

VILNIAUS UNIVERSITETAS
MATEMATIKOS IR INFORMATIKOS FAKULTETAS
KOMPIUTERIJOS KATEDRA

Magistro baigiamasis darbas

**Dirbtinių neuroninių tinklų panaudojimas elektroencefalogramų
analizei**

Atliko:

Rokas Mykolas Deveikis (parašas)

Darbo vadovas:

Prof. dr. Tadas Meškauskas

Vilnius
2018

Turinys

| | |
|--|----|
| Anotacija..... | 3 |
| Summary..... | 4 |
| Terminų žodynas | 5 |
| 1. Įvadas..... | 6 |
| 2. Elektroencefalogramų savybės ir panaudojimas diagnostikoje..... | 7 |
| 2.1 EEG medicininėje diagnostikoje | 7 |
| 2.2 EEG triukšmai..... | 8 |
| 2.2.1 50 Hz elektros tinklo triukšmai | 9 |
| 2.2.2 Akių judesių sukelti triukšmai..... | 9 |
| 2.2.3 EKG triukšmai..... | 9 |
| 2.3 Rolando epilepsija ir jai būdingi EEG pikai | 10 |
| 2.4 Dirbtinių neuroninių tinklų pritaikymas EEG analizėje | 11 |
| 3. Tyrimo metodika ir naudojami duomenys | 14 |
| 3.1 Metodikos aprašymas | 14 |
| 3.2 Duomenų surinkimas ir paruošimas | 14 |
| 3.2.1 Elementų trukmės išskyrimas | 15 |
| 3.2.2 Signalų apdorojimas pašalinant 50 Hz elektros tinklo triukšmus | 16 |
| 3.3 Duomenų aprašymas..... | 18 |
| 4. Algoritmų taikymas | 22 |
| 4.1 Tiesinis neuroninis tinklas | 22 |
| 4.1.1 Rezultatų vertinimo metodika | 26 |
| 4.2 Rekurentinis neuroninis tinklas | 34 |
| 4.2.1 LSTM modelis..... | 34 |
| 4.2.2 Tyrimo eiga | 35 |
| 4.3 Papildomo neuroninio tinklo įvedimas | 37 |
| 4.3.1 I sluoksnis | 38 |
| 4.3.2 II sluoksnis..... | 38 |
| 4.4 Praktinis pritaikymas | 39 |
| 5. Rezultatai | 42 |
| 6. Išvados ir rekomendacijos | 43 |
| 7. Ateities tyrimų planas..... | 44 |
| Padėkos..... | 45 |
| Literatūros sąrašas | 46 |
| PRIEDAS A: Eksperto vertinimas | 49 |

Anotacija

Šiame darbe analizuota galimybė atlikti automatizuotą elektroencefalogramų (EEG) analizę, išskiriant tam tikroms ligoms būdingus elementus. Kaip tyrimo objektas pasirinkti EEG fragmentai (dar vadinami pikais), būdingi gerybinei vaikystės epilepsijai su centrotemporalinėmis iškrovomis (angl. *benign childhood epilepsy with centrotemporal spikes*), dar vadinamai Rolando epilepsija (angl. *Rolandic epilepsy*). Siekiant, kad vertinant aukščiau minėtus elementus nereikėtų aprašyti jų morfologijos ir kad analizės algoritmą būtų galima nesunkiai priderinti kito pobūdžio elementams klasifikuoti, pasirinktas analizės metodas remiasi neuroniniais tinklais. Darbo eigoje parašyta programa, skirta duomenų surinkimui ir su eksperto pagalba surinkti trijų pacientų EEG su pikų koordinatėmis, kurios panaudotos apmokant neuroninį tinklą. Pavyko sukurti tiesiniu (angl. *feedforward*) neuroniniu tinklu paremtą algoritmą, sugebantį identifikuoti ~70% (iki 99%) tyrime naudotų pikų, lyginant su kitu automatizuotos EEG analizės algoritmu arba ~97%, lyginant su eksperto pateiktais duomenimis. Remiantis šiuo algoritmu, sukurta programa, skirta EEG analizei ir gebanti išskirti Rolando epilepsijai būdingus pikus.

Summary

Application of Artificial Neural Networks for Analysis of Electroencephalograms

In this paper, an analysis of electroencephalograms (EEG) is presented with the purpose to identify elements associated with certain neurological conditions. More specifically, the paper focuses on benign childhood epilepsy with centrotemporal spikes, also (called Rolandic epilepsy). Artificial neural networks have been chosen as the main analysis tool in order to avoid common pitfalls of automatic analysis algorithms, such as the necessity to hardcode morphology of spikes, in which case the algorithms have to be completely rewritten for different conditions. An application has been developed to collect EEG spike data from three patients and spike data with exact spike coordinates was collected with a help of an expert. In order to develop automatic analysis algorithm I have investigated classification quality of feedforward and recurrent (based on LSTM model) neural networks and compared results with automatic EEG analysis algorithm based on mathematical morphological filters and data collected from expert.

In this research – feedforward neural network outperformed recurrent neural network. Algorithm based on former was able to identify (on average) ~95% of spikes, identified by expert and ~70% of spikes identified by algorithm based on morphological filters. Nevertheless – not all elements classified as spikes by aforementioned algorithm were actual spikes therefore I conclude that algorithm based on feedforward neural network is suitable for identification (with average spike recognition exceeding 70%) of spikes associated with Rolandic epilepsy from raw EEG data.

Terminų žodynas

Rolando epilepsija - gerybinė vaikystės epilepsija su centrotemporalinėmis iškrovomis (angl. *benign childhood epilepsy with centrotemporal spikes*)

EEG – Elektorencefalograma

EDF — Europos duomenų formatas (angl. *European Data Format*)

Aktyvacijos funkcija (angl. *Activation Function*) – neuroniniame tinkle naudojama funkcija, skirta transformuoti įvesties duomenis. Pagal šios funkcijos rezultatą sprendžiama, ar neuronas bus aktyvuotas

1. Įvadas

Signalų analizė – plati mokslo sritis, apimanti įvairios kilmės signalų surinkimą, modifikavimą ir tolesnį tyrimą. Dėl didelių duomenų kiekių ji šiandien sunkiai įsivaizduojama be kompiuterinio signalų apdorojimo. Analizuojant signalus, duomenų apdorojimas kompiuteriu gali būti naudojamas visuose etapuose – nuo duomenų paruošimo iki galutinės analizės ar modifikavimo. Ne išimtis ir žmogaus organizmo generuojami elektrofiziologiniai signalai. Šiame darbe tiriamas vienas iš tokių signalų – elektroencefalogramos (EEG). Tai – žmogaus smegenų kuriamos elektros srovės matavimai, atliekami siekiant nustatyti įvairias ligas, analizuoti miegą ar bandant suprasti, kaip smegenys apdoroja informaciją [1]. Tačiau, nepaisant panaudojimo platumo, medicininė diagnostika išlieka pagrindinė EEG panaudojimo sritis ir svarbiausias analizės rezultatas yra galimybė įvertinti tam tikrų anomalijų pasireiškimą.

EEG analizė daugeliu atvejų atliekama rankiniu būdu, gydytojui vizualiai vertinant signalą ir ieškant įvairių požymių, būdingų tam tikroms ligoms [18]. Atsižvelgiant į tai, kad tokie matavimai gali būti atliekami pakankamai ilgą laiką, o pačios EEG dažniausiai sudarytos iš 21 kanalo (o tam tikrais atvejais – net ir iki 60), tokia analizė yra sudėtinga bei užimanti daug laiko. Siekiant išspręsti šią problemą, kuriami įvairūs automatiniai analizės metodai (žr. [18], [21], [27]), tačiau jų gaunami rezultatai ne visada leidžia efektyviai surasti ieškomus elementus bei dažnu atveju yra pritaikyti analizuoti tik vieno tipo darinius.

Pagrindinis šio darbo tikslas – ištirti galimybę analizuoti EEG panaudojant dirbtinius neuroninius tinklus. Šis metodas pasirinktas siekiant išspręsti aukščiau įvardintas problemas bei sukurti algoritmą, su kurio pagalba būtų galima ne tik tiksliai įvertinti EEG duomenis, tačiau ir jų nesunkiai pritaikyti ligoms diagnozuoti. Kaip tyrimo objektas pasirinkti EEG pikai, būdingi gerybinei vaikystės epilepsijai su centrotemporalinėmis iškrovomis (angl. benign childhood epilepsy with centrotemporal spikes), tačiau naudojami metodai gali būti pritaikyti ir kitoms epilepsijos rūšims ar smegenų pažeidimams diagnozuoti. Taip pat šiuo darbu siekiama sukurti automatinei EEG analizei pritaikytą algoritmą.

Šiame darbe panaudoti EEG ir jose pasitaikančių triukšmą aprašymai iš autoriaus mokslo tiriamojo darbo (aptariami 2 skyriuje) bei pritaikytas tame pačiame darbe aprašytas 50Hz filtras (aprašytas 3 skyriuje), skirtas pašalinti elektros tinklo triukšmus.

Darbas suskirstytas į dvi pagrindines dalis:


- Pirmojoje dalyje apžvelgiami tiriamai epilepsijos rūšiai būdingi EEG pikai, dirbtiniai neuroniniai tinklai, jų rūšys ir taikymo medicininėje diagnostikoje galimybės;
- Antrojoje dalyje tiriamas konkrečių algoritmų taikymas, dirbant su turimais duomenimis ir siekiant įvertinti įvairių tipų neuroninių tinklų ir jų parametrų tinkamumą.

2. Elektroencefalogramų savybės ir panaudojimas diagnostikoje

2.1 EEG medicininėje diagnostikoje

Apie 1830 m. Carlo Matteucci ir Emil Du Bois pirmieji pasiūlė idėją matuoti žmogaus kūno sukuriamus elektros signalus. Kiek vėliau pastebėta, kad matuojant smegenų sukuriama elektros krūvį galima identifikuoti tam tikrus neurologinius pakitimus, pavyzdžiui, epilepsiją [1]. Nuo tada elektrofiziologijos mokslas smarkiai patobulėjo ir šiandien yra pritaikomas atliekant elektroencefalogramas, elektrookulogramas, elektrokardiogramas ir kitus tyrimus. Nepaisant tokių išsivysčiusių modernių diagnostinių procedūrų kaip magnetinis rezonansas ar kompiuterinė tomografija, elektrofiziologiniai matavimai tebėra plačiai naudojami ir šiandien. Šiame darbe analizuojamos būtent elektroencefalogramos (toliau - EEG) ir jų savybės.

Medicinoje EEG naudojamos stebėti smegenų aktyvumą ir identifikuoti nukrypimus nuo normos. Vienas iš dažniausių EEG panaudojimų – epilepsijos aptikimas [2], tačiau jos taip pat pakankamai dažnai naudojamos ir tiriant miego sutrikimus, komos būseną ar kitus smegenų sutrikimus. Tokio tyrimo metu ant žmogaus skalpo išdėliojamas tam tikras kiekis elektrodų ir per tam tikrą laiko tarpą iš jų surenkami duomenys apie fiksuojamos įtampos pokyčius. Tiek matavimo laikas, tiek elektrodų kiekis priklauso nuo tyrimo srities. Atliekant EEG diagnostiką, dažniausiai naudojama tarptautinė 10-20 elektrodų išdėstymo schema (1 pav.), kai ant žmogaus skalpo išdėstomas 21 elektrodas, tarp jų paliekant tarpus, lygius 10-20% bendro atstumo tarp skalpo priekio ir galo bei kairės ir dešinės pusės. Vieningo metodo naudojimas leidžia lengviau palyginti skirtingų pacientų rezultatus ir užtikrina, kad pastarieji nebus iškraipyti skirtingų skalpo dydžių [1]. Taip pat elektrofiziologiniai matavimai gali būti kombinuojami. Vienas dažniausių pavyzdžių – kartu su EEG matavimu atliekami elektrookulogramų (EOG) matavimai tiriant miego sutrikimus.



1 pav. 10-20 elektrodų išdėstymo schema [12]

Vienas iš pagrindinių EEG trūkumų yra tai, kad dėl pakankamai mažos raiškos yra sudėtinga išskirti tam tikras smegenų sritis [4]. Visgi, kaip minėta anksčiau, šis metodas yra iki šiol plačiai naudojamas ir turi nemažai privalumų, tokių kaip:

- Mažesnė (lyginant su alternatyviomis sistemomis, tokiomis kaip magnetinis rezonansas) kaina [5];
- Tai – neinvazinis metodas;
- Lyginant su kitomis smegenų skenavimo technologijomis, EEG nėra toks jautrus pacientų judesiams [6];
- Atsižvelgiant į tai, kad įranga yra pakankamai mobili, ji gali būti greičiau sumontuota ir nėra tokia reikli patalpoms.

Atliekant EEG matavimus, dažniausiai ieškoma tam tikrų elementų, kurie nėra būdingi įprastai smegenų veiklai (šiam darbe dar vadinama fonine smegenų veikla), kurioje dominuoja keletas pagrindinių smegenų bangų. Literatūroje galima rasti keletą skirtingų smegenų bangų klasifikavimų [39]. Dažniausiai sutinkamas išskiria penkias pagrindines bangų grupes, priklausomai nuo veikimo diapazono [1]:

- delta (δ) – 0,5 - 4 Hz;
- alpha (α) - <8-16 Hz;
- theta (θ): 4 – 8 Hz;
- beta (β) – 14-26 Hz;
- gamma (γ) 30 – 100 Hz.

Kaip alternatyvą Klimesch [40] išskyrė keturis bangų tipus, būdingus būtent žmonėms ir labiausiai besiskiriančius nuo kitų žinduolių: Delta: 1–4 Hz; Theta: 4–7 Hz; Alpha: 7.5–12.5 Hz; Alpha 1: 7.5–10 Hz; Alpha 2: 10–12.5 Hz; Beta: 13–20 Hz. Tačiau, nepaisant skirtingų metodikų, galima teigti, kad reikšmingos informacijos dažnių diapazone iki 0,4 Hz ir virš 100 Hz nėra. Taigi siekiant kiek įmanoma labiau išvalyti signalą, paliekant tik svarbią informaciją, tikslinga anksčiau minėtą diapazoną pašalinti, kaip darbinį diapazoną paliekant viską nuo 0,4 Hz iki 100 Hz.

Svarbu pabrėžti, kad šiame darbe aprašomi metodai gali būti naudojami išskirti daugeliui EEG darinių, tačiau, siekiant apibrėžti konkrečią tyrimo sritį, pasirinkti būtent gerybinei vaikystės epilepsijai su centrotemporalinėmis iškrovomis (angl. benign childhood epilepsy with centrotemporal spikes), dar vadinamai Rolando epilepsija (angl. Rolandic epilepsy), būdingi EEG fragmentai. Ši epilepsijos rūšis pasirinkta dėl sąlyginai didelio paplitimo (žr. skyrių 2.3), aiškiai išreikštų pikų ir galimybės gauti tikslius duomenis.

2.2 EEG triukšmai

EEG, kaip ir kiti elektrofiziologiniai matavimai, gali būti paveiktos įvairių triukšmų. Pastarieji apsunkina tiek vizualinę EEG analizę, tiek ir automatizuotų algoritmų darbą, o tikslumas šiuo atveju yra ypač susijęs su tinkamai nustatyta diagnoze. EEG triukšmai skirstomi į du pagrindinius tipus: vidinius (generuojami paciento ar smegenų veiklos) ir išorinius (generuojami matavimo prietaiso ar kitų išorinių veiksnių, kaip netoliese esanti elektroninė įranga). Žemiau išvardinti pagrindiniai triukšmų šaltiniai [1]:

Vidiniai:

- Judesio;
- Akių judesiai (EOG);
- Širdies veikla (EKG);
- Smegenų aktyvumas;
- Prakitavimas.

Išoriniai

- Netoliese esanti elektroninė įranga;
- Elektros tinklo triukšmai (50/60Hz);
- Kiti elektros tinklo trikdžiai;
- Pažeisti laidai;
- Nesubalansuota elektrodų varža.

Šiame skyriuje išsamiau aprašoma keletas dažniausiai pasitaikančių triukšmų:

2.2.1 50 Hz elektros tinklo triukšmai

50Hz elektros tinklo triukšmas atsiranda dėl elektrodų jautrumo elektros tinklo srovei [1]. Nors tokio tipo triukšmą įmanoma nesunkiai pašalinti matavimo metu įdiegus į prietaisą atitinkamus filtrus, deja, iki šiol daug matavimo prietaisų tokio filtro neturi (kas galioja ir tyrime naudojamiems duomenims), taigi tokiu atveju rekomenduojama šalinimą atlikti programiškai iš jau surinktų duomenų. Atsižvelgiant į tai, kad šio tipo triukšmas yra randamas labai siaurame ir pastoviam dažnių diapazone, jo šalinimo procedūra yra ypač paprasta, tačiau reikia atkreipti dėmesį į tai, kad juo paveikiami visi signalai – taigi ši procedūra yra vis tiek naudinga.

2.2.2 Akių judesių sukelti triukšmai

Akių judesių triukšmai atsiranda, kai akies judesio ar mirksėjimo metu atsiradęs raumenų sujudėjimas fiksuojamas ant skalpo esančių elektrodų [1]. Toks signalas vadinamas elektrookulograma (EOG) ir taip pat naudojamas medicininėje diagnostikoje, tačiau yra nepageidaujamas EEG.

Dažniausiai šis signalas fiksuojamas skalpo priekyje esančių elektrodų [3], kas apriboja paveiktų kanalų skaičių, o konkrečių kanalų žinojimas palengvina tolesnę analizę. Svarbiausia šio triukšmo savybė – tai, kad akių judesiai labai panašūs į EEG pakitimus, atsirandančius esant tam tikriems smegenų pažeidimams. Taigi tokie triukšmai gali būtų klaidingos diagnozės priežastimi, kai triukšmas identifikuojamas kaip smegenų anomalija ir apsunkina tiek automatizuotų algoritmų darbą, tiek vizualinę analizę. Taigi sėkmingai pašalinus tokio tipo triukšmus, galima ženkliai pagerinti diagnostikos kokybę.

Dalis šio tipo triukšmų pašalinimo algoritmų remiasi regresija paremtais metodais, kai triukšmo paveiktas signalas lyginamas su atitinkamu vien tik pirminį triukšmo šaltinį turinčiu kanalu (dažniausiai - EOG) [41] darant prielaidą, kad triukšmas ir originalus jo šaltinis pasižymi tokia pačia morfologija. Tačiau tokio tipo metodų naudojimas ne visada įmanomas, atsižvelgiant į tai, kad atskaitos kanalo duomenyse gali nebūti (t. y. ne visa įranga kartu matuoja ir EOG).

2.2.3 EKG triukšmai

Dar vienas triukšmo šaltinis yra EKG arba širdies darbo sukelti triukšmai. Šie triukšmai atsiranda, kai ant skalpo įtaisyti elektrodai užfiksuoja širdies darbą [42]. Šie triukšmai labai panašūs į EOG triukšmus tuo aspektu, kad jų morfologija nėra identiška gryno EKG signalo morfologijai.

2.3 Rolando epilepsija ir jai būdingi EEG pikai

Tai – viena iš dažniausiai vaikams pasitaikančių epilepsijos rūšių. Vidutiniškai ja serga apie 23% ankstyvo mokyklinio amžiaus (apie 7 metų) vaikų [14]. Taip pat dažniausiai šia liga serga berniukai, apytiksliai santykiu 1:1,5 [15]. Šia epilepsija sergantiems pacientams dažniausiai būdingi trumpi traukuliai, pasireiškiantys veido srityje, tačiau neretai pereinantys ir į galūnes. Ši epilepsijos rūšis pasižymi gana specifiniais dariniais (pikais), matomais EEG. Tipinis pikas dažniausiai pasižymi didele amplitude ir fazės pokyčiu (t. y. apima tiek teigiamas, tiek neigiamas įtampos reikšmes) [14]. Taip pat svarbu pabrėžti, kad egzistuoja ir netipiniai Rolando epilepsijos požymiai, tačiau remiantis įvairiais šaltiniais jie sudaro nuo 1% [15] iki 7% visų atvejų [16, psl. 49], taigi šiame darbe nagrinėjami nebus.

Aukščiau minėti pikai gali pasižymėti skirtingomis amplitudėmis ar turėti šiek tiek skirtingas formas, tačiau visada pasižymi aukščiau aptartomis savybėmis.

Taip pat pikai gali būti skirstomi į du tipus:

- **Aštrios bangos** – trumpalaikiai, aiškiai iš foninės smegenų veiklos išskiriami **70 – 200 ms.** trukmės EEG dariniai. Pagrindinis komponentas dažniausiai būna neigiamos fazės.
- **Pikai** - trumpalaikiai, aiškiai iš foninės smegenų veiklos išskiriami **20 – 70 ms.** trukmės EEG dariniai. Pagrindinis komponentas dažniausiai būna neigiamos fazės [17].

Kaip matome iš apibrėžimo, pikai ir aštrios bangos yra labai panašūs, o pagrindinis jų skirtumas – trukmė. Remiantis Chrysostomos P. Panayiotopoulos [17], tiek piko, tiek aštrios bangos pirmasis arba “kilimo” etapas (t. y. atkarpa, kol pikas pasiekia lokalų maksimumą) yra vienodi, tačiau aštrių bangų atveju nusileidimo etapas yra ilgesnis. Kadangi šiame darbe pikai ir aštrios bangos atskirai nėra tyrinėjami, siekiant paprastumo, nuo šiol abu šie dariniai bus vadinami *pikais*.

Aptariamieji pikai iš kitų signalo elementų išsiskiria savo specifine morfologija, kuri gali būti aprašoma vertinant amplitudę, trukmę ir aštrumą (angl. *sharpness*). Frost J.D. [26], tirdamas Rolando epilepsija sergančių pacientų EEG, išskyrė aukščiau aptariamų dydžių vertes, būdingas iki 70 ms trukmės pikams bei apskaičiavo CSP pikų indeksą (angl. *composite spike parameter* arba CSP). Šiuo atveju aštrumas apskaičiuojamas kaip antros eilės išvestinė nuo įtampos piko aukščiausiam (arba žemiausiam) taške ir normalizuota pagal amplitudę. Autoriaus išskirtos piko charakteristikos pateikiamos lentelėje:

Lentelė 1. Frost J.D. [26] išskirtos Rolando epilepsijai būdingų iki 70 ms trukmės pikų charakteristikos.

| | Vidurkis | Standartinis nuokrypis |
|------------------------------|-----------------|-------------------------------|
| Amplitudė (μV) | 160,9 | 68,0 |
| Trukmė (ms) | 74 6,7 | 6,7 |
| Aštrumas(μV /ms/8 ms) | 0,022 | 0,004 |

Taip pat papildomai pikai gali būti išskiriami pagal šiuos požymius: 1. Piko amplitudė bent du kartus aukštesnė už dominuojančios bangos amplitudę; 2. Nuožulnesnis besileidžiantis piko bangos šlaitas [18]. Gloor (1975) [28] apibrėžė, kad minima dominuojanti banga apima 5 s. atkarpa iki piko einančio signalo.

Remiantis šiais duomenimis, būtų galima atlikti automatinę pikų analizę, tačiau tokiu atveju vertinimas būtų apribotas būtent čia aprašytais pikais, būdingais tik vienai epilepsijos rūšiai, o taip pat toks algoritmas būtų labai jautrus triukšmui. Bandymų sukurti tokio tipo algoritmą buvo ne vienas. Carrie JR. 1972 m. [29] publikavo vieną pirmųjų algoritmų, skirtą identifikuoti EEG esančius pikus. Šis algoritmas rėmėsi tam tikrų piko viršūnės savybių apskaičiavimu. Guedes de Oliveira ir kiti [34] aprašė metodą, skirtą identifikuoti pikus vertinant jų išlinkį, o pikai ir ne pikai buvo atskiriami nustačius tam tikrą ribą. Vienas iš naujesnių darbų, atliktas Vilniaus Universiteto mokslininkų, remiasi signalo analize taikant morfologinius filtrus [21]. Gydytojų-ekspertų vertinimu šis algoritmas sugeba tinkamai identifikuoti ~90% Rolando epilepsijai būdingų pikų.

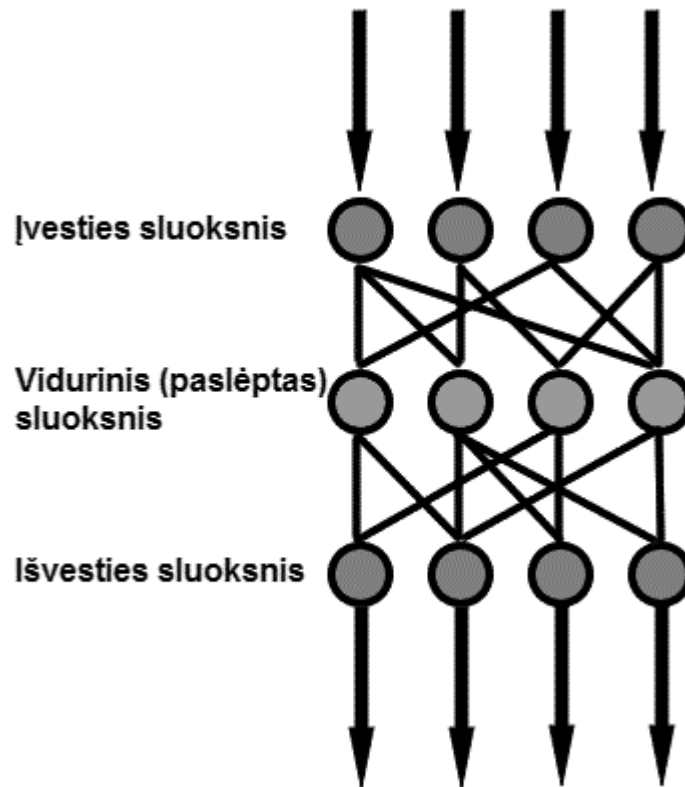
Nors naudojant kai kuriuos iš aprašomų algoritmų gaunami pakankamai geri rezultatai, tačiau jie turi keletą trūkumų:

- 1) Yra jautrus triukšmui, taigi aukštas klasifikavimo tikslumas pasiekiamas ne su visais signalais, o taip pat naudojant algoritmą su skirtingais elektroencefalografais rezultatų kokybė gali nukentėti;
- 2) Gali būti naudojami identifikuoti tik vienai ar keletui ligų būdingus elementus, taigi gali būti sudėtinga (arba net neįmanoma) tokio tipo algoritmus pritaikyti keletui skirtingų ligų diagnozuoti.

Siekiant išspręsti šias problemas, naudojami įvairūs kompiuterinio mokymosi algoritmai, o vienas dažniausių sutinkamų metodų – dirbtiniai neuroniniai tinklai.

2.4 *Dirbtinių neuroninių tinklų pritaikymas EEG analizėje*

Idėja panaudoti dirbtinius neuroninius tinklus siekiant išskirti tam tikras EEG savybes nėra nauja. J. Gotman ir J. Ives [7] vieni pirmųjų analizavo neuroninių tinklų panaudojimą, siekiant išskirti kitais metodais sunkiai identifikuojamas EEG anomalijas. Pagrindinis tokio metodo privalumas yra tai, kad nėra būtina tiksliai nurodyti pikų trukmę (tačiau svarbu – maksimali trukmė) ir morfologija [17], taigi neuroninį tinklą galima paprasčiau pritaikyti darbui su keletu skirtingu būdu įrašytų signalų (pavyzdžiui, įranga, registruojanti skirtingais dažniais) ar keletui skirtingų EEG elementų tipų klasifikavimui. Neuroninių tinklų panaudojimo diagnostikoje tyrimai ilgą laiką buvo vykdomi dviem kryptimis: vieni tyrėjai analizavo jau apdorotus duomenis (žr. Gabor ir Seyal, 1992 [12]; Webber ir kiti, 1996 [24]; Wilson ir kiti, 1999), tuo tarpu kiti imdavo neapdorotus (angl. *raw*) duomenis (žr. Ozdamar ir Kalayci, 1998 [8]). Pastarieji autoriai, tirdami 3600 pacientų EEG bylas, sugebėjo tinkamai identifikuoti EEG anomalijas ~96% atveju. Bendras (teigiamų ir neigiamų) identifikavimo rodiklis siekė ~80%. Tačiau pabandę pakartoti tyrimą, Webber ir kiti gavo gerokai prastesnius rezultatus (atitinkamai 76% ir ~40%, dirbant su neapdorotais EEG).



2 pav. ChengWen ir Hsiao-Wen [9] panaudoto vienakrypčio dirbtinio neuroninio tinklo su trimis sluoksniais schema. Rodyklės simbolizuoja duomenų judėjimą viena kryptimi. CC BY-SA 3.0 licencijos su modifikavimo teise saugoma iliustracija pagal licencijos leidimą panaudota ir modifikuota autoriaus [22]

Cheng-We ir Hsiao-Wen [9] naudojo neuroninį tinklą, sudarytą iš trijų sluoksnių, turintį 30 neuronų įvesties sluoksnyje (skaičius yra lygus jų naudojamam elementų skaičiui atkarpoje), šešis neuronus viduriniame sluoksnyje ir vieną – išvesties sluoksnyje. Jie bandė pakartoti Ozdamar ir Kalayci tyrimą ir priėjo prie išvados, kad klaidingai paruošti duomenys greičiausiai paveikė [8] rezultatus, dirbant su neapdorotais EEG. Pagrindinė bėda, su kuria susidūrė autoriai – pastovi piko vieta (jų atveju – ties dešimtu elementu). Dėl pastovios piko vietos didesnis svoris yra priskiriamas dešimtam neuronui tiesiniame neuroniniame tinkle, taigi dešimtas sekos elementas nulemia, ar atkarpos yra identifikuojamos kaip pikai. Šią problemą K. Cheng-We Ko ir C. Hsiao-Wen bandė spręsti apmokydami neuroninį tinklą su nepastoviomis pikų vietomis, tačiau ir tai neleido pasiekti norimo rezultato. Autoriai savo tyrimą baigė išvada, kad „atsižvelgiant į šių dienų kompiuterių galimybes, dirbtinių neuroninių tinklų panaudojimas neapdorotų EEG analizei greičiausiai nėra įmanomas“ [8].

Vienas iš sprendimų siekiant geresnių rezultatų yra pradinis duomenų apdorojimas. Nigam, ir Graupe [23] analogišką tyrimą atliko prieš tai EEG signalus apdoroję kelių etapų netiesiniu filtru, o apdoroti duomenys buvo klasifikuojami naudojant neuroninį tinklą. Autoriai parodė, kad tokiu atveju įmanoma pasiekti ~97% klasifikavimo tikslumą. Tačiau tokio metodo problema – būtinybė individualiai konfigūruoti filtrą skirtingiems EEG signalams ar skirtingiems fragmentams klasifikuoti.

Webber ir kiti (1996) [24] sukūrė neuroniniu tinklu paremtą EEG pikų klasifikavimo algoritmą ir pademonstravo, kad jis sugeba identifikuoti bent vieną piką 76% EEG signalų, kuriuose yra pikai ir neidentifikavo pikų 93% EEG signalų, kuriuose pikų nebuvo.

Apibendrinant aptartus tyrimus, galima teigti, kad neuroninis tinklas nors ir ne visada pasiekia labai tikslių rezultatų, tačiau iš principo gali būti tinkamas EEG elementų klasifikavimui, siekiant išskirti pikus. Taip pat svarbu pabrėžti, kad neuroniniai tinklai yra pastoviai vystoma sritis, o atsirandantys nauji algoritmai ar jų konfigūracijos gali pagerinti rezultatus.

3. Tyrimo metodika ir naudojami duomenys

3.1 Metodikos aprašymas

Visi bandymai atliekami Python (3.6) programavimo kalba, panaudojant tokias trečiųjų šalių bibliotekas:

Numpy – tai įvairius statistinius skaičiavimus ir darbą su duomenų masyvais optimizuojanti biblioteka [35];

Matplotlib – funkcijų ir grafikų vizualizacijai skirta biblioteka [36];

Pyedflib – biblioteka, skirta nuskaityti EDF/EDF+ bylas ir jas konvertuoti į Numpy tipo masyvus (EEG duomenys dažniausiai pateikiami EDF/EDF+ bylose) [37];

TensorFlow – biblioteka, skirta neuroninio tinklo sukūrimui ir valdymui [19].

Algoritmai, skirti duomenų valdymui (t. y. bylų nuskaitymui, analizei, paruošimui, filtravimui 50Hz filtru ir išsaugojimui), atlikti autoriaus, o konvertavimas iš EDF bylos į Numpy duomenų masyvą atliekamas su Pyedflib biblioteka. Jeigu nenurodyta kitaip, visos aprašomos manipuliacijos ar algoritmai parašyti darbo autoriaus, remiantis atitinkamais šaltiniais.

Neuroniniai tinklai kurti naudojant **TensorFlow** [19] biblioteką, o jų valdymas atliktas su **Keras** biblioteka [20].

3.2 Duomenų surinkimas ir paruošimas

Neuroninio tinklo apmokymui buvo svarbu turėti kuo tikslesnes pikų koordinates. Siekiant kiek įmanoma sumažinti netikslumus, duomenys buvo renkami su eksperto pagalba. Pirmame etape buvo parašyta programa (toliau vadinama klientu), kurioje ekspertas gali žymėti pikus ir darinius, panašius į pikus, kurie nėra pikai. Šiuo atveju bendradarbiauta su viešosios įstaigos Vilniaus universiteto ligoninės Santaros klinikų filialo Vaikų ligoninėje dirbančia vaikų neurologe Dr. Rūta Samaitiene (toliau darbe – ekspertas). Analogiškas duomenų rinkimas panaudotas ir aukščiau aptariamuose darbuose ([7],[8]).

Minėta programa parašyta autoriaus, naudojant jau minėtą Python (3.6) programavimo kalbą ir aukščiau išvardintas bibliotekas:

Programa buvo supakuota į .exe bylą (vykdomąją bylą, angl. *executable*), naudojant *cx_Freeze* biblioteką [38], kartu pridėdant visas reikalingas bibliotekas, pritaikyta veikti 64 bitų operacinėje sistemoje ir perkelta į eksperto kompiuterį. Duomenų surinkimo metu programos funkcionalumas leido žymėti ir trinti tiek pikus, tiek fragmentus, kurie nėra pikai, išsaugoti rezultatus tiek kompiuteryje, tiek ftp serveryje, keisti matomo laiko ar amplitudės intervalus.


Ekspertui programoje pažymėjus pikus ir juos išsaugojus, duomenys buvo įrašomi į tekstinį failą ir perkelti į ftp serverį, iš kur autorius galėjo juos pasiimti. Iš viso surinkta daugiau nei 500 pikų koordinacių ir apie 50 koordinacių – į pikus panašių elementų, kurie nėra pikai.

Svarbu pabrėžti, kad mano žiniomis tokio tipo duomenų surinkimas, tiriant automatinės EEG analizės galimybes Vilniaus universitete ir Santaros klinikose, panaudotas pirmą kartą. Duomenys prieinami Vilniaus universiteto tyrėjams, kas gali palengvinti ateities tyrimus šioje

srityje. Taip pat atsižvelgiant į tai, kad gauti teigiami eksperto atsiliepimai apie programą, duomenis nesudėtinga papildyti.

Be EEG duomenų surinkimo programa turi tokias funkcijas:

- Galimybę įkelti edf/edf+ bylas į FTP serverį;
- Galimybę keisti matomo vaizdo amplitudę ir rodomą laiko intervalą
- Signalų glodinimą slenkančio vidurkio filtru (nurodant elementų skaičių)
- Saugoti pikų koordinatas tiek vartotojo kompiuteryje, tiek FTP serveryje;
- Išsaugoti vartotojo nustatymus



3. pav. Duomenų surinkimui naudotos programos lango pavyzdys.

Minėtame tekstiniame faile duomenys apie pikų vietas saugomi nurodant elemento numerį signalo reikšmių masyve. Atsižvelgiant į tai, kad visi signalai įrašyti naudojant 256 Hz registravimo dažnį, pikų vietas buvo konvertuojamos į laiko vienetus (sekundes), jas padalinant iš 256. Taip pat, remiantis tarpusavio susitarimu, ekspertas pikus žymėjo centre.

3.2.1 Elementų trukmės išskyrimas

Atsižvelgiant į tai, kad ekspertas pažymėdavo tik piko centrą, svarbus etapas buvo nustatyti jo ribas (t. y. EEG atkarpą, kuri bus naudojama apmokant neuroninį tinklą). Šiame darbe aptariama sistema testuojama su vieno tipo epilepsijai (Rolando) būdingais elementais (epilepsijai būdingomis iškrovomis), kurie aprašyti 2 skyriuje. Taip pat atsižvelgiant į tai, kad

tiesioginiai, teikiantys aštrios bangos yra susiję būtent su Rolando epilepsija bei tarpusavyje yra labai panašūs, tolesnis šių elementų atskyrimas nebus vykdomas, o tolesniems tyrimams imama maksimali piko (šiuo atveju – aštrios bangos) trukmė, kuri yra 200 ms. Atsižvelgiant, kad visais atvejais turimo signalo registravimo dažnis yra 256Hz (t. y. 1 laiko eilutės elementas atitinka 3,90625 ms), nuo eksperto nurodyto piko centro imama 25 elementų atkarpa atgal ir 25 elementų atkarpa pirmyn (t. y. ~98 ms į vieną pusę), o bendra atkarpos trukmė sudaro 196 ms. Toks skaičius pasirinktas, siekiant supaprastinti tolesnį duomenų valdymą, kuris taptų sudėtingesnis pasirinkus 51 elementą (t. y. ~199 ms) bei, vizualiai įvertinus, yra pakankamas, kad informacija nebūtų prarasta.

3.2.2 Signalo apdorojimas pašalinant 50 Hz elektros tinklo triukšmus

Kaip aptarta 2 skyriuje, 50Hz elektros tinklo triukšmas atsiranda dėl elektrodų jautrumo elektros tinklo srovei [1]. Atsižvelgiant į tai, kad šio tipo triukšmas yra randamas labai siaurame ir pastoviam dažnių diapazone, jo šalinimo procedūra yra ypač paprasta, tačiau reikia atkreipti dėmesį į tai, kad juo paveikiami visi signalai – taigi ši procedūra yra vis tiek naudinga.

Siekiant išvengti aukščiau paminėtų triukšmų, taikomas 50Hz filtras. Kadangi 50Hz elektros tinklo triukšmas paveikia visus elektrodus, kaip pavyzdys imamas vienas kanalas. Kanalo signalo charakteristika pateikiama žemiau:

Pavadinimas: *F8-AR*;

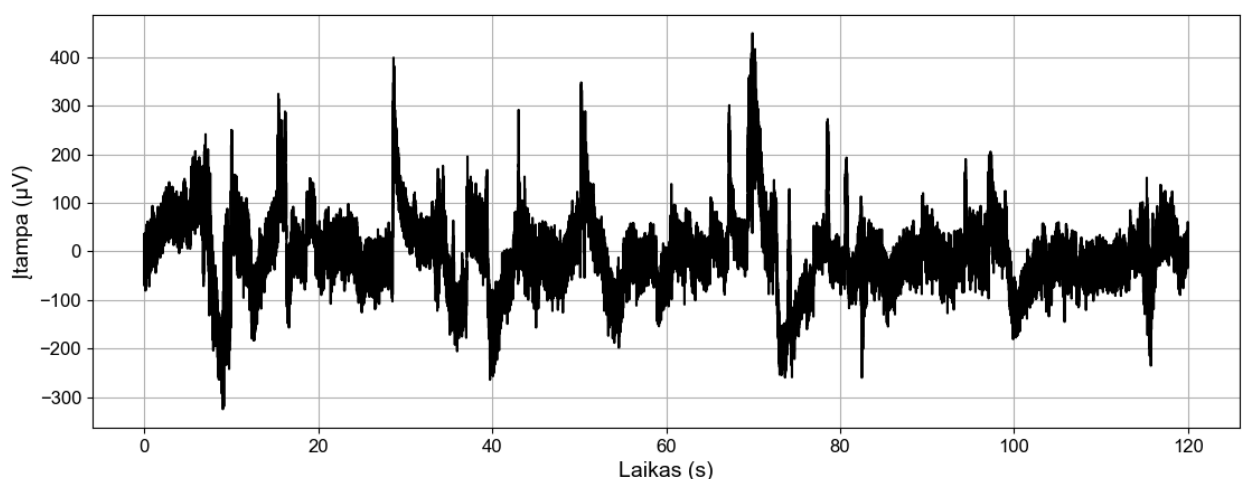
Matavimo trukmė (t): *20 minučių*;

Viso matavimų, per laiką t: 307200;

Matavimo vienetai: *mikro voltai*;

Registravimo dažnis: *256Hz*

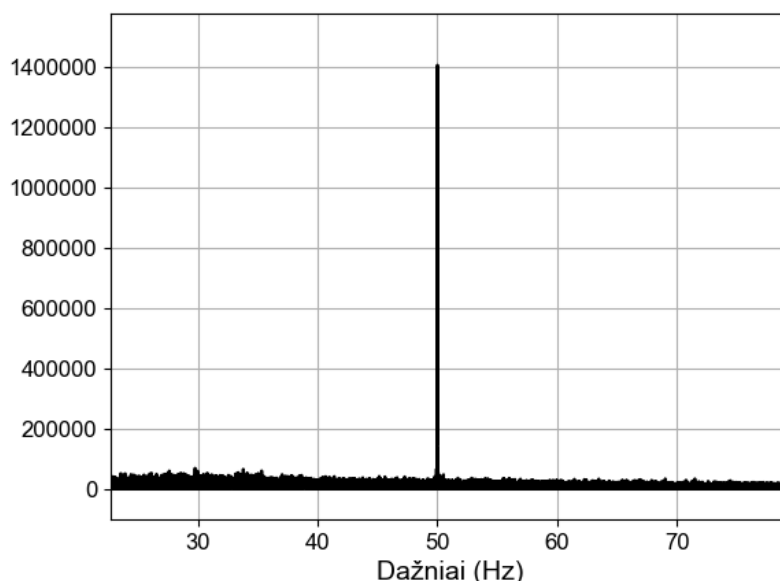
Šio kanalo signalo pavyzdys pateikiamas 4 pav.



4 pav. FP1-RF kanalo sekundžių trukmės neapdoroto signalo 120 sekundžių atkarpa

Analizuojant turimus duomenis, matoma, kad šio tipo triukšmas randamas visuose kanaluose (signalų amplitudžių spektre matome, kad signalas 49 – 51 ruože turi sąlyginai daugiau energijos nei aplink, kas atitinka [1] nurodytą triukšmo apibrėžimą). Priklausomai nuo

duomenų, šis triukšmas turi skirtingą amplitudę, o tai gali būti paaiškinama tuo, kad matavimai nebuvo atlikti viena įranga, tam tikri prietaisai jau gali turėti 50Hz filtrą. 5 pav. kaip pavyzdys pateikiamas vieno paciento F8-AR kanalo amplitudžių spektro fragmentas:



5 pav. Padidinta signalo amplitudžių spektro atkarpa.

Šis filtras įgyvendintas naudojant Furje transformaciją, kai signalas transformuojamas į Furje skleidinį, apskaičiuojant atitinkamus kompleksinius Furje koeficientus:

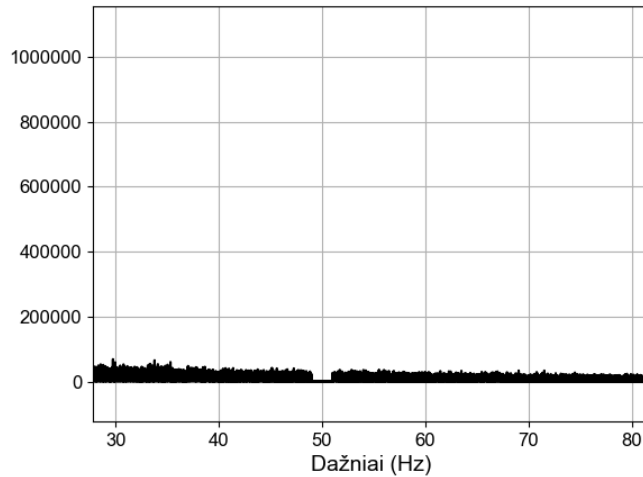
$$c_k = \sum_{j=0}^{N-1} f_j e^{-i\frac{2\pi}{N}jk}$$

Čia N – signalo ilgis; f_j – signalo vertė laiko momentu j ; $k = 0, 1, \dots, N-1$; $j = 0, 1, \dots, N-1$

Siekiant pagreitinti algoritmo veikimą, naudojama greitoji Furje transformacija, įgyvendinta su Numpy bibliotekos funkcija `numpy.fft.fft(x)` (čia x – analizuojamas signalas). Aptariamasis filtras iš pradžių transformuoja signalą x į Furje koeficientus, taip pat apskaičiuojami dažniai, atitinkantys Furje koeficientų reikšmes, naudojant Numpy komandą `numpy.fft.fftfreq`.


Įgyvendinant filtrą, jau atlikus Furje transformaciją, randami atitinkamai 49-51Hz dažnius atitinkantys Furje koeficientų masyvo elementai ir pakeičiami nuliais. Po to, naudojant Numpy bibliotekos funkciją `numpy.fft.ifft(x)`, signalas x transformuojamas atgal.

Nufiltruoto signalo amplitudžių spektro atkarpa pateikiama 6 pav.:



6 pav. Signalo amplitudžių spektro atkarpa, pritaikius 50Hz filtrą

Toliau analizuojant signalą galima matyti, kad vizualiai jis yra žymiai aiškiau suprantamas bei yra lengviau identifikuoti tam tikrus dėsningumus.




7 pav. To paties signalo 4 s. trukmės (priklausomybės nuo laiko grafikas) atkarpa prieš filtravimą (kairėje) ir pritaikius 50Hz filtrą (dešinėje).

Iš 7 pav. matome, kad pritaikius Furjė filtrą triukšmingam signalui, vizualiai jis ženkliai pasikeičia. Iš filtruoto signalo yra lengviau išskirti tam tikrus dėsnius ar vizualiai ieškoti svarbios diagnostinės informacijos.

3.3 Duomenų aprašymas

Kaip aptarta 3.2 skyriuje, tyrime naudojami duomenys gauti iš VšĮ Vilniaus universiteto ligoninės Santaros klinikų, vaikų skyriaus. Vienas duomenų failas (pateikiamas EDF formatu) sudarytas iš 19 EEG kanalų ir 1 EKG (pavyzdys pateikiamas 8 pav.).

Duomenys pateikiami EDF formatu.




8 pav. 5 sekundžių, nefiltruoto, 20-ties kanalų EEG signalo pavyzdys. VšĮ Vilniaus universiteto ligoninės Santaros klinikų, vaikų skyriaus EEG duomenys.

Duomenų imtį sudarė 9 pacientų elektroencefalogramos, iš kurių trijose ekspertas nurodė 499 pikus su tiksliais koordinatėmis.

Lentelė 2. Eksperto pateiktų EEG, kuriose nurodytos pikų koordinatės, aprašymas

| Paciento Nr. | EEG kanalas | Viso pikų kanale | Viso atkarpų | Signalo trukmė (s.) | Signalo registravimo dažnis |
|--------------|-------------|------------------|--------------|---------------------|-----------------------------|
| 1 | T4 | 177 | 47310 | 184.8 | 256 Hz |
| 2 | T3 | 144 | 185550 | 724.8 | 256 Hz |
| 2 | T5 | 28 | 185550 | 724.8 | 256 Hz |
| 3 | P4 | 150 | 66510 | 259.8 | 256 Hz |

Iš viso iš eksperto buvo surinkti 499 pikų pavyzdžiai ir 46 į pikus panašūs elementai, kurie nėra pikai. Surinktų atkarpų su pikais pavyzdžiai pateikiami 9 pav.



9 pav. Iš eksperto surinkti pikų pavyzdžiai. Vertikaliomis linijomis pažymėti pikų centrai


Autoriaus prašymu ekspertas stengėsi pažymėti piko centrą, tačiau dėl objektyvių priežasčių tai padaryti pavyksta ne visada. Norint padidinti tikslumą, visų pikų centrai buvo perskaičiuoti, perkeltant juos pagal mažiausią y ašies (įtampos) reikšmę. Šio patikslinimo pavyzdys pateikiamas 10 pav. Tokiu būdu buvo patikslinti visi surinkti duomenys.

Atsižvelgiant į tai, kad amplitudė eksperto nurodyta kaip viena iš svarbiausių piko charakteristikų (t. y. ekspertas nežymėjo į pikus panašių darinių, kurių amplitudė buvo mažiau nei du kartus didesnė už foninės smegenų veiklos), papildomai įvertintos visos atkarpos.

Lentelė 3. Eksperto nurodytų pikų amplitudės įverčiai

| | |
|------------------------|-------|
| Vidutinė amplitudė | 142,8 |
| Standartinis nuokrypis | 44,2 |
| Mažiausia amplitudė | 51 |
| Didžiausia amplitudė | 325,7 |

Iš 3 lentelės matome, kad eksperto nurodytų pikų vidutinė amplitudė ~12% skiriasi nuo aprašytos 2 skyriuje bei apie 35% skiriasi standartinis nuokrypis (šiam darbe naudojamų pikų jis yra mažesnis). Iš to galima daryti išvadą, kad pažymėti pikai atitinka tipinius Rolando epilepsijos pikus.



10 pav. Perkelta piko centro koordinatė x ašyje. Tiesi vertikali linija rodo pradinę (eksperto nurodytą) piko vietą, o brūkšniuota - naują piko vietą, parinktą pagal mažiausią įtampos vertę 200 ms atkarpoje.

Siekiant kiek įmanoma padidinti naudojamų duomenų kiekį, buvo pridėti pikų duomenys, gauti tas pačias elektroencefalogramas išanalizavus [21] aprašomu algoritmu. Norint įvertinti, ar šiuo algoritmu gauti rezultatai atitinka eksperto vertinimą, parinktos dvi EEG, kurias buvo galima palyginti (kadangi [21] algoritmas pateikia rezultatus tik kanale, kuriame rasta daugiausia pikų, šis kanalas ne visada atitiko tą, kuriame pikus žymėjo ekspertas). Šie pikų duomenys buvo apdoroti taip pat ir perkeliant pikų centrus. Kadangi aptariamasis algoritmas [21] nėra optimizuotas rasti piko centrą, buvo laikoma, kad pikai sutampa, jei nurodytas piko centras buvo nutolęs ne daugiau nei 10% analizuojamos signalo atkarpos (200 ms) tiek į priekį, tiek ir atgal nuo eksperto nurodyto ir patikslinto piko centro. Taip pat svarbu pabrėžti, kad piko centras gali būti tiek teigiamos įtampos, tiek neigiamos, tačiau šiuo atveju visuose iš eksperto surinktuose duomenyse piko centras buvo neigiamas, taigi pasirinktas centro perkėlimas pagal minimalią reikšmę. Centro perkėlimas buvo naudojamas tik duomenims paruošti ir netaikomas tolesnėje analizėje. Rezultatai pateikti 4 lentelėje:

Lentelė 4. Rezultatų palyginimas

| Bandymo Nr. | 1 | 2 |
|---|----------|----------|
| Eksperto nurodytas pikų skaičius | 177 | 144 |
| Sutapusių pikų skaičius | 142 | 139 |
| [21] algoritmo identifikuotų pikų skaičius | 156 | 367 |
| Sutapimas | 80% | 97% |

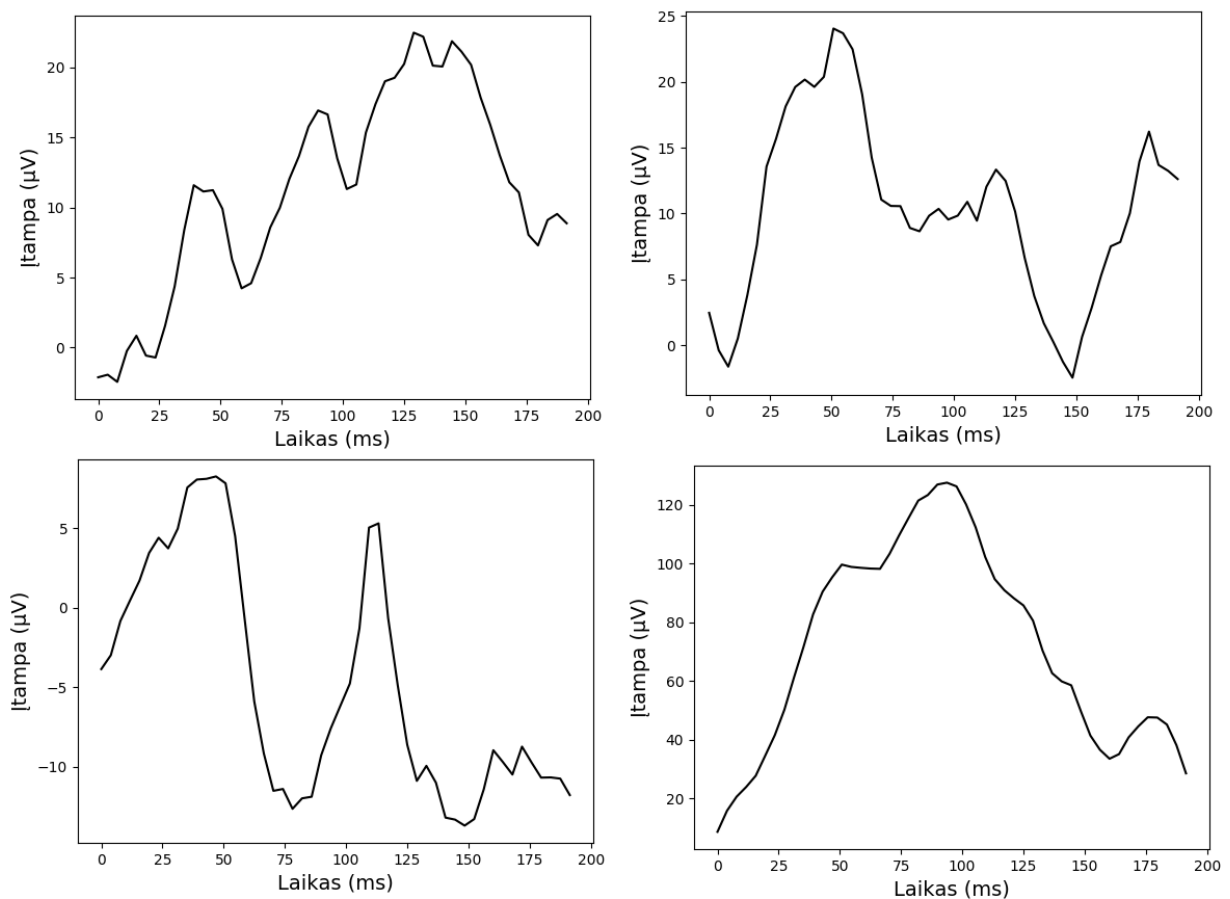
Kaip parodoma 1 lentelėje, rezultatai net ir tokiu atveju nesutampa (antruoju bandymu minėtas algoritmas identifikavo ženkliai daugiau kanalų nei eksperto, nors ir tiksliai pataikė net 97% iš jos nurodytų), taigi atsižvelgiant į tai, kad apmokymui būtinas duomenų tikslumas [21], pateikti rezultatai tolesniuose tyrimuose bus naudojami ribotai.

4. Algoritmų taikymas

4.1 Tiesinis neuroninis tinklas

Iš pradžių tyrimai atliekami su tiesiniu, vienakrypčiu (angl. feedforward) kelių sluoksnių neuroniniu tinklu (dar vadinamu daugiasluoksniu perceptronu) (toliau darbe – tiesinis neuroninis tinklas). Šiame etape jis buvo pasirinktas, kadangi yra nesunkiai konfigūruojamas bei sąlyginai nereiklus kompiuterio resursams, lyginant su kitais neuroniniais tinklais.

Bandymai atliekami su trijų pacientų EEG bylomis ir keturiais kanalais. Atradus piko vietą, gautos ~200 ms trukmės atkarpos, kuriose yra pikai (t.y. atkarpos pradžia ir pabaiga atitinkamai nutolusios nuo piko centro per 98ms arba 25 elementus). Atitinkamai norint nustatyti vietas, kur pikų nėra, paimti 47 eksperto identifikuoti objektai ir papildomai parinktos atkarpos, kurios neatitinka piko apibrėžimo (t. y. nėra staigaus (iki 200 ms atkarpoje) amplitudės pokyčio, kaip tai aprašyta 2.2 skyriuje), o yra vizualiai panašios į foninę, EEG aptinkamą smegenų veiklą. Taip tinklo apmokymui surinkti 499 pikai ir 499 elementai, kurie tikrai nėra pikai. Keli tokių atkarpų pavyzdžiai pateikiami 11 pav.



11 pav. Apmokymui parinktų atkarpų, kurios neatitinka piko apibrėžimo, pavyzdžiai.

Siekiant parinkti tinkamiausią tinklo konfigūraciją, buvo pritaikytas tarpusavio validacijos metodas. Atliekant tarpusavio validaciją, duomenys buvo sumaišyti ir padalinti į keturias dalis, iš kurių trys naudojamos apmokymams, o viena – bandymams, po to dalys apkeičiamos.

Sprendžiant, kokias konfigūracijas įtraukti, buvo remiamasi panašaus pobūdžio tyrimais:

- Remiantis Cheng-Wen Ko ir Hsiao-Wen Chu (2000) tyrimu [9], pasirinkta kombinacija sudaryta iš trijų sluoksnių (įvesties, išvesties ir vidurinio arba slaptojo (angl. *Hidden layer*), kuriuose buvo atitinkamai 30 (atkarpos ilgis), 6 ir 1 neuronai);
- Cheng-wen et. al. (1998) [11] panaudojo trijų sluoksnių tinklą su 4, 5, 1 neuronais (atitinkamai sluoksniuose);
- Weng ir Khorasani [12] panaudojo trijų sluoksnių neuroninį tinklą su 9,90,1 neuronų konfigūracija sluoksniuose;
- Mirchandani ir Cao (1989) [43] parodė, kad optimalų neuronų skaičių paslėptame sluoksnyje galima apskaičiuoti pagal formulę:

$$H = \log_2 M$$

Čia H – neuronų skaičius; M – didžiausias tiesiškai atskiriamų regionų skaičius įvesties duomenyse (šiuo atveju $M = 50 - 1 = 49$).

Pagal šią formulę viduriniame sluoksnyje rekomenduojami penki neuronai, kai atkarpos ilgis - 50 elementų.

Taigi atsižvelgiant į aukščiau paminėtus šaltinius, tolesnis tyrimas atliekamas su trijų sluoksnių neuroniniu tinklu. Iš pradžių sudaryta imtis iš galimų tinklo konfigūracijų, skirta tarpusavio validacijai, kuri apimtų visuose darbuose minimas konfigūracijas ir tikrintų tiek mažesnes, tiek didesnes vertes (atitinkamai į intervalą įtraukiant 50-100 % mažesnes ir didesnes vertes). Atitinkamai buvo parinktos 3 lentelėje nurodytos parametų konfigūracijos.

Lentelė 5. Tiesinio neuroninio tinklo konfigūracijos išbandomos ieškant optimalios struktūros.

| Neuronai įvesties sluoksnyje | Neuronai paslėptame (angl. <i>hidden</i>) sluoksnyje |
|------------------------------|---|
| 25 | 2 |
| 50 (atkarpos ilgis) | 5 |
| 100 | 10 |
| | 20 |
| | 30 |
| | 60 |
| | 90 |
| | 120 |

Remiantis Wilson ir kiti [13] publikuotu tyrimu, kuriame autoriai parodė, kad **SGD** (angl. *single gradient descent*) optimizavimo algoritmas (naudojant tiesinį neuroninį tinklą) leidžia pasiekti geresnius rezultatus, lyginant su keletu kitų populiariausių (kaip *Adam* ar *Rsmprop*),

naudojant būtent tiesinį neuroninį tinklą, sudarytą iš trijų sluoksnių, taigi tyrimams pasirinkta būtent SGD optimizavimo funkcija, o šiame etape kitos netiriamos.

Apmokymo metu rezultatai vertinti pagal dvejetainį klasifikavimo tikslumą. Kiekvieną kartą atliekant apmokymą buvo užtikrinta, kad tinklas bus apmokomas tol, kol jo klasifikavimo tikslumas nebedidės bent 10 epochų iš eilės (t. y. daroma prielaida, kad pasiektas geriausias galimas apmokymas su tam tikra konfiguracija). Taip pat siekiant, kad apmokymas būtų baigtinis, nustatytas maksimalus – 300 epochų apmokymo limitas. Klasifikavimo tikslumo apskaičiavimas pateikiamas žemiau.

4.4.1 Klasifikavimo tikslumas

1) Suklasifikuojamos atkarpos $X = (x_1, x_2 \dots, x_n)$

Čia x_1, x_2, \dots – klasifikavimui panaudotos ~ 200ms trukmės signalo atkarpos.

2) Gaunami rezultatai, kur vienas elementas v_i atitinka vienos atkarpos rezultatą ir yra intervale
 $0 \leq v \leq 1$

Pateikiamas rezultatų sąrašas $A = (v_1, v_2 \dots, v_n)$

Čia A - iš tinklo gautų įverčių masyvas

3) Kiekvienas v_i iš A suapvalinamas į artimiausią sveiką skaičių

4) Kiekvienas elementas lyginamas su iš anksto žinomais rezultatais,

$$B = (k_1, k_2 \dots, k_n)$$

Čia k gali įgyti vertes tik 0 (jei atkarpoje piko nėra) arba 1 (jei atkarpoje pikas yra)

Taip sudarant naują masyvą, kurio kiekvienas elementas gali turėti vertę 0 (jei $v_i \neq k_i$) ir 1 (jei $v_i = k_i$). Visų šio masyvo elementų vidurkis ir yra vidutinis klasifikavimo tikslumas

Bandymo rezultatai pateikiami 1 lentelėje - pateikiamos tik tos konfiguracijos, kurių vidutinis klasifikavimo tikslumas viršijo 0,9

Lentelė 6. Tiesinio neuroninio tinklo klasifikavimo tarpusavio validacijos rezultatai taikant skirtingas konfigūracijas. Pateikti tik rezultatai, kurių vidutinis tikslumas viršijo 0,9

| Neuronai | | | | | |
|------------------|------------------------|----------------------|-----------------------|---------------------|-------------|
| Įvesties neuronų | viduriniame sluoksnyje | Mažiausias tikslumas | Didžiausias tikslumas | Vidutinis tikslumas | Δ tikslumas |
| 50 | 10 | 0.965 | 0.977 | 0.972 | 0.012 |
| 50 | 20 | 0.934 | 0.977 | 0.961 | 0.043 |
| 25 | 30 | 0.915 | 0.977 | 0.957 | 0.062 |
| 25 | 10 | 0.903 | 0.969 | 0.949 | 0.066 |
| 50 | 5 | 0.829 | 0.973 | 0.933 | 0.143 |
| 100 | 90 | 0.903 | 0.973 | 0.931 | 0.070 |
| 25 | 5 | 0.876 | 0.977 | 0.930 | 0.101 |
| 25 | 20 | 0.764 | 0.973 | 0.916 | 0.209 |
| 50 | 30 | 0.702 | 0.977 | 0.902 | 0.275 |
| 50 | 10 | 0.965 | 0.977 | 0.972 | 0.012 |

Taigi remiantis bandymo rezultatais, pasirinkta konfigūracija su geriausiu dvejetainio klasifikavimo tikslumo vidurkiu (atliekant tarpusavio validaciją, vidurkis skaičiuojamas iš keturių apmokymo ir vertinimo iteracijų) ir pagal ją apmokytas tinklas. Taip pat svarbu atkreipti dėmesį į tai, kad su geriausia konfigūracija aptinkamas ir mažiausias skirtumas tarp 4 iteracijų (šiuo atveju - 50 ir 10 neuronų, atitinkamai I ir II sluoksniuose).

Tuo pačiu metodu pasirinkta ir aktyvacijos funkcija. Šiuo atveju imta optimali neuronų konfigūracija ir išbandytos šios aktyvacijos funkcijos: *sigmoid*, *rectifier* ir *tanh*. Rezultatai pateikiami 7 lentelėje.

Lentelė 7. Tiesinio neuroninio tinklo bandymo rezultatai su skirtingomis aktyvacijos funkcijomis

| Mažiausias tikslumas | Didžiausias tikslumas | Vidutinis tikslumas | Δ tikslumas | Funkcija |
|----------------------|-----------------------|---------------------|-------------|----------|
| 0.961 | 0.988 | 0.976 | 0.027 | sigmoid |
| 0.965 | 0.977 | 0.972 | 0.012 | relu |
| 0.919 | 0.934 | 0.928 | 0.016 | tanh |

Šioje lentelėje matome, kad aktyvacijos funkcijos tarp I ir II sluoksnių pasirinkimas didelės įtakos rezultatams neturi. Dėl šiek tiek geresnio klasifikavimo vidurkiu pasirinkta sigmoid funkcija. Taip pat svarbu pabrėžti, kad paskutiniame sluoksnyje visada naudojama *sigmoid* aktyvacijos funkcija. Ši funkcija pateikiama žemiau:

$$S(x) = \frac{1}{1 + e^x}$$

čia x – vieno neurono išvestis

Tokia kombinacija parinkta dėl to, kad šios funkcijos vertės yra tarp 0 ir 1, taigi puikiai tinka dvejetainiam klasifikavimui (kai vertės yra 0 arba 1).

Lentelė 8. 3 sluoksnio tiesinio neuroninio tinklo charakteristikos

| | |
|--|----------------|
| Įvesties sluoksniai | 1 |
| Vidiniai (paslėptieji) sluoksniai | 1 |
| Išvesties sluoksniai | 1 |
| Neuronų I sluoksnyje | 50 |
| Neuronų II sluoksnyje | 10 |
| Neuronų III sluoksnyje | 1 |
| I ir II sluoksnių Aktyvacijos funkcija | <i>sigmoid</i> |

Siekiant įvertinti algoritmo rezultatus imituojant panaudojimą, klasifikuojant nematytus duomenis, algoritmas apmokytas naudojant optimalią konfigūraciją. Po to vienas kanalas (kuris buvo naudotas apmokymuose) buvo padalintas 200 ms trukmės atkarpomis – slenkančio lango principu, paslenkant per vieną elementą. Taip buvo imituojama situacija, kai analizuojama nauja elektroencefalograma ir pikai gali būti be kurioje vietoje. Bandytas pakartotas tris kartus trims skirtingiems kanalams (visi buvo panaudoti apmokant neuroninį tinklą). Rezultatai ir jų vertinimo metodika aptariami tolesniuose skyriuose.

4.1.1 Rezultatų vertinimo metodika

Taip pat šiuo atveju buvo svarbu atsižvelgti į vertinimo metodikos tinkamumą. Kadangi 60 sekundžių trukmės signalas susidaro iš 15360 atkarpu, tik mažiau nei 1% signalo sudaro pikai. Tokiu atveju naudojant dvejetainio klasifikavimo tikslumo skaičiavimą (aprašytą aukščiau), bus gaunami geri rezultatai, nepaisant to, ar bus randami pikai, ar ne. Taip pat tokiu atveju vienodai vertinami atvejai, kai vienas pikas randamas keletą kartų (gretimos atkarpos) ir randami keli atskiri pikai (kas šio tyrimo atveju yra svarbiau). Taigi kuriant vertinimo metodiką buvo atsižvelgiama į tris pagrindines savybes:

- 1) Koks santykis algoritmo randamų pikų su eksperto nurodytais pikais;
- 2) Kiek atkarpu algoritmas klaidingai klasifikuoja kaip pikus;
- 3) Kiek atkarpu su pikais algoritmas klaidingai klasifikuoja kaip pikus.

Kadangi šiuo atveju buvo tiksliai žinomos pikų vietos, rezultatams įvertinti buvo panaudota tokia metodika:

- 1) Naudojant neuroninį tinklą suklasifikuojamos visos atkarpos. Svarbu atkreipti dėmesį, kad pateikiamos tik atkarpos su pikais (t. y. ne visi klasifikavimo rezultatai). Jeigu atkarpa pažymėta kaip turinti piką, jai priskiriama koordinatė, lygi

$$x_i + \text{atkarpos ilgis} / 2$$

Čia x – signalo elementas, i – atkarpos pradžios laiko koordinatė.

- 2) Kiekvienas x_i lyginamas su eksperto pateiktomis ir paslinktomis pikų koordinatėmis.

Taip pat svarbu įvertinti, kad imama maksimali piko trukmė, kuri yra 200 ms. Tačiau į atkarpą gali patekti ir pikai nuo 20 iki 200 ms. Kadangi visada naudojamas 200 ms

langas, svarbu paskaičiuoti paklaidą, į kurią patekęs atkarpos centras bus priskiriamas pikui.


Kadangi trumpiausia piko trukmė - 20ms, o norint įvertinti, ar atkarpa yra pikas reikia matyti bent 2/3 šios atkarpos, vertinama, kad pikas gali būti pačioje 200 ms atkarpos pradžioje arba pabaigoje. Tokiu atveju (darant prielaidą, kad tiriama atkarpa apima intervalą [0;200], o jos centro x koordinatė lygi 100), anksčiausiai pikas gali būti klasifikuojamas, kai jo centras patenka į intervalą [15;185] (t. y. ¾ mažiausios piko trukmės nuo intervalo galų) arba nuo atkarpos centro (x=100) yra nutolęs per 85 ms (arba ~21 elementą, kai atkarpos ilgis – 50 elementų) atgal arba pirmyn nuo centro, kas sudaro 42,5% atkarpos ilgio.

Taigi pikams priskiriamos visos atkarpos, kurių centras patenka į intervalą:

$$[v - \text{atkarpos ilgis} * 0,425; v + \text{atkarpos ilgis} * 0,425]$$

Čia v – eksperto nurodyto ir paslinkto piko centras. Atkarpos ilgis šiuo atveju – visa tiriama atkarpa (200 ms)

Priskyrimas pavaizduotas 12 pav.



12 pav. kairėje – pirmoji atkarpa priskiriama pikams, viduryje – eksperto nurodytas ir patikslintas piko centras, paskutinė atkarpa priskiriama pikams (atkarpos centras pažymėtas vertikalia linija).

Iš šio pavyzdžio matome, kad ilgesnių pikų atveju ši riba neleidžia tiksliai vizualiai identifikuoti, ar tai – tikrai pikas, tačiau tokia metodika užtikrina, kad bus įtraukti patys trumpiausi (20 ms) pikai, esantys atkarpos kraštuose.

- 3) Jeigu eksperto pažymėtam pikui buvo priskirta bent viena atkarpa (vadovaujantis 2 punkto taisyklėmis), pažymima, kad jis rastas. Taip siekiama išvengti situacijos, kai aplink vieną piką randama daug atkarpų, o kitas yra išvis praleidžiamas. Bet kurios kitos papildomos atkarpos priskyrimas įtakos šiam rezultatui nebeturės.
- 4) Visos atkarpos, patenkančios į 2 aprašytą intervalą, pažymimos kaip tinkamai klasifikuotos.
- 5) Visos atkarpos, nepatenkančios į 2 intervalą, pažymimos kaip netinkamai suklasifikuotos.

Atsižvelgiant į aprašytą metodiką, kiekviename kanale atkarpų, pažymėtų kaip pikai, kiekis buvo didesnis nei tikrasis eksperto pažymėtų pikų kiekis.

Remiantis aukščiau aprašyta vertinimo metodika ir tinklo konfigūracija, analizuojamas visas kanalas. Klasifikavimo rezultatai pateikiami 7 lentelėje. Joje naudojami sutrumpinimai:

TP – (angl.: *True positive*) algoritmo klasifikavimo atvejis, kai atkarpa klasifikuojama kaip turinti piką ir ekspertas klasifikavo kaip turinčią, t. y. algoritmo ir eksperto klasifikavimas sutampa.

FP – (angl.: *False positive*) algoritmo klasifikavimo atvejis, kai atkarpa klasifikuojama kaip turinti piką, o ekspertas klasifikavo kaip neturinčią, t. y. algoritmo ir eksperto klasifikavimas nesutampa.

TP santykis – atkarpų, teisingai klasifikuotų kaip pikai, santykis su visa rezultatų imtimi.

FP santykis – atkarpų, klaidingai klasifikuotų kaip pikai, santykis su visa rezultatų imtimi.

Rasta – neuroninio tinklo rastų ir eksperto identifikuotų pikų santykis (skaičiuojami tik sutampantys pikai)

Iš rezultatų matome, kad nors algoritmas tinkamai klasifikavo ir atpažino visus pikus, tačiau labai daug atkarpų buvo atpažinta kaip pikai, nors tai nėra pikai.

Lentelė 9. tiesinio neuroninio tinklo klasifikavimo rezultatai su visais kanale esančiais duomenimis

| Paciento nr. | EEG kanalas | Viso rezultatų (atkarpų) | | | | |
|--------------|-------------|--------------------------|-------------|-------------|------------------|-----|
| | | Rasta | TP santykis | FP santykis | Viso pikų kanale | |
| 1 | T4 | 100% | 59% | 41% | 3070 | 177 |
| 2 | T3 | 100% | 18% | 82% | 8490 | 144 |
| 2 | T5 | 100% | 3% | 97% | 9524 | 28 |
| 3 | P4 | 100% | 21% | 79% | 7342 | 150 |

Šiuo atveju galima daryti išvadą, kad kanale yra daugiau skirtingų elementų ir keletu atkarpų atrinkimas nereprezentuoja viso kanalo informacijos bei yra nepakankamas tinklui apmokyti. Siekiant išspręsti šią bėdą, tinklas buvo pakartotinai apmokytas, tačiau šį kartą apmokymui buvo panaudota visa kanalo informacija, t. y. panaudojus slenkančio lango principą, visas kanalas suskaidytas ~200 ms trukmės atkarpomis. Visos atkarpos, nutolusios nuo piko centro per ~85 ms (taikoma aukščiau aprašyta metodika įtraukiant visas atkarpas, kurių centras nutolęs per 42,5% atkarpos ilgio) pirmyn ir atgal, pažymėtos kaip turinčios pikus, o visos kitos - kaip neturinčios (atitinkamai klasifikuojamos 0 ir 1).

Taip pat svarbu paminėti, kad šioje situacijoje ženkliai išauga duomenų kiekis, taigi aukščiau aptarta tinklo konfigūracija gali būti nebetinkama, todėl siekiant pasiekti geresnių rezultatų pakartotinai atliekama tarpusavio validacija, tačiau šįkart naudojama visa kanale esanti informacija. Apmokymui panaudoti duomenys aprašyti 10 lentelėje.

Lentelė 10. Apmokymui ir vertinimui panaudotų duomenų aprašymas (duomenys paruošti piko centrui priskiriant keletą atkarpų)

| Paciento nr. | EEG kanalas | Viso pikų kanale | Viso atkarpų klasifikuojamų kaip pikai | Viso atkarpų | Signalų trukmė (s.) |
|--------------|-------------|------------------|--|--------------|---------------------|
| 1 | T4 | 177 | 4248 | 47310 | 184.8 |
| 2 | T3 | 144 | 3456 | 185550 | 724.8 |
| 2* | T5 | 28 | 672 | 185550 | 724.8 |
| 3 | P4 | 150 | 3600 | 66510 | 259.8 |

Atsižvelgiant į šio skyriaus pradžioje išdėstytus argumentus, atliekant tarpusavio validaciją naudojama nebe klasifikavimo tikslumą skaičiuojanti funkcija, o vėliau aprašyta vertinimo metodika. Dėl šios priežasties duomenys nėra sumaišomi, o taip pat tarpusavio validacija neatliekama su 2 paciento T5 kanalu (7 lentelėje pažymėtas *) dėl ypač mažo atkarpų su pikais skaičiaus (mažiau nei 0,04%). Šio bandymo rezultatai pateikti 11 lentelėje (pastaba – lentelėje nėra pateikiamos konfigūracijos, su kuriomis bent viename kanale nebuvo rastas nei vienas pikas).

Lentelė 11. Tiesinio neuroninio tinklo apmokymų rezultatai su įvairiomis neuronų konfigūracijomis ir sigmoid aktyvacijos f-ja abiejuose sluoksniuose. * Trumpiniai: I N. - neuronų skaičius įvesties sluoksnyje, II N. - neuronų skaičius paslėptame sluoksnyje

| I n. | II n. | Vid. TP | Δ TP | Vid. rasta | Δ rasta | Vid. FP | Δ FP |
|------|-------|---------|------|------------|---------|---------|------|
| 25 | 90 | 70% | 48% | 97% | 4% | 30% | 48% |
| 50 | 20 | 70% | 50% | 95% | 10% | 30% | 50% |
| 25 | 20 | 72% | 47% | 95% | 7% | 28% | 47% |
| 25 | 30 | 72% | 48% | 93% | 8% | 28% | 48% |
| 50 | 10 | 71% | 43% | 92% | 14% | 29% | 43% |
| 50 | 30 | 70% | 46% | 92% | 17% | 30% | 46% |
| 100 | 30 | 71% | 49% | 91% | 12% | 29% | 49% |
| 25 | 10 | 71% | 48% | 91% | 19% | 29% | 48% |
| 100 | 20 | 66% | 46% | 82% | 33% | 34% | 46% |

Iš lentelės matome, kad nors šiuo atveju neuroninis tinklas ir pasiekė geresnių rezultatų, tačiau pakankamai daug atkarpų (~30%) klaidingai priskiriama pikams, o taip pat sumažėjo tinkamai randamų pikų.

Taip pat svarbu atkreipti dėmesį, kad rezultatai (ypač FP dalis) ženkliai skiriasi skirtinguose kanaluose, nors bendras kaip pikai klasifikuotų atkarpų skaičius yra panašus.

Lentelė 12. Algoritmo kaip pikai identifikuotos atkarpos ir klaidingai pikais identifikuotų atkarpų pasiskirstymas kanaluose. * pažymėta aukščiau aprašyta optimali tinklo konfigūracija


| FP atkarpų skaičius 1 kanale | FP atkarpų skaičius 2 kanale | FP atkarpų skaičius 3 kanale | Viso atkarpų su pikais 1 kanale | Viso atkarpų su pikais 2 kanale | Viso atkarpų su pikais 3 kanale |
|------------------------------|------------------------------|------------------------------|---------------------------------|---------------------------------|---------------------------------|
| 269 | 2622 | 1555 | 4462 | 4832 | 5269 |
| 223 | 2617 | 1919 | 4180 | 4755 | 6725 |
| 252 | 2194 | 1612 | 5259 | 4216 | 5937 |
| 142 | 1549 | 1661 | 3713 | 2989 | 5785 |
| 175 | 1617 | 2181 | 2837 | 3260 | 6917 |
| 270 | 1455 | 1776 | 4034 | 2783 | 5701 |
| 141* | 2156* | 1883* | 3038* | 4054* | 6341* |
| 145 | 1234 | 2716 | 4549 | 2413 | 8253 |
| 93 | 984 | 2830 | 1528 | 1879 | 6394 |

Vertinant algoritmo veikimą, svarbu išanalizuoti klaidingai identifikuotas atkarpas, siekiant išvengti situacijos, kad jos buvo tinkamai identifikuotos, tačiau nepažymėtos eksperto pateiktuose duomenyse. Norint tuo įsitikinti, buvo parinkta konfigūracija su didžiausiu vidutinių rastų pikų skaičiumi ir mažiausiu vidutiniu FP skaičiumi ir bandymas pakartotas kiekvienoje iteracijoje du kanalus naudojant apmokymui, o vieną testavimui. Taip pat šioje vietoje svarbu įvertinti, kad kelios FP atkarpos gali būti priskiriamos vienam pikui, taigi gauti rezultatai buvo sugrupuoti, į vieną grupę įtraukiant visas atkarpas, kurių centras nuo pirmojo rasto centro nėra nutolęs toliau nei per vieną atkarpos ilgį. Taip įvertinus 141 gautas atkarpas, buvo sudarytos 53 grupės, kurias šiuo atveju galima interpretuoti kaip 53 pikus.

Toliau buvo detaliau išanalizuotas 1 kanalas, kuriame gydytoja nurodė 177 pikus.

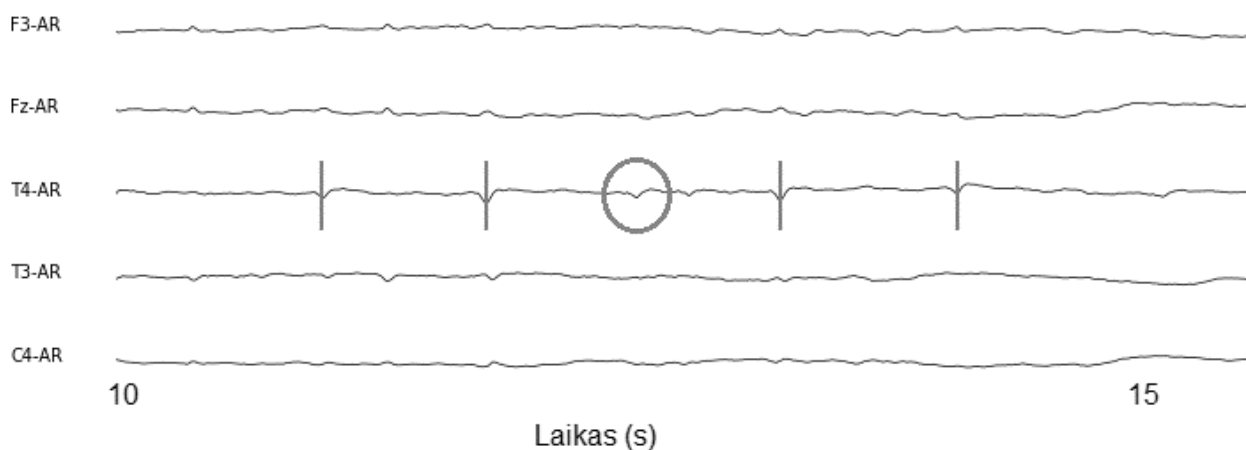
Analizuojant duomenis pastebėta, kad klaidingai (pagal vertinimo metodiką) pikams priskirtos atkarpos yra trijų rūšių:

- 1) Atkarpos, į kurias patenka eksperto nurodyto piko dalis, tačiau kurios nepatenka į aukščiau nurodytą paklaidos intervalą. Toks pavyzdys pateikiamas 13 pav. Jame matosi, kad tai yra to paties piko dalis, tačiau iš jos vizualiai neįmanoma įvertinti, ar tai tikrai yra pikas. Šiame pavyzdyje atkarpos centras yra ties 10459 x ašies elementu, o eksperto nurodytas pikas – 10436 (skirtumas – 23 elementai arba ~45% atkarpos ilgio).



13 pav. Kairėje - neuroninio tinklo identifikuota atkarpa kaip turinti piką, dešinėje - eksperto nurodytas pikas.


- 2) Atkarpos, kuriose yra dariniai, vizualiai panašūs į pikus, tačiau jie yra žemesni nei dviguba foninės amplitudės vertė, taigi eksperto nėra klasifikuojami kaip pikai (pavyzdys pateikiamas 14 pav.):



14 pav. vertikaliomis linijomis pažymėti eksperto nurodyti pikų centrai, apskritimu pažymėtas darinys - neuroninio tinklo identifiukuotas kaip pikas

Nusiuntus šį pavyzdį (14 pav.) ekspertui, buvo patvirtinta, kad tai gali būti pikas, tačiau – mažos amplitudės.

3) Atkarpos, kurios nėra pikai (vertinant vizualiai):



15 pav. Trijų sluoksnių tiesinio neuroninio tinklo klaidingai identifiukuotos atkarpos pavyzdys.

Atliekant detalesnį rezultatų vertinimą, bandymas pakartotas apmokius neuroninį tinklą su visais turimais duomenimis ir pabandžius analizuoti kanalą, apie kurio pikų skaičių nėra žinoma. Siekiant supaprastinti vertinimo metodiką, tas pats signalas įvertintas ir [21] algoritmu.

Gauti rezultatai pateikiami 13 lentelėje:

Lentelė 13. Tiesinio neuroninio tinklo ir [21] algoritmo rezultatų palyginimas

| Rasta pikų | [21] algoritmo identifikuotų pikų skaičius | Sutampantys rasti pikai % | Rasta nesutampančių pikų (klaidingai identifikuota lyginant su [21] algoritmo rezultatais) |
|------------|--|---------------------------|--|
| 97 | 98 | 99% | 76 |
| 517 | 593 | 87% | 492 |
| 2 | 38 | 5% | 37 |
| 1 | 5 | 20% | 10 |
| 39 | 49 | 80% | 63 |
| 0 | 1 | 0% | 0 |


Iš lentelės matome, kad gaunami rezultatai pakankami nepastovūs ir kinta 5-99% ribose, vidutiniškai tinkamai identifikuojant (lyginant su aukščiau minėtu algoritmu) ~50% pikų arba ~70%, neįtraukiant dviejų blogiausių rezultatų. Taip pat svarbu atkreipti dėmesį, kad aukščiau minėtas algoritmas nebūtinai garantuoja 100% tikslų pikų identifikavimą. Siekiant patikrinti rezultatus pasirinktas vienas iš aukščiau aprašytų kanalų, o nesutampančios atkarpos įvertintos atskirai.

Lentelė 14. Išsamiai analizei pasirinkto signalo automatinės analizės rezultatai


| | Viso identifikuota pikų | Sutampančių |
|-----------------------------|-------------------------|-------------|
| [21] algoritmas | 98 | 97 |
| Tiesinis neuroninis tinklas | 173 | 97 |

Pastebėta, kad nesutampančios atkarpos yra trijų tipų:

- 1) Vienas [21] identifikuotas pikas neuroninio tinklo nebuvo atpažintas. Atidžiau analizuojant šią atkarpą, akivaizdu, kad ji neatitinka piko požymių, todėl laikoma, kad neuroninis tinklas jos teisingai nepriskyrė pikams.


**16 pav.** [20] algoritmo EEG elementas identifikuotas kaip pikas.

- 2) Atkarpos, kuriose tikrai nėra pikų arba yra akivaizdžiai per mažą jų amplitudę.



17 pav. Atkarpa, kurioje nėra piko, tačiau neuroninio tinklo identifikuota kaip turinti jį

- 3) Dalis atkarpų, kurios buvo identifikuotos neuroninio tinklo, tačiau ne [x] algoritmo, nors vizualiai atrodo kaip pikai. Vizualiai įvertinus, dešimt tokių atkarpų pavyzdžių nusiųsta ekspertui papildomam vertinimui.



18 pav. Atkarpos, kurios vizualiai panašios į pikus, tačiau nebuvo išskirtos [21] algoritmo

Iš dešimties darinių du įvertinti kaip tikrai esantys pikai, o du – kaip tikrai ne pikai. Visi likę ekspertui buvo panašūs į pikus, tačiau to garantuoti negalėjo.

Taigi iš dešimt pavyzdžių didžioji dalis ekspertui buvo labai panašūs į pikus, iš ko galima daryti išvadą, kad tiesinis neuroninis tinklas randa daugiau pikų nei [21] algoritmas. Šiuo atveju tai gali būti pikai, tačiau kylantys smegenų vietose, nukreiptose tam tikru kampu į elektrodą. Tuo atveju pikas gali būti morfologiškai ne visai panašus į kitus, tačiau dėl EEG matavimo ribojimų to patikslinti neįmanoma. Taip pat Rolando epilepsija yra diagnozuojama remiantis ne pavieniais pikų pavyzdžiais, o viso kanalo pikais ir jų išsidėstymu, o diagnozė neturėtų būti pagrįsta vien netipiniais pikais. Atsižvelgiant į tai, galima daryti išvadą, kad nors šie netipiniai pikai ir gali būti būdingi Rolando epilepsijai, jie turi būti vertinami kitos informacijos (kaip kiti pikai, jų išsidėstymas ir pan.) kontekste taigi toks išskyrimas vis tiek reikalautų papildomos rankinės EEG analizės.

Taip pat dėl riboto laiko, kurį ekspertas galėjo skirti šiam tyrimui, nebuvo galimybės įvertinti didesnio atkarpų kiekio, tačiau šie rezultatai leidžia daryti išvadą, kad realūs algoritmo klasifikavimo rezultatai gali būti geresni nei šiame palyginime. Taip pat svarbu atkreipti dėmesį, kad didelė dalis darinių, klasifikuotų kaip pikai, vizualiai yra į juos panašios, taigi galima daryti išvadą, kad net nedidelė apmokymo imtimi algoritmo tikslumas yra pakankamas bent pirminei EEG analizei, o plečiant duomenų imtį, būtų galima pasiekti geresnių rezultatų. Nepaisant čia pateiktų rezultatų, dėl labai mažo pavyzdžių kiekio yra sudėtinga įvesti paklaidą lyginant rezultatus, taigi tolesnis palyginimas bus atliekamas tik tarp iš algoritmų gautų rezultatų.

Apibendrinant galima teigti, kad tiesinis trijų sluoksnių neuroninis tinklas pakankamai sėkmingai išskiria į pikus morfologiškai panašius darinius (identifikuoti ~70% (iki 99%) tyrime naudotų pikų, lyginant su [21] automatizuotos EEG analizės algoritmu arba ~97%, lyginant su

eksperto pateiktas duomenimis), o taip pat neranda pikų kanaluose, kur jų yra sąlyginai mažai (pavyzdžiui, atveju, kai kanale buvo 1 pikas išskirtas [21] algoritmo, tiesinis neuroninis tinklas jame pikų nerado). Tačiau tiesinis neuroninis tinklas prastai atskiria aukštus (kurių didžiausia ir mažiausia vertės yra daugiau nei dvi vidutinės foninės veiklos amplitudės) ir žemus (kurių didžiausia ir mažiausia vertės yra mažiau nei dvi vidutinės foninės veiklos amplitudės) pikus, o tai lemia, kad vien tokios analizės rezultatais pasitikėti negalima, tačiau tai padėtų ženkliai supaprastinti rankinę analizę. Šiame etape būtų galima taikyti papildomą filtrą paremtą pikų morfologija ar amplitude, tačiau tokiu atveju neuroninis tinklas tik papildytų automatinės analizės algoritmą, o tai nėra šio darbo tikslas.

Taip pat svarbu pabrėžti, kad šioje vietoje pakankamai sudėtingas tampa ir optimalios konfigūracijos parinkimas, kadangi klasifikavimo uždavinyje galima išskirti du tikslus:

- 1) Rasti kuo daugiau pikų (t. y. prie kuo daugiau pikų priskirti bent vieną atkarpą)
- 2) Kuo mažiau atkarpų klaidingai identifikuoti kaip pikus.

Siekiant pagerinti rezultatus, tyrimas tęsiamas išbandant rekurentinį neuroninį tinklą.

4.2 Rekurentinis neuroninis tinklas

Siekiant geresnių rezultatų, atliekami tyrimai su rekurentiniais neuroniniais tinklais. Šio tipo tinklai pasižymi galimybe informaciją siųsti dviem kryptimis, t. y. link išėjimo (angl. *output*) vartų ir atgal, kol nepasiekiamas optimalus svorio koeficientas. Dėl tokio tipo sandaros šie tinklai gali geriau apsimokyti tam tikriems uždaviniams bei demonstruoja geresnius rezultatus nei tiesiniai.

A. Petrosian ir kiti [30] analizavo galimybę panaudoti rekurentinį neuroninį tinklą, siekiant iš EEG išskirti ankstyvoms Alzheimerio ligos stadijoms būdingus simptomus. Prieš tai atlikus analizuojamų duomenų vinelės transformaciją (angl. *wavelet transform*), autoriams pavyko tinkamai identifikuoti 80% ligai būdingų elementų. Autoriai priėjo prie išvados, kad šis metodas potencialiai gali būti naudojamas EEG analizėje, tačiau siekiant klinikinio pritaikymo reikalauja platesnių tyrimų. N. F. Güler ir kiti [31] tyrė galimybę klasifikuoti epilepsija sergančių pacientų EEG naudojant Elmano rekurentinio neuroninio tinklo (angl. Elman Recurrent Neural Network) modelį, kartu su signalų Lyapunovo eksponentės apskaičiavimu. Šiuo atveju autoriai lygino savo modelį su tiesiniu neuroniniu tinklu ir priėjo prie išvados, kad rekurentinis neuroninis tinklas tokio tipo užduočiai yra tinkamesnis.

4.2.1 LSTM modelis

Šis modelis leidžia išspręsti nykstančio gradiento problemą (angl. *vanishing gradient problem*), t. y. atvejus, kai neuroninio tinklo svorius atnaujinantis gradientas tampa nysktamai mažas, todėl apmokymo metu svoriai nebėra atnaujinami ir gali nepasiekti optimalios konfigūracijos. [25]

LSTM modeliu paraemto rekurentinio neuroninio tinklo ir tiesinio neuroninio tinklo palyginimų nėra daug. Sundermeyer ir kiti [33] vertino šiuos du modelius siekiant atpažinti (klasifikuoti) prancūzų kalbos žodžius. Autoriai parodė, kad šiuo atveju LSTM modelis sugebėjo pasiekti didesnę klasifikavimo tikslumą, lyginant su tiesiniu neuroniniu tinklu, tačiau taip pat

priėjo prie išvados, kad tikėtina, jog būtų galima dar labiau pagerinti LSTM modelio rezultatus analizuojant kito pobūdžio duomenis.

Bandymų panaudoti LSTM modelį EEG analizėje nėra daug. P. R. Davidson ir kiti [32] tyrė galimybę įvertinti, ar subjektus ištinka mikro-miego būseną. Autoriai savo darbe kaip vieną iš parametrų naudojo EEG informaciją, o duomenis klasifikavo naudojant LSTM modeliu paremtą neuroninį tinklą. Bandymas tik su EEG duomenimis parodė, kad nors šis metodas ir sugebėdavo tinkamai įvertinti subjekto būseną, tačiau rezultatai buvo labai nepastovūs, taigi autoriai pateikė išvadą, kad šiai dienai LSTM tinklu paremtas metodas nėra pakankamai patikimas. Salma Alhagry ir kiti [33] analizavo galimybę klasifikuoti emocijas, remiantis EEG signalais. Panaudojus LSTM modeliu paremtą neuroninį tinklą ir neapdorotus EEG duomenis, autoriams vidutiniškai pavyko pasiekti apie 85% klasifikavimo tikslumą.

Deja, nepavyko rasti tyrimų, kur LSTM modelis būtų naudojamas EEG analizei su tikslu identifikuoti Rolando epilepsijai būdingus pikus, tačiau, remiantis kitais tyrimais, galima daryti išvadą, kad šis modelis gali būti tinkamas.

Taip pat svarbu paminėti, kad vienas LSTM elementas (dar vadinamas bloku, angl. *block*) gali būti laikomas rekurentiniu neuroniniu tinklu ir veikti savarankiškai.

4.2.2 Tyrimo eiga

Iš pradžių atliekamas tyrimas, analogiškas 4.1 skyriuje aprašytam su tiesiniu neuroniniu tinklu (t. y. taikomas tas pats tarpusavio validacijos metodas, naudojant gydytojos sužymėtus pikų centrus tose pačiose EEG bylose). Šiuo atveju naudojamas vienas LSTM blokas kaip savarankiškas rekurentinis neuroninis tinklas ir ieškoma optimalios jo konfigūracijos.

Pagrindiniai analizuojami LSTM modelio parametrai yra šie:

- imties dydis (angl. batch size)*;
- būsenos išlaikymas (angl. statefulness)*;
- optimizavimo algoritmas (angl. optimizer)*.

Atsižvelgiant, kad paketo dydis (angl. *batch size*) turi būti skaičius, iš kurio dalinasi tiek mokymo (šiuo atveju - 774 atkarpos), tiek ir analizuojami (šiuo atveju – 47310, 185550 ir 66510) duomenys, atitinkamai parenkami paketų dydžiai: 2, 3, 6 ir 10.

Apmokymo parametrai pateikti 7 lentelėje.

Lentelė 15. Rekurentinio neuroninio tinklo konfigūracijos išbandomos ieškant optimalios struktūros.

| Paketo dydis (angl. <i>batch size</i>) | Būsenos išlaikymas (angl. <i>stateful</i>) | Optimizavimo algoritmas |
|---|---|-------------------------|
| 0 (nenaudojama) | Taip | SGD |
| 2 | Ne | Adam |
| 3 | | RMSprop |
| 6 | | tanh |

Šiame etape išmetimo (angl. *dropout*) koeficientai nėra naudojami, kadangi nėra aišku, ar modelis turės pernelyg tikslaus įsiminimo (angl. *overfitting*) problemą. Kiekvieną kartą atliekant apmokymą buvo užtikrinta, kad tinklas bus apmokomas tol, kol jo klasifikavimo tikslumas

nebedidės bent 10 epochų (t. y. daroma prielaida, kad pasiektas geriausias galimas apmokymas su tam tikra konfigūracija). Taip pat siekiant, kad apmokymas būtų baigtinis, nustatytas maksimalus – 300 epochų apmokymo limitas. Atliekant bandymus naudojama 4.3 aprašyta rezultatų vertinimo metodika.

Rezultatai pateikiami 16 lentelėje:

Lentelė 16. LSTM modelio (vieno bloko) tarpusavio validacijos rezultatai.

| Optimizavimo funkcija | Paketo dydis | Vid. TP | Δ TP | Vid. rasta | Δ rasta | Vid. FP | Δ FP |
|-----------------------|--------------|---------|-------------|------------|----------------|---------|-------------|
| Adam | 0 | 64% | 54% | 93% | 18% | 36% | 54% |
| Adam | 3 | 60% | 60% | 80% | 31% | 40% | 60% |

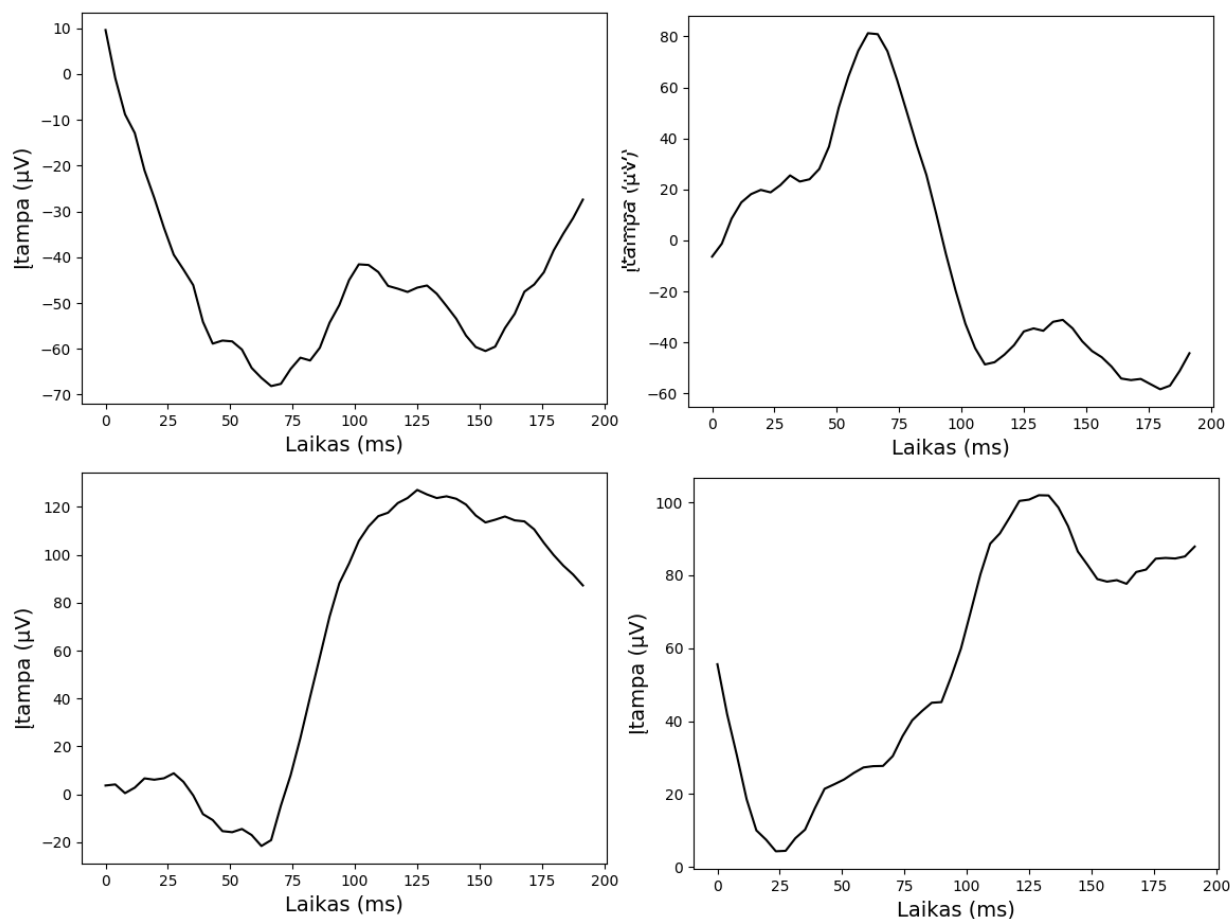
Remiantis lentelėje pateiktais rezultatais, apmokymui pasirinktas tinklas su nenaudojamu būsenos išlaikymu ir Adam algoritmu. Taip pat svarbu pabrėžti, kad tik 2 iš 16 konfigūracijų visada rasdavo bent vieną piką visuose kanaluose.

Su tokia konfigūracija pakartojamas bandymas analogiškas atliktajam su tiesiniu neuroniniu tinklu. Šiuo atveju imamas tas pats kanalas, kaip ir prieš tai ir rezultatai lyginami su [21] algoritmo pateiktais duomenimis.

Lentelė 17. Neuroninio tinklo ir [21] algoritmo rezultatų palyginimas

| Rasta pikų | [21] algoritmo identifikuotų pikų skaičius | Sutampantys rasti pikai % | Rasta nesutampančių pikų (klaidingai identifikuota lyginant su [21] algoritmo rezultatais) |
|------------|--|---------------------------|--|
| 96 | 98 | 98% | 1555 |
| 520 | 593 | 88% | 6989 |
| 7 | 38 | 18% | 13 |
| 3 | 5 | 60% | 18 |
| 44 | 49 | 90% | 592 |
| 0 | 1 | 0% | 0 |

Iš lentelės matome, kad ir šiuo atveju gaunami rezultatai pakankamai nepastovūs ir kinta 18-98% ribose, vidutiniškai tinkamai identifikuojant (lyginant su aukščiau minėtu algoritmu) ~60% pikų arba ~80%, neįtraukiant dviejų blogiausių rezultatų. Šiuo atveju vidutiniškai rekurentinis neuroninis tinklas pasiekė šiek tiek geresnių rezultatų identifikuojant sutampančius pikus, tačiau tuo pačiu žymiai daugiau atkarpų buvo klaidingai klasifikuotos kaip pikai (19 pav.).



19 pav. Rekurentinio neuroninio tinklo, sudaryto iš vieno LSTM bloko, klaidingai kaip pikai klasifikuoti EEG dariniai.

Toks rezultatas gali būti paaiškinamas dėl tinklo paprastumo (t. y. naudojamas tik vienas LSTM blokas), taip pat dėl sąlyginai mažo duomenų kiekio. Tačiau atsižvelgiant į tai, kad tiesinis neuroninis tinklas pakankamai gerai klasifikavo duomenis, o šis neuroninis tinklas buvo bandomas tik siekiant sumažinti klaidingai kaip pikai identifikuotų atkarpų skaičių, tolesnių tyrimų su rekurentiniu neuroniniu tinklu nuspręsta nebetęsti.

Šiame etape akivaizdu, kad nei tiesinis, nei rekurentinis neuroninis tinklas negali visais atvejais efektyviai klasifikuoti pikų, kai vertinami šiame darbe naudoti EEG duomenys.

Nepaisant to, tiesinis neuroninis tinklas tam tikrais atvejais leido pasiekti pakankamai gerus rezultatus, todėl galima teigti, kad jis tinkamas pirminiam EEG elementų klasifikavimui, siekiant išskirti Rolando epilepsijai būdingus pikus. Blogiausi rezultatai gaunami imituojant realias sąlygas, t. y. įkeliant visą EEG kanalą be iš anksto atrinktų atkarpų. Taip gali būti dėl didelio skirtumo tarp duomenų, su kuriais tinklas apmokytas arba per didelės signalo variacijos, atsirandančios dėl triukšmo. Taigi tęsiant tyrimą nuspręsta uždavinį padalinti į dvi dalis.

4.3 Papildomo neuroninio tinklo įvedimas

Atsižvelgiant į aukščiau pateiktus tiek tiesinio, tiek rekurentinio neuroninio tinklo rezultatus, nuspręsta klasifikavimo uždavinį padalinti į dvi dalis, kiekvienai iš jų įvedant skirtingą neuroninį tinklą ir iškeliant skirtingus tikslus. Toks sprendimas priimtas dėl to, kad neuroninis tinklas demonstravo pakankami gerus rezultatus klasifikuojant iš anksto paruoštus

duomenis (suskaitytus), tačiau rezultatai smarkiai pablogėdavo bandant nuskaityti visą EEG kanale esančią informaciją:

- 1) I dalyje uždavinys - iš visų signalo atkarpų išskirti pikus ir visas į juos panašias atkarpas bei jas apjungti, taip sumažinant pradinę imtį;
- 2) II dalies tikslas – iš pirmame etape gautų atkarpų išskirti atkarpas su pikais.

Padalinimas į dvi dalis atliktas siekiant optimaliai apmokyti neuroninius tinklus, kiek įmanoma sumažinant paduodamų duomenų variaciją.

4.3.1 I sluoksnis

Atsižvelgiant į ankstesniame skyriuje aprašytus rezultatus, šiame sluoksnyje naudojamas rekurentinis neuroninis tinklas, siekiant, kad būtų atpažinta kiek įmanoma daugiau pikų. Tinklas paruoštas ir apmokytas kaip aprašyta 4.2 skyriuje.

4.3.2 II sluoksnis

Šio sluoksnio tikslas – dirbant su pirmame sluoksnyje paruoštais duomenimis, kaip įmanoma tiksliau identifikuoti pikus ir sumažinti klaidingai pikams priskirtų atkarpų skaičių.

Šiuo atveju apmokant neuroninį tinklą panaudoti rezultatai gauti išanalizavus duomenis 4.2 aprašytu neuroniniu tinklu ir gautus rezultatus patikslinus pagal eksperto nurodytus pikus, taikant 3 skyriuje aprašytą paklaidą. Remiantis 4.1 skyriuje aprašytais eksperimentais, parinktas tiesinis neuroninis tinklas dėl mažesnio atkarpų, klaidingai identifikuotų kaip pikai, skaičiaus.

Lentelė 18. II sluoksnyje Panaudoto neuroninio tinklo parametrai

| | |
|-----------------------------------|---------|
| Įvesties sluoksniai | 1 |
| Vidiniai (paslėptieji) sluoksniai | 1 |
| Išvesties sluoksniai | 1 |
| Neuronų I sluoksnyje | 25 |
| Neuronų II sluoksnyje | 90 |
| Neuronų III sluoksnyje | 1 |
| I ir II Aktyvacijos funkcija | sigmoid |

Bandymui panaudoti tie patys duomenys kaip ir ankstesniuose skyriuose, o rezultatai ir vėl palyginti su [21] algoritmu. Rezultatai pateikiami 19 lentelėje.

Lentelė 19. Neuroninio tinklo ir [21] algoritmo rezultatų palyginimas

| Rasta pikų | [21] algoritmo identifikuotų pikų skaičius | Sutampantys rasti pikai % | Rasta nesutampančių pikų (klaidingai identifikuota lyginant su [21] algoritmo rezultatais) |
|------------|--|---------------------------|--|
| 76 | 98 | 78% | 446 |
| 425 | 593 | 72% | 2305 |
| 1 | 38 | 3% | 2 |
| 1 | 5 | 20% | 8 |
| 31 | 49 | 63% | 160 |
| 0 | 1 | 0% | 0 |

Šiuo atveju gauti ženkliai blogesni rezultatai vertinant rastų ir sutampančių pikų skaičių. Tokius rezultatus galima paaiškinti ribota antrojo etapo apmokytų duomenų imtimi. Šioje situacijoje neruoninis tinklas apmokomas tik su keleto kanalų atkarpomis, kurios pirmojo sluoksnio buvo klasifikuotos kaip pikai, tačiau bandant analizuoti kitus EEG kanalus, į algoritmą gali būti pateikiami visai kito pobūdžio duomenys nei buvo naudota apmokant, taigi rezultatai tampa nepastovūs. Atsižvelgiant į šiame poskyryje pateiktus rezultatus, bandymų su dviem neuroniniais tinklais nuspręsta nebetęsti.

4.4 Praktinis pritaikymas

Iki šiol skyriuje aprašyti tyrimai buvo naudojami tik tinklo analizei ir algoritmo tobulinimui. Tačiau svarbu atkreipti dėmesį, kad vienas iš darbo tikslų yra patogios ne tik duomenų surinkimui, bet ir praktiniam pritaikymui sistemos sukūrimas. Šiame poskyryje aprašoma sistema kurta dėl dviejų pagrindinių priežasčių:

- 1) Siekiant sukurti galimybę patogiai analizuoti EEG bylas;
- 2) Siekiant gerinti neuroninio tinklo veikimą, pastoviai didinant duomenų kiekį.

Atsižvelgiant į tai, kad analizuojant EEG 4.1 skyriuje aprašytu tiesiniu neuroniniu tinklu buvo pasiekti sąlyginai geri rezultatai, panaudojus šį neuroninį tinklą toliau kuriamas analizės įrankis.

3 skyriuje aprašoma programa buvo panaudota kaip klientas, o algoritmas pritaikytas dirbti serveryje ir gauti užklausas bei siųsti atsakymus. Siekiant išvengti tinklo apkrovimo, EDF bylos ir rezultatai laikomi FTP serveryje. Tai leido algoritmu naudotis daugeliui klientų, tuo pačiu optimizuojant suderinamumą ir kompiuterio resursus. Bendro pobūdžio sekos diagrama pavaizduota 20 pav.

Kaip minėta aukščiau, sistema susideda iš dviejų elementų, kurie yra:

Serveris – programa, valdanti užklausas ir atliekanti EDF bylų analizę, paremtą neuroniniu tinklu. Serverio funkcijos:

- Neuroninio tinklo modelių valdymas ir parinkimas pagal atitinkamas užklausas;
- Neuroninio tinklo apmokymas;
- Pateiktų bylų analizė.

Klientas – 4 skyriuje aprašyta programa, atliekanti tokias funkcijas:

- EDF bylų atvaizdavimas;
- Pikų ir ne pikų atvaizdavimas;
- Apmokymo ir analizės užklausų siuntimas į serverį.

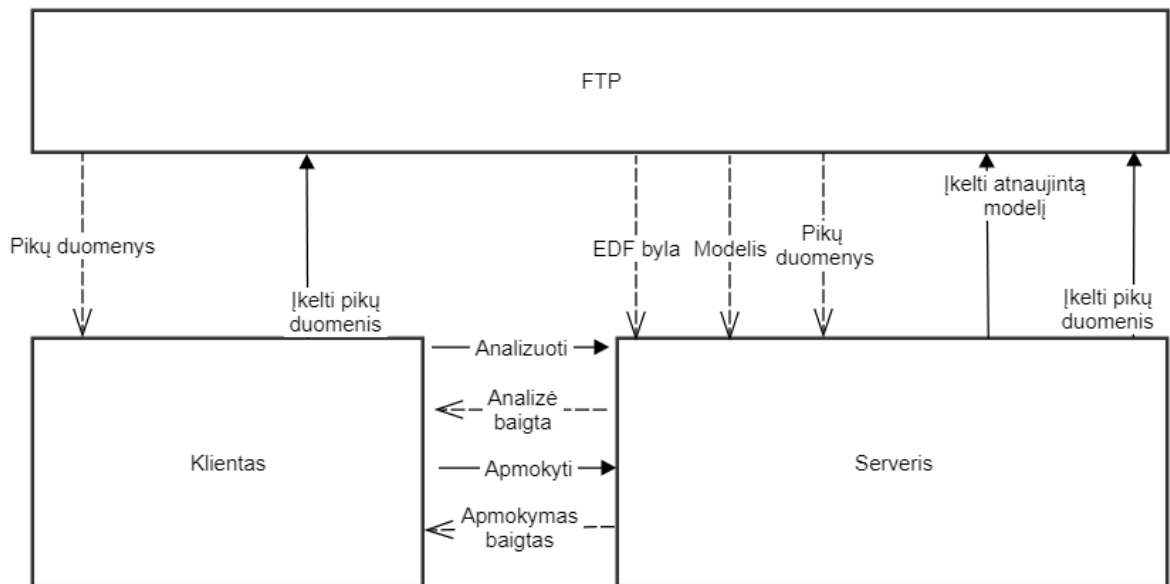
Sistema kurta taip, kad joje galėtų veikti neribotas kiekis klientų ir vienas serveris. Svarbu pabrėžti, kad šiame darbe aprašoma sistema pritaikyta tirti tik vieną – Rolando epilepsijos atvejį. Esant poreikiui, sistema gali būti išplėsta, papildomai įtraukiant kitas ligas ar kito pobūdžio klasifikavimo uždavinius. Ši sistema turi dvi pagrindines funkcijas: EEG analizę ir papildomą apmokymą.

EEG analizė vykdoma tokia eilės tvarka:

- 1) Vartotojas įkelia EDF bylą į FTP serverį (tai galima atlikti naudojant programą);
- 2) Vartotojas atsidaro EDF bylą, naudodamas klientą ir pasirenka funkciją „analizuoti automatiškai“;
- 3) Klientas nusiunčia bylos pavadinimą ir kanalus, kuriuos nurodė Vartotojas serveriui;
- 4) Serveris pagal jo užklausą parenka tinkamą neuroninio tinklo modelį iš FTP serverio;
- 5) Naudodamas parinktą modelį, serveris išanalizuoja EDF bylą ir į FTP serverį įkelia .txt bylą, kurioje pažymėtos pikų koordinatės;
- 6) Klientas gauna pranešimą, kad analizė baigta ir įkelia pikų duomenis iš FTP serverio.

Papildomas neuroninio tinklo apmokymas vykdomas tokia tvarka:

- 1) Vartotojas (naudodamas klientą) sužymi pikus ir juos išsaugo FTP serveryje;
- 2) Vartotojas taip pat į FTP serverį įkelia EDF bylą (tai galima atlikti naudojant programą);
- 3) Klientas nusiunčia bylos pavadinimą ir kanalus, kuriuos nurodė Vartotojas serveriui;
- 4) Serveris pagal jo užklausą parenka tinkamą neuroninio tinklo modelį iš FTP serverio;
- 5) Serveris atsiunčia EDF bylą, modelį ir pikų duomenis, juos paruošia pagal šio darbo 4.1 skyriuje aprašytą metodiką (paruošimas vykdomas iš visų kanalo duomenų) ir pakartoja neuroninio tinklo apmokymą
- 6) Apmokytas modelis įkeliamas į serverį
- 7) Klientas informuojamas, kad apmokymas atliktas.



20 pav. kliento-serverio architektūros schema, skirta algoritmo praktiniam pritaikymui realizuoti.

Taip pat svarbus šios sistemos elementas – algoritmo tobulinimas. Darant prielaidą, kad vartotojai būtų linkę tobulinti sistemos veikimą, galima daryti išvadą, kad algoritmas potencialiai gali pasiekti klasifikavimo tikslumą, artimą 100% dirbant su tam tikros rūšies ligos diagnoze ir duomenimis. Šiame etape aptariama sistema taip pat naudinga dėl galimybės patogiai ir efektyviai atlikti papildomus apmokymus, o taip pat - gauti kokybiškus duomenis ir jais dalintis bei atlikti apmokymo eksperimentus.

5. Rezultatai

Šiame darbe tirtas dirbtinių neuroninių tinklų panaudojimas atliekant neapdorotų arba minimaliai apdorotų EEG analizę. Pagrindinis šios analizės tikslas – identifikuoti tam tikroms ligoms būdingus EEG elementus, o kaip tyrimo objektas buvo pasirinkti gerybinei vaikystės epilepsijai su centrotemporalinėmis iškrovomis (angl. *benign childhood epilepsy with centrotemporal spikes*, dar vadinamai Rolando epilepsija) būdingi EEG pikai. Darbo eigoje pasiekti šie rezultatai:

- Siekiant surinkti duomenis, parašyta programa, skirta ekspertams pažymėti tam tikrus EEG elementus. Bendradarbiaujant su viešosios įstaigos Vilniaus universiteto ligoninės Santaros klinikų filialo Vaikų ligoninėje dirbančia vaikų neurologe Dr. Rūta Samaitiene (toliau – Ekspertė) surinkti 499 Rolando epilepsijai būdingi pikų pavyzdžiai su tiksliais koordinatėmis ir 48 į pikus panašūs dariniai, kurie nėra pikai. Surinkti duomenys leido pasiekti kiek įmanoma tikslesnį algoritmų apmokymą, o tiek programa, tiek ir surinkti duomenys gali būti panaudoti ateities tyrimuose.

- Naudojant surinktus duomenis, apmokytas tiesinis, trijų sluoksnių neuroninis tinklas, kuris vidutiniškai identifikuodavo ~95% ekspertės nurodytų pikų, vertinant 3 pacientų EEG.

- Tas pats neuroninis tinklas vidutiniškai identifikuodavo ~70% pikų (vertinant 9 pacientų EEG), lyginant su morfologiniais filtrais paremtu automatizuotos EEG analizės algoritmu ir vidutiniškai ~40% iš visų identifikuotų elementų nesutapdavo. Ekspertei įvertinus nesutampančius elementus, konstatuota, kad dalis jų tikrai yra pikai, tai parodo, kad neuroninis tinklas gali pasiekti didesnę nei 70% vidutinį tikslumą, tačiau lygiai taip pat dalis yra ir netipiniai pikai, remiantis vien kuriais, negalima nustatyti diagnozės.

- Naudojant duomenų surinkimo programą kaip klientą, sukurta kliento-serverio infrastruktūra, leidžianti automatiškai išanalizuoti EEG bei pastoviai gerinti algoritmo veikimą, apmokant tinklą papildomais duomenimis.

6. Išvados ir rekomendacijos

Apibendrinant darbą galima įvardinti keletą pagrindinių išvadų:

- Remiantis literatūros analize ir 4.1 skyriuje išbandžius įvairias neuroninio tinklo apmokymo strategijas, nustatyta, kad optimaliausia šiam uždaviniui yra apmokyti neuroninį tinklą su visa EEG kanale esančia informacija, surinkta nuskaitant kanalą slenkančio lango principu, o 200 ms atkarpa klasifikuojant kaip turinčias pikus, kai jų centras yra nutolęs nuo eksperto pažymėto piko centro per ~42,5% atkarpos ilgio.
- Išbandžius keletą neuroninių tinklų tipų su skirtingomis konfigūracijomis, nustatyta, kad tiesinis trijų sluoksnių neuroninis tinklas, turintis 25 (kai analizuojamos atkarpos ilgis yra lygus 50 elementų), 90 ir 1 neuronų, atitinkamai I, II ir III sluoksniuose yra tinkamiausias iš darbe analizuotų metodų EEG analizei, siekiant išskirti Rolando epilepsijai būdingus pikus (4.1 skyrius, rezultatai pateikiami 11 lentelėje).
- Atsižvelgiant į eksperto vertinimą (aprašyta skyriuje 4.1, o detalūs pavyzdžiai pateikti priede A) galima daryti išvadą, kad tiesinis neuroninis tinklas tam tikrais atvejais gali identifikuoti daugiau pikų nei morfologiniais filtrais paremtas automatinės EEG analizės algoritmas [21], tačiau identifikuojami netipiniai pikai riboja šio neuroninio tinklo pritaikymą pilnai automatizuotai analizei ir nulemia tai, kad rezultatai bet koku atveju turėtų būti papildomai vertinami eksperto.
- Bandant padalinti uždavinį į dvi dalis ir naudoti dviejų skirtingų konfigūracijų neuroninius tinklus, nepavyko pasiekti rezultatų pagerėjimo (žr. skyrių 4.4), taigi galima daryti išvadą, kad toks algoritmo dizainas nepadedą pasiekti geresnių rezultatų.

7. Ateities tyrimų planas

Nors šio darbo dalis ir buvo duomenų surinkimas, tačiau detalesnę analizę riboja įvairaus pobūdžio duomenų trūkumas. Kadangi darbe analizuotas atvejis su Rolando epilepsija, būtų tikslinga išplėsti apimtį, analizuojant kitas epilepsijos rūšis arba kitas ligas, pasireiškiančias įvairiomis EEG anomalijomis.

Darbe naudotos dvi neuroninio tinklo rūšys (tiesinis ir rekurentinis, paremtas LSTM modeliu). Papildomai būtų tikslinga įvertinti kito tipo neuroninių tinklų klasifikavimo rezultatus bei ištirti galimybę juos apjungti.

Klasifikavimą apsunkino darbas su neapdorotais EEG duomenimis, o papildomas jų apdorojimas (be 50Hz filtro) nebuvo analizuojamas. Norint išplėsti tyrimą (ir potencialiai pagerinti rezultatus), galima pabandyti aptariamus metodus pritaikyti jau apdorotiems duomenims, t. y. gautas atkarpas papildomai apdoroti arba įvesti papildomus duomenis apie signalą kaip papildomus parametrus neuroniniams tinklams.

Atsižvelgiant į tai, kad epilepsijos diagnozės procesą sudaro ne vien EEG pikų identifikavimas, būtų tikslinga išplėsti tyrimą vertinant papildomus EEG ir pikų parametrus ir taip bandant sukurti algoritmą galintį pateikti pilną diagnozę.

Padėkos

Dėkoju Vilniaus universiteto ligoninės Santaros klinikų filialo Vaikų ligoninės vaikų neurologei Dr. Rūtai Samaitienei už pagalbą surenkant ir analizuojant duomenis, bei jos pateiktas įžvalgas.

Literatūros sąrašas

- [1] EEG SIGNAL PROCESSING. Saeid Sanei and J.A. Chambers Centre of Digital Signal Processing Cardiff University, UK
- [2] Tatum, William O. (2014). Handbook of EEG interpretation. Demos Medical Publishing. pp. 155–190. ISBN 9781617051807. OCLC 874563370.
- [3] Krishnaveni, V., Jayaraman, S., Aravind, S., Hariharasudhan, V., & Ramadoss, K. (2006). Automatic identification and removal of ocular artifacts from EEG using wavelet transform. *Measurement science review*, 6(4), 45-57.
- [4] Srinivasan, Ramesh (1999). "Methods to Improve the Spatial Resolution of EEG". *International Journal*. 1 (1): 102–11.
- [5] Vespa, Paul M.; Nenov, Val; Nuwer, Marc R. (1999). "Continuous EEG Monitoring in the Intensive Care Unit: Early Findings and Clinical Efficacy". *Journal of Clinical Neurophysiology*. 16 (1): 1–13. PMID 10082088. doi:10.1097/00004691-199901000-00001.
- [6] O'Regan, S; Faul, S; Marnane, W (2010). "2010 Annual International Conference of the IEEE Engineering in Medicine and Biology": 6353–6. ISBN 978-1-4244-4123-5. doi:10.1109/IEMBS.2010.5627282.
- [7] Gotman J, Ives J. Computer-assisted data collection and analysis. In: Wyllie E, editor. *The treatment of epilepsy: principles and practice*, 2. Baltimore, MD: Williams and Wilkins, 1996. pp. 280±291.
- [8] Ozdamar O, Kalayci T. Detection of spikes with artificial neural networks using raw EEG. *Comput Biomed Res* 1998;31:122–142.
- [9] Ko, C. W., & Chung, H. W. (2000). 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*, 111(3), 477-481.
- [10] Schirrmester, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggersperger, K., Tangermann, M., ... & Ball, T. (2017). Deep learning with convolutional neural networks for EEG decoding and visualization. *Human brain mapping*, 38(11), 5391-5420.
- [11] Ko, C. W., Lin, Y. D., Chung, H. W., & Jan, G. J. (1998). An EEG spike detection algorithm using artificial neural network with multi-channel correlation. In *Engineering in Medicine and Biology Society, 1998. Proceedings of the 20th Annual International Conference of the IEEE (Vol. 4, pp. 2070-2073)*. IEEE.
- [12] Gabor, A. J., & Seyal, M. (1992). Automated interictal EEG spike detection using artificial neural networks. *Electroencephalography and clinical Neurophysiology*, 83(5), 271-280.
- [13] Wilson, A. C., Roelofs, R., Stern, M., Srebro, N., & Recht, B. (2017). The Marginal Value of Adaptive Gradient Methods in Machine Learning. arXiv preprint arXiv:1705.08292.

- [14] Kramer U (July 2008). "Atypical presentations of benign childhood epilepsy with centrotemporal spikes: a review". *J. Child Neurol.* 23 (7): 785–90. doi:10.1177/0883073808316363. PMID 18658078
- [15] Fejerman, N., Caraballo, R., & Tenenbaum, S. N. (2000). Atypical Evolutions of Benign Localization-Related Epilepsies in Children: Are They Predictable?. *Epilepsia*, 41(4), 380-390.
- [16] Panayiotopoulos, C. P. (1999). *Benign childhood partial seizures and related epileptic syndromes* (Vol. 15). John Libbey Eurotext.
- [17] Valenti, P., Cazamajou, E., Scarpettini, M., Aizemberg, A., Silva, W., & Kochen, S. (2006). Automatic detection of interictal spikes using data mining models. *Journal of neuroscience methods*, 150(1), 105-110.
- [18] Samaitienė R. Rolando epilepsija sergančių vaikų EEG pakitimu, miego bei elgesio sutrikimu ir klinikiniu charakteristikų sąsajos. Vilniaus universitetas, 2013.
- [19] Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., ... & Ghemawat, S. (2016). Tensorflow: Large-scale machine learning on heterogeneous distributed systems. arXiv preprint arXiv:1603.04467.
- [20] Chollet, Francois et al. Keras (2015). <https://github.com/keras-team/keras>
- [21] Misiūnas, A. V. M., Meškauskas, T., & Juozapavičius, A. On the implementation and improvement of automatic EEG spike detection algorithm.
- [22] Wikimedia commons. Feed forward neural net. https://en.wikipedia.org/wiki/File:Feed_forward_neural_net.gif
- [23] Nigam, V. P., & Graupe, D. (2004). A neural-network-based detection of epilepsy. *Neurological Research*, 26(1), 55-60.
- [24] Webber, W. R. S., Lesser, R. P., Richardson, R. T., & Wilson, K. (1996). An approach to seizure detection using an artificial neural network (ANN). *Electroencephalography and clinical Neurophysiology*, 98(4), 250-272.
- [25] S. Hochreiter, Y. Bengio, P. Frasconi, and J. Schmidhuber. Gradient flow in recurrent nets: the difficulty of learning long-term dependencies. In S. C. Kremer and J. F. Kolen, editors, *A Field Guide to Dynamical Recurrent Neural Networks*. IEEE Press, 2001.
- [26] Frost, J. D., Hrachovy, R. A., & Glaze, D. G. (1992). Spike morphology in childhood focal epilepsy: relationship to syndromic classification. *Epilepsia*, 33(3), 531-536.
- [27] Wilson, S. B., & Emerson, R. (2002). Spike detection: a review and comparison of algorithms. *Clinical Neurophysiology*, 113(12), 1873-1881.
- [28] Gloor P. Contributions of electroencephalography and electrocorticography in the neurosurgical treatment of the epilepsies. *Adv Neurol* 1975;8:59–105.
- [29] Carrie JR. A hybrid computer technique for detecting sharp EEG transients.

Electroencephalogr Clin Neurophysiol 1972;33(3):336–8.

[30] Petrosian, A. A., Prokhorov, D. V., Lajara-Nanson, W., & Schiffer, R. B. (2001). Recurrent neural network-based approach for early recognition of Alzheimer's disease in EEG. *Clinical Neurophysiology*, 112(8), 1378-1387.

[31] Güler, N. F., Übeyli, E. D., & Güler, I. (2005). Recurrent neural networks employing Lyapunov exponents for EEG signals classification. *Expert systems with applications*, 29(3), 506-514.

[32] Davidson, P. R., Jones, R. D., & Peiris, M. T. R. (2006, January). Detecting behavioral microsleeps using EEG and LSTM recurrent neural networks. In *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the* (pp. 5754-5757). IEEE.

[33] Sundermeyer, M., Oparin, I., Gauvain, J. L., Freiberg, B., Schlüter, R., & Ney, H. (2013, May). Comparison of feedforward and recurrent neural network language models. In *Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference on* (pp. 8430-8434). IEEE.

[34] De Oliveira, P. G., Queiroz, C., & Da Silva, F. L. (1983). Spike detection based on a pattern recognition approach using a microcomputer. *Electroencephalography and clinical neurophysiology*, 56(1), 97-103.

[35] NumPy kūrēju bendruomenė. 2017. <http://www.numpy.org/>

[36] J. Hunter, D. Dale, E. Firing, M. Droettboom ir Matplotlib kūrēju bendruomenė. Matplotlib . 2017. <https://matplotlib.org/>

[37] H. Nahrstaedt. Pyedflib. 2017. <http://pyedflib.readthedocs.io>

[38] cx_Freeze. https://anthony-tuininga.github.io/cx_Freeze/

[39] Gerrard, Paul, and Robert Malcolm. "Mechanisms of modafinil: a review of current research." *Neuropsychiatric disease and treatment* 3.3 (2007): 349.

[40] Klimesch, W. (1999). EEG alpha and theta oscillations reflect cognitive and memory performance: a review and analysis. *Brain research reviews*, 29(2), 169-195.


[41] Princy, R., Thamarai, P., & Karthik, B. (2015). Denoising EEG signal using wavelet transform. *International Journal of Advanced Research in Computer Engineering & Technology*, 3.

[42] Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng CK, Stanley HE. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation* 101(23):e215-e220.
Prieiga per internetą: <https://physionet.org/physiobank/database/erpbc/>

[43] Mirchandani, G., & Cao, W. (1989). On hidden nodes for neural nets. *IEEE Transactions on circuits and systems*, 36(5), 661-664.

PRIEDAS A: Eksperto vertinimas

Čia pateikiami tiesinio trijų sluoksnių neuroninio tinklo identifikuoti pikai, kurių neišskyrė [21] aprašomas automatinės EEG analizės algoritmas (pažymėta apskritimais) ir eksperto vertinimas (kitame puslapyje). Visais atvejais pateikiamas to paties paciento T4 kanalas. Vieno signalo amplitudė: 800



| Nr. | Vertinimas | Atkarpos su piku pradžia (s) |
|-----|---|------------------------------|
| 1 | Pikas | 0.19 |
| 2 | Pikas su maža amplitude ir per mažu aštrumu | 1.27 |
| 3 | Pikas | 36,57 |
| 4 | Galbūt pikas su per mažu aštrumu | 51.87 |
| 5 | Ne pikas | 55.20 |
| 6 | Galbūt pikas, tačiau su per mažu aštrumu | 83.06 |
| 7 | Tikriausiai ne pikas | 93.82 |
| 8 | Tikriausiai pikas | 97.93 |
| 9 | Tikriausiai pikas | 119.37 |
| 10 | Pikas (tačiau su mažesniu aštrios bangos aštrumu) | 138.93 |