

VILNIAUS UNIVERSITETAS

Andrius Vytautas
MISIUKAS MISIŪNAS

Elektroencefalogramų analizės metodų tyrimas

DAKTARO DISERTACIJA

Gamtos mokslai,
Informatika N 009

VILNIUS 2020

Disertacija rengta 2015–2019 metais Vilniaus universitete.

Mokslinis vadovas

prof. dr. Tadas Meškauskas (Vilniaus universitetas, gamtos mokslai,
informatika – N 009)

TURINYS

Sutrumpinimai	6
Įvadas	8
Tyrimo objektas	10
Tikslas ir uždaviniai	10
Tyrimo metodai ir priemonės	11
Mokslinis rezultatų naujumas	12
Praktinė rezultatų reikšmė	12
Ginamieji teiginiai	13
Rezultatų patvirtinimas	13
1 Elektroencefalogramos (EEG)	16
1.1 EEG ir jų taikymas diagnostikoje	16
1.1.1 Tarptautinė 10–20 EEG sistema	16
1.1.2 Normali CNS veikla	17
1.1.3 EEG artefaktai	18
1.1.4 EEG pikai	19
1.1.5 Morfologiniai EEG piko požymiai	20
1.2 Analizei naudoti EEG duomenys	20
2 EEG analizės metodai ir algoritmai	27
2.1 Morfologinis EEG pikų aptikimo algoritmas	27
2.1.1 Pirminis EEG apdorojimas	27
2.1.2 Morfologinės operacijos	27
2.1.3 Struktūriniai elementai	30
2.1.4 EEG pikų aptikimo algoritmas	31
2.1.5 Morfologinių filtrų tobulinimo svarba	32
2.1.6 Artefaktų filtravimas	34
2.1.7 Algoritmo jautrumo ir specifiškumo vertinimas	36
2.2 Morfologinio filtro optimizavimas genetiniu algoritmu	37
2.2.1 Tikslų funkcijos parinkimas	40
2.2.2 Optimizavimo rezultatai	41
2.3 Pikų aptikimo algoritmo lygiagretinimas	43
2.3.1 MPI ir gijos	43
2.3.2 EEG pikų paieškos algoritmo išlygiagretinimas	43

2.3.3	Pagreitėjimo testavimas	45
2.3.3.1	Tyrimas asmeniniame kompiuteryje . . .	46
2.3.3.2	Tyrimas superkompiuteryje	46
3	EEG klasifikavimas pagal diagnozę	50
3.1	EEG klasifikavimo pagal diagnozę algoritmas	50
3.2	Mašinių mokymosi klasifikavimo metodai	51
3.2.1	LDA	51
3.2.2	Logistinė regresija	52
3.2.3	MLP	52
3.2.4	Atraminių vektorių mašina	55
3.2.5	Sprendimų medis	61
3.2.6	Atsitiktinis miškas	61
3.2.7	Labai atsitiktiniai medžiai	62
3.2.8	CNN	63
3.2.8.1	Atgalinis klaidos sklidimas CNN	63
3.2.8.2	Konvoliuciniai sluoksniai	64
3.2.8.3	Sutelkimo sluoksniai	65
3.2.8.4	Visiškai sujungti sluoksniai	65
3.2.8.5	Tipinės CNN architektūros	65
3.2.9	AdaBoost	66
3.2.10	Daugumos balsavimo klasifikatorius	67
3.3	Klasifikatorių testavimo metodika	67
3.3.1	Klasifikatorių kokybės metrikos	67
3.3.1.1	TPR ir TNR	67
3.3.1.2	Matthewso koreliacijos koeficientas	68
3.3.1.3	Tikslumas ir svorinis tikslumas	69
3.3.1.4	<i>Recall</i> ir F_1 metrikos	69
3.3.1.5	ROC AUC	69
3.3.1.6	Cohen κ	70
3.3.2	<i>k-fold</i> kryžminė patikra	70
3.4	EEG klasifikavimo algoritmas, naudojantis geometrinius pikų parametrus	71
3.4.1	EEG piko geometrinių charakteristikų nustatymas	71
3.4.2	Mašinių mokymusi pagrįstų klasifikatorių taikymas klasifikuojant EEG pagal EEG pikų geometrinius parametrus	73

3.4.2.1	EEG pikų geometrinių parametų perdavimo būdo pasirinkimas	73
3.4.2.2	Netinkamų klasifikatorių pašalinimas iš tolesnės analizės	74
3.4.2.3	Klasifikavimo pagal EEG pikų geometrinius parametrus rezultatai	75
3.4.2.4	Tinkamiausio EEG pikų skaičiaus ir parametų parinkimas	76
3.4.2.5	Klasifikavimo tikslumo ribos nustatymas	78
3.4.2.6	MLP architektūros optimizavimas	79
3.4.3	EEG pikų geometrinių charakteristikų analizė . . .	79
3.5	EEG klasifikavimas, naudojant signalų atkarpas	81
3.5.1	Duomenų perdavimo strategijos pasirinkimas . . .	81
3.5.2	EEG klasifikatorių tyrimas, naudojant EEG signalo atkarpas	82
3.6	EEG klasifikavimas, naudojant visų EEG kanalų duomenis	83
3.6.1	EEG duomenų perdavimo CNN klasifikatoriui strategija	84
3.6.2	CNN architektūros pasirinkimas	84
3.6.3	Vieno piko klasifikavimas, naudojant CNN	85
3.6.4	Daugumos balsavimo klasifikatorius su CNN . . .	86
3.6.5	Gautų algoritmų pritaikomumas praktikoje	89
	Išvados	91
	Priedai	93
	Literatūra	96
	Padėkos	106
	Autoriaus publikacijos disertacijos tema	107
	Curriculum vitae	110
	Summary	113

SUTRUMPINIMAI

I grupė – pacientai, kuriems diagnozuota gerybinė vaikų epilepsija, pvz., Rolando epilepsija.

II grupė – pacientai, kuriems diagnozuota įvairių struktūrinių smegenų pažeidimų: struktūrinė židininė epilepsija, cerebrinis paralyžius, smegenų žievės displazija, gliozė ir kt.

ANN – (angl. *Artificial neural network*) dirbtinis neuroninis tinklas.

CNN – (angl. *Convolutional neural network*) konvoliucinis neuroninis tinklas.

CNS – (angl. *Central nervous system*) centrinė nervų sistema.

EEG – elektroencefalograma.

FNR – (angl. *False negative rate*) neteisingai klasifikatoriaus priskirtų II grupei pavyzdžių dalis (II tipo klaidos).

FPR – (angl. *False positive rate*) neteisingai klasifikatoriaus priskirtų I grupei pavyzdžių dalis (I tipo klaidos).

Jautrumas – (angl. *Sensitivity*) algoritmu nustatytų teigiamų pavyzdžių santykis su visais teigiamais pavyzdžiais.

LDA – (angl. *Linear discriminant analysis*) tiesinė diskriminantinė analizė.

MLP – (angl. *Multilayer perceptron*) dirbtinis neuroninis tinklas, pagrįstas daugiasluoksniu perceptronu.

Skaičiavimų efektyvumas (k_{eff}) – skaičiavimų dalis, išreikšta procentais, vykdoma lygiagrečiai, atliekant daugiagijus skaičiavimus.

Spartinimas (T) – (angl. *Speedup*) reliatyvus skaičiavimų pagreitėjimas, kartais – tarp kelių tos pačios sistemos konfigūracijų (šiam darbe – atliekant skaičiavimus su didesniu gijų skaičiumi).

Specifiškumas – (angl. *Specificity*) algoritmu nustatytų teisingai teigiamų pavyzdžių dalis iš algoritmo rezultatų visumos.

SVM – (angl. *Support vector machine*) atraminių vektorių mašina.

TNR – (angl. *True negative rate*) teisingai klasifikatoriaus priskirtų II grupei pavyzdžių dalis.

Klasifikuojamo duomens charakteristika – (angl. *feature*) skaitinė ar kita reikšmė, sudaranti dalį klasifikuojamo duomens, pvz.: EEG piko pakilimo kampas, EEG piko nusileidimo kampas.

MPI – (angl. *Message passing interface*) žinučių perdavimo protokolas, naudojamas dalytis informacija tarp procesų paskirstytos atminties platformose.

Persimokymas – (angl. *Overfitting*) mašinų mokymosi algoritmo būseną, kai algoritmas geba nustatyti mokymosi imties duomenų triukšmą (ar kitas charakteristikas, mažai reikšmingas klasifikuojant), o ne apibendrinti mokymosi imties duomenų savybes.

TPR – (angl. *True positive rate*) teisingai klasifikatoriaus priskirtų I grupei pavyzdžių dalis.

U – (angl. *Voltage*) elektrinė įtampa, šiame darbe matuojama mikrovoltais (μV).

IVADAS

Signalai ir įvairūs jų apdorojimo bei analizės algoritmai yra kasdienio gyvenimo dalis. Mūsų žiūrimos nuotraukos (JPEG formatas), vaizdo įrašai (MPEG ir kiti formatai), girdima muzika ir garsai (MP3 ir kiti formatai) veikia greitosios Furjė transformacijos (angl. FFT) ir kitų signalų apdorojimo algoritmų pagrindu [54]. Įvairiais signalų analizės metodais analizuojami finansinių rinkų pokyčiai [62]. Ne išimtis ir medicina: čia įrašomi ir nagrinėjami tokie signalai, kaip elektrokardiogramos (ECG) [21, 65, 74] ir šiame darbe nagrinėjamos elektroencefalogramos (EEG) [20, 59, 63].

1875 m. Ričardas Katonas aprašė triušių smegenų elektrinį aktyvumą. Pirmoji žmogaus EEG buvo įrašyta 1924 m. vokiečių psichiatro Hanso Bergerio. Praėjus dešimčiai metų atrasti epileptoforminiai EEG pikai [17]. EEG tyrimai plačiai taikomi ir šiandien, tiek Lietuvoje [55], tiek užsienyje [64].

EEG, kaip ir kiekvienas medicininis instrumentinis tyrimas, turi savų privalumų ir trūkumų [64]. Pagrindinis EEG privalumas – didelė skyra laiko atžvilgiu. Smegenų elektrinis aktyvumas dažniausiai fiksuojamas 256 Hz disk-retizacijos dažniu, nors atskirais atvejais šis dažnis gali skirtis. Be to, EEG tyrimas yra neinvazinis, pacientas nepatiria jonizuojančiosios spinduliuotės, stiprių elektrinių ar magnetinių laukų, kaip kitų medicininių tyrimų atveju. EEG tyrimas yra tylus, nekelia tiriamajam pašalinių stimulų. Minėtina ir tai, kad EEG tyrimo kaina yra mažesnė, palyginti su dauguma kitų instrumentinių galvos smegenų tyrimo metodų [10].

Pagrindinis EEG trūkumas – maža erdvinė skyra. Disertacijoje naudojama tarptautinė 10–20 EEG sistema, kurią taikant įrašomas smegenų



1 pav. EEG tyrimo elektrodai ant paciento galvos [12] (autorių teisių nesaugoma iliustracija iš *Wikimedia Commons* [11])

elektrinis aktyvumas 21 kanale. Taigi turime 21 taško erdvinę skyrą. Be to, EEG tyrimas prastai atspindi smegenų veiklą gilesnėse smegenų dalyse, signalo ir triukšmo santykis yra mažesnis, palyginti su kitais galimais tyrimais.

Atsižvelgiant į minėtus privalumus ir trūkumus, EEG tyrimas medicinoje gali būti taikomas įvairiais tikslais [64]: struktūriniais smegenų pažeidimams, smegenų augliams, miego sutrikimams, epilepsijai ir kitiems sutrikimams diagnozuoti ir ligos eigai sekti. Tam sukurta įvairių EEG analizės algoritmų: EEG pikų paieškos [19, 24, 46, 72, 73], sveikų ir sergančių žmonių EEG klasifikavimo [8, 28], sergančiųjų ir nesergančiųjų alkoholizmu klasifikavimo [3, 44], epilepsijos priepuolių aptikimo ir klasifikavimo [66, 67] ir daugybė kitų.

Šiame darbe tiriamos vaikų (3–17 m. amžiaus), sergančių gerybine (rolandine) epilepsija (I grupė) ir turinčių struktūrinių smegenų pažeidimų (II grupė), EEG. Nors abiejų grupių EEG pikai dažnai skiriasi (skirtumai

matyti net ne medikui), esama atvejų, kai minėtasias EEG sunku atskirti (ar neįmanoma jų atskirti) net patyrusiems neurologams. Šie sunkiai atskiriami atvejai ir nagrinėjami disertacijoje.

TYRIMO OBJEKTAS

Disertacijos tyrimo objektas – vaikų (3–17 m. amžiaus), kuriems nustatyta I arba II grupės diagnozė, EEG.

TIKSLAS IR UŽDAVINIAI

Disertacijos tikslas – sukurti algoritmus, kurie automatiškai klasifikuotų I ir II grupių EEG pagal diagnozę, gydytojams (neurologams) tiriant sunkiai atpažįstamus atvejus ir klasifikavimui naudojant tik EEG signalo duomenis, ir verifikuoti šiuos algoritmus kompiuterinio modeliavimo eksperimentais.

Tikslui pasiekti iškelti šie uždaviniai:

- Pasirinkti ir optimizuoti EEG pikų paieškos algoritmą.
- Nustatyti EEG piko geometrines (ir kitas) charakteristikas, tinkamas klasifikuoti pagal diagnozę.
- Pasirinkti mašinių mokymusi pagrįstus klasifikavimo metodus ir pritaikyti juos EEG klasifikuoti pagal diagnozę, atlikti pasirinkimą pagrindžiančius eksperimentus.
- Sujungti pasirinktus algoritmus į EEG klasifikavimo pagal diagnozę algoritmą, eksperimentiškai palyginti įvairių algoritmo versijų veikimą.

- Įgyvendinti (suprogramuoti) pasiūlytus algoritmus.
- Atlikti eksperimentus, reikalingus pasiūlytiems algoritmams ir kitiems gautiems rezultatams patvirtinti.

TYRIMO METODAI IR PRIEMONĖS

Darbe aprašyti EEG klasifikavimo ir pagalbinių metodai bei algoritmai išbandyti ir įgyvendinti *Python* programavimo kalba (rengiant disertaciją, pradžioje naudota 2.7.10 versija, vėliau pereita prie *Python* 3.5 ir 3.6 versijų, vėliausia naudota 3.6.8 versija). Naudotasi šiomis programavimo kalbos bibliotekomis: *NumPy* (kai kurių skaičiavimų paspartinimas) [47], *SciPy* (matematinės morfologijos ir kiti metodai) [69], *Matplotlib* (grafikų braižymas) [22], *Scikit-learn* (mašinių mokymosi metodų įgyvendinimas) [48], *Tensorflow* (konvoliucinio neuroninio tinklo (CNN) įgyvendinimas) [1], *Tensorflow-GPU* (CNN skaičiavimų paspartinimas naudojant kompiuterio vaizdo plokštę (GPU)), *EegTools* ir *PyEdfLib* (EDF ir EDF+ failų nuskaitymas), *mpi4py* (MPI protokolo palaikymas *Python*), *GeneticAlgorithmPython* (genetinio algoritmo įgyvendinimas) ir kt.

Dauguma skaičiavimų atlikti doktoranto asmeniniu kompiuteriu. Techniniai kompiuterio duomenys: *Intel i7-6700K* centrinis procesorius (4,0 GHz, 4 branduoliai, 8 skaičiavimo gijos), *Asus Z170 Deluxe* pagrindinė plokštė, 32 GB DDR4 RAM (4 vnt. 8 GB talpos *Corsair Vengeance LPX* 2400 MHz, 13-15-15-28), *Asus Strix GeForce GTX 980 Ti OC* vaizdo plokštė (2 816 CUDA branduolių, 6 GB GDDR5 atminties), *Noctua NH-D15 CPU* aušintuvas, 5 vnt. *Noctua NF-A14-PWM* korpuso aušintuvų. Kompiuteryje naudotos *Windows 10* ir *Linux Ubuntu 14.04 LTS* (vėliau – *Linux Ubuntu 18.04 LTS*) operacinės sistemos (visos – 64-bit).

Dalis skaičiavimų atlikta VU MIF Paskirstytų skaičiavimų tinkle (PST)¹ (1 920 procesorių branduoliai, 3,6 TB operatyviosios atminties, 620 TB duomenų saugykla, skaičiavimų sparta apie 25 TFLOP/s).

MOKSLINIS REZULTATŲ NAUJUMAS

- Sukurtas trijų žingsnių algoritmas, skirtas klasifikuoti I ir II grupių pacientų EEG pagal diagnozę. Tai pirmas mokslinėje literatūroje aprašytas šį uždavinį sprendžiantis algoritmas.
- Genetiniu algoritmu optimizuoti EEG pikų paieškos algoritmo, pagrįsto matematinės morfologijos filtru, parametrai. Tai pirmas mokslinėje literatūroje aprašytas minėto algoritmo parametrų optimizavimas genetiniu algoritmu.
- Ištirti keli mašinių mokymosi algoritmų EEG pikų duomenų charakteringų parametrų išskyrimo būdai antrame EEG klasifikavimo pagal diagnozę algoritmo žingsnyje.
- Ištirta kelių klasifikatorių, pagrįstų mašinių mokymusi, veikla trečiajame EEG klasifikavimo pagal diagnozę algoritmo žingsnyje, maksimaliai padidinanti klasifikavimo tikslumą ir kitas svarbias metrikas.

PRAKTINĖ REZULTATŲ REIKŠMĖ

Sukurtas automatinis algoritmas, leidžiantis klasifikuoti vaikų, kuriems diagnozuota gerybinė epilepsija arba struktūriniai smegenų pažeidimai, EEG. Algoritmo įgyvendinimas praktikoje leistų sumažinti neteisingų diagnozių skaičių, gydytojais neurologais galėtų greičiau įvertinti pacientų EEG.

¹Prieiga internete: <<https://mif.vu.lt/cluster/>>

EEG pikų aptikimo algoritmas jau yra praktiškai įgyvendintas NKSPS (Nacionalinė klinikinių sprendimų palaikymo sistema, Nr. VP2-3.1-IVPK-10-V-01) projektu ir yra naudojamas gydytojų. Klasifikavimo pagal diagnozę algoritmų praktinis įgyvendinimas palengvintų gydytojų darbą.

GINAMIEJI TEIGINIAI

- Naudojant disertacijoje pristatomus mašinių mokymosi pagrindų veikiančius klasifikavimo algoritmus, I ir II grupių EEG gali būti klasifikuojamos 75–82 proc. tikslumu.
- Naudojant EEG pikų geometrinius parametrus, geriausia klasifikavimo kokybė pasiekama taikant daugiasluoksnį perceptroną.
- Naudojant EEG pikų signalų atkarpų (kanale, kuriame aptiktas EEG pikas) masyvą, geriausia klasifikavimo kokybė pasiekama taikant labai atsitiktinio medžio klasifikatorių.
- Konvoliucinio neuroninio tinklo ir daugumos balsavimo pagrindų veikiantis klasifikavimo algoritmas pasižymi geriausiomis klasifikavimo ir panaudojamumo savybėmis, todėl rekomenduojamas tolesniems tyrimams ir taikytinas praktiškai.

REZULTATŲ PATVIRTINIMAS

Rengiant disertaciją, paskelbtas straipsnis, kuriame nagrinėjamas EEG klasifikavimas pagal diagnozę, naudojant MLP ir geometrinius EEG pikų parametrus. Straipsnis išspausdintas *Biomedical Signal Processing and Control* žurnale, kuris *Clarivate Analytics Web of Knowledge* duomenų bazėje pagal citavimo indeksą yra pirmajame savo kategorijos

žurnalų sarašo ketvirtyje (Q1). Autoriaus indėlis – modelių sudarymas ir programavimas, eksperimentų atlikimas, svariai prisidėta rašant tekstą.

Kitas straipsnis, kuriame nagrinėjamas EEG klasifikavimas pagal diagnozę, naudojant CNN ir daugumos balsavimo klasifikatorių, priimtas spausdinti žurnale *Nonlinear Analysis: Modelling and Control*, indeksuojamame *Clarivate Analytics Web of Knowledge* duomenų bazėje. Autorius kūrė modelius ir programavo, atliko eksperimentus, svariai prisidėjo rašant tekstą.

Mašinių mokymosi metodo pasirinkimas klasifikavimo pagal geometrinius pikus algoritmui pristatytas tarptautinėje mokslinėje konferencijoje *Ninth International Conference on Numerical Methods and Applications*. Rezultatai pateikti straipsnyje, publikuotame tęstiniame recenzuojamame žurnale *Springer Lecture Notes On Computer Science*.

Klasifikavimo algoritmas, naudojantis EEG pikų atkarpas, pristatytas tarptautinėje mokslinėje konferencijoje *11th Conference of the Euro-American Consortium for Promoting the Application of Mathematics in Technical and Natural Sciences*. Rezultatai pateikti straipsnyje, publikuotame tęstiniame recenzuojamame žurnale *American Institute of Physics Conference Proceedings*.

Iš viso rezultatai pristatyti keturiose Lietuvos ir dviejose tarptautinėse konferencijose:

- DAMSS 2014 (Druskininkai, Lietuva): *Data analysis methods for software systems: 6th International Workshop*. 2014 m. gruodžio 4–6 d.
- LMD 56 (Kaunas, Lietuva): 56-oji Lietuvos matematikų draugijos konferencija. 2015 m. birželio 16–17 d.
- LMD 57 (Vilnius, Lietuva): 57-oji Lietuvos matematikų draugijos konferencija. 2016 m. birželio 20–21 d.

- NM&A'18 (Borovecas, Bulgarija): *Ninth International Conference on Numerical Methods and Applications*. 2018 m. rugpjūčio 20–24 d.
- DAMSS 2018 (Druskininkai, Lietuva): *10th international workshop on data analysis methods for software systems*. 2018 m. lapkričio 29 d. – gruodžio 1 d.
- AMiTaNS'19 (Albena, Bulgarija): *Eleventh Conference of the Euro-American Consortium for Promoting the Application of Mathematics in Technical and Natural Sciences*. 2019 m. birželio 20–25 d.

Visus konferencijų pranešimus pristatė disertantas. Jis buvo ir pagrindinis pranešimų autorius.

Už sėkmingą rezultatų pristatymą autoriui AMiTaNS'19 konferencijoje įteiktas Jaunojo mokslininko apdovanojimas (*Young Scientist Award Certificate*).

1. ELEKTROENCEFALOGRAMOS (EEG)


1.1 EEG IR JŲ TAIKYMAS DIAGNOSTIKOJE

Šiame skyriuje aprašomi EEG signalai ir jų savybės. EEG atspindi tiek normalią, tiek ir sutrikusią smegenų veiklą, todėl EEG plačiai taikoma įvairių CNS ligų diagnostikai.

1.1.1 Tarptautinė 10–20 EEG sistema

Registruojant EEG, pasaulyje plačiausiai naudojama tarptautinė 10–20 elektrodų išdėstymo sistema. Taikant šią sistemą, įprastai naudojamas 21 EEG matavimo kanalas [57], standartiškai nustatoma kiekvieno elektrodo vieta. Sistema reglamentuoja elektrodų tvirtinimą prie paciento galvos taškus ir matavimo elektrodų santykius, todėl elektrodai kiekvienam pacientui išdėstomi apytiksliai virš tos pačios smegenų dalies. Aptartos savybės leidžia minėtą sistemą taikyti medicininei diagnostikai bei pasitelkti ją šiame darbe: aptiktas pikas turi atsikartoti bent dviejuose gretimuose elektroduose. Kurie elektrodai yra gretimi, žinoma iš standartinio 10–20 EEG sistemos išdėstymo. 1.1 pav. pateikiama standartinė EEG elektrodų išdėstymo schema, laikantis tarptautinės 10–20 EEG sistemos.

Disertacijoje nagrinėjamos epilepsija sergančių vaikų EEG, tačiau aptartas tyrimas gali būti naudojamas ir įvairių kitų ligų diagnostikai. EEG matavimai atliekami tiek budrumo, tiek miego metu (žr. 1.1 lentelę).



1.1 pav. Standartinis elektrodų išdėstymas, laikantis tarptautinės 10–20 EEG sistemos [57] (autorių teisių nesaugoma iliustracija iš *Wikimedia Commons* [11])

1.1 lentelė. EEG naudojimas medicinoje

EEG tipas	Diagnozė, kuriai nustatyti naudojama EEG
Miego EEG	Autizmas, miego sutrikimai; miego EEG taikytina priešinantis budrumo būsenos tyrimui dėl mažo amžiaus
Budrumo būsenos EEG	Migrena, neaiškios etiologijos priepuoliai, encefalopatija, įvairių etiologijų komos, lokalūs smegenų pažeidimai
Budrumo būsenos arba miego EEG	Epilepsija, Rolando epilepsija, raidos regresas, neurodegeneracinės ligos

1.1.2 Normali CNS veikla

Normaliai smegenų veiklai būdingi smegenų ritmai (žr. 1.2 lentelę). Priklausomai nuo paciento būsenos, dažniausiai vyrauja vienas iš smegenų aktyvumo ritmų. Ritmo dažnį gali lemti daugelis veiksnių (budrumo lygis, amžius), tačiau šis dažnis gali keistis ir dėl kai kurių CNS sutrikimų,

pavyzdžiui, sutrikus raidai ar esant demencijai [57].

1.2 lentelė. Smegenų aktyvumo ritmai

Pavadinimas	Dažnis	Aprašymas
α	8–16 Hz	Dominuoja atsipalaidavus, esant budrumo būsenos, bet užmerkus akis.
β	13–30 Hz	Dominuoja esant budrumo būsenos, atmerkus akis ir reaguojant į išorinį pasaulį.
γ	30–100 Hz	Tikslių duomenų nėra.
δ	0,5–4 Hz	Dominuoja giliai miegant ar pacientui esant nesąmoningam.
θ	4–8 Hz	Dominuoja miegant ar gilios meditacijos metu.

Kaip matyti iš 1.2 lentelės, miegant dominuoja δ ir θ smegenų ritmai.

Jau minėta, kad EEG matavimus galima atlikti tiek miego, tiek budrumo metu. Budrumo būsenos EEG atliekamos pacientui ramiai gulint užsi-merkus, šiose EEG dominuoja α ritmas. Minėtina, kad EEG atliekama pacientui miegant arba esant ramybės būsenos, nes pacientui judant sukuriamas EEG artefaktų, kurie neleidžia atlikti matavimų šiais artefaktais užterštose signalo vietose.

Suaugusiems pacientams ir vyresniems vaikams EEG matavimai dažniausiai atliekami esant budrumo būsenos. Miego EEG pasitelkiama mažiems vaikams, kurie negali ilgai išbūti ramūs ar priešinasi tyrimui. Epilepsijos diagnostikai vienodai vertinga tiek miego, tiek budrumo būsenos EEG, tačiau skiriasi kai kurių EEG smegenų galių ritmų santykių normos. Šios normos disertacijoje nėra nagrinėjamos, reikiama diagnostinė informacija gaunama iš EEG pikų.

1.1.3 EEG artefaktai

Normaliai smegenų veiklai būdingi įvairios kilmės artefaktai, kurie vizualiai gali atrodyti panašūs į EEG pikus. Vieni iš tokių artefaktų –

judesio artefaktai, todėl EEG matavimai atliekami pacientui esant ramybės būsenos arba, kai pacientas negali ilgą laiką išbūti ramus, jam miegant.

Esant galimybei, neurologai epilepsijai diagnozuoti įprastai naudoja budrumo būsenos EEG, nes miego EEG būdingi tokie artefaktai, kaip greitai akių judesiai ar K-kompleksai, kuriuos pacientas atlieka nevalingai. EEG šiuos artefaktus gali būti sunku atpažinti.

Minėtini artefaktai, kurių atsiranda dėl paciento širdies veiklos. Kaip žinome, kraujotaką užtikrina periodiškai susitraukiantis širdies raumuo, jo veikla taip pat gali būti matoma EEG. Vis dėlto šį artefaktą nesunku atskirti dėl jo periodiškumo. Be to, dauguma EEG tyrimo aparatų matuoja ir EKG, kuri, kaip žinoma, fiksuoja širdies aktyvumą.

Ketvirtas artefaktas, pastebimas visose EEG, yra neperiodinis smegenų aktyvumas. Smegenų veikla nėra griežtai periodinė, smegenyse vyksta daugybė sudėtingų neperiodinių procesų, kurie šiandien neturi jokios medicininės vertės ir kartu su prietaiso matavimo paklaidomis yra suprantami kaip triukšmas. Žinomi keli būdai, kaip pašalinti nepageidaujamas neperiodines signalo dedamasias. Minėtinis [52] bangelių transformacijos triukšmui šalinti (angl. *Wavelet Denoising*), esama ir kitų būdų, pavyzdžiui, autokoreliacijos algoritmas [25]. Disertacijoje nagrinėjamos I ir II grupių EEG būdingi gerai apibrėžtos formos EEG pikai, todėl, atliekant tyrimą, naudota EEG pikų parametrų validacija pagal mediciniškai galimas jų reikšmių ribas.

1.1.4 EEG pikai

Šiuo metu žinoma daugybė ligų, pasižyminčių EEG pikais [64], tačiau disertacijoje nagrinėjamos tik dviejų diagnozių grupės (I ir II grupės, žr. apibrėžtis skyriuje „Sutrupinimai“). Tipiškų nagrinėtų epilepsijos sukeltų EEG pikų pavyzdys pateikiamas 1.2 paveiksle.

Paveiksle matyti trys pikai, atitinkantys EEG pikams keliamus reikalavimus. Kad EEG pikas būtų įskaitytas, jis turi atsikartoti mažiausiai dviejuose gretimuose kanaluose. Kaip matyti 1.2 paveiksle, pikai atsikartoja daugelyje kanalų tuo pačiu metu. Antras reikalavimas, keliamas EEG pikui, – šis pikas nors du kartus turi iškilti virš foninio smegenų aktyvumo. Minėtina, kad pikas gali turėti tiek teigiamą, tiek neigiamą amplitudę. EEG piko morfologiniai požymiai aptariami tolesniame skyriuje.

1.1.5 Morfologiniai EEG piko požymiai

EEG pikui taikomi tam tikri morfologiniai reikalavimai [55] (schematinį EEG piko vaizdą žr. 1.3 pav.). Viso piko trukmė ($S1 + S2 + SD$) turėtų būti ne mažesnė negu 40 ms ir ne ilgesnė negu 200 ms. Piko amplitudė $A1$ visada turi būti didesnė už iškrovos amplitudę $A2$. Be to, to paties paciento šių amplitudžių santykis įprastai išlieka panašus [55]:

$$\frac{A1}{A2} \approx const. \quad (1.1)$$

Minėtina, kad EEG piko pakilimo kampas visada turi būti didesnis už piko nusileidimo kampą ($\angle a > \angle b$).

1.2 ANALIZEI NAUDOTI EEG DUOMENYS

Disertacijos tyrimai atlikti naudojant duomenis, gautus iš VšĮ Vilniaus universiteto ligoninės Santaros klinikų Vaikų ligoninės Vaikų neurologijos skyriaus. Duomenys rinkti 2010–2019 m. EDF [27] ir EDF+ [26] formatais.

Nagrinėti 168 pacientų 263 EEG duomenys. Minėtina, kad duomenų skaičius ilgainiui didėjo, nes atsirasdavo vis daugiau naujų EEG duomenų

[40, 41]. Duomenų pasiskirstymas pateikiamas 1.3 lentelėje.

Disertacijoje naudojami duomenys skirstytini į šias grupes:

- **I grupė:** gerybinė (rolandinė) vaikų epilepsija su centrotemporaliniais pikais (iš viso – 215 EEG (apie 80 proc. visų EEG), 135 pacientai (apie 80 proc. visų pacientų)). Šioje grupėje nustatyta 85 proc. visų disertacijoje nagrinėjamų EEG pikų.
- **II grupė:** struktūrinė židininė epilepsija, cerebrinis paralyžius, smegenų žievės displazija, gliozė ir kt. (iš viso – 48 EEG (apie 20 proc. visų EEG), 33 pacientai (apie 20 proc. visų pacientų)). Šioje grupėje nustatyta 15 proc. visų disertacijoje nagrinėjamų EEG pikų.

1.3 lentelė. EEG pasiskirstymas tarp mokymosi ir testavimo imčių (skliausteliuose nurodoma: 1) mokymosi imties EEG dalis* nuo visų atitinkamos grupės EEG, 2) mokymosi imties pacientų dalis** nuo viso atitinkamos grupės pacientų skaičiaus)

Grupė ir duomenų skaičius	I grupė	II grupė	Iš viso
EEG skaičius (iš viso)	215	48	263
Pacientų skaičius (iš viso)	135	33	168
EEG skaičius (mokymosi imtis)	43 (20,0 %*)	35 (72,9 %*)	78
Pacientų skaičius (mokymosi imtis)	37 (27,4 %**)	21 (63,6 %**)	58

Duomenų pasiskirstymą tarp mokymosi ir testavimo imčių (žr. 1.3 lentelę) lėmė duomenų, medikų išvalytų rankiniu būdu, pasiekiamumas. Išvalytais darbe laikomi duomenys, iš kurių gydytojai rankiniu būdu iškirpo artefaktų turinčias EEG atkarpas (žr. 1.1.3 poskyrį). EEG pikų aptikimo algoritmas nėra tobulas (žr. 2.1 skyrelį) tiek jautrumui, tiek specifiškumui nagrinėti, todėl EEG pikų paieškos algoritmo rezultatų kokybė yra geresnė, naudojant išvalytus EEG duomenis.

Atlikus eksperimentus, paaiškėjo, kad geriausių klasifikavimo pagal diagnozę rezultatų gaunama naudojant algoritmą, apdorojantį išvalytus

duomenis. Taigi klasifikavimo algoritmai buvo mokomi dirbti su išvalytais duomenimis. Minėtina, kad išvalytų duomenų kiekį riboja medikų galimybė skirti šiai veiklai laiko. Aptartos priežastys lėmė mokymo ir testavimo imčių pasiskirstymą (žr. 1.3 lentelę).

Dėl turimos programinės įrangos techninių apribojimų disertacijoje nagrinėti EEG pikai teikiami dviem būdais. Pirmieji duomenys buvo pateikti iki 2018 m. Neurologai pikus skaičiavo visoje EEG (nagrinėta 30 EEG, suskaičiuoti 5 557 pikai) ar jos laiko atkarpose (žr. 1.4 lentelę). EEG pikų paieškos algoritmas buvo optimizuojamas pagal neurologų nustatytą EEG pikų skaičių.


Minėtas duomenų teikimo būdas turi akivaizdų trūkumą: nors algoritmo nustatytas EEG pikų skaičius yra panašus, neįmanoma tiksliai sužinoti algoritmo jautrumo ir specifiškumo, nes lyginamas tik aptiktų EEG pikų skaičius (60 s arba 10 s EEG atkarpoje), bet lieka neaišku, ar algoritmas aptinka EEG pikus tose pačiose vietose, kaip ir neurologai. Dėl šios priežasties 2018 m. pradėta fiksuoti tiksliai EEG pikų padėtis, šiems duomenims rinkti [15] sukurtas atskiras įrankis. Visa tai leido tiksliai įvertinti algoritmo jautrumą ir specifiškumą, vėliau – optimizuoti pikų paieškos algoritmo parametrus. Neurologų surinkti duomenys apie EEG pikų vietas pateikiami 1.5 lentelėje.

1.4 lentelė. Neurologų suskaičiuoti EEG pikai (skaičius žymi visus EEG užfiksuotus pikus, toliau nurodyta, kuriuose kanaluose šie pikai nustatyti, skyra žymi, kokių intervalų EEG pikai buvo perskaičiuojami; kai kurių EEG pikai skaičiuoti mažesniu intervalu (laiko skyra didesnė), siekiant įsitikinti, kad algoritmas nespėja pikų skaičiaus)


EEG	Skaičius (iš viso)	Kanalai	Skyra
1	981	T4, C4	60 s
2	207	T3, C3	60 s
3	22	T6	60 s
4	370	T3, T5	60 s
5	211	C4, P4	10 s
6	52	T4, T6, C4	10 s
7	2	T3	60 s
8	857	C3, T5, Fp2, F4, F8	60 s
9	0	–	60 s
10	398	T6, T4	60 s
11	0	–	60 s
12	43	T6	60 s
13	59	T6, T4, F4	60 s
14	152	T3, T5	60 s
15	132	T3, T5	60 s
16	26	C3, T3	60 s
17	64	T4, T6	60 s
18	166	C3, T5, T6, P4	60 s
19	99	Cz, P4, C4, P3, Pz	10 s
20	163	T3, C3	60 s
21	263	T3, T5, T4	60 s
Iš viso:	4 267	–	–

1.5 lentelė. Disertacijoje naudoti EEG pikų duomenys, neurologų suskaičiuoti sukurtu įrankiu [15]

EEG	EEG pikų skaičius	Kanalas
1	177	T4
2	144	T3
3	150	P4
4	244	T3
5	16	T3
6	115	T3
7	54	T4
8	12	P3
9	69	P4
10	98	T3
11	101	T5
12	127	Pz
Iš viso:	1 307	–



1.2 pav. I grupės EEG pikų pavyzdžiai (grafike – 19 kanalų EEG 5 sekundžių atkarpa; šioje atkarpoje matyti trys pikai (ties 1,7, 2,6 ir 3,0 sekundėmis))



1.3 pav. EEG piko morfologija (piko dalis tarp S1 ir S2 yra pagrindinis EEG pikas, SD dalis – iškrova, kuri eina po kiekvieno EEG piko; A1 žymi piko, o A2 – iškrovos amplitudę

2. EEG ANALIZĖS METODAI IR ALGORITMAI

2.1 MORFOLOGINIS EEG PIKŲ APTIKIMO ALGORITMAS

Šiame skyriuje aprašomas morfologinis algoritmas, naudotas EEG pikams aptikti. Algoritmą, paremtą kitų tyrėjų darbais [24, 46, 72, 73], yra patobulinęs disertacijos autorius [39, 40].

2.1.1 Pirminis EEG apdorojimas

Prieš aptinkant EEG pikus, greitąją Furjė transformacija (FFT) pagrįstu filtru nufiltruotas elektros tinklo dažnis (50 Hz). Filtruotos visos dažnių dedamosios nuo 49 Hz iki 51 Hz. Taip sumažintas EEG signalo foninis triukšmas ir padidinta EEG pikų detekcijos kokybė.

2.1.2 Morfologinės operacijos

Disertacijoje naudojamas mokslinėje literatūroje [24, 46, 72, 73] gana plačiai aprašytas algoritmas. Jis paremtas morfologinėmis operacijomis ir serija filtrų. Elementariausios morfologinės operacijos, naudojamos disertacijoje, yra morfologinis susiaurinimas ir morfologinis išplėtimas.

Tiriamas signalas yra aprašomas kaip laiko eilutė $f(t)$. Struktūrinis elementas apibrėžiamas kaip $g(t)$, o jo atspindys $g^s(t) = g(-t)$. D yra $f(t)$ signalo apibrėžties sritis. Šiuo atveju morfologinis susiaurinimas gali

būti aprašytas kaip:

$$(f \ominus g^s)(t) = \min_{\tau \in D} \{f(\tau) - g(-(t - \tau))\}. \quad (2.1)$$

Morfologinis išplėtimas gali būti aprašomas analogiškai kaip:

$$(f \oplus g^s)(t) = \min_{\tau \in D} \{f(\tau) + g(-(t - \tau))\}. \quad (2.2)$$

Naudojant pateiktus apibrėžimus (žr. (2.1) ir (2.2) formules), galima apibrėžti morfologinio atidarymo ir uždarymo operacijas. Morfologinis atidarymas apibrėžiamas kaip:

$$(f \circ g)(t) = [(f \ominus g^s) \oplus g](t). \quad (2.3)$$

Morfologinis uždarymas apibrėžiamas analogiškai:

$$(f \bullet g)(t) = [(f \oplus g^s) \ominus g](t). \quad (2.4)$$


Kaip jau minėta, EEG pikai gali turėti tiek teigiamą, tiek neigiamą amplitudę, todėl reikia apibrėžti papildomas morfologines operacijas, kurios išryškintų bet kurio ženklo amplitudės EEG pikus. Naudojantis (2.3) ir (2.4) formulėmis, uždarymo ir atidarymo operacija apibrėžiama kaip:

$$OC(f(t)) = f(t) \circ g_1(t) \bullet g_2(t). \quad (2.5)$$

Atidarymo ir uždarymo operacija apibrėžiama analogiškai:

$$CO(f(t)) = f(t) \bullet g_1(t) \circ g_2(t). \quad (2.6)$$

Atidarymo ir uždarymo operacija vidutinę signalo reikšmę padidina, o uždarymo ir atidarymo operacija vidutinę signalo reikšmę sumažina vienodu (pagal modulio reikšmę) dydžiu, esant vienodiems struktūriniais elementams. Pritaikant (2.5) ir (2.6) formules, sukuriama kombinuota morfologinė operacija, kuri nufiltruoja foninį smegenų aktyvumą ir



2.1 pav. Morfologinių filtrų veikimas (EEG pikas matyti ties 136,57 s; A dalyje vaizduojamas originalus EEG signalas ir jo filtravimas OC, CO ir kombinuotu OCCO filtrais, B dalyje parodytas pradinio ir OCCO filtru nufiltruoto signalo skirtumas)

išryškina pikus:

$$OCCO(f(t)) = \frac{OC(f(t)) + CO(f(t))}{2}. \quad (2.7)$$

2.1 paveiksle vaizduojamas aprašytų filtrų veikimas. Kaip matyti iš A dalies, EEG pikus geriausiai išskiria OC filtras, tačiau šis filtras prasčiausiai apgaubia signalo artefaktus. CO signalas artefaktus sumažina labiausiai, tačiau prasčiau išskiria EEG pikus. Dėl šios priežasties kai kurie tyrėjai [24] renka filtravimą OCCO filtru.

Struktūrinis elementas parenkamas taip, kad nufiltruojami net didelės amplitudės iškilimai virš signalo. Priežastis – morfologinio filtravimo metu išryškinami tik trumpi pikai, būdingi epilepsijai. Kaip morfologiniai

filtrai veikia, aiškinama tolesniuose skyriuose.

2.1.3 Struktūriniai elementai

Morfologiniam filtrui pritaikyti būtini struktūriniai elementai. Disertacijoje struktūriniai elementai parinkti taip, kad nuo EEG pikų atskirtų foninį smegenų aktyvumą. Foninį smegenų aktyvumą geriausiai aproksimuoja parabolė:

$$g_i(t) = a_i k_i t^2 + b_i, \quad i = 1, 2. \quad (2.8)$$

Kad algoritmą būtų galima optimizuoti genetiniu algoritmu (plačiau žr. 2.2 poskyrį), įvedamas k_i koeficientas. Pradinė šio koeficiento reikšmė yra 1.

Smegenų ritmai gali būti bet kokio dažnio tarp 0,5 Hz ir 100 Hz. Kiekvienos EEG atkarpos parabolinių amplitudės dažniausiai skiriasi. Taip pat skiriasi ir kiekvienos EEG signalo atkarpos a ir b parametrai. Todėl svarbu apibrėžti masyvą W , kuris yra signalo arkų ilgių masyvas. Parametrai a ir b gali būti apibrėžti kaip:

$$a_1 = \frac{2 \text{Median}(|f|)}{\text{Median}(W)}, \quad a_2 = \frac{2 \text{Median}(|f|)}{3 \text{Median}(W)}, \quad b_1 = b_2 = \text{Median}(|f|). \quad (2.9)$$

Šie parametrai periodiškai turi būti vertinami iš naujo tokiu periodu:

$$t_r = 5 \text{ s}. \quad (2.10)$$

Nufiltruotas signalas gali būti apibrėžiamas kaip:

$$f_{\text{filtered}}(t) = |f(t) - OCCO(f(t))|. \quad (2.11)$$

(2.5), (2.6), (2.7) ir (2.11) formulėmis aprašytų filtrų veikimas iliustruojamas 2.1 pav.

2.1.4 EEG pikų aptikimo algoritmas

Disertacijos 2 skyriuje aprašomas EEG pikų aptikimo algoritmas yra patobulinta algoritmo, aprašyto mokslinėje literatūroje [24], versija. Įgyvendinus algoritmą, eksperimentais nustatyta, kad analizei, kuriai tinka ir anksčiau aprašyti a_i ir b_i parametrai, tinkamiausia maždaug 5 s trukmės EEG signalo atkarpa. EEG atkarpa, nagrinėjama iteracijoje, turi būti pakankamai ilga, kad joje būtų galima aptikti EEG piką ir nustatyti vyraujančius smegenų ritmus, tačiau kartu ji turėtų būti ir gana trumpa, kad vyraujantys ritmai labai nepasikeistų. Pasikeitus vyraujantiems smegenų ritmams, a_i ir b_i parametrus privalu vertinti iš naujo, siekiant atpažinti foninį smegenų aktyvumą. Jei parametrai parinkti netiksliai, smegenų foninis aktyvumas nufiltruojamas netinkamai, todėl EEG pikai pradedami detektuoti ten, kur jų nėra (mažėja algoritmo specifiškumas), arba praleidžiami mažiau virš fono iškilę pikai (mažėja algoritmo jautrumas).

Minėtas iteracinis signalo ilgis pasirinktas dėl šios priežasties: atliekant tyrimą, ilgainiui dėl prakaito ir kitų veiksnių keičiasi pacientų galvos odos laidumas, todėl keičiasi ir struktūrinių elementų parametrai (ypač amplitudė). Taigi šiuos parametrus būtina perskaičiuoti. Minėtina, kad įvardytus artefaktus lengviausia nufiltruoti, kai EEG signalo atkarpa yra 4–6 s trukmės.

Nurodyto iteracijos periodo pasirinkimą lėmė faktas, kad algoritmas yra sudėtingas ne tik viso signalo ilgio, bet ir analizuojamos signalo atkarpos ilgio atžvilgiu. Mažesnėse signalo atkarpose algoritmas veikia greičiau. Analizuojamos signalo atkarpos negali būti smarkiai mažinamos dėl jau minėtų priežasčių: signalo atkarpa privalo būti pakankamai ilga, kad joje būtų galima nustatyti vyraujančius smegenų ritmus ir iš jų išskirti EEG pikus.

Kiekvienam pacientui būdingi skirtingos morfologijos pikai, todėl tiksli

detekcijos riba kiekvienu atveju skiriasi. Disertacijoje skaičiavimai atliekami taikant kelias detekcijos ribas. Kuris iš apskaičiuotų pikų yra tiksliausias, paliekama nuspręsti gydytojui. Ribos, kuriose aptinkami pikai, apibrėžiamos kaip:

$$L = 2 k_L \text{Median}(f_{\text{filtered}}). \quad (2.12)$$

Pradinė k_L koeficiento reikšmė yra 1 (plačiau apie šio koeficiento taikymą žr. 2.2 poskyryje).


Nuo pasirinktos EEG ribos (ir kitų parametru) priklauso EEG pikų aptikimo algoritmo jautrumas, specifiškumas ir kitos charakteristikos. Minėtų parametru optimizacija tyrimo pradžioje buvo atliekama rankiniu būdu, tačiau vėliau, patikslinus EEG pikų duomenis, atsirado galimybė optimizaciją automatizuoti.

2.1.5 Morfologinių filtrų tobulinimo svarba

Kaip jau minėta, EEG pikų aptikimo algoritmas yra itin jautrus kai kuriems morfologinio filtro parametrams. 2.2 paveiksle vaizduojamas originalus signalas, nufiltruotas morfologiniais filtrais, kuriems būdingi įvairaus ilgio struktūriniai elementai. Paveikslu akcentuojama tinkamo ilgio struktūrinio elemento pasirinkimo svarba.

Paveikslo A dalyje vaizduojamas originalus EEG signalas.

B dalyje vaizduojamas signalas, nufiltruotas morfologiniu filtru, turinčiu per trumpą struktūrinį elementą. Kaip matyti, minėtu atveju labai efektyviai nufiltruojamas signalo triukšmas ir artefaktai, tačiau labai menkai išryškinami EEG pikai. Per daug sumažinus detekcijos ribą, tikėtina, mažėtų algoritmo jautrumas, per daug šią ribą padidinus – specifiškumas.



2.2 pav. Detekcijos kokybės priklausymas nuo struktūrinio elemento ilgio (A dalyje vaizduojamas originalus signalas, B dalyje – signalas, nufiltruotas morfologiniu filtru, turinčiu per trumpą struktūrinį elementą, C dalyje – signalas, nufiltruotas morfologiniu filtru, turinčiu per ilgą struktūrinį elementą, D dalyje – signalas, nufiltruotas filtru, turinčiu tinkamo ilgio struktūrinį elementą)

C dalyje vaizduojamas tas pats signalas, tik nufiltruotas morfologiniu filtru, turinčiu per ilgą struktūrinį elementą. Šiuo atveju lieka daug įvairių signalo artefaktų, išauga tikimybė, kad jie viršys detekcijos ribą. Vienas artefaktas, viršijęs detekcijos ribą, algoritmo specifiškumui nenkenkia, nes, kaip jau minėta, EEG pikas fiksuojamas tik tada, kai jis tuo pat metu randamas bent dviejuose gretimuose kanaluose. Vis dėlto, nereikalingas signalo dalis filtruojant netinkamai, išauga tikimybė, kad piku gali būti palaikyti dviejuose gretimuose kanaluose esantys artefaktai ir jie klaidingai gali būti traktuojami kaip pikas. Dėl šių priežasčių ypač svarbu tinkamai parinkti morfologinio filtro struktūrinio elemento ilgį.

D dalyje vaizduojamas originalus EEG signalas (žr. A dalį), nufiltruotas morfologiniu filtru, turinčiu tinkamo ilgio struktūrinį elementą. Kaip matyti, triukšmas ir įvairūs artefaktai nufiltruojami pakankamai efektyviai, o EEG pikai labai išryškinami. Galima pastebėti, kad išryškinamas ne tik pikas, bet ir po jo susiformuojanti lėta banga, tačiau tai algoritmui netrukdo, nes lėta banga yra laikoma EEG piko dalimi (skaičiuojamas vienas EEG pikas).


Gautas tinkamiausias struktūrinio elemento ilgis:

$$t_e = 4 k_e \text{Median}(W). \quad (2.13)$$

Dėl nurodytų priežasčių tikslinga optimizuoti ir EEG piko struktūrinio elemento t_e ilgį – jį padauginti iš atitinkamo daugiklio k_e , kurio pradinė reikšmė lygi 1.

2.1.6 Artefaktų filtravimas

Morfologiniai filtrai sukurti taip, kad atmestų daugelį EEG artefaktų. 2.3 paveiksle vaizduojamas EEG signalas, kuriam būdingi tiek EEG pikai, tiek artefaktai. Kaip matyti, ilgalaikiškesni signalo pakilimai efektyviai



2.3 pav. Originalus signalas, turintis artefaktų ir pikų (A dalyje vaizduojamas originalus signalas, turintis artefaktų, B dalyje – originalus signalas, nufiltruotas morfologiniu filtru)

nufiltruojami, o dauguma trumpalaikių triukšmų detekcijos ribos nesiekia ir toliau nėra nagrinėjami. Kai kuriais atvejais artefaktai viršija EEG piko detekcijos ribą, bet minėtais atvejais atsižvelgiama į piko morfologinius požymius, aprašytus ankstesniuose skyriuose. Tais atvejais, kai morfologinis filtras negeba nufiltruoti pikų, pasitelkiami kiti piko validavimo kriterijai.

EEG pikai validuojami pagal kriterijus, nustatytus remiantis medicinos literatūroje aprašytomis pikų savybėmis [55, 57, 64]:

- EEG piko aštrios bangos pakilimo kampas k_u negali būti mažesnis už piko nusileidimo kampą k_d (žr. 3.4.1 poskyrį).
- EEG piko aštrios bangos trukmė negali būti mažesnė negu 20 ms ir

didesnė negu 60 ms.

- EEG piko trukmė (aštri ir lėta bangos) negali viršyti 200 ms.

EEG piko iškilimas virš foninio signalo nebuvo tikrinamas, nes manoma, kad šį patikrinimą atlieka morfologinio filtro ir detekcijos ribos ((2.12) formulė) kombinacija.


Tinkamai nustatytų ir gerai aproksimuotų pikų pavyzdžių pateikiama 2.4 pav., nekorektiškai nustatytų pikų pavyzdžių pateikta 2.5 pav.

2.1.7 Algoritmo jautrumo ir specifiškumo vertinimas


EEG pikų aptikimo algoritmo jautrumas ir specifiškumas negali būti įvertinti visiškai tiksliai. Pagrindinė priežastis – gydytojai nesutaria, kas laikytina EEG piku, o ko EEG piku laikyti nereikėtų. Minėtina, kad tas pats gydytojas, kelis kartus skaičiuodamas pikus toje pačioje EEG, gali gauti šiek tiek skirtingus rezultatus. Vien dėl šios priežasties EEG pikų aptikimo algoritmo jautrumas ir specifiškumas niekada nesieks 100 proc.

Vis dėlto disertacijoje naudojami neurologų pateikti EEG pikų skaičiai ir duomenys apie tikslias šių pikų vietas traktuoti kaip atspirties taškas, vertinant algoritmą.

2.6 paveiksle pateikiamas sudėtingai aptinkamo EEG piko pavyzdys. Tokius pikus neurologai vertina kaip tikrus, tačiau šie pikai ne visada atitinka formaliai keliamus reikalavimus. Esame apskaičiavę, kad, vertinant EEG pikų aptikimo algoritmo specifiškumą ir jautrumą, dėl jau minėtų priežasčių tikėtina maždaug 5 proc. paklaida. Detalios minėtų parametrų reikšmės bus aptartos tolesniuose skyriuose.



(a)




(b)


2.4 pav. Tinkamai nustatytų pikų pavyzdžiai (algoritmas [24, 39]; pikų parametrus sėkmingai aptiko EEG pikų metrikos algoritmas [40])

2.2 MORFOLOGINIO FILTRO OPTIMIZAVIMAS GENETINIU ALGORITMU

Turint tinkamus EEG pikų duomenis (tiksliai EEG pikų vietas signale), atsirado techninė galimybė optimizuoti EEG pikų paieškos algoritmą. Minėtina, kad algoritmas turi tam tikrų konstantų, kurių kilmė nėra iki galo pagrįsta, todėl, optimizuojant koku nors algoritmu, siekiama rasti tinkamiausias parametrų reikšmes.



(a)




(b)

2.5 pav. Originalaus algoritmo neteisingai nustatytų pikų pavyzdžiai (algoritmas [24, 39]; pikai atmesti, nes jų parametru reikšmės neatitiko mediciniškai įmanomų pikų reikšmių [40])

Svarstyti įvairūs galimi algoritmų pasirinkimai. Algoritmų pasirinkimo galimybes itin riboja šie veiksniai:

- Esant kai kurioms parametru kombinacijoms, dėl dalybos iš nulio ar kitų matematinių klaidų neįmanoma nustatyti tikslo funkcijos reikšmės. Pavyzdžiui, k_e (žr. (2.13) formulę) parametro reikšmė gali būti tik didesnė už nulį, todėl darytina išvada, kad tikslo funkcija yra trūki.



2.6 pav. EEG signalo gretimuose elektroduose dalys ir nufiltruotos jų versijos su detekcijos ribomis (P1 ir P2 žymi pikų vietas, kurios būtų detektuojamos medikų, tačiau nėra detektuojamos algoritmo; A ir C dalyse vaizduojami originalūs signalai, B ir D dalyse – nufiltruoti signalai $f_{filtered}$ su detekcijos ribomis)

- Nėra žinoma jokių kitų tikslo funkcijos matematinė savybių, išskyrus netolydumą.
- Kiekvienas tikslo funkcijos įvertis reikalauja atskiro eksperimento (jautrumo ir specifiškumo įvertinimo duotais parametrais).
- Nėra tiksliai žinoma, kokiame verčių intervale reikšmė turėtų būti optimizuota.
- Optimizuojama funkcija neturi matematinės išraiškos ir gali būti įvertinta tik eksperimentu.

Tokie algoritmai, kaip nusileidimas pakoordinačiui ar gradientinis nusileidimas, reikalauja tam tikrų tikslo funkcijos savybių (netrūkumo, diferencijuojamumo), kurių, kaip minėta, neįmanoma užtikrinti. Mokslinėje literatūroje nurodoma, kad šioms problemoms spręsti ypač dažnai naudojamas genetinis algoritmas [30, 36, 51].

Kita priežastis, paskatinusi rinktis genetinį algoritmą, yra tai, kad šį algoritmą palyginti lengvai galima išlygiagretinti. Ilgiausiai trunkanti iteracijos dalis – genetinių individų įvertinimas. Taikant minėtą algoritmą, individai gali būti vertinami lygiagrečiai, jų tikslo funkcijos įverčiai surenkami valdančiąjame procese.

Minėtos priežastys lėmė genetinio algoritmo pasirinkimą morfologinio algoritmo parametrus optimizuoti.

2.2.1 Tikslo funkcijos parinkimas

Optimizacijai atlikti reikalinga tikslo funkcija, todėl ieškoma šios funkcijos globaliojo ar lokaliajo ekstremumo (minimumo arba maksimumo). EEG pikų paieškos algoritmą galima optimizuoti pagal kelias metrikas (pavyzdžiui, pagal tikslumą, jautrumą, specifiškumą) ar jų kombinacijas. Metrikos pasirinkimas iš esmės priklauso nuo sprendžiamo uždavinio: vieniems uždaviniams gali reikėti kuo daugiau aptiktų EEG pikų, kitiems gali būti svarbus EEG pikų aptikimo jautrumas, o kiekis mažiau svarbus.

Disertacijoje iš esmės sprendžiami du uždaviniai: 1) EEG pikų paieška, 2) EEG klasifikavimas pagal diagnozę. Atsižvelgiant į tai, kad vieninteliai moksliniai darbai, klasifikuojantys I ir II grupių EEG pagal diagnozę, yra disertacijos autoriaus, nuspręsta vienu metu tirti kelias metrikas:

- jautrumą (siekiama nustatyti kuo daugiau pikų, atsižvelgiant į riziką, kad didelė šių pikų dalis bus neteisingai teigiamai aptikti pavyzdžiai);

- specifiškumą (kuo daugiau nustatytų pikų turėtų būti teisingai teigiamai aptikti pavyzdžiai, išliekant didelei rizikai neaptikti daugelio EEG pikų);
- jautrumo ir specifiškumo verčių minimumą (ši tikslo funkcija turėtų būti kompromisas tarp specifiškumo ir jautrumo, nes, sumažėjus bent vienai iš minėtų charakteristikų, kartu sumažėtų ir tikslo funkcijos reikšmė).

2.2.2 Optimizavimo rezultatai

Kaip buvo matyti 2.1 poskyryje, morfologinio algoritmo formulėse įvesti specialūs kintamieji, per kuriuos labai lengva apibrėžti genetinį individą. Tai $[k_1, k_2, k_L, k_e]$, kurių pradinės reikšmės $[1, 1, 1, 1]$. Koeficientai k_1 ir k_2 turi poveikį struktūrinio elemento formai ir yra įvedami (2.8) formulėje, k_L koeficientas veikia pikų aptikimo ribą ir yra įvedamas (2.12) formulėje, k_e koeficientas veikia struktūrinio elemento ilgį ir yra įvedamas (2.13) formulėje. Minėtina, kad (2.8) formulėje prie b_i nėra optimizavimui skirto koeficiento, nes, atliekant išankstinį tyrimą, nustatyta, jog minėtas parametras neturėjo įtakos galutiniam rezultatui, todėl buvo pašalintas iš tolesnių tyrimų kaip nereikšmingas.

Atsižvelgiant į praktinius skaičiavimo pajėgumus, pasirinktas 100 genетinių individų populiacijos dydis. Siekiant, kad pradinis sprendinys $[1, 1, 1, 1]$ būtų gana arti tikrojo sprendinio, nuspręsta taikyti vadinamąjį genetinio algoritmo elitizmą, 10 proc. geriausių populiacijos individų perkeliant į kitą populiaciją. Šis sprendimas padėjo užtikrinti, kad sprendinys nenutolo nuo optimizuojamos reikšmės.

Genetiniai individai generuoti taikant Gauso (normalųjį) skirstinį (vidurkis $\mu = 1$, sklaida $\sigma^2 = 1$). Tai užtikrino genetinių individų išsibarstymą apie pradinį sprendinį. Taip pat taikyta 2 proc. mutacijos tikimybė. Individui mutuojant, atsitiktinė jo savybė buvo keičiama naudojant Gauso

2.1 lentelė. Pradinė reikšmė ir optimizavimo rezultatai, gauti taikant genetinį algoritmą (GA) (rezultatai gauti atliekant eksperimentus su EEG, turinčiomis artefaktų)

Optimizavimo būdas	Jautrumas	Specifiškumas	k_1	k_2	k_L	k_e
Pradinė reikšmė	0,70	0,71	1,00	1,00	1,00	1,00
Jautrumas (GA)	0,92	0,38	0,56	0,61	0,26	0,53
Specifiškumas (GA)	0,11	0,88	1,61	1,63	6,82	1,03
Min (jautrumas, specifiškumas) (GA)	0,73	0,72	1,06	1,08	1,25	1,01

skirstinį, kurio vidurkis lygus esamai reikšmei, o sklaida $\sigma^2 = 1$. Kryžminimas įgyvendintas du individus perskiriant ties atsitiktiniu jų savybių indeksu, galines dalis sukeičiant vietomis ir vėl jas sujungiant.

Algoritmas buvo stabdomas, kai 10 populiacijų iš eilės nepavykdavo pagerinti geriausio rasto sprendinio. Kiekvienos tikslo funkcijos algoritmas pakeistas po 5 kartus, siekiant įsitikinti, kad gaunamas panašus (paklaidos ribose) sprendinys. Gauti optimizavimo rezultatai pateikiami 2.1 lentelėje.

Minėtina, kad 2.1 lentelėje pateikiami rezultatai yra prastesni negu nurodyti kitų autorių [19]. Tai lemia keletas priežasčių: 1) dauguma autorių tiria itin siaurą diagnozių ratą, dažniausiai apsiribojantį viena konkrečia diagnoze, 2) nagrinėjami rankiniu būdu apdoroti (pvz., iškarpanant artefaktų paveiktas vietas ar kt.) arba sintetiškai generuoti duomenys, 3) tiriamos mažos, todėl statistiškai nereikšmingos EEG ir pikų duomenų imtys. Atsižvelgiant į anksčiau minėtas priežastis, galima teigti, kad gautasis EEG pikų aptikimo algoritmo jautrumas ir specifiškumas yra panašūs į nurodytus kitose, neturinčiose trūkumų studijose, tiriančiose statistiškai reikšmingas duomenų imtis.

Tolesniuose poskyriuose aprašytiems EEG klasifikavimo algoritams svarbus tiek didelis pikų skaičius, tiek kuo didesnis specifiškumas, todėl naudojami EEG pikai, nustatyti *Min (jautrumas, specifiškumas)* metrikos gautais morfologinio filtro parametrais.

2.3 PIKŲ APTIKIMO ALGORITMO LYGIAGRETINIMAS

Disertacijoje įgyvendintas EEG pikų aptikimo algoritmas yra gana imlus skaičiavimams², todėl kilo poreikis algoritmą išlygiagretinti. Šiuo tikslu galima naudoti įvairias technologijas. Technologijos yra ribojamos veikimo aplinkos, jos turi savų privalumų ir trūkumų.

2.3.1 MPI ir gijos


Programavime šiuo metu naudojamos dvi programų lygiagretinimo strategijos: lygiagretinimas gijomis (angl. *multithreading*) ir lygiagretinimas procesais, perduodant žinutes (MPI). Abu metodai leidžia pagreitinti programos veikimą, dalį skaičiavimų lygiagrečiai atliekant skirtinguose procesoriuose ar jų branduoliuose. Esminis skirtumas – gijos skirtos skaičiavimų sistemoms, turinčioms bendrą RAM, MPI – sistemoms, kurių RAM paskirstyta (gali veikti ir sistemose, turinčiose bendrą RAM) [70].

Atliekant disertacijoje pristatomus tyrimus, kaip jau minėta, skaičiavimai vykdyti dviejose sistemose: VU MIF PST ir doktoranto asmeniniame kompiuteryje (žr. skyrių „Tyrimo metodai ir priemonės“). Atsižvelgiant į tai, kad PST yra paskirstytųjų skaičiavimų tinklas, programai lygiagretinti nuspręsta naudoti MPI protokolą, nors eksperimentai buvo atliekami ir doktoranto kompiuteriu.

2.3.2 EEG pikų paieškos algoritmo išlygiagretinimas

Svarstytos dvi pagrindinės išlygiagretinimo schemas, taikytinos pikų paieškos algoritmui. Pirmoji schema pagrįsta tuo, kad EEG turi fiksuotą


²EEG pikų paieškos algoritmas užtrunka apie 1 min., analizuojant 1 min. trukmės atkarpą asmeniniu kompiuteriu, naudojant nuosekliai vykdomos programos versiją.



2.7 pav. Lygiagretinimo pagal EEG kanalus schema

kanalų skaičių, todėl kiekvienam procesui analizuoti galima skirti po vieną kanalą. Išsamiau apsvarsčius, šios schemos atsisakyta kaip menkai efektyvios. Programa veiktų tik su tiek gijų, koks jų skaičius atkartotų EEG kanalų skaičių. Be to, norint patvirtinti, kad signale rastas ieškomas objektas, šis objektas turi būti stebimas bent dviejuose gretimuose kanaluose – taip didėtų komunikacijos tarp gijų apimtis, nes procesas, aptikęs darinį, panašų į ieškomą signalo vietą, turėtų komunikuoti su kitais procesais, tikrindamas, ar darinys buvo aptiktas gretimuose EEG kanaluose. Kitas variantas – palikti tikrinimą baigiamajam procesui, bet tokiu atveju ši programos dalis nebūtų lygiagreti (žr. 2.7 pav.).

Darbe pasirinktos lygiagretinimo schemos esmė – kiekvienas procesas gauna vienodo ilgio visų kanalų EEG atkarpą. Procesų skaičius gali būti bet koks, o anksčiau minėtas tikrinimo procesas gali veikti kiekvieno proceso ribose ir taip būti išlygiagretintas (2.8 pav.). Vis dėlto, atlikus tokį išlygiagretinimą, suprastėjo EEG pikų aptikimo jautrumas. Jis atkurtas uždėjus 1 s trukmės persidengimus tarp gijų nagrinėjamų fragmentų. Minėtina, kad versijoje, kurioje persidengimai nenaudoti, kai kurie ieškomi EEG dariniai buvo „perpjaujami“ gijų paskirstymo vietose ir nedetektuojami nė vienoje gijoje. Tikrinant galutinius rezultatus, turi būti išmetami skirtingų gijų du kartus detektuoti dariniai. Dėl šios priežasties šiek tiek sulėtėjo programos vykdymas, tačiau gauti rezultatai buvo identiški vieno proceso programos versijai.



2.8 pav. Lygiagretinimo pagal EEG laiką schema

2.3.3 Pagreitėjimo testavimas

Norint gauti kuo tikslesnius rezultatus, pasirinkta ilgesnė (23 min. trukmės) EEG. Laikytasi požiūrio, kad jei apdorojimo laikas bus pakankamai ilgas, su programos vykdymu nesusiję, tačiau sistemos resursus naudojantys procesai statistiškai turės kuo mažiau įtakos rezultatams. Testas 100 kartų atliktas doktoranto asmeniniame kompiuteryje, 10 kartų – superkompiuteryje, apskaičiuota medianinė vertė. Atsižvelgus į turimos sistemos techninę charakteristiką, doktoranto asmeniniame kompiuteryje testai buvo atliekami naudojant 1, 2, 3 ir 4 procesorių branduolius (sistema turi 4 fizinius branduolius). Superkompiuteryje tyrimas buvo atliekamas iki 32 procesų.

Siekiant palyginti sistemos pagreitėjimą, atliekant MPI ir gijų technologijos pagrindu paremtus skaičiavimus, sukurtos dvi išlygiagretintos sistemos versijos: viena iš jų remiasi MPI technologija ir *MPI4Py* biblioteka, kita premta standartine *Python* programavimo kalbos biblioteka *Threading*.

2.3.3.1 Tyrimas asmeniniame kompiuteryje


Iš gautų rezultatų galima daryti išvadą, kad gijų pagrindu išlygiagretinta programa veikia šiek tiek greičiau, tačiau ši programa negali veikti paskirstytųjų skaičiavimų platformose, t. y. ten, kur atskiri procesoriaus branduoliai negali prieiti prie tų pačių RAM adresų. MPI pagrindu išlygiagretintos programos yra universalesnės, jos gali veikti bet kokiose sistemose, kurių mazgai gali susisiekti tinklu ar kitais būdais.

Mokslinėje literatūroje yra paskelbta, kad MPI ir gijų programavimas net taikytinas kartu (mazgo ribose programa veikia gijų pagrindu, o mazgai tarpusavyje bendrauja MPI pagrindu) [70]. Kai kuriais atvejais tai gali paspartinti programos veikimą, nors vis dėlto, manytina, kad šis sprendimas nėra tikslingas – skirtumas tarp MPI ir gijų veikimo greičio nėra didelis, o įgyvendinimas, tikėtina, sudėtingas.


Atkreiptinas dėmesys, kad tarp programos veikimo greičių egzistuoja triukšmas, ypač MPI aplinkoje. Tai gali lemti kelios priežastys. Visų pirma, minėtinos kompiuteryje veikiančios skaičiavimams nebūtinai programos, kurios vis tiek naudoja tam tikrą kompiuterio resursų dalį. Antra, testas buvo atliekamas *Oracle VM VirtualBox* pagrindu veikiančioje *Ubuntu Linux* virtualioje mašinoje, kuri taip pat naudoja resursus.

2.3.3.2 Tyrimas superkompiuteryje

Kaip jau minėta, programos veikimas taip pat buvo tirtas VU MIF superkompiuteryje. Siekiant sumažinti aparatūros įtaką rezultatams, tyrimas buvo atliekamas tik Gamma telkinio mazguose, nes šie mazgai tarpusavyje susisiekiama greičiausiai (40 GB/s Infiniband). Minėtina, kad šis greitis teoriškai netgi viršija asmeninio kompiuterio sisteminės magistralės veikimo greitį (34,1 GB/s). Vis dėlto yra kitų techninių niuansų: procesoriaus branduolio skaičiavimų našumas, RAM atminties



2.9 pav. Spartinimo (T) priklausomybė nuo gijų skaičiaus



2.10 pav. Išlygiagretinimo efektyvumo koeficiento (k_{eff}) priklausomybė nuo gijų skaičiaus


greitis ir vėlinimas, todėl pirminiai rezultatai tiesiogiai nebuvo lyginti, o superkompiuteryje, naudojant vieną procesorių, atliktas naujas bazinis skaičiavimas.

Superkompiuteris – sistema, iš esmės skirtinga nuo asmeninio kompiuterio: jos mazgai tarpusavyje gali susisiekti tik tinklu, vienas mazgas negali tiesiogiai prieiti prie kito mazgo RAM turinio, visiems mazgams pasiekiamas tik tas pats kietojo disko turinys. Dėl šių priežasčių superkompiuteriu buvo atliekamas tik MPI versijos tyrimas. Gijomis išlygiagretintą programos versiją teoriškai galima būtų tirti vieno superkompiuterio mazgo ribose. To atsisakyta dėl dviejų priežasčių: MPI ir gijų efektyvumo lyginimas jau buvo atliktas asmeniniu kompiuteriu, be to, nebuvo pagrindo tikėtis kitų rezultatų.


Superkompiuteryje pastebimas (žr. 2.10 pav.) mažesnis rezultatų išsibarstymas. Tai, tikėtina, skiriasi nuo rezultatų, gautų asmeniniu kompiuteriu, nes superkompiuteryje nėra skaičiavimams nebūtinų programų, galinčių panaudoti reikalingus resursus. Be to, superkompiuteris neveikia virtualių mašinų pagrindu, todėl skaičiavimams lieka papildomų resursų.

Tiriamosios sistemos mazguose yra po 4 procesorius, turinčius po 4 branduolius, todėl tyrimas buvo atliekamas pradedant nuo 4 procesų, jų skaičių keliant po 4 iki 32 procesų. Taip pat, kaip jau minėta, buvo atliktas bazinis skaičiavimas, naudojant vieną procesorių.

Lygiagretinimas superkompiuteryje rodo tas pačias tendencijas, kaip ir skaičiavimai asmeniniu kompiuteriu, tik, esant didesniai procesorių skaičiui, geriau matyti, kaip greitai krinta skaičiavimo efektyvumas. Jei apie 96 proc. kodo veikia lygiagrečiai, esant 32 procesoriams, pagreitėjimas siekia maždaug 14 kartų, o tai reiškia, kad išlygiagretinimo efektyvumas, esant aptartoms sąlygoms, yra apie 45 proc. (žr. 2.12 pav.).



2.11 pav. Skaičiavimo spartinimo (T) priklausomybė nuo gijų skaičiaus superkompiuteryje



2.12 pav. Išlygiagretinimo efektyvumo koeficiento (k_{eff}) priklausomybė nuo procesorių skaičiaus superkompiuteryje

3. EEG KLASIFIKAVIMAS PAGAL DIAGNOZĘ

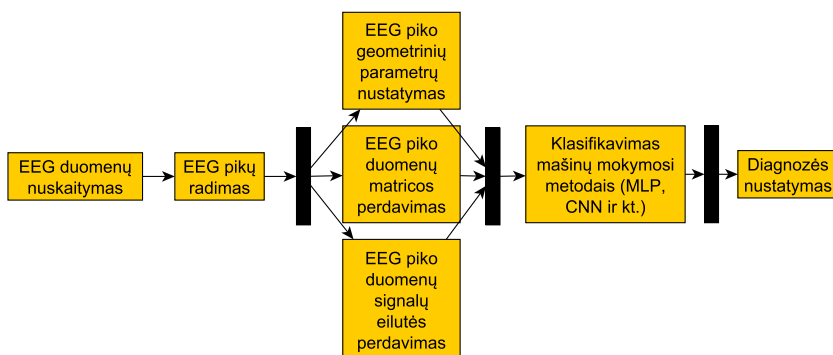
Šiame skyriuje aprašomas siūlomas EEG klasifikavimo pagal diagnozę algoritmas, jo tyrimo eksperimentų rezultatai. Aptariami naudoti klasifikatoriai, pateikiamos šių klasifikatorių kokybės metrikos, apžvelgiami kiti klasifikavimui svarbūs aspektai.

3.1 EEG KLASIFIKAVIMO PAGAL DIAGNOZĘ ALGORITMAS

Disertacijoje siūlomi trys EEG klasifikavimo pagal diagnozę algoritmo variantai. Visiems jiems būdingi tie patys esminiai žingsniai:

- pirminis EEG apdorojimas (žr. 2.1.1 poskyrį),
- EEG pikų aptikimas (žr. 2 skyrių),
- aptiktų EEG pikų paruošimas klasifikavimo algoritmams (pvz., nustatomi geometriniai parametrai),
- mašinių mokymusi pagrįstų klasifikatorių taikymas.

EEG apdorojimo ir EEG pikų aptikimo žingsniai yra bendri visiems šiame darbe siūlomiems EEG klasifikavimo pagal diagnozę algoritmo variantams. Pagrindiniai algoritmo variantų skirtumai atsispindi paskutiniuose dviejuose klasifikavimo žingsniuose (žr. 3.1 pav.).



3.1 pav. Algoritmo eigos diagrama (storos juodos linijos žymi galimus algoritmo išsišakojimus; darbe naudojami keli mašinių mokymosi metodai, aprašyti disertacijos 3.2 poskyryje)

3.2 MAŠINŲ MOKYMOŠI KLASIFIKAVIMO METODAI

Šiame skyriuje aprašomi darbe naudoti klasifikavimo metodai. Pasirinkti klasikiniai ir nauji algoritmai, naudojami medicininiams duomenims klasifikuoti. Algoritmų įgyvendinimai pasiekiami *Python* bibliotekose.

3.2.1 LDA

Tiesinė diskriminantinė analizė (angl. *Linear discriminant analysis*, LDA) yra vienas iš klasikinių daugelio klasių klasifikavimo metodų. Tai apibendrintas Fisherio tiesinio diskriminanto atvejis. LDA veikia panašiai kaip ir pagrindinių dedamųjų analizė, tačiau ne tik randa ašis, kuriose yra didžiausia sklaida, bet ir papildomai išplečia ašį, per kurią išsiskiria klasifikuojamos grupės.

LDA rezultatai priklauso nuo stebimų charakteristikų nepriklausomumo. Atsižvelgiant į darbe nagrinėjamus duomenis, šią duomenų savybę užtik-

rinti sudėtinga. Vis dėlto aptariamas klasifikatorius įtrauktas į analizę kaip vienas iš klasikinių klasifikatorių, galimų palyginti.

3.2.2 Logistinė regresija

Logistinė regresija (angl. *Logistic regression*) yra vienas iš klasikinių regresinių modelių, padedančių nustatyti tikimybę (tarp 0 ir 1), kad objektas priklauso vienai iš dviejų klasių. Šiuo tikslu naudojama logistinė lygtis:

$$y(x) = \frac{L_{max}}{1 + e^{-k_{lr}(x-x_0)}}. \quad (3.1)$$


Čia L_{max} yra didžiausia funkcijos vertė, k_{lr} – koeficientas, aprašantis logistinės kreivės augimo spartą, x_0 – funkcijos vidutinės reikšmės (0,5) vieta.

Pagrindinis logistinės regresijos privalumas – galima apskaičiuoti tikimybę, ar klasifikuojamas objektas priklauso tam tikrai klasei. Minėtina, kad logistinės regresijos matematiniam aparate daroma prielaida, jog duomenys, pagal kuriuos atliekamas klasifikavimas, yra matematiškai nepriklausomi. Mūsų atlikto tyrimo atveju tokios prielaidos užtikrinti negalima dėl medicininės duomenų kilmės ir itin sudėtingos CNS struktūros. Nepaisant to, atliekant eksperimentus, buvo ištirtas ir šio metodo veikimas.

3.2.3 MLP

Dirbtiniai neuroniniai tinklai (angl. *Artificial neural networks*, ANN) yra vienas iš klasikinių mašinių mokymosi metodų, pradėtų plėtoti 1950–1960 m. [45]. Viena iš ANN formų, naudotų disertacijoje, yra daugiasluoksnis perceptronas (angl. *Multilayer perceptron*, MLP)³. Sukurti MLP

³Atsižvelgiant į tai, kad šis klasifikatorius nėra vienintelė darbe vartojama ANN forma, daugiasluoksnis perceptronas toliau bus žymimas MLP santrumpa.

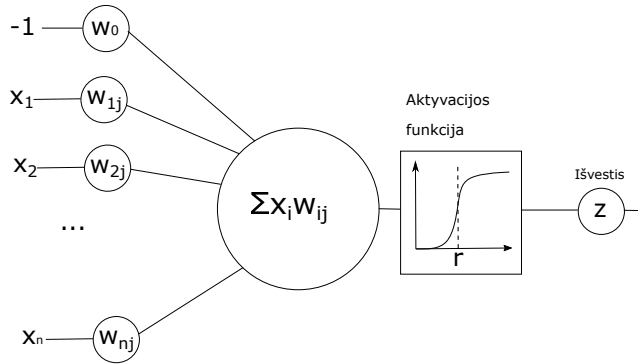


3.2 pav. Neuron modelis biologijoje [13] (autorių teisių nesaugoma iliustracija)

leido gamtoje egzistuojančios nervų sistemos ląstelės – neuronai. Nors tiksliai ląstelės struktūra gali priklausyti nuo gyvūno rūšies ar nervų sistemos dalies, kurioje ji randama, MLP modeliui svarbios fundamentalios neuroono dalys ir funkcijos: dendritai, ląstelės kūnas ir aksonai (žr. 3.2 pav.).

Neuroono dalys, priimančios signalus iš kitų neuroonų aksonų, yra dendritai (žr. 3.2 pav.). Jų atitikmuo neuroono matematiniam modelyje yra įvestis x_i (žr. 3.3 pav.), čia i yra neuroono įvesties numeris. Realios neurologinės sistemos išmoka į vienus signalus reaguoti jautriau, į kitus mažiau, į kai kuriuos signalus visai nereaguoti. Tai būdinga ir MLP – reagavimo jautrumą lemia svorio daugiklis w_{ij} (žr. 3.3 pav.) (čia j yra neuroono numeris).

Įvestys, padaugintos iš daugiklių, siunčiamos į ląstelės kūno atitikmenį, sudėtuva $\sum x_i w_{ij}$, o vėliau – į aktyvacijos funkciją, kurios paskirtis – nuspręsti, ar siųsti žadinimo signalą z (aksono atitikmuo) kitiems neuronams, ar ne. Klasikiniame neuroono modelyje galimos dvi išvesties reikšmės (0 arba 1), priklausomai nuo to, ar įvestis viršijo aktyvacijos



3.3 pav. MLP neurono modelis

funkcijos ribą r , ar ne.

MLP – tai tarpusavyje sąveikaujančių neuronų rinkinys. Taigi MLP išvestis gali būti apibrėžta kaip:

$$\vec{z} = f(\vec{x}, \vec{w}, \vec{r}). \quad (3.2)$$

Pageidaujama MLP išvestis gali būti apibrėžta kaip:

$$\vec{d} = g(\vec{x}). \quad (3.3)$$

MLP mokymas reiškia radimą tokių \vec{w} ir \vec{r} reikšmių, su kuriomis MLP duodamas atsakymas \vec{z} yra panašiausias į \vec{d} . Todėl reikia pasirinkti tikslo funkciją P , kuri bus optimizuojama, t. y. bus ieškoma lokalaus minimumo (vienu iš gradientinio nuolydžio metodų). Dėl matematinio ir programavimo patogumo dažniausiai naudojama funkcija:

$$P = \frac{1}{2} \|\vec{d} - \vec{z}\|^2. \quad (3.4)$$

Tam, kad suveikimo riba r netrukdytų minėtos išraiškos optimizuoti, įvedamas w_0 svoris, kuris visada dauginamas iš -1 (dėl matematinio

patogumo) ir parenkamas taip, kad suveikimo riba būtų $r = 0$.

Šiame darbe MLP klasifikatoriams naudota *Softmax* aktyvacijos funkcija, kuri gali būti apibūdinama kaip [45]:

$$a_j^L = \frac{e^{z_j^L}}{\sum_k e^{z_k^L}}, \quad (3.5)$$

j -tajam neuronui L -ajame sluoksnyje. Čia:

$$z_j^L = \sum_k w_{jk}^L a_k^{L-1} - w_0, \quad (3.6)$$

x_j yra MLP įvestis.

3.2.4 Atraminų vektorių mašina

Atraminų vektorių mašina (angl. *Support vector machine*, SVM) (apie jos naudojimą žr. 3.4 ir 3.5 skyriuose) yra mašinų mokymusi pagrįstas metodas, taikomas klasifikuojant ir kitais tikslais [2, 56].

Įvairūs klasifikatoriai pasižymi skirtingomis klasių atskyrimo strategijomis. SVM yra pagrįsta „plačiausios gatvės“ principu, kai klasifikuojamas imtis bandoma atskirti hiperpaviršiumi, labiausiai nutolusiu nuo abiejų imčių taškų (žr. 3.4 pav.).


Klasifikavimo taisyklė pirmajai klasei:

$$\vec{w} \cdot \vec{U} \geq c.$$

Antrajai klasei:

$$\vec{w} \cdot \vec{U} < c.$$

Čia \vec{w} yra atraminis vektorius (statmenas klasifikavimo plokštumai), o \vec{U} – vektorius, rodantis į klasifikuojamą tašką.



3.4 pav. SVM „plačiausios gatvės“ principo pavyzdys (klasifikuojamas grupės atskiriantis paviršius brėžiamas taip, kad būtų kuo labiau nutolęs nuo abiejų klasifikuojamų grupių (ištinė linija); $\vec{\omega}$ yra atraminis vektorius (statmenas „plačiausiai gatvei“), \vec{U} – vektorius, rodantis į naują klasifikuojamą nežinomos grupės tašką (pažymėtą pilka spalva).

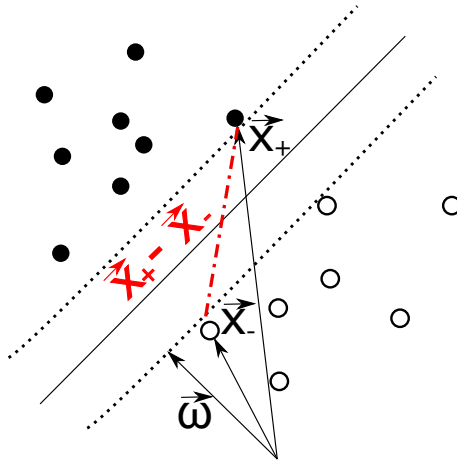
Pateikta klasifikavimo taisyklė nenurodo, kokio ilgio ir kaip turėtų būti brėžiamas atraminis vektorius, todėl jam taikomi tokie apribojimai:

$$\vec{\omega} \cdot \vec{x}_+ - c \geq 1, \quad (3.7)$$

$$\vec{\omega} \cdot \vec{x}_- - c \leq -1. \quad (3.8)$$

Čia \vec{x}_+ yra vektorius iš atraminio į žinomą pirmosios klasės tašką, o \vec{x}_- – vektorius iš atraminio į žinomą antrosios klasės tašką. Apribojimai reiškia, kad „plačiausia gatvė“ (žr. 3.4 pav.) yra $(-1; 1)$ intervale (kai atraminis vektorius skalariškai dauginamas su žinomu pirmos ar antros grupės pavyzdžiu).

Toliau apibrėžiame kintamąjį y_i ($y_i = 1$ pirmosios klasės pavyzdžiams, $y_i = -1$ antrosios klasės taškams). (3.7) ir (3.8) formules padauginame



3.5 pav. SVM „plačiausios gatvės“ pločio apskaičiavimas (čia x_+ ir x_- – pirmosios ir antrosios klasės taškai, esantys „gatvės pakraštyje“ pagal (3.10) sąlygą)

iš y_i kintamojo. Atsižvelgiant į tai, kad $y_i = -1$ antrosios klasės pavyzdžiams, (3.8) formulės nelygybės ženklas pasikeičia į priešingą ir (3.7) ir (3.8) nelygybės tampa vienodos:

$$y_i (\vec{x}_i \cdot \vec{\omega} - c) \geq 1, \quad (3.9)$$

čia \vec{x}_i – vektorius į bet kurios klasės tašką.

Atlikta operacija leidžia supaprastinti klasifikavimo taisyklę iki vienos nelygybės. Taip pat taikomas papildomas apribojimas taškams, esantiems „plačiausios gatvės“ pakraščiuose:

$$y_i (\vec{x}_i \cdot \vec{\omega} - c) - 1 = 0. \quad (3.10)$$

Remiantis 3.5 pav. ir faktu, kad atraminis vektorius $\vec{\omega}$ yra statmenas

„plačiausiai gatvei“, galime apibrėžti „plačiausios gatvės“ plotį:

$$P = (\vec{x}_+ - \vec{x}_-) \cdot \frac{\vec{\omega}}{\|\vec{\omega}\|}. \quad (3.11)$$

Iš (3.11) ir (3.10) formulių gauname, kad „plačiausios gatvės pakraštyje“:

$$\vec{x}_+ = 1 - c, \quad (3.12)$$

$$\vec{x}_- = 1 + c. \quad (3.13)$$

Iš to išeina, kad:

$$P = \frac{2}{\|\vec{\omega}\|}. \quad (3.14)$$

SVM „plačiausios gatvės“ radimas reiškia (3.14) išraiškos maksimizavimą. Minėtos išraiškos maksimizavimas yra ekvivalentus tokios išraiškos minimizavimui:

$$P' = \frac{1}{2} \|\vec{\omega}\|^2. \quad (3.15)$$

Keičiama todėl, kad (3.15) išraišką minimizuoti yra matematiškai paprasčiau. Taip gaunamas optimizavimo su tam tikrais apribojimais uždavinys, kurį išspręsti padeda Lagranžo daugikliai α_i :

$$P'' = \frac{1}{2} \|\vec{\omega}\|^2 - \sum_i \alpha_i (y_i [\vec{\omega} \cdot \vec{x}_i - c] - 1). \quad (3.16)$$

Minimizavimas reikalauja rasti tašką, kur išvestinė lygi nuliui:

$$\frac{\partial P''}{\partial \vec{\omega}} = \vec{\omega} - \sum_i \alpha_i y_i \vec{x}_i = 0. \quad (3.17)$$

Iš to išeina, kad:

$$\vec{\omega} = \sum_i \alpha_i y_i \vec{x}_i. \quad (3.18)$$

Kitas kintamasis, esantis (3.16) lygtyje, yra c , todėl:

$$\frac{\partial P''}{\partial c} = \sum_i \vec{x}_i y_i = 0.$$

(3.16) formulę įkėlus į (3.16) ir suprastinus gaunama:

$$P'' = \sum_i \alpha_i - \frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j \vec{x}_i \cdot \vec{x}_j. \quad (3.19)$$

(3.19) formulę galima minimizuoti skaitiniais metodais, tačiau atkreiptinas dėmesys, kad minėta išraiška iš esmės priklauso nuo x_i ir x_j skaliarinės sandaugos.

(3.8) klasifikavimo taisyklę taip pat galima perrašyti naudojantis atraminio vektoriaus apibrėžimu, remiantis (3.18) formule:


$$\sum_i \alpha_i y_i \vec{x}_i \cdot \vec{U} \geq 0. \quad (3.20)$$

Minėtina, kad visos klasifikuojamos aibės gali būti atskiriamos hiperplokštuma, todėl SVM naudojamos erdvinės transformacijos, klasifikuojamą erdvę keičiančios kita erdve, kurioje galima atskirti klases. 3.6 pav. vaizduojama erdvė efektyviai paverčiama į 3.4 pav. vaizduojamą erdvę, pasinaudojant branduoliu.

Branduolys gali būti apibrėžiamas kaip:

$$K(\vec{x}_i, \vec{x}_j) = \phi(\vec{x}_i) \cdot \phi(\vec{x}_j); \quad (3.21)$$

čia ϕ yra transformacijos funkcija.



3.6 pav. SVM su branduoliu taikymas klasėms, neatskiriamoms plokštuma

Klasifikavimo taisyklė SVM su K branduoliu gali būti užrašyta kaip:

$$\sum_{i=1}^n \alpha_i y_i K(\vec{x}_i, \vec{x}_j) \cdot \vec{U} \geq 0. \quad (3.22)$$

Vietoje K (3.22) klasifikavimo taisyklėje gali būti naudojamas bet koks branduolys. Šiame darbe (žr. 3.4 ir 3.5 skyrius) buvo pritaikyti mašinių mokymosi srityje populiariausi naudojami branduoliai: tiesinis, kubinis ($N_p = 3$), sigmoidinis ir radialinės bazinės funkcijos (RBF).

Polinominiai branduoliai (šiuo darbe – tiesinis ir kubinis) gali būti užrašomi:

$$K(\vec{x}_i, \vec{x}_j) = (\vec{x}_i \cdot \vec{x}_j + 1)^d, \quad (3.23)$$

čia d – branduolio laipsnis.

RBF branduolys:

$$K(\vec{x}_i, \vec{x}_j) = \exp\left(-\gamma \|\vec{x}_i - \vec{x}_j\|^2\right), \quad (3.24)$$

čia $\gamma > 0$.

Sigmoidinis branduolys:

$$K(\vec{x}_i, \vec{x}_j) = \tanh(\alpha \vec{x}_i^T \vec{x}_j + c). \quad (3.25)$$

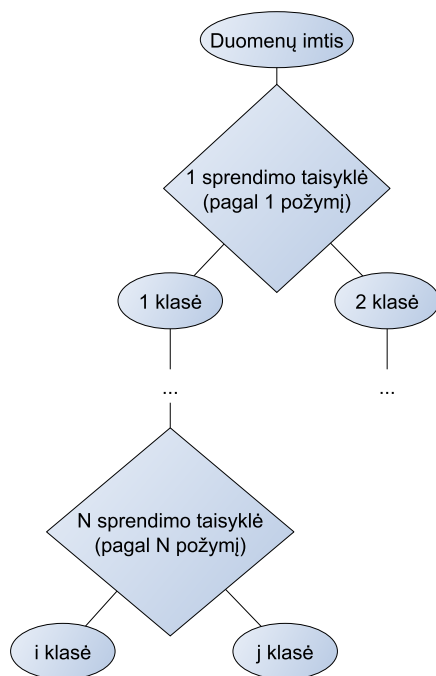
3.2.5 Sprendimų medis

Sprendimų medžiai yra vienas seniausių ir populiariausių mašinių mokymosi metodų [56]. Kiekvieno duomenų imties elemento klasifikavimas pradamas nuo aukščiausio medžio išsišakojimo. Duomenų imties elemento charakteristikos tikrinamos pagal nustatytas taisykles, tada duomuo perduodamas žemesnei šakai. Procesas tęsiamas tol, kol pasiekiamas paskutinis medžio išsišakojimas, kuriame yra lapas (pvz., i ir j klasės (žr. 3.7 pav.)).

Esama įvairių sprendimų medžio klasifikatoriaus mokymo algoritmų. Dažniausiai naudojama sprendimų medžio indukcija iš viršaus į apačią (angl. *top-down induction of decision trees*, TDIDT) ir rekursyvus dalijimas (vadinamasis „skaldyk ir valdyk“ mokymas, angl. *divide-and-conquer learning*) [56].

3.2.6 Atsitiktinis miškas

Atsitiktinis miškas yra kolektyvinis mašinių mokymosi metodas [56]. Sprendimų medis čia naudojamas kaip pamatinis klasifikatorius kartu su *Bagging* (angl. *Bootstrap AGGREGatING*) ir sprendimų medžio algoritmais. Kiekvienas medis yra sukurtas pagal dalinę egzistuojančių mokymosi duomenų imtį. Sukurti medžiai nėra genimi (angl. *prunning*), todėl gaunami medžiai yra permokomi pagal savo mokymosi imties duomenų dalį. Siekiant gaunamų medžių įvairovės, kiekvienas medis yra mokomas ne su visomis klasifikuojamų duomenų charakteristikomis. Atsitiktinis charakteristikų rinkinys yra sudaromas kiekvienam išsišakojimui.



3.7 pav. Sprendimų medžio diagrama (kiekviename medžio išsišakojime mokymosi imties elementai klasifikuojami pagal tam tikrą požymį į dvi klases)

3.2.7 Labai atsitiktiniai medžiai

Labai atsitiktiniai medžiai yra kita sprendimų medžio kolektyvinė variacija. Čia, palyginti su atsitiktinio miško klasifikatoriumi [18], atsitiktinės variacijos esama daugiau. Aptariamas algoritmas plačiai taikomas interpretuojant dėvimų jutiklių duomenis [68] ir medicinoje (smegenų augliams nustatyti [61]). Tai paskatino rinktis šį metodą tirti disertacijoje.

3.2.8 CNN

Konvoliucinis neuroninis tinklas (angl. *Convolutional Neural Network*, CNN) yra vienas iš mašinių gilaus mokymosi metodų, pagrįstų ANN, ypač plačiai taikomas klasifikuojant vaizdus ir kompiuterių regoje. CNN gali būti išmokytas pastebėti laikines ir erdvines priklausomybes, todėl taikomas ir signalų analizės uždaviniuose.

3.2.8.1 Atgalinis klaidos sklidimas CNN

Dažniausiai naudojama kvadratinė netekties funkcija (angl. *Loss Function*):

$$E^N = \frac{1}{2} \sum_{n=1}^N \sum_{m=1}^c (t_m^n - y_m^n)^2. \quad (3.26)$$

Čia c – klasifikuojamų klasių skaičius (m – klasės numeris), N – mokymosi imties dydis (n – mokymosi imties elemento numeris), t_m^n – n -tojo imties elemento klasė, y_m^n – neurono išvestis m -tajam išvesties sluoksniui atsakant į n -tąją įvestį.

Atsižvelgiant į tai, kad visa netektis yra atskirų netekčių suma, atgaliniam sklidimui naudojama netekties funkcija vienai klaidai (n -tajai įvesčiai):

$$E^n = \frac{1}{2} \sum_{m=1}^c (t_m^n - y_m^n)^2 = \frac{1}{2} \| \vec{t}^n - \vec{y}^n \|_2^2. \quad (3.27)$$

Kaip matyti, gauta raiška primena (3.4) formulę, nes CNN yra viena iš patobulintų ANN formų: įterpiama konvoliucinių ir sutelkimo sluoksnių, įvedama kitų šiame disertacijos poskyryje aprašytų pakeitimų.

Turint įprastus visiškai sujungtus sluoksnius (žr. 3.2.8.4 poskyrį), galima apskaičiuoti E^N dalines išvestines svorių atžvilgiu. Dabartinį sluoksni

pažymėkime S . Šio sluoksnio išvestis:

$$\vec{x}^S = f(\vec{u}^S). \quad (3.28)$$

Čia

$$\vec{u}^S = \vec{W}\vec{x}^{S-1} + \vec{b}^S, \quad (3.29)$$

kur f yra aktyvacijos funkcija.

Viena iš aktyvacijos funkcijų, naudojamų CNN, yra sigmoidinė aktyvacijos funkcija (kartais dar vadinama logistine; šiame darbe naudojama CNN klasifikatoriuose) (kai $x \in [-\infty, +\infty]$, $f \in [0,1]$):

$$f(x) = \left(1 + e^{-\beta x}\right)^{-1}. \quad (3.30)$$

Minėtina ir hiperbolinio tangento aktyvacijos funkcija (kai $x \in [-\infty, +\infty]$, $f \in [-a, +a]$):

$$f(x) = a \tanh(bx). \quad (3.31)$$

3.2.8.2 Konvoliuciniai sluoksniai

Konvoliucinio sluoksnio pagrindinė funkcija yra pereito sluoksnio charakteristikų žemėlapių konvoliucija (arba sąsūka) su apmokomais branduoliais, kuri perleidžiama per aktyvacijos funkciją į išvesties charakteristikų žemėlapi. Gauname:

$$\vec{x}_j^L = f\left(\sum_{i \in M_j} \vec{x}_i^{S-1} * \vec{K}_{ij}^S + b_j^S\right). \quad (3.32)$$

Čia $*$ reiškia konvoliucijos operaciją, M_j – įvesties žemėlapi, K – branduolį (filtrą), su kuriuo atliekama konvoliucija.

3.2.8.3 Sutelkimo sluoksniai

Sutelkimo (angl. *Subsampling Layer*) sluoksnio funkcija – sumažinti charakteristikų žemėlapių dydį. Įprastai CNN, esant N įvesties žemėlapiams, turima ir N išvesties žemėlapių. Sutelkimo sluoksnis padeda sumažinti jų dydį. Formaliai tai galima užrašyti taip:

$$\vec{x}_j^S = f(\beta_j^S \text{down}(\vec{x}_j^{S-1} + b_j^S)). \quad (3.33)$$

Čia $\text{down}(\cdot)$ reiškia sutelkimo (angl. *Subsampling*) funkciją. Tipiškai ji susumuoja kelių charakteristikų reikšmes žemėlapyje, taip sumažindama išvesties žemėlapi. Įprastai kiekvienas sluoksnis turi savo daugiklį β ir poslinkio reikšmę b , kurie randami mokant CNN.

3.2.8.4 Visiškai sujungti sluoksniai

Dažniausia visiškai sujungto sluoksnio paskirtis yra surinkti žemiau esančių sluoksnių įvestį ir atlikti klasifikavimą. Daugiaklasiai CNN klasifikatoriai gali turėti daug visiškai sujungtų sluoksnių.

Visiškai sujungtų sluoksnių tikslas – išlyginti įvesties žemėlapi į vektorių, kuris nurodytų tikimybes, kad klasifikuojamas objektas priklauso galimoms klasėms.

3.2.8.5 Tipinės CNN architektūros

Šiame poskyryje aptarėme esmines CNN matematinio aparato dalis ir sluoksnius. Galimybių sukonstruoti CNN iš minėtų sluoksnių yra be galo daug.

Mokslinėje literatūroje nurodoma dešimtys CNN architektūrinių modelių, kurie geriau negu kiti susidoroja su jiems skirtomis užduotimis. Viena iš

pirmųjų paplitusių CNN architektūrų šiandien yra žinoma kaip LeNet-5 [34]. Šiai architektūrai būdingi du konvoliucijos ir trys sutelkimo sluoksniai. AlexNet architektūra [31] prie LeNet-5 architektūros pridėjo kelis papildomus sluoksnius; jai būdingi 5 konvoliucijos ir 3 sutelkimo sluoksniai. VGG-16 architektūra [60] – tai patobulinta AlexNet. VGG-16 sudaro 13 konvoliucijos sluoksnių ir 3 sutelkimo sluoksniai. ResNet-50 [35] architektūrai būdingi net 152 sluoksniai.

Kaip jau minėta, CNN architektūrų yra labai daug. Ne visos jos aprašytos mokslinėje literatūroje (ypač recenzuojamoje), todėl gana sudėtinga išsiaiškinti visus jų privalumus ir trūkumus. Minėtina, kad tokių CNN architektūrų, kaip ResNet-50 ar Inception v1 (ir vėlesnių modifikacijų), nors ir naudojamų moksliniuose tyrimuose, ištakas galima atsekti tik *GitHub* kodo pakeitimų sekimo ir dalijimosi platformoje ir iš menkos dokumentacijos.

3.2.9 AdaBoost

Skirtingai nuo kitų aprašytų klasifikatorių, AdaBoost (angl. *Adaptive Boosting*) yra klasifikavimo metaalgoritmas. Jis tinka tik dvinarei klasifikacijai. Metaalgoritmo esmė – pasitelkti grupę prasčiau (bet ne mažesniu negu 50 proc. tikslumu) klasifikuojančių algoritmų (silpnų klasifikatorių) ir sudaryti klasifikatorių, pasižymintį geresnėmis klasifikavimo savybėmis (stiprų klasifikatorių).

Klasikiniame AdaBoost klasifikatoriuje imčiai sudaryti naudojami LDA klasifikatoriai, tačiau galima naudoti ir kitus.

Vykdamt algoritmą nauji silpnieji klasifikatoriai yra mokomi skirtingose algoritmo iteracijose atpažinti ankstesnėse iteracijose neteisingai suklasifikuotus duomenis. Šiems klasifikatoriams suteikiamas didesnis svoris kitoje iteracijoje, mokant naujus modelius. Pagrindinė mintis – vėlesni modeliai gali kompensuoti ankstesnių modelių padarytas klaidas.

3.2.10 Daugumos balsavimo klasifikatorius

Daugumos balsavimo klasifikatorius gali veikti tik kartu su vienu ar daugiau kitų klasifikavimo metodų.

Surenkami kitų klasifikatorių rezultatai. Kiekvienas klasifikavimo rezultatas laikomas vienu balsu už atitinkamą klasifikavimo rezultatą. Suskaičiavus balsus, klasifikuojamas objektas priskiriamas kategorijai, kuri surenka daugiausia balsų.

3.3 KLASIFIKATORIŲ TESTAVIMO METODIKA

3.3.1 Klasifikatorių kokybės metrikos

Klasifikavimo kokybės įvertinimas atrodo gana paprastas – įvertinti tikslumą (kiek EEG diagnozė klasifikuota tinkamai), tačiau iš tiesų tai gana sudėtinga. Disertacijos atveju įvertinti klasifikavimo kokybę dar sunkiau, nes turimi duomenys yra nesubalansuoti, t. y. I grupės duomenų yra gerokai daugiau negu II grupės.

3.3.1.1 TPR ir TNR

Minėtina, kad kai kurie klasifikatoriai pasiekia 75 proc. tikslumą, klasifikuodami visus testinės imties duomenis (pavyzdžiui, I grupės EEG) [42]. Tokių klasifikatorių tikslumas gana aukštas, tačiau dėl tam tikrų priežasčių jie nėra tinkami naudoti praktiškai (pavyzdžiui, šiame darbe). Disertacijoje pagrindinėmis laikytos dvi metrikos:

- **TPR** (angl. *True positive rate*) – teigiamai klasifikuotų teigiamų pavyzdžių dalis, absoliutusis šių pavyzdžių skaičius žymimas TP;

- **TNR** (angl. *True negative rate*) – neigiamai klasifikuotų neigiamų pavyzdžių dalis, absoliutusias šių pavyzdžių skaičius žymimas TN.

Taip pat galima apibrėžti dvi metrikas, priešingas minėtosioms:

- **FPR:** (angl. *False Positive Rate*) – teigiamai klasifikuotų neigiamų pavyzdžių dalis, absoliutusias šių pavyzdžių skaičius žymimas FP;
- **FNR:** (angl. *False Negative Rate*) – neigiamai klasifikuotų teigiamų pavyzdžių dalis, absoliutusias šių pavyzdžių skaičius žymimas FN.

Geras klasifikatorius turėtų pasižymėti kuo aukštesniais tiek TPR, tiek TNR. Tai reikštų, kad klasifikatorius gali tiksliai klasifikuoti tiek I, tiek ir II grupės EEG. Anksčiau minėtas klasifikatorius, klasifikuojantis viską kaip vieną grupę, pasižymėtų labai aukšta viena iš metriku, tačiau kitos metrikos reikšmė būtų lygi nuliui.

Kalbamosios metrikos leidžia gana tiksliai atskirti tikslus ir „sukčiaujančius“ klasifikatorius. Šios savybės ir lėmė metriku pasirinkimą disertacijoje.

3.3.1.2 Matthewso koreliacijos koeficientas

Matthewso koreliacijos koeficientas yra dvinario (dvi klases klasifikuojančio) klasifikatoriaus kokybės metrika, 1975 m. išvesta Briano W. Matthewso [38]. Ši metrika gerai tinka nesubalansuotoms duomenų imtims [9]. Metrika apibrėžiama taip:

$$MCC = \frac{(TP \cdot TN - FP \cdot FN)}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}. \quad (3.34)$$

3.3.1.3 Tikslumas ir svorinis tikslumas

Tikslumas yra lengviausiai suprantama klasifikatoriaus kokybės metrika: tai teisingai klasifikuotų pavyzdžių santykis su visais pavyzdžiais. Kaip jau minėta, aukšta šios metrikos vertė nereiškia geros klasifikavimo kokybės. Vis dėlto žema šios metrikos reikšmė (artima 0,5 arba mažesnė) reiškia prastą klasifikavimo kokybę. Tai padeda atpažinti žemos kokybės klasifikatorius.

Svorinis tikslumas apibrėžiamas kaip visų klasifikuojamų klasių teisingai klasifikuotų pavyzdžių dalių vidurkis. Disertacijoje skiriamos dvi klasės (I ir II grupės), tad svorinis tikslumas yra TPR ir TNR vidurkis. Kalbamoji metrika labiau tinka klasifikatorių kokybei vertinti esant nevienodam turimų klasių duomenų kiekiui.

3.3.1.4 *Recall* ir F_1 metrikos

Recall metrika yra teisingai teigiamai klasifikuotų pavyzdžių dalis, pada-lyta iš teisingai teigiamai ir neteisingai neigiamai klasifikuotų pavyzdžių dalies sumos. Ši metrika gana dažnai naudojama klasifikacijoms mokslinėje literatūroje, tačiau, atliekant pristatomą tyrimą, ji nebuvo itin informatyvi, nes neatsižvelgia į pavyzdžių kiekio skirtumus klasifikuojamose grupėse.

F_1 metrika apibrėžiama kaip tikslumo ir *recall* metrikų harmoninis vidurkis:

$$F_1 = \frac{2 \cdot \text{Tikslumas} \cdot \text{Recall}}{\text{Tikslumas} + \text{Recall}}. \quad (3.35)$$

3.3.1.5 ROC AUC

ROC kreivė (angl. *Receiver Operating Characteristic Curve*) yra klasifikatoriaus diagnostinių galimybių iliustracija, vaizduojanti TPR priklaus-

somybę nuo FPR. ROC AUC (angl. *Area Under Curve*) yra plotas po ROC kreive, sunormuotas į visą grafiko plotą.

3.3.1.6 Cohen κ

Cohen κ yra dar viena klasifikatorių vertinimo metrika, atsižvelgianti tiek į duomenų kiekio skirtumus klasėse, tiek į tikimybę klasifikatoriui atspėti klasifikuojamo duomens klasę. Ši metrika kritikuojama dėl rezultatų inter-pretavimo sudėtingumo [23]. Vis dėlto ji gali būti naudinga šiame darbe, ją nagrinėjant kitų metrikų kontekste.

3.3.2 k -fold kryžminė patikra

k -fold kryžminė patikra disertacijoje yra ypač svarbus mašinių mokymosi algoritmų klasifikavimo kokybės analizės įrankis. Dirbant su mašinių mokymosi algoritmais, gana dažnai susiduriama su problema, kai, ne daug pakeitus mokymosi imtį, reikšmingai pasikeičia algoritmo klasifikavimo kokybė, todėl tampa sudėtinga rezultatus apibendrinti. Vienas efektyviausių būdų šiems pokyčiams nustatyti yra k -fold analizė.

Šiame darbe k -fold analizė buvo atliekama atsižvelgiant į turimus pacientus. Pirmoje algoritmo iteracijoje išrinkti visi turimi pirmojo paciento EEG duomenys, jie naudoti klasifikatoriui testuoti. Kitų pacientų duomenys naudoti kaip mokymosi ir validavimo⁴ imtis. Antroje iteracijoje išskiriamas antrasis pacientas ir atliekama ta pati operacija. Kartojama tiek kartų, kiek turima pacientų EEG duomenų imtyje.

Metodikos privalumas – klasifikatoriaus kokybė įvertinama daug kartų, todėl galima vertinti klasifikatorių stabilumą. Tai ypač svarbu, norint

⁴Validavimo imtis yra mokymosi imties dalis. Ji naudojama mokomam modeliui vertinti. Kadangi į validavimo imtyje esančius duomenis iš dalies atsižvelgiama mokymo metu, jie nenaudojami testavimo imtyje.

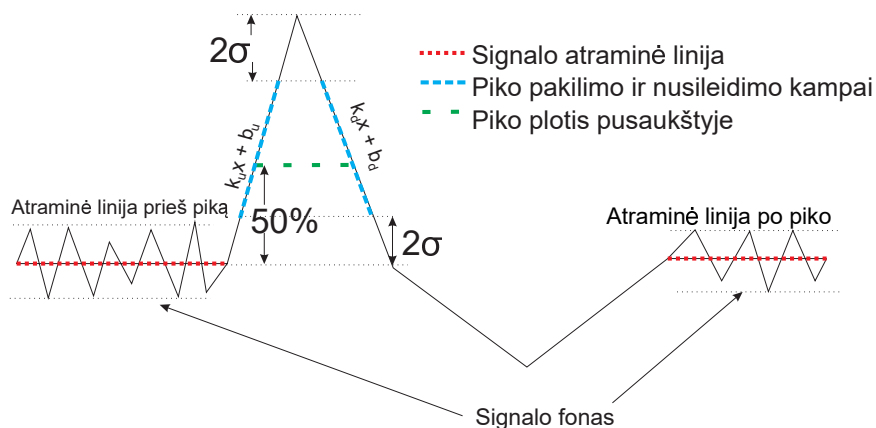
atpažinti „spėliojančius“ klasifikatorius, kurie, susiklosčius tinkamoms aplinkybėms, gali atspėti testavimo imties diagnozes. *k-fold* analizės metu gaunamas gana stabilus rezultatas, o tai rodo, kad šis rezultatas, veikiausiai, yra tikras.

3.4 EEG KLASIFIKAVIMO ALGORITMAS, NAUDOJANTIS GEOMETRINIUS PIKŲ PARAMETRUS

Šiame poskyryje aptarsime rekomenduotiną EEG klasifikavimo pagal diagnozę algoritmo versiją, naudojančią EEG pikų geometrines charakteristikas.

3.4.1 EEG piko geometrinių charakteristikų nustatymas

Siekiant įvertinti pagrindines EEG piko metrikas, skaičiuojami keli tarpiniai parametrai. Disertacijoje nagrinėjami tokie parametrai, kaip piko pakilimo ir nusileidimo greičiai ir plotis pusaukštyje (apibrėšime juos vėliau). Norint apibrėžti piko pakilimo ir nusileidimo greičius, reikia signalo atraminės linijos, kuri naudojama piko maksimumui ir pusei šio maksimumo apskaičiuoti. Atraminė linija apskaičiuojama vidurkinant signalo vertes prieš piką ir po jo, imant trukmę, kuri lygi apie 50 proc. viso EEG piko trukmės, tiek esant 5 proc. laiko prieš piką, tiek 20 proc. laiko po piko, prieš piką ir po jo paliekant tarpus, siekiant, kad pikas neturėtų įtakos signalo pamatinei vertei nustatyti. Signalo atraminė linija nėra algoritmo išvesties parametras, bet figūruoja apskaičiuojant kitas metrikas. Minėti laiko tarpai, kaip duodantys geriausių rezultatų, parenkami eksperimentiškai. Atkreiptinas dėmesys, kad per trumpi periodai lemia didelį triukšmą rezultatuose, o per ilgi periodai turi didelę



3.8 pav. EEG piko ir jo parametrų schematinis vaizdavimas (k_u – piko pakilimo koeficientas, k_d – piko nusileidimo koeficientas)

riziką būti paveikti kitų greta esančių pikų, artefaktų ar natūraliai smegenyse pasitaikančių lėtų bangų. EEG pikas turi būti aptinkamas ir bent viename gretimame kanale. Dažniausiai jis stebimas iš karto keliuose gretimuose kanaluose.

Disertacijoje nagrinėjamas tik tas kanalas, kuriame pikai yra stipriausi. Algoritmas automatiškai parenka analizei kanalą, kuriame randama daugiausia pikų, nes kanaluose, kuriuose pikai silpnesni, algoritmas dalies šių pikų nepastebi. Piko maksimumas yra didžiausia arba mažiausia vertė ($-0,05/+0,05$) sekundės intervale nuo detektuoto piko (pikai gali būti tiek teigiami, tiek neigiami). Pasirinktą intervalą lemia tai, kad piko greita banga gali būti iki 0,1 s trukmės. Minėti parametrai naudojami piko pločiui pusaukštyje apskaičiuoti. Pikų charakteristikos vaizduojamos 3.8 pav.

Plotis pusaukštyje pasirenkamas dėl kelių priežasčių. Pirmiausia, piko pločio matavimas ties atramine linija yra netikslus: neįmanoma tiksliai nustatyti, kur prasideda ir baigiasi pikas, nes piko pradžia yra susiliejęsi su matavimo aparatūros triukšmu ir normalia fonine smegenų veikla.

Antra, tai standartinė kitų sričių praktika, kur dirbama su triukšmingais signalais, pavyzdžiui, spektroskopijoje [50, 53]. Plotis pusaukštyje teikia tą pačią informaciją kaip ir piko plotis, bet yra mažiau paveiktas įvairaus triukšmo.

Vėliau apskaičiuojami piko pakilimo ir nusileidimo koeficientai k_u ir k_d . Jie skaičiuojami atitinkamas piko dalis aproksimuojant tiesėmis mažiausių kvadratų metodu, atitinkamai prieš didžiausią piko reikšmę ir po jos. Tiesė aproksimuojama neimant 20 proc. iki didžiausios vertės ir tiek pat paliekant iki žemiausio piko taško.

Toliau atliekama EEG pikų validacija pagal pikų parametrus (žr. 2.1.6 poskyrį).

3.4.2 Mašinių mokymusi pagrįstų klasifikatorių taikymas klasifikuojant EEG pagal EEG pikų geometrinius parametrus

Aptikus EEG pikus ir nustačius jų geometrinius parametrus, kitas algoritmo žingsnis – nustatyti diagnozę. Norint rasti tinkamiausią algoritmą, reikia išsiaiškinti:

- kurie EEG piko geometriniai parametrai yra reikšmingiausi,
- kiek EEG pikų reikia diagnozei nustatyti,
- kuris klasifikatorius tiksliausiai geba atpažinti diagnozę.

3.4.2.1 EEG pikų geometrinių parametų perdavimo būdo pasirinkimas

EEG pikų geometrinių parametų perdavimo strategija pasirenkama atsižvelgiant į kelis esminius veiksnius. Visų pirma, ji turėtų tikti kuo

3.1 lentelė. EEG pikų geometrinių parametų perdavimo strategija (p indeksas žymi piko eilės numerį, f indeksas – parametro eilės numerį, N_{Pikai} – pikų skaičių, perduodamą klasifikatoriui)

Įvesties parametras	1	2	...	M	$M + 1$...	MN_{Pikai}
Duomuo	p_1f_1	p_1f_2	...	p_1f_M	p_2f_1	...	$p_{N_{Pikai}}f_M$

didesniam mašinų mokymusi pagrįstų metodologijų skaičiui. Antra, EEG pikas gali turėti ne vieną reikšminį parametą, pagal kurį gali būti klasifikuojamas. Trečia, tikėtina diagnozė greičiausiai negali būti nustatyta iš vieno EEG piko.

Atsižvelgiant į tai, kad beveik visos mašinų mokymusi pagrįstos klasifikavimo metodologijos reikalauja vienodo ilgio įvesties, pasiūlyta pikų ir jų parametų sudėjimo paeiliui strategija (žr. 3.1. lentelę). Strategijos pasirinkimą lėmė tai, kad, nustačius tinkamiausią EEG pikų skaičių ir tinkamiausius jų parametrus, įvesties ilgis mašinų mokymusi pagrįstiems klasifikatoriams visada bus fiksuotas.

Tolesni eksperimentai su geometriniais EEG pikų parametrais buvo atliekami taikant minėtą strategiją.

3.4.2.2 Netinkamų klasifikatorių pašalinimas iš tolesnės analizės

Atlikus eksperimentus su 3.2 skyriuje aprašytais klasifikavimo metodais, paaiškėjo, kad kai kurie iš jų akivaizdžiai netinka EEG klasifikuoti. LDA buvo atmesta dėl mažo klasifikavimo tikslumo (53 %). SVM, turinčios tiesinį ir kvadratinį branduolius, rezultatai buvo visapusiškai blogesni, palyginti su SVM, turinčios kubinį branduolį, rezultatais (dėl šios priežasties toliau analizei taikyta tik SVM su kubiniu branduoliu). SVM su RBF branduoliu visas įvestis klasifikavo kaip I grupę, todėl šio klasifikatoriaus taip pat atsisakyta.

3.2 lentelė. EEG klasifikavimo tikslumas, naudojant EEG pikų geometrinis parametrus ($N_p = 3$ reiškia kubinį SVM branduolį)

Vertė / Algoritmas	Atsitiktinis miškas	Sprendimų medis	Labai atsitiktinis medis	AdaBoost	MLP	SVM $N_p = 3$	Idealus klasifikatorius
Tikslumas	0,78	0,76	0,80	0,81	0,75	0,69	1,00
TPR	0,79	0,76	0,83	0,90	0,79	0,79	1,00
TNR	0,74	0,77	0,71	0,52	0,74	0,48	1,00
F_1	0,76	0,76	0,75	0,64	0,78	0,57	1,00
ROC AUC	0,53	0,49	0,56	0,69	0,64	0,49	1,00
Cohen κ	0,06	-0,01	0,12	0,38	0,28	0,26	1,00
Matthewso koreliacijos koeficientas	0,07	-0,01	0,15	0,42	0,38	0,28	1,00
Recall	0,78	0,76	0,81	0,84	0,78	0,69	1,00

3.4.2.3 Klasifikavimo pagal EEG pikų geometrinius parametrus rezultatai

Klasifikatorių, kurie nebuvo atmesti (žr. 3.4.2.2 poskyrį), rezultatai pateikiami 3.2 lentelėje.

Geriausiai veikiantis algoritmas pagal tikslumą yra AdaBoost, tačiau jo TPR (II grupei aptikti) yra žemas. Dėl šios priežasties AdaBoost negali būti naudojamas EEG pikams klasifikuoti pagal diagnozę, remiantis EEG pikų geometrinių parametru duomenimis. Dėl minėtos priežasties netinka ir SVM su kubiniu branduoliu.

Atlikus tyrimą, nustatyti klasifikavimo algoritmai, potencialiai tinkami EEG pagal diagnozę klasifikuoti: MLP, atsitiktinis miškas, sprendimų medis ir labai atsitiktinis medis. Tolesnei analizei pasirinktas MLP (gerai geba atpažinti II grupės pacientus, būdingos aukštesnės Cohen κ koeficiento reikšmės). Cohen κ koeficiento reikšmė parodė, kad atsitiktinio miško, sprendimų medžio ir labai atsitiktinio medžio rezultatai yra panašūs į spėliojimą. Kaip jau buvo minėta, I ir II grupių EEG ir pacientų skaičius nevienodas, todėl algoritmas gali priimti spėliojimo strategiją.

Dėl nurodytų priežasčių tolesni eksperimentai klasifikuojant EEG pagal

3.3 lentelė. Tinkamiausia klasifikatoriams EEG pikų parametų perdavimo strategija (k_u ir k_d – EEG piko pakilimo ir nusileidimo koeficientai (žr. 3.8 pav.), N_{Pikai} – pateikiamų EEG pikų skaičius)

Ivesties parametras	1	2	3	4	...	$2N_{Pikai} - 1$	$2N_{Pikai}$
Duomuo	k_{u1}	k_{d1}	k_{u2}	k_{d2}	...	$k_{uN_{Pikai}}$	$k_{dN_{Pikai}}$

pikų parametrus atliekami taikant MLP klasifikatorių.


3.4.2.4 Tinkamiausio EEG pikų skaičiaus ir parametų parinkimas

EEG pikų skaičius ir svarbiausių EEG pikų geometrinių parametų nustatymas yra du atskiri uždaviniai, tačiau jie negali būti visiškai atskirti vienas nuo kito. Turint netinkamą EEG pikų skaičių ar netinkamus jų parametrus, mašinių mokymosi metodais diagnozė negali būti tinkamai nustatyta.

Pirminiai eksperimentai buvo atliekami naudojant visus turimus EEG pikų parametrus (žr. 3.4.1 poskyrį). Eksperimentais nustatyta, kad tinkamiausias EEG pikų skaičius yra apie 100 EEG pikų (žinant, kad kiekvienas pikas turi du parametrus (k_u ir k_d), klasifikatoriui perduodama 200 parametų): imant mažiau verčių, tikslumas mažėja, imant daugiau verčių, klasifikavimo tikslumas neauga.

Atsižvelgiant į gautą informaciją, atliktas eksperimentas, skirtas nustatyti klasifikavimui tinkamiausius EEG pikų parametrus. EEG pagal jų pikų duomenis klasifikuoti eksperimentiškai, kaskart išmetant po vieną EEG piko parametą. Eksperimentų metu nustatyta, kad didžiausių testinių klasifikatorių tikslumą lemia EEG piko pakilimo ir nusileidimo koeficientai ir naudojama strategija (žr. 3.3 lentelę).

Radus tinkamiausius klasifikuoti EEG pikų parametrus, pereita prie optimalaus EEG pikų skaičiaus nustatymo. 3.9 pav. vaizduojama klasifi-



3.9 pav. EEG klasifikavimo tikslumo priklausomybė nuo EEG pikų skaičiaus, naudojant MLP pagrįstą klasifikatorių

kavimo tikslumo priklausomybė nuo EEG pikų skaičiaus ir pasirinktų parametrų. Minėtina, kad, naudojant k_u ir k_d , klasifikavimo tikslumas auga greičiausiai.

Tikslumas (angl. *accuracy*) apibrėžiamas kaip teisingai teigiamai klasifikuotų pavyzdžių santykis su visais pavyzdžiais.

Tolesni eksperimentai buvo atliekami naudojant 100 EEG pikų k_u ir k_d parametrus.

3.4.2.5 Klasifikavimo tikslumo ribos nustatymas

Išnagrinėjus 3.9 pav., galima daryti išvadą, kad kuo daugiau EEG pikų turima, tuo tiksliau gali būti automatiškai nustatoma EEG diagnozė. Teoriškai būtų idealu turėti begalinį pacientų ir pikų skaičių, tačiau realybėje šie skaičiai yra riboti. Tikslumo priklausomybė nuo EEG pikų skaičiaus aproksimuota tokia analitine funkcija:

$$A(N_{Pikai}) = \frac{1}{\frac{C_1}{N_{Pikai} + C_2} + C_3}, \quad (3.36)$$

čia A – klasifikavimo tikslumas, N_{Pikai} – EEG pikų skaičius.

(3.36) formulė parinkta pagal šį kriterijų: atliekant eksperimentus, buvo stebimas tikslumo įsisotinimas didėjant pikų skaičiui, todėl rinktasi iš funkcijų, artėjančių prie asimptotinės vertės (naudotasi *Origin 2018* programų paketu). Pasirinkta funkcija, kuria duomenis aproksimavus mažiausių kvadratų metodu, buvo gaunama mažiausia nuokrypių kvadratų suma.

Radus (3.36) lygties parametrus mažiausių kvadratų metodu pagal tikslumo priklausomybę nuo EEG pikų skaičiaus, gautos tokios reikšmės: $C_1 \approx 0,065$, $C_2 \approx 16,51$ ir $C_3 \approx 0,012726$. Taigi vidutinis tikslumas, turint 100 EEG pikų ($N_{pikai} = 100$) sąrašą, yra:

$$A(100) \approx 75,3 \%. \quad (3.37)$$

Kai turimų EEG pikų skaičius artėja į begalybę $N_{pikai} \rightarrow \infty$ (darant prielaidą, kad EEG pikų parametru sąrašų ilgis auga), aproksimuotoji $A(N_{pikai})$ funkcija artėja prie asimptotinės reikšmės:

$$A(N_{Pikai}) \rightarrow \frac{1}{C_3} \approx 78,6 \%. \quad (3.38)$$

3.4 lentelė. Išbandytos MLP architektūros (atsižvelgiant į tai, kad įvesties ir išvesties sluoksnių dydis apribotas turimų duomenų, buvo keičiamas paslėpto sluoksnio dydis)

Paslėpto sluoksnio dydis	5	10	15	20	25	...	100
TPR	0,61	0,76	0,79	0,79	0,74	...	0,59
TNR	0,59	0,71	0,72	0,74	0,70	...	0,54

3.4.2.6 MLP architektūros optimizavimas


Atsižvelgiant į tai, kad MLP klasifikatorius gali turėti skirtingą neuronų ir jų sluoksnių skaičių, MLP architektūra optimizuota kuo aukštesniam tikslumui (ir kitoms charakteristikoms) pasiekti.

Išbandyta įvairių MLP architektūrų (žr. 3.4 lentelę). Eksperimentais nustatyta, kad geriausia MLP architektūra (kuria gauti aprašyti rezultatai) yra 1 paslėptas sluoksnis su 20 neuronų. Įvesties sluoksnio neuronų skaičių diktuoja įvesties duomenų skaičius (šiuo atveju – 200), išvesties – išvesties klasių skaičius (šiuo atveju – 1 neuronas).

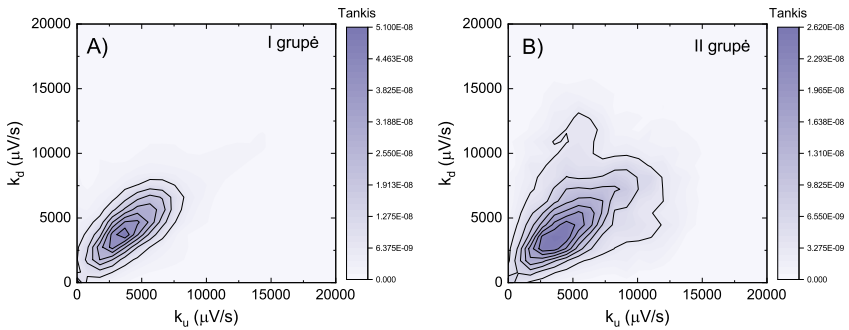
3.4.3 EEG pikų geometrinių charakteristikų analizė

Žinant EEG klasifikavimo pagal diagnozę, naudojant EEG pikų geometrinius parametrus, rezultatus, kyla klausimas, kokios šių parametrų savybės lemia galimybę klasifikuoti EEG pagal diagnozę. Minėtos savybės atskleidžiamos 3.10 ir 3.11 pav.

Kaip matyti 3.11 pav., k_u ir k_d parametrų erdvės persidengia, tačiau II grupės parametrai pasklidę plačiau negu I grupės. Tikėtina, kad mašinų mokymusi pagrįsti EEG klasifikatoriai atsiremia būtent į šį klasifikuojamų EEG skirtumą.



3.10 pav. k_u ir k_d verčių pasiskirstymo histograma (A – I grupės k_u , B – II grupės k_u , C – I grupės k_d , D – II grupės k_d)



3.11 pav. Kontūrinė I ir II grupių k_u ir k_d pasiskirstymo diagrama (A – I grupės, B – II grupės; kaip matyti, rezultatų intervalai persidengia, tačiau II grupės vertės pasklidusios plačiau (kaip ir 3.10 pav.))

3.5 EEG KLASIFIKAVIMAS, NAUDOJANT SIGNALŲ ATKARPAS

Šiame skyriuje pristatomas antras rekomenduotinas klasifikavimo algoritmo variantas – EEG klasifikavimas pagal signalų atkarpas.


3.5.1 Duomenų perdavimo strategijos pasirinkimas

Išnagrinėjus klasifikavimo galimybes, pasinaudojant EG piko geometriniais parametrais, pradėtos nagrinėti kitos EEG piko duomenų perdavimo galimybės [43]. Pagrindinė geometrinių EEG piko parametrų gavimo problema – esama atveju, kai šie parametrai nustatomi neteisingai. Be to, nėra žinoma, ar nėra kitų, klasifikuoti tinkamesnių EEG piko parametrų. Minėtas galimas problemas iš esmės išsprendžia EEG signalo fragmento naudojimas piko aplinkose. Nebelieka ir problemų dėl galimai klaidingų ar neinformatyvių EEG piko parametrų nustatymo, nes šis žingsnis praleidžiamas.

Kitas svarbus klausimas, kokios trukmės EEG signalo atkarpa reikalinga tinkamai klasifikuoti EEG pagal diagnozę. I ir II grupių EEG pasižymi gerybinėmis epileptoforminėmis iškrovomis [14, 55, 64], kurių trukmė yra ne didesnė negu 200 ms. Nėra žinoma, pagal kurią EEG piko vietą išmoks klasifikuoti mašinių mokymosi algoritmai, todėl pasirinktas 300 ms intervalas (po 150 ms į abi puses nuo detektuotos EEG piko vietos). Atsižvelgiant į tai, kad visos turimos EEG buvo įrašytos 256 Hz diskretizacijos dažniu,

$$N_{elementai} = 256 \text{ Hz} \cdot 0,3 \text{ s} = 76,8 \approx 77. \quad (3.39)$$

Taigi nesudėtingas skaičiavimas atskleidžia, jog, naudojant 77 EEG piko signalo elementus, imamas visas EEG signalo ruožas, kuriame yra EEG



3.12 pav. EEG klasifikavimas pagal diagnozę, naudojant EEG signalo, kuriame aptiktas EEG pikas, duomenis

pikas. Turėdami vienodą EEG pikų ilgį ir skaičių, turėsime ir visada vienodo ilgio įvestį mašinų mokymusi pagrįstiems klasifikatoriams. Įvestis klasifikatoriams gaunama paeiliui sudedant EEG signalų iškarpas kanale, kuriame aptiktas EEG pikas (žr. 3.12 pav.).

3.5.2 EEG klasifikatorių tyrimas, naudojant EEG signalo atkarpas

Tie patys klasifikatoriai, kuriuos jau aptarėme vertindami jų tinkamumą EEG pikams klasifikuoti pagal geometrinius parametrus, tirti ir naudojant *k-fold* kryžminę patikrą (žr. 3.5 lentelę).

Rezultatai skiriasi nuo anksčiau gautųjų. MLP rezultatai (net ir atlikus architektūros optimizaciją) EEG pikams klasifikuoti minėtu būdu yra prasti. SVM rezultatai panašūs į gautuosius atlikus eksperimentą su EEG pikų geometriniais parametrais.

Kaip potencialiai geriausi klasifikatoriai išryškėjo sprendimų medžio, atsitiktinio miško ir labai atsitiktinio medžio klasifikatoriai. Tinkamiausias klasifikatorius – labai atsitiktinis medis (tiek dėl aukšto TPR, tiek dėl TNR). Atlikus eksperimentą su įprasta duomenų imtimi, labai atsitiktinio medžio klasifikatoriaus tikslumas – 82 proc.

3.5 lentelė. EEG klasifikavimo tikslumas, naudojant EEG signalų atkar-
pas kanale, kuriame aptiktas EEG pikas, tiriant k -fold kryžmine patikra
($N_p = 3$ reiškia kubinį SVM branduolį, SD – standartinį nuokrypį (angl.
standard deviation) tarp k -fold testų)

Algoritmas \ Metrika	TPR	SD	TNR	SD
Logistinė regresija	0,636	0,001	0,599	0,008
Atsitiktinis miškas	0,851	0,05	0,768	0,016
Sprendimų medis	0,906	0,008	0,683	0,011
Labai atsitiktinis medis	0,915	0,003	0,805	0,017
AdaBoost	0,765	0,031	0,781	0,053
LDA	0,949	0,001	0,467	0,002
MLP	0,601	0,029	0,58	0,04
SVM $N_p = 3$	0,879	0,02	0,124	0,019
SVM su RBF branduoliu	0,783	0,058	0,264	0,041
SVM su sigmoidiniu branduoliu	0,579	0,063	0,511	0,042

3.6 EEG KLASIFIKAVIMAS, NAUDOJANT VISŲ EEG KANALŲ DUOMENIS

Dar vienas rekomenduotinas EEG klasifikavimo pagal diagnozę algorit-
mo variantas naudoja visų 21 EEG kanalo (tarptautinėje 10–20 EEG
sistemoje) duomenis EEG piko aplinkoje. Konvoliuciniai neuroniniai
tinklai (CNN) mokslinėje literatūroje yra pripažinti vienais geriausių
vaizdų klasifikatorių [16, 31, 37, 71]. CNN pradedami plačiai taikyti ir
signalams klasifikuoti [29, 49]. Daug sėkmingų CNN taikymo pavyzdžių
yra ir medicinoje [7, 33], įskaitant medicininių signalų analizę [4, 5].
Atsižvelgus į mokslinės literatūros šaltinių, patvirtinančių puikius CNN
rezultatus, gausą, EEG klasifikavimo pagal diagnozę algoritmo variantą,
pagrįstą CNN, nuspręsta ištirti ir disertacijoje.

3.6 lentelė. CNN standartinių architektūrų veikimo palyginimas

Imtis Architektūra \ Metrika	Mokymosi		Testavimo	
	TPR	TNR	TPR	TNR
LeNet-5	0,88	0,87	0,51	0,52
AlexNet	0,90	0,88	0,53	0,50
VGG-16	0,91	0,89	0,55	0,54
ResNet-50	0,99	0,99	0,51	0,50

3.6.1 EEG duomenų perdavimo CNN klasifikatoriui strategija

Geriausiai ištirtas CNN taikymas vaizdams klasifikuoti [6, 58]. Be to, naudojant įvairius metodus (pavyzdžiui, verčiant į spektrogramas), signalai konvertuojami į vaizdus ar kitas matricas [29]. Gydytojai, nagrinėdami pacientų EEG pikus, taip pat atsižvelgia į kelių EEG kanalų informaciją [55, 57]. Atsižvelgus į minėtas aplinkybes, buvo nuspręsta naudoti ne tik kanalo, kuriame aptiktas EEG pikas (plg. 3.4 skyrių), bet visų 21 EEG kanalo duomenis.

Kaip nustatyta 3.5.1 poskyryje, tinkamiausias EEG atkarpos ilgis yra apie 300 ms arba 77 elementai aptikto EEG piko aplinkoje. Dėl šios priežasties kiekvienam klasifikuojamam EEG pikui sukonstruota ir CNN klasifikatoriui perduota 21x77 dydžio matrica (21 EEG kanalas po 77 elementus) (žr. 3.13 pav.).

3.6.2 CNN architektūros pasirinkimas

Tiek mokslinėje literatūroje, tiek kituose šaltiniuose skelbiama daug informacijos apie įvairias CNN architektūras. Daugelis šių architektūrų skirtos įvairiems vaizdams klasifikuoti [31, 34, 60]. Disertacijoje nagrinėjama problema – EEG klasifikavimas pagal diagnozes – gana unikali, CNN architektūra šiai problemai optimizuoti nėra tirta.

Darbe išbandyta keletas žinomų CNN architektūrų, sėkmingai naudotų kitoms klasifikavimo užduotims atlikti. Pirmiausia parengta kelių standartinių CNN architektūrų veikimo lyginamoji analizė (žr. 3.6 lentelę). Lyginant CNN architektūras, pastebėta, kad paprastos CNN architektūros (LeNet-5 ir AlexNet) yra linkusios nesimokyti (tiek mokymosi, tiek testavimo tikslumas gana žemas), o sudėtingos architektūros (kaip ResNet-50) yra linkusios persimokyti (didelis mokymosi, tačiau žemas testavimo tikslumas) (žr. 3.6 lentelę). Atsižvelgus į šiuos duomenis, nustatyta, kad geriausiomis pradinėmis savybėmis (TPR ir TNR) pasižymi VGG-16 architektūra.


Nustačius tinkamiausią pradinę architektūrą, išbandytos įvairios jos modifikacijos. Modifikacija atlikta rankiniu būdu maksimizuojant testavimo TPR, TNR ir tikslumą. Pasirinktos CNN architektūros duomenys pateikiami 3.7 lentelėje.

3.7 lentelė. CNN architektūra

Sluoksnis	Aprašymas	Išvesties forma
Įvestis	–	21, 77
2D konvoliucija	16 7x7 branduolių	15, 71, 16
2D maks. sutelkimas	2x2 santalkos dydis	14, 70, 16
2D konvoliucija	32 5x5 branduoliai	10, 66, 32
2D konvoliucija	64 3x3 branduoliai	7, 63, 64
Išlyginimas	–	5 952
Visiškai sujungta	1 024 neuronai, tanh akt. f-ja	1 024
Išvestis	1 neuronas, sigmoidinė akt. f-ja	1

3.6.3 Vieno piko klasifikavimas, naudojant CNN

Kiekvienas pikas suklasifikuotas pagal EEG diagnozę. Pirminiai rezultatai parodė maždaug 58 proc. tikslumą (daugiau rezultatų žr. 3.8 ir 3.9 lentelėse). Kaip matyti iš gautų rezultatų, CNN klasifikatorius pagal vieną EEG piką nėra pakankamas. Rezultatas nestebina, nes gydytojais



3.13 pav. CNN klasifikatoriui perduodamos matricos pavyzdys (raudona linija žymi apytikslį EEG piko centrą)

3.8 lentelė. Vieno piko EEG klasifikatoriaus, pagrįsto CNN, klasifikavimo matrica (angl. *Confusion Matrix*) *k*-fold analizei

	I grupė	II grupė
I grupė	20 872 (TPR = 0,59)	14 806 (FPR = 0,41)
II grupė	6 871 (FNR = 0,43)	9 123 (TNR = 0,57)

neurologai, nustatydami diagnozę, įprastai remiasi daugiau negu vienu EEG piku [55, 57]. CNN mokymosi metu parinkti svoriai vizualizuoti disertacijos prieduose.

3.6.4 Daugumos balsavimo klasifikatorius su CNN

Kaip matyti iš 3.6.3 poskyrio, vieno EEG piko nepakanka tiksliai diagnozei nustatyti. Problemą būtų galima spręsti analogiškai, kaip siūlyta

3.9 lentelė. CNN metrikos vieno piko ir balsavimo EEG klasifikatoriui

Parametras	CNN klasifikatorius	Balsavimo klasifikatorius
Tikslumas	0,580	0,802
Svorinis tikslumas	0,572	0,795
F_1	0,256	0,856
ROC AUC	0,579	0,916
Matthewso koreliacijos koeficientas	0,144	0,550

3.10 lentelė. Klasifikavimo matrica balsavimo klasifikatoriui

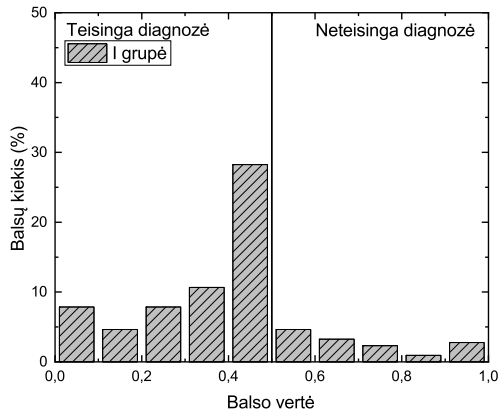
	I grupė	II grupė
I grupė	128 (TPR = 0,81)	30 (FPR = 0,19)
II grupė	13 (FNR = 0,22)	46 (TNR = 0,78)

3.4 ir 3.5 skyriuose. Vis dėlto šio sprendimo būdo atsisakyta dėl kelių priežasčių:

1. Mažinant EEG pikų detekcijos algoritmo specifiškumą (įtraukiant daugiau neteisingai teigiamai aptiktų pikų), klasifikavimo tikslumas mažėja. Tai leidžia daryti prielaidą, kad atsisakyti EEG pikų aptikimo proceso, veikiausiai, nepavyks.
2. EEG klasifikavimo tikslumas siekia 58 proc. (žr. 3.6.3 poskyrį); tai yra geriau negu atsitiktinis spėjimas.
3. Rekomenduoti algoritmo variantai (žr. 3.4 ir 3.5 skyrius) yra pritaikyti fiksuotam EEG pikų skaičiui (šis skaičius gali būti pakeistas, tačiau tai reikalautų visiško klasifikatoriaus mokymo iš naujo; be to, visos EEG privalo turėti vienodą pikų skaičių).

Dėl nurodytų priežasčių rekomenduotinas daugumos balsavimo klasifikatorius (žr. 3.2.10 poskyrį). Jo privalumai:

1. Gali būti klasifikuojamos neapibrėžtą EEG pikų kiekį turinčios EEG; CNN klasifikatoriaus nereikia mokyti iš naujo.




3.14 pav. I grupės balsavimo rezultatai

- Didėjant EEG pikų skaičiui, klasifikavimo tikslumas taip pat didėja (atmetus EEG, turinčias iki 100 pikų, klasifikavimo tikslumas padidėja 2 proc.).

I ir II grupių pacientų EEG balsavimo rezultatai pavaizduoti 3.14 ir 3.15 pav. Visi turimi EEG pikai klasifikuoti CNN klasifikatoriumi, vėliau skaičiuotas vidutinis balsas.

Taikant daugumos balsavimo klasifikatorių, CNN klasifikatoriaus tikslumas, testavimo imtyje naudojant neišvalytus duomenis, siekė iki 80 proc. (rezultatas panašus į pateiktąjį 3.5 skyriuje). Vis dėlto šis rekomenduotinas algoritmo variantas laikytinas geriausiu dėl anksčiau minėtų jo privalumų, konkrečiau – dėl galimybės klasifikuoti EEG, turinčią nepibrėžtą pikų kiekį, CNN klasifikatoriaus nemokant iš naujo. Atmetus EEG, turinčias mažiau negu 100 pikų (taip buvo daroma tiriant kitus klasifikavimo algoritmo variantus), tikslumas padidėja iki 82 proc., o tai sutampa su labai atsitiktinio medžio rezultatu, klasifikuojant EEG signalo atkarpas. Atsižvelgiant į tai, kad šie rezultatai buvo patvirtinti



3.15 pav. II grupės balsavimo rezultatai

naudojant *k-fold* kryžminę patikrą, panašaus tikslumo galima tikėtis ir naudojant kalbamąjį algoritimą praktikoje.

Dėl nurodytų priežasčių aptartasis algoritmo variantas – daugumos balsavimo klasifikatorius su CNN – yra rekomenduojamas naudoti kaip geriausias.

3.6.5 Gautų algoritmų pritaikomumas praktikoje

Atsižvelgiant į tai, kad pasiektas klasifikavimo pagal diagnozę tikslumas nėra šimtaprocentinis (siekia 82 proc.), ekspertinėje diagnostinėje sistemoje galėtų būti naudojami tiek taikomo algoritmo, tiek gydytojo gauti rezultatai [32]. EEG gali būti klasifikuojama atskirai gydytojo ir klasifikavimo algoritmo, o klasifikatoriaus ir gydytojo klasifikacijoms nesutapus, galėtų būti prašoma antro gydytojo nuomonės.

Disertacijoje pateikiami rezultatai patikrinti taikant *k-fold* kryžminę patikrą, naudojant visus turimus (iššalytus ir neiššalytus) EEG duomenis.

Tai leidžia daryti prielaidą, kad analogiško tikslumo (ir kitų kokybinių metrikų) bus pasiekta ir taikant algoritmą praktikoje. Būtina sąlyga – turi būti naudojamos bent 100 pikų turinčios EEG.

IŠVADOS


1. EEG gali būti klasifikuojamos taikant klasifikavimo pagal diagnozę (I ir II grupių) algoritmą, naudojantį geometrinius pikų parametrus 75 proc. tikslumu (su EEG, turinčiomis 100 pikų). Šiam tikslui pasiekti tinkamiausias MLP klasifikatorius.
2. EEG gali būti klasifikuojamos pagal diagnozę (I ir II grupių) su labai atsitiktinio medžio metodu pagrįstu EEG klasifikatoriumi, klasifikuojančiu pagal EEG signalų atkarpas, naudojančiu kanalo, kuriame aptiktas pikas, duomenis 82 proc. tikslumu (su EEG, turinčiomis 100 pikų).
3. EEG gali būti klasifikuojamos pagal diagnozę (I ir II grupių) su CNN ir daugumos balsavimo klasifikatoriumi, naudojančiu visų EEG kanalų duomenis 80 proc. tikslumu arba 82 proc. tikslumu, jeigu klasifikuojamos EEG, turinčios bent 100 pikų. Šis algoritmas laikytinas geriausiu iš pasiūlytų dėl turimų pranašumų: 1) gali klasifikuoti EEG, turinčias neapibrėžtą pikų kiekį (skirtingai nuo kitų algoritmų, kurie buvo testuojami su EEG, turinčiomis po 100 pikų), nereikia iš naujo mokyti klasifikatorių, 2) nagrinėjant EEG, turinčias 100 ar daugiau pikų, pasiekia ne blogesnę tikslumą negu kiti pasiūlyti algoritmai.
4. Visi rekomenduotini EEG klasifikavimo pagal diagnozę algoritmo variantai yra jautrūs EEG pikų skaičiui, todėl, siekiant kuo tikslesnio EEG klasifikavimo pagal diagnozę rezultato, esant galimybei, reikėtų naudoti EEG, turinčias kuo daugiau pikų.

Darbe pristatyti algoritmai gali būti tobulinami. EEG pikų detekcijos jautrumo ir specifiškumo gerinimas, tikėtina, didintų EEG klasifikavimo pagal diagnozę tikslumą.


Pasiūlytus klasifikavimo pagal diagnozę algoritmus galima būtų taikyti ir kitoms epilepsijos rūšims klasifikuoti. Šiame darbe nagrinėti dviejų epilepsijos rūšių atvejai, kuriuos gydytojams neurologams sunku atskirti. Rekomenduotinas algoritmas taikytinas kitoms epilepsijos rūšims klasifikuoti, tikėtina, galėtų veikti taip pat, nes kai kurių kitų epilepsijos rūšių EEG skirtumai yra labiau išreikšti. Vis dėlto reikėtų gana didelio duomenų kiekio (daug EEG duomenų, sužymėtų pikų pavyzdžių), kad būtų galima priėti prie pagrįstų išvadų.

PRIEDAI


Toliau pateikiamos CNN klasifikatoriaus pagal vieną EEG piką svorių vizualizacijos, iš kurių matyti, kurioms sluoksnių dalims buvo priskirti didesni ar mažesni svoriai. Grafikuose šviesesnė spalva (didesnis skaičius pagal legendą) reiškia didesnį svorį, tamsesnė spalva (mažesnis skaičius pagal legendą) – mažesnį svorį.




16 pav. Testinė matrica įvesties sluoksnyje (klasifikatorius bando atpažinti diagnozę pagal EEG piko pradinę dalį (kur matuojamas koeficientas k_u geometriniais piko parametrais pagrįstame modelyje, žr. 3.8 pav.), centrinę dalį ir EEG piko pabaigą; mažiau svorio suteikiama piko nuolydžiui (kur matuojamas koeficientas k_d))




17 pav. Pirmas konvoliucijos sluoksnis



18 pav. Didžiausio sutelkimo sluoksnis



19 pav. Antras konvoliucijos sluoksnis



20 pav. Trečias konvoliucijos sluoksnis

LITERATŪRA

- [1] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Jozefowicz, L. Kaiser, M. Kudlur, J. Levenberg, D. Mané, R. Monga, S. Moore, D. Murray, C. Olah, M. Schuster, J. Shlens, B. Steiner, I. Sutskever, K. Talwar, P. Tucker, V. Vanhoucke, V. Vasudevan, F. Viégas, O. Vinyals, P. Warden, M. Wattenberg, M. Wicke, Y. Yu, and X. Zheng. TensorFlow: Large-scale machine learning on heterogeneous systems, 2015. URL <http://tensorflow.org/>. Software available from tensorflow.org.
- [2] S. Abe. *Support Vector Machines for Pattern Classification*. Springer, 2005.
- [3] U. Rajendra Acharya, S. V. Sree, S. Chattopadhyay, and J. S. Suri. Automated diagnosis of normal and alcoholic EEG signals. *International Journal of Neural Systems*, 22(3), 2012.
- [4] U. Rajendra Acharya, H. Fujita, S. L. Oh, Y. Hagiwara, J. H. Tan, and M. Adam. Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals. *Information Sciences*, 415–416: 190–198, 2017. ISSN 0020-0255. doi: 10.1016/j.ins.2017.06.027. URL <http://www.sciencedirect.com/science/article/pii/S0020025517308009>.
- [5] U. Rajendra Acharya, S. L. Oh, Y. Hagiwara, J. H. Tan, M. Adam, A. Gertych, and R. San Tan. A deep convolutional neural network model to classify heartbeats. *Computers in Biology and Medicine*, 89:389–396, 2017. ISSN 0010-4825. doi: 10.1016/j.compbiomed.2017.08.022. URL <http://www.sciencedirect.com/science/article/pii/S0010482517302810>.
- [6] H. H. Aghdam and E. J. Heravi. *Guide to Convolutional Neural Networks A Practical Application to Traffic-Sign Detection and*

- Classification*. Springer International Publishing, 2018.
- [7] M. Anthimopoulos, S. Christodoulidis, L. Ebner, A. Christe, and S. Mougiakakou. Lung pattern classification for interstitial lung diseases using a deep convolutional neural network. *IEEE Transactions on Medical Imaging*, 35(5): 1207–1216, May 2016. doi: 10.1109/TMI.2016.2535865.
 - [8] V. Bevilacqua, A. A. Salatino, C. Di Leo, G. Tattoli, D. Buongiorno, D. Signorile, C. Babiloni, C. Del Percio, A. I. Triggiani, and L. Gesualdo. Advanced classification of Alzheimer’s disease and healthy subjects based on EEG markers. *2015 International Joint Conference on Neural Networks (IJCNN)*, pages 1–5, July 2015. ISSN 2161-4407. doi: 10.1109/IJCNN.2015.7280463.
 - [9] S. Boughorbel, F. Jarray, and M. El-Anbari. Optimal classifier for imbalanced data using Matthews correlation coefficient metric. *PLOS ONE*, 12(6): 1–17, 06 2017. doi: 10.1371/journal.pone.0177678.
 - [10] Th. Chemmanam, A. Radhakrishnan, S. P. Sarma, and K. Radhakrishnan. A prospective study on the cost-effective utilization of long-term inpatient video-EEG monitoring in a developing country. *Journal of Clinical Neurophysiology*, 26(2): 123–128, 2009. doi: 10.1097/WNP.0b013e31819d8030.
 - [11] Wikipedia Community. Electrode locations of international 10–20 system for EEG (electroencephalography) recording, 2010. https://commons.wikimedia.org/wiki/File:21_electrodes_of_International_10-20_system_for_EEG.svg.
 - [12] Wikipedia Community. An EEG recording setup, 2010. https://en.wikipedia.org/wiki/Electroencephalography#/media/File:EEG_cap.jpg.
 - [13] Wikipedia Community. File:neuronas.gif, 2013. <https://commons.wikimedia.org/wiki/File:Neuronas.gif>.
 - [14] R. Degen, H. Holthausen, T. Pieper, I. Tuxhorn, and P. Wolf. Benign epileptic discharges in patients with lesional partial epilepsies. *Pediatric Neurology*, 20(5): 354–359, 2017/05/07 1999. ISSN 0887-

8994. doi: 10.1016/S0887-8994(99)00004-1.
- [15] R. M. Deveikis. Dirbtinių neuroninių tinklų panaudojimas elektroencefalogramų analizei, 2018. Magistro baigiamasis darbas.
- [16] M. Dyrmann, H. Karstoft, and H. S. Midtiby. Plant species classification using deep convolutional neural network. *Biosystems Engineering*, 151:72–80, 2016. ISSN 1537-5110. doi: 10.1016/j.biosystemseng.2016.08.024. URL <http://www.sciencedirect.com/science/article/pii/S1537511016301465>.
- [17] S. Finger, F. Boller, and K. L. Tyler. *History of Neurology: Handbook of Clinical Neurology*. Elsevier, 2010. ISBN 978-0444-52009-8.
- [18] P. Geurts, D. Ernst, and L. Wehenkel. Extremely randomized trees. *Machine Learning*, 63(1): 3–42, Apr 2006. ISSN 1573-0565. doi: 10.1007/s10994-006-6226-1.
- [19] J. J. Halford. Computerized epileptiform transient detection in the scalp electroencephalogram: Obstacles to progress and the example of computerized ECG interpretation. *Clinical Neurophysiology*, 120(11):1909–1915, 2009. ISSN 1388-2457. doi: 10.1016/j.clinph.2009.08.007.
- [20] A. R. Hassan and A. Subasi. Automatic identification of epileptic seizures from EEG signals using linear programming boosting. *Computer Methods and Programs in Biomedicine*, 136: 65–77, 2016. ISSN 0169-2607. doi: 10.1016/j.cmpb.2016.08.013. URL <http://www.sciencedirect.com/science/article/pii/S0169260716304928>.
- [21] Y. Hsu, J. Wang, W. Chiang, and C. Hung. Automatic ECG-based emotion recognition in music listening. *IEEE Transactions on Affective Computing*, 2017. ISSN 1949-3045. doi: 10.1109/TAFFC.2017.2781732.
- [22] J. D. Hunter. Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9(3): 90–95, 2007. doi: 10.1109/MCSE.2007.55.
- [23] R. G. Pontius Jr and M. Millones. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment.

- International Journal of Remote Sensing*, 32(15): 4407–4429, 2011. doi: 10.1080/01431161.2011.552923.
- [24] A. Juozapavičius, G. Bacevičius, D. Bugelskis, and R. Samaitienė. EEG analysis – automatic spike detection. *Nonlinear Analysis: Modelling and Control*, 16(4): 375–386, 2011. URL http://www.mii.lt/na/issues/NA_1604/NA16401.pdf.
- [25] A. Juozapavičius and T. Meškauskas. Vaizdų ir signalų analizė ir apdorojimas. TEV, 2011.
- [26] B. Kemp and J. Olivan. European data format 'plus' (EDF+), an EDF alike standard format for the exchange of physiological data. *Clinical Neurophysiology*, 114(9): 1755–1761, 2003. ISSN 1388-2457. doi: 10.1016/S1388-2457(03)00123-8.
- [27] B. Kemp, A. Varri, A. C. Rosa, K. D. Nielsen, and J. Gade. A simple format for exchange of digitized polygraphic recordings. *Clinical Neurophysiology*, 82: 391–393, 1992. URL <http://www.hsr.nl/bobkemp/papers/1992KempClinNeuroPhys-EuropeanDataFormat.pdf>.
- [28] H. Komijani, A. Nabaei, and H. Zarrabi. Classification of normal and epileptic EEG signals using adaptive neuro-fuzzy network based on time series prediction. *Neuroscience and Biomedical Engineering*, 4(4): 273–277, 2016.
- [29] G. Korvel, P. Treigys, G. Tamulevičius, J. Bernatavičienė, and B. Kostek. Analysis of 2D feature spaces for deep learning-based speech recognition. *Journal of the Audio Engineering Society*, 66(12): 1072–1081, 2018. doi: 10.17743/jaes.2018.0066.
- [30] K. Krishnakumar and D. E. Goldberg. Control system optimization using genetic algorithms. *Journal of Guidance, Control, and Dynamics*, 15(3): 735–740, 1992. doi: 10.2514/3.20898.
- [31] A. Krizhevsky, I. Sutskever, and G. E. Hinton. Imagenet classification with deep convolutional neural networks. 25: 1097–1105, 2012.
- [32] A. V. S. Kumar. Fuzzy expert systems for disease diagnosis. pages 1–400, 01 2014. doi: 10.4018/978-1-4666-7240-6.

- [33] P. Lakhani and B. Sundaram. Deep learning at chest radiography: Automated classification of pulmonary tuberculosis by using convolutional neural networks. *Radiology*, 284(2): 574–582, 2017. doi: 10.1148/radiol.2017162326. PMID: 28436741.
- [34] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11): 2278–2324, Nov 1998. ISSN 1558-2256. doi: 10.1109/5.726791.
- [35] T. Lee. ResNet, ResNetV2, and ResNeXt models for Keras., 2019. URL https://github.com/keras-team/keras-applications/blob/master/keras_applications/resnet_common.py.
- [36] Y. Y. Leu, L. A. Matheson, and L. P. Rees. Assembly line balancing using genetic algorithms with heuristic-generated initial populations and multiple evaluation criteria. *Decision Sciences*, 25(4): 581–605, 1994. doi: 10.1111/j.1540-5915.1994.tb00822.x. URL <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1540-5915.1994.tb00822.x>.
- [37] E. Maggiori, Y. Tarabalka, G. Charpiat, and P. Alliez. Convolutional neural networks for large-scale remote-sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(2): 645–657, Feb 2017. doi: 10.1109/TGRS.2016.2612821.
- [38] B. W. Matthews. Comparison of the predicted and observed secondary structure of T4 phage lysozyme. *Biochimica et Biophysica Acta (BBA) – Protein Structure*, 405(2): 442–451, 1975. ISSN 0005-2795. doi: 10.1016/0005-2795(75)90109-9.
- [39] A. V. Misiukas Misiūnas, T. Meškauskas, and A. Juozapavičius. On the implementation and improvement of automatic EEG spike detection algorithm. *Proc. of the Lithuanian Mathematical Society*, 56(Ser. A): 60–65, 2015.
- [40] A. V. Misiukas Misiūnas, T. Meškauskas, and R. Samaitienė. Derivative parameters of electroencephalograms and their measurement methods. *Proc. of the Lithuanian Mathematical Society*, 57(Ser. A):

- 47–52, 2016.
- [41] A. V. Misiukas Misiūnas, T. Meškauskas, and R. Samaitienė. Algorithm for automatic EEG classification according to the epilepsy type: Benign focal childhood epilepsy and structural focal epilepsy. *Biomedical signal processing and control*, 48: 118–127, 2019. ISSN 1746-8094.
 - [42] A. V. Misiukas Misiūnas, T. Meškauskas, and R. Samaitienė. Accuracy of different machine learning type methodologies for EEG classification by diagnosis. *Lecture Notes in Computer Science*, 11189: 441–448, 2019.
 - [43] A. V. Misiukas Misiūnas, T. Meškauskas, and R. Samaitienė. Machine learning based EEG classification by diagnosis: Approach to EEG morphological feature extraction. *AIP Conference series*, 2164: 080005–1–080005–5, 2019. doi: 10.1063/1.5130828.
 - [44] M. R. Nazari Kousarrizi, A. Asadi Ghanbari, A. Gharaviri, M. Teshnehlab, and M. Aliyari. Classification of alcoholics and non-alcoholics via EEG using SVM and neural networks. *2009 3rd International Conference on Bioinformatics and Biomedical Engineering*, pages 1–4, June 2009. ISSN 2151-7614. doi: 10.1109/ICBBE.2009.5162504.
 - [45] M. A. Nielsen. *Neural Networks and Deep Learning*. Determination Press, 2015.
 - [46] S. Nishida, M. Nakamura, A. Ikeda, and H. Shibasaki. Signal separation of background EEG and spike by using morphological filter. *IFAC Proceedings Volumes of 14th World Congress of IFAC*, 32(2): 4301–4306, 1999.
 - [47] T. E. Oliphant. *A guide to NumPy*, volume 1. Trelgol Publishing USA, 2006.
 - [48] F. Pedregosa, G. Varoquaux and A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Van der Plas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12: 2825–2830, 2011.

- [49] K. J. Piczak. Environmental sound classification with convolutional neural networks. *2015 IEEE 25th International Workshop on Machine Learning for Signal Processing (MLSP)*, pages 1–6, Sep. 2015. doi: 10.1109/MLSP.2015.7324337.
- [50] S. W. Provencher. Estimation of metabolite concentrations from localized in vivo proton NMR spectra. *Magnetic Resonance in Medicine*, 30(6): 672–679, 1993. doi: 10.1002/mrm.1910300604. URL <https://onlinelibrary.wiley.com/doi/abs/10.1002/mrm.1910300604>.
- [51] S. Rajeev and C. S. Krishnamoorthy. Discrete optimization of structures using genetic algorithms. *Journal of Structural Engineering*, 118(5): 1233–1250, 1992. doi: 10.1061/(ASCE)0733-9445(1992)118:5(1233).
- [52] R. Romo Vázquez, H. Vélez-Pérez, R. Ranta, V. Louis Dorr, D. Maquin, and L. Maillard. Blind source separation, wavelet denoising and discriminant analysis for EEG artefacts and noise cancelling. *Biomed. Signal Process. Control*, 7(4): 389–400, 2012. ISSN 1746-8094. doi: 10.1016/j.bspc.2011.06.005. URL <http://www.sciencedirect.com/science/article/pii/S1746809411000589>.
- [53] S. Meneses-Goytia, R. F. Peletier, S. C. Trager, J. Falcón-Barroso, M. Koleva, and A. Vazdekis. Single stellar populations in the near-infrared – I. Preparation of the IRTF spectral stellar library. *Astronomy & Astrophysics*, 582: A96, 2015. doi: 10.1051/0004-6361/201423837.
- [54] D. Salomon, G. Motta, and D. Bryant. *Data compression: The Complete Reference*. Springer, 2006. ISBN 978-1-84628-602-5.
- [55] R. Samaitienė. Rolando epilepsija sergančių vaikų EEG pakitimų, miego bei elgesio sutrikimų ir klinikinių charakteristikų sąsajos. Vilnius University, 2013.
- [56] C. Sammut and G. I. Webb. *Encyclopedia of Machine Learning and Data Mining*. Springer, 2017.
- [57] S. Sanei and J. A. Chambers. EEG signal processing. John Wiley & Sons, 2007.

- [58] M. Sewak, R. Karim, and P. Pujari. *Practical convolutional neural networks: implement advanced deep learning models using Python*. Packt Publishing, 2018.
- [59] M. Sharma, A. Dhere, R. B. Pachori, and U. Rajendra Acharya. An automatic detection of focal EEG signals using new class of time–frequency localized orthogonal wavelet filter banks. *Knowledge-Based Systems*, 118: 217–227, 2017. ISSN 0950-7051. doi: 10.1016/j.knosys.2016.11.024. URL <http://www.sciencedirect.com/science/article/pii/S0950705116304816>.
- [60] K. Simonyan and A. Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv 1409.1556*, 09 2014.
- [61] M. Soltaninejad, G. Yang, T. Lambrou, N. Allinson, T. L. Jones, T. R. Barrick, F. A. Howe, and X. Ye. Automated brain tumour detection and segmentation using superpixel-based extremely randomized trees in FLAIR MRI. *International Journal of Computer Assisted Radiology and Surgery*, 12(2): 183–203, Feb 2017. ISSN 1861-6429. doi: 10.1007/s11548-016-1483-3.
- [62] Z. R. Struzik. Wavelet methods in (financial) time-series processing. *Physica A: Statistical Mechanics and its Applications*, 296(1): 307–319, 2001. ISSN 0378-4371. doi: 10.1016/S0378-4371(01)00101-7. URL <http://www.sciencedirect.com/science/article/pii/S0378437101001017>.
- [63] A. Supratak, H. Dong, C. Wu, and Y. Guo. Deepsleepnet: A model for automatic sleep stage scoring based on raw single-channel EEG. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(11): 1998–2008, Nov 2017. ISSN 1534-4320. doi: 10.1109/TNSRE.2017.2721116.
- [64] W. O. Tatum, A. M. Husain, S. R. Benbadis, and P. W. Kaplan. *Handbook of EEG Interpretation*. Demos Medical Publishing, 2006. ISBN 978-1-933864-11-2.
- [65] M. Thomas, M. Kr Das, and S. Ari. Automatic ECG arrhythmia classification using dual tree complex wavelet based featu-

- res. *AEU – International Journal of Electronics and Communications*, 69(4): 715–721, 2015. ISSN 1434-8411. doi: 10.1016/j.aeue.2014.12.013. URL <http://www.sciencedirect.com/science/article/pii/S1434841114003641>.
- [66] K. D. Tzimourta, A. T. Tzallas, N. Giannakeas, L. G. Astrakas, D. G. Tsalikakis, and M. G. Tsipouras. Epileptic seizures classification based on long-term EEG signal wavelet analysis. *Precision Medicine Powered by pHealth and Connected Health*, pages 165–169, 2018.
- [67] K. D. Tzimourta, A. T. Tzallas, N. Giannakeas, L. G. Astrakas, D. G. Tsalikakis, P. Angelidis, and M. G. Tsipouras. A robust methodology for classification of epileptic seizures in EEG signals. *Health and Technology*, 9(2): 135–142, Mar 2019. ISSN 2190-7196. doi: 10.1007/s12553-018-0265-z.
- [68] M. T. Uddin and M. A. Uddiny. Human activity recognition from wearable sensors using extremely randomized trees. *2015 International Conference on Electrical Engineering and Information Communication Technology (ICEEICT)*, pages 1–6, May 2015. doi: 10.1109/ICEEICT.2015.7307384.
- [69] P. Virtanen, R. Gommers, T. E. Oliphant, M. Haberland, T. Reddy, D. Cournapeau, E. Burovski, P. Peterson, W. Weckesser, J. Bright, S. J. van der Walt, M. Brett, J. Wilson, K. Jarrod Millman, N. Mayorov, A. R. J. Nelson, E. Jones, R. Kern, E. Larson, C. J. Carey, Í. Polat, Y. Feng, E. W. Moore, J. Van der Plas, D. Laxalde, J. Perktold, R. Cimrman, I. Henriksen, E. A. Quintero, C. R. Harris, A. M. Archibald, A. H. Ribeiro, F. Pedregosa, P. van Mulbregt, and SciPy 1.0 Contributors. SciPy 1.0 - Fundamental Algorithms for Scientific Computing in Python. *arXiv e-prints*, page arXiv:1907.10121, Jul 2019.
- [70] B. Wilkinson and M. Allen. *Parallel Programming: Techniques and Applications Using Networked Workstations and Parallel Computers (2Nd Edition)*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA,

2004. ISBN 0131405632.

- [71] T. Xiao, Y. Xu, K. Yang, J. Zhang, Y. Peng, and Z. Zhang. The application of two-level attention models in deep convolutional neural network for fine-grained image classification. *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2015.
- [72] G. Xu, J. Wang, Q. Zhang, and J. Zhu. An automatic EEG spike detection algorithm using morphological filter. *2006 IEEE International Conference on Automation Science and Engineering*, pages 170–175, Oct 2006. ISSN 2161-8070. doi: 10.1109/COASE.2006.326875.
- [73] G. Xu, J. W. Q. Zhang, S. Zhang, and J. Zhu. A spike detection method in EEG based on improved morphological filter. *Computers in Biology and Medicine*, 37(11): 1647–1652, 2007.
- [74] M. Yochum, C. Renaud, and S. Jacquir. Automatic detection of P, QRS and T patterns in 12 leads ECG signal based on CWT. *Biomedical Signal Processing and Control*, 25: 46–52, 2016. ISSN 1746-8094. doi: 10.1016/j.bspc.2015.10.011. URL <http://www.sciencedirect.com/science/article/pii/S1746809415001779>.

PADĖKOS

Dėkoju dr. Rūtai Samaitienei, dirbančiai Vilniaus universiteto liginės Santaros klinikų Vaikų liginėje, už tyrimui suteiktus duomenis, konsultacijas ir idėjas tyrimams.

Dėkoju dr. Valdui Rapševičiui, dirbančiam Vilniaus universiteto Matematikos ir informatikos fakulteto Informatikos institute, už konsultacijas dėl konvoliucinių neuroninių tinklų taikymo ir idėjas tyrimams.

Dėkoju Jeff La Roux už disertacijos santraukos redagavimą anglų kalba.

Andrius Vytautas Misiukas Misiūnas

Vilnius

2020 m. liepos 1 d.

AUTORIAUS PUBLIKACIJOS
DISERTACIJOS TEMA

PUBLIKACIJOS PERIODINIUOSE
RECENZUOJAMUOSE MOKSLINIUOSE
ŽURNALUOSE

1. A.V. Misiukas Misiūnas, T. Meškauskas, R. Samaitienė (2019). Algorithm for automatic EEG classification according to the epilepsy type: benign focal childhood epilepsy and structural focal epilepsy. *Biomedical Signal Processing and Control* 48, p. 118–127. doi: 10.1016/j.bspc.2018.10.006 [Web of Science].
2. A.V. Misiukas Misiūnas, V. Rapševičius, R. Samaitienė, T. Meškauskas (2020). Electroencephalogram spike detection and classification by diagnosis with convolutional neural network. *Nonlinear Analysis: Modelling and Control*. [Web of Science] [Priimtas spausdinti].

PUBLIKACIJOS TĘSTINIUOSE
RECENZUOJAMUOSE MOKSLINIUOSE
ŽURNALUOSE

1. A.V. Misiukas Misiūnas, T. Meškauskas, R. Samaitienė (2019). Accuracy of Different Machine Learning Type Methodologies for EEG Classification by Diagnosis. *Springer Lecture Notes in Computer Science* 11189, p. 441–448. doi: 10.1007/978-3-030-10692-8_50 [Conference Proceedings Citation Index, Web of Science].

2. A.V. Misiukas Misiūnas, T. Meškauskas, R. Samaitienė (2019). Machine Learning Based EEG Classification by Diagnosis: Approach to EEG Morphological Feature Extraction. *AIP Conference Proceedings* 2164, p. 080005-1 – 080005-5. doi: 10.1063/1.5130828 [Conference Proceedings Citation Index, Web of Science].
3. A.V. Misiukas Misiūnas, T. Meškauskas, A. Juozapavičius (2015). On the implementation and improvement of automatic EEG spike detection algorithm. *Lietuvos matematikos rinkinys [Proc. of the Lithuanian Mathematical Society]*, ser. A (56), p. 60–65. doi: 10.15388/LMR.A.2015.11.
4. A.V. Misiukas Misiūnas, T. Meškauskas, R. Samaitienė (2016). Derivative parameters of electroencephalograms and their measurement methods. *Lietuvos matematikos rinkinys [Proc. of the Lithuanian Mathematical Society]*, ser. A (57), p. 47–52. doi: 10.15388/LMR.A.2016.09.

PUBLIKACIJOS KONFERENCIJŲ SANTRAUKŲ RINKINIUOSE IR PROGRAMOSE

1. A. V. Misiukas Misiūnas, T. Meškauskas, A. Juozapavičius (2014). On implementation of automatic EEG spikes detection algorithm. *Data analysis methods for software systems: 6th International Workshop. Abstracts book*. Druskininkai, Lietuva, 2014, gruodžio 4–6 d., p. 41. ISBN 9789986680505.
2. A.V. Misiukas Misiūnas, T. Meškauskas, R. Samaitienė (2018). Accuracy of different machine learning type methodologies for EEG classification by diagnosis. *Numerical Methods and Applications: 9th international conference. Abstracts book*. Borovecas, Bulgarija, 2018, rugpjūčio 20–24 d., p. 64.

3. A.V. Misiukas Misiūnas, T. Meškauskas, R. Samaitienė (2018). On implementation of Three-Stage Algorithm for EEG Classification by Diagnosis. *Data analysis methods for software systems: 10th International Workshop. Abstracts book*. Druskininkai, Lietuva, 2018, lapkričio 29 d.–gruodžio 1 d., p. 60. ISBN 9786090700433.
4. A.V. Misiukas Misiūnas, T. Meškauskas, R. Samaitienė (2019). Machine Learning Based EEG Classification by Diagnosis: Approach to EEG Morphological Feature Extraction. *11th Conference of the Euro-American Consortium for Promoting the Application of Mathematics in Technical and Natural Sciences. Abstracts book*. Albena, Bulgarija, 2019, birželio 20–25 d., p. 63.

CURRICULUM VITAE

Jau nuo mokyklos autorius yra linkęs į įvairius mokslinius tyrimus ir programavimą. Jis lankė astronomijos būrelį tuometiniuose Respublikiniuose moksleivių techninės kūrybos rūmuose (2005–2008 m.), dalyvavo Lietuvos mokinių astronomijos olimpiadose (užėmė II–III vietas), dalyvavo *International Olympiad on Astronomy and Astrophysics*, Nacionaliniame jaunųjų mokslininkų konkurse (užėmė I–II vietas), 20-ajame ES Jaunųjų mokslininkų konkurse. Vilniaus universiteto Fizikos fakultete studijavo kompiuterinę fiziką (bakaluro studijos), vėliau VU universiteto Matematikos ir informatikos fakultete – kompiuterinį modeliavimą (magistro studijos). Studijas tęsė VU informatikos mokslo krypties doktorantūroje.

Išsilavinimas:

- 2015–2019 m., Vilniaus universitetas, Informatikos mokslo krypties doktorantūra.
- 2013–2015 m., Vilniaus universitetas, Kompiuterinio modeliavimo magistrantūra.
- 2008–2012 m., Vilniaus universitetas, Kompiuterinės fizikos bakalauro studijos.
- 2008 m., Vilniaus „Minties“ gimnazija.

Darbo patirtis:

- 2017 09–dabar, Vilniaus universitetas, Matematikos ir informatikos fakultetas, jaunesnysis asistentas. Vedamos *Programų sistemų architektūros* paskaitos ir pratybos bakalauro ir išlyginamųjų (PKI) studijų studentams. Vadovaujama bakalaurantų baigiamiesiems darbams, praktikoms.
- 2015 10–dabar, Lietuvos Respublikos specialiųjų tyrimų tarnybos administravimo valdybos informacinių technologijų skyriaus vyriausiasis specialistas. Kuriama speciali analitinė programinė įranga, kuri yra naudojama strateginės, taktinės ir operatyvios analizės padalinių veikloje. Kita, jau sukurta programinė įranga naudojama kriminalinės žvalgybos ir ikiteisminio tyrimo veiklose.
- 2016 02–2017 06, Vilniaus universitetas, Matematikos ir informatikos fakultetas, lektorius. Vestos *Programų sistemų architektūros* ir *Praktinės informatikos* paskaitos ir pratybos.
- 2014 05–2015 06, NKSPS projekto EEG modulio kūrėjas. Suprogramuotas modelis, generuojantis ataskaitą apie EEG pikus, rastus Rolando epilepsija sergančių vaikų EEG.
- 2014 07–2014 12, UAB *iTree Lietuva*, *Java* programuotojas.
- 2012 09–2013 01, vykdomi studentų moksliniai tyrimai, projektinė mokslinė veikla. Dirbamas mokslinis darbas, susijęs su astrofizika, reikalaujantis puikių analitinių įgūdžių, gebėjimų savarankiškai spręsti iškilusias problemas. Esant dideliame analizuojamų duomenų kiekiui, savarankiškai sukurti algoritmai ir programos, padedančios apdoroti tyrimų duomenis.
- 2011 10–2012 09, Vilniaus universiteto Teorinės fizikos ir astronomijos institutas, praktikantas.

Papildoma informacija:

- 2006–2008 m., Nacionalinio jaunųjų mokslininkų konkurso prizininkas ir nugalėtojas (I–II vietos), Europos jaunųjų mokslininkų konkurso dalyvis.
- 2005–2008 m., Lietuvos mokinių astronomijos olimpiados prizininkas (II–III vietos), tarptautinių olimpiadų dalyvis.

SUMMARY

Automatic algorithm for electroencephalogram (EEG) classification by diagnosis: benign childhood epilepsy with centrotemporal spikes (rolandic epilepsy) (Group I) and structural focal epilepsy (Group II) are presented in this thesis. Manual classification of these groups is sometimes difficult, especially when no clinical record is available, thus presenting the need for an algorithm for automatic classification. A few possible classification by diagnosis algorithm versions are proposed in this thesis: 1) geometric EEG spike parameter and feed-forward multilayer perceptron (MLP) based classifier achieving 75% classification accuracy; 2) extremely randomized tree based algorithm using signal in channel where EEG spikes are classifying 82% accuracy; and 3) convolutional neural network (CNN) and majority rule classifier based algorithm achieving 80% accuracy, or 82% if only EEGs with 100 or more spikes are classified.

UŽRAŠAMS

UŽRAŠAMS

Vilniaus universiteto leidykla
Saulėtekio al. 9, III rūmai, LT-10222 Vilnius
El. p. info@leidykla.vu.lt; www.leidykla.vu.lt
Tiražas 20 egz.