



VILNIAUS UNIVERSITETAS  
MATEMATIKOS IR INFORMATIKOS FAKULTETAS  
INFORMATIKOS INSTITUTAS  
KOMPIUTERINIO IR DUOMENŲ MODELIAVIMO KATEDRA

Magistro baigiamasis darbas

## **Signalų analizė ir apdorojimas su automatizuotu apmokymu**

Atliko:

Agnė Dukšaitė

parašas

Vadovas:

prof. dr. Tadas Meškauskas

Vilnius  
2019

# Turinys

<b>Sutartinis terminų žodynas</b>	<b>4</b>
<b>Santrauka</b>	<b>5</b>
<b>Summary</b>	<b>6</b>
<b>Įvadas</b>	<b>7</b>
<b>1. Susijusių darbų apžvalga</b>	<b>9</b>
<b>2. Elektroencefalogramos ir jų taikymas</b>	<b>9</b>
2.1. EEG diagnostika ir CNS veikla . . . . .	10
2.2. EEG pikai ir jų aptikimas . . . . .	11
<b>3. Pagalbiniai įrankiai ir duomenys</b>	<b>12</b>
3.1. Pacientų EEG duomenys . . . . .	12
3.2. Programavimo kalbos pasirinkimas . . . . .	13
3.2.1. Naudotos bibliotekos . . . . .	13
3.3. Triukšmo šalinimas signaluose . . . . .	14
3.3.1. FFT taikymas . . . . .	14
<b>4. Morfolginiai filtrai EEG pikų aptikimui</b>	<b>15</b>
4.1. Struktūrinis elementas . . . . .	15
4.1.1. Parabolė . . . . .	15
4.2. Morfolginės operacijos . . . . .	16
4.3. Morfolginių operacijų kombinacijos taikymas . . . . .	16
<b>5. Dirbtinis neuroninis tinklas EEG pikų aptikimui</b>	<b>17</b>
5.1. DNT metodo pagrindinės teorinės sąvokos . . . . .	17
5.2. DNT aktyvacijos funkcijos . . . . .	18
5.3. Tiesioginio sklidimo neuroninis tinklas . . . . .	18
5.4. DNT mokymas . . . . .	19
5.4.1. Duomenų normalizavimas . . . . .	20
5.5. Klaidos atgalinis sklidimas . . . . .	20
5.6. DNT taikymas EEG analizei . . . . .	21
5.7. Konvoliucinis neuronų tinklas . . . . .	21
<b>6. Kompiuterinis įrankis EEG pikų aptikimui</b>	<b>23</b>
6.1. Morfolginių filtrų algoritmo įgyvendinimas ir testavimas . . . . .	23
6.1.1. Signalų atkarpos ilgis . . . . .	23
6.1.2. Pikų detekcijos ribos pasirinkimas . . . . .	24
6.1.3. Struktūrinio elemento ilgis . . . . .	24
6.1.4. Rezultatų apibendrinimas . . . . .	25
6.2. Dirbtinis neuroninis tinklas EEG pikų aptikimui . . . . .	26
6.2.1. DNT taikymas realiems pacientų duomenims . . . . .	27
6.2.2. DNT parametrų įtaka ir jų analizė . . . . .	28
6.2.3. DNT aktyvacijos funkcijos pasirinkimas . . . . .	32

6.2.4. Paslėptojo sluoksnio neuronų skaičius . . . . .	33
6.2.5. Morfologinių filtrų įtaka DNT tikslumui . . . . .	34
6.2.6. Konvoliucinis neuroninis tinklas . . . . .	35
6.2.7. Rezultatų apibendrinimas . . . . .	37
<b>Išvados ir rekomendacijos</b>	<b>38</b>
<b>Ateities tyrimų planas</b>	<b>40</b>
<b>Literatūros šaltiniai</b>	<b>41</b>

## Sutartinis terminų žodynas

- AUC – plotas po klasifikatoriaus ypatybių kreive (*angl. Area Under Curve*)
- CNS – centrinė nervų sistema (*angl. Central Nervous System*)
- DNT – dirbtinis neuronų tinklas (*angl. Artificial Neural Network*)
- EDF – Europos duomenų formatas (*angl. European Data Format*)
- EEG – elektroencefalograma (*angl. Electroencephalogram*)
- FFT – greitoji Furje transformacija (*angl. Fast Fourier Transform*)
- CNN – konvoliucinis neuronų tinklas (*angl. Convolutional Neural Network*)
- PSO – pasaulinės sveikatos organizacija (*angl. World Health Organization*)
- ROC – klasifikatoriaus ypatybių kreivė (*angl. Receiver Operating Characteristic*)

## Santrauka

Šiame darbe analizuojamos elektroencefalogramos (EEG) – pagrindinis įrankis diagnozuojant centrinės nervų sistemos (CNS) ligas, kurios pasižymi pikais. Supažindinama su jų sąvoka, reikšme ir svarba medicinoje, jose randamų pikų teorija bei galimybėmis automatizuoti apdorojimo procesą. Taip pat, apžvelgiami susiję darbai ir pasiekimai šioje srityje. Pirmoje praktinio darbo dalyje nagrinėjamas ir įgyvendinamas EEG pikų aptikimo algoritmas, kuris remiasi morfologinėmis operacijomis ir filtrais. Tiriamos optimalios algoritmo parametrų reikšmės. Antroje dalyje analizuojami ir EEG pikų aptikimui taikomi dirbtiniai neuronų tinklai (DNT) – daugiasluoksnis perceptronas bei konvoliucinis neuronų tinklas (CNN). Atliekami skirtingi testai su realiais duomenimis, siekiama išsiaiškinti, kurie parametrai turi įtakos DNT tikslumui, taip pat, kokios architektūros DNT pranašesnis EEG analizėje. Be to, siūloma galimybė sujungti abejose dalyse aptartus algoritmus. Siekiant iširti pateikto pasiūlymo tinkamumą, įgyvendintas hibridinis modelis, skirtas EEG pikų detekcijai.

# Summary

## **Analysis and Machine Learning for Signals Processing**

This paper focuses on electroencephalograms (EEG) – the main tools in diagnosis and treatment of specific neurological disorders characterized by epileptic seizures. Definition of EEG signals, significance in medicine field, theory of their peaks and possibilities to improve processing using computers were analysed during this work and described in this paper. First part of this work is dedicated to implementation of algorithm based on series of mathematical morphological operations and filters. This algorithm was selected because it filters out background activity, distinguishes centrottemporal spikes and has high reliability according scientific literature. Efficient parameters of this algorithm were analysed and applied. Testing and verification of implemented algorithm were done with real patients' electroencephalograms already fully analysed by doctors. Second part of this work focuses on theory and implementation of artificial neural networks (ANN). Two types of ANN are detailed in this paper – feedforward neural network and convolutional neural network. Practical tests using various parameters were investigated in order to achieve better results and precision of ANN. Also, both architectures of neural networks were compared to identify which one is more suitable for analysis of EEG. Moreover, an idea to combine algorithms mentioned in both parts – morphological filters and neural networks – was presented and analysed. On this purpose, a hybrid model for EEG peaks detection was implemented. Python programming language was used for implementation. Conclusions and observations are presented at the end of this paper. In general, experiments show that compared to algorithm based on morphological operations and filters ANN has achieved better results – approximately 90% of accuracy – in EEG peaks detection. However, results of hybrid model do not meet the expectations and no significant improvement was achieved.

## Ivydas

Dažnai net nesusimąstome, kiek daug reikšmingų signalų galime aptikti mus supančiame pasaulyje – iš meteorologijos, finansų, ekonomikos, medicinos ir kt. sričių. Signalai ypač svarbūs šių sričių specialistams, pavyzdžiui, meteorologams padeda prognozuoti orus, ekonomistams – vertinti būsimą pelną ar nuostolius, medikams – nustatyti žmogaus sveikatos būklę bei sutrikimus. Vienas svarbiausių uždavinių, su kuriuo susiduriama – kaip tiksliai atskirti, kuri signalo dalis yra reikšminga informacija, o kurią galima atmesti kaip triukšmą. Signalų analizės ir apdorojimo palengvinimui dažnai pasitelkiama kompiuterių pagalba, yra sukurta daug naudingų algoritmų.

Šiame darbe susitelkiama į medicinos sritį ir plačiau nagrinėjami medicininiai signalai. Įvairūs signalai medicinoje sutinkami itin dažnai, juos gydytojai gali gauti matuodami pulsą, atlikdami elektrokardiogramą, elektroencefalogramą ar kitus tyrimus. Būtent pastarųjų medicininį signalų – elektroencefalogramų – analizė yra pagrindinis šio darbo tikslas. Elektroencefalogramos (EEG) naudojamos epilepsijai ir įvairioms centrinės nervų sistemos (CNS) ligoms identifikuoti. Automatinis EEG apdorojimas yra labai svarbi problema šių dienų medicinoje, kadangi dažniausiai jos vertinamos rankiniu būdu. Tai reikalauja daug laiko ir pastangų, o nuo gautų išvadų gali priklausyti paciento būklė ir tolesnis gydymas. Dėl šios priežasties nekyla abejonių, kad automatizuoti įrankiai tikrai palengvintų medikų darbą – pagreitintų EEG analizę, minimizuotų klaidingų išvadų tikimybę ir taip netgi galėtų prisidėti prie efektyvaus paciento gydymo.

Vienas svarbiausių uždavinių EEG analizėje – pikų detekcija. Būtent pagal pikų kiekį, jų susitelkimo vietas ir charakteristikas gydytojai vertina paciento būklę, nustato diagnozę, skiria gydymą. Taigi, pikų svarba yra pagrindinis veiksnys, kuris skatina ieškoti efektyvių automatinio EEG apdorojimo būdų.

Šio darbo tikslas – realioms duomenims pritaikyti dviejų automatinų EEG apdorojimo būdų kombinaciją ir ištirti, ar toks pasirinkimas yra tinkamas pikų detekcijai. Pirmame etape pikai išryškunami, taikant EEG apdorojimo algoritmą, paremtą morfologinėmis operacijomis ir filtrais. Vertinami pagrindiniai algoritmo parametrai – signalo atkarpos ilgis, pikų detekcijos riba, struktūrinio elemento ilgis. Antrame etape pikų identifikavimas užbaigiamas dirbtinio neuronų tinklo (DNT) pagalba. Taikomi skirtingos architektūros dirbtiniai neuronų tinklai – daugiasluoksnis perceptronas bei konvoliucinis neuronų tinklas. Rezultatai vertinami analizuojant modelių tikslumą, klaidų matricą, kreivę, atspindinčią modelių jautrumo ir specifiškumo sąryšus, bei plotą po šia kreive.

Užsibrėžto tikslo siekiama įgyvendinant tokius uždavinius ir žingsnius:

1. Išanalizuoti elektroencefalogramas, jų taikymo sritis, diagnostiką;
2. Išanalizuoti elektroencefalogramų pikus, savybes ir jų aptikimo algoritmus;
3. Išanalizuoti dirbtinius neuroninius tinklus ir galimybes juos panaudoti EEG pikų aptikimui;
4. Įgyvendinti EEG pikų aptikimo algoritmą, paremtą morfologinėmis operacijomis ir filtrais;
  - Ištirti optimalius parametrus, su kuriais pikų kiekis būtų išryškintas geriausiai;
5. Įgyvendinti DNT, pritaikytą pikų aptikimui;
  - Pritaikyti daugiasluoksnį perceptroną pikų identifikavimui;
  - Pritaikyti konvoliucinį neuronų tinklą pikų identifikavimui;

- Ištirti struktūrą, parametrus ir sąlygas, su kuriomis pikų identifikavimas būtų tiksliausias;
6. Atlikti 4-ame ir 5-ame žingsniuose įgyvendintų algoritmų kombinacijos testavimą ir analizę su realiais pacientų duomenimis.

Pirmame skyriuje apžvelgiami šioje srityje atlikti tyrimai ir darbai. Antrame skyriuje bendrai aptiriamos elektroencefalogramos ir pikai. Trečias skyrius skirtas algoritmų įgyvendinimui reikalingų pagalbinių įrankių pristatymui. Toliau ketvirtame skyriuje analizuojamas pasirinktas EEG pikų algoritmas, paremtas morfologinėmis operacijomis ir filtrais. Penktame skyriuje nagrinėjami skirtingų struktūrų dirbtiniai neuroniniai tinklai, pagrindinės sąvokos ir parametrai. Paskutiniame, šeštame, skyriuje pateikiamos praktinės ketvirtame ir penktame skyriuose nagrinėtų algoritmų įgyvendinimo detalės ir įvertinami testavimo rezultatai. Išvadose apibendrinamos išvalgos ir rekomendacijos, o ateities tyrimų plane – aptarti darbai, kuriais būtų galima toliau tobulinti iškelto uždavinio sprendimą ir siekti pikų detekcijos tikslumo.

Šis magistro baigiamasis darbas yra tęstinis. Dalis uždavinių buvo išspręsti mokslo tiriamajame darbe. 1, 2, 4, 5 skyrių informacija paimta iš mokslo tiriamojo darbo bei atnaujinta ir papildyta. Taip pat, algoritmo, paremto morfologinėmis operacijomis ir filtrais, pagrindinė dalis, aptariama 6 skyriaus 6.1 poskyryje, buvo įgyvendinta mokslo tiriamajame darbe. Tęsiama darbo rezultatai – minėto algoritmo tyrimas su naujausiais duomenimis, gilesnė DNT analizė, įgyvendinimas ir testavimas bei hibridinio modelio sukūrimas pikų detekcijai.



# 1. Susijusių darbų apžvalga

Apie elektroencefalogramų analizę ir jų apdorojimo automatizavimą parašyta nemažai mokslinių straipsnių. Pristatoma vis daugiau naujos informacijos ir pasiūlymų – tai įrodo, kad ši tema aktuali iki šiol. Šiuo metu visus egzistuojančius EEG analizės algoritmus galima suskirstyti į kelias kategorijas [14], pagrindinės yra šios: bangų transformacijos, spektrinės analizės, dirbtinių neuronų tinklų ir parametriniai bei šablono atitikties metodai. Tačiau, nepaisant technologijų plėtros ir tobulėjimo, pilnas EEG pikų aptikimo automatizavimas yra sudėtingas uždavinys dėl įvairių priežasčių. Pirmiausia, automatizavimo algoritmams apmokyti kuo tiksliau atpažinti pikus yra reikalingas didžiulis duomenų kiekis. Be to, svarbus duomenų teisingumas, pikų pavyzdžių tikslumas. Galiausiai, netgi esant pakankamam duomenų kiekiui, reikalingas bendradarbiavimas su medicinos ekspertais, nes kiekvieno paciento atvejis yra specifinis ir galutinei diagnozei priimti rekomenduojama įvertinti kelių gydytojų nuomones [32].

Vieni iš pirmųjų bandymų išryškinti EEG pikus buvo aprašyti dar 1976m. [3] Originalus šiame darbe nagrinėjamas pikų aptikimo algoritmas, paremtas morfologinėmis operacijomis ir filtrais, pristatytas konferencijoje, Kinijoje, 2006m. [33] Nuo tada buvo stengiamasi šiam algoritmui surasti optimalius parametrus – ši užduotis plačiai nagrinėjama ir pasiekta gerų rezultatų: [18], [26]. Algoritmas pasižymi tuo, kad morfologinių operacijų pagalba smegenų foninė veikla yra nufiltruojama, o ligos pikai išryškinami. Nagrinėjamoje literatūroje skelbiamas gana aukštas algoritmo tikslumas – 91, 62% [33].

Kitas, šiomis dienomis aktualus ir daug žadantis automatizavimo metodas – dirbtiniai neuroniniai tinklai (DNT). Nuo pat pirmojo pasiūlymo panaudoti dirbtinius neuroninius tinklus EEG analizei [21], šis metodas laikomas vienu iš efektyviausių būdų, galinčių padėti automatizuoti EEG apdorojimą. Pagrindinės darbų kryptys:


- DNT panaudojimas neapdorotoms EEG [29];
- DNT panaudojimas iš anksto apdorotoms EEG [31].

DNT algoritmai yra vieni iš plačiausiai nagrinjamų metodų, kadangi jų pikų aptikimo tikslumas yra gana didelis [13], o tobulėjančios technologijos suteikia galimybes šiuos algoritmus efektyviai realizuoti. Dėl to, vis dažniau bandoma automatinei EEG analizei taikyti ir konvoliucinius neuronų tinklus [1]. Taigi, būtent dėl tokių priežasčių, šio darbo pagrindinė idėja yra su tuo glaudžiai susijusi – tiriami DNT panaudojimo būdai iš anksto morfologinėmis operacijomis ir filtrais apdorotoms EEG.

## 2. Elektroencefalogramos ir jų taikymas

Remiantis tyrinėjimais, manoma, kad galvos smegenų signalai atspindi ne tik pagrindines smegenų funkcijas, bet taip pat gali suteikti informacijos apie bendrą žmogaus sveikatos būklę. Pasaulinės sveikatos organizacijos (PSO) duomenimis, egzistuoja apie 50 milijonų žmonių, sergančių įvairiomis epilepsijos formomis. Toks mąstymas ir statistiniai duomenys pabrėžia elektroencefalogramų (EEG) reikšmę medicinoje – jos yra vienas iš svarbiausių smegenų veiklos matavimo įrankių ir pagrindinė priemonė, kurios pagalba gali būti diagnozuojama epilepsija, miego sutrikimai, nervų, psichikos ligos ir kiti smegenų pažeidimai [30].

Pagal bendrinę apibrėžimą, EEG – tai galvos smegenų aktyvumo užrašas. Būtent, gydytojai analizuoja šiuos užrašus ir stebi smegenų veiklą, ritmus, ieško epileptoforminių pikų, kurie bus plačiau nagrinėjami skyriuje 2.2.



1 pav. Elektrodo išdėstymas pagal tarptautinę 10-20 EEG nuskaitymo sistemą. Žymėjimas: "INION" – žemiausia pakaušio dalis, "NASION" – žemiausia kaktos dalis. Lyginiais skaičiais numeruojami dešinės galvos pusės kanalai, o nelyginiais – kairės. Raidės "F", "T", "C", "P", "O" atitinka priekinę, smilkinių, centrinę, pakaušio, išorinę sritis, o raidėmis "A" pažymėta ausų vieta. Iliustracija viešai prieinama Wikimedia Commons [4].

## 2.1. EEG diagnostika ir CNS veikla

EEG diagnostikos pradžia galime laikyti 1924-uosius metus, kai žymus šios srities specialistas, psichiatras Hansas Bergeris (*Hans Berger*, 1873 – 1941) pirmą kartą atliko šį tyrimą žmogui, o gautus rezultatus pristatė publikacijoje 1929-aisiais metais [30].

EEG yra neinvazinis tyrimas, atliekamas paviršinių elektrodų pagalba, kurie yra tvirtinami prie paciento galvos. Dažniausiai pasaulyje naudojama tarptautinė 10-20 EEG nuskaitymo sistema, vaizduojama 1 pav. Čia naudojamas 21 elektrodas-kanalas, kiekvienas iš jų turi savo pavadinimą ir tikslią vietą. Tokia sistema palengvina tyrimo struktūros išlaikymą ir užtikrina galimybę lengvai gauti, atkurti, lyginti bei tirti paciento rezultatus. Tyrimo metu kiekvienas elektrodas tam tikrą laiko tarpą fiksuoja ir surenka įtampos pokyčių duomenis. Pavyzdžiui, pacientams, besigydantiems namuose, EEG tyrimo trukmė yra apie 20 minučių, tačiau stacionariai gydomiems ligoniams gali būti atliekami detalūs tyrimai, trunkantys ir keliolika valandų.

Be to, atitinkamai pagal siekiamą diagnozuoti ligą, elektroencefalograma gali būti matuojama pacientui esant skirtingose būsenose - tiek miego, tiek budrumo. Dažniausiai tyrimas atliekamas pasyvioje būsenoje – pacientas turėtų būti nemiegantis, tačiau budrus, izoliuotas nuo triukšmo, ryškios šviesos. Nuo būsenos priklauso bangų dažniai, kurie taip pat keičiasi kartu su paciento amžiumi. Esant normaliai centrinės nervų sistemos (CNS) veiklai, šie dažniai irgi yra įvairūs bei kinta priklausomai nuo būsenos. Pagal tai smegenų bangos dažniausiai skirstomos į penkias ritmų grupes – alfa ( $\alpha$ ), beta ( $\beta$ ), gama ( $\gamma$ ), delta ( $\delta$ ), ir teta ( $\theta$ ), kurios išsamiau aprašytos 1 lentelėje [28].

Pavadinimas	Dažnis	Būsena
$\delta$ ritmas	3, 5 Hz ir mažiau	Pasireiškia gilaus miego būsenoje. Suaugsiems žmonėms pastebimas galvos smegenų priekyje, o vaikams – galinėje dalyje.
$\theta$ ritmas	4 – 7, 5 Hz	Pasireiškia mieguistumo, miego būsenoje arba gilios meditacijos metu.
$\alpha$ ritmas	8 – 13 Hz	Pasireiškia atsipalaidavimo būsenoje, užmerktomis akimis. Pastebimas žmogaus galvos smegenų galinėje dalyje.
$\beta$ ritmas	14 – 30 Hz	Pasireiškia mąstymo, susikaupimo būsenoje. Pastebimas žmogaus galvos smegenų priekinėje dalyje bei šonuose.
$\gamma$ ritmas	30 Hz ir daugiau	Pasireiškia retai.

1 lentelė. Smegenų aktyvumo ritmai

## 2.2. EEG pikai ir jų aptikimas


Atlikus EEG tyrimą, gydytojai vizualiai tikrina gautą smegenų aktyvumo užrašą, bando identifikuoti neįprastą smegenų veiklą ar rasti nebūdingų padidėjusio aktyvumo požymių. Kai kurioms ligoms yra būdingi epileptiforminiai pikai, kuriuos ne visada lengva atpažinti be papildomų įrankių ar skaičiavimų, kadangi jie gali būti vizualiai panašūs į įvairius artefaktus. Tokių ligų pavyzdys – epilepsija. Tai viena iš centrinės nervų sistemos ligų, kuriai būdingi pasikartojantys ir nekontroliuojami priepuoliai, sukelti elektrinės smegenų iškrovas, kurios lemia sutrikimus elektroencefalogramose. Taigi, EEG yra pagrindinis įrankis tokių ligų tyrime. Šiame darbe plačiau nagrinėjama vaikams būdinga epilepsijos forma – Rolando epilepsija. Jos sukeltų pikų pavyzdys yra matomas elektroencefalogramose 2 pav.

Neretai gydytojams sunku identifikuoti pikus dėl įvairios kilmės artefaktų, kas tuo pačiu apsunkina ir automatizavimo algoritmų darbą [30]. Pavyzdžiui, išoriniai nuolat pasitaikantys artefaktai – elektroninė įranga, elektros tinklo triukšmai (50 Hz) ar trikdžiai, netvarkingi elektros laidai, ir vidiniai – žmogaus judesiai, akių mirkčiojimas, širdies veikla, taip pat neperiodinis smegenų aktyvumas. Smegenyse vyksta daugybė sudėtingų neperiodinių procesų, tačiau minėtų ligų diagnostavimui – jie neturi svarbios reikšmės ir netgi apsunkina ieškomų pikų identifikavimą, todėl yra laikomi triukšmu.

EEG analizėje svarbu tiksliai apibrėžti, koks darinys yra laikomas pikų, dėl to yra keliami reikalavimai. Tam, kad EEG pikas būtų užregistruotas, jis turi tenkinti tokius morfologinius reikalavimus [28]:

- pikas privalo tęstis bent 40 ms, bet ne daugiau nei 200 ms;
- pikas turi iškilti bent du kartus virš foninio smegenų aktyvumo;
- pikas turi atsikartoti bent dvejuose kaimyniniuose kanaluose;
- dažnai aptinkamas C4/C3 kanaluose.

Tokie pikai taip pat pasižymi aukšta amplitude (100 – 300  $\mu V$ ), dažnai juos lydi lėta iškrovos banga, gali būti aptinkami skirtingose galvos srityse tiek pavieniai, tiek grupėse.



2 pav. EEG signalų pavyzdžiai, matuojami mikrovoltais per milisekundę. Vaizduojami 5 kaimyniniai kanalai. Pikas matomas maždaug ties 34,8 sekunde. Jis pažymėtas plona raudona linija.

### 3. Pagalbiniai įrankiai ir duomenys

#### 3.1. Pacientų EEG duomenys

Kaip buvo minėta, šiame darbe nagrinėjamos vaikų, kuriems diagnozuota Rolando epilepsija, elektroencefalogramos. Duomenys gauti iš vaikų ligoninės, priklausančios viešajai įstaigai Vilniaus universiteto ligoninės Santaros klinikų filialui. Duomenys saugomi Europos duomenų formatu (EDF). Tai standartinis failų formatas, tinkamas biologinės ir fizinės kilmės signalams archyvuoti [2].

Iš viso gauta daugiau nei 100 elektroencefalogramų, iš kurių 21 turi detalius aprašymus, informaciją apie pikus – nurodytą vietą, sužymėtus kaimyninius kanalus, pikų skaičių tam tikrose minutėse. Papildoma informacija apie pacientų lytį taip pat žinoma, tačiau tikslus amžius nėra nurodytas.

Svarbiausios ir šiame darbe nagrinėjamos elektroencefalogramos – gydytojų sužymėtos su tiksliais pikų koordinatėmis. Darbe laikoma, kad turima informacija apie pikų vietas laike yra korektiška ir neturi klaidų. Duomenų apibendrinimas pateiktas 2 lentelėje. Visa turima informacija naudojama algoritmų testavimuose, kas padeda nustatyti parametrų tinkamumą ir įvertinti gaunamus rezultatus.

Skirtingų pacientų skaičius	Kanalų skaičius	Vidutinė EEG trukmė	Iš viso pažymėta
12	21 arba 26	50 min	929 pikų

2 lentelė. Nagrinėjamų EEG duomenų apibendrinimas


## 3.2. Programavimo kalbos pasirinkimas

Darbo praktinė dalis – signalų apdorojimas, vizualizavimas, algoritmų įgyvendinimas ir testavimas – atlikta Python (3.6) atvirojo kodo programavimo kalba. Šį pasirinkimą lėmė kelios priežastys. Python programavimo kalba yra lengvai suprantama, turi visas reikiamas papildomas bibliotekas, kurios nesunkiai įdiegiamos. Dėl to praktinė dalis nėra apkrauta nereikalingais skaičiavimais, o vartotojui patogiu tokį programinį kodą skaityti ir analizuoti.

### 3.2.1. Naudotos bibliotekos

Praktinė dalis buvo realizuota naudojantis tokiomis papildomomis Python bibliotekomis:

- Matplotlib – tai Python braižymo biblioteka, skirta kokybiškam funkcijų vizualizavimui ir 2D grafikų kūrimui [16]. Šiame darbe naudojami vizualūs pavyzdžiai sukurti šios bibliotekos pagalba.
- NumPy – tai vienas iš pagrindinių Python paketų, skirtų moksliniams skaičiavimams, efektyviam darbui su duomenų masyvais [8]. Šį paketą naudoja ir kitos Python bibliotekos, tokios kaip SciPy, Matplotlib. Darbe buvo naudojamos įvairios matematinės funkcijos, esančios šiame pakete – eksponentinė funkcija (*exp*), greitosios Furje transformacijos funkcijos (*FFT*) ir kitos.
- PyEDFlib – tai Python biblioteka, kurios pagalba yra skaitomos Europos duomenų formato (EDF/EDF+) bylos [27]. Šiuo įrankiu nuskaitytos darbe nagrinėjamos EEG.
- SciPy – tai didelis Python paketas, skirtas matematiniais, moksliniais, inžineriniams skaičiavimams [9]. Darbe buvo pasinaudota šioje bibliotekoje esančiomis morfologinėmis operacijomis, kurių pagalba buvo įgyvendintas algoritmas, paremtas morfologiniais filtrais.
- Keras – tai dirbtinių neuroninių tinklų (DNT) valdymo biblioteka [7]. Darbe buvo pasinaudota šia biblioteka tam, kad įvertinti, ar įgyvendintas DNT algoritmas veikia korektiškai. Taip pat, ši biblioteka suteikia galimybę dirbti ir lengvai valdyti konvoliucinius neuroninius tinklus.
- Theano – tai greito, gerai optimizuoto skaičiavimo biblioteka, galinti naudoti tiek centrinio procesoriaus (*angl. Central Processing Unit – CPU*), tiek grafikos plokštės (*angl. Graphics Processing Unit – GPU*) išteklius [10]. Taip pat, Theano biblioteka yra vienas iš pagrindinių įrankių, naudojamų gilaus mokymosi algoritmų įgyvendinime. Šiame darbe Theano pasirinktas kaip pagrindas dirbtinių neuroninių tinklų kūrimui, kurie gali būti lengvai valdomi aukščiau paminėtos bibliotekos Keras pagalba. Vienas iš faktorių lėmusių tokį pasirinkimą yra pačios bibliotekos Theano, programavimo kalbos Python (3.6) ir operacinės sistemos (*Windows 10*) versijų suderinamumas.
- scikit-learn – tai automatizuoto apmokymo Python biblioteka [5], kuria galima paprastai įgyvendinti duomenų analizės uždavinius. Šiame darbe keliuose testuose buvo panaudotas įrankis, esantis šioje bibliotekoje, skirtas atsitiktinių dirbtinio neuronų tinklo apmokymo imčių parinkimui.



3 pav. Kairėje vaizduojamas EEG kanalo  $P3 - RF$  spektras prieš  $50Hz$  komponentės pašalinimą, o dešinėje – po pašalinimo.

### 3.3. Triukšmo šalinimas signaluose

EEG signalų kokybė dažnai priklauso nuo įvairių pašalinių veiksnių. Kaip buvo minėta 2.2 skyriuje, nepageidautiną triukšmą signale gali lemti tiek vidiniai, tiek išoriniai veiksniai. Vienas iš dažniausiai pasitaikančių išorinių veiksnių – elektros tinklo triukšmai [30]. Siekiant išvengti šio tipo triukšmų, EEG analizėje rekomenduojama taikyti Furje filtrus  $50Hz$  komponentės nufiltravimui.

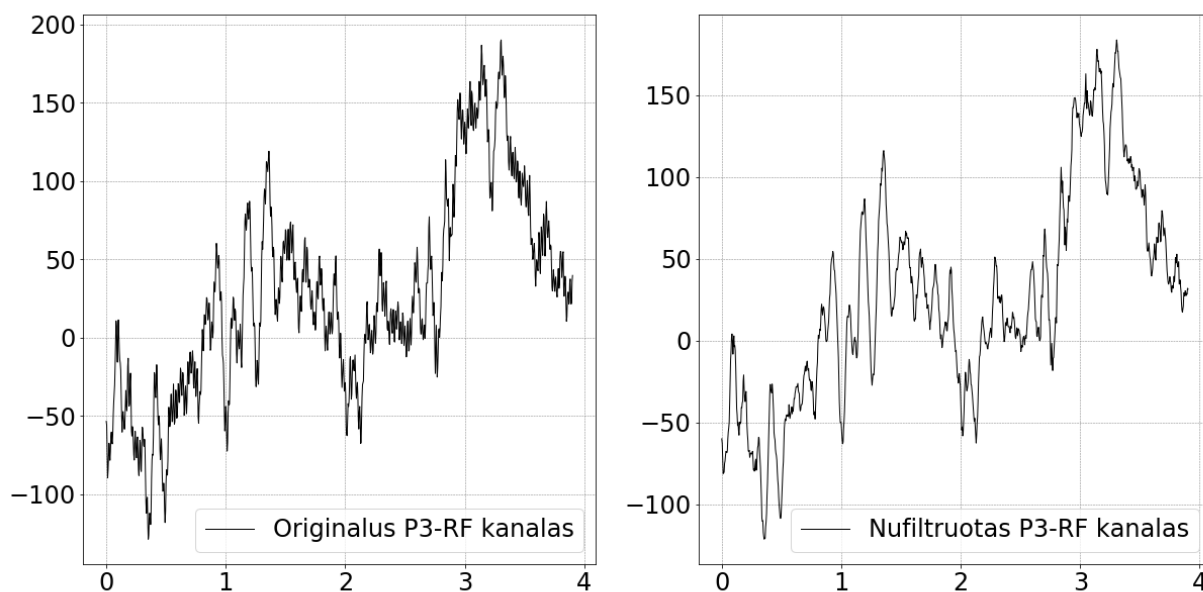
#### 3.3.1. FFT taikymas

$50Hz$  elektros tinklo triukšmo šalinimo procedūra nėra sudėtinga, tačiau svarbi ir naudinga, kadangi šiuo triukšmu yra paveikiami visų kanalų duomenys. Tam, kad jį nufiltruoti, darbe buvo panaudotas greitosios Furje transformacijos (*angl. Fast Fourier Transform – FFT*) algoritmas.

Šiuo filtru apdorojamos ne pačios signalo reikšmės, o jo spektras. Vieno paciento EEG signalo spektro pavyzdys pateikiamas 3 pav.

Šiame pavyzdyje galime pamatyti ir įsitikinti, kad egzistuoja spektro reikšmių šuolis ties  $50Hz$ . Ne visų pacientų EEG signalų spektruose galime pamatyti tokį akivaizdų šuolį, kadangi EEG tyrimas galėjo būti atliktas skirtingomis aplinkybėmis ar naudojant skirtingus matavimo aparatus. Nepaisant to, toliau šiame darbe nuspręsta visoms nagrinėjamos EEG taikyti FFT filtrą.

Siekiant efektyvaus ir greito algoritmo veikimo, Furje filtras įgyvendintas naudojantis Python biblioteka NumPy [8]. Signalų reikšmės iš pradžių transformuojamos į Furje koeficientus ir surandami atitinkami dažniai. Taigi, nagrinėjamu atveju, atlikus Furje transformaciją, surandami  $49,5 - 50,5Hz$  dažnius atitinkantys elementai ir prilyginami nuliams. Tada atvirkštinės Furje transformacijos pagalba signalo reikšmės transformuojamos atgal.



4 pav. Kairėje vaizduojamas originalus EEG kanalo  $P3 - RF$  signalas, o dešinėje – tas pats signalas po  $50Hz$  komponentės pašalinimo, naudojant FFT filtrą. Matavimo vienetai: mikrovoltai per milisekundę.

FFT filtro veikimo pavyzdys pateikiamas 4 pav. Matome, kad FFT filtras signalo žymiai nepakeičia, tačiau pašalindamas triukšmą pagerina jo kokybę.

## 4. Morfolginiai filtrai EEG pikų aptikimui

Taigi, įvairiais metodais siekiama palengvinti EEG analizę, automatizuoti pikų atpažinimo procesą. Šiame darbe nagrinėjamas pikų aptikimo algoritmas, pasižymintis morfolginėmis operacijomis ir filtrais. Tai vienas iš patikimiausių tokio tipo algoritmų, pasižymintis dideliu tikslumu [18]. Be to, šio algoritmo vykdymo metu EEG pikai išryškinami, o foninė smegenų veikla nufiltruojama.

Toliau šiame skyriuje apžvelgiami svarbiausi algoritmo įgyvendinimo žingsniai.

### 4.1. Struktūrinis elementas

Svarbus uždavinys įgyvendinant algoritmą – struktūrinio elemento pasirinkimas.

#### 4.1.1. Parabolė

Remiantis literatūra [18] ir jau atliktais darbais, galime teigti, kad geriausiai foninį smegenų aktyvumą aprašo – parabolė, kadangi smegenų veiklai būdingi periodiniai ritmai. Parabolė konstruojama tokiu būdu:

$$g_i(t) = a_i t^2 + b_i, \quad i = 1, 2. \quad (4.1)$$

Parabolės koeficientai apskaičiuojami taip:

$$a_1 = \frac{\text{median}(|f|)}{0.5\text{median}(W)}, \quad a_2 = \frac{\text{median}(|f|)}{1.5\text{median}(W)}, \quad b_1 = b_2 = \text{median}(|f|), \quad (4.2)$$

kur  $W$  – signalo arkų pločiai, o  $|f|$  – signalo aukščių amplitudės.

## 4.2. Morfologinės operacijos

Pagrindinės morfologinės operacijos, kuriomis remiasi nagrinėjamas algoritmas, yra morfologinis susiaurinimas ir morfologinis išplėtimas.

Pažymėkime turimą signalą  $f(t)$ , struktūrinį elementą  $g(t)$  ir jo atspindį  $g^s(t) = g(-t)$ . Laikykime  $D$  signalo  $f(t)$  apibrėžimo sritimi. Tada, morfologinis susiaurinimas aprašomas formule:

$$(f \ominus g^s)(t) = \min_{\tau \in D} \{f(\tau) - g(-(t - \tau))\}, \quad (4.3)$$

o morfologinis išplėtimas aprašomas taip:

$$(f \oplus g^s)(t) = \min_{\tau \in D} \{f(\tau) + g(-(t - \tau))\}. \quad (4.4)$$

Naudodami pateiktas formules, galime išvesti dvi operacijas – morfologinio uždarymo:

$$(f \circ g)(t) = [(f \ominus g^s) \oplus g](t) \quad (4.5)$$

ir morfologinio atidarymo:

$$(f \bullet g)(t) = [(f \oplus g^s) \ominus g](t). \quad (4.6)$$

Tiek neigiamų, tiek teigiamų EEG pikų atpažinimui, reikalinga apibrėžti dar dvi naujas operacijas – uždarymo-atidarymo:

$$CO(f(t)) = f(t) \bullet g_1(t) \circ g_2(t) \quad (4.7)$$

bei analogiškai atidarymo-uždarymo:

$$OC(f(t)) = f(t) \circ g_1(t) \bullet g_2(t). \quad (4.8)$$

## 4.3. Morfologinių operacijų kombinacijos taikymas

Uždarymo-atidarymo operacija (4.7) pakelia signalo reikšmes, o atidarymo-uždarymo operacija (4.8) – sumažina. Dėl tokios signalo deformacijos gali atsirasti netikslumų pikų aptikime, todėl sukuriamas kombinuotas morfologinis filtras:

$$OCCO(f(t)) = \frac{OC(f(t)) + CO(f(t))}{2}. \quad (4.9)$$

Pritaikius morfologinį filtrą, gaunamas signalas  $x(t)$ :

$$x(t) = |f(t) - OCCO(f(t))|, \quad (4.10)$$


kuriame foninis smegenų aktyvumas nufiltruotas, o pikai išryškinti.



## 5. Dirbtinis neuroninis tinklas EEG pikų aptikimui

Dėl besivystančių naujų technologijų, kompiuterių, kurie geba atlikti sudėtingus skaičiavimus, apdoroti didelius duomenų kiekius ir tą daryti dideliu greičiu, sparčiai auga automatizuoto apmokymo populiarumas. Tai dirbtinio intelekto sritis, kur algoritmai prisitaiko prie pateiktų duomenų ir mokosi iš ankstesnių skaičiavimų be žmogaus įsikišimo. Automatizuotas apmokymas plačiai naudojamas tokiose srityse kaip vaizdų ir balsų atpažinimas, paieškos sistemos, robotų judėjimas, žaidimų kūrimas, ligų diagnozavimas ir kt. Žymiausi ir plačiausiai taikomi algoritmai – dirbtinis neuronų tinklas (*angl. Artificial Neural Network*), sprendimų medis (*angl. Decision Tree*), Bajeso tinklai (*angl. Bayesian Networks*). Atsižvelgiant į programavimo kalbas, yra sukurta nemažai kompiuterinių įrankių, bibliotekų, padedančių vykdyti automatizuoto apmokymo algoritmus, pavyzdžiui tokie *Python* plėtiniai kaip *SciKit-Learn*, *Keras*, *TensorFlow*, *Theano* ir kt. Pasirinktos naudoti programos aprašytos skyriuje 3.2.1.

Taigi, šiame darbe aptariamas vienas iš automatizuoto apmokymo algoritmų – dirbtinis neuronų tinklas (DNT) [15] klasifikavimo užduočiai spręsti. Toliau bus nagrinėjamas būtent šis algoritmas, bus supažindinama su pagrindinėmis sąvokomis, tipais, apmokymo ir testavimo procesais.



5 pav. DNT neurono modelis. Iliustracija pagal [15].

### 5.1. DNT metodo pagrindinės teorinės sąvokos

Dirbtinis neuroninis tinklas (DNT) – tai tarpusavyje sujungti dirbtiniai neuronai, kurie atlieka panašų darbą kaip ir žmogaus galvos smegenys. Dirbtinis neuronas – biologinio neurono abstrakcija – tai funkcija, kuri turi baigtinį skaičių įvesties reikšmių ir vieną išvesties reikšmę. Kiekviena įvesties reikšmė ( $x_1, x_2, \dots, x_n$ ) turi savo perdavimo koeficientą – svorį ( $w_{k1}, w_{k2}, \dots, w_{kn}$ ). DNT neurono modelis pateikiamas 5 pav. Čia  $v_k$  reikšmė apskaičiuojama pagal formulę:

$$v_k = \sum_{i=0}^m w_{ki}x_i + b_k,$$

kur  $b_k$  yra poslinkis, o  $m$  – įvesties duomenų skaičius. Gauta  $v_k$  reikšmė toliau perduodama aktyvacijos funkcijai  $f$ , kurios rezultatas yra išvesties reikšmė  $y_k$ . Kitame skyriuje nagrinėjamos skirtingos aktyvacijos funkcijos, kurios gali būti panaudotos išvesties reikšmei rasti.

## 5.2. DNT aktyvacijos funkcijos

Aktyvacijos funkcijos pagalba apskaičiuojama DNT neurono išvesties reikšmė. Kitaip tariant, aktyvacijos funkcija nurodo, kokią reikšmę perduodame kitam DNT neuronui. Gali būti naudojamos įvairios aktyvacijos funkcijos, pavyzdžiui:

- žingsninė funkcija:

$$f(x) = \begin{cases} 0, & x \leq 0 \\ 1, & x > 0 \end{cases};$$

- sigmoidinė funkcija:

$$f(x) = \frac{1}{1 + e^{-x}};$$

- hiperbolinio tangento funkcija:

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}.$$

Čia  $f$  – aktyvavimo funkcija,  $x$  – įvesties reikšmė.

Šiame darbe pagrinde naudojamos sigmoidinė ir hiperbolinio tangento funkcijos, kurių rezultatai palyginami vėlesniuose skyriuose.


## 5.3. Tiesioginio sklidimo neuroninis tinklas

Nuo sprendžiamo uždavinio sudėtingumo, priklauso DNT sluoksnių skaičius ir neuronų skaičius juose. Neuroniniai tinklai gali būti skirstomi į vienasluoksnius ir daugiasluoksnius neuroninius tinklus.

Paprasčiausios architektūros neuroninis tinklas yra vadinamas perceptronu. Jį šeštajame dešimtmetyje sukūrė amerikiečių mokslininkas Frankas Rosenblatt (1928-1971). Tai tiesioginio sklidimo neuroninis tinklas, turintis po vieną įvesties ir išvesties sluoksnį. Tokį tinklą nesunku implementuoti, o jo apmokymas vyksta greitai, tačiau jis tinkamas tik nesudėtingiems klasifikavimo uždaviniams spręsti, kadangi rezultatas yra 0 (*ne*) arba 1 (*taip*).

Tinklai, kurie turi daugiau nei vieną sluoksnį, vadinami daugiasluoksniais perceptronais arba daugiasluoksniais tiesioginio sklidimo neuroniniais tinklais. Tokie tinklai tarp įvesties ir išvesties sluoksnių turi paslėptus neuronų sluoksnius. Įvesties sluoksnyje gaunami išoriniai duomenys, jie perduodami paslėptajam sluoksniui, kuriame yra apdorojami, tačiau rezultatai nėra matomi. Iš paslėptojo sluoksniu duomenys perduodami paskutiniam, išvesties, sluoksniui ir galutinis rezultatas siunčiamas iš neuronų tinklo. Tokių daugiasluoksnių tinklų struktūra yra sudėtingesnė, dėl to jų apmokymas užtrunka ilgiau, tačiau jie gali būti taikomi sudėtingų uždavinių sprendimui.

Aptartų rūšių neuroninių tinklų apibendrinta struktūra vaizduojama 6 pav.



6 pav. Dirbtinių neuroninių tinklų rūšys: kairėje vaizduojamas tiesinis vienasluoksnis neuroninis tinklas, o dešinėje – daugiasluoksnis. Iliustracija pagal [15].

## 5.4. DNT mokymas

Vienas iš esminių intelekto požymių – gebėjimas mokytis. Dirbtinis neuroninis tinklas, būtent, ir yra pagrįstas mokymusi. Šis procesas gali būti apibrėžtas kaip parametų keitimo uždavinys. Tikslas – rasti tokius parametrus, kad išvesties reikšmių ir tikrojo rezultato skirtumas būtų kuo mažesnis. Taigi, mokymosi metu nuolat perskaičiuojami dirbtinio neuronų tinklo parametrai – svoriai ( $w$ ) ir paslinkiai ( $b$ ). Yra trys pagrindiniai neuroninių tinklų apmokymo būdai:

- mokymas su mokytoju;
- mokymas be mokytojo;
- mokymas su paskatinimu.

Mokymas su mokytoju gali būti naudojamas, kai yra žinomos išvesties reikšmės. Tokiu atveju siekiama rasti parametrus, su kuriais skirtumas tarp ieškomų ir gaunamų išvesties reikšmių būtų kiek įmanoma mažesnis. Šiuo atveju svarbu turėti didelį apmokymui skirtų duomenų kiekį. Priešingu atveju – esant nepakankamam duomenų kiekiui – dirbtinis neuronų tinklas nesugebės išspręsti uždavinio. Tolesniuose darbuose, siekiant automatizuoti EEG apdorojimą, galėtų būti naudojamas mokymosi su mokytoju metodas.

Dažnai išvesties reikšmės nėra žinomos, tada naudojami mokymosi be mokytojo algoritmai. Tokiu atveju tinklui paduodamas tik įvesties sluoksnis ir jis pats turi ieškoti duomenų panašumų, reguliarumų ar ypatumų, neturėdamas teisingų atsakymų.

Mokymosi su paskatinimu atveju išvesties sluoksniis taip pat nėra žinomas, tačiau neuroniniam tinklui pranešama, ar gauta reikšmė teisinga, ar klaidinga. Parametrai perskaičiuojami, siekiant gauti kuo tikslesnį atsakymą, tačiau toks apmokymas užtrunka ilgiau.

#### 5.4.1. Duomenų normalizavimas

Svarbu ne tik apmokymo duomenų kiekis, bet ir jų ypatybės. Nuo duomenų priklauso dirbtinio neuronų tinklo apmokymo greitis, o taip pat ir rezultatai.

Vienų aktyvacijos funkcijų rezultatus kartais gali iškreipti per didelės reikšmės, kitų – neigiamos reikšmės. Pavyzdžiui, remiantis pav. matome, kad hiperbolinio tangento aktyvacijos funkcijos atveju, esant vien tik didelėms duomenų reikšmėms ir jų sumoms, į kito sluoksnio neuronus bus paduodama tik  $-1$  ir  $1$  reikšmės, o tai reiškia, kad išvestinės reikšmė bus apytiksliai lygi  $0$ . Iš to seka, kad svoriai beveik nepasikeis ir apmokymas vyks labai lėtai, o tam tikrais atvejais visai nevyks.

Siekiant išvengti minėtų situacijų, duomenis rekomenduojama normalizuoti taip, kad jų vidurkis būtų artimas  $0$ , o dispersija  $-1$  [24]. Tuo atveju duomenys gali būti normalizuojami naudojant formulę:

$$x_{norm} = \frac{x - \mu}{\sigma},$$

čia  $x$  – neurono įvesties duomenys;  $\mu$  – įvesties duomenų vidurkis;  $\sigma$  – įvesties duomenų standartinis nuokrypis.

### 5.5. Klaidos atgalinis sklidimas

Mokymo su mokytoju atveju gali būti naudojamas klaidos atgalinio sklidimo algoritmas (*angl. backward propagation*). Šiame skyriuje trumpai aprašoma klaidos atgalinio sklidimo algoritmo eiga.

Taigi, klaidos atgalinio sklidimo algoritmo paskirtis – rasti naujas parametrų reikšmes apmokymo metu. Algoritmas, naudodamas gradientų nusileidimo strategiją (*angl. gradient descent*) ieško tokių parametrų reikšmių, kad išvesties reikšmių ir realių rezultatų skirtumas būtų pats mažiausias. Šiam algoritmui taikoma viena būtina sąlyga – aktyvacijos funkcija turi būti diferencijuojama. Be to, algoritmas turi ir papildomą parametą – mokymosi greitį (*angl. learning rate*). Mokymosi greičio paskirtis – nustatyti mokymosi žingsnio dydį, kad jis būtų užtektinai mažas.

Pagrindiniai klaidos atgalinio sklidimo etapai:

- Pradžioje poslinkiai yra lygūs  $0$ , o svoriai yra inicializuojami atsitiktinėmis reikšmėmis. Pavyzdžiui, tam galima naudoti atsitiktines reikšmes, pasiskirsčiusias pagal normalųjį skirstinį.
- Toliau vyksta įvesties reikšmių sklidimas į išvesties sluoksnį ir paklaidos sklidimas iš išvesties sluoksnio atgal į įvesties sluoksnį. Paklaida skaičiuojama tokiu būdu:

$$E = (\text{rezultatas} - \text{išvesties reikšmė}) \cdot \varphi',$$

kur  $\varphi'$  – aktyvacijos funkcijos išvestinė išvesties reikšmei.

- Taip perskaičiuojami svoriai ir poslinkiai, naudojant senas jų vertes, paklaidą, mokymosi greičio parametras. Algoritmas vykdomas nurodytą skaičių kartų, kurį galima nustatyti rankiniu būdu.

Šiame darbe įgyvendintas dirbtinis neuronų tinklas paremtas aprašyta klaidos atgalinio sklaidimo strategija.

## 5.6. DNT taikymas EEG analizei

Elektroencefalogramų analizei DNT taikymas nėra nauja idėja. Gali būti taikomi skirtingos struktūros dirbtiniai neuroniniai tinklai. Tyrimai rodo, kad vienus geriausių rezultatų galima pasiekti naudojant trijų sluoksnių dirbtinį neuroninį tinklą su 50 įvesties sluoksnio ir 10 paslėpto sluoksnio neuronų [6]. Egzistuoja darbu, kuriuose naudojamas trijų sluoksnių dirbtinis neuroninis tinklas tik su 4 įvesties sluoksnio ir 5 paslėpto sluoksnio neuronais [22]. Taip pat, yra išbandytas ir trijų sluoksnių dirbtinis neuroninis tinklas su 120 įvesties sluoksnio ir 10 paslėpto sluoksnio neuronų [17].

Ne tik tiesinis neuroninis tinklas gali būti naudojamas EEG analizei. N. F. Güler, E. D. Übeyli ir I. Güler [11] savo darbuose naudojo rekurentinį neuroninį tinklą (tai toks neuroninis tinklas, kuris turi grįžtamojo ryšio jungtis – reikšmės yra siunčiamos iš tolimesnių į ankstesnius neuronus). Be to, egzistuoja darbu, kuriuose EEG pikų detekcija vykdoma 2 etapais – taikant tiek tiesinį daugiasluoksnį neuronų tinklą, tiek rekurentinį [6].

Apibendrinami galime pastebėti, kad iš literatūroje pateiktų rezultatų išryškėja pagrindinės priežastys ir sprendimai, kaip pagerinti DNT veikimą ir rezultatų tikslumą. Vienas iš tokių sprendimų – pradinis duomenų apdorojimas.

Dirbtinis neuroninis tinklas EEG pikų aptikimui ir jo struktūra tolimesniems darbams bus pasirinkta atsižvelgiant į minėtų susijusių darbų rezultatus.

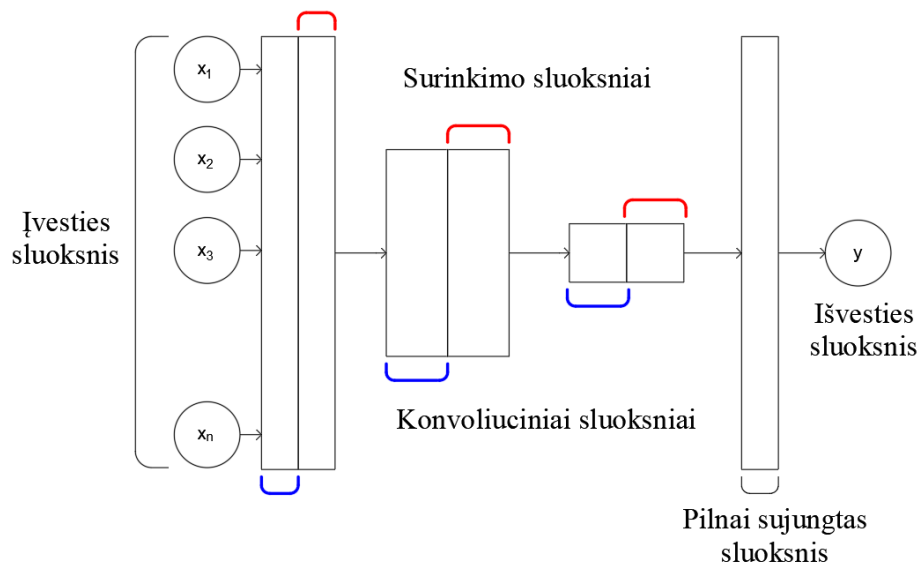
## 5.7. Konvoliucinis neuronų tinklas

Plečiantis automatizuoto apmokymo panaudojimo galimybėms, sudėtingiems uždaviniams spręsti dažnai taikomi įvairios architektūros dirbtiniai neuronų tinklai. Nuolat vyksta tyrimai, kaip pagerinti žinomus metodus, ieškoma kuo tinkamesnių taikymo būdų dideliems duomenų kiekiams. Dar vienas iš šiuo metu plačiausiai taikomų automatizuoto apmokymo metodų yra konvoliuciniai neuronų tinklai (*angl. Convolutional Neural Networks – CNN*).

Populiariausias taikymo sritys – vaizdų, vaizdo ir garso įrašų, laiko eilučių atpažinimas ir prognozavimas. Literatūroje galime rasti įrodymų, kad konvoliuciniai neuronų tinklai netgi viršija žmogaus tikslumą būtent vaizdų [20] bei teksto atpažinimo iš simbolių uždaviniuose [34], taip pat biologinių sekų tyrime [19].

Pagrindinis skirtumas tarp konvoliucinio neuronų tinklo ir anksčiau aptartojo – sluoksnių struktūra. Šių tinklų sluoksnių tipai yra tokie: konvoliucinis sluoksnis (*angl. convolutional layer*), surinkimo sluoksnis (*angl. pooling layer*), pilnai sujungtas sluoksnis (*angl. fully-connected layer*). Taip pat, viena iš konvoliucinių neuronų tinklų ypatybių – ta, kad juose naudojami bendri svoriai ir parametru kiekis sumažinamas paskirstant juos per sluoksnių filtrus. Tačiau, iš kitos pusės, konvoliucinių neuronų tinklų įgyvendinimas yra iššūkis dėl sunaudojamų išteklių kompleksiniams skaičiavimams.

Toliau plačiau aptariami kiekvieno iš konvoliucinių neuronų tinklų sluoksnių paskirtis ir savybės.



7 pav. Konvoliucinio neuronų tinklo sluoksnių išdėstymo pavyzdys. Mėlynai pažymėti 3 konvoliuciniai sluoksniai, o raudonai – 3 surinkimo sluoksniai. Iliustracija pagal [23].

**Konvoliucinis sluoksnis** Pavadinimas – konvoliucinis neuronų tinklas – žymi tai, kad tinklo apmokymo metu bent vieną kartą naudojama matematinė operacija, vadinama konvoliucija [12]:

$$y_k = \sum_{n=0}^{N-1} x_n h_{k-n},$$

kur  $x$  yra įvesties reikšmė,  $h$  – mokomasis filtras. o  $N$  – įvesties duomenų kiekis. Sluoksnis, kuriame vykdoma ši operacija, vadinamas – konvoliuciniu sluoksniu. Tai pagrindinė nagrinėjamo dirbtinio neuronų tinklo dalis.

Konvoliucinis sluoksnis yra sudarytas iš mokomųjų filtrų rinkinio (*angl. Learnable Filters*). Filto pozijos keitimo metu yra skaičiuojama filtro elemento ir perduoto duomenų svorio skaliarinė sandauga. Tokiu būdu gaunamas konvoliucinio sluoksnio rezultatas – požymių žemėlapių rinkinys (*angl. Feature Maps*). Kiekviename požymių žemėlapyje esanys neuronai dalinasi tais pačiais svoriais. Tokiu būdu tinklas išmokomas atpažinti požymius, pavyzdžiui, objektų briaunas ar regionus, kuriuose dominuoja panašios savybės.

Po kiekvieno konvoliucinio sluoksnio dirbtiniame neuronų tinkle naudojamos aktyvacijos funkcijos. Jos gali būti tokios pačios kaip aptarta poskyryje 5.2.

**Surinkimo sluoksnis** Tarp konvoliucinių sluoksnių dirbtiniame neuronų tinkle dažniausiai naudojami – surinkimo sluoksniai (*angl. Pooling Layers*). Juose paprastai naudojamos maksimalaus surinkimo (*angl. Max Pooling*) arba vidutinio surinkimo (*angl. Average Pooling*) operacijos.

Surinkimo sluoksnių pagrindinė funkcija yra požymių žemėlapių mažinimas. Tai atliekama sumažinant prieš tai buvusio sluoksnio požymių žemėlapių neuronų skaičių juos apjungiant į vieną neuroną. Tada gautas rezultatas dauginamas iš svorio, skaičiuojama paklaida ir, taip pat, naudojama aktyvacijos funkcija 5.2.

Taigi, surinkimo sluoksnio pagalba sumažinamas įvesties dydis – dėl šios priežasties, sumažėja parametru ir skaičiavimų kiekis. Tokiu būdu galima paspartinti ir kontroliuoti konvoliucinio neuronų tinklo apmokymo procesą.

**Pilnai sujungtas sluoksnis** Po aptartų sluoksnių konvoliuciniame neuronų tinkle yra vienas arba daugiau pilnai sujungtų sluoksnių (*angl. Fully-Connected Layers*). Šie sluoksniai nagrinėjama me tinkle yra privalomi, kadangi būtent jie vykdo klasifikavimą, taip pat naudodami aktyvacijos funkciją 5.2.

Pilnai sujungtuose sluoksniuose kiekvienas neuronas yra jungiamas su kiekvienu ankstesnio sluoksnio neuronu. Neuronų kiekis sluoksnyje gali būti pasirenkamas atsitiktinai, priklausomai pagal sprendžiamo uždavinio sudėtingumą. Tačiau paskutiniajame konvoliucinio neuronų tinklo sluoksnyje turėtų būti tiek neuronų, kiek skirtingų pradinių duomenų klasių norima atpažinti.

Konvoliucinio neuronų tinklo sluoksnių išdėstymo pavyzdys vizualiai pateiktas 7 pav.

## 6. Kompiuterinis įrankis EEG pikų aptikimui

Šio darbo praktinė dalis – dviejų automatinių EEG apdorojimo būdų taikymas ir jų kombinacijos analizė. Pirmasis pasirinktas algoritmas, paremtas morfologinėmis operacijomis ir filtrais, buvo nagrinėtas mokslo tiriamajame darbe – pritaikytas realiems duomenims, atsižvelgiant į svarbiausius parametrus ir optimalias jų reikšmes. Antrasis praktinės dalies etapas buvo įgyvendintas šio semestro metu – EEG apdorojimui panaudotas dirbtinis neuronų tinklas, pritaikyta abiejų algoritmų kombinacija.

### 6.1. Morfologinių filtrų algoritmo įgyvendinimas ir testavimas


Algoritmo testavimui naudojami medicininiai signalai – realių pacientų elektroencefalogramos. Kaip buvo minėta 3.1, dalis darbe naudotų EEG jau išanalizuotos gydytojų ir turi detalius aprašymus, kurioje signalo minutėje ir kiek užregistruota pikų. Taigi, algoritmo įgyvendinimas ir optimalūs parametrai nustatomi atsižvelgiant į realius tryimus.

Morfologinių operacijų veikimas pavaizduotas 8 pav. Kaip buvo minėta 4.3 skyriuje, galime įsitikinti, kad uždarymo-atidarymo (CO) operacija pakelia signalo reikšmes, o atidarymo-uždarymo (OC) operacija jas sumažina. Toliau šiame skyriuje pristatomos praktinės algoritmo įgyvendinimo detalės.

#### 6.1.1. Signalu atkarpos ilgis

Smegenų veikla nuolat kinta. Dėl šios priežasties, struktūrinis elementas turi būti nuolat perskaičiuojamas. EEG atkarpa turi būti pakankamo ilgio pikų identifikavimui, tačiau ne per ilga, kad vyraujantys smegenų ritmai nepasikeistų. Optimalus EEG atkarpos ilgis yra tarp 4 ir 6 sekundžių. Tokio ilgio atkarpai dar tinka parinkti struktūrinio elemento koeficientai (4.2) ir nėra poreikio jų perskaičiuoti.

Be to, pasirinkta 4-6 sekundžių atkarpa yra optimali ir dėl daugiau priežasčių [26]. Atliekant EEG tyrimą gali kisti paciento galvos odos laidumas dėl prakaito ar kitų faktorių, kas gali apsunkinti artefaktų nufiltravimą. Taip pat, esant optimaliam EEG atkarpos ilgiui, pikų aptikimo algoritmas veikia pakankamai greitai.



8 pav. Morfologinių operacijų veikimas. Nagrinėjamas Cz-RF EEG kanalas, kuriam pritaikytos atidarymo-uždarymo (OC) ir uždarymo-atidarymo (CO) operacijos bei jų kombinacija (OCCO). Matavimo vienetai: mikrovoltai per milisekundę. Struktūrinis elementas: parabolė, plotis 20 taškų (apie 0,078 sekundės).

### 6.1.2. Pikų detekcijos ribos pasirinkimas

Kiekvienas pacientas yra unikalus ir pasižymi skirtingos morfologijos pikais. Dėl to, tiksli pikų detekcijos riba kiekvienam pacientui yra skirtinga. Ši riba žymi reikšmę, virš kurios išskylančios signalo viršūnės yra laikomos pikais, ir yra randama pagal formulę:

$$L = d * median|extrema(x(t))|, \quad (6.1)$$

kur  $x(t)$  yra nufiltruotas signalas (4.10), o  $d$  – detekcijos ribos koeficientas.

Būtent minėtas detekcijos ribos koeficientas kiekvienam pacientui gali būti skirtingas, tačiau nustatyta, kad tai yra skaičius-konstanta tarp 6 ir 12. Literatūroje [18] siūloma detekcijos ribos koeficientą laikyti lygų 8, su tokiu koeficientu gauti rezultatai pavaizduoti 9, 10, 11 pav. Atliekant testavimo darbus koeficiento  $d$  reikšmės buvo naudotos nuo 2 iki 20.

### 6.1.3. Struktūrinio elemento ilgis

Struktūrinio elemento ilgis – tai parabolę, aprašytą 4.1 skyriuje, sudarančių taškų skaičius. Šiame darbe buvo koreguojami struktūrinio elemento ilgiai ir kiekvieno paciento atveju buvo ieškoma tinkamiausio. Optimalus struktūrinio elemento ilgis:


$$S_L = 4median|W|, \quad (6.2)$$

kur  $W$  yra signalo arkų pločiai.

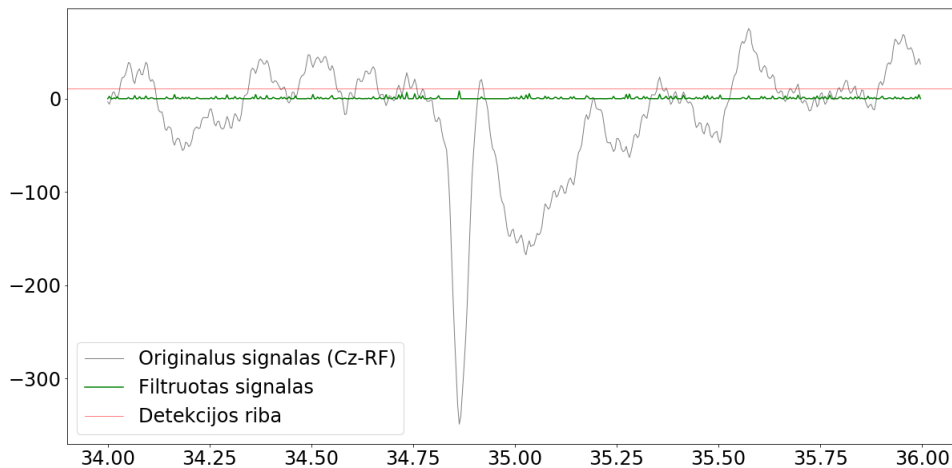
Toks ilgis  $S_L$  parodo, kad optimaliu atveju parabolė turėtų būti 4 kartus platesnė, nei EEG parabolė pločių mediana. Struktūrinio elemento ilgio pasirinkimas turi didelę įtaką signalo filtravimui, tuo galime įsitikinti palyginę morfologinius filtrus su įvairių ilgių struktūriniais elementais, kai kiti parametrai yra fiksuoti. Tinkamo struktūrinio elemento ilgio pasirinkimo pavyzdys pateikiamas 9 pav.

Jeigu struktūrinis elementas yra per trumpas, gali atsitikti taip, kad bus nufiltruota ne tik foninė smegenų veikla, bet ir pikai. Per trumpo struktūrinio elemento pavyzdys pateikiamas 10 pav.





9 pav. Pavyzdys, kai pasirinktas tinkamo ilgio struktūrinis elementas. Nagrinėjamas Cz-RF EEG kanalas. Matavimo vienetai: mikrovoltai per milisekundę.

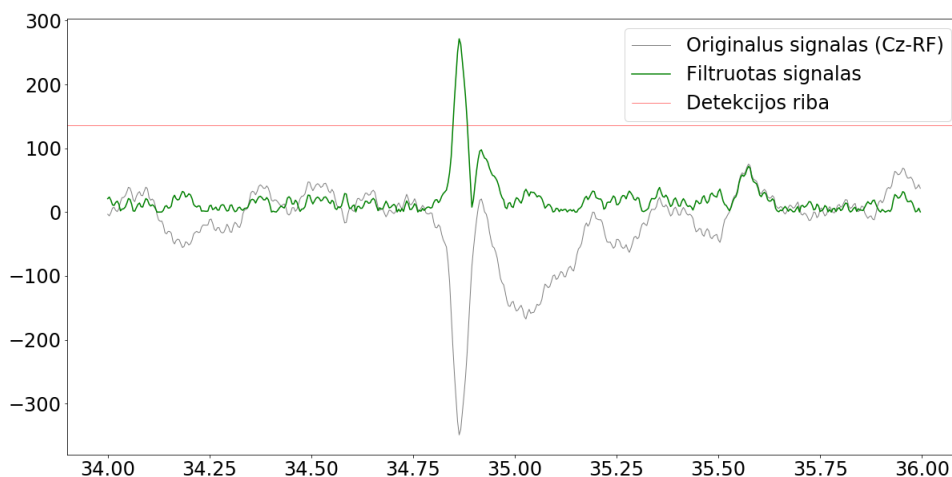


10 pav. Pavyzdys, kai pasirinktas per trumpas struktūrinis elementas, kurio ilgio koeficientas 0,5. Nagrinėjamas Cz-RF EEG kanalas. Matavimo vienetai: mikrovoltai per milisekundę.

Jeigu struktūrinis elementas yra per ilgas, tada priešingai – foninė smegenų veikla gali likti tinkamai nenufiltruota, palikti artefaktai, o pikai neišryškinti ir apsunkintas jų radimas. Per ilgo struktūrinio elemento pasirinkimo pavyzdys pateikiamas 11 pav.

#### 6.1.4. Rezultatų apibendrinimas

Šiame poskyryje pateikiami rezultatai, gauti realių pacientų elektroencefalogramoms pritaikius įgyvendintą algoritimą, atsižvelgiant į aptartus optimalius parametrus. Turimi pacientų duomenys buvo aptarti 3.1 skyrelyje. Detaliam testavimui pasirinktos 3 skirtingos EEG, kurios jau yra išanalizuotos gydytojų. Kadangi kiekvienai iš jų gydytojai buvo pateikę tikslų pikų skaičių ir nurodę, kurioje minutėje jie aptikti, rankiniu būdu keičiant algoritmo parametrus buvo lyginami gaunami rezultatai su pateiktais gydytojų rezultatais. Apibendrinimas pateiktas 3 lentelėje. Matome, kad algoritmas, paremtas morfologinėmis operacijomis ir filtrais, dažnai aptinka daugiau pikų, nei yra iš tikrųjų.



11 pav. Pavyzdys, kai pasirinktas per ilgas struktūrinis elementas, kurio ilgio koeficientas 8. Nagrinėjamas Cz-RF EEG kanalas. Matavimo vienetai: mikrovoltai per milisekundę.

Nagrinėjant naujausius duomenis, kurie aprašyti 3.1, pastebėta tokia pati tendencija – morfologiniais filtrais paremtas algoritmas aptinka daugiau pikų, negu identifikuoja gydytojai, o patikimumas svyruoja apytiksliai apie 80%. Tačiau tolimesniuose darbuose toks požymis neapsunkina situacijos, o priešingai – padeda surasti daug EEG darinių (kandidatų), kurie panašūs arba yra pikai, ir galėtų būti panaudojami tiriant DNT tikslumą pikų detekcijai. Šio algoritmo panaudojimas kartu su dirbtiniu neuronų tinklu detalčiau aprašytas 6.2.5 poskyryje.

<b>EEG nr. 1</b>	<b>1 min</b>	<b>2 min</b>	<b>3 min</b>	<b>4 min</b>	<b>5 min</b>	<b>6 min</b>
<b>Gydytojų nurodytų pikų sk.</b>	1	4	2	1	4	2
<b>Algoritmo aptiktų pikų sk.</b>	5	3	0	6	2	2
<b>EEG nr. 2</b>	<b>1 min</b>	<b>2 min</b>	<b>3 min</b>	<b>4 min</b>	<b>5 min</b>	<b>6 min</b>
<b>Gydytojų nurodytų pikų sk.</b>	2	12	10	12	15	5
<b>Algoritmo aptiktų pikų sk.</b>	1	19	11	27	2	1
<b>EEG nr. 3</b>	<b>1 min</b>	<b>2 min</b>	<b>3 min</b>	<b>4 min</b>	<b>5 min</b>	<b>6 min</b>
<b>Gydytojų nurodytų pikų sk.</b>	9	4	2	6	6	2
<b>Algoritmo aptiktų pikų sk.</b>	9	9	5	9	22	9

3 lentelė. Rezultatų, gautų pritaikius algoritmą, ir rezultatų, pateiktų gydytojų, palyginimas. Lyginami pikų skaičiai kiekvienoje iš šešių minučių.

## 6.2. Dirbtinis neuroninis tinklas EEG pikų aptikimui


Šioje praktinėje dalyje įgyvendintas dirbtinis neuronų tinklas, paremtas teorine analize, kuri buvo pristatyta 5 skyriuje. Pirmiausia atliekami bandymai su daugiasluoksniu perceptronu, kuris pasirinktas dėl jo privalumų, aptartų 5.3 poskyryje.

### 6.2.1. DNT taikymas realiems pacientų duomenims

Praktiniai testai atliekami su realiais pacientų duomenimis, kurie detalizuojami 3.1 skyriuje. Taip pat, remiantis literatūros analize, prieš pradėdant darbą su dirbtiniu neuroniniu tinklu yra taikomas pradinis duomenų apdorojimas. Iš pat pradžių, visiems turimiems duomenims taikomi šie žingsniai:

- triukšmo šalinimas Furje filtru (3.3);
- įvesties sluoksnio sudarymas slenkančio lango principu;
- išvesties (rezultatų) sluoksnio apibendrinimas;
- apmokymo ir testavimo imčių parinkimas.

**Slenkančio lango principas.** Kiekvienas nagrinėjamų EEG kanalas yra suskaidomas į atskiras atkarpas, kurių plotį pasirenka vartotojas. Toliau šiame darbe atliekamuose testuose pasirinktas maždaug  $200ms$  ( $0,2$  sekundės) atkarpos ilgis. Būtent toks ilgis pasirinktas neatsitiktinai – kaip buvo minėta 2.2 poskyryje, epileptiforminis pikas gali tęstis ne ilgiau kaip  $200ms$ . Vadinasi, kiekviena EEG kanalo atkarpa gali būti prilyginama pikui (1) arba ne pikui (0). Siekiant išvengti tų atvejų, kai piko vieta yra būtent ant atkarpos krašto, algoritmas papildytas dar vienu parametru – persidengimo pločiu. Vizualiai slenkančio lango principas pateiktas 12 pav.



12 pav. Slenkančio lango principas. Žymėjimas  $a$  atitinka slenkančio lango plotį, o  $b$  – persidengimo plotį. Pavyzdyje vaizduojamas EEG T5-RF kanalas. Matavimo vienetai: mikrovoltai per milisekundę.

**Išvesties sluoksnis.** Kaip aptarta aukščiau, įvesties sluoksnyje nagrinėjamu atveju turime atkarpas, kurios yra arba nėra pikai. Toks norimas rezultatas lemia ir išvesties sluoksnio struktūrą – jo dydis yra 2 elementai:

- $(0, 1)$  – piko atkarpoje **nėra**;
- $(1, 0)$  – pikas atkarpoje **yra**.

Apibendrinami siekiamą gauti rezultata, galime daryti išvadą, kad šio darbo tikslas susiveda į klasifikavimo uždavinį, turintį dvi klases – pikas arba ne pikas.

**Apmokymo ir testavimo imtys.** Iš viso apmokymui ir testavimui turime 929 (3.1) pikų. Tuo tarpu atkarpu, kurios nėra pikai, turime daugybę kartų daugiau – vidutinė EEG trukmė yra beveik  $3000000ms$  (apie 50 minučių). Atsižvelgiant į duomenų kiekį, testavimui paliekame 200 pikų, o likusius naudojame apmokymui. Po suskaidymo apmokymui turime iš viso 1269 atkarpas, kuriose yra pikai – taip yra dėl to, kad tas pats pikas, esantis ant atkarpos krašto, patenka į abi atkarpas. Atitinkamai apmokymui taip pat atrenkame 1269 skirtingas atkarpas, kurios nėra pikai.

### 6.2.2. DNT parametrų įtaka ir jų analizė

Tolimesni tyrimai atliekami su trijų sluoksnių tiesiniu neuroniniu tinklu. Sluoksniai yra šie:

1. Įvesties sluoksnis – 51 neuronas;
2. Paslėptasis sluoksnis – 15 neuronų;
3. Išvesties sluoksnis – 2 neuronai.

Tokie neuronų sluoksniuose skaičiai pasirinkti dėl to, kad įvesties sluoksnis yra suskaidytas atkarpomis, kur kiekvieną jų turi po 51 elementą. Pradinis paslėptojo sluoksnio neuronų skaičius pasirinktas atsitiktinai, vėliau šiame darbe išbandomi ir kitos konfigūracijos dirbtiniai neuroniniai tinklai, siekiant palyginti paslėptojo sluoksnio neuronų skaičiaus įtaką rezultatams. Galiausiai, išvesties sluoksnyje turime 2 neuronus – elementus, kurie gali būti lygūs 0 arba 1.

**Pagrindiniai parametrai: teisingumo riba, mokymosi greitis, ciklų skaičius.** Teisingumo riba – tai skaičius, kuris nurodo, kada dirbtinio neuronų tinklo rezultatas yra teisingas. Apmokymo, aprašyto 5.5 poskyryje, metu, svariai perskaičiuojami taip, kad spėjamas atsakymas būtų kuo arčiau tikrojo (0 ar 1). Kai dirbtiniam neuronų tinklui paduodame atkarpą, kurioje yra pikas, tikimės, kad jis gražins atsakymą – (1, 0). Tačiau iš DNT gautas atsakymas nebus lygus 0 arba 1, o galimas interpretuoti kaip tikimybė, kad toje atkarpoje egzistuoja pikas, pavyzdžiui, (0.81, 0.19). Siekiant apibrėžti atsakymo teisingumą, darbuose naudojama teisingumo riba lygi 0.8. Kitaip tariant, laikoma, kad DNT atsakymas yra teisingas, jeigu jis atitinka bent 80%. Gana aukšta riba pasirinkta dėl eksperimentų metu nustatyto optimalaus santykio tarp atpažįstamų pikų ir ne pikų.

Kiti dirbtinio neuronų tinklo konfigūracijoje svarbūs parametrai – mokymosi greitis ir ciklų skaičius – pasirinkti remiantis aptarta literatūra. Mokymosi greitis, kuris apibrėžia mokymosi žingsnio dydį, laikomas lygiu 0,001. Mokymosi ciklų skaičius, kuris nurodo, kiek kartų vyks apmokymas, yra lygus 10000. Siekiant išbandyti įvairias konfigūracijas ir taikyti tinkamiausią, visi minėti parametrai yra lengvai keičiami ir gali būti įvedami vartotojo.

Įvesties sluoksnis	1 sluoksnis – 51 neuronas
Paslėptasis sluoksnis	1 sluoksnis – 15 neuronų
Išvesties sluoksnis	1 sluoksnis – 2 neuronai
Teisingumo riba	0,8
Mokymosi greitis	0,001
Mokymosi ciklų skaičius	10000
Aktyvacijos funkcija	Sigmoidinė funkcija

4 lentelė. Nagrinėjamo DNT struktūra

Taigi, taikomo dirbtinio neuronų tinklo struktūra pateikiama 4 lentelėje. Tokio tipo DNT teisingai nurodė, ar atkarpoje yra pikas, ar jo nėra, 86% tikslumu. Tačiau tikslumas yra ne vienintelis rodiklis, pagal kurį vertinamas DNT modelis. Mūsų atveju testavimo atkarpu, kurios yra ne pikai, yra žymiai daugiau. Jos nesudaro net 1% visų atkarpu. Dėl to, dirbtiniam neuronų tinklui neatspėjus nei vieno piko, jo tikslumas vis tiek būtų aukštas. Siekiant geriau iširti DNT modelį, buvo vertinama klaidų matrica (*angl. confusion matrix*):

$$\begin{pmatrix} TP & FP \\ FN & TN \end{pmatrix} = \begin{pmatrix} 339 & 18756 \\ 213 & 117587 \end{pmatrix}, \quad (6.3)$$

kur:

- *TP (angl. true positive)* vertė, kuri atitinka tikruosius pikus, kuriuos DNT teisingai identifikavo kaip pikus;
- *FP (angl. false positive)* vertė, kuri atitinka ne pikus, kuriuos DNT identifikavo kaip pikus;
- *FN (angl. false negative)* vertė, kuri atitinka tikruosius pikus, kurių DNT neidentifikavo kaip pikų;
- *TN (angl. true negative)* vertė, kuri atitinka ne pikus, kuriuos DNT teisingai identifikavo būtent kaip ne pikus.

Apibendrinus rezultatus, turime tokias tikimybes:


- Tikimybė, kad DNT teisingai ras piką – 61,4%
- Tikimybė, kad DNT teisingai ras ne piką – 86,24%
- Tikimybė, kad DNT neteisingai ras piką (pirmos rūšies klaida) – 13,76%
- Tikimybė, kad DNT neteisingai ras ne piką (antros rūšies klaida) – 38,6%

Matome, kad egzistuoja antros rūšies klaidos tikimybė. Tai reiškia, kad įgyvendintas DNT algoritmas, lyginant su gydytojų išvadomis, vis dėl to gali neaptikti tikro piko. Taip pat, atitinkamai egzistuoja ir pirmos rūšies klaidos tikimybė, tačiau ji nėra didelė. Tai reiškia, kad įgyvendintas DNT algoritmas be gydytojų pažymėtų pikų aptinka ir atkarpu, kurias klasifikuoja kaip pikus, nors jose pikų iš tikrųjų nėra.

Papildomai, 13 pav. pateikiama ROC (*angl. Receiver Operating Characteristics*) kreivė, skirta aptariamo klasifikatoriaus jautrumui ir specifiškumui palyginti. Kadangi plotas po šia kreive (*angl. Area Under Curve – AUC*) yra ne mažesnis nei 0,5, vadinasi, statistiškai klasifikatorius laikomas pasižyminčiu geromis prognostinėmis savybėmis.

Toliau bus siekiama tikslesnių įgyvendinto DNT algoritmo rezultatų, taikant papildomus duomenų apdorojimo algoritmus ir keičiant parametrus.


**K-dalių kryžminė patikra** Pastarasis testas atliktas taikant nepriklausomą patikrinimą (*angl. hold-out validation*) – visi turimi duomenys padalinti į dvi nepersidengiančias dalis, kurių viena skirta dirbtinio neuronų tinklo apmokymui, o kita skirta apmokyto DNT testavimui. Apie tai buvo plačiau kalbama 6.2.1 poskyryje.



13 pav. Testo ROC kreivė, atspindinti DNT jautrumo ir specifiškumo sąryšį. AUC (angl. *Area Under Curve*) – plotas po šia kreive.

Kadangi nepriklausomo patikrinimo atveju DNT testavimui naudojami atskiri, nauji, jam dar nematyti duomenys, todėl gauname tikslesnį algoritmo įvertinimą. Aptariamo testo metu buvo gautas tikslumas lygus 86%. Tačiau šio metodo galimas trūkumas – priklausomybė nuo atskirtų duomenų. Atsitiktinai apmokymui atskirta duomenų dalis gali neatspindėti pagrindinių požymių, būti per daug paprasta arba priešingai – gali būti labai sudėtingai klasifikuojama. Siekiant išvengti šios problemos, apmokymo ir testavimo duomenų imtims buvo taikoma k-dalių kryžminė patikra (angl. *k-fold cross validation*).

Atsižvelgiant į duomenų kiekį, taikoma 4-dalių kryžminė patikra. Taigi, duomenys atsitiktinai suskirstomi į 4 dalis – iš kurių viena paliekama patikrinimui (testavimui), o kitos trys naudojamos apmokymui. Procesas vykdomas 4 kartus – kiekvieną kartą patikrinimo dalis sukeičiama su viena nauja dalimi iš apmokymo dalių. Be to, papildomai patikra kartojama 10 kartų ir vertinamas rezultatų vidurkis, kuris pateiktas 14 pav.



14 pav. 4-dalių kryžminės patikros rezultatai. Patikra kartojama 10 kartų. Pateiktas rezultatų vidurkis procentais.

Matome, kad skirstant apmokymo ir testavimo imtis įvairias būdais, dirbtinio neuronų tinklo tikslumas svyruoja 80 – 90% ribose. Mažiausias rezultatų vidurkis – 84,35%, o didžiausias – 86,49%.

**Rezultatų palyginimas su Python įrankiu** Naudojamas dirbtinis neuronų tinklo algoritmas buvo suprogramuotas rankiniu būdu, todėl buvo norima išsiaiškinti, ar veikimas yra korektiškas, ir palyginti rezultatus su laisvai prieinamomis *Python* bibliotekomis, skirtomis DNT kūrimui bei valdymui. Apie bibliotekų pasirinkimą plačiau nagrinėjama 3.2.1 skyriuje. Pasirinkta naudoti *Keras* biblioteką, veikiančią *Theano* bibliotekos pagrindu.

Atliekamas pastarasis, aukščiau aprašytas testas. Naudojami tie patys duomenys, paruošti slenkančio lango principu. Parinktos tokios pačios apmokymo ir testavimo imtys. Paruošta tokia pati DNT konfigūracija – 1 įvesties sluoksniu su 51 neuronu; 1 paslėptasis sluoksniu su 15 neuronu; 1 išvesties sluoksniu su 2 neuronais. Naudojama sigmoidinė aktyvacijos funkcija.

Gauti labai panašūs rezultatai. DNT tikslumas arti 90%. Antros rūšies klaidos – kad DNT neras piko, ten kur jis yra – tikimybė skiriasi labai mažai – 36,96%. Tuo tarpu, pirmos rūšies klaidos – kad DNT ras piką, nors jo ten nėra – tikimybė palyginus yra šiek tiek geresnė – 9,74%.

Nepaisant nedidelių skirtumų, kurie galėjo atsirasti dėl optimizavimo priežasčių, reikšmingu nukrypimų nepastebėta, todėl toliau laikoma, kad įgyvendintas dirbtinis neuronų tinklas veikia korektiškai.

**Duomenų normalizavimo įtaka** Apie įtaką, kurią gali turėti dirbtinio neuronų tinklo įvesties duomenų ypatybės, ir apie įvesties duomenų normalizavimą buvo rašoma 5.4.1 poskyryje.

Iki šiol į įvesties duomenų normalizavimą atsižvelgta nebuvo. Tačiau, analizuojant EEG kanalų duomenis, buvo pastebėta, kad pasitaiko labai didelių reikšmių. Taip pat, vyrauja tiek teigiamos, tiek neigiamos įvairios reikšmės, bet dažnai vidurkis siekia kraštutinius. Taigi, šio testo tikslas – patikrinti, ar EEG kanalų duomenų normalizavimas gali turėti įtakos DNT tikslumui.

Išlaikant nuoseklumą, atliekamas testas, panašus į iki šiol nagrinėtą. DNT struktūra naudojama tokie pati – sudaryta iš 3 sluoksnių. Tačiau šiuo atveju duomenys naudojami prieš tai juos normalizavus, 5.4.1 aprašytu procesu, taip kaip rekomenduojama [24] – vidurkis artimas 0, o dispersija artima 1.

Gauti rezultatai pastebimai geresni, palyginus su 6.2.2 atliktu testu. Po duomenų normalizavimo, DNT teisingai nurodė, ar atkarpoje yra pikas, ar jo nėra, 95% tikslumu. Toliau apžvelgsime kitas DNT rezultatų vertinimo metrikas.

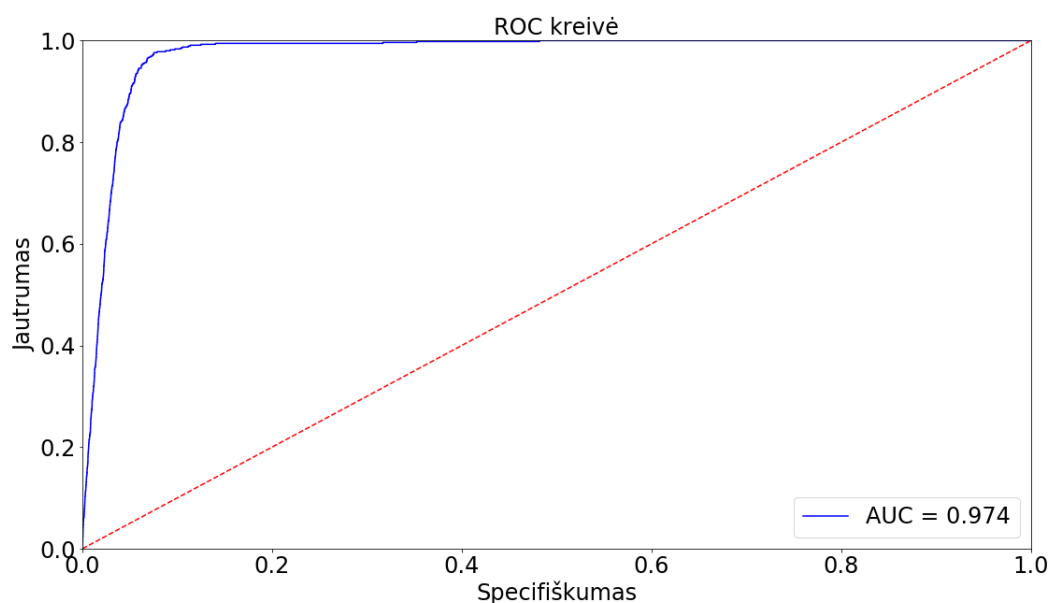
Nagrinėdami gautą klaidų matricą (elementų reikšmės aprašytos po formule 6.3):

$$\begin{pmatrix} TP & FP \\ FN & TN \end{pmatrix} = \begin{pmatrix} 494 & 6766 \\ 58 & 129577 \end{pmatrix},$$

galime daryti tokias išvadas:

- Tikimybė, kad DNT teisingai ras piką – 89,49%
- Tikimybė, kad DNT teisingai ras ne piką – 95,04%
- Tikimybė, kad DNT neteisingai ras piką (pirmos rūšies klaida) – 4,96%
- Tikimybė, kad DNT neteisingai ras ne piką (antros rūšies klaida) – 10,51%

Matome, kad antros rūšies klaidos tikimybė, normalizuotų duomenų atveju, yra daugiau nei 3 kartus mažesnė. Vadinasi, DNT algoritmas daug tiksliau atpažįsta tikruosius pikus, kuriuos taip pat atpažino ir gydytojas. Be to, pirmos rūšies klaidos tikimybė šiuo atveju irgi yra mažesnė. Tai reiškia, kad dabar DNT algoritmas nepažymi tiek daug pikų atkarpose, kur jų iš tikrųjų nėra. Gautus rezultatus 15 pav. iliustruoja ROC kreivė. Plotas po kreive ženkliai didesnis – siekia net 0,97.



15 pav. Testo su normalizuotais duomenimis ROC kreivė, atspindinti DNT jautrumo ir specifiškumo sąryšį. AUC (*angl. Area Under Curve*) – plotas po šia kreive.

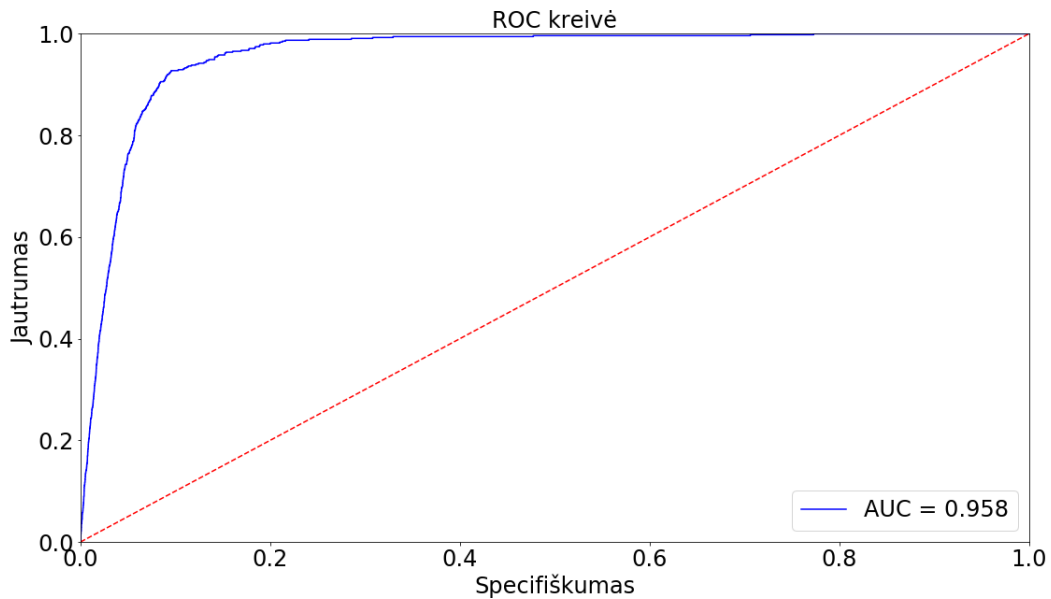
### 6.2.3. DNT aktyvacijos funkcijos pasirinkimas

Iki šiol testuose buvo naudojama sigmoidinė aktyvacijos funkcija. Tačiau, kaip minima 5.2, tai ne vienintelis galimas variantas. Šiame skyriuje sigmoidinę aktyvacijos funkciją palyginsime su hiperbolinio tangento aktyvacijos funkcija.

Taigi, testo sąlygos – duomenys ir DNT konfigūracija – tokios pat kaip prieš tai aprašyto testo. Vienintelis skirtumas – naudojama hiperbolinio tangento aktyvacijos funkcija. Gautas rezultatas labai panašus – DNT teisingai nurodė, ar atkarpoje yra pikas, ar jo nėra, 93% tikslumu. Žymaus skirtumo nepastebėta ir tarp kitų nagrinėjamų metrikų. Pirmos rūšies klaidos tikimybės beveik nesiskiria, o antro rūšies – šiek tiek didesnė. Rezultatus 16 pav. iliustruoja ROC kreivė. Plotas po kreive yra apytiksliai lygus 0,96.

Rrezultatai nėra labai reikšmingi, kad būtų galima teigti, jog viena aktyvacijos funkcija yra geresnė už kitą ir visada vertėtų taikyti vieną ir tą pačią. Tad, apibendrinami galime pasakyti, kad sigmoidinė aktyvacijos funkcija yra tik šiek tiek pranašesnė už hiperbolinio tangento aktyvacijos funkciją. Dėl nežymių skirtumų, kaip ir pirmuosiuose testuose, toliau bus naudojama sigmoidinė aktyvacijos funkcija.





16 pav. Testo, naudojant hiperbolinio tangento aktyvacijos funkciją, ROC kreivė, atspindinti DNT jautrumo ir specifiškumo sąryšį. AUC (*angl. Area Under Curve*) – plotas po šia kreive.

#### 6.2.4. Paslėptojo sluoksnio neuronų skaičius

Šiame skyriuje siekiama ištirti paslėptojo sluoksnio neuronų skaičiaus įtaką DNT rezultatui. Iki šiol testai buvo atliekami su 15 paslėpto sluoksnio neuronų. Šį skaičių vartotojas gali pasirinkti pats kokį tik nori, bet kyla klausimas – koks kiekis paslėpto sluoksnio neuronų yra optimalus.

Neuronų skaičius paslėptajame sluoksnyje turi įtakos ne tik DNT klasifikavimo tikslumui, bet netgi algoritmo vykdymo greičiui. Nors nėra formulės, kaip rasti šį neuronų skaičių, kuri tiktų visiems atvejams, tačiau egzistuoja įvairių parinkimo strategijų. Jos gali priklausyti nuo įvesties ir išvesties neuronų skaičių, apmokymo imčių kiekio, aktyvacijos funkcijos, bendros DNT konfigūracijos, kitų parametrų ir, taip pat, nuo pačio uždavinio sudėtingumo. Literatūroje randamos rekomendacijos yra tokios:

- Optimalų neuronų skaičių paslėptajame sluoksnyje galime apskaičiuoti pagal formulę [25]:

$$H = \log_2 M,$$

kur  $H$  – neuronų skaičius, o  $M$  – didžiausias tiesiškai atskiriamų regionų, esančių įvesties duomenyse, skaičius. Nagrinėjamu atveju –  $H$  būtų lygus 5.

- Optimalų neuronų skaičių paslėptajame sluoksnyje galime apskaičiuoti pagal formulę:

$$H = (I + O) \cdot \frac{2}{3},$$

kur  $H$  – neuronų skaičius,  $I$  – įvesties neuronų skaičius,  $O$  – išvesties neuronų skaičius. Nagrinėjamu atveju –  $H$  būtų lygus maždaug 35.

- Optimalų neuronų skaičių  $H$  paslėptajame sluoksnyje patariama rinktis tokį, kad atitiktų vieną iš šių pasiūlymų:

- $H$  turėtų būti tarp įvesties ir išvesties neuronų skaičių. Nagrinėjamu atveju –  $H$  būtų tarp 2 ir 51.
- $H$  turėtų būti ne didesnis už padvigubintą įvesties neuronų skaičių. Nagrinėjamu atveju –  $H$  būtų ne didesnis už 100.

Kaip matome, patarimų yra daug ir jie visi skirtingi, todėl toliau šiame skyriuje yra išbandoma keletas paslėptojo sluoksnio neuronų skaičiaus reikšmių ir palyginami rezultatai.

Naudojami tokie pat duomenys, kaip prieš tai nagrinėtame teste, taip pat naudojama tokia pati DNT konfigūracija – 1 įvesties sluoksnis su 51 neuronu; 1 paslėptasis sluoksnis su  $H$  neuronų; 1 išvesties sluoksnis su 2 neuronais. Naudojama sigmoidinė aktyvacijos funkcija. Išbandomos tokios  $H$  vertės:

$$H = 5, 10, 15, 20, 25, 30, 35, 40, 45, 50.$$

Visų atliktų testų su skirtingomis  $H$  reikšmėmis rezultatai apibendrinami ir pateikiami 5 lentelėje.

<b>H</b>	5	10	15	20	25
Laikas (s)	20*	(20) + 8	(28) + 10	(38) + 9	(47) + 10
Rezultatas (%)	94,3847	94,6908	94,7280	94,9472	94,8946
<b>H</b>	30	35	40	45	50
Laikas (s)	(57) + 19	(76) + 13	(89) + 9	(98) + 13	(111) + 9
Rezultatas (%)	95,2511	95,2430	94,7398	95,1445	94,9180

5 lentelė. DNT tikslumo priklausomybė nuo paslėptojo sluoksnio neuronų skaičiaus  $H$ .

\* – laikas pateikiamas tik kaip papildomas rodiklis, leidžiantis stebėti, kaip ilgėja programos vykdymas, keičiant  $H$  vertę; konkretus laikas nelaikomas išvadoms svarbiu veiksmu, kadangi priklauso nuo individualaus kompiuterio išteklių ir galimybių.

Palyginę rezultatus, galime pastebėti, kad, iš tikrųjų, paslėptojo sluoksnio neuronų skaičius daro įtaką tikslumui. Nors ši įtaka nėra labai didelė, tačiau tendencija išryškėja – kad didėjant neuronų skaičiui, tikslumas irgi didėja. Matome, kad rezultatas apytiksliai viršija 95% nuo 30 neuronų skaičiaus, bet didžiausias skirtumas tarp rezultatų maždaug yra tik 1%. Reikia nepamiršti ir fakto, kad didėjant neuronų skaičiui, didėja ir vykdymo laikas.

Atsižvelgdami į tokius rezultatus, galime teigti, kad sigmoido aktyvacijos funkcijos atveju matomas pastovumas ir klasifikavimo tikslumai yra panašūs, lyginant pagal paslėptojo sluoksnio neuronų skaičių  $H$ . Be to, iki šiol testuose naudotas neuronų skaičius  $H = 15$  atitinka literatūroje rekomenduojamas vertes, o rezultatas, gautas naudojant tokį skaičių, mažiau nei per 0,5% skiriasi nuo kitų.

### 6.2.5. Morfologinių filtrų įtaka DNT tikslumui

Vienas iš pagrindinių šiame darbe atliekamų testų – hibridinio modelio taikymas pikų detekcijai. Hibridinis modelis – tai morfologinėmis operacijomis ir filtrais paremto algoritmo bei dirbtinio neuronų tinklo kombinacijos taikymas. Toliau aptarsime šio testo detales.

6 skyriaus 6.1 dalyje buvo įsitikinta, kad morfologinėmis operacijomis ir filtrais paremtas algoritmas nufiltruoja foninę smegenų veiklą ir išryškina pikus. Buvo pastebėta, kad šio algoritmo pagalba aptinkama daugiau pikų negu yra iš tikrųjų. Tai reiškia, kad šio algoritmo pagalba galima surasti daug EEG darinių, kurie yra pikai arba yra panašūs į pikus. Svarbu paminėti vieną iš reikšmingiausių algoritmo parametrų – pikų detekcijos ribą  $L$ . Signalų reikšmės, kurios iškyla virš šios ribos – yra laikomos pikais. Optimalus šios ribos pasirinkimas buvo nagrinėjamas 6.1.2 poskyryje. Nagrinėjamam testui atlikti buvo pasirinkta tokia pikų detekcijos ribos  $L$  reikšmė, kad nufiltruotoje EEG liktų daug darinių-kandidatų į pikus ir nebūtų klaidingai atmesti realūs pikai. Taigi,  $L$  formulėje 6.1 naudojamas koeficientas  $d$  pasirinktas lygus 4.

Toliau taikomas dirbtinis neuronų tinklas. Iš esmės, pakartojamas testas, aprašytas 6.2.2 skyrelyje (sąlygos tos pačios). Tačiau duomenys naudojami jau apdorojus juos morfologinėmis operacijomis ir filtrais paremtu algoritmu. Atmestos visos atkarpos, kurias pastarasis algoritmas nufiltravo. Taigi, turime mažesnę imtį ne pikų klasės elementų – sumažėjimas lygus 10033.

Gauti rezultatai nepatvirtina iškelto spėjimo, kad toks hibridinis modelis padėtų pasiekti tikslesnių rezultatų. DNT teisingai nurodė, ar atkarpoje yra pikas, ar jo nėra, 86,04% tikslumu. Rezultatas beveik toks pat kaip ir pirmojo testo. Gauta tokia klaidų matrica:

$$\begin{pmatrix} TP & FP \\ FN & TN \end{pmatrix} = \begin{pmatrix} 339 & 17624 \\ 213 & 108686 \end{pmatrix},$$

Buvo tikimasi, kad atmetus atkarpas, kurios tikrai nėra pikai, sumažėtų pirmos rūšies klaidos tikimybė (tikimybė, kad DNT ras piką, nors jo toje atkarpoje nėra). Tačiau, nepaisant to, kad dalis atkarpų buvo atmestos, ir šiuo atveju pirmos rūšies klaidos tikimybė apytiksliai lygi 14%.

Viena iš priežasčių, kodėl nematome reikšmingo pikų detekcijos tikslumo pagerėjimo, gali būti ta, kad morfologinėmis operacijomis ir filtrais paremtas algoritmas atmeta atkarpas, kurios akivaizdžiai yra ne pikai. Rezultatai rodo, kad tokias atkarpas dirbtinis neuronų tinklas gebėdavo atpažinti ir netaikant pirmojo algoritmo.

### 6.2.6. Konvoliucinis neuroninis tinklas

Vienas iš šiame darbe iškeltų uždavinių – skirtingos struktūros dirbtinių neuronų tinklų taikymas EEG pikų detekcijai. Palyginimui su 6.2.2 atliktu testu, kur naudojamas trijų sluoksnių perceptronas, buvo įgyvendintas konvoliucinis neuronų tinklas. Įgyvendinimas atliktas Python bibliotekos Keras pagalba.

Toliau aprašomas testas atliktas su tokios struktūros konvoliuciniu neuronų tinklu:

1. **Įvesties sluoksnis.** Paduodami EEG duomenys, suskaidyti slenkančio lango principu. Naudojamos analogiškos imtys kaip ir pirmajame teste.
2. **Konvoliuciniai sluoksniai.** Pasirinktas modelis sudarytas iš 2-iejų konvoliucinių sluoksnių, kurie turi po 3 mokomuosius filtrus.
3. **Surinkimo sluoksnis.** Maksimalaus surinkimo sluoksnis, kurio dydis 2, taikomas kiekvienam iš požymių žemėlapių.
4. **Pilnai sujungtas sluoksnis.** Šiame sluoksnyje naudojama 100 paslėptųjų neuronų.
5. **Aktyvacijos funkcija.** Visiems modelio sluoksniams naudojama sigmoidinė aktyvacijos funkcija.

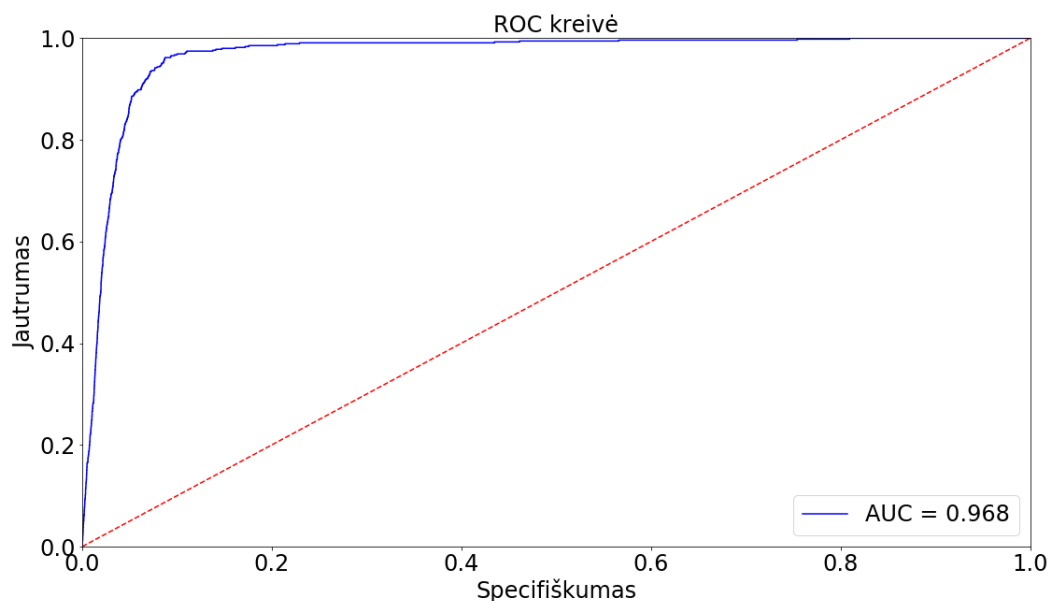
## 6. Mokymosi ciklų skaičius. Maksimalus apmokymo kartų skaičius – 100.

Aprašytos struktūros konvoliucinis neuronų tinklas pasiekė iki 93% tikslumą, kas reiškia, jog klasifikavimo rezultatai pagerėjo, lyginant su 6.2.2 atliktu testu. Vertinant kitas metrikas taip pat pastebimas geresnis klasifikavimas. Nagrinėdami gautą klaidų matricą:

$$\begin{pmatrix} TP & FP \\ FN & TN \end{pmatrix} = \begin{pmatrix} 509 & 8723 \\ 43 & 127620 \end{pmatrix},$$

matome, kad antros rūšies klaidos tikimybė žymiai mažesnė – apie 7,8%, o atitinkamai pirmos rūšies klaidos tikimybė taip pat mažesnė – 6,4%. Tai reiškia, kad konvoliucinio neuronų tinklo pagalba pikų detekcijos kokybė pagerėja – neteisingai praleidžiama mažiau tikrų pikų ir taip pat mažiau atkarpų, kuriose iš tikrųjų pikų nėra, neteisingai priskiriama pikams.

Papildomai, 17 pav. pateikiama ROC kreivė, skirta klasifikatoriaus – konvoliucinio neuronų tinklo – jautrumui ir specifiškumui palyginti. Plotas po šia kreive yra lygus 0,968 ir didesnis, palyginus su testo rezultatais, kai buvo naudojamas 3 sluoksnių perceptronas.



17 pav. Testo, atlikto konvoliuciniu neuronų tinklu, ROC kreivė, atspindinti jautrumo ir specifiškumo sąryšį. AUC (*angl. Area Under Curve*) – plotas po šia kreive.

Tęsiant šiame darbe iškelto uždavinio tyrimą, aprašytą 6.2.5, analogiškas testas buvo atliktas, naudojant hibridinį modelį sudarytą iš algoritmo, paremto morfologinėmis operacijomis ir filtrais, bei konvoliucinio neuronų tinklo. Šio testo rezultatai, kaip ir pirmuoju atveju, nepateisino iškeltos idėjos – konvoliucinio neuronų tinklo klasifikavimo tikslumui reikšmingos įtakos neturėjo tai, kad dalis atkarpų buvo atmestos kaip tikrai ne pikai. Dėl tokių priežasčių buvo nuspręsta, kad toks hibridinis modelis pikų detekcijai nėra tinkamas.

Be to, svarbu paminėti, kad vienas pagrindinių veiksnių, apsunkinančių eksperimentus su konvoliuciniu neuronų tinklu – skaičiavimų kompleksiskumas, kuris reikalauja daug resursų. Vienas bandymas gali užtrukti iki keleto valandų. Dėl tokių priežasčių, įvairių konfigūracijų, parametrų, skirtingų įvesties duomenų testavimas su konvoliuciniu neuronų tinklu tampa ribotas.

### 6.2.7. Rezultatų apibendrinimas

Šio 6.2 skyriaus pagrindinis tikslas buvo išanalizuoti dirbtinių neuronų tinklų panaudojimą EEG pikų aptikimui. Naudojami duomenys buvo realių pacientų minimaliai apdorotos EEG. DNT rezultatai vertinami pagal tikslumą procentais, klaidų matricą, pirmos ir antros rūšies klaidų tikimybes, plotą po ROC kreive. Apibendrinami galime pasakyti, kad DNT taikymas leidžia pasiekti gerų rezultatų – pikų identifikavimo tikslumas tam tikromis sąlygomis siekia daugiau nei 90%.

Svarbiausi veiksniai, kurie daro įtaką klasifikavimo tikslumui yra tokie:

- DNT struktūra – sudėtingesnės konfigūracijos DNT pasižymi geresniais rezultatais: konvoliuciniai neuronų tinklai pranoksta 3-jų sluoksnių perceptronus, tačiau yra labai sunkūs skaičiavimo išteklių prasme;
- DNT parametrai – DNT tikslumo užtikrinimui svarbu atsakingai pasirinkti pagrindinius parametrus: teisingumo ribą, mokymosi greitį, mokymosi ciklų skaičių, aktyvacijos funkciją, apmokymo bei testavimo imčių dydžius;
- DNT patikrinimas – DNT apmokymo metu svarbi šio proceso priežiūra: verta įsitikinti, kad klasifikatorius netampa priklausomas nuo duomenų ar perderinamas. Tam buvo naudojama 4-dalių kryžminė patikra, kurios pagalba buvo įsitikinta, kad DNT veikia tvarkingai;
- EEG pradinių duomenų apdorojimas – DNT pasižymi geresniais rezultatais, jeigu EEG duomenys iš anksto paruošiami: juose pašalinant triukšmą ar juos normalizuojant.

Taip pat, šiame darbe buvo iškeltas tikslas – išsiaiškinti, ar pagerėtų DNT klasifikavimo rezultatai, jeigu prieš tai EEG duomenims būtų pritaikytas algoritmas, paremtas morfologinėmis operacijomis ir filtrais, bei atmestos tos EEG atkarpos, kurios nufiltruojamos kaip tikrai ne pikai. Įgyvendinus tokį hibridinį modelį pikų detekcijai, pavyksta atmesti iki 10% atkarpų, kuriose nėra pikų, tačiau tai nepadeda DNT pasiekti geresnių rezultatų.

## Išvados ir rekomendacijos

Šiame darbe buvo analizuojami medicininiai signalai – elektroencefalogramos. Darbo metu įgyvendinti du skirtingi metodai elektroencefalogramų pikų detekcijai – morfologinėmis operacijomis ir filtrais paremtas algoritmas bei dirbtiniai neuronų tinklai. Atlikti testai apima skirtingus eksperimentus, kai keičiami algoritmų parametrai, taikomi struktūros pakeitimai, papildomai apdorojami duomenys, sujungiami nagrinėjami metodai ir vertinami rezultatai. Visi bandymai įgyvendinti naudojant realių pacientų elektroencefalogramas.

Atlikus darbą ir apibendrinus rezultatus, gautos tokios išvados:

1. Remiantis literatūros analize ir 6.1 skyriuje atliktais eksperimentais, įrodyta, kad morfologinėmis operacijomis ir filtrais paremtas algoritmas tinka elektroencefalogramų analizei, kadangi nufiltruoja foninę smegenų veiklą ir išryškina pikus, tačiau patikimumas nėra idealus – vidutiniškai apie 80%. Taip pat, nustatyta, kad didžiausią įtaką algoritmo tikslumui turi šie parametrai:
  - optimali signalo atkarpa analizei yra tarp 4 ir 6 sekundžių;
  - pikų detekcijos riba kiekvienam pacientui turėtų būti parenkama individualiai, koeficientas  $d$  gali svyruoti tarp 2 ir 12;
  - optimalus struktūrinis elementas – parabolė – turėtų būti 4 kartus ilgesnė, nei signalo arkų pločių mediana;
2. Skyriuje 6.2.2 aprašyti bandymai rodo, kad galima pasiekti maždaug 86% pikų detekcijos tikslumą, taikant nesudėtingos struktūros dirbtinį neuronų tinklą – 3 sluoksnių perceptroną. Be to, gauto klasifikatoriaus plotas po ROC kreive lygus 0,8. Taip pat, nustatyti šie pastebėjimai:
  - DNT gali aptikti daugiau pikų negu algoritmas, paremtas morfologinėmis operacijomis ir filtrais, tačiau egzistuoja tikimybė, kad DNT piko neras, o atkarpa, kurios nėra pikai, atpažins kaip pikus;
  - DNT tikslumas pagerėja iki 95%, jeigu naudojami duomenys yra normalizuojami, taip pat maždaug 3 kartus pagerėja tikrų pikų atskyrimas nuo atkarpų, kurios nėra pikai, o plotas po ROC kreive siekia 0,97;
  - DNT tikslumas, kai naudojamos skirtingos aktyvacijos funkcijos – sigmoidinė arba hiperbolinio tangento – svyruoja mažai, daugiausia iki 2%, tad šias funkcijas lyginant tarpusavyje reikšmingos įtakos rezultatams nėra;
  - DNT tikslumas didžiausias, kai paslėptajame sluoksnyje yra bent 30 neuronų;
3. Atlikus skyriuje 6.2.5 aprašytą eksperimentą, kai atkarpos, kuriose tikrai nėra pikų, atmetamos morfologinėmis operacijomis ir filtrais paremtu algoritmu, o po to pikų atpažinimas tęsiamas DNT pagalba – nepavyko gauti geresnių rezultatų. DNT tikslumas nepagerėjo, o iš rezultatų buvo pastebėta, kad pirmasis algoritmas pašalina tas atkarpas, kurias DNT ir taip lengvai atpažįsta kaip ne pikus.
4. Skyriuje 6.2.6 aprašyti bandymai rodo, kad pikų detekcijos tikslumas išauga iki 93%, jeigu pikų detekcijai naudojamas konvoliucinis neuronų tinklas. Be to, gauto klasifikatoriaus plotas po ROC kreive padidėja iki 0,968. Taip pat, nustatyti šie pastebėjimai:

- palyginus su daugiasluoksniu perceptronu, konvoliucinis neuronų tinklas geriau identifikuoja gydytojų pažymėtus pikus ir mažiau atkarpų priskiria pikams, kuriose iš tikrųjų pikų nėra;
- nors konvoliucinis neuronų tinklas leidžia pasiekti gerų rezultatų, tačiau bandymus riboja didelių skaičiavimo išteklių poreikis;
- hibridinis modelis, sudarytas iš morfologinėmis operacijomis ir filtrais paremto algoritmo bei konvoliucinio neuronų tinklo, kaip ir daugiasluoksniu perceptrono atveju, pasiekti geresnių rezultatų nepadedą.

## Ateities tyrimų planas

Atsižvelgiant į šiame darbe analizuotus tyrimus, toliau automatinio EEG apdorojimo darbus galima tęsti atliekant tokius uždavinius:

1. Kitų duomenų paruošimo ir apdorojimo metodų tyrimas. Vienas iš tokių metodų galėtų būti bangelių (*angl. wavelet*) transformacija. Vertėtų išsiaiškinti, ar toks būdas yra tinkamas kaip išankstinis EEG duomenų paruošimas ir galėtų pagerinti dirbtinių neuronų tinklų efektyvumą.
2. Dirbtinių neuronų tinklų architektūros ir parametrų optimizavimas. Pavyzdžiui, šiam uždaviniui spręsti galima apsvarstyti genetinio algoritmo panaudojimo galimybes.
3. Dirbtinių neuronų tinklų taikymo apdorotiems ir neapdorotiems EEG duomenims tobulinimas. Atsižvelgiant į EEG signaluose aptinkamą informaciją, apmokyti DNT atpažinti tiek pikus, tiek *Vertex* bangas (3-klasių klasifikacija).
4. Algoritmų įgyvendinimas našiose skaičiavimų platformose. Siekiant efektyvaus veikimo, vertėtų analizuoti programinio kodo išlygiagretinimo galimybes.



## Literatūros šaltiniai

- [1] U. Rajendra Acharya, Shu LihOh, Yuki Hagiwara, Jen Hong Tan, and Hojjat Adeli. Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. *Computers in Biology and Medicine*, September 1, 2018, 100: 270-278.
- [2] Diego Alvarez-Estevez. European Data Format.  
<http://www.edfplus.info/>.
- [3] Guangyi Chen. Automatic EEG seizure detection using dual-tree complex wavelet-fourier features. *Expert Systems with Applications*, 2014.
- [4] Wikimedia Commons. 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](https://commons.wikimedia.org/wiki/File:21_electrodes_of_International_10-20_system_for_EEG.svg).
- [5] David Cournapeau. *scikit-learn*, 2019.  
<https://scikit-learn.org/stable/>.
- [6] Rokas Mykolas Deveikis. Magistro baigiamasis darbas: Dirbtinių neuroninių tinklų panaudojimas elektroencefalogramų analizei. Vilniaus Universitetas, 2018.
- [7] Keras developers. *Keras: The Python Deep Learning library*, 2015.  
<https://keras.io/>.
- [8] NumPy developers. *NumPy*, 2018.  
<http://www.numpy.org/>.
- [9] SciPy developers. *SciPy*, 2018.  
<https://www.scipy.org/>.
- [10] Montreal Institute for Learning Algorithms. *Theano*, 2017.  
<https://keras.io/>.
- [11] Nihal Fatma Güler, Elif Derya Übeyli, and Inan Güler. Recurrent neural networks employing Lyapunov exponents for EEG signals classification. *Expert Systems with Applications* 29: 506–514, 2005.
- [12] I. Goodfellow, Y. Bengio, and A. Courville. *Deep Learning*. MIT Press, 2016.
- [13] Ling Guo, Daniel Rivero, and Alejandro Pazos. Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks. *Journal of Neuroscience Methods*, 2010.
- [14] Jonathan J. Halford. Computerized epileptiform transient detection in the scalp electroencephalogram: Obstacles to progress and the example of computerized ECG interpretation. *Clinical Neurophysiology*, 2009.
- [15] Simon Haykin. *Neural Networks and Learning Machines*. Pearson Prentice Hall, 2009.

- [16] John Hunter, Darren Dale, Eric Firing, Michael Droettboom, and the Matplotlib development team. Matplotlib, 2018.  
<https://matplotlib.org/>.
- [17] Howard J. Carey III. EEG interictal spike detection using artificial neural networks. Virginia Commonwealth University, 2016.
- [18] A. Juozapavičius, G. Bacevičius, D. Bugelskis, and R. Samaitienė. EEG analysis – automatic spike detection. *Nonlinear Analysis: Modelling and Control*. 16(4):375 – 386, 2011.
- [19] Søren Kaas, Søren Kaas, Henrik Nielsen, and Ole Winther. Convolutional LSTM Networks for Subcellular Localization of Proteins. *Algorithms for Computational Biology*, 2015.
- [20] He Kaiming, Zhang Xiangyu, Ren Shaoqing, and Sun Jian. Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. *IEEE International Conference on Computer Vision (ICCV)*, 2015.
- [21] Cheng-Wen Ko and Hsiao-Wen Chung. Automatic spike detection via an artificial neural network using raw EEG data: effects of data preparation and implications in the limitations of online recognition. *Clinical Neurophysiology III (2000)* 477 – 481, 1999.
- [22] Cheng-Wen Ko, Hsiao-Wen Chung, Yue-Der Lin, and Gwo-Jen Jan. An EEG spike detection algorithm using artificial neural network with multi-channel correlation. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Vol. 20, No 4., 1998.
- [23] Moshe Kravchik and Asaf Shabtai. Detecting Cyber Attacks in Industrial Control Systems Using Convolutional Neural Networks. *Industrial Control and SCADA Systems*, October 19, 2018, Canada.
- [24] Yann LeCun, Leon Bottou, Genevieve B. Orr, and Klaus-Robert Müller. *Efficient BackProp. Neural Networks: tricks of the trade*, Springer., 1998.
- [25] G. Mirchandani and W. Cao. On hidden nodes for neural nets. *IEEE Transactions on Circuits and Systems*, 36(5), 661-664., 1989.
- [26] Andrius Vytautas Misiukas Misiūnas. *Magistro baigiamasis darbas: Automatinė elektroencefalogramų analizė*. Vilniaus Universitetas, 2015.
- [27] Holger Nahrstaedt. *PyEDFlib – EDF/BDF Toolbox in Python*, 2018.  
<http://pyedflib.readthedocs.io/en/latest/#description>.
- [28] E. Niedermeyer and F.H.L. Da Silva. *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. Lippincott Williams & Wilkins, 2004.
- [29] Ozdamar O. and Kalayci T. Detection of spikes with artificial neural networks using raw EEG. *Comput Biomed Res*. 31(2):122-42., 1998.
- [30] Saeid Sanei and J.A. Chambers. *EEG Signal Processing*. John Wiley & Sons, 2007.

- [31] Abdulhamit Subasi, M. Kemal Kiymik, Ahmet Alkan, and Etem Koklukaya. Neural Network Classification of EEG Signals by Using AR with MLE Preprocessing for Epileptic Seizure Detection. *Mathematical and Computational Applications*, 2005.
- [32] W.R.S Webber, R.S Fisher, and R.P Lesser. Automatic EEG Spike Detection: What Should The Computer Look For? *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society Volume 13: 1991, 1991*, pp. 1195-1196, 1991.
- [33] G. Xu, J. Wang, Q. Zhang, and J. Zhu. An automatic 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*, pp. 170–175.
- [34] X. Zhang and Y. LeCun. *Text Understanding from Scratch*. CoRR, 2015.