

Elektroencefalogramų analizės metodų tyrimas

Doktorantas Andrius Vytautas Misiukas Misiūnas

Vadovas prof. Dr. Tadas Meškauskas

Formalių reikalavimų vykdymas

Straipsniai periodiniuose recenzuojamuose moksliniuose žurnaluose

- 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]
- A.V. Misiukas Misiūnas, V. Rapševičius, R. Samaitienė, T. Meškauskas (2019). On electroencephalogram classification by diagnosis with convolutional neural network. Recenzuojama Nonlinear Analysis: Modelling and Control.

Straipsniai recenzuojamuose testiniuose žurnaluose I

- A. V. Misiukas Misiūnas, T. Meškauskas, R. Samaitienė (2019). Accuracy of Different Machine Learning Type Methodologies for EEG Classification by Diagnosis, Numerical Methods and Applications, 9th International Conference, NMA 2018 Borovets, Bulgaria, August 20–24, 2018. Springer Lecture Notes in Computer Science, p. 441-448. doi: 10.1007/978-3-030-10692-8_50 [Conference Proceedings Citation Index, Web of Science dalis]
- 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 (AMiTaNS'18), AIP Conference Proceedings, p. 080005-1-080005-5. doi: 10.1063/1.5130828 [Conference Proceedings Citation Index, Web of Science dalis]

Straipsniai recenzuojamuose testiniuose žurnaluose II

- A.V. Misiukas Misiūnas, T. Meškauskas, A. Juozapavičius (2015). On the implementation and improvement of automatic EEG spike detection algorithm. Liet. matem. rink. Proc. LMS, Ser. A (56), p. 60-65. doi: 10.15388/LMR.A.2015.11
- A.V. Misiukas Misiūnas, T. Meškauskas, R. Samaitienė (2016). Derivative parameters of electroencephalograms and their measurement methods. Liet. matem. rink. Proc. LMS, Ser. A (57), p. 47-52. doi: 10.15388/LMR.A.2016.09

Pranešimai tarptautinėse konferencijose

- 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. Borovets, Bulgarija, Rugpjūčio 20-24, 2018.
- 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. Albena, Bulgarija, Birželio 20-25, 2019.

*Pranešėjas

Pranešimai nacionalinėse konferencijose

- 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. Druskininkai, Lietuva, Gruodžio 4-6, 2014.
- A. V. Misiukas Misiūnas*, T. Meškauskas, A. Juozapavičius (2015). Automatizuoto EEG pikų atpažinimo algoritmo realizacija ir taikymai. 56-toji Lietuvos Matematikų Draugijos LVI konferencija. Kaunas, Lietuva, Birželio 16-17, 2015.
- A. V. Misiukas Misiūnas*, T. Meškauskas, R. Samaitienė (2016). Elektroencefalogramų išvestiniai parametrai ir jų nustatymo metodika. 57-toji Lietuvos Matematikų Draugijos LVI konferencija. Vilnius, Lietuva, Birželio 20-21, 2016.
- 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. Druskininkai, Lietuva, Lapkričio 29 - Gruodžio 1, 2018.

*Pranešėjas

Publikacijos konferencijų santraukų rinkiniuose ir programose

- 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, Gruodžio 4-6, 2014. ISBN 9789986680505. p. 41.
- 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, Borovets, Bulgarija, Rugpjūčio 20-24, 2018. p. 64.
- 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, Lapkričio 29 - Gruodžio 1, 2018. ISBN 9786090700433. p. 60.
- 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, Birželio 20-25, 2019.

Egzaminai

- Visi numatyti egzaminai išlaikyti
 - „Lygiagretieji ir paskirstytieji skaičiavimai“. Vertinimo komisija: prof. dr. Julius Žilinskas, prof. habil. dr. G. Dzemyda, dr. V. Medvedev. Įvertinimas 10 (puikiai)
 - „Dirbtiniai neuroniniai tinklai“. Vertinimo komisija: prof. habil. dr. Šarūnas Raudys, dr. Valdas Dičiūnas, dr. Rimantas Kybartas. Įvertinimas 9 (labai gerai).
 - „Skaitiniai metodai“. Vertinimo komisija: prof. habil. dr. Feliksas Ivanauskas, doc. dr. Pranas Katauskis, prof. dr. Tadas Meškauskas. Įvertinimas 10 (puikiai).
 - „Daugiamačių duomenų vizualizavimo metodai“. Komisija: prof. habil. dr. Gintautas Dzemyda, prof. dr. Olga Kurasova, dr. Viktor Medvedev. Įvertinimas: 9 balai (labai gerai).

Disertācijas būsena

- Pateikta institutui
- Bus toliau tobulinama ir pildoma
- Šiuo metu apie 110 000 + 29 000 spaudos ženklų


Moksliniai rezultatai

Disertacijos ginami teiginiai

- Grupės I ir Grupės II EEG gali būti klasifikuojamos naudojant disertacijoje pristatomas metodologijas.
- Naudojant EEG pikų geometrinius parametrus geriausias klasifikavimo tikslumas (75%) yra pasiekiamas su dirbtiniu neuroniniu tinklu.
- Naudojant EEG pikų signalų atkarpų (kanale kur aptiktas EEG pikas) masyvą geriausias klasifikavimo tikslumas pasiekiamas su labai atsitiktinio medžio klasifikatoriumi (82%).
- Naudojant EEG pikų signalo atkarpas visuose kanaluose, konvoliucinį neuroninį tinklą ir daugumos balsavimo klasifikatorių pasiektas 80% klasifikavimo tikslumas.

Tyrimų objektas


- Vaikų (3-17 metų), diagnozuotų su dviemis skirtingomis epilepsijos formomis elektroencefalogramos (EEG), matuotos 10-20 tarptautinėje sistemoje
 - EEG – smegenų aktyvumo įrašas iš 21 elektrodo (10-20 sistemoje), uždėto ant paciento galvos odos



https://upload.wikimedia.org/wikipedia/commons/b/bf/EEG_cap.jpg

Tyrimų objektas

- EEG pikai visada rodo nenormalų smegenų aktyvumą
 - Daug centrinės nervų sistemos ligų pasižymi jais
 - Kai kurie lengvai randami ir atpažįstami, kiti – ne



EEG pikų pavyzdžiai

Pacientų grupės

Grupė I


- Pacientai, kuriems diagnozuota Rolando epilepsija
 - Aiškūs EEG pikai
 - Pikų forma daug nesikeičia EEG eigoje

Grupė II

- Struktūrinė židininė epilepsija, cerebrinis paralyžius ir kt.
 - Dažniausiai pikai aiškiai skiriasi savo forma nuo RE grupės
 - Kai kuriais atvejais pikai labai panašūs
 - Mes tiriamo tik tuos pikus, kurie yra labai panašūs (arba neatskiriami) neurologams


EEG klasifikavimo algoritmo esminiai žingsniai

1. EEG pikų aptikimas
2. EEG pikų parametrų nustatymas (jei reikia)
3. EEG klasifikavimas pasinaudojant mašinų mokymosi metodais



1 žingsnis. Pikų aptikimo algoritmas (bendras visoms metodologijoms)


- Paremtas matematine morfologija
- Nufiltruoja žinomą normalų smegenų aktyvumą palikdamas nenormalų
- Algoritmas sugalvotas kitų autorių, patobulintas ir įgyvendintas doktoranto



ANN klasifikatorius, naudojantis
geometrinius EEG pikų
parametrus

2 žingsnis. EEG pikų geometriniai parametrai (1 metodologija)

- Įmanoma nustatyti tam tikrus pikų parametrus
 - Galbūt tikslesnis ir objektyvesnis būdas, negu vizuali analizė
- Analizė rodo, kad reikšmingiausi diagnozei parametrai yra piko pakilimo ir nusileidimo greitis



TNR ir TPR analizė

Metrika / Algoritmas	Atsitiktinis miškas	Sprendimų medis	Labai atsitiktinis medis	AdaBoost	ANN	SVM $N = 3$
Tikslumas	0,78	0,76	0,80	0,81	0,75	0,69
TNR	0,79	0,76	0,83	0,90	0,79	0,79
TPR	0,74	0,77	0,71	0,52	0,74	0,48
F1 metrika	0,76	0,76	0,75	0,64	0,78	0,57
Cohen kapa	0,06	-0,01	0,12	0,38	0,28	0,26

Teisingas atsakymas gaunamas spėliojant

Prastai aptinkamos CP EEG

F1 metrika atsižvelgia tiek į TPR tiek į TNR


Dirbtinio neuroninio tinklo (ANN) savybės

- 100 įvesties neuronų
- 10 paslėptų neuronų
- 1 išvesties neuronas
 - Išvesties reikšmė suapvalinama iki artimiausio sveikojo skaičiaus
 - Jei išvestis yra 1 – virtuali EEG yra CP grupėje, kitu atveju – RE grupėje
- Softmax aktyvacijos funkcija
 - Toks pats veikimas kaip sigmoidinės, bet greitesnis mokymasis

EEG klasifikatorius, naudojantis
EEG pikų signalo duomenis, kur
buvo rastas pikas

Antra metodologija

- EEG pikai sudedami paeiliui
- Gautas masyvas klasifikuojamas mašinų mokymosi metodais



Validavimas su k-fold metodologija

Algoritmas\Metrika	TPR	SD	TNR	SD
Logistinė regresija	0,656	0,001	0,6	0,006
Atsitiktinis miškas	0,951	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
ANN	0,601	0,029	0,58	0,04
SVM N=3	0,879	0,02	0,124	0,019
SVM RBF	0,783	0,058	0,264	0,041
SVM sigmoid	0,579	0,063	0,511	0,042

Metodologija, naudojanti visus EEG pikus


CNN klasifikatorius

Sluoksnis	Aprašymas	Išvesties forma
Input	-	21, 77
2D sąsūka	16 7x7 filtrų	15, 71, 16
2D mak. sutelkimas	2x2 santalkos dydis	14, 70, 16
2D sąsūka	32 5x5 filtrų	10, 66, 32
2D sąsūka	64 3x3 filtrų	7, 63, 64
Išlyginimas	-	5952
Pilnai sujungta	1024 neuronų, tanh akt, f-ja	1024
Išvestis	1 neuronas, sigmoidinė akt. f-ja	1


Metodikos esmė

- CNN klasifikatorius nustato kiekvieno EEG piko diagnozę atskirai
 - 58% patikimumas
- Daugumos balsavimo klasifikatorius surenka CNN klasifikatoriaus rezultatus
 - Tada gaunamas 80% patikimumas

Balsavimo klasifikatorių rezultatai



3.18 pav.: Grupės I balsavimo rezultatai



3.19 pav.: Grupės II balsavimo rezultatai

Metodikos privalumai

- Galima klasifikuoti bet kiek pikų turinčias EEG iš naujo nemokant CNN
 - Su kitom siūlomom metodologijom norint pakeisti pikų skaičių, tai reikia padaryti
- Pasiekiamas toks pats ar geresnis tikslumas, negu su kitomis metodologijomis
- Dėl to rekomenduojama naudoti šią metodologiją