




**Vilniaus universitetas  
Matematikos ir informatikos  
fakultetas  
LIETUVA**



---

INFORMATIKA (09 P)

---

# **ELEKTROENCEFALOGRAMŲ ANALIZĖS METODŲ TYRIMAS**

**Andrius Vytautas Misiukas Misiūnas**

2017 m. spalio

Mokslinė ataskaita MII-DS-09P-17-2

## **Santrauka**

Šioje ataskaitoje aprašomi darbai už antruosius doktorantūros metus. Remiantis ankstesniais metais ir šiemet sukurtais algoritmais buvo sukurtas elektroencefalogramų (EEG) klasifikatorius, galintis klasifikuoti EEG pacientų, sergančių dviem epilepsijos rūšimis. Šiame darbe buvo apibrėžtos tokios pacientų grupės: 1) pacientai, sergantys gėrybine vaikų epilepsija, pvz. Rolando epilepsija, 2) pacientai, sergantys struktūriniais smegenų pažeidimais, smegenų žievės displazija ar cerebriniu paralyžiumi. Jų EEG klasifikavimui sukurtas trijų žingsnių algoritmas: 1) EEG pikų aptikimo, (ankstesnių metų darbas) 2) EEG pikų parametru apskaičiavimo ir jų validavimo (šių ir ankstesnių metų darbas), 3) dirbtiniais neuroniniais tinklais pagrįsto klasifikatoriaus (šių metų darbas). Algoritmas buvo ištestuotas su 94 EEG (ataskaitos rašymo metu, atsiradus daugiau tinkamų pacientų imtis bus plečiama), pasiektas 72% tikslumas.

**Raktiniai žodžiai:** EEG, elektroencefalogramos, EEG pikai, epilepsija, dirbtiniai neuroniniai tinklai

# Turinys

---

1	Įvadas .....	4
2	Tyrimo duomenys .....	4
	2.1 EEG parinkimas .....	4
	2.2 DNT klasifikatoriaus mokymo ir testavimo strategija .....	5
3	EEG klasifikavimo algoritmas .....	5
	3.1 EEG pikų aptikimas .....	6
	3.2 EEG pikų parametrų nustatymo algoritmas .....	6
	3.2.1 EEG pikų validavimas.....	8
	3.3 EEG klasifikavimo algoritmas .....	8
	3.3.1 DNT klasifikatorius .....	8
	3.3.2 SVM klasifikatorius .....	9
4	Rezultatų aptarimas .....	9
	4.1 Statistinė analizė .....	9
	4.2 Eksperimentai su DNT klasifikatoriumi.....	11
	4.3 Įgyvendinimo priemonės .....	12
5	Išvados ir pagrindiniai rezultatai .....	12
	Literatūros sąrašas .....	13

# 1 Įvadas

Pagrindinis disertacijos tikslas – elektroencefalogramų (EEG) kompiuterinė analizė. Tai yra plačiai ir ilgą laiką moksle nagrinėjama tema, tačiau joje iki šiol lieka tam tikrų nepakankamai išnagrinėtų sričių, apie vieną kurių ir bus rašoma šioje ataskaitoje. Šioje ataskaitoje aprašomi darbai už antruosius doktorantūros metus. Darbe vartojamos sąvokos ir algoritmai buvo detalčiai aprašyti pernai metų ataskaitoje [Mis16], todėl čia bus pateikiama tik tiek informacijos, kiek reikia šių metų darbų supratimui, detalesnė informacija pateikiama pernai metų ataskaitoje [Mis16] ir autoriaus mokslinėse publikacijose [MMJ15, MMS16].

Yra atlikta labai mažai tyrimų, kuriuose buvo bandyta klasifikuoti EEG pagal epilepsijos tipą remiantis EEG pikų parametrais. Šiame darbe buvo susikoncentruota ties dviem epilepsijos tipais: gėrybinė vaikų epilepsija (Grupė I) ir struktūrinė židininė epilepsija (Grupė II), plačiau aprašyta 2.1 skyrelyje.

Pradinė darbo hipotezė buvo iškelta, kai neurologai „iš akies“ pastebėjo, kad Grupės II pikai EEG eigoje keičiasi labiau, negu Grupės I pikai. Pasinaudojus EEG pikų aptikimo algoritmu (žr. skyrelį 3.1 ir [MMJ15]) ir EEG pikų parametrų nustatymo algoritmais (žr. skyrelį 3.2 ir [MMS16]) pradinė hipotezė buvo patvirtinta ir sukurtas EEG klasifikatorius (žr. 3.3 skyrelį).

Šiame darbe pasiūlytas algoritmas, skirtas automatiškai klasifikuoti minėtų grupių EEG klasifikavimui pagal jų pikus sudarytas iš tokių žingsnių: 1) EEG pikų aptikimo, (ankstesnių metų darbas) 2) EEG pikų parametrų apskaičiavimo ir jų validavimo (šių ir ankstesnių metų darbas), 3) dirbtiniais neuroniniais tinklais pagrįsto klasifikatoriaus (šių metų darbas). Šis algoritmas detalčiau aprašytas 3 skyrelyje.

## 2 Tyrimo duomenys

Šiame darbe naudoti VšĮ Vilniaus Universiteto ligoninės Santaros klinikų filialo Vaikų ligoninės neurologų pateikti EEG tyrimų duomenys. Darbe analizuojami EEG tyrimai buvo atlikti 2010-2017 metais, atrinkti duomenys pasižymintys gėrybinėms vaikų epilepsijoms būdingais EEG pikais.

### 2.1 EEG parinkimas

Reikėtų pastebėti, kad šiame tyrime trivialūs atvejai nebuvo analizuojami. Grupės I EEG visada pasižymi panašios formos pikais, kurie daug nesikeičia EEG eigoje. Grupės II EEG kai kuriais atvejais akivaizdžiai skiriasi nuo Grupės I EEG net ne profesionalams, tokie atvejai šiame darbe analizuojami nebuvo. Buvo tiriami tik tokie Grupės II duomenys, kurie yra (beveik arba visiškai) neatskiriami neurologams be ligos anamnezės ar kitų duomenų, neesančių EEG failuose.

Šiame darbe buvo apdorotos 94 EEG, gautos iš 86 skirtingų pacientų, padalintų į tokias grupes:

- **Grupė I:** gėrybinė vaikų epilepsija su EEG pikais, šiuo atveju Rolando epilepsija (62 EEG, arba apie 66% visų duomenų).
- **Grupė II:** struktūrinė židininė epilepsija pacientams, kenčiantiems nuo cerebrinio paralyžiaus, smegenų žievės displazijos ir pan. (32 EEG, arba apie 34% iš visų EEG).

## 2.2 DNT klasifikatoriaus mokymo ir testavimo strategija

Šiame darbe buvo griežtai taikomas principas, kad pacientas (su visomis jo EEG ir visais jų pikais) priskiriamas tik vienai: mokymo arba testavimo imčiai. Jei vienas pacientas turi kelias EEG (irašytas skirtingais laikais) visos jos priskiriamos tai pačiai (mokymo arba testavimo) imčiai. Tai yra atlikta dėl akivaizdžios priežasties: DNT persimokymo (angl. *overfitting*) išvengimo.

Tam, kad išsiaiškinti DNT persimokymo efektų svarbą buvo atliktas eksperimentas atsitiktinius pikus priskiriant atsitiktiniai (mokymo ar testavimo) imčiai ir jo metu nustatytas klasifikatoriaus pseudo patikimumas siekė 95-99% (vietoje 72% esant korektiškai metodologijai).

Mokymo ir testavimo imtys (DNT klasifikatoriui) buvo apibrėžtos taip:


- 62 Grupės I EEG, 21 algoritmo mokymui (apie 34%) ir 41 testavimui (apie 66%);
- 32 Grupės II EEG, 11 algoritmo mokymui (apie 34%) ir 21 testavimui (apie 66%).

Mokymo imtys buvo rankiniu būdu (gydytojų neurologų) išvalytos nuo EEG artefaktų (kaip paciento judesiai, mirksėjimas, ir pan.) todėl, kad DNT apmokyti su kuo švaresniais duomenimis maksimaliam rezultatui. Ta pati strategija taikyta ir palaikomųjų vektorių mašinų klasifikatoriaus mokymui.

## 3 EEG klasifikavimo algoritmas

Šiame darbo skyrelyje bus detaliau aprašytas EEG pasiūlytas algoritmas. Jis sudarytas iš tokių esminių žingsnių:

1. EEG pikų aptikimas (plačiau 3.1 skyrelyje ir [MMJ15]);
2. EEG pikų parametrų nustatymas (plačiau 3.2 skyrelyje ir [MMS16]) ir validavimas (plačiau 3.2.1 skyrelyje ir [MMS16]);
3. EEG klasifikatorius (plačiau 3.3 skyrelyje).



1 pav.: Matematinės morfologijos pagrindu veikiančio filtro veikimo demonstracija. Signalas turi du pikus ties 6.2 ir 7.0 sekundės. A) Nefiltruotas signalas, B) Morfologiniu filtru nufiltruotas signalas.

### 3.1 EEG pikų aptikimas


Šiame skyrelyje aprašomas pirmasis EEG klasifikavimo algoritmo žingsnis. Šio algoritmo studija ir įgyvendinimas iš esmės yra ankstesnių doktorantūros metų darbas, tačiau jo veikimas primenamas tam, kad geriau suprasti bendrą EEG klasifikatoriaus veikimą. Šio algoritmo paskirtis yra surasti pikų vietas EEG signale. Algoritmas yra jau žinomas [NNIS99, XWZZ06, XWZ+07, JBBS11, MMJ15].

Algoritmas veikia morfologinių filtrų pagrindu, signalas yra filtruojamas 4 sekundžių slenkančio lango filtru. Morfologinio filtro struktūrinis elementas yra sukonstruotas taip, kad filtruojant signalą pašalintų žinomą normalią smegenų veiklą, kaip pvz. smegenų ritmai, palikdamas tik nenormalią (žr. 1 pav.), pvz EEG pikus. Tačiau nenormaliai atrodanti veikla nebūtinai yra tik EEG būdingi pikai, o ir nemažai kitų darinių, todėl algoritmas ankstesniais metais buvo tobulinamas kuriant pikų parametrų nustatymo ir validavimo algoritmus.

Šiame žingsnyje parenkamas tas EEG kanalas, kuriame randama daugiausiai pikų ir toliau nagrinėjamas būtent šis kanalas. Ankstesnių metų tyrimai rodo, kad būtent šis kanalas būna arčiausiai epilepsijos židinio, todėl pikų parametrų nustatymo algoritmas jame veikia tiksliausiai.

### 3.2 EEG pikų parametrų nustatymo algoritmas

Šiame skyrelyje aprašomas antrasis EEG klasifikavimo algoritmo žingsnis. Šio algoritmo paskirtis yra gavus EEG pikų vietas išmatuoti jų parametrus. Pradinė šio algoritmo paskirtis buvo išmatuoti EEG pikų parametrus tam, kad juos galima būtų validuoti.



2 pav.: EEG piko parametrų vizualinė schema: pakilimo kampas, nusileidimo kampas, signalo bazinė linija ir plotis pusaukštyje

Vėliau buvo pastebėta, kad šiuos parametrus būtų galima taikyti ir EEG klasifikavimui pagal diagnozę. Algoritmas išmatuoja tokias charakteristikas kaip EEG piko pakilimo kampas ( $k_U$ ), nusileidimo kampas ( $k_D$ ), bazinė linija, aštrios bangos ir piko trukmė.

Šiame darbe svarbiausi parametrai yra piko pakilimo ir nusileidimo kampai, todėl lyginant su ankstesniais metais buvo patobulinta jų nustatymo metodika. Abiejuose metodikose piko pakilimo ir nusileidimo kampas yra nustatomas prie atitinkamos piko dalies aproksimuojant tiesę. Pagrindinė kliūtis išmatuoti šį parametą – neaišku kurioje tiksliai piko dalyje vykdyti aproksimaciją. Todėl buvo peržiūrėtas būtent šis kriterijus: dabar vietoje rišimosi prie piko maksimalios (absoliutinės) vertės, yra rišamasi prie signalo, esančio aplink piką svyravimo (žr. 2 pav.). Dabar imamas dvigubas standartinis nuokrypis nuo signalo aplink piką maksimumų ir atkerpami du šie dydžiai nuo piko apačios ir viršaus, o likusi dalis naudojama aproksimavimui. Tai leido tiksliau nustatyti piko parametrus esant tiek mažiems šalutiniams triukšmams, tiek ir esant dideliems triukšmams.

Kaip jau minėta 1 skyrelyje, pradinė hipotezė buvo, kad vienos EEG eigoje Grupės I pacientų pikai tarpusavyje skiriasi labiau, negu Grupės II pikai. prieš atliekant tolimesnius darbus ši hipotezė buvo patikrinta atliekant gautų EEG pikų parametrus statistiniais metodais. Pastebėta, kad egzistuoja skirtumas tarp EEG piko pakilimo ir nusileidimo kampų, jų vidurkiai yra panašūs, tačiau standartiniai nuokrypiai skiriasi. Toks skirtumas yra per sudėtingas banaliam *if-else* klasifikatoriui, tačiau turėtų būti klasifikuojami kokiais nors algoritmais kaip palaikomųjų vektorių mašinų (SVM) arba DNT pagrindu veikiančiais klasifikatoriais.

### 3.2.1 EEG pikų validavimas

Kaip jau minėta 3.2 pradinė EEG pikų parametrų paskirtis buvo jų validavimas. Yra tikrinami tokie parametrai [Sam13]:

- Piko pakilimo ir nusileidimo kampai turi turėti priešingus ženklus, po šios operacijos dirbama tik su absoliutinėmis jų reikšmėmis.
- Piko aštri banga turi trukti tarp 20 ms ir 80 ms
- Visas pikas turi trukti ne daugiau, negu 200 ms.

Tik tie pikai, kurie atitinka visus šiuos kriterijus yra nagrinėjami toliau. Piko pakilimo ir nusileidimo kampų ženklai yra toliau neanalizuojami, nes jie yra priklausomi vien tik nuo EEG matavimo aparato konfigūracijos, todėl neneša jokios svarbios informacijos, todėl patikrinus ar jie yra skirtingi, toliau imamos jų absoliučios reikšmės.

### 3.3 EEG klasifikavimo algoritmas

Šiame darbo skyrelyje aprašomas trečiasis ir paskutinis EEG klasifikavimo algoritmo žingsnis: EEG pikų klasifikatorius ir eksperimentai su juo.

#### 3.3.1 DNT klasifikatorius

Atsižvelgiant į tuos faktus, kad SVM klasifikatorius šiai problemai nesuveikė (žr. 3.3.2 skyrelį) ir DNT klasifikatorius tokio tipo problemai veikia geriau [PM08], šiai problemai buvo pritaikytas DNT pagrįstas klasifikatorius.

Buvo sukurtas vieno paslėpto sluoksnio pereptroninis DNT be atgalinio klaidų sklindimo (angl. *backpropagation*). Įvesties sluoksnį sudarė lygiai tiek neuronų, kiek kiekvienu atveju buvo įvesties parametrų, paslėptame sluoksnyje buvo 20 neuronų, išvesties sluoksnį sudarė 1 neuronas (nes buvo vienintelis išvesties parametras 0 - Grupei I ir 1 - Grupei II). Apmokymui buvo naudotas normuotas konjugacinis gradientas (angl. *Scaled conjugate gradient*) algoritmas.

Kaip aktyvavimo funkcija pradžioje buvo naudota sigmoidinė funkcija, tačiau susidurta su tuo, kad šia funkcija pagrįsti neuronai apmokomi lėtai. DNT apsimokydavo tik per 300-500 epochų, galutinis patikimumas gana stipriai keisdavosi priklausomai nuo pradinių svorių, kurie buvo pasirinkti atsitiktinai. Sigmoidinio neurono lėtas mokymasis yra gerai žinoma problema [Nie15], todėl buvo pritaikyta kros entropijos kainos funkcija (kuri yra minimizuojama) [Nie15]:

$$C = -\frac{1}{n} \sum_x \left[ y \ln a + (1 - y) \ln (1 - a) \right], \quad (1)$$

čia  $n$  yra mokymosi imties dydis, sumuojama per visus mokymosi imties elementus  $x$ ,  $y$  yra norimas rezultatas ir  $a$  aktyvavimo funkcija. Buvo pritaikyta taip vadinama softmax



aktyvavimo funkcija [Nie15]

$$a_j^L = \frac{e^{z_j^L}}{\sum_k e^{z_k^L}}, \quad (2)$$

kaip aktyvavimo funkcija  $j$ -ajam neuronui  $L$ -ajame sluoksnyje, čia

$$z_j^L = \sum_k w_{jk}^L a_k^{L-1} + b_j^L, \quad (3)$$

$w_{jk}^L$  yra svoris nuo  $k$ -tojo neurono praėjusiam sluoksnyje ( $L - 1$ -ajame) į  $j$ -ąjį neuroną esamame ( $L$ -ajame) sluoksnyje,  $b_j^L$  yra  $j$ -ojo neurono slenkstinis parametras (angl. *bias*)  $L$ -ajame sluoksnyje,  $a_L^j$  aktyvacijos funkcija  $j$ -ojo neurono  $L$ -ajame sluoksnyje,  $a_k^{L-1}$  yra aktyvacijos funkcija  $k$ -ajam neuronui ankstesniame ( $L - 1$ ) sluoksnyje. Eksperimentai įvairiomis aktyvavimo funkcijomis (pvz. sigmoidine) parodė, kad (1) ir (2) kombinacija veikia geriausiai.

Efektyvus DNT mokymasis šiame darbe yra svarbus, nes daugėjant tiriamos grupės pacientų ir kartu didėjant duomenų imčiai jis bus mokomas iš naujo, ateityje neatmetama pridėti ir daugiau pacientų grupių.

### 3.3.2 SVM klasifikatorius

Atsižvelgiant į tai, kad SVM yra klasikinis binarinio klasifikavimo uždavinio sprendimo būdas, pirmiausia buvo išbandytas būtent šis klasifikatorius. Šiame darbe SVM klasifikatorius tepasiekė 50-52% patikimumą, kas yra statistinės paklaidos atsitiktiniam spėjimui ribose.


Tai veikiausiai atsitiko dėl kelių priežasčių, labiausiai tikėtina yra tai, kad EEG pikų serijos parametru debesis persidengia (žr. 3 pav. ir 4 pav.) ir aukštesnėse dimensijose, dėl ko SVM klasifikatorius negali jų atskirti. Antra priežastis yra ta, kad galbūt egzistuoja toks hiperpaviršius, kuriuo galima būtų atskirti minėtų parametru grupes, tačiau mes nežinome net apytikslės jo formos. Atsižvelgiant į šiuos faktus ir į tai, kad DNT klasifikatorius panašaus tipo problemoms vis tiek veikia geriau [PM08], galutiniam algoritmui buvo naudojamas DNT pagrindu veikiantis klasifikatorius.

## 4 Rezultatų aptarimas

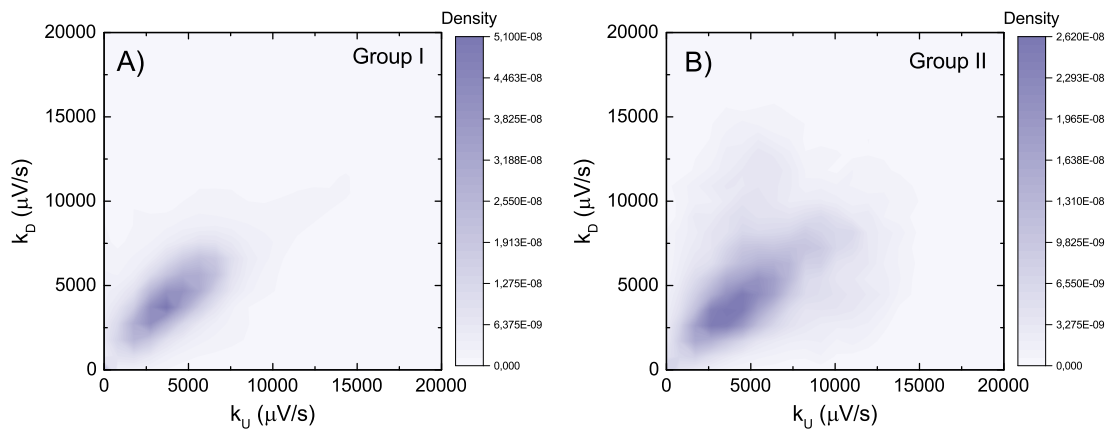
### 4.1 Statistinė analizė

Prieš pradėdant programuoti klasifikatorių buvo svarbu įsitikinti, kad EEG pikų parametrai tikrai neša kažkokią informaciją, ir, kad bus įmanoma patikrinti medikų iškeltą hipotezę (kad Grupės I pikai kinta mažiau negu Grupės II pikai). Pradinis šios hipotezės patikrinimas buvo atliktas pasinaudojant programiniu paketu OriginLab.

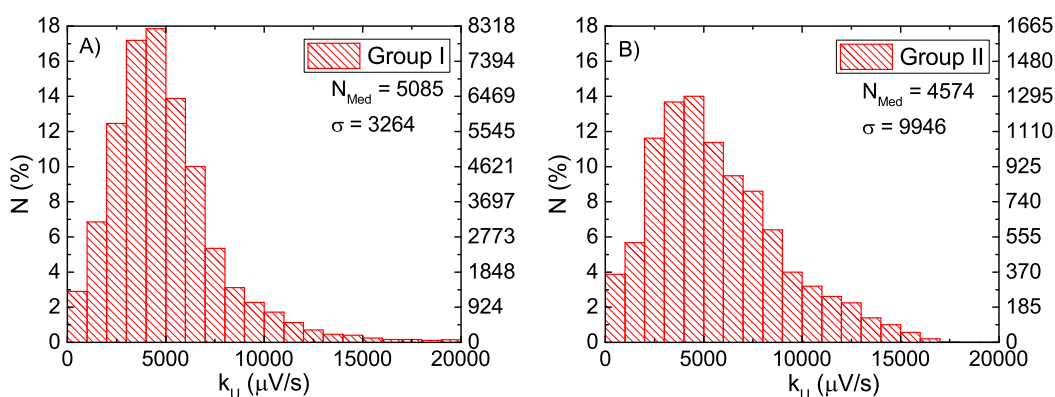
Nustatyta, kad EEG pikų parametru skirstiniai turi panašius vidurkius, tačiau jų standartiniai nuokrypiai skiriasi (žr. 5 pav. ir 6 pav.). Tai patvirtina iškeltą pradinę hi-



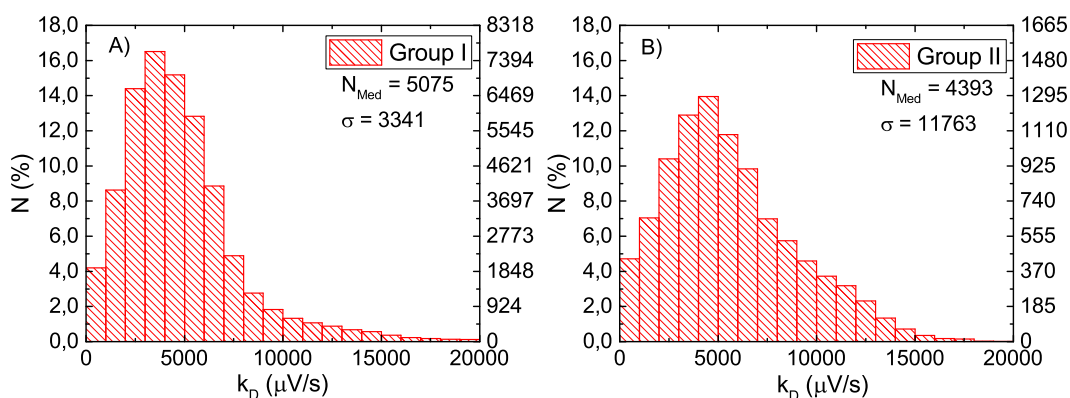
3 pav.: Pikų pakilimo ir nusileidimo kampų grafikas Grupės I ir Grupės II pacientams. Kaip matome taškai persidengia, jų vidurkis panašus tačiau išsibarstymas skiriasi. Tai iliustruoja kodėl su šiuo klasifikavimo uždaviniu geriausiai susidoroja DNT klasifikatorius.



4 pav.: EEG pikų pakilimo ir nusileidimo kampų branduolio tankio grafikas [Ori17].



5 pav.: Pikų pakilimo kampų (Grupės I ir Grupės II histograma). A) dalyje rodoma Grupės I histograma B) Grupės II histograma. Skirstinių vidurkiai yra panašūs, bet standartiniai nuokrypiai skiriasi.



6 pav.: EEG pikų nusileidimo kampų histograma. A) dalyje vaizduojami Grupės I rezultatai B) Grupės II. Šiuo atveju skirtumai mažesni, negu pakilimo kampų atveju, bet vis tiek matomi.

potezę, kad minėtų pacientų imčių statistiniai duomenys skiriasi, po to buvo pradėtas programuoti šiame darbe aptariamas klasifikatorius.

## 4.2 Eksperimentai su DNT klasifikatoriumi

Suprogramavus EEG klasifikatorių su juo buvo atlikti tam tikri eksperimentai. Visų pirma buvo siekta išsiaiškinti kokie EEG piko parametrai yra svarbiausi. Prisiminus 3.2 skyrelį ir [MMS16], yra nustatomi keli EEG piko parametrai: pakilimo kampas, nusileidimo kampas, bazinė linija, plotis pusaukštyje, piko ilgis ir vieta signale. Buvo atlikti eksperimentai su įvairiomis šių parametru kombinacijomis ir nustatyta, kad didžiausią įtaką rezultatui turi piko pakilimo ir nusileidimo kampas.

Taip pat buvo atlikti eksperimentai siekiant nustatyti optimalų parametru (pikų pakilimo ir nusileidimo porų) kiekį. Teoriškai kuo didesnis duomenų kiekis – tuo tiks-

lesnė diagnozė, ir tai yra tiesa šiam tyrimui. Tačiau praktiškai EEG yra riboto ilgio su ribotu pikų skaičiumi, todėl verta susirasti parametru skaičių, ties kuriuo patikimumas įsisotina. Šiam tikslui buvo padarytas toks eksperimentas: buvo apmokomas DNT ir nustatomas patikimumas imant nuo 1 iki 100 pikų serijas ir jų parametrus diagnozės nustatymui (žr. 7 pav.)

Nustatyta, kad EEG klasifikatorius gali veikti ir žinant tik vieną EEG piko parametru (pakilimo arba nusileidimo kampa), tačiau tokiu atveju jam reikia daug maž dvigubai daugiau pikų diagnozei nustatyti tokiu pačiu patikimumu. Nors algoritmo patikimumas įsisotina turint 50-100 EEG pikų duomenis, algoritmu galima naudoti ir su mažiau duomenų gaunant mažesnį patikimumo lygmenį (pvz. 25 pikai - 65% patikimumas).

Nustatyta, kad su optimaliu duomenų kiekiu klasifikatoriaus patikimumas - 72%. Nors tai iš pirmo žvilgsnio neatrodo kaip labai aukštas patikimumas, tačiau reikėtų turėti mintyje, kad medikai klasifikuodami tokius duomenis be ligos istorijos taip pat klysta, o nagrinėti buvo tik tie duomenys, kurie pasirodė sunkiai klasifikuojami ir patiems neurologams. Taip pat iš esmės nėra su kuo palyginti šį rezultatą, nes mūsų žiniomis tokio tipo klasifikatorių neegzistuoja (daugiausiai yra EEG pikų paieškos algoritmu žinomiems sergantiems pacientams ir sveikų/sergančių pacientų klasifikatorių). Taip pat testavimui buvo naudoti rankiniu būdu nuo artefaktų nevalyti duomenys, kas taip pat pablogina galutinį klasifikatoriaus rezultatą, tačiau geriau atspindi algoritmo veikimo situaciją realaus pasaulio taikymuose.

Tai yra iš esmės naujas rezultatas ir jo pagrindu yra ruošama mokslinė publikacija tarptautiniam periodiniam recenzuojamam leidiniui.

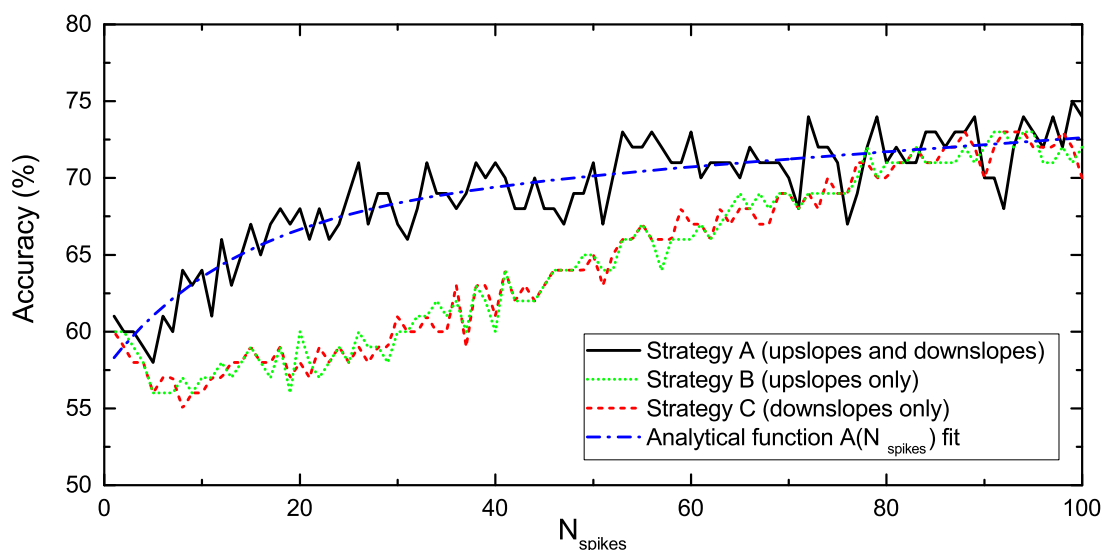
### 4.3 Įgyvendinimo priemonės

Pristatytas algoritmas įgyvendintas su Python 2.7.10 programavimo kalba, panaudojant NumPy [kb14], SciPy [kb09], OpenCV [kb15], Mpi4Py [Dal14] ir EdfTools [Red12] bibliotekas. Algoritmas buvo paleistas superkompiuteryje, Vilniaus Universiteto Matematikos ir Informatikos fakulteto Skaitinių tyrimų ir skaičiavimų centre.

## 5 Išvados ir pagrindiniai rezultatai

Šioje ataskaitoje pristatomi antrųjų doktorantūros metų moksliniai darbai ir jų rezultatai.

- Patobulintas EEG pikų parametru nustatymo algoritmas pakeičiant pikų parametru aproksimacijos sritį ir jos rišimą ne prie piko absoliutaus dydžio, o prie šalia esančio signalo triukšmo.
- Iškelta ir patikrinta hipotezė, kad EEG piko parametrai gali priklausyti nuo paciento diagnozės.



7 pav.: Klasifikavimo rezultatų demonstracija. Kaip matome pakilimo ir nusileidimo kampų porų ėmimas duoda geriausius rezultatus (Strategija A), kada parametrų ėmimas atskirai duoda prastesnius rezultatus (Strategijos B ir C). Nors kreivės laikui bėgant susilygina, vis tiek labiausiai apsimoka taikyti Strategiją A, ypač jei turimų duomenų kiekis yra ribotas.

- Sukurtas trijų žingsnių EEG klasifikavimo algoritmas, duodantis 72% patikimumą sąlygomis, panašiomis į realias su duomenimis, kurie sunkiai klasifikuojami (be ligos anamnezės) netgi patiems neurologams.

## Literatūros sąrašas

- [Dal14] L. Dalcin. MPI for Python, 2014.  
<http://mpi4py.scipy.org/>.
- [JBBS11] A. Juozapavičius, G. Bacevičius, D. Bugelskis, and R. Samaitienė. EEG analysis – automatic spike detection. *Nonlinear Analysis: Modelling and Control*, 16(4):375 – 386, 2011.
- [kb09] SciPy kūrėjų bendruomenė. Scipy reference guide, 2009.  
<http://docs.scipy.org/doc/scipy-0.7.x/scipy-ref.pdf>.
- [kb14] NumPy kūrėjų bendruomenė. Numpy reference, 2014.  
<http://docs.scipy.org/doc/numpy-dev/numpy-ref.pdf>.
- [kb15] OpenCV kūrėjų bendruomenė. Opencv api reference, 2015.  
<http://docs.opencv.org/modules/refman.html>.
- [Mis16] Andrius Vytautas Misiukas Misiūnas. Elektroencefalogramų analizės metodų tyrimas, 2016. Mokslinė ataskaita MII-DS-09P-16-1.

- [MMJ15] 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.
- [MMS16] 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.
- [Nie15] Michael A. Nielsen. *Neural Networks and Deep Learning*. Determination Press, 2015.
- [NNIS99] Shigeto Nishida, Masatoshi Nakamura, Akio Ikeda, and Hiroshi Shibasaki. Signal separation of background EEG and spike by using morphological filter. *IFAC Proceedings Volumes, 14th World Congress of IFAC*, 32(2):4301–4306, 1999.
- [Ori17] OriginLab Corp. Help online - labtalk programming - ks2density, 2017.
- [PM08] L. M. Patnaik and Ohil K. Manyam. Epileptic EEG detection using neural networks and post-classification. *Computer Methods and Programs in Biomedicine*, 91(2):100–109, 2008.
- [Red12] B. Redurnik. Eegtools, 2012.  
<https://raw.githubusercontent.com/breuderink/eegtools/master/README.md>.
- [Sam13] Rūta Samaitienė. Rolando epilepsija sergančių vaikų EEG pakitimų, miego bei elgesio sutrikimų ir klinikinių charakteristikų sąsajos. Vilniaus universitetas, 2013.
- [XWZ<sup>+</sup>07] Guanghua Xu, Jing Wang, Qing Zhang, Sicong Zhang, and Junming Zhu. A spike detection method in eeg based on improved morphological filter. *Computers in Biology and Medicine*, 37(11):1647 – 1652, 2007.
- [XWZZ06] G. Xu, J. Wang, Q. Zhang, and J. Zhu. EEG spike detection algorithm using morphological filter. *Proceeding of the 2006 IEEE International Conference on Automation Science and Engineering Shanghai, China, October 7–10, 2006*, pages 170 – 175, 2006.