



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

Magistro baigiamasis darbas

Automatizuotos medicininių signalų analizės algoritmai

Atliko:

Greta Kasparaitytė

parašas

Vadovas:

prof. dr. Tadas Meškauskas

Vilnius
2023

Turinys

Sutartinis terminų žodynas	4
Santrauka	5
Summary	6
Įvadas	7
1. Elektroencefalogramos	9
1.1. Diagnostika	9
1.2. Artefaktai	11
1.3. Pikai	12
2. Triukšmo šalinimo algoritmai	13
2.1. Vilnelės transformacija	13
2.1.1. Vilnelė	13
2.1.2. Nuolatinė Vilnelės transformacija	14
2.1.3. Diskrečioji Vilnelės transformacija	14
2.1.4. Vilnelių tipai	15
2.2. Furje transformacija	16
2.2.1. Diskrečioji Furje transformacija	17
2.2.2. Greitoji Furje transformacija	17
3. Pikų aptikimo algoritmas	17
3.1. Morfologinės operacijos	18
3.2. Struktūriniai elementai	20
3.3. Pikų atpažinimas	21
3.3.1. Signalo atkarpos ilgis	21
3.3.2. Pikų detekcijos riba	21
3.3.3. Struktūrinio elemento ilgis	22
4. Praktinė darbo dalis	22
4.1. Duomenys	22
4.2. Programavimo kalbos pasirinkimas	23
4.3. Naudotos bibliotekos	23
4.4. Algoritmų taikymas	24
4.4.1. Greitosios Furje transformacijos taikymas	24
4.4.2. Vilnelės transformacijos taikymas	27
4.4.3. Morfologinių operacijų taikymas	30
4.4.4. Rezultatų apibendrinimas	34
Išvados ir rekomendacijos	38
Ateities tyrimų planas	39
Padėkos	40

Literatūros šaltiniai	41
Priedai	43
A. Algoritmo pritaikymo rezultatų tęsinys	43

Sutartinis terminų žodynas

EEG (angl. Electroencephalogram) — elektroencefalograma

CWT (angl. Continuous Wavelet Transform) - nuolatinė Vilnelės transformacija

DWT (angl. Discrete Wavelet Transform) - diskrečioji Vilnelės transformacija

DFT (angl. Discrete Fourier Transform) - diskrečioji Furje transformacija

FFT (angl. Fast Fourier Transform) — greitoji Furje transformacija

CNS (angl. Central Nervous System) — centrinė nervų sistema

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

VT (angl. Wavelet Transform) - Vilnelės transformacija

Santrauka

Šiame darbe buvo analizuojamos elektronecefalogramos, kurių pagalba yra diagnozuojamos įvairios centrinės nervinės sistemos ligos, tokios kaip epilepsija ar kt. Norint atlikti turimų elektroencefalogramų signalų analizę bei rasti epileptoforminius pikus pagrįsti tam tikrai diagnozei, yra reikalinga atlikti triukšmo šalinimo transformacijas, norint išvengti klaidingų signalo požymių, kurie gali būti panašūs į pikus. Tad šiame darbe buvo įgyvendintos ir palygintos dvi triukšmo šalinimo transformacijos - greitoji Furje transformacija bei Vilnelės transformacija. Kita šio darbo dalis buvo morfologinių operacijų ir filtrų bei atitinkamų parametrų radimo įgyvendinimas epileptoforminiams pikams elektronecefalogramų signaluose rasti. Pagrindinis šio darbo tikslas buvo pritaikyti triukšmo šalinimo algoritmus signalams, rasti su kokiais koeficientais bei parametrais įvykdžius morfologines operacijas pikų detektavimas yra tiksliausias bei rezultatų palyginimas tarp implementuotų algoritmų.

Summary

Algorithms for Automatic Analysis of Clinical Signals

The main aim of this work was to analyze electroencephalograms, which are used to diagnose various diseases of the central nervous system, such as epilepsy or others. To perform the analysis of available electroencephalogram signals and to find epileptic spikes to support a specific diagnosis, it is necessary to perform noise removal transformations to avoid false signs of the signal that may look similar to spikes. Therefore, in this paper, two noise removal transformations were implemented and compared - the fast Fourier transformation and the Wavelet transformation. Another part of this work was the implementation of morphological operations and filters and corresponding parameters to find epileptic spikes in EEG signals. The main goal of this work was to apply noise removal algorithms to signals, to find with which coefficients and parameters spikes detection is the most accurate after performing morphological operations, and to compare the results between the implemented algorithms.

Ivyadas

Signalai šiomis dienomis užima nemažą dalį mūsų gyvenimo. Technologiškai besivystančiame pasaulyje, signalus galima sutikti vos ne kiekviename žingsnyje. Signalus bei jų apdorojimą galime taikyti kompiuteriuose bei mobiliuose įrenginiuose. Signalus sutinkame klausant tam tikrų garsų ar muzikos, judant, kuomet judesys yra matuojamas įvairias jutikliais, stebint tam tikrus vaizdus ar nuotraukas, žiūrint vaizdo įrašus. Todėl galima teigti, jos signalai bei jų analizė turi daug panaudojamumo sričių.

Signalai medicinoje yra ne išimtis. Medicininės kilmės signalai nurodo žmogaus organizmo veiklą bei leidžia įvertinti žmogaus medicininę sveikatos būklę. Dažniausiai žmogaus gyvenime yra sutinkamos elektrokardiogramos, kurios leidžia stebėti žmogaus širdies veiklą, tačiau medicinoje galime sutikti ir elektroencefalogramas.

Elektroencefalografija - tai neinvazinis galvos smegenų bioelektrinio aktyvumo tyrimas, kurio metu registruojami galvos smegenų potencialai. Šis tyrimas leidžia nustatyti epilepsiją, diagnozuoti įvairias nervines ir psichikos ligas. Elektrokardiogramos tyrimas yra trumpas, tad analizė neužtrunka ilgą laiką, lyginant su elektroencefalogramų analize. Tuo tarpu, analizuojant elektroencefalogramą bei remiantis 10 - 20 sistema, ją sudaro 21 kanalas bei elektrokardiogramos matavimai gali užtrukti net iki valandos. Būtent todėl dėl didelio signalų kiekio bei trukmės, medicinos gydytojams analizė užtrunka nemažai laiko. Epilepsijos atveju, elektroencefalogramos signale yra ieškoma epileptoforminių pikų, kurie padeda patvirtinti arba paneigti diagnozę pacientui. Gydytojui aptikti pikus trunka daug laiko bei yra žmogiška galimybė įvertinti ne vieną klaidą, tad automatizuotas pikų aptikimas tikrai palengvintų gydytojų darbą.

Šio magistro baigiamojo darbo uždaviniai:

1. Susipažinti su elektroencefalogramų signalais bei jų apdorojimu;
2. Išanalizuoti EEG pikų aptikimų teoriją bei jų savybes;
3. Įgyvendinti greitąją Furje transformaciją EEG signalo triukšmui pašalinti;
4. Įgyvendinti Vilnelės transformaciją EEG signalo triukšmui pašalinti;
5. Įgyvendinti morfologinėmis operacijomis paremtą algoritimą;
6. Surasti parametrus, su kuriais implementuoti algoritmai veikia tiksliausiai, lyginant su jau turimais duomenimis;
7. Palyginti įgyvendintas transformacijas pritaikius morfologines operacijas tarpusavyje.

Pirmajame skyriuje aprašoma, kas yra elektroencefalogramos bei jų svarba ir taikymas medicinoje. Skyriuje taip pat pristatoma 10 - 20 sistema, kuria remiantis vykdoma elektroencefalogramų diagnostika, aprašomi elektroencefalogramų artefaktai, pikai bei jų savybės.

Antrajame skyriuje aprašomos Vilnelės transformacijos bei jų tipai, kuo Vilnelės transformacijos skiriasi tarpusavyje bei kokius rezultatus galima pasiekti naudojant skirtingas vilnelių klases. Taip pat šiame skyriuje aprašoma Furje transformacija bei jos pritaikomumas elektroencefalogramų signalams.

Trečiajame skyriuje analizuojama morfologinių filtrų teorija bei algoritmas, kuris šiame darbe bus pritaikomas epileptoforminiams pikams rasti.

Ketvirtasis skyrius - tai praktinė magistro baigiamojo darbo dalis. Šiame skyriuje aprašomi testiniai duomenys algoritmo įgyvendinimui, apžvelgiamas Europos duomenų formatas. Skyriuje pateikiami implementuojamo algoritmo žingsniai, sprendimai bei rezultatai, apžvelgiamos Python atvirojo kodo programavimo kalbos bibliotekos. Paskutiniame skyriaus poskyryje yra aprašomi gauti rezultatai bei taikytų transformacijų palyginimas detekcijos koeficiento ribai.

Šis magistro baigiamasis darbas yra tęstinis. Dalis uždavinių buvo sprendžiami mokslo tiriamojo darbo metu [18]. 1, 2 ir dalis 4 (4.1 - 4.4.2) skyrių informacijos yra paimta iš mokslo tiriamojo darbo, bet kartu atnaujinta ir papildyta.

1. Elektroencefalogramos


Žmogaus smegenys apdoroja įvairiausių informaciją pasitelkdamas neuronus, kurie siunčia tam tikrus signalus. Smegenyse nervų veikla vyksta nuolat - jos visą parą generuoja elektrinius signalus. Būtent tokių signalų tyrimai yra gyvybiškai svarbūs, norint suprasti smegenų veiklą, jų elgesį, diagnozuoti įvairias ligas. Tyrimams vykdyti yra pasitelkiama daugybė metodų - funkcinio magnetinio rezonanso tomografija, funkcinė artimųjų infraraudonųjų spindulių spektroskopija ar elektroencefalografijos [10]. Funkcinio magnetinio rezonanso tomografija matuoja smegenų veiklą, nuskaitydamas kraujotaką, funkcinė artimųjų infraraudonųjų spindulių spektroskopija matuoja smegenų veiklą, matuodamas hemodinaminį atsaką smegenyse, nustatydamas infraraudonųjų spindulių šviesos šaltinio laikinus pokyčius. Tuo tarpu, elektroencefalografija matuoja smegenų elektrinį aktyvumą elektrodais, uždėtais ant galvos odos.

Elektroencefalografija (EEG) - medicinos technika, kuria naudojantis yra stebima smegenų veikla bei jų aktyvumas. Ji susideda iš kelių kanalų, kurie nurodo neuronų veiklą tam tikrose smegenų dalyse [16]. Elektroencefalografija yra vienas iš pagrindinių įrankių, kuris leidžia diagnozuoti epilepsiją ar kitas centrinės nervinės sistemos ligas.

Epilepsija - neurologinis sutrikimas, kuris pasireiškia nekontroliuojamais priepuoliais. Pasireiškus šiems priepuoliams, smegenyse išsiskiria tam tikros išskyros, dėl kurių sutrinka EEG. Stebint EEG bei ieškant epileptoforminių pikų galima diagnozuoti epilepsiją bei paskirti tam tikrus gydymo metodus. Įprastai EEG turi iki 20 elektrodų ir trunka ilgiau nei valandą.

1.1. Diagnostika

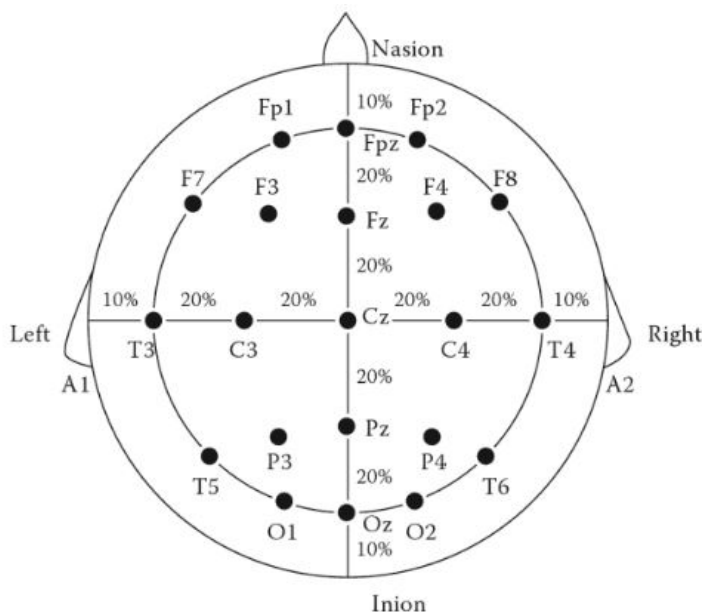
Elektroencefalogramos yra atliekamos naudojant elektrodus, kurie yra pritvirtinami prie galvos odos. Plačiausiai pasaulyje yra naudojama EEG nuskaitymo sistema - 10 - 20 sistema [25]. Remiantis šia sistema, kiekvienas elektrodas turi savo vietą, t.y. elektrodas visuomet yra tvirtinamas tose pačiose paciento galvos vietose tam tikrose smegenų skiltyse, kurios pavaizduotos 1 paveikslėlyje.



1 pav. Galvos smegenų skiltys [1].

Kiekviena smegenų ląstelė, suaktyvinta aplink galvos odą, sukuria elektrinį ir magnetinį lauką. Ši sistema leidžia pastebėti, jog jei signale buvo pastebėtas pikas, jis turi atsikartoti ir kaimyniniuose elektroduose. Kaimyninius elektrodus galime pamatyti 2 paveikslėlyje, kuriame pateikta


EEG elektrodų išdėstymo schema 10 - 20 EEG sistemoje. 2 pav. nurodyti skaičiai 10 ir 20 nurodo atstumą tarp elektrodų, kurie sudaro 10 arba 20 procentų kaukolės priekinės, nugarinės, dešiniojos ir kairiosios dalies atstumo. Kiekvienas elektrodas yra pavadintas pagal smegenų skilties ir pusrutulio vietą. Reikia atkreipti dėmesį, kad centrinė skiltis *C* neegzistuoja, o raidė *Z* nurodo elektrodo vietą vidurinėje linijoje. Lyginiai ir nelyginiai skaičiai nurodo elektrodų vietą atitinkamai dešiniajame ir kairiajame pusrutuliuose.



2 pav. Standartinis 10 - 20 tarptautinės EEG sistemos elektrodų išdėstymas [27].

Ilgas darbas su EEG tyrimais bei signalais nustatė penkias pagrindines EEG signalų smegenų aktyvumo bangų grupes bei ryšį tarp tam tikros smegenų dalies elgesio ir nervinio aktyvumo. Smegenų bangų dažnis gali skirtis priklausomai nuo stebimo asmens būklės, tačiau, kaip ir minėta anksčiau šios smegenų bangos yra suskirstytos į 5 smegenų ritmus pagal jų dažnį:

- **Delta** (0.1 - 4 Hz arba 0.5 - 4 Hz) - Miego būsenoje arba jei pacientas be sąmonės. Delta ritmas yra žemo dažnio banga, tad dažnai ją galima supainioti su judėjimo artefaktu;
- **Teta** (4 - 8 Hz) - Miegoistumo būsenoje;
- **Alfa** (8 - 14 Hz) - Budrumo būsenoje, kai pacientas atsipalaidavęs ir užmerkęs akis;
- **Beta** (14 - 30 Hz) - Kai pacientas atsimerkęs ir aktyviai reaguoja į aplinką - aktyviai mąsto, nerimauja, yra susikaupęs;
- **Gama** (30 - 63 Hz) - Sutinkama retai, tačiau manoma, jog Gama ritmas sujungia informaciją iš dviejų skirtingų sensorių.



3 pav. EEG signalas ir smegenų ritmai.

Dažnai EEG signaluose žemo dažnio Delta ritmas yra dominuojantis neapdorotame signalu, tuo tarpu Gama ritmas yra panašus į triukšmą su labai maža amplitude. Verta paminėti, jog elektroencefalografijos metu visos paminėtų ritmų proporcijos gali būti įtraukos bei keičiamos atsižvelgiant į kognityvinius bei sensorinius procesus [25, 27]. 3 paveikslėlyje vaizduojamas payzdinis EEG signalas bei atitinkami smegenų ritmai.

1.2. Artefaktai

Įprastinė smegenų veikla gali turėti įvairios kilmės artefaktų, kurie gali pasirodyti panašūs į epileptiforminius pikus [25]. Artefaktų įtaka EEG signalams gali būti santykinai proporcinga EEG kanalo vietai ir artefaktų dažnių diapazonui, tad jie gali sutrikdyti EEG analizę paciento diagnozei nustatyti. Jie yra skirstomi į du tipus - vidinius bei išorinius. Vidiniai dažniausiai būna generuojami paciento ar jo smegenų veiklos, tuo tarpu išoriniai - matavimo prietaisų ar kitų išorinių veiksnių, pvz., elektronikos prietaisų. Vidiniai artefaktai dažniausiai gali būti kūno ar akių judesiai, širdies ar smegenų veikla bei prakaitavimas. Išoriniai - elektronikos prietaisai, elektros tinklo triukšmai, pažeisti laidai ar nesubalansuota elektrodų varža.

Vienas iš paminėtų vidinių artefaktų gali būti judesio artefaktas. Todėl stengiamasi užtikrinti, kad EEG matavimas būtų atliekamas ramybės būsenoje arba miegant. Manoma, kad tarp vidinių artefaktų akių mirksėjimas daro didžiausią įtaką EEG signalo analizei dėl didelės amplitudės ir persidengiančių dažnio komponentių. Žmogaus akies ragena ir tinklainė sudaro elektrinį dipolį. Akių judesiai ir mirksėjimai modifikuoja dipolį ir generuoja elektrinį signalą, kuris sukelia stiprius artefaktus signaluose [11]. Akių mirksėjimui yra būdingos žemo dažnio komponentės, turinčios didelę amplitudę, kurių aktyvumas yra simetriškas bei dažniausiai aptinkamas priekinės srities elektrodoose ir mažai sklindantis į kitus elektrodus. Akių judesiai yra identifikuojami kaip žemo dažnio signalai, kurių amplitudės mažesnės, bet sklindimas į kitus elektrodus kur kas didesnis [13].


Išorinis elektros tinklo artefaktas dažnai atsiranda dėl elektrodų jautrumo elektros srovei, todėl atliekant analizę rekomenduojama atlikti triukšmo šalinimo veiksmus. Literatūroje apie išorinius artefaktų šalinimą iš EEG signalų nėra daug informacijos [14, 12]. Elektros tinklo sukeltas išorinis artefaktas gali atsirasti dėl elektrodų poslinkių, odos ir kontakto su ja praradimo, įrašo nutrūkimo.

1.3. Pikai

Įprasta smegenų veikla pasižymi įvairiais smegenų ritmais, kurie vyksta bet kurioje žmogaus būsenoje - smegenys būna aktyvios, todėl EEG gali būti atliekamos tiek miego, tiek ramybės būsenoje. Analizuojant EEG, gydytojas ieško neįprastos smegenų veiklos, suaktyvėjimo - pikų, kuriuos neretai jiems gali būti sunku identifikuoti dėl įvairios kilmės artefaktų [25]. Kartais gali nutikti taip, jog tam tikri artefaktai gali būti panašūs į pikus, todėl pikai apibrėžiami tam tikromis charakteristikomis [16]:

1. Piko trukmė apibrėžiama 40 – 200 ms;
2. Pikas dažniausiai pastebimas C4/C3 arba C5/C6 elektroduose;
3. Pikas turi būti aptinkamas bent dviejuose gretimuose elektroduose;
4. Pikas bent du kartus išskyla virš bazinės linijos amplitudės.

Epileptoforminiai pikai gali būti aptinkami skirtingose galvos srityse. Jie pasižymi aukšta amplitude bei juos dažniausiai lydi iškrovos banga. Tačiau jie taip pat gali pasirodyti tiek vieni, tiek grupėse. Štai 4 paveikslėlyje vaizduojamas epileptoforminis pikas ties 3.55 sekunde, kuris aptiktas tiek C3-RF, tiek kaimyniniame T3-RF kanaluose.



4 pav. Originalus elektroencefalogramos signalas.

2. Triukšmo šalinimo algoritmai

Skiriant laiko signalų analizei, galima pastebėti, jog signalai skiriasi savo kokybe. Kai kuriuose signaluose galima pastebėti tam tikrą triukšmą. Kaip jau buvo minėta ankstesniuose skyriuose, EEG signaluose galima pastebėti skirtingų artefaktų - akių ar staigius judesius, prakaitavimą, kvėpavimą. Kvėpavimas pasireiškia žemo dažnio (0.5 Hz) triukšmu. Senesnio modelio elektroencefalografijos matavimo prietaisuose yra žymus elektros srovės šaltinio veiksnys, dėl kurių encefalogramose gali atsirasti 50 Hz dažnio triukšmas. Šiems artefaktams pašalinti galima naudoti Furje arba Vilnelės transformacijas, kurios pašalins nepageidaujamo dažnio harmonikas iš tiriamų signalų, taip pagerinant signalo kokybę pikų paieškai.

2.1. Vilnelės transformacija

Dažniausiai signalai yra nenuspėjami - signalų savybės bei tendencijos nuolat keičiasi. Šiais laikais EEG signalų savybėms gauti naudojamos įvairios matematinės priemonės - Furje transformacija, greitoji Furje transformacija, trumpalaikė Furje transformacija, Vilnelės transformacija [20]. Pavyzdžiui, norint analizuoti tam tikrus įvykius, dažniausiai yra naudojama laiko ir dažnio analize - Furje transformacija. Būtent šiai transformacijai alternatyva būtų Vilnelės transformacija, kuri koncentruojasi į žemo bei aukšto dažnio signalus. Vienas iš pagrindinių Furje transformacijos trūkumų yra tas, jog ji fiksuoja viso signalo dažnių informaciją, kuri išlieka visame signale. Toks signalo skaidymas gali būti netinkamas tam tikriems signalams, kurie pasižymi trumpais virpesių intervalais. Alternatyvus metodas yra Vilnelės transformacija, kuri išskaido funkciją į vilnelių rinkinį.

Vilnelės transformacija yra laiko ir dažnio analizės tipas, kuris suteikia informacijos apie dažnį ir laiką signaluose. Vienas iš pagrindinių šios transformacijos plusų yra tas, jog ji prisitaiko tiek prie žemų, tiek prie aukštų dažnių, todėl pasiekama optimali laiko dažnio skiriamoji geba visuose dažnių diapazonuose.

2.1.1. Vilnelė

Vilnelė yra bangos tipo osciliazija, kuri yra lokalizuota laike. Vilnelės turi dvi pagrindines savybes - mastelį ir vietą. Vilnelės mastelis nurodo, kiek ji yra ištempta arba suspausta. Ši savybė yra susieta su signalo dažniu. Tuo tarpu vilnelės vieta nurodo jos padėtį laike ar erdvėje.

Viena iš pagrindinių Vilnelės idėjų yra apskaičiuoti, kiek vilnelės yra tam tikrame mastelio ir vietos signale. Vilnelės transformacijos yra dviejų tipų - nuolatinė ir diskrečioji. Nuolatinė Vilnelės transformacija yra apibrėžiama:

$$T(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt. \quad (2.1)$$

Tuo tarpu, diskrečioji Vilnelės transformacija yra aprašoma taip:

$$T_{m,n} = \int_{-\infty}^{\infty} x(t) \psi_{m,n}(t) dt. \quad (2.2)$$

Pagrindinis skirtumas tarp šių dviejų transformacijų tipų yra tai, kad nuolatinė Vilnelės trans-

formacija naudoja visas įmanomas vilneles įvairiose skalėse ir vietose, o diskrečioji Vilnelės transformacija naudoja baigtinį vilnelių rinkinį, apibrėžtą tam tikrame skalių ir vietų rinkinyje.

Vieni iš pagrindinių Vilnelės transformacijų pranašumų yra, jog Vilnelės transformacija vienu metu gali išgauti tiek vietinę spektrinę, tiek laiko informaciją bei turi galimybę rinktis iš daugybės vilnelių tipų.

2.1.2. Nuolatinė Vilnelės transformacija

Nuolatinė Vilnelės transformacija (CWT) yra laiko ir dažnio analizės metodas, kuris leidžia nustatyti aukšto dažnio signalo ypatybes. Ši transformacija taiko skirtingus langų pločius, kuris susijęs su stebėjimo skalėmis. Praktiškai, CWT yra apskaičiuojama per diskretuotą laiko dažnių tinklėlį, kuris apima transformacijos integralo aproksimavimą, apskaičiuotą diskrečioje skalių a ir b pozicijų tinklelio laiko ašyje. Vilnelės transformacija apskaičiuojama kiekviename laiko žingsnyje įvairioms vilnelių skalėms [29].

CWT lygina signalą su paslinktomis ir suspaustomis arba ištemptomis vilnelės versijomis. Funkcijos ištempimas arba suspaudimas bendrai vadinamas išsiplėtimu arba mastelio keitimu ir atitinka fizinę mastelio sąvoką. Palyginus signalą su vilnele įvairiose skalėse ir padėtyse, gaunama dviejų kintamųjų funkcija. Jei vilnelė yra kompleksinės vertės, nuolatinė Vilnelės transformacija yra sudėtingos vertės skalės ir padėties funkcija. Jei signalas yra tikrosios vertės, ši transformacija yra tikrosios vertės skalės ir padėties funkcija. Ne tik skalės ir padėties reikšmės turi įtakos CWT koeficientams, bet vilnelės pasirinkimas taip pat turi įtakos koeficientų reikšmėms.

Yra daug skirtingų leistinių vilnelių, kurias galima naudoti CWT. Nors gali atrodyti painu, kad yra tiek daug galimybių analizuoti vilneles, tačiau iš tikrųjų tai yra signalo analizės privalumas. Priklausomai nuo to, kokias signalo ypatybes bandoma aptikti, galima laisvai pasirinkti vilnelę, kuri palengvina šios funkcijos aptikimą. Pavyzdžiui, jei bandoma aptikti staigius signalo nutrūkimus, galima pasirinkti vieną vilnelę. Kita vertus, gilinamasi į svyravimus galima laisvai pasirinkti vilnelę, kuri labiau atitinka tą elgesį.

2.1.3. Diskrečioji Vilnelės transformacija


Diskrečioji vilnelės transformacija (DWT) kur kas efektyviau pašalina nereikalingą perteklių nei CWT. DWT suteikia pakankamai informacijos tiek pradinio signalo analizei, tiek informacijos gavimui. Ji yra lengvai įdiegiama, sumažina skaičiavimo laiką bei reikalingus išteklius. Ši transformacija yra taikoma atskiriems duomenų rinkiniams - suskaido signalą į dalis, kas yra pagrindinis skirtumas tarp nuolatinės ir diskrečiosios vilnelių transformacijų [20].

Atliekant vilnelės analizę, diskrečioji Vilnelės transformacija suskaido signalą į abipusiai stačiakampių vilnelių bazinių funkcijų rinkinį. Šios funkcijos skiriasi nuo sinusoidinių bazinių funkcijų tuo, kad jos yra lokalizuotos erdvėje – tai yra, nulinės tik dalyje viso signalo ilgio. Be to, vilnelės funkcijos yra bendros funkcijos, žinomos kaip pagrindinė vilnelė, išplėstos, išverstos ir pakeistos masteliu.

Dažniausiai DWT yra įgyvendinamas pasitelkiant filtrų rinkiniu, kuris atskiria pradinį signalą į kelis komponentus. Tai yra efektyvus būdas padalinti signalą į kelias dažnių dalis. Du labiausiai paplitę yra *Haar* ir *Daubechies* vilnelių rinkiniai.

Norint pritaikyti diskrečiąją Vilnelės transformaciją signalui, pirmiausia yra analizuojamas aukšto dažnio elgesys. Antrame etape skalė padidėja du kartus ir tuomet yra analizuojamas per pusę didžiausio dažnio elgesys. Trečiame etape - analizuojamas ketvirtadalis didžiausio dažnio

elgesys. Su kiekvienu etapu signalo elgesys yra analizuojama iki kol pasiekiamas maksimalus skilimo lygis.



5 pav. Aproksimacijos ir detalūs koeficientai.

5 paveikslėlyje galima matyti du rinkinius, kuriuos gražina diskrečioji Vilnelės transformacija. Aproksimacijos koeficientai parodo žemo dažnio filtro rezultatą. Tuo tarpu, detalūs koeficientai nurodo aukšto dažnio filtro rezultatą. Kituose lygiuose taikant šią transformaciją, gaunama kito lygio vilnelės transformacija. Kaip minėta anksčiau, kiekviename lygyje pradinis signalas yra sumažinamas du kartus - sekančiame lygyje aproksimavimo koeficientai padalijami į didesnę žemo dažnio ir aukšto dažnio dalis, o žemųjų dažnių daliai taikoma DWT.

2.1.4. Vilnelių tipai

Vienas iš skirtumų, kuo skiriasi Furje ir Vilnelės transformacijos yra tas, kad Vilnelės transformacija turi daug skirtingų tipų. Kiekvienas Vilnelės tipas turi skirtingą formą, lygumą bei kompaktiškumą bei yra naudojamas skirtingiems tikslams įgyvendinti. Vilnelė turi tenkinti dvi matematinės sąlygas - normalizavimo bei ortogonalizacijos - tad bet kada galima sukurti naują vilnelės tipą.

Vilnelės tipo pasirinkimą lemia signalo charakteristika ir norimas taikymo pobūdis. Kiekviena vilnelė skiriasi sau būdingomis savybėmis:

- *Haar* - viena iš paprasčiausių vilnelių, kuri yra nenutrūkstama ir primena žingsnio funkciją. Ši vilnelė yra veiksminga tokiose programose kaip signalų ir vaizdo glaudinimas elektros ir kompiuterių inžinerijoje, nes suteikia paprastą ir skaičiavimo požiūriu efektyvų metodą vietiniams signalo aspektams analizuoti;

- *Daubechies* - yra stačiakampių vilnelių šeima, apibrėžianti diskrečią vilnelės transformaciją ir kuriai būdingas maksimalus išnykimo momentų skaičius tam tikrai atramai;
- *Biorthogonal* - tai vilnelės, su kuria susijusi vilnelės transformacija yra apverčiama, bet nebūtinai stačiakampė. Biortogoninių vilnelių projektavimas suteikia daugiau laisvės nei stačiakampių bangelių. Vienas papildomas laisvės laipsnis yra galimybė sukurti simetriškas vilnelės funkcijas;
- *Coiflets* - tai vilnelės tipas turintis mastelio keitimo funkcijas su nykstančiais momentais. Vilnelė yra beveik simetriška, jų funkcijos turi išnykimo momentus ir mastelio keitimo funkcijas;
- *Symlets* - vilnelė, kuri žinoma kaip mažiausiai asimetrinė vilnelė, apibrėžianti stačiakampių vilnelių šeimą;
- *Morlet* - vilnelė, sudaryta iš kompleksinės eksponentės. Ši vilnelė yra susijusi su žmogaus klausa bei rega;
- *Mexican Hat* - viena iš pagrindinių vilnelės funkcijų, suformuluota remiantis Gauso funkcija;
- *Meyer* - viena iš stačiakampės vilnelių tipo, kuris gali būti taikomas adaptyviems filtrams, atsitiktiniams fraktaliniams laukams ar kelių gedimų klasifikacijai.

2.2. Furje transformacija

Furje transformacija - tai matematinė funkcija, kuri paverčia laiko funkciją į dažnio funkciją. Ši transformacija yra taikoma bangoms, suskaidydama jos formą į sinusoidinę. Furje transformacijos rezultatas yra dažnio funkcija. Furje transformacijos absoliuti vertė parodo dažnio reikšmę, esančią pradinėje funkcijoje, o jos sudėtinis argumentas – pagrindinės sinusinės formos fazės poslinkį tame dažnyje.

Furje transformacija dar vadinama Furje skleidiniu [21]. Šis terminas gali būti taikomas tiek dažnio srities vaizdavimui, tiek matematinėms funkcijoms. Furje transformacija padeda išplėsti Furje seriją iki neperiodinių funkcijų, o tai leidžia peržiūrėti bet kurią funkciją kaip paprastų sinusoidų sumą.

Furje transformacijos funkcija yra apibrėžiama:

$$f(x) = \int_{-\infty}^{\infty} F(k)e^{2\pi i k x} dk. \quad (2.3)$$

$$F(k) = \int_{-\infty}^{\infty} f(x)e^{-2\pi i k x} dx, \quad (2.4)$$

kur $F(k)$ yra apskaičiuojama naudojant atvirkštinę Furje transformaciją.

2.2.1. Diskrečioji Furje transformacija

Diskrečioji Furje transformacija (DFT) yra viena iš galingiausių skaitmeninio signalo apdorojimo įrankių, kuris leidžia rasti baigtinės trukmės signalo spektrą. Pirmiausia, DFT leidžia apskaičiuoti signalo dažnių spektrą, kuris padeda gauti informaciją, kuri yra užkoduota komponentinių sinusoidų dažnyje, fazėje bei amplitudėje. Taip pat, ši transformacija gali rasti sistemos dažnio atsaką pagal sistemos impulsinį atsaką ir atvirkščiai. Tai leidžia analizuoti sistemas dažnio srityje. Diskrečioji Furje transformacija gali būti naudojama kaip tarpinis žingsnis sudėtinguose signalų apdorojimo metoduose [26]. Naudojant Diskrečiąją Furje transformaciją, ji transformuoja bangos formos ciklo struktūrą į sinusinius komponentus:

$$X_k = \sum_{n=0}^{N-1} x_n \cdot e^{-i2\pi kn/N}, \quad (2.5)$$

kai N - signalo ilgis; x_n - signalo vertė laiko momentu n ; $k = 0, 1, \dots, N-1$; $n = 0, 1, \dots, N-1$.

2.2.2. Greitoji Furje transformacija

Greitoji Furje transformacija (FFT) – algoritmas, leidžiantis apskaičiuoti tam tikros sekos diskrečiąją Furje transformaciją, kuri yra skirta konkrečių tipų funkcijų sekoms paversti kitų tipų vaizdiniais. Greitoji Furje transformacija gali būti naudojama įvairių tipų signalų apdorojimui. Tai gali būti naudinga skaitant tokius dalykus kaip garso bangos arba naudojant bet kokias vaizdo apdorojimo technologijas. FFT gali būti naudojama įvairių tipų lygtims išspręsti arba naudingais būdais parodyti įvairių tipų dažnio aktyvumą.

Laikas, kurio reikia norint įvertinti DFT skaitmeniniame kompiuteryje daugiausia priklauso nuo operacijų skaičiaus. Naudojant DFT, šis skaičius yra tiesiogiai susijęs su transformacijos ilgiu. Daugeliui problemų pasirenkama bent 256, kad būtų gautas pagrįstas nagrinėjamos sekos spektro aproksimavimas, todėl skaičiavimo greitis tampa pagrindiniu aspektu [24]. Būtent todėl greitoji Furje transformacija (FFT) naudoja išraiškoje 2.5 harmonikų periodiškumo savybes, norint išvengti nereikalingų skaičiavimų.

$$X_k = \sum_{n=0}^{N-1} x_n + W_N^{kn} \quad (2.6)$$

Iš 2.6 išraiškos galima suprasti, jog W_N^{kn} reikšmės yra skaičiuojamos daug kartų. Abu minėti algortimai duoda vienodus rezultatus, tačiau realiuose skaičiavimuose, FFT randa tikslesnį signalo spektrą - algoritmas vykdo mažiau skaičiavimų, todėl ir paklaidų pasireiškia mažiau [21].

3. Pikų aptikimo algoritmas

Epileptoforminių pikų detekcijai buvo pasirinktas algoritmas, kuris pasižymi morfologinėmis operacijomis bei filtrais. Pirmiausia, morfologinių operacijų metu yra filtruojama smegenų foninė veikla, kuri iš pirminio EEG signalo išskiria foninį smegenų aktyvumą. Taip pat, trumpalaikiai signalai, įskaitant ir pikus, yra gaunami iš EEG atėmus foninį aktyvumą. Galiausiai, epileptoforminiai pikai yra aptinkami pagal iš anksto numatytą slenkstinį kriterijų. Šis pikų aptikimo algoritmas

pasizymi aukštu tikslumu - 91.62% [28].

3.1. Morfoliginės operacijos

Vienos iš pagrindinių morfoliginų operacijų, kurios yra naudojamos pikų aptikimo algoritmui, yra morfoliginis susiaurinimas bei morfoliginis išplėtimas.


Tiriamas EEG signalas yra aprašomas kaip laiko eilutė $f(t)$, struktūrinis elementas - $g(t)$, struktūrinio elemento atspindys $g^s(t) = g(-t)$, kur D - $f(t)$ apibrėžimo sritis.

Morfoliginis susiaurinimas yra aprašomas formule:

$$(f \ominus g^s)(t) = \min_{\tau \in D} \{f(\tau) - g(-(t - \tau))\}. \quad (3.1)$$

Tuo tarpu, morfoliginis išplėtimas yra aprašomas formule:

$$(f \oplus g^s)(t) = \min_{\tau \in D} \{f(\tau) + g(-(t - \tau))\}. \quad (3.2)$$



6 pav. Morfoliginio susiaurinimo bei išplėtimo pritaikymas elektroencefalogramos signalui.

6 paveikslėlyje pavaizduotas originalus elektroencefalogramos signalas, kuriam buvo atliktos morfoliginės operacijos - susiaurinimas bei išplėtimas. Morfoliginės operacijos buvo atliktos su parabolės formos struktūriniu elementu, kuris buvo sudarytas iš 17 taškų. Morfoliginio susiaurinimo metu, struktūriniu elementu yra einama per signalą ir yra ieškoma minimali reikšmė. Pritaikyta parabolės buvo neaukšta, tačiau plati, tad po morfoliginio susiaurinimo signalai matomi pikai ne tokie aštrūs.

Žinant aukščiau nurodytus morfoliginio susiaurinimo bei išplėtimo apibrėžimus, galima išvesti signalo bei jo struktūrinio elemento išraiškas, apibrėžiamas kaip morfoliginio uždarymo ir morfoliginio atidarymo operacijas.

Morfoliginio atidarymo operacija:

$$(f \circ g)(t) = [(f \ominus g^s) \oplus g](t). \quad (3.3)$$

Morfoliginio uždarymo operacija:

$$(f \bullet g)(t) = [(f \oplus g^s) \ominus g](t). \quad (3.4)$$

Epileptoforminiai pikai gali turėti tiek teigiamą, tačiau ir tiek pat neigiamą amplitudes. Morfologinis atidarymas signalo pikus suapvalina iš apačios, o morfologinis uždarymas pakelia signalo reikšmes. Kadangi morfologinis atidarymas ir uždarymas aptinka tik teigiamos arba neigiamos reikšmės pikus, yra reikalingas papildomų morfologinių operacijų apibrėžimas. Papildomos operacijos išryškintų teigiamo ar neigiamo ženklo amplitudės pikus.

Morfologinis uždarymas - atidarymas:


$$CO(f(t)) = f(t) \bullet g_1(t) \circ g_2(t). \quad (3.5)$$

Morfologinis atidarymas - uždarymas:

$$CO(f(t)) = f(t) \circ g_1(t) \bullet g_2(t). \quad (3.6)$$

Šiose 3.5 ir 3.6 apibrėžtose morfologinėse operacijose $g_1(t)$ ir $g_2(t)$ pateikiami kaip struktūriniai elementai. Atidarymo - uždarymo operacija pakelia vidutinę signalo reikšmę, tuo tarpu uždarymo - atidarymo operacija sumažina vidutines signalo reikšmes. Tačiau tokia deformacija gali sukelti neatitikimų norint aptikti pikus, todėl reikia apibrėžti dar vieną kombinuotą morfologinę operaciją, kuria naudojantis foninis smegenų aktyvumas yra nufiltruojamas išryškindamas pikus:

$$OCCO(f(t)) = (OC(f(t)) + CO(f(t)))/2. \quad (3.7)$$



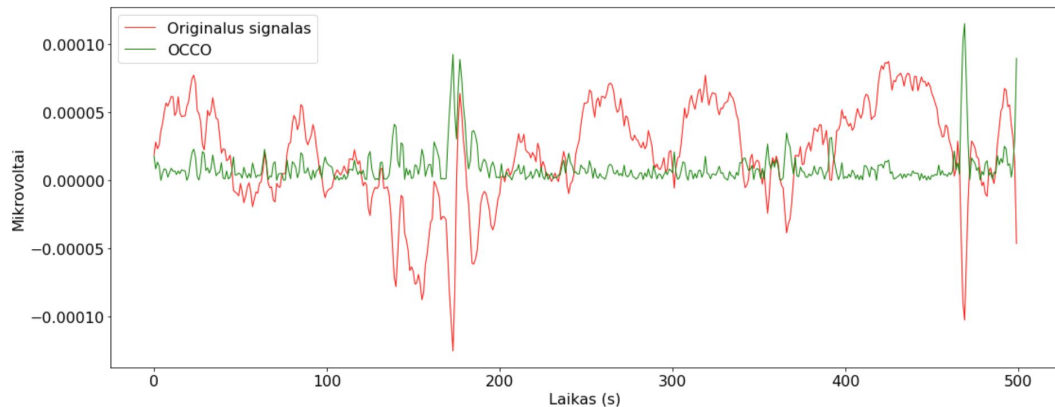
7 pav. Morfologinio uždarymo - atidarymo bei atidarymo - uždarymo pritaikymas elektroencefalogramos signalui.

7 paveikslėlyje pavaizduotas originalus elektroencefalogramos signalas bei pritaikytos atidarymo - uždarymo ir uždarymo - atidarymo morfologinės operacijos.

Pritaikius 3.7 išraiškoje apibrėžtą morfologinį filtrą, gaunamas signalas, kurį galima išreikšti formule [16, 22]:

$$x(t) = |f(t) - OCCO(f(t))|, \quad (3.8)$$

kuriame foninis smegenų aktyvumas yra nufiltruojamas ir pikai išryškunami.



8 pav. Originalus elektronecefalogramos signalas bei EEG signalas, kuriam pritaikytas OCCO filtras.

Štai 8 paveikslėlyje pavaizduotas originalus EEG signalas bei jam pritaikyto OCCO operacijų galutinis rezultatas, kuris buvo aprašytas 3.8 išraiškoje. Šiame paveikslėlyje yra pateiktas ne galutinis signalas, tačiau jo modulis. Būtent šiuo atveju yra gaunamos teigiamos reikšmės, kurios padeda atpažinti pikus, nes jie gali būti tiek teigiami tiek neigiami. Todėl norint rasti pikus, yra naudinga turėti teigiamų ir neigiamų reikšmių signalą, nes detekcijos ribos reikės tik vienos.

3.2. Struktūriniai elementai

Morfologiniai filtrai dažniausiai yra taikomi norint apdoroti skaitmeninius vaizdus. Būtent todėl struktūriniais elementais yra pasirenkami įvairių formų objektais. Šio darbo atveju, elektroencefalogramoms apdoroti, struktūrinius elementus reikia pasirinkti toius, kad taikant morfologinius filtras, foninis smegenų aktyvumas būtų nufiltruojamas taio, kad epileptoforminiai pikai būtų išryškinti. Foninę smegenų veiklą aprašo parabolė:

$$g_i(t) = a_i * t^2 + b_i, i = 1, 2 \quad (3.9)$$

Norint geriausiai nufiltruoti foninę smegenų aktyvumą, reikia pasirinkti teisingą struktūrinį elementą. Kadangi EEG signalo parabolinių amplitudžių aukščiai bei dažniai skiriasi kiekvienoje laiko atkarpoje, todėl a ir b koeficientai kinta atsižvelgiant į foninę smegenų veiklą. Norint optimaliai parinkti atitinkamus koeficientus, reikia apskaičiuoti signalo arkų pločius W bei jų ilgius $|f|$ [22]. W nurodo ilgį tarp dviejų gretimų signalo minimumų arba maksimumų, o $|f|$ - signalų aukščių amplitudes. Apskaičiavus W ir $|f|$, galima apibrėžti konstantas a ir b :

$$a_{1,2} = \frac{\text{median}(|f|)}{k * \text{median}(W)}, k = 0.5, 1.5 \quad (3.10)$$

$$b_{1,2} = \text{median}(|f|) \quad (3.11)$$


Apskaičiavus šias konstantas, yra gaunamos dvi parabolės - vienodo pločio, bet skirtingų aukščių. Struktūriniai elementai yra naudojami filtruojant signalą - morfologinėms operacijoms, parabolėlių filtravimui. Aukščių skirtumas tarp apskaičiuotų struktūrinių elementų išryškina epileptiforminius pikus.

3.3. Pikų atpažinimas

3.3.1. Signalo atkarpos ilgis

Kadangi smegenų aktyvumas nuolat kinta, struktūrinis elementas turi būti nuolat perskaičiuojamas. Norint signalo analizei rasti tinkamą atkarpos ilgį nėra taip lengva, kadangi signalo atkarpos trukmė turi būti pakankamai ilgai, bet kartu ir ne per trumpa, jog būtų galima aptikti piką, tačiau kartu smegenų veikloje vyraujantys ritmai nepakistų. Vienas iš optimalių EEG ilgio pasirinkimų yra 4 ir 6 sekundžių EEG atkarpa.

Taip pat, galima paminėti, jog minėtoji atkarpa yra optimali ir dėl kitų priežasčių. EEG tyrimo metu, gali pasikeisti paciento galvos odos laidumas dėl įvairių faktorių, kas gali apsunkinti tyrimą norint nufiltruoti tam tikrus artefaktus [23].



9 pav. Originalus signalas bei jam pritaikytos morfologinės operacijos

9 paveikslėlyje pavaizduotas morfologinių operacijų veikimas. Morfologinės operacijos buvo pritaikytos 5 sekundžių originaliam elektroencefalogramos signalui.

3.3.2. Pikų detekcijos riba

Kadangi kiekvienas signalas pasižymi skirtingomis savybėmis, artefaktais, pikų detekcija kiekvienam pacientui irgi yra skirtinga. Pikų detekcijos riba nurodo reikšmę, virš kurios signalo reikšmės yra laikomos epileptiforminiais pikais. Šią ribą galima aprašyti formule:

$$L = d * \text{median}|extrema(x(t))|, \quad (3.12)$$

kur $x(t)$ yra nufiltruotas signalas (3.8 išraiška), o d - detekcijos ribos koeficientas. Jei detekcijos ribos koeficientas bus per didelis, daugelis pikų būtų tiesiog neaptinkami. Jei per mažas - pikai būtų aptinkami tose vietose, kur jų net neturėtų būti, tad tokiu atveju atsiranda tikimybė, jog pastebėti signalo triukšmai ar artefaktai bus pažymėti kaip pikai. Detekcijos ribos koeficientas kiekvienam pacientui yra skirtingas, tačiau yra nustatyta, kad šis koeficientas svyruoja nuo 6 iki 12, nors literatūroje galima rasti detekcijos ribos koeficientą prilygintą 8 [16].

3.3.3. Struktūrinio elemento ilgis

Struktūrinio elemento ilgis - parabolę sudarančių taškų skaičius. Kaip jau buvo minėta anksčiau, struktūrinis elementas kinta, jei yra keičiami a ir b parametrai, kurie buvo išreikšti 3.10 ir 3.11 išraiškose. Šie koeficientai nedaro didelės įtakos parabolės pločiui, tad optimalus struktūrinio elemento plotis gali būti apibrėžiamas formule:

$$S_L = 4 * median|W| \quad (3.13)$$

S_L nurodo, jog optimaliu atveju parabolė turėtų būti 4 kartus platesnė, nei EEG signalo parabolė arkų pločių mediana. Jei struktūrinis elementas yra per ilgas, parabolė bus per plati, foninė smegenų veikla gali būti tinkamai nenufiltruota, neišryškinti pikai, palikti artefaktai. Jei per trumpas ir parabolė per siaura - foninis smegenų aktyvumas bei pikai gali būti nufiltruoti.

4. Praktinė darbo dalis

4.1. Duomenys

Šiame darbe buvo naudojami duomenys iš Vaikų ligoninės, VšĮ Vilniaus universiteto ligoninės Santaros klinikų filialo. Turimuose duomenyse buvo nurodoma, jog pacientai sirgo Rolando arba įvairių fizinių smegenų pažeidimų (pvz. cerebrinio paralyžiaus) sukelta epilepsija. Duomenys buvo pateikti EDF failo formatu.

Duomenyse buvo pateikiami pacientų EDF failai su gydytojo nustatyta diagnoze bei pikų kanalu. Kiekvienas failas turėjo 21 ar net ir daugiau EEG kanalų. Failuose taip pat buvo pateikta diskretizavimo dažnio, signalų laiko, kanalų pavadinimų informacija.

Europos duomenų formatas

Europos duomenų formatas (EDF) - standartinis failo formatas, suprojektuotas keisti bei saugoti daug kanalų turinčius biologinius ir fizinius signalus [2]. EDF yra pripažintas standartas keistis elektroencefalogramų ir polisomnogramų duomenimis tarp skirtingų įrenginių ir laboratorijų.

Standartinį EDF failą sudaro antraštė bei duomenų įrašai. Antraštė identifikuoja pacientą ir nuorodo technines įrašytų signalų charakteristikas, kuriose pateikiamos fiksuotos trukmės įrašytų signalų epochos. Standartinį EDF+ failą taip pat sudaro antraštė bei duomenų įrašai, tačiau EDF+ turi papildomų specifikacijų [19].

EDF+ antraštė

EDF+ antraštė identifikuoja pacientą ir nurodo įrašytų signalų technines charakteristikas remiantis EDF specifikacijomis, išskyrus pirmuosius 44 simbolius, kurie turi prasidėti *EDF+ C*, jei įrašas nebuvo nutrauktas, bei gretimus duomenų įrašus - kiekvieno duomenų įrašo pradžios laikas sutampa su ankstesniojo įrašo pabaiga. Jei įrašas buvo sutrikdytas, antraštė turi prasidėti *EDF+ D*, todėl ne visi duomenų įrašai yra gretimi. Abiem atvejais laikas turi būti saugojamas kiekviename įrašė.

Vienintelis skirtumas tarp EDF ir EDF+ yra tas, jog EDF signalai gali būti įrašomi nepertraukiamai. Todėl EDF+ gali būti nurodoma 0 versija. Taip nuspręsta, jog naudojantis tokiu būdu esamos EDF peržiūros priemonės toliau veiks bei rodys EDF failus. Tuo tarpu, EDF+ programinė įranga atpažins skirtumą tarp nenutrūkstamų ir nutrūkstamų failų iš antraštės pirmųjų 44 simbolių.

EDF+ duomenų įrašai

Signalas EDF duomenų įrašė yra 2 baitų pavyzdžių serija, o tolimesnės reikšmės nurodo to signalo sveikąsias reikšmes, kurios buvo užfiksuotos vienodais laiko intervalais. Tokį signalą galima pavadinti įprastu signalu. Įprasti signalai duomenų įrašuose yra pateikiami pagal EDF specifikacijas. Įprasto signalo imtys turi turėti vienodus laiko intervalus kiekviename įrašė, bet laiko intervalas iki kito duomenų įrašo pradžios gali skirtis.

4.2. Programavimo kalbos pasirinkimas

Elektroencefalogramų analizė buvo įgyvendinta Python (3.9.0) atvirojo kodo programavimo kalba. Ši programavimo kalba buvo pasirinkta dėl itin plataus bibliotekų pasirinkimo bei sintaksės paprastumo. Naudojant Python programavimo kalbą, triukšmo šalinimo bei morfologinių operacijų įgyvendinimas yra kur kas paprastesnis, nes neapkrauna kodo įvairiais rankiniais skaičiavimais ir yra lengviau skaitomas bei suprantamas naudotojui.

4.3. Naudotos bibliotekos

NumPy

NumPy yra viena iš pagrindinių *Python* statistinių skaičiavimų ir darbo su duomenų masyvais optimizuojanti biblioteka. Ši biblioteka leidžia dirbti su daugiamačiais duomenų masyvo objektais, matricomis, greitomis masyvų operacijomis, matematinėmis bei loginėmis funkcijomis, rūšiavimu, Furje transformacijomis bei kt. [6]

Matplotlib

Matplotlib yra *Python* programavimo kalbos ir *NumPy* plėtinio biblioteka. Ši biblioteka skirta kurti statines, animacines bei interaktyvias vizualizacijas [4].

Math

Math biblioteka suteikia prieigą prie C standarto apibrėžtų matematinių funkcijų ir konstantų, kurias galima naudoti norint atlikti sudėtingesnius matematinius skaičiavimus [3].

MNE-Python

MNE-Python programinė įranga yra atvirojo kodo *Python* paketas, skirtas tirti, vizualizuoti ir analizuoti žmogaus neurofiziologinius duomenis - MEG, EEG, sEEG, ECoG ir kt. Tai apima duomenų įvesties/išvesties, išankstinio apdorojimo, vizualizavimo, šaltinio įvertinimo, laiko ir dažnio analizės, ryšio analizės, mašininio mokymosi ir statistikos modulius. *MNE-Python* duomenų struktūros yra pagrįstos FIF failo formatu, tačiau yra skaitymo funkcijų, skirtų ir kitiems duomenų formatams. Ši biblioteka turi sąsajų su įvairiais viešai prieinamais duomenų rinkiniais [5].

PyWavelets

PyWavelets yra atvirojo kodo vilnelės transformacijos programinė įranga, kuri sujungia paprastą aukšto lygio sąsają su žemo lygio atlikimu. Bangos yra pagrindinės matematinės funkcijos, kurios yra lokalizuotos tiek laiko, tiek dažnio atžvilgiu. Vilnelės transformacijos yra laiko ir dažnio transformacijos, naudojant bangas. Jos yra panašios į Furje transformacijas, tačiau skiriasi tuo, kad Furje transformacijos yra lokalizuotos tik pagal dažnį, o ne pagal laiką ir dažnį [8].

OpenCV

OpenCV-Python yra atvirojo kodo kompiuterinės vizijos ir mašininio mokymosi programinės įrangos biblioteka, kuri buvo sukurta siekiant sukurti bendrą infrastruktūrą kompiuterinio matymo programoms ir paspartinti mašinos suvokimo naudojimą komerciniuose produktuose. Bibliotekoje yra daugiau nei 2500 optimizuotų algoritmų, apimančių išsamų klasikinių ir naujausių kompiuterinės vizijos ir mašininio mokymosi algoritmų rinkinį. Šie algoritmai gali būti naudojami aptikti ir atpažinti veidus, identifikuoti objektus, klasifikuoti žmogaus veiksmus vaizdo įrašuose, sekti kameros judesius, sekti judančius objektus, išgauti 3D objektų modelius, sukurti 3D taškų debesis iš stereo kamerų, sujungti vaizdus, kad būtų sukurta didelė raiška. *OpenCV* yra parašyta C++ ir turi šabloninę sąsają, kuri sklandžiai veikia su STL konteineriais [7].

4.4. Algoritmų taikymas


4.4.1. Greitosios Furje transformacijos taikymas

50 Hz komponentės filtravimas

Ankstesniuose skyriuose buvo aprašyti veiksniai, kurie gali turėti įtakos elektroencefalogramos signalo kokybei bei jo analizei. Triukšmą signale gali lemti įvairūs vidiniai ar išoriniai veiksniai. Vienas iš dažniausiai pasitaikančių veiksnių - elektros jautrumas elektros srovei [25]. Dėl šios kilmės artefakto yra rekomenduojama pritaikyti Furje filtrus. Elektros tinklo triukšmui naikinti turėtų būti nufiltruotas 50 Hz triukšmas, kuris šalina elektrodų jautrumo elektros srovei artefaktą.

2.2 skyriuje aprašyta greitoji Furje transformacija nėra sudėtinga, tačiau remiantis šia transformacija ir pašalinus 50 Hz elektros tinklo triukšmą, galima pamatyti skirtumą tarp filtruotų ir nefiltruotų signalo duomenų, kadangi šiuo triukšmu yra paveikiami visų kanalų duomenys.


Šia transformacija yra apdorojamos ne signalo reikšmės, o galios spektrinis tankis (PSD). 10 paveikslėlyje pavaizduotas originalus 2 sekundžių vieno iš pacientų EEG signalas.



10 pav. Originalus EEG signalas.


Šiame pavyzdyje galima atkreipti dėmesį, jog šiame signale egzistuoja 50 Hz komponentė, kuri gali turėti įtakos signalo kokybei. Reikia atkreipti dėmesį, jog ne visuose EEG signaluose galima pamatyti šią komponentę, kadangi kiekvienas elektroencefalogramos tyrimas yra atliekamas skirtingomis aplinkybėmis bei naudojant skirtingus matavimo prietaisus. Vis dėlto, neigiamos įtakos 50 Hz dažnio komponentė triukšui šalinti nepadaro, tad tolimesniuose darbo veiksmuose nuspręsta taikyti greitąją Furje transformaciją.

Toliau nagrinėjant 50 Hz dažnio komponentės triukšmą signale, galima atkreipti dėmesį į žemiau pateiktą 11 paveikslėlį, kuriame yra pavaizduotas galios spektrinis tankis signalui apžvelgtam 10 paveikslėlyje. Šiame paveikslėlyje atvaizduota to paties originalaus signalo priklausomybė dažnio srityje bei nufiltruota 50 Hz dažnio komponentė.



11 pav. Galios spektrinis tankis (PSD).

Pašalinus 50 Hz dažnio komponentę iš originalaus signalo, didelio įtakos originaliam signalui nepadaro - tai pavaizduota 12 paveikslėlyje. Tikėtina, jog taip nutiko, nes EEG prietaisas, kuriuo buvo atlikti matavimai, buvo aukšto tikslumo bei nesukėlė artefaktų, kurie turėtų įtakos signalo kokybei.




12 pav. Originalus bei nufiltruotas signalas Furje filtru.

Siekiant efektyvaus algoritmo veikimo, greitoji Furje transformacija buvo įgyvendinta naudojantis Python biblioteka NumPy, kuri buvo aprašyta 4.3 skyrelyje. Originalaus signalo reikšmės programavimo aplinkoje buvo transformuojamos Furje koeficientus, juos pakeičiant į atitinkamus dažnius. Radus 50 Hz dažnio komponentės elementą, jis buvo prilygintas nuliui. Tuomet naudojant atvirkštinę Furje transformaciją likusios signalo reikšmės buvo transformuojamos atgal į nufiltruotą signalą.

Tad galima teigti, jog nufiltravus 50 Hz komponentę, ji neduoda didelės įtakos signalo analizei, tačiau bet kuriuo atveju, jei duomenys būtų prastesnės kokybės, šios komponentės filtravimas būtų naudingas.


Kitų komponentių filtravimas

Elektroencefalogramose dažnai galima sutikti ir kitokių pašalinių veiksnių - paciento mirkčiojimas, staigūs judesiai, prakaitavimas ar kvėpavimas. Pavyzdžiui, kvėpavimas signale pasireiškia 0.5 Hz komponente.




13 pav. Originalus EEG signalas.

Štai 13 paveikslėlyje pavaizduotas 4 sekundžių vieno iš kanalų signalo atkarpa. Šiai signalo atkarpai buvo pritaikytas komponentių iki 0.5 Hz ir daugiau nei 100 Hz filtravimas [23]. 14 paveikslėlyje galima pamatyti galios spektrinį tankį pritaikius greitąją Furje transformaciją.



14 pav. Galios spektrinis tankis (PSD).

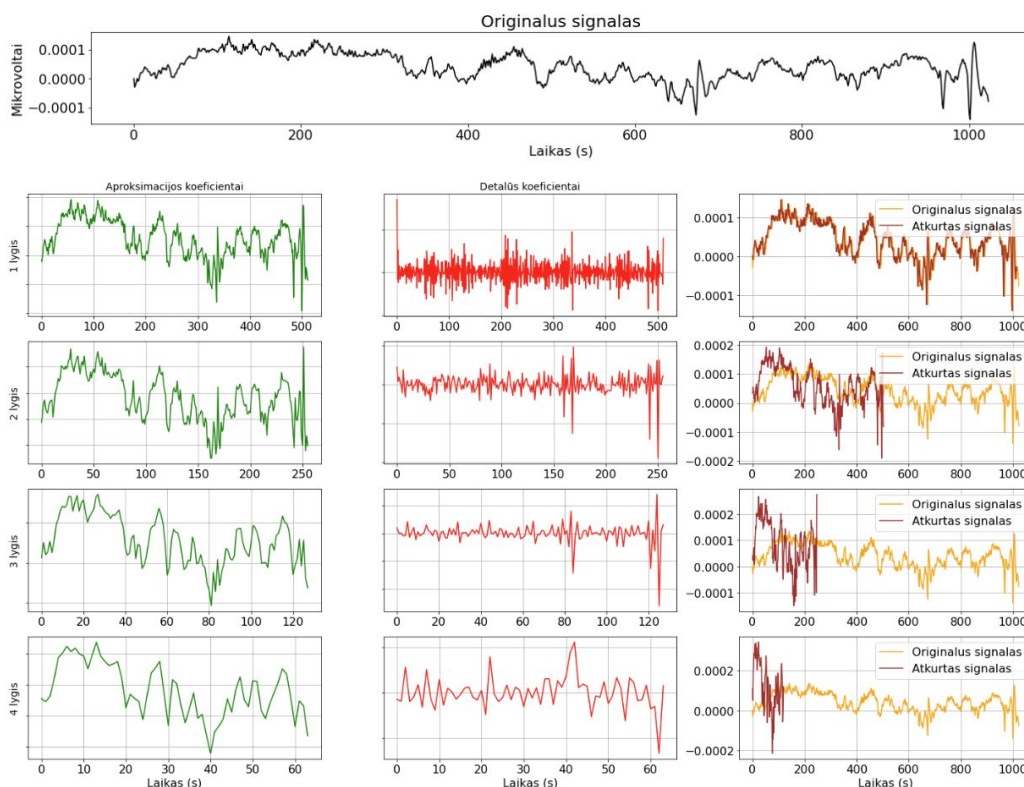
15 paveikslėlyje galima pamatyti rezultatą nufiltravus visas komponentes iki 0.5 Hz ir daugiau nei 100 Hz. Ne visose pacientų elektroencefalogramose galima pamatyti tokį ryškų signalo pasikeitimą po transformacijų panaudojimo, tačiau nevisuomet galima būti užtikrintu, kad procedūra buvo atlikta tuo pačiu prietaisu bei ar procedūroje nebuvo tam tikrų trikdžių, kurie gali turėti įtakos paciento diagnozei. Apdorojus signalą triukšmo šalinimo algoritmu, yra lengviau pamatyti tam tikras tendencijas, pikus, galima nustatyti tam tikras reikšmes, kurios gali būti naudingos vėlesnei analizei.



15 pav. Originalus bei nufiltruotas signalas Furje filtru.


4.4.2. Vilnelės transformacijos taikymas

Kita transformacija naudojama triukšmui šalinti yra Vilnelės transformacija. Šis metodas yra dažnai taikomas elektroencefalogramų signalams epileptoforminiams pikams aptikti [15]. Ankstesniame skyriuje buvo apžvelgiama, kaip aproksimacijos ir detalumo koeficientai gali būti dekonstruoti į signalą. Jei būtų norima atkurti signalą, atsižvelgiant į minėtus koeficientus, būtų gautas pradinis signalas. Būtent 16 paveikslėlyje yra pavaizduoti Vilnelės aproksimacijos ir detalumo koeficientai tam tikrame dekonstravimo lygyje. Detalumo koeficientai signale nurodo aukšto signalo dalį, tad, jei signale yra daug aukšto dažnių, vienas iš sprendimo būdų tam triukšmui nufiltruoti būtų filtruoti atitinkamą spektro dalį.




16 pav. Aproximacijos ir detalumo koeficientai bei atkurti signalai.

Viena iš efektyviausių Vilnelės transformacijų elektroencefalogramų signalų triukšmui šalinti yra *Daubechies* vilnelės šeima [9, 17]. Štai 17 paveikslėlyje pavaizduotos pritaikytos *Daubechies* vilnelės transformacijos dviems elektroencefalogramos signalo kanalams *T3-RF* ir *C3-RF*. Šiems kanalams buvo pritaikyta *db2*, *db4*, *db20* transformacijos. Iš paveikslėlio galima pamatyti, jog šios transformacijos triukšmą nufiltruoja panašiai, tačiau lyginant rezultatus tolimesniam analizės darbui būtų galima naudoti *db20* vilnelės transformaciją.



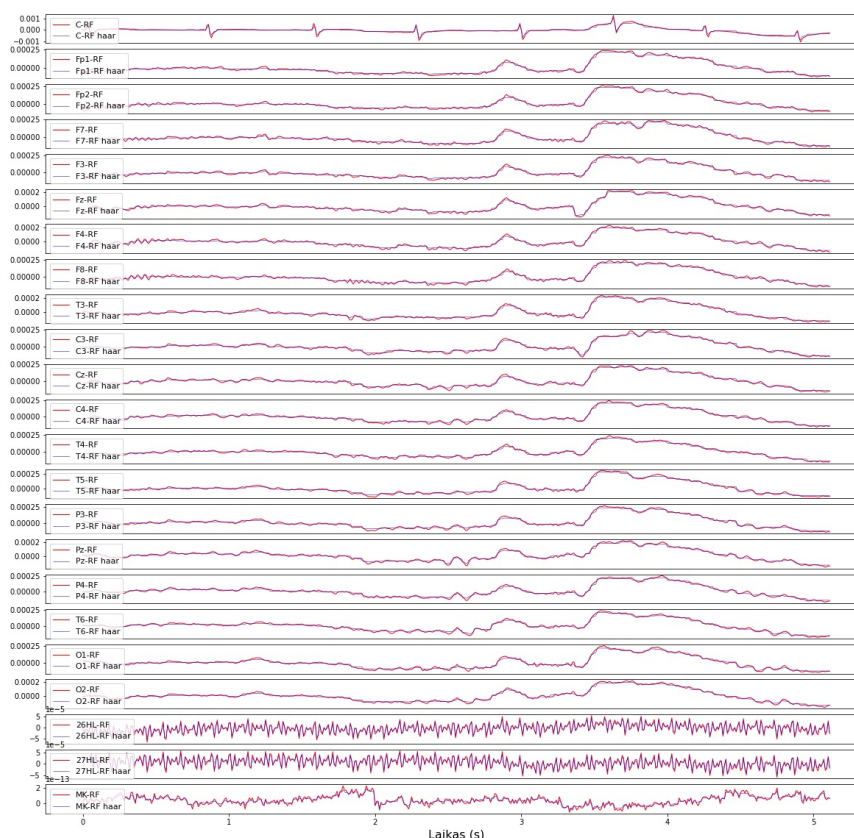
17 pav. Elektroencefalogramos signalui pritaikytos *Daubechies* vilnelės šeimos transformacijos.

18 paveikslėlyje yra pavaizduotas originalaus EEG signalo kanalų duomenys, kuriems pritaikyta *db20* vilnelės transformacija. Slenkstinė vertė (angl. *threshold*) šiai transformacijai buvo pasirinkta 0.1. Ši transformacija buvo taikoma visiems elektroencefalogramos kanalų duomenims.



18 pav. Elektroencefalogramos signalui pritaikytos *Daubechies* vilnelės šeimos transformacijos.

2.1.3 skyriuje buvo apžvelgta jog kitas iš dažnai naudojamų Vilnelės transformacijų yra *Haar* šeimos transformacija. 19 paveikslėlyje pavaizduota *haar4* vilnelės transformacija. Slenkstinė vertė *Haar* vilnelės šeimos transformacijai buvo pasirinkta 0.1. Triukšmo šalinimas buvo atliekamas visiems elektroencefalogramos kanalų duomenims, ne tik tiems kanalams, kuriuose buvo išvelgiamas epileptoforniniai pikas.



19 pav. Elektroencefalogramos signalui pritaikytos *Haar* vilnelės šeimos transformacijos.

4.4.3. Morfologinių operacijų taikymas

Šiame poskyryje aprašomas algoritmas, kuris remiasi morfologinių filtrų teorija. Naudojant šiuos filtrus, signale yra pašalinama foninė smegenų veikla bei išryškinami pikai. Algoritmo testavimui buvo naudojami realūs pacientų duomenys. Dalis darbe naudotų EEG buvo išanalizuotos gydytojų, tad algoritmo įgyvendinimui buvo atsižvelgiama į turimus duomenis, kadangi duomenys buvo pateikti su detaliais aprašymais, kurioje signalo minutėje kiek pikų buvo aptikta gydytojų.

Struktūrinio elemento ilgis

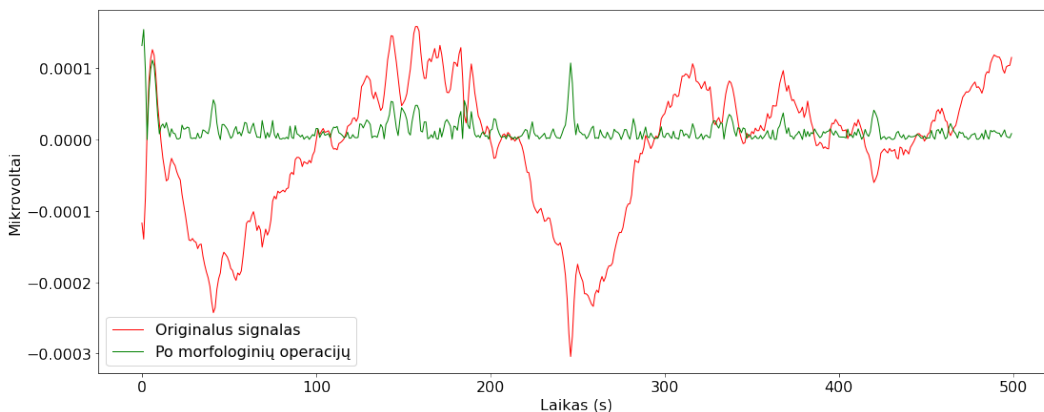
Struktūrinio elemento ilgis - parabolę, kuri buvo aprašoma 3.3.3 skyriuje, sudarančių taškų skaičius. Šiame baigiamajame darbe buvo keičiami struktūrinio elemento ilgiai ir ieškoma, koks struktūrinio elemento ilgis yra tinkamas norint rasti epileptiforminius pikus elektroencefalogramų signaluose. Optimalus struktūrinio elemento ilgis buvo:

$$S_L = 4 * median|W|. \quad (4.1)$$

Tokia 4.1 formulėje pateikta išraiška nurodo, kad parabolė turėtų būti keturis kartus platesnė

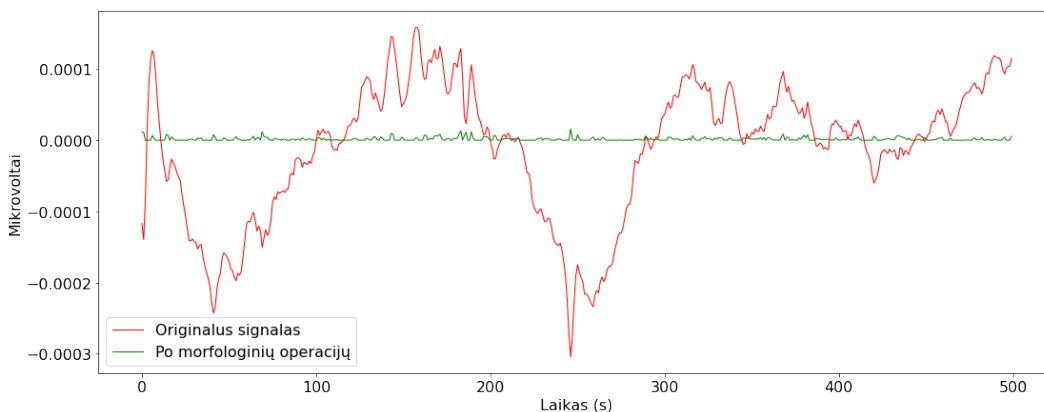
nei vidurinis encefalogramą sudarančių smegenų veiklos parbolių plotis. Analizuojant turimus duomenis buvo pastebėta, jog smegenų veiklą aprašančių parbolių pločių mediana svyravo nuo devynių iki aštuoniolikos struktūrinio elemento ilgio taškų. Kadangi piko ilgis svyruoja nuo 0.04 iki 0.2 sekundžių, tad galima teigti, jog struktūrinio elemento parabolė turėtų būti piko pločio.

Kuo struktūrinį elementą sudarys daugiau reikšmių, tuo parabolė bus platesnė, tad struktūrinio elemento ilgio pasirinkimas turi didelę įtaką EEG signalo analizei, kas buvo pastebėta lyginant morfologinių filtrų operacijas su įvairaus ilgio struktūriniais elementais. Vieną iš struktūrinio elemento ilgio pavyzdžių galima pavaizduoti 20 paveikslėlyje.




20 pav. Originalus elektronecefalogramos signalas bei nufiltruotas EEG signalas, kuriam buvo pritaikytas tinkamo ilgio struktūrinis elementas.

20 paveikslėlyje pavaizduotas optimalaus ilgio struktūrinis elementas, tačiau, jei struktūrinis elementas yra per trumpas ar per ilgas, dažniausiai nutinka taip, jog yra nufiltruojama ne tik foninė smegenų veikla, tačiau ir pikai, o per ilgo struktūrinio elemento atveju - foninė smegenų veikla nenufiltruojama bei paliekami artefaktai bei neišryškinti pikai. Per trumpo ir ilgo struktūrinių elementų pavyzdžiai pateikiami 21 ir 22 paveikslėliuose.



21 pav. Originalus elektronecefalogramos signalas bei nufiltruotas EEG signalas, kuriam buvo pritaikytas per trumpas struktūrinis elementas.



22 pav. Originalus elektronecefalogramos signalas bei nufiltruotas EEG signalas, kuriam buvo pritaikytas per ilgus struktūrinis elementas.


Struktūrinių parbolių skirtumas

3.9 formule yra aprašomos dvi parabolės g_1 ir g_2 , kurie yra naudojami morfologinėms operacijoms. Uždarymo - atidarymo bei uždarymo - atidarymo filtruose yra atliekamos morfologinės uždarymo bei atidarymo operacijos naudojant apskaičiuotus struktūrinius elementus. Parabolės g_1 ir g_2 yra tokio paties, tačiau skirtingų aukščių, kuriuos lemia koeficiento a reikšmės, kurios buvo aprašytos 3.2 skyrelyje:

$$a_1 = \frac{\text{median}(|f|)}{0.5 * \text{median}(W)}, \quad (4.2)$$

$$a_2 = \frac{\text{median}(|f|)}{1.5 * \text{median}(W)}. \quad (4.3)$$

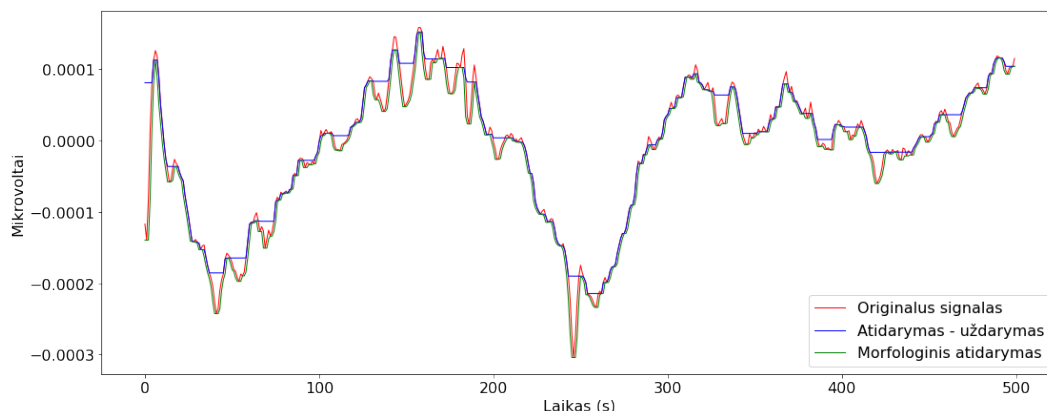
Iš 4.2 ir 4.3 išraiškų galima pastebėti, jog koeficientas a_1 yra tris kartus didesnis nei koeficientas a_2 . Šis skirtumas tarp struktūrinių elementų aukščių, išryškina epileptoforminius pikus taikant morfologines operacijas.



23 pav. Originalus elektronecefalogramos signalas, nufiltruoti EEG signalai OC filtru bei atidarymo morfologine operacija, kai struktūriniai elementai skiriasi.

23 paveikslėlyje vaizduojamas signalas po atidarymo - uždarymo morfologinio filtro, kuris

buvo pritaikytas su skirtingų aukščių struktūriniais elementais.

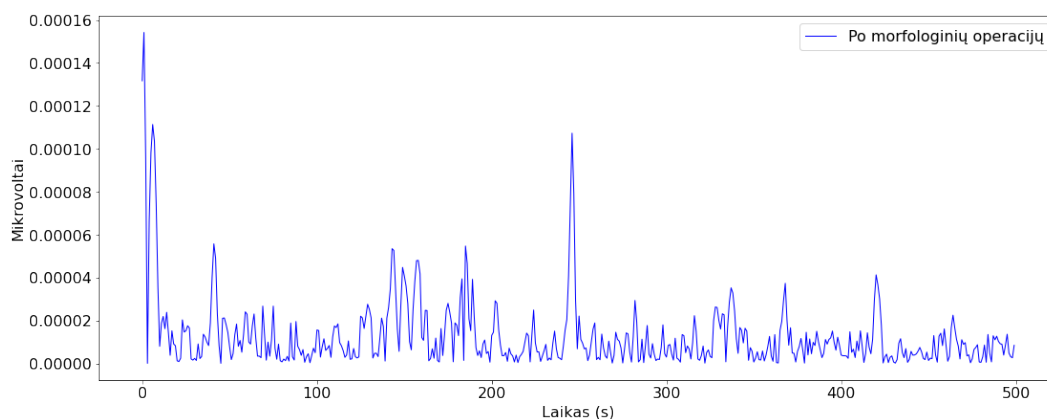


24 pav. Originalus elektronecefalogramos signalas, nufiltruoti EEG signalai OC filtru bei atidarymo morfologine operacija, kai struktūriniai elementai nesiskiria.

24 paveikslėlyje vaizduojamas signalas po atidarymo - uždarymo morfologinio filtro, kuriam buvo pritaikytas vienodo aukščio struktūriniais elementais. Galima pamatyti, jog šiuo atveju pikas yra išryškinamas kur kas labiau nei 23 paveikslėlyje. Kadangi morfologinį OC filtrą sudaro atidarymo ir uždarymo filtrai, atidarymo filtras yra pritaikomas naudojant $g1$ struktūrinį elementą, tad galima matyti, jog naudojant šią operaciją yra išryškinama signalo reikšmė, kuri gali būti panaši į piką, tačiau uždarymo filtro atveju tiek 23 pav., tiek 24 pav. buvo taikomas $g2$ struktūrinis elementas, kurio aukštis buvo vienodas, tad rezultatas yra nelabai žymus.

Pikų detekcijos riba

Kuomet yra įvykdytos visos morfologinės filtrų operacijos, apskaičiuotas galutinis signalas - skirtumas tarp originalaus signalo prieš morfologinių operacijų pritaikymą ir OCCO filtru apdorotą signalą. Gautasis signalas yra mažesnės amplitudės nei originalus signalas bei gautajame signale yra išryškinami rasti pikai.




25 pav. Originalaus elektronecefalogramos signalo, kuris buvo nufiltruotas OCCO filtru, signalų skirtumas.

25 paveikslėlyje yra pateikiamas nufiltruotas morfologinėmis operacijomis signalo modulis, kuris pateikia tik teigiamas reikšmes. Iš šio paveikslėlio galima teigti, jog vienos signalo viršūnės yra didesnės už kitas, tačiau riba, nuo kurios fiksuoti epileptoforminį piką yra neaiški.

Norint signalo reikšmę fiksuoti kaip epileptoforminį piką, galima panaudoti 3.12 formulę. Ši formulė apskaičiuoja tiesę, nuo kurios visos tiesę viršijusios signalo reikšmės, bus laikomos epileptoforminiu piku. Piko detekcijos ribai surasti reikia nufiltruoto signalo viršūnių amplitudžių vidurkio, kuris turi būti padaugintas iš detekcijos ribos koeficiento.

Testavimo metu buvo pastebėta, jog pikų detekcijos ribos koeficientas kiekvienai elektroencefalogramai yra skirtingas, tačiau pastebėta, jog ribos koeficientas būdavo skaičius tarp šešių ir dvylikos. Literatūros šaltiniuose siūloma detekcijos ribos koeficientą laikyti lygų 8 [16], nors testavimo metu pikų detekcijos koeficiento reikšmės buvo naudotos nuo 7 iki 13. Vienas iš pavyzdžių su pikų detekcijos riba pavaizduotas 26 paveikslėlyje. Originaliam elektroencefalogramos signalui buvo pritaikytas OCCO filtras ir detekcijos riba buvo prilyginta 9.0.



26 pav. Originalus elektroencefalogramos signalas, signalas nufiltruotas OCCO filtru bei detekcijos riba.

4.4.4. Rezultatų apibendrinimas

Kaip jau buvo minėta anksčiau epileptoforminių pikų detekcijos ribos nustatymas turi didelę įtaką elektroencefalogramų analizei. Jei detekcijos ribos koeficientas bus per mažas, atlikus visus algoritme numatomus žingsnius, bus detektuoti ne visi signalo pikai. Taip pat, jei riba bus per aukšta, ne visi pikai bus aptikti ir tai turės įtakos ligos diagnozei.

Šiame darbe buvo įgyvendinti trys algoritmai, kurie naudingi epileptoforminiams pikams nustatyti. Pirmieji du - Furje ir Vilnelės transformacijos buvo taikomos triukšmo šalinimui, trečiasis rėmėsi morfologinių filtrų teorija. Algoritmai buvo testuojami tomis pačiomis sąlygomis, naudojantis tuo pačiu kompiuteriu bei analizuojant tas pačias elektroencefalogramas. Algoritmai buvo suprogramuoti Python atvirojo kodo programavimo kalba.

Naudojantis greitąja Furje transformacija, kuri gali pašalinti 50 Hz triukšmą, galima palyginti skirtumą tarp filtruoto ir nefiltruoto signalo, kadangi yra paveikiami viso kanalo duomenys. Šia transformacija apdorojami ne visi signalų duomenys, tačiau galios spektrinis tankis. Vilnelės transformacija nurodo aukšto ir žemo dažnių dalis, kas padeda nufiltruoti atitinkamas spektro dalis. Morfologinės operacijos nufiltruoja foninę smegenų veiklą ir išryškina epileptoforminius pikus, pritaikius tam tikrą detekcijos ribą.

Nagrinėjant turimus pacientų elektroencefalogramų duomenis, buvo pastebėta tendencija, jog morfologiniais filtrais paremtas algoritmas aptinka daugiau pikų nei identifiko gydytojas abejais triukšmo šalinimo atvejais. Furje transformacija ir Vilnelės transformacija atitinkamai buvo atliekama visiems turimiems signalų kanalams. Tai padėjo preliminariai identifikuoti epileptoforminius pikus signalo reikšmėms dar nepritaikius morfologinių operacijų. Kadangi literatūroje

buvo pateikiama informacija, jog morfologinius filtrus reikia taikyti 4 - 6 signalo atkarpoms dėl skirtingų struktūrinių elementų, buvo pasirinkta 5 sekundžių signalo atkarpa, kuriai buvo taikytos visos anksčiau paminėtos morfologinės operacijos.

Testavimo metu buvo pastebėta jog atlikus triukšmo šalinimą Furje ar Vilnelės transformacijomis detekcijos ribos koeficientas kinta atitinkamai nuo pritaikytos triukšmo šalinimo transformacijos. Norint pritaikyti detekcijos koeficientą po atliktos Vilnelės transformacijos, detekcijos ribos koeficientas visais testavimo atvejais buvo didesnis nei po Furje triukšmo šalinimo transformacijos.

Štai 1 lentelėje pateikti skirtingų pacientų elektroencefalogramų tyrimų duomenys su skirtingais triukšmo šalinimo algoritmais bei skirtingais detekcijos ribos koeficientais. Galima atkreipti dėmesį, jog pritaikius tą patį detekcijos koeficientą d signalui, kuris buvo nufiltruotas naudojantis Furje transformacija bei Vilnelės transformacija, gauti rezultatai skiriasi, tačiau pritaikius didesnę pikų detekcijos koeficientą Vilnelės transformacijai bendras detektuotų pikų skaičius, kurį aptiko gydytojas ir kurį aptikos algoritmas, pritaikius skirtingas triukšmo šalinimo transformacijas, skiriasi nežymiai.

EEG nr. 1	1 min	2 min	3 min	4 min	5 min	6 min	7 min	8 min
Gydytojo nurodytas pikų sk.	11	7	6	8	12	9	10	15
Aptiktų pikų sk. pritaikius FFT ir $d = 9.0$	12	6	8	6	17	7	10	12
Aptiktų pikų sk. pritaikius VT ir $d = 9.0$	24	26	21	12	31	21	16	25
Aptiktų pikų sk. pritaikius VT ir $d = 11.0$	16	3	6	7	16	8	12	14
EEG nr. 2	1 min	2 min	3 min	4 min	5 min	6 min	7 min	8 min
Gydytojo nurodytas pikų sk.	10	13	15	29	11	14	11	18
Aptiktų pikų sk. pritaikius FFT ir $d = 6.5$	10	19	22	30	10	12	18	22
Aptiktų pikų sk. pritaikius VT ir $d = 6.5$	19	28	23	41	20	20	25	27
Aptiktų pikų sk. pritaikius VT ir $d = 7.25$	13	17	13	30	12	11	15	19
EEG nr. 3	1 min	2 min	3 min	4 min	5 min	6 min	7 min	8 min
Gydytojo nurodytas pikų sk.	4	6	2	2	4	5	2	4
Aptiktų pikų sk. pritaikius FFT ir $d = 8.0$	8	12	4	2	0	0	6	3
Aptiktų pikų sk. pritaikius VT ir $d = 8.0$	22	27	12	5	2	1	23	14
Aptiktų pikų sk. pritaikius VT ir $d = 10.0$	10	15	5	2	1	0	11	2

1 lentelė. Algoritmo pritaikymo rezultatai taikant skirtingą detekcijos ribą po Furje transformacijos (FFT) ir po Vilnelės transformacijos (VT).

Testuojant algoritmą, buvo koncentruojamasi, kiek pikų konkrečioje minutėje rado gydytojas bei kiek detektavo algoritmas. Iš 1 ir 2 lentelių galima pamatyti, jog radus tinkamą detekcijos ribos koeficientą, algoritmo aptiktų pikų buvo daugiau nei pažymėjo gydytojas, tačiau toks požymis galėtų būti naudingas tolimesnei tyrimo eigai, jei būtų naudojami neuroniniai tinklai.

EEG nr. 4	1 min	2 min	3 min	4 min	5 min	6 min	7 min	8 min
Gydytojo nurodytas pikų sk.	9	4	2	6	6	2	6	5
Aptiktų pikų sk. pritaikius FFT ir $d = 9.0$	7	4	2	6	17	3	4	5
Aptiktų pikų sk. pritaikius VT ir $d = 9.0$	10	8	5	11	18	6	11	6
Aptiktų pikų sk. pritaikius VT ir $d = 11.0$	7	4	2	6	11	4	7	6
EEG nr. 5	1 min	2 min	3 min	4 min	5 min	6 min	7 min	8 min
Gydytojo nurodytas pikų sk.	6	12	7	8	7	5	4	8
Aptiktų pikų sk. pritaikius FFT ir $d = 8.75$	9	9	7	7	6	5	3	10
Aptiktų pikų sk. pritaikius VT ir $d = 8.75$	13	10	7	12	9	6	6	13
Aptiktų pikų sk. pritaikius VT ir $d = 9.0$	11	10	7	11	8	6	4	12

2 lentelė. Algoritmo pritaikymo rezultatai taikant skirtingą detekcijos ribą po Furje transformacijos (FFT) ir po Vilnelės transformacijos (VT).

Žiūrint į rezultatus, užfiksuotus kas minutę, kaip jau minėta anksčiau, rastų pikų skaičius kai kuriuose kanaluose skiriasi minimaliai, tačiau, jei orientuojamasi į bendrą pikų skaičių visam kanalui galima pamatyti, kaip rezultatai skiriasi pritaikius tą pačią ribą bei atitinkamai 10, 20, 25 procentų daugiau ar mažiau. Štai 3 ir 4 lentelėse pateikiami rezultatai anksčiau pritaikytiems detekcijos ribos koeficientams ir padidinus ar pamažinus juos 10, 20 ar 25 procentais.

Signalo nr.	Gydytojo detektuoti pikai	d (FFT)	$d - 25\%$	$d - 20\%$	$d - 10\%$	d
1	102	9.0	236 (131.37%)	183 (79.41%)	135 (32.35%)	105 (2.94%)
2	151	6.5	522 (245.70%)	422 (179.47%)	273 (80.79%)	176 (16.56%)
3	45	8.0	142 (215.56%)	107 (137.78%)	60 (33.33%)	37 (-17.78%)
4	49	9.0	138 (181.63%)	110 (124.49%)	76 (55.10%)	59 (20.41%)
5	73	8.75	160 (119.18%)	128 (75.34)	84 (15.07)	64 (-12.33%)
Signalo nr.	Gydytojo detektuoti pikai	d (VT)	$d - 25\%$	$d - 20\%$	$d - 10\%$	d
1	102	11.0	260 (154.90%)	221 (116.67%)	162 (58.82%)	112 (9.8%)
2	151	7.25	461 (205.3%)	365 (141.72%)	253 (67.55%)	159 (5.3%)
3	45	10.0	144 (220%)	107 (137.78%)	67 (48.89%)	48 (6.67%)
4	49	11.0	115 (134.69%)	98 (100%)	73 (48.98%)	60 (-22.45%)
5	73	9.0	218 (198.63%)	165 (126.03%)	104 (42.47%)	77 (5.48%)

3 lentelė. Detekcijos ribos keitimas, pritaikius Furje (FFT) ir Vilnelės (VT) transformacijas, kai detekcijos ribos koeficientas mažinamas.

Šių lentelių pateiktuose rezultatuose galima pamatyti, kaip keičiasi skirtingi tyrimo duomenys, parenkant vis kitą detekcijos ribos koeficientą po atliktų triukšmo šalinimo algoritmų. Lentelės viršutinėje dalyje pateikiami rezultatai po Furje transformacijos, apatinėje dalyje - po Vilnelės

Signalo nr.	Gydytojo detektuoti pikai	d (FFT)	d	$d + 10\%$	$d + 20\%$	$d + 25\%$
1	102	9.0	105 (2.94%)	78 (-23.53%)	64 (-37.25%)	63 (-38.24%)
2	151	6.5	176 (16.56%)	129 (-14.57%)	88 (-41.72%)	69 (-54.30%)
3	45	8.0	37 (-17.78%)	23 (-48.89%)	14 (-68.89%)	11 (-75.56%)
4	49	9.0	59 (20.41%)	51 (4.08)	41 (-16.33%)	39 (-20.41%)
5	73	8.75	64 (-12.33%)	51 (-30.14%)	40 (-45.21%)	34 (-53.24%)

Signalo nr.	Gydytojo detektuoti pikai	d (VT)	d	$d + 10\%$	$d + 20\%$	$d + 25\%$
1	102	11.0	112 (9.8%)	87 (-14.71%)	68 (-33.33%)	62 (-39.22%)
2	151	7.25	159 (5.3%)	99 (-34.44%)	71 (-52.98%)	62 (-58.94%)
3	45	10.0	48 (6.67%)	31 (-31.11%)	26 (-42.22%)	21 (-53.33%)
4	49	11.0	60 (-22.45%)	47 (-4.08%)	38 (-22.45%)	34 (-30.61%)
5	73	9.0	77 (5.48%)	60 (-17.81%)	48 (-34.25%)	42 (-42.47%)

4 lentelė. Detekcijos ribos keitimas, pritaikius Furje (FFT) ir Vilnelės (VT) transformacijas, kai detekcijos ribos koeficientas didinamas.

transformacijos. Rezultatai šiose lentelėse pateikiami darant prielaidą, jog gydytojo užfiksuoti pikai sudaro 100%. Todėl buvo ieškomas procentinis pokytis tarp užfiksuotų gydytojo ir algoritmo rezultatų. Teigiamos procentinės vertės rodo, kiek procentiškai algoritmas rado daugiau pikų nei gydytojas. Tuo tarpu, neigiami - kiek procentiškai algoritmas aptiko mažiau pikų nei gydytojo nustatyta pikų detekcijos riba.

Išvados ir rekomendacijos

Šiame magistro baigiamajame darbe buvo gilinamasi į medicininius signalus - elektroencefalogramas. Darbo metu buvo įgyvendinti trys skirtingi algoritmai - du elektroencefalogramų signalų triukšmui šalinti bei vienas morfologinėmis operacijomis paremtas algoritmas epileptoforminių pikų aptikimui. Atlikti testai apėmė skirtingus eksperimentus, kuomet buvo keičiami algoritmų parametrai skirtingiems realiems pacientų duomenims. Darbo metu buvo įsitikinta, jog triukšmo šalinimas ir morfologinės operacijos reikalingos epileptoforminių pikų aptikimui, tačiau algoritmo pritaikymas taikant tam tikrus parametrus nėra maksimaliai patikimi dėl skirtingos ribos koeficiento, nuo kurio būtų fiksuojami epileptoforminiai pikai.

Remiantis morfologinių operacijų ir filtrų testavimo metu gautais rezultatais, galima tvirtinti, jog nufiltravus foninę smegenų veiklą yra išryškunami pikai, kurie padeda analizuoti elektroencefalogramų signalus. Testavimo buvo koncentruojamasi į šiuos parametrus:

- Tinkamiausias struktūrinis elementas elektroencefalogramų analizei taikant morfologinius filtrus - parabolė, kuri turi būti 4 kartus ilgesnė nei signalo arkų pločių mediana. Taikant per trumpą struktūrinį elementą nufiltruojama per daug foninės smegenų veiklos, todėl epileptoforminiai pikai būna nufiltruoti. Tuo tarpu, parinkus per ilgą struktūrinį elementą yra išryškunami ne tik pikai, tačiau ir kiti elektronencefalogramų artefaktai.
- Optimaliausias signalo atkarpos ilgis yra tarp 4 ir 6 sekundžių. Testavimo metu visi mokslo baigiamajame darbe pateikti morfologinių operacijų eksperimentai buvo atliekami su 5 sekundžių trukmės signalo atkarpomis, gauti rezultatai buvo panašūs į gydytojo rezultatus, buvo signalo atkarpų, kuriose pikų aptikta buvo daugiau ar mažiau nei pažymėjo gydytojas, tačiau bendras pikų skaičius buvo procentiškai nebuvo didesnis nei detektavo gydytojas.
- Tikslios detekcijos ribos, pritaikius skirtingus triukšmo šalinimo algoritmus ir atlikus morfologines operacijas, nėra. Eksperimentų metu įsitikinta, jog pikų detekcijos ribos koeficientas pacientui turi būti parenkamas gydytojo, tačiau testavimo metu detekcijos riba svyravo nuo 7 iki 13.

Magistro baigiamajame darbe prieš atliekant morfologines operacijas, kurios padeda geriau aptikti epileptoforminius pikus, buvo atliktos ir triukšmo šalinimo transformacijos. Testavimo metu pastebėta, jog norint nufiltruoti triukšmą ir pritaikyti morfologinius filtrus, reikia turėti omenyje, jog detekcijos ribos koeficientai nebus vienodi, t. y. pritaikius atitinkamą transformaciją reikia atsižvelgti į kitą detekcijos ribos koeficientą. Eksperimentų metu buvo pastebėta, kad pritaikius Vilnelės transformaciją elektronencefalogramų signalams, detekcijos ribos koeficientas bus visuomet didesnis nei lyginant su greitosios Furje transformacijos pritaikymu. Ribos pokytis pikų detekcijos ribos koeficientui pritaikius Furje ir Vilnelės triukšmo šalinimo transformacijos kito nuo 0.5 iki 2.

Epileptoforminių pikų analizė buvo atlikta su realiais pacientų duomenimis. Analizei buvo pasirinkta 20 pacientų elektroencefalogramų. Visi trys minėtieji algoritmai buvo įgyvendinti su Python atvirojo kodo programavimo kalba. Furje ir Vilnelės transformacijų palyginimas tarpusavyje yra ganėtinai sudėtingas dėl jų skirtingų veikimo specifikacijų. Pritaikius abi transformacijas atskirai nebuvo galima pritaikyti tos pačios detekcijos ribos koeficiento, tad tokiu atveju galima likti prie rėžių, kuriuos pritaikius gydytojas pats turėtų nuspręsti, kokią ribą taikyti toliau.

Ateities tyrimų planas

Galimi tolimesni darbai automatizuotų medicininių signalų analizei:

- Pritaikyti neuroninius tinklus pikų aptikimui bei identifikavimui;
- Rekurentinių diagramų pritaikymas, kurios gali būti naudingos rasti signalo pasikartojimo pobūdį, ar jis yra generuotas atsitiktinio ar chaotiško proceso;
- Įgyvendinti algoritmų veikimą našiose skaičiavimų platformose;
- Patobulinti pikų detekcijos ribos koeficiento radimą, kad algoritmo naudotojui tektų kuo mažiau rankinio darbo, t. y. jam nereikėtų pasirinkti ribos, nuo kurios būtų ieškomi pikai.

Padėkos

Dėkoju Vilniaus universiteto ligoninės Santaros klinikų filialo Vaikų ligoninės vaikų neurologi dr. Rūtai Samaitienei už pasidalintus testinius realių pacientų duomenis.

Literatūros šaltiniai

- [1] Blank brain diagram. https://commons.wikimedia.org/wiki/File:EEG_10-10_system_with_additional_information.svg.
- [2] European data format. <https://www.edfplus.info/>.
- [3] Math documentation. <https://docs.python.org/3/library/math.html>.
- [4] Matplotlib documentation. <https://matplotlib.org/>.
- [5] Mne-python documentation. https://mne.tools/stable/auto_tutorials/intro/10_overview.html.
- [6] Numpy documentation. <https://numpy.org/doc/stable/>.
- [7] Opencv documentation. <https://opencv.org/>.
- [8] Pywavelets documentation. <https://pywavelets.readthedocs.io/en/latest/>.
- [9] Ibrahim Aliyu and Chang Gyoon Lim. Selection of optimal wavelet features for epileptic eeg signal classification with lstm. *Neural Computing and Applications*, pages 1--21, 2021.
- [10] Nikesh Bajaj. Wavelets for eeg analysis. In *Wavelet Theory*. IntechOpen, 2020.
- [11] P Berg and M Scherg. Dipole modelling of eye activity and its application to the removal of eye artefacts from the eeg and meg. *Clinical Physics and Physiological Measurement*, 12(A):49, 1991.
- [12] Sarah Blum, Nadine SJ Jacobsen, Martin G Bleichner, and Stefan Debener. A riemannian modification of artifact subspace reconstruction for eeg artifact handling. *Frontiers in human neuroscience*, 13:141, 2019.
- [13] Arielle Crespel and Philippe Gélisse. *Atlas of Electroencephalography: Activation Procedures and Artifacts. awake and sleep EEG*, volume 1. John Libbey Eurotext, 2005.
- [14] Roberto Guarnieri, Marco Marino, Federico Barban, Marco Ganzetti, and Dante Mantini. Online eeg artifact removal for bci applications by adaptive spatial filtering. *Journal of neural engineering*, 15(5):056009, 2018.
- [15] Jonathan J Halford. Computerized epileptiform transient detection in the scalp electroencephalogram: Obstacles to progress and the example of computerized ecg interpretation. *Clinical Neurophysiology*, 120(11):1909--1915, 2009.
- [16] Algimantas Juozapavičius, Bacevičius Gytis, Dmitrijus Bugelskis, and Rūta Samaitienė. Eeg analysis-automatic spike detection. *Nonlinear Analysis: Modelling and Control*, 16(4):375--386, 2011.
- [17] Tulga Kalayci and Ozcan Ozdamar. Wavelet preprocessing for automated neural network detection of eeg spikes. *IEEE engineering in medicine and biology magazine*, 14(2):160--166, 1995.
- [18] Greta Kasparaitytė. Automatizuotos medicininių signalų analizės algoritmai. Mokslo tiriamasis darbas, 2022.

- [19] Bob Kemp and Jesus Olivan. European data format 'plus'(edf+), an edf alike standard format for the exchange of physiological data. *Clinical neurophysiology*, 114(9):1755--1761, 2003.
- [20] Nitendra Kumar, Khursheed Alam, and Abul Hasan Siddiqi. Wavelet transform for classification of eeg signal using svm and ann. *Biomedical and Pharmacology Journal*, 10(4):2061-2069, 2017.
- [21] Tadas Meškauskas. Signalų analizė ir apdorojimas. Vilniaus universitetas, Matematikos ir informatikos fakultetas, 2017.
- [22] Andrius Vytautas Misiukas Misiūnas, Tadas Meškauskas, and Algimantas Juozapavičius. On the implementation and improvement of automatic eeg spike detection algorithm. *Lietuvos matematikos rinkinys. Ser. A*, 56:60--65, 2015.
- [23] Andrius Vytautas Misiukas Misiūnas. Automatinė elektroencefologramų analizė. Magistro baigiamasis darbas, 2015.
- [24] Stephen Roberts. Signal processing filter design, 2003.
- [25] Saeid Sanei and Jonathon A Chambers. *EEG signal processing*. John Wiley & Sons, 2013.
- [26] Steven W Smith. Digital signal processing: Scientist and engineers guide, 1997.
- [27] Andrew Wood. *Physiology, Biophysics, and Biomedical Engineering*. Taylor & Francis, 2016.
- [28] Guanghua Xu, Jing Wang, Qing Zhang, and Junming Zhu. An automatic eeg spike detection algorithm using morphological filter. In *2006 IEEE International conference on automation science and engineering*, pages 170--175. IEEE, 2006.
- [29] Maxime Yochum, Charlotte Renaud, and Sabir Jacquir. Automatic detection of p, qrs and t patterns in 12 leads ecg signal based on cwt. *Biomedical Signal Processing and Control*, 25:46--52, 2016.

Priedai

A. Algoritmo pritaikymo rezultatų tęsinys

EEG nr. 1	9 min	10 min
Gydytojo nurodytas pikų sk.	13	11
Aptiktų pikų sk. pritaikius FFT ir $d = 9.0$	13	14
Aptiktų pikų sk. pritaikius VT ir $d = 9.0$	26	21
Aptiktų pikų sk. pritaikius VT ir $d = 11.0$	15	13
EEG nr. 2	9 min	10 min
Gydytojo nurodytas pikų sk.	8	22
Aptiktų pikų sk. pritaikius FFT ir $d = 6.5$	12	21
Aptiktų pikų sk. pritaikius VT ir $d = 6.5$	24	27
Aptiktų pikų sk. pritaikius VT ir $d = 7.25$	10	19
EEG nr. 3	9 min	10 min
Gydytojo nurodytas pikų sk.	4	12
Aptiktų pikų sk. pritaikius FFT ir $d = 8.0$	1	1
Aptiktų pikų sk. pritaikius VT ir $d = 8.0$	2	3
Aptiktų pikų sk. pritaikius VT ir $d = 10.0$	1	1
EEG nr. 4	9 min	10 min
Gydytojo nurodytas pikų sk.	5	4
Aptiktų pikų sk. pritaikius FFT ir $d = 9.0$	6	5
Aptiktų pikų sk. pritaikius VT ir $d = 9.0$	10	7
Aptiktų pikų sk. pritaikius VT ir $d = 11.0$	7	6
EEG nr. 5	9 min	10 min
Gydytojo nurodytas pikų sk.	8	8
Aptiktų pikų sk. pritaikius FFT ir $d = 8.75$	4	4
Aptiktų pikų sk. pritaikius VT ir $d = 8.75$	5	3
Aptiktų pikų sk. pritaikius VT ir $d = 9.0$	5	3

5 lentelė. Algoritmo pritaikymo rezultatai taikant skirtingą detekcijos ribą