį 50%/50%.

3.5. Spektrinio spindulio įtakos tyrimas

Šiame tyrime įvertinama spektrinio spindulio įtaka. Spektrinis spindulys apsprendžia rezervuaro neuronų tarpusavio sąveikos nuotolį. Rezervuaro spektrinis spindulys ρ keičiamas nuo 0 iki 1, 0.05 žingsniu. Tyrimas atliekamas su vaikų duomenų bazės EEG signalais. Parenkami tokie pradiniai ABDNT parametrai: įėjimų skalės daugiklis $\gamma = 1$, įėjimų į ABDNT kiekis $M = 5$, rezervuaro triukšmo lygis $\mu = 0,001$, išėjimo neuronų aktyvacijos funkcija – tiesinė, neuronų pralaidumo koeficientas $l = 0,8$, neuronų skaičius $N = 400$, apmokymo duomenų santykis 50%/50%. Tyrimo metu skaičiuojama NRMSE paklaida. 3.8 pav. pateikti tyrimo rezultatai.

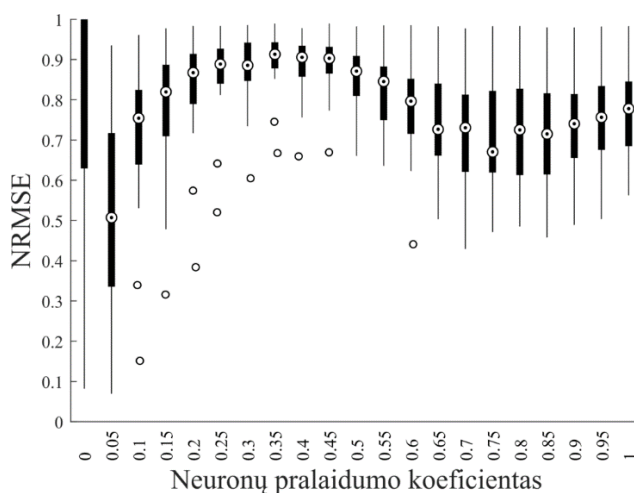


3.8 pav. Spektrinio spindulio įtakos tyrimo rezultatai, atvaizduojant NRMSE paklaidos priklausomybę nuo spektrinio spindulio [0:1] ribose.

Mažiausia NRMSE ribose tarp 0 ir 1 gaunama kai spektrinis spindulys lygus $\rho = 0,95$, tačiau dėl skaičiavimo supaprastinimo naudojamas dydis $\rho = 1$, kuriam esant NRMSE skiriasi nežymiai.

3.6. Neuronų pralaidumo koeficiento įtakos tyrimas

Šiame tyrime atliekamas neuronų pralaidumo koeficiento l (angl. leakage) įtakos įvertinimas. Parametras keičiamas nuo 0 iki 1, 0,05 žingsneliu, kur mažesnis koeficientas reiškia didesnę filtravimo lygį. Tyrimas atliekamas su vaikų duomenų bazės EEG signalais. Parenkami tokie pradiniai ABDNT parametrai: įėjimų skalės daugiklis $\gamma = 1$, įėjimų į ABDNT kiekis $M = 5$, rezervuaro triukšmo lygis $\mu = 0,001$, išėjimo neuronų aktyvacijos funkcija – tiesinė, neuronų skaičius $N = 400$, apmokymo duomenų santykis 50%/50%, spektrinis spindulys $\rho = 1$. Tyrimo metu skaičiuojama NRMSE paklaida. 3.9 pav. pateikti tyrimo rezultatai naudojant stačiakampę diagramą.



3.9 pav. Neuronų pralaidumo koeficiento įtakos tyrimo rezultatai, atvaizduojant pralaidumo koeficiento [0:1] ribose įtaką NRMSE paklaidai.

Matome, kad ribose tarp 0 ir 1 gaunama mažiausia NRMSE kai neuronų pralaidumo koeficientas artėja į 0, tačiau siekiant išvengti ABDNT nestabilumo ir generavimo šios vertės nėra priimtinos. Tai puikiai iliustruoja daugiau kaip tris kartus išaugusi NRMSE sklaida. Taip pat galima pastebėti, kad esant didžiausiai paklaidai tuo pat metu stebima mažiausia NRMSE sklaida. Gauname, kad mažiausia NRMSE gaunama ties neuronų pralaidumo koeficientu $l = 0,75$.

3.7. Kitų aido būsenos dirbtinio neuroninio tinklo parametrų tyrimas

Analogiški tyrimai atliekami likusiems parametrams: įėjimų skalės daugikliui γ , rezervuaro triukšmo lygiui μ , rezervuaro ir išėjimo neuronų aktyvacijos funkcijoms. Čia gauname, kad mažiausios NRMSE vertės pasiekiamos su tokia parametrų kombinacija: $\gamma = 0,75$, $\mu = 0,001$, išėjimo neuronų aktyvacijos funkcija „*tiesinė*“, rezervuaro neuronų aktyvacijos funkcija „hiperbolinio tangento“.

3.8. Skyriaus išvados

1. Didesnis ABDNT neuronų skaičius rezervuare siejamas su didesne atmintimi, kas gali leisti pasiekti geresnius rezultatus. Visgi, dėl didelio neuronų skaičiaus ABDNT lėčiau reaguoja į staigius pokyčius EEG signale.
2. Pirminė EEG signalų analizė parodė, kad kai kurie kanalai gali pabloginti ABDNT apmokymą, nes juose nėra akivaizdžių skirtumų prieš epilepsiją ir epilepsijos metu. Bandymai su skirtingu kanalų skaičiumi parodė, kad didesnis kanalų skaičius padidina NRMSE, ir pablogina ABDNT apmokymą. NRMSE mažai kinta keičiant epilepsijos epizodo trukmės ir prieš epilepsiją esančio EEG signalo trukmės santykį. Stebimas priešingas efektas, t. y. didėjant prieš epilepsiją esančio EEG trukmei didėja NRMSE sklaida.

4. Personalizuoto epilepsijos stebėsenos metodo tyrimas su klinikiniais signalais

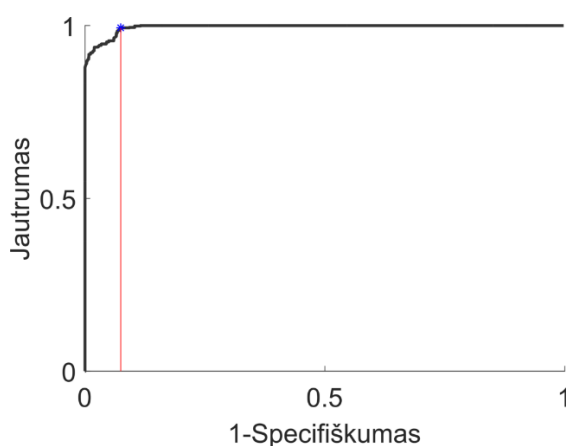
Atliekami metodo tyrimai su epilepsijos priepuolių turinčiomis klinikinėmis duomenų bazėmis. Pirmasis tyrimas atliekamas su vaikų duomenų baze. Antrasis tyrimas atliekamas su naujagimių duomenų baze.

4.1. Aido būsenos dirbtinio neuroninio tinklo tyrimo su klinikiniais signalais kriterijai

ABDNT tirti su klinikiniais dviejų duomenų bazių EEG signalais naudojamas kryžminės validacijos būdas. ABDNT išėjimas triukšmingas (žr. 4.2 pav.), todėl naudojamas judančio lango medianos filtras (mėlyna kreivė). Tuomet kiekvienam pacientui taikomas slenkstis, kuris skaičiuojamas naudojant *Youdeno* indeksą J :

$$J = \max(\text{jautrumas} + \text{specifiškumas} - 1), \quad (4.1)$$

kur *jautrumas* ir *specifiškumas* gaunami iš operatoriaus charakteringų kreivių (ROC), 4.1 pav. Kiekvienas ROC kreivės taškas gaunamas suskaičiavus jautrumą ir specifiškumą prie skirtingų slenksčio lygių.



4.1 pav. Paciento Nr. 1 ROC kreivės pavyzdys, kur slenkstio vertė nustatoma remiantis *Youdeno* indeksu.


Galiausiai, skaičiuojamas jautrumas, specifiškumas ir diagnostinis tikslumas atsižvelgiant į kiekvieną EEG signalo imtį, pagal (4.2 – (4.4) formules:

$$\text{Jautrumas} = \frac{TT}{TT + KN} \quad (4.2)$$

$$\text{Specifiškumas} = \frac{TN}{TN + KT} \quad (4.3)$$

$$\text{Diagnostinis tikslumas} = \frac{TT + TN}{TT + KT + KN + TN} \quad (4.4)$$

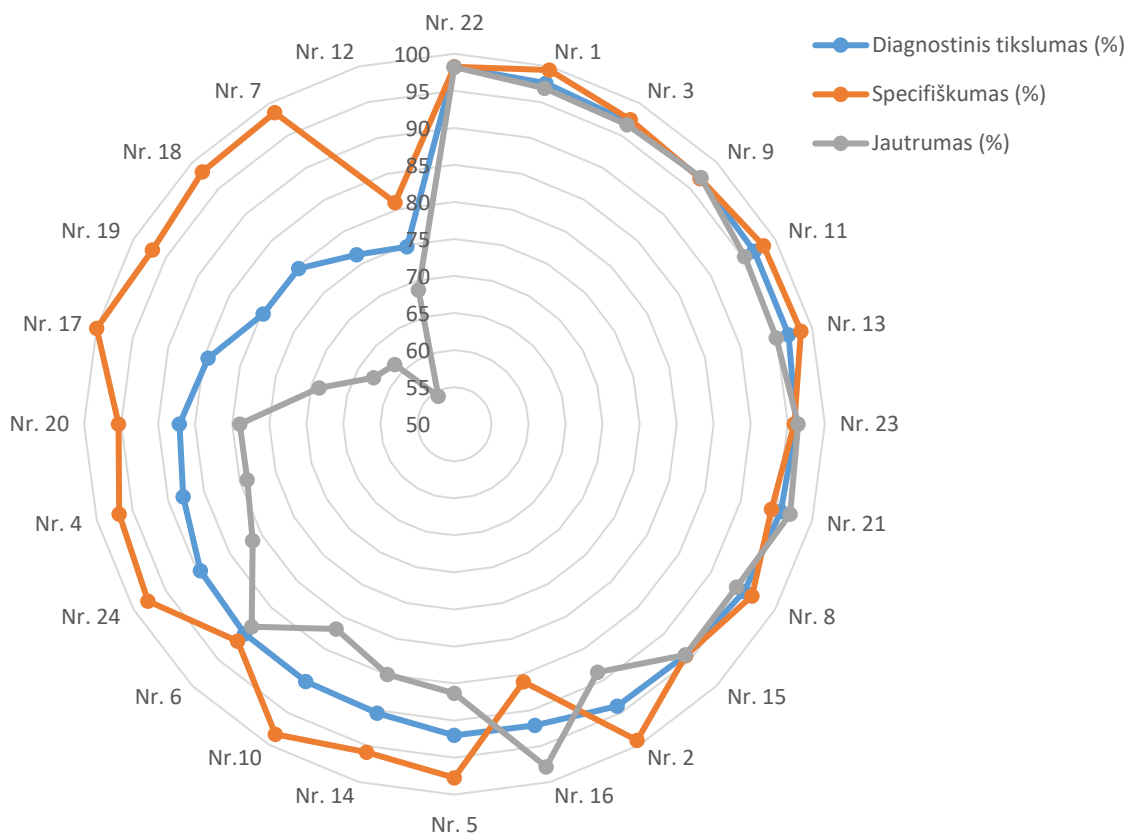
Diagnostinio klasifikavimo rezultatai skaičiuojami lyginant 4.2 pav. b) $x_{i\delta}$ signalą su 4.2 pav. c) anotacijos x_a , kur TT – atskaita anotuota kaip priepuolis, o metodo išėjimas teigiamas; KT – atskaita anotuota kaip normali veikla, bet metodo išėjimas teigiamas; TN – atskaita anotuota kaip normali veikla, o metodo išėjimas neigiamas; KN – atskaita anotuota kaip priepuolis, bet metodo išėjimas neigiamas.



4.2 pav. Paciento Nr. 1 diagnostinio tikslumo, jautrumo ir specifiškumo skaičiavimo pavyzdys ABDNT rezultatams, kur a) ABDNT išėjimo signalas b) apdorotas išėjimo signalas ir c) anotuotas signalas. Diagnostinis tikslumas 96,96 %, jautrumas 95,92 % ir specifiškumas 97,95 %.

4.2. Tyrimas su klinikiniais vaikų duomenų bazės signalais

Atlikus kryžminę validaciją bendras metodo diagnostinis tikslumas naudojant vaikų duomenų bazę lygus 90,87 %. Atskiri pacientų rezultatai pateikiami 4.3 pav. ir priede Nr. 3.




4.3 pav. Metodo rezultatai, testavime naudojant vaikų duomenų bazę, pateikti radaro tipo grafiku. Rezultatai išrikiuoti diagnostinio tikslumo mažėjimo tvarka.

Analizuojant kiekvieno paciento EEG signalams pasiektą diagnostinį tikslumą, galime pastebėti, kad pacientas Nr. 22, 1 ir 3 turi didesnę kaip 98 % diagnostinį tikslumą, specifiškumą ir jautrumą.

4.3. Tyrimas su klinikiniais naujagimių duomenų bazės signalais

Greta turimos vaikų duomenų bazės atlikti tyrimai su ABDNT parametru radime nenaudota naujagimių duomenų base. Naudojamas analogiškas EEG signalų pirminis apdorojimas, kanalų atrankos metodika ir ABDNT parametrai kaip ir vaikų duomenų bazės atveju. Dėl didelio kiekio epilepsijos priepuolių ir mažo atstumo tarp skirtingų priepuolių duomenų bazę sunku išskaidyti į apmokymo ir testavimo epizodus kaip tai padaryta vaikų duomenų bazės atveju (žr. 2.13 pav.). Todėl visa EEG signalo trukmė dalinama 80–20 % principu neišskiriant atskirų epilepsijos priepuolių, kur 20 % EEG trukmės skirta apmokyti ABDNT ir 80 % testuoti. Gauti rezultatai pateikiami 4.4 pav.



4.4 pav. Įgyvendinto metodo rezultatai, testavime naudojant naujagimių duomenų bazę, pateikiami radaro tipo grafiku. Rezultatai išrikiuoti diagnostinio tikslumo mažėjimo tvarka.

Bendras metodo diagnostinis tikslumas naudojant naujagimių duomenų bazę lygus 85,17 %, kur specifiskumas ir jautrumas atitinkamai lygūs 86,82 % ir 80,83 %. Atskiri pacientų rezultatai pateikiami priede Nr. 5. Analizuojant rezultatus pagal priepuolio lokaciją, galima pastebėti, kad geriausius rezultatus rodo atvejai su abipuse priepuolio lokacija (atvejai #47, #41, #13), tačiau yra ir išimčių (atvejis #69). Blogiausių diagnostinį tikslumą 80,42 % rodo besikeičiančios lokacijos priepuolius turintis atvejis #1. Čia kanalų atrankos metodas iš pirmojo priepuolio išrenka didžiausius skirtumus reprezentuojančius kanalus ir šie kanalai naudojami likusiems atvejo priepuoliams diagnozuoti. Jei pacientas turi besikeičiančios lokacijos priepuolius, tai tokiu atveju pasikeitus priepuolio lokacijai išrinktuose kanaluose pakitusi veikla gali būti nepastebima. Šią problemą galima spręsti tik didinant kanalų skaičių. Taip pat žinoma, kad naujagimių EEG keičia savo formą pirmomis savaitėmis po gimimo, atsižvelgus į atskirus rezultatus galime pastebėti, kad tiriamųjų amžius diagnostiniam tikslumui įtakos neturėjo.

5. Diskusija


Pastebėta, kad kai kurie epilepsijos epizodai priepuolio pradžioje panašūs į įprastą EEG, dėl to sumažėja metodo jautrumas ir tai gali būti netikslios anotacijos pasekmė. Be to, pastebėta, kad nekeičiant ABDNT parametrų ir iš naujo atlikus pradinį inicializavimą gaunamas skirtingas diagnostinis tikslumas, kurį gali lemti likęs triukšmas EEG signaluose. Tai didžiąja dalimi elektromiografiniai triukšmai. Elektromiografinių triukšmų šalinimas reikalauja didelių energijos sąnaudų, todėl EEG nefiltruoti nuo šių triukšmų stengiantis išlaikyti žemą energijos suvartojimą. Apie didelio artefaktų kiekio įtaką metodo rezultatams užsimena ir kiti autoriai [32]. Taip pat maždaug 50% autorių nefiltruoja EEG signalų bandant aptikti priepuolius, o likusiųjų didžioji dalis filtruoja signalus tik pusiau automatiniais metodais. Papildomai metode galima skaičiuoti EEG kokybės indeksą, kuris parodytų triukšmingas signalo vietas. Tokios EEG signalo vietos galėtų būti nenaudojamos epilepsijai aptikti. Tokiu atveju atmetus atvejus Nr. 12 ir 7 iš vaikų duomenų bazės bendras metodo diagnostinis tikslumas, jautrumas ir specifiškumas atitinkamai taptų lygus 91,89 %, 87,33 % ir 96,51 %. Modernėjant elektromiogramos šalinimo iš EEG signalo metodams galima apsvarstyti ir papildomus triukšmo mažinimo būdus bei įvertinti jų įtaką metodo rezultatams.

Norint užtikrinti energetinį efektyvumą taip pat atliktas tyrimas su skirtingais diskretizavimo dažniais, kur geriausius rezultatus rodo 25 Hz dažniu diskretizuoti EEG signalai. Sumažinus diskretizavimo dažnį iki 25 Hz EEG signalams iš vaikų duomenų bazės buvo gautas 92,02 % diagnostinis tikslumas, 95,40 % specifiškumas ir 88,68 % jautrumas. Padidinus diskretizavimo dažnį iki 100 Hz metodo diagnostinis tikslumas, priešingai nei tikėtasi, sumažėjo iki 90,53 %. Tokie rezultatai leidžia diskretizuoti EEG signalus 25 Hz dažniu, kas savo ruožtu sumažina energijos resursų sunaudojimą skaičiavimams. Taip pat reikia pabrėžti, kad kanalų mažinimo metodika padidino bendrą metodo diagnostinį tikslumą apie 12 %.

Literatūroje pastebėta, kad epilepsijos priepuolius sudėtingiau aptikti naujagimių EEG veikloje, dėl kelių priežasčių. Visų pirma, epilepsijos priepuoliai skiriasi nuo suaugusių ar vyresnių vaikų, nes priepuoliai dažni ir trumpi, tai galima pastebėti ir iš 2.4 pav. a) dalies, kur 100 minučių EEG signale anotuoti net 36 priepuoliai. Nors ir pagrindinė smegenų žievė naujagimiuose susiformavusi, tačiau dendritinės jungtys ir sinapsinė stabilizacija nėra visiškai subrendusi, kaip ir mielino sluoksnis, kuris turi sumažinti priepuolių plitimą į kitas smegenų sritis [33]. Sukurtas metodas remiasi ABDNT apmokymu iš neapdorotų EEG, vietoje EEG signalus parametrizuojančių charakteristikų radimo, todėl toks tyrimas gerai pademonstravo metodo prisitaikymo galimybes prie santykinai kitokių EEG signalų ir atvejų.

5.1. Aido būsenos dirbtinio neuroninio tinklo atsitiktinio inicializavimo įtaka

Pastebėta, kad nekeičiant jokių ABDNT parametrų ir apmokymo duomenų, gaunami skirtingi testavimo rezultatai. Tai sukelia atsitiktinis pradinis ABDNT inicializavimas ir dėl to atsirandanti nevienoda galutinė tinklo būsena. Tam tikrais atvejais prieš apmokymo procesą atsitiktinai inicializavus ABDNT svorius šie greitai konverguoja apmokymo etape ir geba tinkamai aptikti epilepsijos priepuolius. Tuo tarpu būna atvejų kai dėl atsitiktinio inicializavimo ABDNT sunkiai konverguoja ir gaunami sąlyginai blogi rezultatai. Toks ABDNT rezultatų variavimas įvertinamas atliekant testą, kuriame nekeičiant jokių parametrų kartojamas apmokymo protokolas su tais pačiais duomenimis. Čia atikus penkias ABDNT apmokymo iteracijas pateikiamas apskaičiuotas diagnostinis tikslumas.



5.1 pav. Atsitiktinio inicializavimo įtaka, kai ABDNT rezervuaro dydis: a) 400 neuronų ir b) 1000 neuronų.

Pacientų Nr. 17/19/4/7 diagnostinis tikslumas varijuoja labiau nei likusių pacientų, tai atsispindi ir 4.3 pav. rezultatuose, kur gaunamas žemesnis metodo diagnostinis tikslumas. Jautrumas ir specifiškumas šiuose atvejuose taip pat nutolęs nuo diagnostinio tikslumo. Toki rezultatai nestebimi aukšto diagnostinio tikslumo atvejuose pvz.: Nr. 1/2/3/21/22. Tokia ABDNT veikla įrodo, kad tam tikrais atvejais tinklas nekonverguoja. Tikėtina, kad tai priklauso nuo anotacijų tikslumo, bet ne nuo turimų apmokymo priepuolių skaičiaus. Tokį teiginį pagrindžia priede Nr. 4 pateiktos diagramos. Čia diagnostinis tikslumas, priepuolių skaičius, bendra ir vidutinės priepuolių trukmės pateikiamos radaro tipo diagramomis, kur atitinkami dydžiai išrikiuoti mažėjimo tvarka. Matome, kad priepuolio trukmės bei skaičiaus įtaka nekoreliuoja su diagnostinio tikslumo rezultatais. Pacientai Nr. 2 ir Nr. 9 turi atitinkamai 3 ir 4 priepuolius, tačiau metodas rodo aukštą diagnostinį tikslumą (94% ir 97 %). Tuo tarpu pacientas Nr. 24 turi 16 priepuolių, o metodu pasiektas tik 89 % diagnostinis tikslumas.

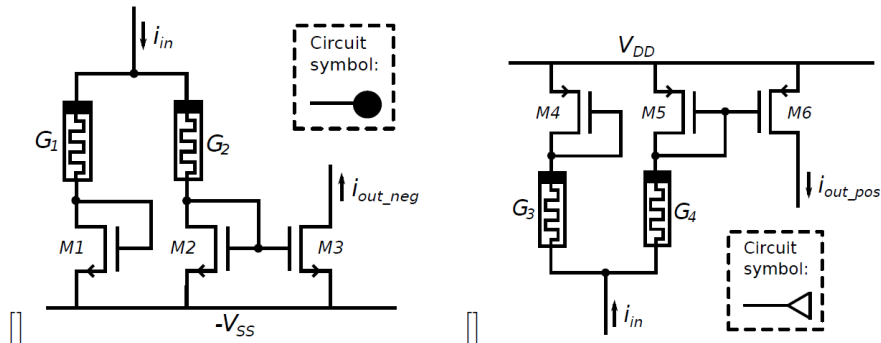
5.2. Energetinių sąnaudų aptarimas

Kaip jau buvo minėta anksčiau ABDNT pasižymi nedideliu matematinių operacijų skaičiumi. Taip pat toks tinklas paprastai turi mažą vidinių jungčių skaičių (angl. *connectivity*), kas savo ruožtu leidžia dar labiau sumažinti matematinių operacijų skaičių. Rezervuarui turint 100 % vidinių jungčių kiekį ABDNT turėtų 160000 svorių S , tačiau ABDNT turi savybę dirbti esant mažam tarpusavio jungčių skaičiui j . Mūsų atveju prie $N = 400$ neuronų, jungčių skaičius $j = 2,5 \%$, todėl svorių S skaičius sumažėja iki 3944. Įėjimo sluoksnio jungtys M taip pat sujungtos su kiekvienu neuronu N , kur susidaro 2000 svorių (kanalų skaičius \cdot neuronų skaičius). Išėjimo sluoksnyje yra tik viena jungtis K , todėl ji turi 400 svorių. Įėjimo EEG signalas dauginasi iš svorių ir prieš tai buvusių neuronų būsenų, todėl atliekant maždaug 10000 daugybos veiksmų galima apskaičiuoti ABDNT atsaką į 5 kanalų vieną įėjimo atskaitą. Reikia pabrėžti, kad dalis šių matematinių veiksmų atliekami su nekintančia konstanta, tokia kaip neuronų pralaidumas l . Tokios matematinės operacijos nereikalauja daug energijos resursų, nes nereikia saugoti viso elementų masyvo dinaminėje atmintyje. Skaičiavimai gali būti įgyvendinami iteraciniu būdu. Taip pat procesoriuje galima pakeisti daugybas, matematinės sumos funkcija, kuri leidžia padidinti energetinį efektyvumą. Taip pat energetinį efektyvumą galima pagerinti naudojant integrinius lustus, kuriuose iš memristyviųjų⁵ (angl. *memristive*) elementų imituojamas dirbtinis neuronas (žr. 5.3 skyrių).

⁵ Atmintį turintis elementas sudarytas iš varžinių elementų ir lauko tranzistoriaus.


5.3. Tolimesnis projekto vystymas

Šiuo metu sparčiai populiarėjant dirbtinio neurono idėjoms ir kalbant apie naują mašininio mokymosi bangą atsiranda vis daugiau bandymų sukurti neuroninį tinklą įgyvendinančią aparatinę įrangą. ABDNT rezervuaro ir įėjimo sluoksnio svorių atsitiktinis inicializavimas įgalina nesudėtingą įgyvendinimą, kur svorių keitimo poreikis atsiranda tik išėjimo sluoksnyje. Todėl dirbtinis neuronas su aktyvacijos funkcijomis bei svoriu gali būti suformuotas iš dviejų memristyvinių sinapsių bei paties neurono [34], 5.2 pav. ir 5.3 pav.



5.2 pav. Kairėje: slopinamoji sinapsė. Dešinėje: jaudinamoji sinapsė [35].

Slopinamoji sinapsė sumažina srovę tekančią į sinapsinį neuroną, sumažindama jo potencialą įėjime, panašiai kaip gaba–amino butirinės rūgšties receptoriai biologinėse sinapsėse. Jaudinamoji sinapsė tiekia srovę į postsinapsinį neuroną, padidindama jo įėjimo potencialą. Neuronų svoris parenkamas kontroliuojant laidumus $G1$, $G2$, $G3$ ir $G4$ parenkant atitinkamas varžas projektavimo metu. Pats neuronas gali būti sudarytas iš diferencinės poros lauko tranzistorių, kaip pateikta 5.3 pav.



5.3 pav. Dirbtinio neurono aparatinis įgyvendinimas [35].

Neuronų išėjimo srovė i_{out} priklauso nuo užtūros potencialų skirtumo (lauko tranzistoriai $M1$ ir $M2$). Kadangi antrojo tranzistoriaus $M2$ užtūra įžeminta, tai neuronų išėjimo srovė tiesiogiai priklauso nuo srovės i_{in} ir įėjimo varžos R_{in} . Tokiu būdu sujungiant didelį neuronų rezervuarą galima įgyvendinti dirbtinį neuroninį tinklą. Tokio tinklo apmokymą galima atlikti kompiuterinėmis programomis, o gavus reikiamus svorius įgyvendinti aparatiškai. Pirminiai tokio metodo testavimai rodo, kad 200 neuronų turintis tinklas vieną signalo atskaitą užtrunka apdoroti maždaug 0,06 sekundės [35], todėl įgyvendintas ABDNT galėtų būti toliau plėtojamas ir energetiškai efektyvinamas naudojant būtent šią metodiką. Tokiu principu veikiantys neurosinapsiniai metodai jau pasirodė rinkoje. Pavyzdžiui IMB įmonės plėtojama „TrueNorth“ mikroschema yra viena iš efektyviausiai veikiančių integrinių lustų prieinamų rinkoje. Taip pat įmonė Intel lygiagrečiai plėtoja 14 nm integrinį lustą „Loihi“ kurio dydis yra 7,8 x 7,8 mm [38], [39]. Tokia technologija leidžia išbandyti naujus dirbtinių neuroninių tinklų metodus, kurie anksčiau nebuvo galimi dėl aparatinės įrangos trūkumo [36], [37].

Išvados

1. Esamų epilepsijos aptikimo metodų analizė parodė, kad didžioji dalis mokslinių tyrimų remiasi EEG signalų analize, tačiau nėra vieningo metodo, kuris patikimai atpažintų skirtingų tipų priepuolius. Esamiems *state-of-the-art* metodams dažnai reikia didelių anotuotų duomenų bazių, todėl nuspręsta epilepsijai atpažinti naudoti rekurentinį aido būsenos dirbtinį neuroninį tinklą, gebantį apsimokyti atskiro paciento atveju.
2. Sukurtas personalizuotas aido būsenos dirbtinio neuroninio tinklo pagrindu veikiantis metodas, gebantis aptikti epilepsijos priepuolius iš ilgalaikių EEG signalų. Identifikuota laisvai prieinamos naujagimių duomenų bazės anotacijų nesutapimo problema, (*Fleiss* anotacijų sutapimo indeksas $\kappa = 0,777$), kas daro neigiamą įtaką vystant epilepsijos atpažinimo metodus.
3. Pirmojo epilepsijos priepuolio atpažinimo galimybių tyrimas nenaudojant ABDNT parodė, kad dažnu atveju priepuolio pradžia ir pabaiga gali būti aptinkama naudojant linijos ilgio, netiesinės energijos ir RMS parametrus. Tokiu būdu eliminuojamas didelių duomenų bazių kaupimo ir anotavimo poreikis, nes ABDNT gali būti apmokytas naudojant pirmąjį priepuolį. Taip pat pasiūlyta EEG kanalų atrinkimo metodika siekiant sumažinti energetines sąnaudas bei pateiktas metodo aparatinio įgyvendinimo būdas. Pasiūlyta informatyviausių kanalų atrinkimo metodika sumažino naudojamų kanalų skaičių nuo 18 iki 5 ir padidino metodo diagnostinį tikslumą 12 %. Padidinus diskretizavimo dažnį iki 100 Hz metodo diagnostinis tikslumas, priešingai nei tikėtasi, sumažėjo nuo 90,87 % iki 90,53 %. Tuo tarpu sumažintas diskretizavimo dažnis iki 25 Hz leido padidinti diagnostinį tikslumą nuo 90,87 % iki 92,02 %.
4. Ištyrus metodą su klinikinėmis epilepsijos priepuolių turinčiomis duomenų bazėmis pasiektas 92,02 % diagnostinis tikslumas, 88,68 % jautrumas ir 95,40 % specifiskumas. Analizuojant rezultatus pagal priepuolio lokaciją pastebėta, kad geriausi atpažinimo rezultatai gaunami esant abipusei priepuolio lokacijai, o blogiausi – besikeičiančiai lokalizacijai. Šią problemą galima spręsti didinant kanalų skaičių. Taip pat atsižvelgus į atskirų pacientų rezultatus nustatyta, kad tiriamųjų amžius diagnostiniam tikslumui įtakos neturi, nepaisant to, kad naujagimių EEG kinta pirmomis savaitėmis po gimimo. Taip pat atlikti tyrimai parodė, kad priepuolio trukmė bei priepuolių skaičius EEG signale nedaro įtakos metodo diagnostiniam tikslumui.

Literatūros sąrašas

- [1] L. Kalilani, X. Sun, B. Pelgrims, M. Noack-Rink, and V. Villanueva, “The epidemiology of drug-resistant epilepsy: A systematic review and meta-analysis,” *Epilepsia*, vol. 59, no. 12, pp. 2179–2193, 2018.
- [2] A. Ulate-Campos, F. Coughlin, M. Gaínza-Lein, I. S. Fernández, P. L. Pearl, and T. Loddenkemper, “Automated seizure detection systems and their effectiveness for each type of seizure,” *Seizure*, vol. 40, pp. 88–101, 2016.
- [3] M. Sillanpa, L. Forsgren, E. Beghi, and A. Oun, “The epidemiology of epilepsy in Europe – a systematic review,” *Eur. J. Neurol.*, vol. 12, pp. 245–253, 2005.
- [4] J. Christensen, C. B. Pedersen, P. Sidenius, J. Olsen, and M. Vestergaard, “Long-term mortality in children and young adults with epilepsy-A population-based cohort study,” *Epilepsy Res.*, vol. 114, pp. 81–88, 2015.
- [5] W. Löscher and D. Schmidt, “Modern antiepileptic drug development has failed to deliver: Ways out of the current dilemma,” *Epilepsia*, vol. 52, no. 4, pp. 657–678, 2011.
- [6] E. Szemere and H. Jokeit, “Quality of life is social - Towards an improvement of social abilities in patients with epilepsy,” *Seizure*, vol. 26, pp. 12–21, 2015.
- [7] B. Blachut, C. Hoppe, R. Surges, J. Stahl, C. E. Elger, and C. Helmstaedter, “Counting seizures: The primary outcome measure in epileptology from the patients’ perspective,” *Seizure*, vol. 29, pp. 97–103, 2015.
- [8] B. Blachut, C. Hoppe, R. Surges, C. Elger, and C. Helmstaedter, “Subjective seizure counts by epilepsy clinical drug trial participants are not reliable,” *Epilepsy Behav.*, vol. 67, pp. 122–127, 2017.
- [9] S. L. Moshé, E. Perucca, P. Ryvlin, and T. Tomson, “Epilepsy: New advances,” *Lancet*, vol. 385, no. 9971, pp. 884–898, 2015.
- [10] Y. Zheng, G. Wang, K. Li, G. Bao, and J. Wang, “Epileptic seizure prediction using phase synchronization based on bivariate empirical mode decomposition,” *Clin. Neurophysiol.*, vol. 125, no. 6, pp. 1104–1111, 2014.
- [11] A. Van de Vel *et al.*, “Non-EEG seizure detection systems and potential SUDEP prevention: State of the art: Review and update,” *Seizure*, vol. 41, pp. 141–153, 2016.
- [12] X. Zhao and S. D. Lhatoo, “Seizure detection: do current devices work? And when can they be useful?,” *Curr. Neurol. Neurosci. Rep.*, vol. 18, no. 7, 2018.
- [13] A. B. Usakli, “Improvement of EEG Signal Acquisition: An Electrical Aspect for State of the Art of Front End,” *Comput. Intell. Neurosci.*, vol. 2010, pp. 1–7, 2010.
- [14] K. Gadhomi, J. M. Lina, F. Mormann, and J. Gotman, “Seizure prediction for therapeutic devices: A review,” *J. Neurosci. Methods*, vol. 260, no. 029, pp. 270–282, 2016.
- [15] A. Eftekhar, W. Juffali, J. El-Imad, T. G. Constandinou, and C. Toumazou, “Ngram-derived pattern recognition for the detection and prediction of epileptic seizures,” *PLoS One*, vol. 9, no. 6, 2014.
- [16] M. Bandarabadi, C. A. Teixeira, J. Rasekhi, and A. Dourado, “Epileptic seizure prediction using relative spectral power features,” *Clin. Neurophysiol.*, vol. 126, no. 2, pp. 237–248, 2015.
- [17] K. Gadhomi, J. M. Lina, and J. Gotman, “Seizure prediction in patients with mesial temporal lobe epilepsy using EEG measures of state similarity,” *Clin. Neurophysiol.*, vol. 124, no. 9, pp. 1745–1754, 2013.
- [18] N. Moghim and D. W. Corne, “Predicting epileptic seizures in advance,” *PLoS One*, vol. 9, no. 6, 2014.
- [19] A. Aarabi and B. He, “Seizure prediction in hippocampal and neocortical epilepsy using a model-based approach,” *Clin. Neurophysiol.*, vol. 125, no. 5, pp. 930–940, 2014.
- [20] P. Fergus, A. Hussain, D. Hignett, D. Al-Jumeily, K. Abdel-Aziz, and H. Hamdan, “A machine learning system for automated whole-brain seizure detection,” *Appl. Comput. Informatics*, vol.

- 12, no. 1, pp. 70–89, 2016.
- [21] L. Vidyaratne, A. Glandon, M. Alam, and K. M. Iftekharuddin, “Detection,” pp. 1202–1207, 2016.
- [22] A. Craik, Y. He, and J. L. Contreras-Vidal, “Deep learning for electroencephalogram (EEG) classification tasks: A review,” *J. Neural Eng.*, vol. 16, no. 3, 2019.
- [23] P. Buteneers, B. Schrauwen, D. Verstraeten, and D. Stroobandt, “Real-Time epileptic seizure detection on intra-cranial rat data using reservoir computing,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 5506 LNCS, no. PART 1, pp. 56–63, 2009.
- [24] P. Buteneers *et al.*, “Automatic detection of epileptic seizures on the intra-cranial electroencephalogram of rats using reservoir computing,” *Artif. Intell. Med.*, vol. 53, no. 3, pp. 215–223, 2011.
- [25] I. Ullah, M. Hussain, E. Qazi, and H. Aboalsamh, “An Automated System for Epilepsy Detection using EEG Brain Signals based on Deep Learning Approach Insight Centre for Data Analytics , National University of Ireland , Galway , Ireland Visual Computing Lab , Department of Computer Science , College of Com,” *Expert Syst. Appl.*, no. 107, pp. 61–71, 2018.
- [26] A. Shoeb, “Application of machine learning to epileptic seizure onset detection and treatment,” *Diss. Massachusetts Inst. Technol.*, pp. 157–162, 2009.
- [27] N. J. Stevenson, K. Tapani, L. Lauronen, and S. Vanhatalo, “A dataset of neonatal eeg recordings with seizure annotations,” *Sci. Data*, vol. 6, pp. 1–8, 2019.
- [28] K. T. Tapani, S. Vanhatalo, and N. J. Stevenson, “Time-Varying EEG Correlations Improve Automated Neonatal Seizure Detection,” *Int. J. Neural Syst.*, vol. 29, no. 4, 2019.
- [29] M. R. Nuwer *et al.*, “IFCN standards for digital recording of clinical EEG,” *Electroencephalogr. Clin. Neurophysiol.*, vol. 106, no. 3, pp. 259–261, 1998.
- [30] K. Patel, C. P. Chua, S. Faul, and C. J. Bleakley, “Low power real-time seizure detection for ambulatory EEG,” *2009 3rd Int. Conf. Pervasive Comput. Technol. Healthc. - Pervasive Heal. 2009, PCTHealth 2009*, 2009.
- [31] G. Li, B. J. Li, X. G. Yu, and C. T. Cheng, “Echo state network with Bayesian regularization for forecasting short-term power production of small hydropower plants,” *Energies*, vol. 8, no. 10, pp. 12228–12241, 2015.
- [32] A. Mansouri, S. P. Singh, and K. Sayood, “Online EEG seizure detection and localization,” *Algorithms*, vol. 12, no. 9, 2019.
- [33] M. R. Cilio, “EEG and the newborn,” *J. Pediatr. Neurol.*, vol. 7, no. 1, pp. 25–43, 2009.
- [34] S. Wen, R. Hu, Y. Yang, T. Huang, Z. Zeng, and Y. D. Song, “Memristor-Based Echo State Network with Online Least Mean Square,” *IEEE Trans. Syst. Man, Cybern. Syst.*, vol. 49, no. 9, pp. 1787–1796, 2019.
- [35] C. Merkel, Q. Saleh, C. Donahue, and D. Kudithipudi, “Memristive reservoir computing architecture for epileptic seizure detection,” *Procedia Comput. Sci.*, vol. 41, no. November, pp. 249–254, 2014.
- [36] I. Kiral-Kornek *et al.*, “Epileptic Seizure Prediction Using Big Data and Deep Learning: Toward a Mobile System,” *EBioMedicine*, vol. 27, pp. 103–111, 2018.
- [37] A. Amir *et al.*, “A low power, fully event-based gesture recognition system,” *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017*, vol. 2017-Janua, pp. 7388–7397, 2017.
- [38] M. Davies *et al.*, “Loihi: A Neuromorphic Manycore Processor with On-Chip Learning,” *IEEE Micro*, vol. 38, no. 1, pp. 82–99, 2018.
- [39] X. Sun *et al.*, “Hybrid 8-bit Floating Point (HFP8) Training and Inference for Deep Neural Networks,” no. NeurIPS, pp. 1–10, 2018.

Priedai

1 priedas. Metoduose naudotos vaikų duomenų bazės aprašas.

Pacientas Nr.	Lytis ⁶	Amžius metais	Priepuolių skaičius	Įrašų trukmė
1	M	11	7	40:33:08
2	V	11	3	35:15:59
3	M	14	7	38:00:06
4	V	22	4	156:03:54
5	M	7	5	39:00:10
6	M	1.5	10	66:44:06
7	M	14.5	3	67:03:08
8	V	3.5	5	20:00:23
9	M	10	4	67:52:18
10	V	3	7	50:01:24
11	M	12	3	34:47:37
12	M	2	27	20:41:40
13	M	3	12	33:00:00
14	M	9	8	26:00:00
15	V	16	20	40:00:36
16	M	7	10	19:00:00
17	M	12	3	21:00:24
18	M	18	6	35:38:05
19	M	19	3	29:55:46
20	M	6	8	27:36:06
21	M	13	4	32:49:49
22	M	9	3	31:00:11
23	M	6	7	26:33:30
24	–	–	16	21:17:47
Iš viso				979:56:07

⁶ Lytis: moteris (M), vyras (V).

2 priedas. Metoduose naudotos naujagimių duomenų bazės aprašas.

Pacientas Nr.	Lytis ⁷	Amžius sav. ⁸	Priepuolio lokacija	Įrašų trukmė
#1	M	37	Abu pusrutuliai, keičiasi	01:56:33
#5	M	40	Kairys pusrutulis	01:04:01
#7	V	38	Dešinysis pusrutulis	01:00:54
#9	M	40	Kairės frontotemporalinės skilties centras, kairysis	00:59:10
#13	V	39	Abipusis	04:16:56
#14	M	38	Užpakalinis dešinysis kvadrantas	01:02:06
#15	V	36	Artimoji viršugalvė, centras	01:54:58
#16	V	41	Dešinysis pusrutulis	01:39:01
#17	M	36	Artimoji viršugalvė, centras	01:31:33
#39	V	41	Kairysis pusrutulis	01:17:09
#40	V	41	Kairioji momeninė–pakaušinė skiltis	01:37:17
#44	M	41	Abipusis	00:56:00
#47	M	41	Abipusis	01:00:06
#63	M	39	Dešinysis pusrutulis	01:05:00
#66	M	43	Dešinės frontotemporalinės skilties centras, pakaušinė	03:09:10
#69	V	42	Abu pusrutuliai	01:06:13
#71	V	39	Abipusis	01:11:16
#73	M	39	Kairės frontotemporalinės skilties centras, abipusis	01:02:10
#77	M	41	Kairės pusės centro momeninė skiltis	01:09:53
#78	M	41	Dešinysis pusrutulis	01:22:51
#79	M	41	Kairės frontotemporalinės skilties centras, momeninė	00:54:57
Iš viso:				31:17:14

⁷ Lytis: moteris (M), vyras (V).

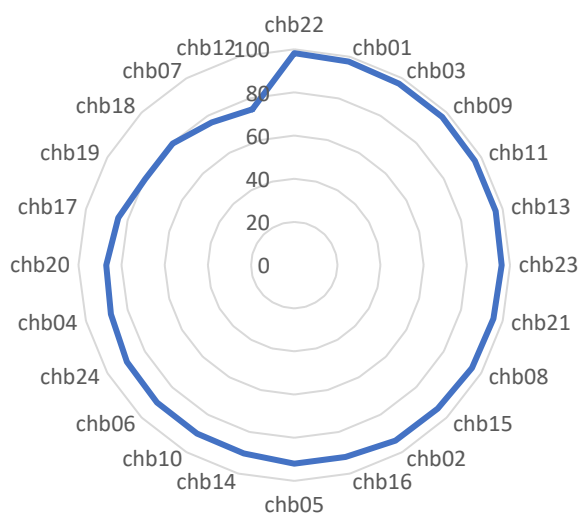
⁸ Išnešiojimo amžius savaitėmis.

3 priedas. Metodo rezultatai, naudojant vaikų duomenų bazę.

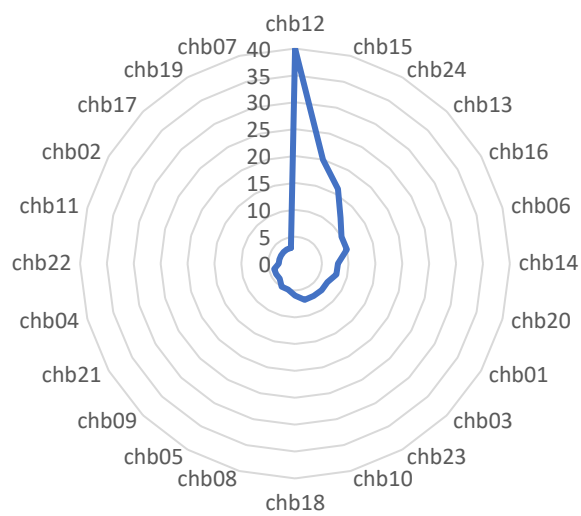
Pacientas Nr.	Priepuolių skaičius	Diagnostinis tikslumas (%)	Specifiškumas (%)	Jautrumas (%)
1	7	98,23	98,21	98,24
2	3	97,67	96,96	99,49
3	7	97,07	96,66	97,47
4	4	97,00	97,10	96,89
5	5	96,71	95,23	98,20
6	10	96,69	94,98	98,42
7	3	96,14	96,40	95,87
8	5	95,61	96,90	94,31
9	4	95,17	93,98	96,37
10	7	94,11	94,07	94,16
11	3	93,97	88,67	99,30
12	27	92,08	97,88	86,01
13	12	92,01	86,31	97,73
14	8	90,37	84,99	95,83
15	20	90,10	81,90	98,34
16	10	90,03	88,70	91,40
17	3	89,57	81,46	97,78
18	6	87,90	78,98	96,87
19	3	87,12	78,98	95,34
20	8	84,42	68,90	100,00
21	4	79,79	62,59	97,08
22	3	79,71	61,41	98,15
23	7	76,41	54,36	98,55
24	16	74,80	68,75	80,95
Iš viso	185	90,87	85,18	95,95

4 priedas. Priepuolių skaičiaus, trukmės ir diagnostinio tikslumo priklausomybės.


Diagnostinis tikslumas, (%)



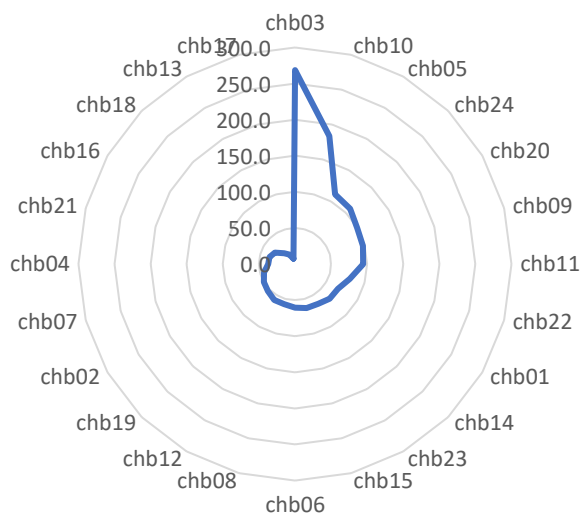
Priepuolių skaičius



Bendra priepuolių trukmė, (s)



Vidutinė priepuolių trukmė, (s)



5 priedas. Metodo rezultatai, naudojant naujagimių duomenų bazę.

Pacientas Nr.	Diagnostinis tikslumas (%)	Specifiškumas (%)	Jautrumas (%)
#1	80,42	81,81	70,63
#5	83,88	91,19	81,85
#7	93,75	94,29	86,20
#9	84,25	90,08	73,78
#13	95,44	96,94	83,31
#14	91,64	96,30	90,28
#15	84,55	85,36	81,18
#16	85,67	79,61	87,97
#17	88,13	88,37	83,21
#39	89,39	91,74	88,45
#40	88,72	88,25	95,71
#44	97,38	97,20	99,10
#47	99,37	99,50	96,60
#63	84,51	87,58	57,45
#66	91,13	93,03	76,71
#69	85,81	94,11	80,61
#71	91,29	91,23	93,00
#73	89,44	89,11	90,34
#77	81,77	81,06	84,22
#78	86,80	92,05	78,89
#79	95,72	96,16	88,54
Iš viso	85,17	86,82	80,83