



KAUNO TECHNOLOGIJOS UNIVERSITETAS
INFORMATIKOS FAKULTETAS

Egidijus Murauskas

PARKINSONO LIGOS DETEKCIJA IŠ KALBOS SIGNALO

Baigiamasis magistro projektas

Vadovas
doc. dr. E. Vaičiukynas

KAUNAS, 2018

KAUNO TECHNOLOGIJOS UNIVERSITETAS
INFORMATIKOS FAKULTETAS

PARKINSONO LIGOS DETEKCIJA IŠ KALBOS SIGNALO

Baigiamasis magistro projektas
Informacinių sistemų inžinerijos studijų programa (kodas 621E15001)

Vadovas

doc. dr. E. Vaičiukynas
2018-05-23

Recenzentas

doc. dr. V. E. Rudžionis
2018-05-23

Projektą atliko

Egidijus Murauskas
2018-05-23



KAUNO TECHNOLOGIJOS UNIVERSITETAS
INFORMATIKOS FAKULTETAS

(Fakultetas)

Egidijus Murauskas

(Studento vardas, pavardė)

Informacinių sistemų inžinerijos studijų programa, 621E15001

(Studijų programos pavadinimas, kodas)

Baigiamojo projekto „Parkinsono ligos detekcija iš kalbos signalo“

AKADEMINIO SAŽININGUMO DEKLARACIJA

20 18 m. gegužės 23 d.
Kaunas

Patvirtinu, kad mano, **Egidijaus Murausko**, baigiamasis projektas tema „Parkinsono ligos detekcija iš kalbos signalo“ yra parašytas visiškai savarankiškai ir visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs.

Aš suprantu, kad išaiškėjus nesąžiningumo faktui, man bus taikomos nuobaudos, remiantis Kauno technologijos universitete galiojančia tvarka.

(vardą ir pavardę įrašyti ranka)

(parašas)

Murauskas, Egidijus. Parkinsono ligos detekcija iš kalbos signalo. Magistro baigiamasis projektas / vadovas doc. dr. Evaldas Vaičiukynas; Kauno technologijos universitetas, Informatikos fakultetas.

Mokslo kryptis ir sritis: Informatikos inžinerija, technologijos mokslai

Reikšminiai žodžiai: *Parkinsono liga, kalbos signalo analizė, Essentia audio požymiai, GMM-UBM, atsitiktinis miškas, ekspertinė sistema.*

Kaunas, 2018. 59 p.

SANTRAUKA

Šiame tiriamajame darbe nagrinėjamas Parkinsono ligos detekcijos uždavinys naudojant kalbos įrašo analizės metodus. Literatūros apžvalgos dalyje aptarti jau egzistuojantys tyrimai, detekcijos problemos, naudojami požymiai, taikomi metodai, pasiekti rezultatai. Tyrimo metodų pasirinkimo dalyje, kalbos signalo analizės procesas išskaidytas į etapus, nuodugniau išnagrinėjant įrašo išskaidymą į informacijos kadrus, gautų požymių suspaudimo procesą panaudojant matematinės statistikas ir Gauso mišinių modelį (GMM), detekcijai panaudojant atsitiktinio miško klasifikatorių.

Ekspperimentams naudotos dvi kalbos įrašų duomenų bazės: pirmoji iš 369 įrašų naudojant akustinį kardioidinį mikrofoną ir antroji iš 98 įrašų naudojant išmanaus telefono mikrofoną. Išmanių telefonų daryti įrašai buvo įrašyti ne visiems pirmos duomenų bazės subjektams. Abi duomenų bazės sudarė sakinio „turėjo senelė žilą oželį“ įrašai.

Detekcijos tikslumui įvertinti naudotas lygių klaidų lygis (EER). Ekspperimentų rezultatai atskleidė, jog naudojant siūlomą GMM pirmajai įrašų bazei pasiektas 13.41% EER, o 13 statistinių funkcijų EER siekė 13.43%. Suvienodinus įrašų skaičių (naudojami tų pačių subjektų įrašai), akustiniam mikrofonui pasiektas mažiausias 21.32% EER naudojant statistines funkcijas, o išmanaus telefono mikrofonu gautiems įrašams mažiausias 26.65% EER pasiektas naudojant GMM metodą.

Atlikta požymių svarbos analizė, siekiant nustatyti kadrinių požymių ir 13 statistinių funkcijų įtaką detekcijos rezultatams parodė, jog svarbiausi audio požymiai yra Mel'o skalės kepsriniai koeficientai (MFCC) ir įvairaus tipo *Essentia* bibliotekos spektriniai požymiai, o informacijos kadru suspaudime – viršutinio kvartilio ir standartinio nuokrypio statistinės funkcijos.

Darbo metu realizuotas Parkinsono ligos atpažinimo ekspertinės sistemos prototipas, leidžiantis sistemos naudotojui iširti savo kalbos įrašą naudojantis interneto naršykle. Sukurtu sprendimu siekiama pasidalinti gautais rezultatais, bei aptikti ligą ankstyvoje jos stadijoje naudojant neinvazinę priemonę. Ateityje, siekiant pagerinti Parkinsono ligos detekcijos tikslumą, siūloma apjungti detektorių sprendimus iš kalbos ir balso modalumų.

Murauskas, Egidijus. Parkinson's disease detection from speech signal. Master's thesis in Information Systems Engineering / supervisor assoc. prof. dr. Evaldas Vaičiukynas. The Faculty of Informatics, Kaunas University of Technology.

Research area and field: Informatics Engineering, Technological Sciences

Key-words: Parkinson's disease, speech signal analysis, Essentia audio descriptors, GMM-UBM, random forest, expert system.

Kaunas, 2018. 59 p.

SUMMARY

This master thesis investigates the detection of Parkinson's disease using techniques of speech signal analysis. Existing researches, detection problems, used features, applied methods and achieved results are discussed in the literature review section. The process of speech signal analysis is divided into stages, analysis of the speech feature extraction is made, the process of compression of the received attributes using statistical functionals and GMM by using the random classification of the forest is done in the research methods part.

Two databases of speech recordings were used during the experiments. The first database consists of 369 recordings that are recorded by acoustic cardioid microphone and the second database consists of 98 recordings that are recorded by smart phone. Signals for both databases are recorded simultaneously, under the same conditions, but the second database has fewer subjects than the first one. Both databases contain a single pronunciation sentence "turėjo senelė žilą oželį".

The equal error rate (EER) was used to evaluate the goodness of detection. The experimental investigation has shown that using the GMM for the first database resulted in EER 13.41% and EER 13.43% was achieved by using statistical functions. After the first dataset was reduced to the second size (both datasets had same subjects), the lowest EER 21.32% was achieved by using statistical functions of the acoustic microphone. Meanwhile, the smart phone achieved the lowest EER of 26.65% by using the GMM.

Variable importance analysis from the random forest indicated that Mel-frequency cepstral coefficients (MFCC) and various spectral descriptors from Essentia library are the most important descriptors for detection accuracy. Furthermore, statistical functions of the upper quartile and standard deviation are the most important for compression of the short-term audio features.

A prototype of the Parkinson's disease detection expert system was created during the research, which allows the system user to access it using the internet browser. This solution was created to share the results and to detect the disease at an early stage phase using a non-invasive tool. It is proposed to combine from speech and sustained voice modalities in the future in order to improve the accuracy of Parkinson's disease detection.

TURINYS

LENTELIŲ SĄRAŠAS	8
PAVEIKSLŲ SĄRAŠAS	9
TERMINŲ IR SANTRUMPŲ ŽODYNAS.....	10
1. ĮVADAS.....	11
1.1. Darbo problematika ir aktualumas.....	11
1.2. Darbo tikslas ir uždaviniai	11
1.3. Darbo rezultatai ir jų svarba.....	12
1.4. Darbo struktūra	12
2. EGZISTUOJANČIŲ TYRIMŲ APŽVALGA.....	13
2.1. Tyrimo objektas, sritis ir problema.....	13
2.2. Esamų problemos sprendimų metodų analizė (Lietuvos ir tarptautiniu mastu)	13
2.3. Siekiamo sprendimo apibrėžimas	17
2.4. Analizės išvados.....	18
3. TYRIMO METODAI	19
3.1. Kadrinių požymių išskyrimas	19
3.1.1. <i>Essentia</i> audio požymiai.....	19
3.2. Požymių vektoriaus sudarymas.....	20
3.2.1. 13 statistinių funkcijų	20
3.2.2. Gauso mišinių modelis	21
3.3. Detekcija	22
3.3.1. Atsitiktinis miškas	22
3.3.2. Detektoriaus sprendimo formavimas.....	23
3.3.3. RF detektoriaus tikslumo įvertinimas.....	24
3.3.4. Sumaišymų matrica ir jos vertinimas	24
3.3.5. Požymių įtakos įvertinimas	25
3.3.6. Daugiamačių skalių algoritmo naudojimas duomenų vizualizacijai	26
3.4. Įrankiai ir metodai programinio prototipo kūrimui.....	27
3.4.1. Programavimo aplinka <i>Matlab</i>	27
3.4.2. Puslapio serveris	28
4. EKSPERIMENTŲ REZULTATAI	29
4.1. Pradiniai duomenys, parametrai ir nuskaitymas	29
4.2. Tyrimo rezultatai naudojant akustinį mikrofoną.....	29
4.3. Tyrimo rezultatų palyginimas naudojant akustinį ir išmanaus telefono mikrofonus.....	36
4.4. Eksperimentinės dalies rezultatai.....	38
5. PROTOTIPINĖS SISTEMOS KŪRIMAS IR TESTAVIMAS.....	39
5.1. Reikalavimų specifikacija	39
5.1.1. Funkciniai reikalavimai	39
5.1.2. Nefunkciniai reikalavimai	46

5.2. Loginė sistemos architektūra	46
5.3. Realizacijos modelis	47
5.3.1. Komponentų modelis.....	47
5.3.2. Diegimo modelis	47
5.4. Sistemos naudotojo dokumentacija.....	48
5.4.1. Pagrindinis puslapis.....	48
5.4.2. Įrašo apdorojimo ir rezultatų išvedimo puslapis	49
5.5. Prototipo testavimas.....	51
6. IŠVADOS	53
7. LITERATŪRA.....	54
8. PRIEDAI.....	57
8.1. priedas. Klasifikavimo klaidų pasiskirstymas priklausomai nuo RF medžių skaičiaus	57
8.2. priedas. Slenksčio parinkimo vertinimas akustinio mikrono atveju	57
8.3. priedas. ROC kreivių palyginimas naudojant išmanaus telefono mikrofoną	58
8.4. priedas. Slenksčio parinkimo vertinimas mobilaus telefono mikrono atveju	58

LENTELIŲ SĄRAŠAS

2.1 lentelė. Parkinsono ligos detekcijos iš balso signalo palyginimas pagal naudotus požymius ir detektorius.....	14
2.2 lentelė. Parkinsono ligos nustatymo iš kalbos ir balso signalų pagal taikytas metodikas palyginimas	15
2.3 lentelė. Parkinsono ligos nustatymo iš kalbos signalo palyginimas pagal naudotus požymius ir detektorius.....	17
3.1 lentelė. Sumaišymo matrica	24
3.2 lentelė. ROC kreivių papildomi įvertinimai [34, 35]	25
4.1 lentelė Apibendrinta duomenų bazė: skaičiai rodo asmenų kiekį (įrašų skaičius)	29
4.2 lentelė. ROC kreivių palyginimas naudojant AUC skaičiavimus pirmos duomenų bazės atveju .	31
4.3 lentelė. Sumaišymo matrica naudojant 13 matematinių statistikų kalbos signalo kadrų suspaudimui	32
4.4 lentelė. Sumaišymo matrica naudojant 32 centrų GMM kalbos signalo kadrų suspaudimui	32
4.5 lentelė. 13 statistikų ir 32 centrų GMM palyginimas pagal tikslumo įverčius, gaunamus iš sumaišymų matricos.....	33
4.6 lentelė. ROC kreivių palyginimo įverčiai, antros duomenų bazės atveju	37
4.7 lentelė. Sumaišymo matrica naudojant 13 matematinių statistikų kalbos signalo kadrų suspaudimui	37
4.8 lentelė. Sumaišymo matrica naudojant 16 centrų GMM kalbos signalo kadrų suspaudimui	37
4.9 lentelė. 13 statistikų ir 16 centrų GMM palyginimas pagal tikslumo įverčius, gaunamus iš sumaišymų matricos.....	37
5.1 lentelė. PA „Inicijuoti detekciją“ specifikacija	39
5.2 lentelė. PA „Atlikti detekciją“ specifikacija	40
5.3 lentelė. PA „Įkelti įrašus“ specifikacija	41
5.4 lentelė. PA „Išskirti kadrinius požymius“ specifikacija.....	42
5.5 lentelė. PA „Suspausti į vektorius“ specifikacija.....	43
5.6 lentelė. PA „Klasifikuoti“ specifikacija	44
5.7 lentelė. PA „Grąžinti rezultata“ specifikacija	45

PAVEIKSLŲ SĄRAŠAS

2.1 pav. Tyrimo proceso eiga	18
3.1 pav. GMM adaptacija panaudojant MAP principą. a) kai pakeisti keli rinkinio λ parametrai, b) kai pakeisti visi rinkinio λ parametrai. Šaltinis: [28]	22
3.2 pav. Atsitiktinio miško struktūra	23
3.3 pav. Detektoriaus tikslumo vertinimo DET (kairėje) ir ROC (dešinėje) kreivės	24
3.4 pav. Įrašų išsibarstymas 2D erdvėje naudojant MDS algoritmą.....	26
4.1 pav. RF detektoriaus DET kreivės ir EER reikšmės priklausomai nuo metodo	30
4.2 pav. RF detektoriaus DET kreivės ir EER reikšmės prie įvairių GMM τ parametro reikšmių.....	30
4.3 pav. 13 statistinių funkcijų ir 32 centrų GMM palyginimas naudojant ROC kreivę	31
4.4 pav. ROC kreivė (kairėje), jautrumo ir specifiškumo kreivės (dešinėje) naudojant 13 statistinių funkcijų.....	31
4.5 pav. Detektoriaus išėjimo reikšmės pasiskirstymas priklausomai nuo klasės bei optimalus slenkstis (punktyrinė linija), prie kurio klasių klaidos susilygina naudojant 13 statistinių funkcijų.....	32
4.6 pav. Atsitiktinio miško ER skaičiavimais grindžiama 13 statistinių funkcijų įtaka detekcijos tikslumui	33
4.7 pav. Atsitiktinio miško AUC skaičiavimais grindžiama 13 statistinių funkcijų įtaka detekcijos tikslumui.....	33
4.8 pav. Atsitiktinio miško ER skaičiavimais grindžiama susumuota požymių įtaka detekcijos tikslumui.....	34
4.9 pav. Atsitiktinio miško AUC skaičiavimais grindžiama susumuota požymių įtaka detekcijos tikslumui	34
4.10 pav. Įrašų išsibarstymas 2D erdvėje, taikant MDS algoritmą (naudojamas 13 statistikų suspaudimas)	35
4.11 pav. Įrašų išsibarstymas 2D erdvėje, taikant MDS algoritmą (naudojamas 32 centrų GMM suspaudimas)	35
4.12 pav. RF detektoriaus DET kreivės naudojant akustinį mikrofoną.....	36
4.13 pav. RF detektoriaus DET kreivės naudojant išmanaus telefono mikrofoną	36
5.1 pav. Parkinsono ligos detekcijos sistemos panaudojimo atvejų diagrama	39
5.2 pav. PA „Inicijuoti detekciją“ veiklos diagrama	40
5.3 pav. PA „Atlikti detekciją“ veiklos diagrama.....	41
5.4 pav. PA „Įkelti įrašus“ veiklos diagrama.....	42
5.5 pav. PA „Išskirti kadrinius požymius“ veiklos diagrama	43
5.6 pav. PA „Suspausti į vektorius“ veiklos diagrama	44
5.7 pav. PA „Klasifikuoti“ veiklos diagrama	45
5.8 pav. PA „Gražinti rezultatą“ veiklos diagrama.....	45
5.9 pav. Sistemos architektūros modelis	46
5.10 pav. Sistemos komponentų diagrama	47
5.11 pav. Sistemos diegimo diagrama	47
5.12 pav. Sistemos pagrindinis puslapis	48
5.13 pav. Registracijos forma	48
5.14 pav. Prisijungimo forma	49
5.15 pav. Garso įrašo ir apdorojimo procesų pasirinkimas sistemoje	49
5.16 pav. Sistemos įrašo apdorojimo proceso vykdymo indikatorius	50
5.17 pav. Sistemos gražinamų rezultatų langas	50
5.18 pav. Įrašo analizės trukmės priklausomybė nuo įrašų skaičiaus.....	51
5.19 pav. Įrašo analizės trukmės ir apdorojimo spartos priklausomybė nuo įrašo dydžio	52
8.1 pav. Klasifikavimo klaidų (OOB) lygio pasiskirstymo priklausomybė nuo medžių skaičiaus	57
8.2 pav. ROC kreivė (kairėje), jautrumo ir specifiškumo kreivės (dešinėje) naudojant 32 centrų GMM.....	57
8.3 pav. Detektoriaus išėjimo reikšmės pasiskirstymas priklausomai nuo klasės bei optimalus slenkstis (punktyrinė linija), prie kurio klasių klaidos susilygina naudojant 32 centrų GMM	58
8.4 pav. 13 statistinių funkcijų ir 16 centrų GMM palyginimas naudojant ROC kreives	58
8.5 pav. ROC kreivė (kairėje), jautrumo ir specifiškumo kreivės (dešinėje) naudojant 13 statistinių funkcijų.....	58
8.6 pav. Detektoriaus išėjimo reikšmės pasiskirstymas priklausomai nuo klasės bei optimalus slenkstis (punktyrinė linija), prie kurio klasių klaidos susilygina naudojant 13 matematinių statistikų	59
8.7 pav. ROC kreivė (kairėje), jautrumo ir specifiškumo kreivės (dešinėje) naudojant 16 centrų GMM.....	59
8.8 pav. Detektoriaus išėjimo reikšmės pasiskirstymas priklausomai nuo klasės bei optimalus slenkstis (punktyrinė linija), prie kurio klasių klaidos susilygina naudojant 16 centrų GMM	59

TERMINŲ IR SANTRUMPŲ ŽODYNAS

Santrumpos/terminai	Paaiškinimas
GMM	(angl. <i>Gaussian mixture modelling</i>) Gauso skirstinių mišinio modelis
UBM	(angl. <i>universal background model</i>) universalus pamatinis modelis
MAP adaptation	(angl. <i>maximum a posteriori adaptation</i>) maksimalus aposteriorinis įvertinimas naudojamas kalbėtojo adaptacijai GMM modelyje
HMM	(angl. <i>hidden Markov modelling</i>) paslėptųjų Markovo grandinių modelis
RF	(angl. <i>random forest</i>) atsitiktinis miškas
MFCC	(angl. <i>Mel frequency cepstral coefficients</i>), Mel'o dažnių skalės keptriniai koeficientai
BBE	(angl. <i>Bark band energy</i>) Bark dažnių spektro energija
Supervector	supervektorius, sudaromas panaudojant Gauso mišinių modelį
OOB Error	(angl. <i>out of bag error</i>) į medžio stebėjimų imtį nepakliuvusių stebėjimų klasifikavimo klaida
AUC	(angl. <i>area under the curve</i>) plotas po kreive
DET	(angl. <i>detection error tradeo-off</i>) detekcijos klaidų kreivė

1. ĮVADAS

„Parkinsono ligos detekcija iš kalbos signalo“ darbas priklauso „Informacinių sistemų inžinerija“ studijų programai. Šiame darbe nagrinėjamos Parkinsono ligos detekcijos iš kalbos ir balso problemos, naudojami požymiai, metodai, klasifikavimo algoritmai kuriais remiantis siekiama diagnozuoti ligą. Darbe siekiama sukurti ekspertinę sistemą Parkinsono ligos detekcijai iš kalbos signalo.

1.1. Darbo problematika ir aktualumas

Parkinsono liga – neurologinis sutrikimas, paveikiantis pagrindinės nervų sistemos funkcijas, charakterizuojamas kaip progresyvus dopaminerginių neuronų praradimas vidurinių smegenų juodojoje medžiagoje (lot. *substantia nigra*) [1]. Tai progresuojanti lėtinė liga, pasižyminti ne tik motorinių, bet ir nemotorinių simptomų įvairove, sutrikdančia funkcijas ir sukeliančia neįgalumą. Sergamumas ir paplitimas didėja tarp vyresnio amžiaus žmonių grupių ir nustatomas 1 – 2 proc. vyresnių nei 65 metų amžiaus žmonių [2]. Klinikinė Parkinsono liga diagnozuojama remiantis šiais motorinių funkcijų sutrikimais: drebulys, raumenų sustingimas, judesių sulėtėjimas, nestabili laikysena. Kartu su motorinių funkcijų sutrikimais vertinami ir nemotorinių funkcijų: autonominių funkcijų ir sensoriniai, miego, pažinimo funkcijų, nuotaikos ir aktyvumo sutrikimai [3]. Balso ir kalbos sutrikimai – tipiniai Parkinsono ligos sutrikimai, atsirandantys didžiąjai daliai subjektų ligos metu [4, 5, 6]. Progresuojantis gebėjimo bendrauti praradimas laikomas svarbiu negalios požymiu sergantiems šia liga asmenims. Tipiniai kalbos sutrikimo požymiai charakterizuojami kaip kvėpčiojantis ar užkimeręs balsas, sumažėjęs garsumas, monotoniškumas, netiksli artikuliacija, kalbos greičio pakitimai, pauzių santykis [7, 8]. Šie daugialypiai kalbos ir balso sutrikimai tradiciškai buvo siejami su dopamino sumažėjimu ir gerklų raumenų sutrikimu [9]. Pacientų neurologinė būklė įvertinama naudojant vieningą Parkinsono ligos reitingavimo skalę UPDRS (angl. *unified Parkinson's disease rating scale*) [10] kuri vertina motorinius sutrikimus ir modifikuotą „Hoehn“ ir „Yahr“ stadijų skalę [11], papildomai vertinančią elgseną, nuotaikos veiksmus, kasdieninio gyvenimo veiklą.

Parkinsono liga antra dažniausiai sutinkama lėtinė neurodegeneracinė liga po Alzheimerio [2] ir manoma, jog sergamumas didės dėl gyventojų senėjimo. Klinikinis ligos nustatymas sudėtingas, apimantis paciento ligų ilgalaikį stebėjimą, įvertinant nusiskundimus, atliekant įvairių simptomų nustatymą invaziniais ir neinvaziniais tyrimais. Klinikinės diagnozės metu dopaminerginių neuronų praradimas gali siekti iki 50% [12] ir sparčiai didėja per 4 metus po diagnozavimo [13]. Medicina ir chirurginė intervencija gali sumažinti ligos progresą, jei ji nustatoma ankstyvojoje stadijoje, taip pagerinant sergančiųjų gyvenimo trukmę ir kokybę. Akustinė kalbos signalo analizė - tai potenciali neinvazinė priemonė Parkinsono detekcijai. Atliekant kalbos signalo analizę, išskiriant įvairius požymius, galima nustatyti sutrikimus ir taip prisidėti prie ankstyvosios Parkinsono ligos fazės nustatymo.

1.2. Darbo tikslas ir uždaviniai

Darbo tikslas – pagerinti Parkinsono ligos atpažinimo rezultatus iš kalbos signalo, panaudojant statistinius informacijos kadrų suspaudimo būdus.

Darbo uždaviniai:

1. Išanalizuoti kalbos signalo apdorojimo procesą.
2. Išanalizuoti esamas kalbos signalo apdorojimo priemones (metodus, įrankius).
3. Parinkti efektyvesnę kalbos signalo analizavimo metodą Parkinsono liga sergančiųjų nustatymui.
4. Palyginti gautus rezultatus su ankstesnių tyrimų rezultatais.
5. Sukurti ekspertinės sistemos programinį prototipą, realizuojantį pasirinktus metodus.
6. Apibendrinti tyrimo rezultatus.

1.3. Darbo rezultatai ir jų svarba

Darbe atliekamas skirtingų metodų (GMM ir 13 pagrindinių statistinių funkcijų) naudojamų kalbos signalo kadrų suspaudimui palyginimas. Tiriama skirtingų mikrofonų (akustinio ir išmanaus telefono) įtaka klasifikatoriaus tikslumui bei identifikuojama, kuris iš lyginamų metodų yra labiau tinkamas kiekvienam iš mikrofonų tipų. Tyrimo rezultatai parodė, jog GMM labiau tinkamas naudojant išmanaus telefono mikrofonu gautus įrašus. Skirtingų mikrofonų palyginimo metu, taip pat įvertinta visų ir sumažintų subjektų skaičiaus įtaka klasifikatoriaus tikslumui.

Parkinsono ligos diagnozavimas net ir patyrusiam specialistui – gydytojui, gali būti sudėtingas uždavinys. Sprendimas, aptikti ligą iš kalbos signalo paremtas neinvaziniais metodais, leistų kiekvienam suinteresuotam asmeniui pasitikrinti sveikatos būklę lankantis Interneto tinklalapyje (telemedicina) ar vizito metu pas specialistą vietoje.

1.4. Darbo struktūra

Šiame darbe tyrimas pradedamas antruoju skyriumi „EGZISTUOJANČIŲ TYRIMŲ APŽVALGA“, kuriame atliekama literatūros šaltinių analizė, apžvelgiant literatūroje pateikiamą informaciją ir pasiektus rezultatus. Tyrimui naudojamos metodologijos ir metodai aptariami trečiajame skyriuje, pavadinimu „TYRIMO METODAI“. Eksperimentinių tyrimų rezultatai, siekiant pagerinti sergančiųjų Parkinsono liga atpažinimo rezultatus iš kalbos signalo, pristatomi ketvirtojoje darbo dalyje, pavadinimu „EKSPERIMENTŲ REZULTATAI“. Penktajame skyriuje „PROTOTIPINĖS SISTEMOS KŪRIMAS IR TESTAVIMAS“ pateikiamas sistemą realizuojantis prototipas. Tiriamasis darbas užbaigiamas pabaigoje atliekant rezultatų apibendrinimą, pateikiant išvadas bei rekomendacijas tolimesniems tyrimams.

2. EGZISTUOJANČIŲ TYRIMŲ APŽVALGA

Įvertinant skirtingus kalbos aspektus arba charakteristikas, svarbu suprasti jų vaidmenį automatizuoto atpažinimo tarp sergančiųjų Parkinsono liga ir sveikų žmonių abiem aspektais – medicininio ir inžinerinio. Šiame skyriuje pateikiama atliktų skirtingų tyrimų analizė, kuriuose panaudoti įvairūs metodai ir įrankiai skirti automatiniam Parkinsono ligos nustatymui iš kalbos ir balso signalų.

2.1. Tyrimo objektas, sritis ir problema

Tyrimo objektas – kalbos signalas.

Tyrimo sritis – atpažinimo teorija, ekspertinė sistema, kalbos signalo analizė.

Tyrimo problema – Parkinsono liga sergančiųjų nustatymas iš kalbos signalo.

2.2. Esamų problemos sprendimų metodų analizė (Lietuvos ir tarptautiniu mastu)

Atliekant Parkinsono liga sergančiųjų automatinio nustatymo iš kalbos signalo literatūros analizę pastebima, jog dažniausiai naudojamos dvi metodikos: sergančiųjų identifikavimas atliekant balsių analizę ir identifikavimas naudojant kalbos signalo analizę. Sergančiųjų Parkinsono liga identifikavimas, taikant akustinės analizės metodus nagrinėjamas šiuose tyrimuose:

M. A. Little's ir kt. [14] tyrime taikė tradicinius ir nestandartinius metodus, siekdami aptikti balso sutrikimus tarp sveikų ir sergančių Parkinsono liga subjektų. Analizė atlikta angliškai balsei „a“ su 31 dalyviu, kur autoriai naudojo 17 požymių, iš kurių atrinko 10 labiausiai koreliavusių (koreliacijos koeficientas didesnis nei 0.95). Požymių rinkinį sudarė: 6 standartiniai požymiai, apskaičiuojami naudojant programinį paketą *PRAAT* (du drebinimo variantai (absoliutus ir vidutinis absoliutus tarp ciklų), amplitudės trikdžių koeficientas, amplitudės mirgėjimas (vidutinis absoliutus skirtumas tarp amplitudžių gaunamų tarp iš eilės einančių periodų), harmonikų ir triukšmo santykis HNS (angl. *harmonics to noise ratio*), triukšmo ir harmonikų santykis NHS (angl. *noise to harmonics ratio*)) ir 4 netiesiniai požymiai (entropijos tankio periodiškumas pasikartojimas RPDE (angl. *recurrence period density entropy*), svyravimų analizė DFA (angl. *detrended fluctuation analysis*), koreliacinė dimensija, kalbos signalo periodo entropija PPE (angl. *pitch period entropy*). Geriausias rezultatas pasiektas, taikant atraminių vektorių mašinos (SVM) klasifikatorių – 91.4%. Išvadose tyrimo autoriai pastebi, jog geriausiai atskirti sveikus ir sergančius subjektus galima taikant nestandartinių metodų kombinaciją kartu su tradiciniu metodu HNR.

A. Tsanas'as ir kt. [15] tyrė 43 dalyvių garsus, eksperimentui naudodami 132 atvejus gautus iš nepertraukiamai tariamos angliškos balsės „a“. Tyrime taikytos keturios skirtingos požymių parinkimo technikos, siekiant rasti geriausią požymių rinkinį, leidžiantį atskirti sveikų ir sergančių subjektų fonacijas. Klasifikavimo uždaviniui naudoti du skirtingi metodai: atsitiktinis miškas ir SVM sudarytas iš Gauso branduolio. Priklausomai nuo pasirinkto požymio rinkinio, autoriai nurodo pasiektą tikslumą nuo 94.4% iki 98.6%. Tyrimo metu kiekvienas subjektas kartojo garsą po keletą kartų ir visi įrašai buvo panaudoti sistemos testavimo ir apmokymo procesui. Realizuotos sistemos aukšti rezultatai gali būti netikslūs, nes nebuvo užtikrinamas sistemos nuo kalbėtojo nepriklausomumas, t. y. apmokymo ir testavimo duomenų imtys nebuvo atskirtos. Gauti rezultatai gali rodyti ne procentinę Parkinsono ligos atpažinimo tikslumą, bet kiek tiksliai sistema atpažįsta tą patį asmenį, kurio įrašai buvo tiriami.

J. R. Orozco-Aroyave's ir kt. [16] naudodami ne linijinius dinامينius požymius atliko Parkinsono liga sergančiųjų fonacijos įvertinimą. Tyrimą atliko su 40 dalyvių ispaniškoms balsėms „a“, „e“, „i“, „o“, „u“. Gauti rezultatai atskleidė, jog priklausomai nuo naudotos balsės eksperimentui, pasiekti rezultatai kinta nuo 70.2% iki 76.8%, kur didžiausias tikslumas gautas su balse „i“. Įvairios fonacijų kombinacijos nepagerino sistemos veikimo, o atliktas darbas leido autoriams nustatyti netiesinių savybių realų indėlį siekiant atskirti sveikus ir sergančius subjektus. Taip pat autoriai pastebi, jog nepertraukiamai tariamų balsių tyrime (A. Tsanas ir kt. [15]), papildomai turi būti naudojami šie požymiai: HNR, NHR, amplitudės drebinimas ir mirgėjimas, siekiant gauti didesnio tikslumo rezultatus.

Tyrimams naudoti požymiai ir gauti rezultatai plačiau detalizuojami 2.1 lentelėje.

2.1 lentelė. Parkinsono ligos detekcijos iš balso signalo palyginimas pagal naudotus požymius ir detektorius

Pavadinimas	Tyrimo dalyvių kalba ir skaičius	Požymiai	Detektorius / Tikslumas	Metai
Tarptautiniu mastu				
M. A. Little'o ir kt. tyrimas [14]	Anglų: • Sergantys – 23; • Sveiki – 8.	6 tradiciniai požymiai iš „PRAAT“ rinkinio, 4 nestandartiniai	SVM / 91.4%	2009
A. Tsanas'o ir kt. tyrimas [15]	Anglų: • Sergantys – 33; • Sveiki – 10.	Drebėjimas, mirguliavimas, triukšmo matavimai, MFCC, netiesiniai matavimai	RF ir SVM / 94.4%	2012
J. R. Orozco–Arroyave'o ir kt. tyrimas [16]	Ispanų: • Sergantys – 20; • Sveiki – 20.	Koreliacijos dimensija, didžiausia Lyapunov'o eksponentė, Lempel–Ziv'o kompleksiškas, Hurst'o eksponentė, RPDE, DFA, apytikslė entropija, apytikslė entropija su Gauso branduoliu, pavyzdinė entropija, pavyzdinė entropija su Gauso branduoliu	SVM / 76.8%	2013
Lietuvos mastu				
E. Vaičiukyno tyrimas ir kt. [17]	Lietuvių: • Sergantys – 75; • Sveiki – 308.	22 skirtingi požymių rinkiniai	RF / 83.69%	2016
E. Vaičiukyno ir kt. tyrimas [18]	Lietuvių: • Sergantys – 64; • Sveiki – 35.	18 skirtingų požymių rinkinių	RF / 79.22%	2017
A. Šimulis ir kt. [19]	Lietuvių: • Sergantys – 75; • Sveiki – 308.	PLPCC kartu su EMD ir VMD komponentais	RF / 93.52%	2017

S. Sapir'o ir kt. [20] atliko tyrimą su 52 dalyviais, naudodami skirtingus spektrinius požymius: balsės užimamas plotas VSA (angl. *vowel space area*), VSA natūrinis logaritmas, formančių centralizacijos santykis FCR (angl. *formant centralization ratio*), F_{2i}/F_{2u} santykis (čia F_{2i} ir F_{2u} yra atitinkamai balsių „i“ ir „u“ antrosios formantės). Tyrimo dalyviai gimtąja anglų kalba turėjo pakartoti tris sakinius keletą kartų per dieną iki balso terapijos ir po jos praėjus bent dviem ar trimis dienoms. Tyrimo metu įrašai buvo skaidomi į balses „a“, „i“ ir „u“.

S. Skodda'a ir kt. [21] atliko tyrimą su 188 dalyviais, eksperimentui naudodami 4 vokiečių kalbos sakinius, kuriems atliko skirtingus garsų ir tonacijos požymių skaičiavimus. Naudoti požymiai buvo grįsti centrinio dažnio (F_0) skaičiavimais, naudojant PRAAT programinį paketą. Pagrindiniai požymiai naudoti tyrimui: vidutinė F_0 vertė, F_0 kitimas apibrėžiant kaip standartinį nuokrypį (F_0SD) išreiškiant hercais, standartinio nuokrypio skirtumas nuo pirmo iki ketvirto sakinio (ΔF_0SD). Kalbos įverčio analizė buvo atliekama matuojant kiekvieno skiemens ir kiekvienos pauzės trukmę, atsižvelgiant į garso slėgio signalo spektrogramą. Šio tyrimo metu autoriai pristatė artikuliacijos pagreičio sąvoką: skirtumas grynojo kalbos greičio NSR (angl. *net speech rate*) gaunamo tarp pirmojo ir ketvirtojo sakinio. Atliekant tyrimą balsėms „a“, „i“ ir „u“ su 68 dalyviais, buvo skaičiuojamos pirmosios dvi jų formantės. Artikuliacijos analizei autoriai taikė trikampio balsės užimamo ploto tVSA (angl. *triangular vowel space area*) ir balsės artikuliacijos indekso VAI (angl. *vowel articulation index*) matavimus. Kalbos tyrimo rezultatuose autoriai pastebėjo, jog pagrindinio dažnio kitimas tarp sergančių subjektų yra mažesnis nei tarp sveikų, o tarp keletą ligos simptomų ir prozodijos kintamųjų (tokių kaip pauzės kalboje) yra koreliacija. Balsių analizės rezultatai parodė, jog balsės artikuliacijos indeksas yra žymiai mažesnis tarp sergančiųjų Parkinsono liga, lyginant su sveikais subjektais. Autoriai taip pat pastebi jog, trikampis balsių užimamas plotas sumažėja tik tarp sergančių vyrų, bei nerasta koreliacija tarp balsių artikuliacijos ir ligos.

J. Rusz'as ir kiti [22] analizavo 46 dalyvių įrašus, šešiose skirtingose užduotyse: 1) nepertraukiamas atskirų balsių tarimas; 2) greitas skiemenų pa-ta-ka pakartojimas; 3) 136 žodžių teksto

skaitymas; 4) 90 sekundžių monologas; 5) sakinių skaitymas; 6) 34 žodžių ritmiškas teksto skaitymas. Užduočių vertinimas buvo charakterizuojamas trimis kategorijomis: artikuliacija, fonacija ir prozodija. Tyrimo išvadose autoriai teigė, jog 78% tiriamųjų asmenų turėjo kalbos sutrikimų, prozodijos bruožai labiausiai paveikti ligos, o artikuliacija antroje vietoje. Taip pat autoriai pastebi, jog fundamentinio dažnio kitimas monologuose ir emocionaliuose sakiniuose turi reikšmingos informacijos atskiriant sergančius ir sveikus subjektus.

Apibendrinti analizuotų tyrimų rezultatai ir naudoti metodai pateikiami 2.2 lentelėje.

2.2 lentelė. Parkinsono ligos nustatymo iš kalbos ir balso signalų pagal taikytas metodikas palyginimas

Pavadinimas	Tyrimo dalyvių kalba ir skaičius	Metodikos/parametrai	Rezultatai	Metai
Balso signalo tyrimai				
S. Sapir'o ir kt. tyrimas [20]	Anglų: <ul style="list-style-type: none"> Sergantys – 38; Sveiki – 14. 	VSA, VSA natūrinis logaritmas, FCR, F_{2i}/F_{2u}	FCR ir F_{2i}/F_{2u} stipriai koreliuoja (koreliacija 0.90) ir abu leidžia atskirti tiek sveikus, tiek pažeistus kalbos signalus.	2009
Kalbos signalo tyrimai				
J. Ruzs'o ir kt. tyrimas [22]	Čekų: <ul style="list-style-type: none"> Sergantys – 23; Sveiki – 23. 	Standartinis nuokrypis nuo centrinio dažnio F_0SD , drebėjimas, amplitudės mirgėjimas, NHR, HNR, DDK, gebėjimas išlaikyti pastovią C–V kombinacijos normą, skirtingi spektro energijos matavimai, VSA	Autoriai patvirtino, jog 78% asmenų turėjo kalbos sutrikimų. Prozodija buvo labiausiai paveikta ankstyvojoje Parkinsono ligos stadijoje, o artikuliacija antras labiausias paveiktas aspektas.	2011
S. Skodda'o ir kt. tyrimas [21]	Vokiečių: <ul style="list-style-type: none"> Sergantys – 138; Sveiki – 50. 	\bar{F}_0 , F_0SD , ΔF_0SD , NSR	F_0SD labiau kinta tarp sveikų subjektų nei sergančių, o tarp prozodijos kintamųjų ir ligos simptomų yra koreliacija.	2011
	Vokiečių: <ul style="list-style-type: none"> Sergantys – 36; Sveiki – 32. 	F_1 ir F_2 balsių formantės, $tVSA$, VAI	VAI mažėja tik tarp sergančių asmenų – vyrų, o tarp balsių artikuliacijos ir ligos nėra koreliacijos.	

T. Bocklet'as ir kiti [23] atliko 176 Parkinsono liga sergančiųjų ir sveikų subjektų automatinę kalbos klasifikaciją, naudodami tris skirtingas strategijas: artikuliaciją, prozodiją, fonaciją. 1582 akustiniai požymiai iš signalo išgauti naudojant *OPENSIMILE* programinį paketą. Artikuliacijos tyrimui buvo naudojama 13 MFCC, toliau suformuojant požymių vektorių su 39 komponentais kiekvienam balso kadru. Požymių vektoriai sumodeliuoti naudojant GMM kiekvienam kalbėtoju. Panaudojant MAP adaptaciją sudarytas universalus pamatinis modelis (GMM–UBM). Prozodija tirta naudojant centrinę dažnį, energiją, trukmę, pauzes, amplitudės drebėjimą ir mirgėjimą. Požymių vektorius sudarytas skaičiuojant vidurkį, minimumą, maksimumą ir standartinę deviaciją kiekvieno garso segmento 73 požymiams. Fonacijos tyrimas buvo grindžiamas gerklų fiziniiais parametrais. Kalbos užduotis sudarė: spontaninė kalba; teksto skaitymas; sakinių skaitymas; atskiri žodžiai; nepertraukiamos balsės ir skiemens „pa“ kartojimas. Gautuose rezultatuose autoriai pastebi, jog artikuliacija ir fonacija yra paveikta tarp 70% ir 90% sergančių subjektų.

J. R. Orozco–Arroyave's ir kiti [24] atliko automatinę kalbos signalo klasifikaciją trimis skirtingomis kalboms: vokiečių, čekų ir ispanų. Tyrimo subjektai buvo analizuojami taikant kalbos užduotis kiekvienai tyrimo dalyvių kalbai atskirai: 1) 6 žodžiai vokiečių kalba; 2) 13 žodžių ispanų kalba; 3) nepertraukiamas skiemenų pa-ta-ka kartojimas čekų kalba. Autoriai šiame tyrime pristatė metodą, kuriame išskiriami išreikšti (angl. *voiced*) ir neišreikšti (angl. *unvoiced*) kalbos signalo segmentai. Kiekvienam segmentui charakterizavimas ir klasifikavimas buvo atliekamas atskirai.

Neišreikštiems garsams didžiausias tikslumas pasiektas su ispaniškais ir vokieškais žodžiais atitinkamai 99% ir 96%, išreikštiems garsams didžiausias tikslumas 84% gautas su ispanišku žodžiu „petaka“. Skiemėnų tarime, ispanų kalba pasiektas tikslumas 99%, o vokiečių ir čekų – 97%. Vokiečių kalbos įrašams didžiausias tikslumas pasiektas 73%. Nepertraukiamų skiemėnų tarime, išreikštiems garsams gauti tokie rezultatai: 90% čekų kalbai, 80% ispanų kalbai ir 69% vokiečių kalbai.

Lietuvoje Parkinsono ligos automatizuoto aptikimo srityje iš kalbos ir balso signalų atlikta keletas tyrimų. E. Vaičiukynas ir kt. [17] (2016 m.) balso signalo tyrime analizavo balsę „a“, o kalbos signalo analizė atliekama fonetiškai subalansuotam lietuvių kalbos sakiniui „turėjo senelė žilą oželį“. Autoriai analizei naudojo 22 skirtingus ir gerai žinomus požymių rinkinius iš šių požymių išskyrimo įrankių: „OpenSMILE“, „Essentia“, „MPEG7“, „YAAFE“, „KTU“, „jAudio“, „Tsanas“. Lyginant su ankstesniais tyrimais (daugiausia naudota 176 įrašai), naudojamos žymiai (du kartus) didesnės įrašų duomenų bazės: kalbos signalo analizei naudojami 375 subjektų įrašai ir balso signalo analizei 383 įrašai. Gauti rezultatai atskleidė, jog naudojant atviro kodo „Essentia“ kadrinių požymių rinkinį pasiekiami geriausi rezultatai, t. y. pasiektas didžiausias Parkinsono ligos atpažinimo tikslumas iš balsės 83.7%, o sakinio 86.7%.

Kitame (2017 m.) tyrime, E. Vaičiukynas ir kt. [18] naudojo tos pačios balsės ir sakinio analizę, tačiau įrašai analizuoti lyginant 18 požymių rinkinių naudojant du skirtingus (profesionalų ir išmanaus telefono) mikrofonus. Duomenų bazė naudota tyrimui mažesnė nei ankstesnio tyrimo ir kiekvienam mikrofono tipui naudoti 99 įrašai. Be balso ir kalbos įrašų dar papildomai naudoti išreikšti ir neišreikšti modalumai iš kalbos įrašų naudojant „PRAAT“ programinį paketą. Tyrimo rezultatai parodė, jog naudojant akustinį kardioidinį mikrofoną, didžiausias pasiekiamas tikslumas su „Essentia“ požymių rinkiniu 79.7%, o naudojant išmanaus telefono mikrofoną didžiausias tikslumas pasiekiamas su „YAAFE“ požymių rinkiniu 74.43%, kai naudojama neišreikšta kalbos įrašo dalis. Prastesnės kokybės įrašams kalbos signalo gaunami rezultatai yra geresni lyginant su balso signalu. Taip pat autoriai pastebi, jog kalbos signalo skaidymas į išreikštą ir neišreikštą dalis yra naudingas naudojant išmanaus telefono mikrofoną. Po visų požymių rinkinių ir skirtingų modalumų apjungimo sprendimo priėmimo lygyje tyrimo rezultatai parodė, jog atitinkamai su akustiniu ir išmanaus telefono mikrofonais pasiekiami tokie tikslumai: 80.73% ir 77%.

2018 metais atliktame E. Vaičiukyno ir kt. [25] tyrime naudoti konvoliuciniai neuroniniai tinklai CNN (angl. *convolutional neural networks*), siekiant ištirti įvairių kalbos signalo segmentų efektyvumą Parkinsono ligos detekcijos uždaviniui. Darbo metu naudotų požymių rinkinį sudarė 9 trumpalaikiai požymiai: melų skalės spektriniai koeficientai (MFSC), pirma laikinė MFSC išvestinė (MFSC_Δ), antroji laikinė MFSC išvestinė (MFSC_{ΔΔ}), Levinson'o Durbin'o atspindžio koeficientai (LRC), balso trakto ploto koeficientai (VTAC) [26], dviejų nuoseklių balso trakto vamzdelių ploto santykis apskaičiuojamas tarp kadrų (VTAC_R), dažnių spektriniai koeficientai (FSC), tiesinės prognozės koeficientai (LPCC) ir MFCC. Eksperimentų rezultatai parodė, jog EER įverčio variacija priklausomai nuo segmento kinta ribose nuo 29.5% žodžiui „turėjo“ iki 20.3% žodžiui „žilą“. Tai leido suprasti, jog kai kurios kalbos įrašo dalys yra reikšmingesnės nei kitos, siekiant atlikti ligos detekcijos uždavinį. Geriausias rezultatas pasiektas skaidant sakinį į dalis 85.9%, o neskaidant 83.2%. Autoriai taip pat pastebi, jog skaidant kalbos signalą į keletą persidengiančių segmentų ir vėliau apjungiant sprendimus gautus iš kiekvieno segmento, padeda pagerinti Parkinsono ligos aptikimą. Skaidymas į segmentus šiame darbe buvo atliktas rankiniu būtu (neautomatizuotai), o gauti rezultatai nepagerino ankstesnių tyrimų rezultatų [17] lietuvių kalboje.

A. Šimulis ir kt. [19] atliko akustinės analizės tyrimą balsei „a“. Signalo dekompozicijai naudojo 2 metodus: dekompoziciją į empirinius komponentus EMD (angl. *empirical mode decomposition*) ir dekompoziciją į variacinius komponentus VMD (angl. *variational mode decomposition*). Gautų komponentų suspaudimui panaudojo perceptualiai adaptuotus tiesinius prognozės kepsstrinius koeficientus PLPCC (angl. *perceptual linear predictive cepstral coefficient*). PLPCC koeficientų suspaudimui naudojo 13 pagrindinių statistinių funkcijų, o klasifikatoriui atsitiktinį mišką. Tyrimo rezultatai parodė, jog naudojant tik PLPCC požymius, be EMD ir VMD komponentų, pasiekiamas sistemos tikslumas 67.1% kai lango trukmė 30 ms, po EMD ir VMD komponentų apjungimo, pasiektas didžiausias sistemos tikslumas 97.79% naudojant tokios pat trukmės lango funkciją. Jautrumo analizė atskleidė, jog atliekant tą pačią užduotį 125 kartus, priklausomai nuo langų skaičiaus (1 ar 3) EER

vidutiniškai kinta atitinkamai nuo 12.13% iki 6.48%, bei didžiausias sistemos tikslumas 93.52% pasiekiamas naudojant 3 vienodai pasiskirstytus langus.

Apibendrinti tyrimų rezultatai gauti iš balso ir kalbos modalumų Lietuvoje pateikiami 2.1 ir 2.3 lentelėse.

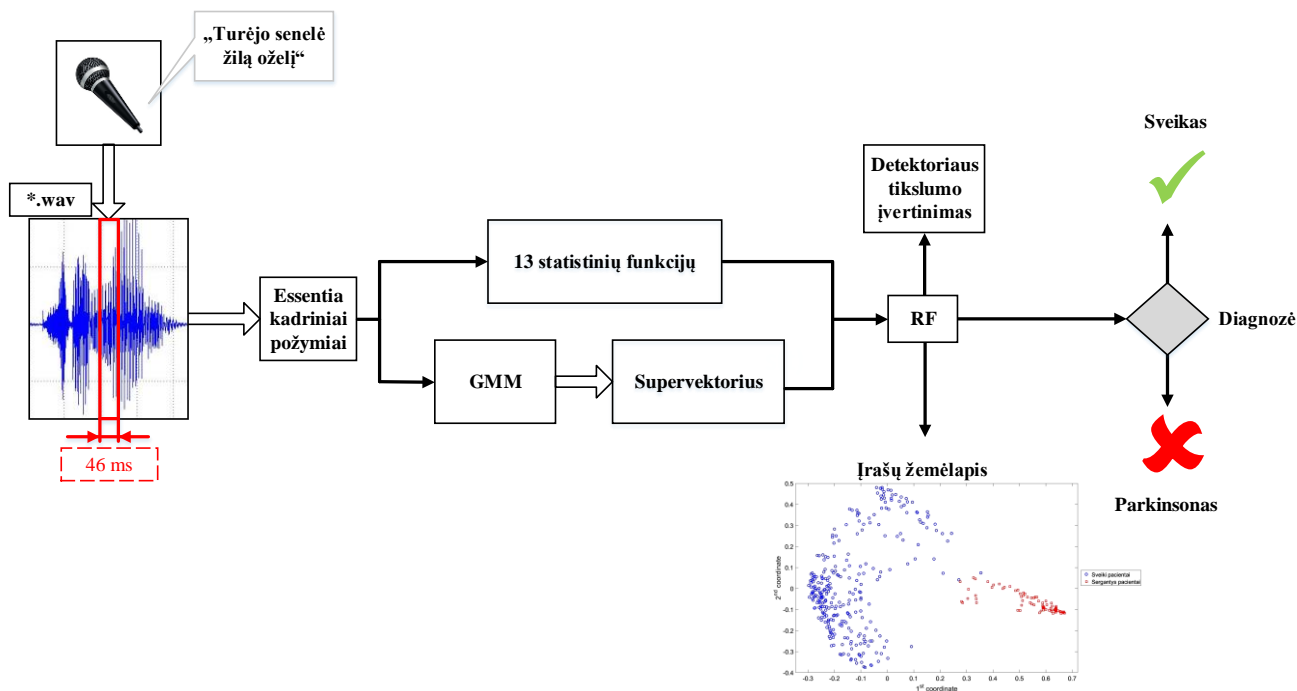
2.3 lentelė. Parkinsono ligos nustatymo iš kalbos signalo palyginimas pagal naudotus požymius ir detektorius

Pavadinimas	Tyrimo dalyvių kalba ir skaičius	Požymiai	Detektorius / Tikslumas	Metai
Tarptautiniu mastu				
T. Bocklet'o ir kt. tyrimas [23]	Vokiečių: • Sergantys – 88; • Sveiki – 88;	MFCC (GMM–UBM)	SVM / 86.5%	2013
J. R. Orozco–Arroyave'o ir kt. tyrimas [24]	Vokiečių: • Sergantys – 88; • Sveiki – 88;	MFCC (GMM–UBM)	78.9%	2016
		MFCC, BBE	97.8%	
		64 požymiai: 18 kalbos trukmei; 28 centriniam dažniui; 18 energijai;	83.9%	
	Čekų: • Sergantys – 20; • Sveiki – 16;	MFCC (GMM–UBM)	80.6%	
		MFCC, BBE	93.6%	
		64 požymiai: 18 kalbos trukmei; 28 centriniam dažniui; 18 energijos;	78.7%	
	Ispanų: • Sergantys – 50; • Sveiki – 50;	MFCC (GMM–UBM)	82%	
		MFCC, BBE	97%	
		64 požymiai: 18 kalbos trukmei; 28 centriniam dažniui; 18 energijos;	77%	
Lietuvos mastu				
E. Vaičiukyno ir kt. tyrimas [17]	Lietuvių: • Sergantys – 74; • Sveiki – 301;	22 skirtingi požymių rinkiniai	RF / 86.7%	2016
E. Vaičiukyno ir kt. tyrimas [18]	Lietuvių: • Sergantys – 64; • Sveiki – 35;	18 skirtingų požymių rinkinių	RF / 79.7%	2017
E. Vaičiukyno ir kt. tyrimas [25]	Lietuvių: • Sergantys – 74; • Sveiki – 194;	MFSC, MFSC _Δ , MFSC _{ΔΔ} , LRC, VTAC, VTAC _R , FSC, LPCC, MFCC	CNN / 85.9%	2018

2.3. Siekiamo sprendimo apibrėžimas

Darbe nagrinėjamas automatizuotas Parkinsono ligos detekcijos iš kalbos signalo procesas. Norima pagerinti ligos atpažinimo rezultatus iš kalbos signalo lietuvių kalboje, panaudojant Gauso mišinių modelį informacijos kadrų suspaudimui bei palyginti gaunamus rezultatus su 13 pagrindinių statistinių funkcijų. Siekiama sukurti įrankį, leidžiantį vartotojui įkeliant į sistemą kalbos įrašą gauti Parkinsono ligos tikimybę.

Tyrimui naudojami komponentai pateikiami 2.1 paveiksle. Analizės procesas pradedamas nuo įrašo įkėlimo į sistemą, tuomet jis išskaidomas į informacijos kadrus (46 ms trukmės), panaudojant lango funkciją. Kiekvienam kadru sudaromas požymių vektorius, gaunamas kadrinių požymių išskyrimo (naudojant Essentia biblioteką) proceso metu. Požymių vektorių kiekis dėl skirtingos įrašo trukmės gaunamas skirtingas. Siekiant aprašyti kiekvieno požymio skirstinį, naudojamas informacijos kadrų suspaudimas su Gauso mišinių modeliu arba statistinių funkcijų rinkiniu.



2.1 pav. Tyrimo proceso eiga

Atsitiktinio miško panaudojimas detekcijai, leidžia identifikuoti sveikus ir sergančius subjektus su išskaičiuojamu EER, taip nustatant sistemos tikslumą. Duomenų pateikimui grafiškai, panaudojamas multidimensinių skalių algoritmas, kurio naudojimas leidžia apskaičiuoti dvimates koordinates. Detektorius pateikia galutinį įvertinimą – diagnozę, kuri nustatoma pagal gautus rezultatus t.y., jei gaunama Parkinsono ligos tikimybė pagal parinktą slenksčių patenka į pirmąjį diapazoną (pvz. (0 ; 40)%), subjektui skiriama diagnozė – sveikas, jei gauta tikimybė patenka į antrąjį diapazoną (pvz. [40 ; 100)%), tuomet skiriama diagnozė – Parkinsonas. Tokia įrašo analizė sudaro ekspertinę sistemą, kuri automatiškai pagal apibrėžtus diapazonus atskiria sveikus ir sergančius subjektus. Apjungiant siūlomus metodus į bendrą visumą, siekiama pagerinti Parkinsono aptikimo rezultatus iš kalbos signalo. Darbo metu norima sukurti ekspertinę sistemą, leidžiančią naudotojui atlikti kalbos signalo apdorojimo analizę ir gauti Parkinsono ligos tikimybę, taip prisidedant prie ankstyvosios ligos stadijos aptikimo.

2.4. Analizės išvados

1. Literatūros apžvalgos analizė parodė, jog daugelis tyrėjų mano, kad akustinė analizė yra svarbi neinvazinė priemonė Parkinsono ligos aptikimui. Akustinė analizė turėtų spręsti regresijos (ligos sunkumo prognozavimas keleto balų skalėje, remiantis balso funkcijos įvertinimu iš įrašų) arba klasifikavimo (ligos aptikimas suskirstant įrašus į sveikų ir sergančių subjektų atvejus) uždavinį.
2. Parkinsono ligos aptikimui naudojamos įvairios užduotys tokios kaip nepertraukiama balsės fonacija, skiemenų kartojimas (pvz. pa-ta-ka), tekstų ir monologų skaitymas. Ankstesniuose tyrimuose nebuvo išspręstos tokios problemos kaip pakankamai tvirtų funkcijų ir/ar metodų radimas, iš kurių būtų galima aptikti Parkinsono ligą skirtingomis kalbomis, bei atlikta mažai tyrimų, kuriuose būtų lyginama įtaka detekcijos tikslumui, kai duomenys įrašyti skirtingais mikrofonais: profesionaliu ir vidiniu išmanaus telefono.
3. Nekorektiškas tikslumo įvertinimas yra dažnai pasitaikanti problema atliekant ligos detekciją iš balso signalo, kuomet sistema apmokoma ir testuojama su tuo pačiu subjektu, nors visi to subjekto įrašai turėtų būti įtraukiami tik arba į apmokymo, arba į testavimo fazę, bet ne į abi, nes gautas tikslumas gali rodyti ne ligos aptikimo tikslumą, o kiek tiksliai sistema atpažįsta tą patį subjektą.
4. Kita dažna problema, leidžianti abejoti rezultatų patikimumu – tai mažos naudotos duomenų bazės, kai tyrimui naudojama mažiau nei 60 sergančių subjektų atvejų.

3. TYRIMO METODAI

Šiame skyriuje analizuojamas Parkinsono ligos detekcijos iš kalbos signalo apdorojimo procesas, gaunamų rezultatų įvertinimas ir jų specifika, taikomi metodai prototipo kūrimui.

3.1. Kadrinių požymių išskyrimas

Naudojant įvairius signalų analizės metodus galima išskirti informaciją, dar vadinamą požymiais, esančią balso ar kalbos signalo įrašuose. Priklausomai nuo signalo trukmės, kadriniai požymiai gali būti skirstomi į:

- globalius požymius: ilgalaikius arba įrašo trukmės arba aukšto lygio požymius;
- lokalius požymius: trumpalaikius arba kadro trukmės arba žemo lygio požymius LLD (angl. *low-level descriptors*).

Lokalūs požymiai išskiriami padalijant įrašą į trumpus ir dažnais atvejais persidengiančius segmentus (kadrus ar langus), tuomet taikant įvairius algoritmus išskaičiuojami požymiai kiekvienam segmentui. Gauti trumpalaikiai požymiai vėliau yra spaudžiami į globalius, taikant įvairias statistines funkcijas.

3.1.1. *Essentia* audio požymiai

Essentia C++ kalbos atviro kodo garso analizės įrankis leidžia išskirti 1915 (17 globalių + 146×13 lokalių) požymius. Detalus požymių sąrašas:

- 1 globalus žemo lygio (angl. *lowlevel*) tipo požymis – vidutinis garsumas;
- 16 globalių *sfx* tipo požymių: 5 laikiniai (požymių vidurkis (centroidas), mažėjimas, ekscesas, asimetrija, pasiskirstymas), 4 morfologiniai (santykis tarp maksimalios signalo gaubtinės vertės ir viso gaubtinės ilgio, santykis laiko vidurkio su signalo gaubtinės ilgiu, svertinis vidurkis gaunamas po maksimalios amplitudės, maksimali reikšmė prieš maksimalią amplitudę), centroido aukštis, stiprus skilimas, plokštumas, logaritminė garso signalo gaubtinės pradžios laiko išraiška, santykis tarp maksimalios garso signalo gaubtinės reikšmės ir viso signalo gaubtinės ilgio, santykis tarp minimalios garso signalo gaubtinės reikšmės ir viso signalo gaubtinės ilgio, santykis garso signalo energijos gaunamas prieš maksimalią vertę ir po maksimalios vertės);
- 141 lokalūs žemo lygio požymiai: spektro energija 77–iuose diapazonuose (28 dažnio diapazonai, 4 žemo/vidutinio–žemo/vidutinio–aukšto/aukšto dažnio diapazonai, 18 ekvivalentinių stačiakampio formos juostų ERB (angl. *Equivalent Rectangular Bandwidth*) diapazonų, 27 Barko juostos), 3 spektrinės energijos statistinės funkcijos Barko juostose (ekscesas, asimetrija, pasiskirstymas), 13 gamos dažnių skalės kepstro koeficientai GFCC (angl. *Gammatone-frequency cepstral coefficients*), 13 MFCC, 15 spektro požymių (energija, entropija, sudėtingumas, centroidas, stiprus pikas, viršūnė, Masri ir Batemano aukšto dažnio turinio matavimas, vidutinė kvadratinė reikšmė RMS, dažnio perdavimo funkcijos statusas, mažėjimas, plokštumas decibelais, nuolatinis kitimas, ekscesas, asimetrija, pasiskirstymas), 6 spektro kontrastai, 6 spektro kontrastų amplitudės, 3 susiję aukščiai (aukštis, momentinė aukščio reikšmė, aukščio iškilimas), tylos garso lygių dažnumas (kai garso lygis 20 dB, 30 dB, 60 dB), neatitikimas, nulio kirtimo dažnumas;
- 5 lokalūs *sfx* tipo požymiai: 3 pagrindinių spalvų reikšmės, dalinių dažnių nukrypimo nuo pagrindinio dažnio kartotinių harmonikų laipsnis, lyginių–nelyginių harmonikų energijos santykis.

Tyrimui bus naudojami tik lokalūs (iš įrašo signalo kadru gaunami) požymiai, o tono ir ritmo požymiai iš žemo lygio ir *sfx* požymių grupių, bei globalūs požymiai nebus naudojami. Globalūs suformuojami panaudojant 13 statistinių funkcijų ir GMM metodą. Požymių išskyrimas naudojant *Essentia* biblioteką atliekamas šiais žingsniais:

- kiekvienam įrašo failui turi būti sudaryta komandinė eilutė, kurioje aprašytas kelias iki įrašo failo, iki požymių ištraukimo failo ir nurodyta direktorija įrašo išsaugojimui;
- kiekvienam įrašui išskleidimo metu (vykdant komandinę eilutę) sudaromas JSON formato tipo failas su apskaičiuotais požymiais;
- iš kiekvieno sudaryto JSON tipo failo pasirenkami požymiai ir kiekvienas požymis spaudžiamas naudojant statistines funkcijas arba GMM, taip sudarant suspaustų požymių matricą įrašui;
- sudarytos suspaustų požymių matricos apjungiamos į bendrą požymių matricą reprezentuojančią visus įrašus, bei galutinė matrica detekcijos atlikimui išsaugojama csv failo formatu.

3.2. Požymių vektoriaus sudarymas

3.2.1. 13 statistinių funkcijų

Lokalūs požymiai gali būti spaudžiami į globalius požymius naudojant įvairias statistines funkcijas: minimumą, maksimumą, aritmetinį vidurkį, medianą, apatinį kvartilį (pirmąjį kvartilį), viršutinį kvartilį (antrąjį kvartilį), triskaitį vidurkį, standartinį nuokrypį, tarpkvartilinį plotį, apatinį ruožą, viršutinį ruožą, asimetrijos koeficientą, eksceso koeficientą. Visos išvardintos 13 statistinių funkcijų plačiau detalizuojamos sekančiai:

- minimumas (angl. *min*) – skaičiuojama mažiausia masyvo elementų reikšmė;
- maksimumas (angl. *max*) – skaičiuojama didžiausia masyvo elementų reikšmė;
- aritmetinis vidurkis (angl. *mean*) – skaičiuojamas masyvo elementų vidurkis:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i; \quad (1)$$

čia x_i – masyvo elementas, n – masyvo imties dydis.

- mediana (angl. *median*) – skaičių aibės centrinė, vidutinė ar vidurinė reikšmė, apskaičiuojamas:

$$M_d = \begin{cases} x_{(n+1)/2}, & \text{kai } n - \text{nelyginis} \\ \frac{x_{(n/2)} + x_{(n/2+1)}}{2}, & \text{kai } n - \text{lyginis} \end{cases}; \quad (2)$$

čia n – masyvo imties dydis.

- apatinis kvartilis (angl. *lower quartile*) – vidurinis skaičius tarp mažiausio skaičiaus ir medianos duomenų aibėje, apskaičiuojamas pagal formulę:

$$Q1 = \frac{n+1}{4}; \quad (3)$$

- viršutinis kvartilis (angl. *upper quartile*) – vidurinis skaičius tarp didžiausio skaičiaus ir medianos duomenų aibėje, apskaičiuojamas pagal formulę:

$$Q3 = \frac{3(n+1)}{4}; \quad (4)$$

- triskaitis vidurkis (angl. *trimean*) – svertinis vidurkis tarp medianos ir jos abiejų kvartilių, naudojamas asimetrinių reikšmių skirstiniams:

$$\text{Triskaitis vidurkis} = \frac{Q1 + M_d + Q3}{4}; \quad (5)$$

- standartinis nuokrypis (angl. *standard deviation*) – atsitiktinio dydžio įgyjamų reikšmių sklaida apie vidurkį, apskaičiuojamas:

$$s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}}; \quad (6)$$

- tarpkvartilinis plotis (angl. *inter-quartile range*) – skirtumas tarp antrojo ir pirmojo kvartilų, naudojamas apskaičiuoti duomenų sklaidai:

$$IQR = Q3 - Q1; \quad (7)$$

- apatinis ruožas (angl. *lower range*) – skirtumas tarp medianos ir pirmojo kvartilio (mediana – Q_1);
- viršutinis ruožas (angl. *upper range*) – skirtumas tarp trečiojo kvartilio ir medianos (Q_3 – mediana);
- asimetrijos koeficientas (angl. *skewness*) – skirstinio grafines funkcijos simetrijos matas. Kai $A > 0$, skirstinys turi teigiamą (dešiniąją) asimetriją, kai $A < 0$, skirstinys turi neigiamą (kairiąją) asimetriją, kai $A = 0$, skirstinys simetriškas.

$$A = \frac{1}{ns^3} \sum_{i=1}^n (x_i - \bar{x})^3; \quad (8)$$

čia n – masyvo imties dydis, s – standartinis nuokrypis, x_i – masyvo elementas, \bar{x} – aritmetinis vidurkis.

- eksceso koeficientas (angl. *kurtosis*) – charakteristika, naudojama įvertinti histogramos lėkštumą. Kai $E > 0$, skirstinio grafiko viršūnė yra aštresnė ir aukštesnė nei normaliojo skirstinio, kai $E < 0$, skirstinio grafiko viršūnė yra lėkštesnė ir žemesnė nei normaliojo skirstinio. Jei $E = 0$, skirstinio duomenų koncentracija apie vidurkį yra tokia pati kaip ir normaliojo skirstinio.

$$E = \frac{1}{ns^4} \sum_{i=1}^n (x_i - \bar{x})^4 - 3; \quad (9)$$

3.2.2. Gauso mišinių modelis

Kalbos signalo modeliavimas per paskutinius 40 metų pasikeitė iš esmės: nuo diskretaus vektoriaus kvantavimo (VK) grindžiamų sistemų iki adaptuotų Gauso mišinių modelių. GMM yra statistinių požymių kitimo modeliavimo metodas ir kartu vienas iš populiariausių kalbos signalo modeliavimo metodų, naudojamų informacijos kadrams suspausti [27].

GMM aprašomas pasiskirstymo tankio funkcija, kurią galima išreikšti formule:

$$p(\vec{x}|\lambda) = \sum_{i=1}^M p_i b_i(\vec{x}); \quad (10)$$

čia \vec{x} – atsitiktinis vektorius, $b_i(\vec{x})$ – komponentių tankiai, p_i – apriorinė tikimybė, $i=1, 2, 3, \dots$, M – Gauso komponentų skaičius.

Kiekvienas komponentės tankis $b_i(\vec{x})$ yra Gauso funkcija, išreiškiama formule:

$$b_i(\vec{x}) = \frac{1}{(2\pi)^{D/2} |\sum_i|^{1/2}} e^{-\frac{1}{2}(\vec{x}-\vec{\mu}_i)^T \sum_i^{-1} (\vec{x}-\vec{\mu}_i)}; \quad (11)$$

čia $\vec{\mu}_i$ – atsitiktinis vektorius, \sum_i – kovariacinė matrica.

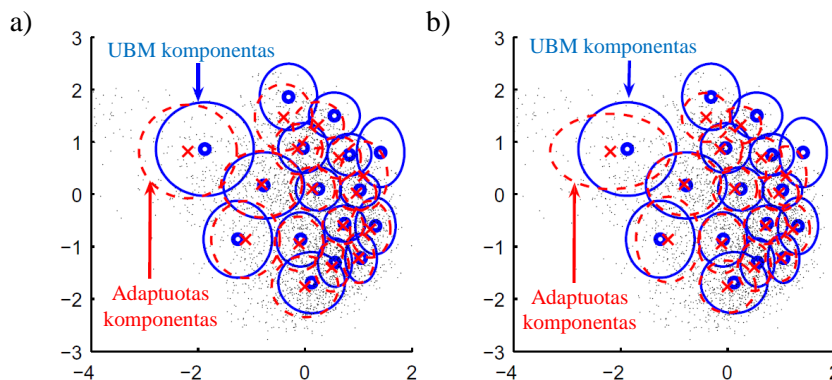
Apriorinės tikimybės turi tenkinti apribojimus:

$$\sum_{i=1}^M p_i = 1; \quad (12)$$

Pasiskirstymo modelio parametrai parametrizuojami apriorinėmis tikimybėmis (mišinių svoriu), atsitiktiniais vektoriais, kovariacinėmis matricomis. Visi šie parametrai yra atstovaujami tam tikru kalbėtojo parametrų rinkiniu:

$$\lambda = \{ p_i, \vec{\mu}_i, \Sigma_i \} \quad i = 1, 2, \dots, M; \quad (13)$$

Priklausomai nuo skirtingų kalbėtojų, aplinkų, kalbėjimo stilių atsiranda duomenų pokyčiai, todėl kalbos signalo tyrimo modelis turi užtikrinti modelio adaptaciją prie naujų sąlygų. Pagrindiniame GMM kalbančiojo atpažinimo modelyje, nepriklausomas kalbančiojo modelis arba UBM iš pradžių turi būti apmokomas EM (angl. *expectation–maximization*) algoritmu, sudarytu iš daugybės valandų trukmės kalbos įrašų [27]. Kiekvieną kartą atliekant naujo kalbančiojo su sistema tyrimą, pamatinio modelio parametrai adaptuojami prie naujo kalbėtojo požymių skirstinio. Naujas adaptuotas modelis naudojamas kaip kalbėtojo modelis. Tokiu būdu modelio parametrai kiekvieną kartą nėra kuriami nuo nulio, vietoj to naudojami iš anksto žinomi kalbos duomenys. Praktikoje dažnai naudinga apmokyti sistemą su dviem pamatiniais modeliais (UBM) suskirstant į: vyrų ir moterų kategorijas. Naujas kalbėtojo modelis adaptuojamas iš pamatinio modelio tokia pačia lytimi kaip ir naujas kalbėtojas. Taikant MAP metodą yra įmanoma adaptuoti pamatinio modelio visus parametrų rinkinio parametrus arba keletą iš jų, kaip pavaizduota 3.1 paveiksle. Mėlynos spalvos elipsės vaizduoja UBM Gauso komponentus, raudoni taškeliai vaizduoja kalbėtojo duomenis, o raudonos elipsės sukurtą kalbėtojo modelį. Pakeičiant rinkinio λ visus parametrus keičiasi modelio elipsės forma ir pozicija, o pakeitus keletą parametrų, keičiama elipsės pozicija.



3.1 pav. GMM adaptacija panaudojant MAP principą. a) kai pakeisti keli rinkinio λ parametrai, b) kai pakeisti visi rinkinio λ parametrai. Šaltinis: [28]

Nustatyta, jog praktikoje naudinga naudoti tik adaptuotus vidurkius [28]. MAP adaptacijos dėka galima atsisakyti kovariacijos matricos (kuri yra GMM dalis), nes ji nėra adaptuojama ir naudoti tik adaptuotus vidurkius.

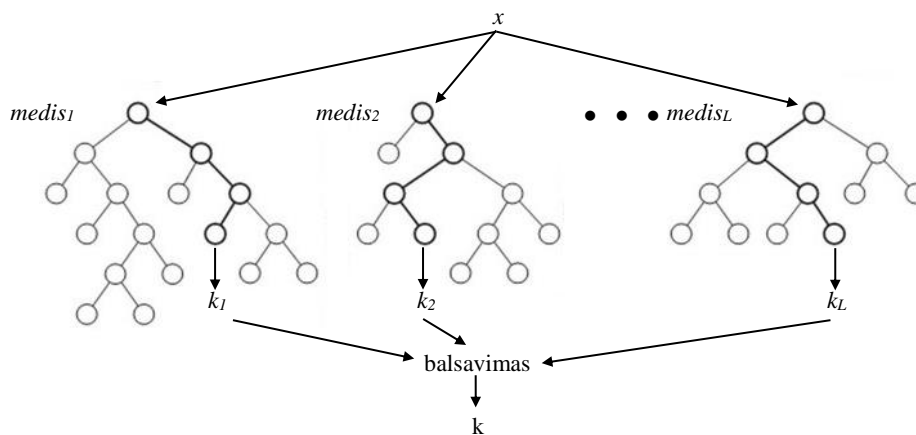
3.3. Detekcija

3.3.1. Atsitiktinis miškas

Parkinsono ligai aptikti panaudojamas populiarus klasifikatorius – atsitiktinis miškas, susidedantis iš medžių struktūros klasifikatorių $\{h(x, \Theta_k), k = 1, \dots\}$, kur $\{\Theta_k\}$ yra nepriklausomi, vienodai pasiskirstę atsitiktiniai vektoriai, o galutinis sprendimas yra priimamas medžių balsų daugumos. Pagrindinė atsitiktinio miško suformavimo idėja yra sujungiant daugelį (iš viso L) sprendimų medžių (kurie yra CART (angl. *classification and regression trees*) tipo), užaugintų naudojant skirtingus duomenų poaibius iš originalių duomenų aibės, bei atsitiktinai parinktus požymių poaibius (iš anksto nustatyto dydžio q) iš požymių rinkinio x^1, \dots, x^p , sudaryti tikslų klasifikatorių. 3.2

paveiksle pateikiamas atsitiktinis miškas sudarytas iš L medžių. Atsitiktinis miškas pasižymi atsparumu persimokymui (savirankos (angl. *bootstrap*) dėka) ir didėjant medžių skaičiui, klasifikavimo klaida stabilizuojasi [29]. RF sudaromas remiantis šiais žingsniais:

1. pasirenkamas atsitiktinio miško dydis L (medžių skaičius) ir erdvės dydis pagal požymių skaičių $q \leq p$ kiekvieno medžio konstravimui;
2. duomenų savirankos imtis sudaroma naudojant atsitiktinį duomenų parinkimą, kur apmokymui paimama $\sim \frac{2}{3} \cdot n$ (n yra stebėjimų skaičius) unikalių stebėjimų, o testavimui paliekant $\sim \frac{1}{3} \cdot n$;
3. negenėti medžiai auginami naudojant savirankos imtį. Auginant medį, kiekvienam mazgui atsitiktinai parenkami q kintamieji iš p požymių;
4. 2 ir 3 punktai kartojami kol pasiekiamas miško medžių skaičius L .



3.2 pav. Atsitiktinio miško struktūra

Rezultatų apskaičiavimas įvertinamas naudojant *OOB* klaidų lygio įvertį, kuris apskaičiuojamas naudojant stebėjimus, neįtrauktus į atsitiktinio miško formavimą (atsitiktinio miško sudarymo metu įsimenami medžio konstravimo stebėjimai). *OOB* patvirtinimas suteikia objektyvų bandymų klaidų įvertinimą, panašų į naudojamą „palikti–vieną–išorėje“ schemeje.

3.3.2. Detektoriaus sprendimo formavimas

Individualūs atsitiktiniai miškai buvo sukurti nepriklausomai nuo duomenų rinkinių ir šių algoritmų sprendimai yra sujungti duomenų apmokymo būdu. Atsitiktinis miškas buvo naudojamas ir kaip pagrindinis, ir kaip sprendimus sujungiantis algoritmas, todėl gauname, jog atsitiktinio miško pirmojo etapo išėjimai yra traktuojami kaip antrojo etapo įėjimai. Priklausymo Parkinsono klasei tikimybė detekcijos uždavinyje apskaičiuojama:

$$d(\{t_1, \dots, t_L\}, x) = \frac{\sum_{i=1}^L f(t_i, x, q=2)}{L}; \quad (14)$$


čia x – klasifikuojamas objektas, L – medžių skaičius t_1, \dots, t_L atsitiktiniame miške, q – klasės identifikatorius (1 – sveiki, 2 – sergantys Parkinsono liga), $f(t_i, x, q)$ – atitinka q -tąją klasės dažnį lapo taške, į kurį x krenta į t_i medį miške:

$$f(t_i, x, q) = \frac{n(t_i, x, q)}{\sum_{j=1}^Q n(t_i, x, q_j)}; \quad (15)$$

čia Q – klasių numeris, $n(t_i, x, q)$ – numeris apmokytų duomenų iš klasės q ir krentantis į tą patį lapo tašką t_i , kaip ir x .

3.3.3. RF detektoriaus tikslumo įvertinimas

Detektoriaus tikslumui įvertinti naudojami OOB duomenys. Atsitiktinio miško balsai konvertuojami į klasių tikimybių rezultata normalizuojant specifinės klasės balsus per bendrą medžių skaičių, kuriems tas atvejis pakliuvo į OOB imtį pagal (14) išraišką. Tolydinės klasės tikimybės panaudojimas vietoj klasės prognozės leidžia atlikti detalesnį detektoriaus tikslumo vertinimą, kuris gali būti reziumuojamas DET kreive vizualiai [30]. DET kreivė gaunama tolydiniam įverčiui išmėginant įvairius slenksčius – jei klasės tikimybė yra virš slenksčio, tai spėjama kad tai ir yra ta klasė, o jei žemiau slenksčio, kad nėra ta klasė. DET kreivė pateikiama 3.3 paveiksle.



3.3 pav. Detektoriaus tikslumo vertinimo DET (kairėje) ir ROC (dešinėje) kreivės

Detektorius su skirtingomis DET kreivėmis galima greitai palyginti pusiausvyros taške, kur kreivė kertama įstrižai EER. Kuo arčiau kairiojo apatinio kampo bus kreivė, tuo geresnis bus detektorius. Kitas dažnas naudojamas būdas atvaizduoti klaidingai teigiamų ir teisingai teigiamų rezultatų dalis yra ROC (angl. *receiver operating characteristic*) kreivė. Vertinant ROC kreives vizualiai, galima palyginti skirtingus detektorius, t. y. kuo arčiau viršutinio kairiojo kampo bus kreivė, tuo geresnis bus detektorius. Tačiau kartais būna sunku palyginti kreives vizualiai. Yra daug įvairių skaičiavimų metodų, kurie visą kreivę įvertina vienu skaičiumi, siekiant palyginti skirtingas kreives. Dažnai naudojamas plotas po ROC kreive AUC (angl. *area under the curve*) [31]. DET kreivė ir EER matavimai apskaičiuojami naudojant ROC išgaubtos kreivės metodą, kuris pateikiamas BOSARIS rinkinyje [32]. Tinkamai sukalibruoto ir naudingo detektoriaus sąlyga jog $EER < 50\%$, o $AUC > 0.5$.

3.3.4. Sumaišymų matrica ir jos vertinimas

Teisingai ir neteisingai klasifikuotų sveikų ir sergančių subjektų atvejų skaičių galima pateikti sumaišymo matrica (angl. *confusion matrix*) [33], kuri pateikiama 3.1 lentelėje. Šioje matricoje galimos keturios rezultatų reikšmės skaičiuojant rezultatus dviem klasėms. Jei tikros pirmos klasės objektas buvo suklasifikuotas kaip priskirtos pirmos klasės objektas, tuomet jis skaičiuojamas kaip teisingai teigiamas tp , priešingu atveju kaip klaidingai neigiamas fn . Jei tikros antros klasės objektas suklasifikuotas kaip priskirtos antros klasės objektas, jis skaičiuojamas kaip teisingai neigiamas tn , priešingu atveju kaip klaidingai teigiamas fp .

3.1 lentelė. Sumaišymo matrica

		Tikra klasė		Iš viso
		1 klasė	2 klasė	
Priskirta klasė	1 klasė	tp	fp	$tp + fp$
	2 klasė	fn	tn	$fn + tn$
Iš viso		$tp + fn$	$fp + tn$	n

Matricos pagrindinė (kertanti matricos elementus nuo viršutinio kairiojo kampo iki apatinio dešiniojo) įstrižainė rodo teisingus atvejus, o šalutinė (kertanti matricos elementus nuo viršutinio dešiniojo kampo iki apatinio kairiojo) rodo kiekvienos klasės klaidas. Apskaičiuotus pagrindinius parametrus nurodytus 3.1 lentelėje ir sudarius sumaišymo matricą, toliau skaičiuojami papildomi įvertinimai kurie pateikiami 3.2 lentelėje, reikalingi detalesnei analizei.

3.2 lentelė. ROC kreivių papildomi įvertinimai [34, 35]

Pavadinimas	Formulė	Aprašymas
Jautrumas	$\frac{tp}{tp + fn}$	Teisingai atpažintų pirmos klasės objektų ir visų tikros pirmos klasės objektų santykis
Specifiškumas	$\frac{tn}{fp + tn}$	Teisingai atpažintų antros klasės objektų ir visų tikros antros klasės objektų santykis
PPV	$\frac{tp}{tp + fp}$	Teigiama prognozuojama vertė (preciziškumas)
NPV	$\frac{tn}{tn + fn}$	Neigiama prognozuojama vertė
Bendras tikslumas	$\frac{tp + tn}{tp + fn + fp + tn}$	Teisingai identifikuotų sveikų ir sergančių subjektų įrašų ir visų abiejų klasių įrašų santykis

3.3.5. Požymių įtakos įvertinimas

Atsitiktinio miško požymių įtakos matavimai dažnai naudojami požymių išrinkimui turint didelių matmenų duomenis, kai reikia įvertinti kiekvieno požymio įtaką gaunamiems rezultatams. Požymių svarbos VI (angl. *Variable Importance*) modeliai požymių išrinkimui atsitiktiniame miške yra du [36]: „Gini“ požymių svarbos matavimas ir požymių pakeitimo svarbos matavimas. „Gini“ idėja yra sumuoti „Gini“ priemaišų sumažėjimą, kurios yra sugeneruojamos požymio, renkantis jį dalinimo procesui. Pakeitimų VI matavimas grąžina požymių klaidų dydžio įverčius. Pakeitimų požymių svarbos matavimas matuoja skirtumą tarp OOB klaidų įverčio prieš ir po požymių verčių pakeitimą. Tuomet VI apskaičiuojamas pagal formulę:

$$VI_j^{ER} = \frac{1}{n_m} \sum_{k=1}^{n_m} (ER_{k_j} - ER_{kj}); \quad (16)$$

čia n_m – medžių skaičius miške; ER_{k_j} – vidutinis klaidų įvertis per visus OOB stebėjimus medyje k , po atsitiktinio požymio j pakeitimo; ER_{kj} – vidutinis klaidų įvertis per visus OOB stebėjimus medyje k , prieš pakeičiant požymį j .

Pagrindinė šių skaičiavimų idėja yra: jei požymis nėra susietas su atsaku, tuomet vertės pakeitimas neturi įtakos klasifikacijai ir taip pat neturi įtakos klaidos įverčiui. Miško klaidos įvertis nėra iš esmės paveikiamas pakeitimo ir požymio vertė tampa artima nuliui, ir tai rodo, jog nėra ryšio tarp požymio ir atsako. Jei atsakas ir požymis yra tarpusavyje susieti, tuomet požymio vertės pakeitimas panaikina ryšį ir pakenkia klasifikavimo tikslumui. Jei skirtumas tarp klaidos įverčių prieš ir po atsitiktinai pakeičiant požymį yra žymus, tuomet požymio VI reikšmė įgyja teigiamą reikšmę ir taip rodo aukštą požymio įtaką.

Požymių pakeitimų svarbos matavimas pateikiamas (16) formulėje nekorektiškai vertina rezultatus, kuomet tiriamos klasės (sveiki ir sergantys Parkinsono liga subjektai) yra nesubalansuotos, t. y. vienos klasės duomenų yra daugiau nei kitos. Šiai problemai spręsti buvo pasiūlyta idėja [36] pakeisti klaidų įvertį ER į AUC. Tuomet gauname tokią išraišką:


$$VI_j^{ER} = \frac{1}{n_m^*} \sum_{k=1}^{n_m^*} (AUC_{k_j} - AUC_{kj}); \quad (17)$$

čia n_m^* – miško medžių skaičius, kur OOB stebėjimai turi stebėjimus iš abiejų klasių; AUC_{kj} – plotas po ROC kreive gauta iš OOB stebėjimų k medyje prieš pakeičiant požymį j ; AUC_{kj} – plotas po ROC kreive gauta iš OOB stebėjimų k medyje po atsitiktinio požymio j pakeitimo.

ROC rodo tą pačią informaciją kaip ir DET kreivė, tik DET kreivėje abiejose ašyse yra klasių klaidos ir ašys logaritminės. AUC vertė yra lygi 1, kai turime idealų medžio klasifikatorių. Idealus klasifikatorius būtų, jei kiekvienas stebėjimas klasifikavimo metu pakliūtų į savo klasę. Kai AUC vertė yra lygi 0.5, tuomet turime nenaudingą klasifikatorių, kuris atsitiktinai paskirsto klasės tikimybes stebėjimams. AUC skirtingai nei ER, abiem klasėms nepriklausomai nuo jų dydžio, suteikia tokio paties svorio koeficientus. ER skaičiavimo metu, pagrindinei klasei suteikia didesnio svorio koeficientus, todėl kad nėra atsižvelgiama į klasių priklausomybę ir manoma, jog visi netinkami klasifikavimai yra vienodai svarbūs.

3.3.6. Daugiamačių skalių algoritmo naudojimas duomenų vizualizacijai

Daugiamatės skalės MDS (angl. *Multidimensional scaling*) – statistinis metodas naudojamas tirti panašumus tarp objektų. MDS pirmiausia naudojamas duomenų vizualizacijai, siekiant nustatyti bet kokį taškų grupavimą, kur panašūs objektai yra išdėstomi arčiau vieni kitų taip sudarant grupę, o skirtingi toliau nuo kitų. Daugiamačių skalių algoritmo taikymas dviejų matmenų vizualizacijai Parkinsono ligos detekcijos uždaviniui iš kalbos signalo pateikiamas 3.4 paveiksle. Šis metodas susideda iš skirtingų algoritmų, kur kiekvieno algoritmo tikslas sukurti optimalią mažų matmenų konfigūraciją, naudojant tam tikro artumo (angl. *proximity*) duomenis.



3.4 pav. Įrašų išsibarstymas 2D erdvėje naudojant MDS algoritmą

Atsitiktinis miškas skaičiuoja artumo matricą, kuri gali būti naudojama 2 ar 3 matmenų MDS grafinei vizualizacijai gauti, padedant stebėti duomenų pasiskirstymą ir įvairius nukrypimus jei tokių yra. Artumo matricos Φ sudarymas remiasi šiais žingsniais [37]: stebėjimai, atvaizduojantys meta-požymius, perleidžiami per kiekvieną auginamą medį ir matricos elementas φ_{ij} padidinamas vienetu, kai du stebėjimai x_i ir x_j patenka į tą patį to paties medžio tašką. Kai meta-RF yra sudarytas, artumai yra išvedami ir dalinami iš visų meta-RF medžių skaičiaus.

3.4. Įrankiai ir metodai programinio prototipo kūrimui

3.4.1. Programavimo aplinka *Matlab*

Matlab yra interaktyvi kūrimo aplinka sukurta *MathWorks* kompanijos, naudojama milijonų inžinierių ir mokslininkų visame pasaulyje įvairiems skaičiavimams, duomenų analizei ir vizualizacijai, algoritmų kūrimui ir programavimui, aplikacijų kūrimui ir diegimui. *Matlab* taip pat yra aukšto lygio programavimo kalba.

Kriterijai įrankio pasirinkimui:

- aukšto lygio kalba skirta mokslinių ir inžinerinių uždavinių sprendimui;
- didelė gausa vidinių priemonių (*Matlab toolboxes*);
- tvarkingai ir išsamiai paruošta dokumentacija, bei didžiulė bendruomenė;
- leidžia kurti aplikacijas naudojant didelę gausą įvairių algoritmų;
- turi sąsajas su *C/C++*, *Fortran*, *Java*, *Python*, *.NET*;

3.4.1.1. *Matlab* produkcijos serveris

Matlab produkcijos serveris leidžia įtraukti analizę į žiniatinklį, duomenų bazes veikiančias specialiuose serveriuose ar debesyse. Algoritmai sukurti *Matlab* programine įranga, turi būti perkelti į specialų paketą naudojant *Matlab Compiler SDK* ir perkelti į *Matlab* produkcijos serverį be papildomo kodo transformacijų ar specialios infrastruktūros kūrimo. Vartotojai gali automatiškai pasiekti naujausios analizės rezultatų duomenis, naudodami prisijungimą.

Lengvasvorės kliento bibliotekos priklausančios šiam serveriui palaiko *.NET*, *JAVA*, *C/C++* ir *Python* aplinkas. *Matlab* produkcijos serverio *RESTful API* leidžia skaičiuoti funkcijas nutolusiuose serveriuose naudojant *Matlab* duomenų tipų *JSON* reprezentaciją. Kūrėjas gali kurti kliento programas, bet kokio programavimo kalba su *HTTP* biblioteka. Šios sąsajos leidžia sistemų architektams ir programų kūrėjams prijungti *Matlab* analitikas į platų interneto serverių, duomenų bazių, darbalaukio programų ir kitų programų asortimentą. Naudojant serveriais grindžiamą jungimosi sistemą, sistemos administratoriai gali centralizuotai tvarkyti ir atnaujinti analitikas, užtikrinant kad jų vartotojai automatiškai naudotų teisingą versiją. *Matlab* produkcijos serveris palaiko *HTTPS*, kuris užtikrina saugesnę komunikaciją tarp serverio ir kliento.

Matlab Compiler SDK leidžia dislokuoti *MATLAB* pagrįstas aplikacijas daugelyje platformų – nuo atskirų darbatalio aplikacijų individualiems vartotojams, iki plataus masto verslo sistemų. Suteikiama galimybė pasirinkti norimą platformą, remiantis įgyvendinamumo, palaikomumo, programavimo kalbų ir organizacijos pageidavimų aspektais.

Pasirinkimas tyrimo atlikimui: tyrimui nuspręsta naudoti internetinę platformą, dėl galimybės didesniai žmonių ratui lengvu būdu pasiekti numatytą sukurtos sistemos prototipą. Verslo sistema yra atmetama vien dėl savo pobūdžio, o asmeniniams kompiuteriams tinkamos aplikacijos siekiant išvengti aplikacijos įdiegimo etapo.

3.4.1.2. *MATLAB* produkcijos serverio diegimas

Matlab serveris susideda iš serverio programinės įrangos ir lengvasvorių kliento bibliotekų. Programinė įranga gali būti diegiama visose platformose ir operacinėse sistemose kurias palaiko *Matlab*. Kliento bibliotekos gali būti integruojamos su bet kuria palaikoma aplinka ir paskirstomos kaip programos dalis bet kokiam galutinių vartotojų skaičiui. Produkcijos serveris naudoja *Matlab Runtime* variklį, siekiant paleisti supakuotas programas su *Matlab Compiler SDK*. Funkcionuojančiam serverio paleidimui reikia įvykdyti šiuos žingsnius:

- 1) Instaliuoti serveryje *Matlab* produkcijos serverio programinę įrangą;
- 2) Instaliuoti serveryje *Matlab Runtime* variklį;
- 3) Sukurti serverio egzempliorių konkrečiam projektui;
- 4) Atlikti reikiamus sukurtą egzemplioriaus konfigūracijos pakeitimus ir nustatymus reikalingus funkcionavimui;
- 5) Paleisti sukurtą serverio egzempliorių;

3.4.2. Puslapio serveris

Siekiant pasidalinti tyrimo rezultatais su vartotojais bei įgalinti atlikti detekcijos procesą, reikia sukurti vartotojo sąsają. Sukuriant internetinę sąsają, sistema galės naudotis bet kuris vartotojas turintis prieigą prie interneto, taip pat bus išvengiama papildomų programų diegimo ar papildomų kaštų licencijų įsigijimui. *Matlab* produkcijos serveris neatstoja *Matlab* vartotojo sąsajos, tai nėra interneto serveris teikiantis *HTML* puslapius, *JAVA* servletus ar serverių puslapius, taip pat nesuteikia standartinių *REST/SOAP* saityno paslaugos sąsajų, tačiau bet kuri iš šių išvardintų galimybių gali būti teikiama kaip naudotojo sąsajos dalis. Saitynu grindžiamas sistemos paprastai sudaro standartiniai saityno serveriai tokie kaip *Microsoft Internet Information Services*, *Apache Tomcat*, *IBM WebSphere* vartotojo programų dalinimuisi. Vienos populiariausių debesų paslaugų, tokios kaip *Amazon Web Services (AWS)*, *Google Cloud Platform*, *Microsoft Azure* ir *IBM Cloud* leidžia nesudėtingai pasiekti serverius, duomenų saugyklas, duomenų bazines ir įvairias paslaugas ar programas internetu. Pagrindiniai debesų paslaugų teikiami privalumai:

- ekonomiškumas;
- didelės duomenų saugyklos;
- dideli skaičiavimo resursai;
- atsarginių kopijų kūrimas ir saugojimas;
- didelė palaikomų įrenginių įvairovė;
- greitas diegimas, lengva integracija;
- energijos vartojimo efektyvumas;
- papildomos saugumo paslaugos.

Remiantis šiais debesų paslaugų pranašumais, nuspręsta kuriamą prototipą talpinti vienoje iš debesų paslaugų. Kiekviena debesų paslaugų teikėją galime palyginti išskiriant pagrindinius privalumus ir trūkumus:

AWS skaičiavimų pajėgumai penkis kartus didesni nei kitų debesų paslaugų tiekėjų. Yra įvairių duomenų centrų įvairiuosiuose regionuose, tokiuose kaip: JAV, Airija, Japonija, Singapūras, Brazilija ir Australija. Suteikia galimybę konfigūruoti apsaugos užkardą pagal privataus ar viešo reikalavimus. Tačiau *AWS* nenumato pakeitimų aparatinės įrangos lygyje, tai reiškia, jei reikia programai aparatinės įrangos pakeitimų siekiant padidinti programos našumą, tokios galimybės nėra. *AWS* nepalaiko grupinio transliavimo (angl. *multicast*), bei eksploatacijos išlaidos yra didesnės lyginant su kitais pagrindiniais debesų paslaugų teikėjais. *AWS* labiausiai tinka programos, kurios nereikalauja aparatinės įrangos pakeitimų, bei organizacijoms, kurios nori tiekti savo paslaugas įvairiuose regionuose.

MS Azure pasižymi greičiu pagrindinėse srityse, o tai suteikia konkurencingumo verslo srityse. Taip pat *MS Azure* gali dirbti sudėtingoje aplinkoje, bei teikia puikią programos atstatymo sistemą. Tačiau ši debesų paslauga reikalauja valdymo ir priežiūros. Visos programos sukurtos *Windows* aplinkoje gali išnaudoti maksimalų šių debesų paslaugų greitį.

Google debesų platforma suteikia pilną priėjimą prie informacijos iš bet kur, per internetines programas naudojamas šių debesų. Taip pat šios debesų platformos kainų pasiūlymai geresni lyginant su kitomis debesų paslaugomis, vartotojas turi mokėti tik už naudojimosi laiką. Pasižymi gera apsaugos sistema, vystyta paskutinius 15 metų, kuri saugo tokias paslaugas kaip Gmail, paiešką ir kt. Remiantis pateikiamu funkcionalumu, *Google* debesų platforma atsilieka nuo *AWS*.

IBM debesų paslaugose įvykus nelaimėi, duomenų atstatymas vykdomas greičiau nei *AWS*, *Google* ar *MS Azure* debesyse. Apkrova paskirstoma sistemingai, tokiu būdu naudotojai gauna gerus programų atsakymus.

Pasirinkta naudoti *MS Azure* debesų paslaugas, dėl pilnai suderinamo *.NET* palaikymo, bei lengvos ir patogios integracijos *MS Windows* aplinkoje.

4. EKSPERIMENTŲ REZULTATAI

4.1. Pradiniai duomenys, parametrai ir nuskaitymas

Parkinsono ligos atpažinimo iš kalbos signalo sistemos tyrimo procesas vykdomas lietuvių kalbos sakiniui „turėjo senelė žilą oželį“. Tyrimui naudojamos dvi duomenų bazės: 1) sudaryta kiekvieną įrašą įrašant patalpoje su garso izoliacija naudojant kardioidinį akustinį mikrofoną „AKG Perception 220“; 2) naudojant išmaniojo telefono „Samsung Galaxy Note 3“ vidinį mikrofoną. Abiejų duomenų bazių įrašai detaliau pateikiami 4.1 lentelėje. 98 subjektų kalbos įrašai įrašyti naudojant akustinį mikrofoną ir išmanųjį telefoną tuo pačiu metu (įrašai įrašyti tiems patiems subjektams) žr. 4.1 lentelę. Mikrofonai buvo pastatyti apytikriai 10 cm atstumu nuo kalbėtojo burnos. Įrašams naudojamas monofoninis PCM (.wav) formatas, atskaitos koduojamos 16 bitų, diskretizacijos dažnis f_d parenkamas 44100 Hz. Dažnio diapazonas turi apimti visą žmogaus girdimą dažnių diapazoną bei tenkinti Naikvisto sąlygą, kuri teigia, jog diskretizavimo dažnis turi būti 2 kartus didesnis nei diskretizuojamo signalo dažnis f ($f_d = 2f$) tam, jog būtų išvengiama spektrų persidengimo.


4.1 lentelė Apibendrinta duomenų bazė: skaičiai rodo asmenų kiekį (įrašų skaičius)

	Akustinis mikrofonas	Išmanus telefonas
Sergantys vyrai	35	29
Sergančios moterys	39	34
Sergantys	74	63
Sveiki vyrai	98	11
Sveikos moterys	197	24
Sveiki	295	35
Iš viso	369	98

4.2. Tyrimo rezultatai naudojant akustinį mikrofoną

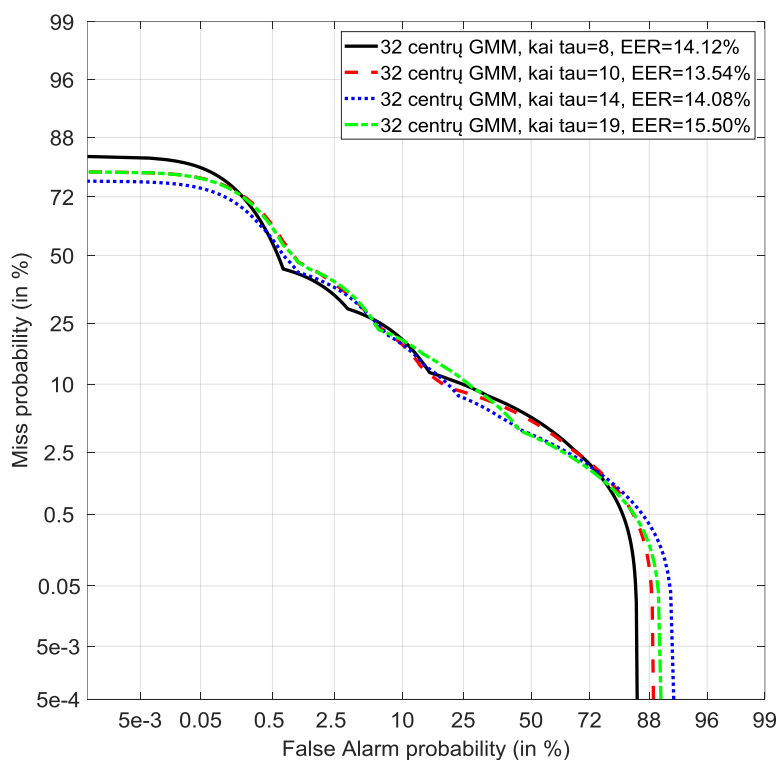
Tyrimui naudojami 369 subjektų įrašai (plačiau detalizuojami 4.1 lentelėje), įrašyti naudojant akustinį kardioidinį mikrofoną. Tyrimo klasifikatoriui atsitiktiniam miškui, medžių skaičius parinktas remiantis OOB klaidų kreive, kuri rodo klaidų lygį, liekanti kai stebėjimai nėra panaudojami medžio konstravimui. Bendras medžių skaičius parenkamas atsižvelgiant į nusistovintą OOB klaidų rezultatą, gautos kreivės pateikiamos 8.1 priede. Vertinant gautas kreives vizualiai, parinktas 3500 medžių skaičius miško konstravimui atsižvelgiant į tai, jog nuo medžių skaičiaus priklauso ir sprendimo apskaičiavimo trukmė, t. y. didėjant medžių skaičiui didėja ir laiko trukmė, reikalinga atlikti skaičiavimus. Taip pat reikšmė yra parenkama tokia, jog siekiama EER reikšmė būtų mažiausia.

Atliekant GMM optimalaus centrų skaičiaus nustatymą, remiamasi gaunamomis DET kreivėmis, kurios pateikiamos 4.1 pav. GMM atveju didžiausias sistemos tikslumas (mažiausia EER reikšmė), pasiekiamas naudojant modeliui 32 centrus, o gauta reikšmė nežymiai (0.02%) skiriasi lyginant su 13 matematinių statistikų. EER reikšmė gaunama taške, kuriame nepataikymo tikimybė (angl. *miss probability*) yra lygi netikro pavojaus tikimybei (angl. *false alarm probability*).




4.1 pav. RF detektoriaus DET kreivės ir EER reikšmės priklausomai nuo metodo

GMM korekcijos parametro τ įtakos vertinimas atliekamas eksperimentiniu būdu, skaičiuojant DET kreives kurios pateikiamos 4.2 paveiksle. Lyginant gaunamas EER reikšmes, pasirenkama τ reikšmė lygi 10, nes su šia reikšme gaunamas mažiausia EER 13.54% reikšmė. Visiems eksperimentams kuriems bus atliekami GMM skaičiavimai, bus naudojama gautoji τ vertė.



4.2 pav. RF detektoriaus DET kreivės ir EER reikšmės prie įvairių GMM τ parametro reikšmių

Naudojant *easyROC* analizės įrankį [33], tirta 13 matematinių statistikų ir 32 centrų GMM (gauti mažiausi EER DET kreivių atveju) įtaka detektoriaus tikslumui taikant ROC kreivių analizę, gautos kreivės pateikiamos 4.3 paveiksle.



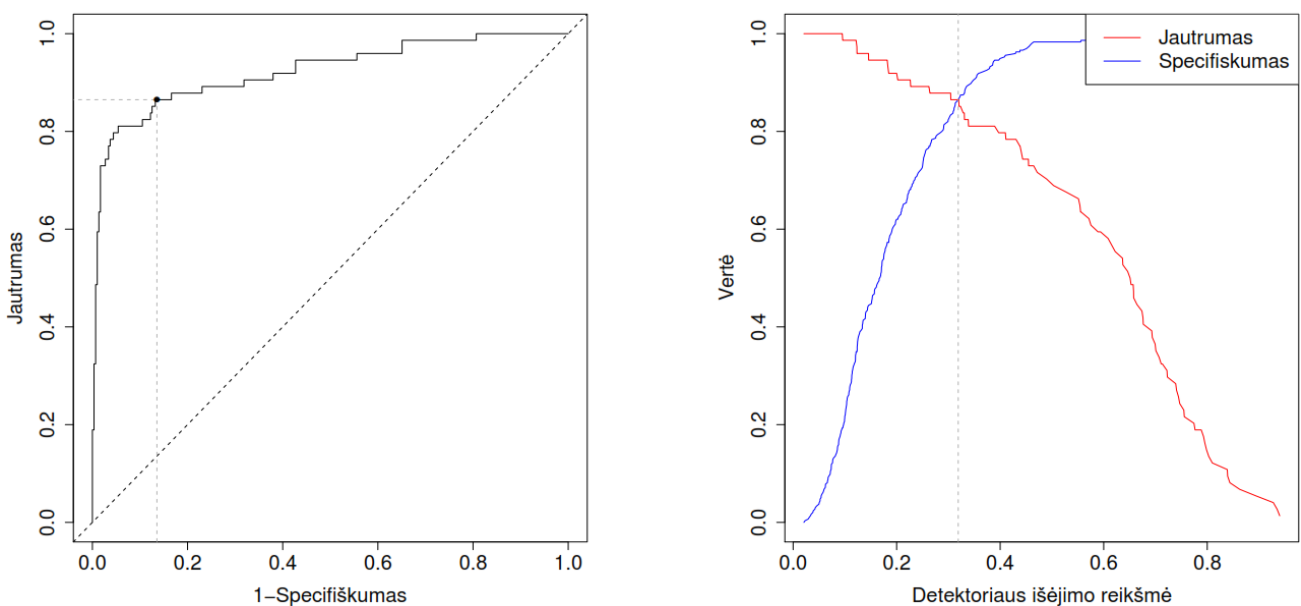
4.3 pav. 13 statistinių funkcijų ir 32 centrų GMM palyginimas naudojant ROC kreivę

Iš gautų kreivių ir 4.2 lentelės galima pastebėti, jog gaunamas plotas po ROC kreive (AUC), taikant 13 statistinių funkcijų yra nežymiai (0.014) didesnis nei Gauso mišinių modelio atveju ir tai rodo, jog statistinės funkcijos pasižymi geresnėmis prognostinėmis savybėmis.

4.2 lentelė. ROC kreivių palyginimas naudojant AUC skaičiavimus pirmos duomenų bazės atveju

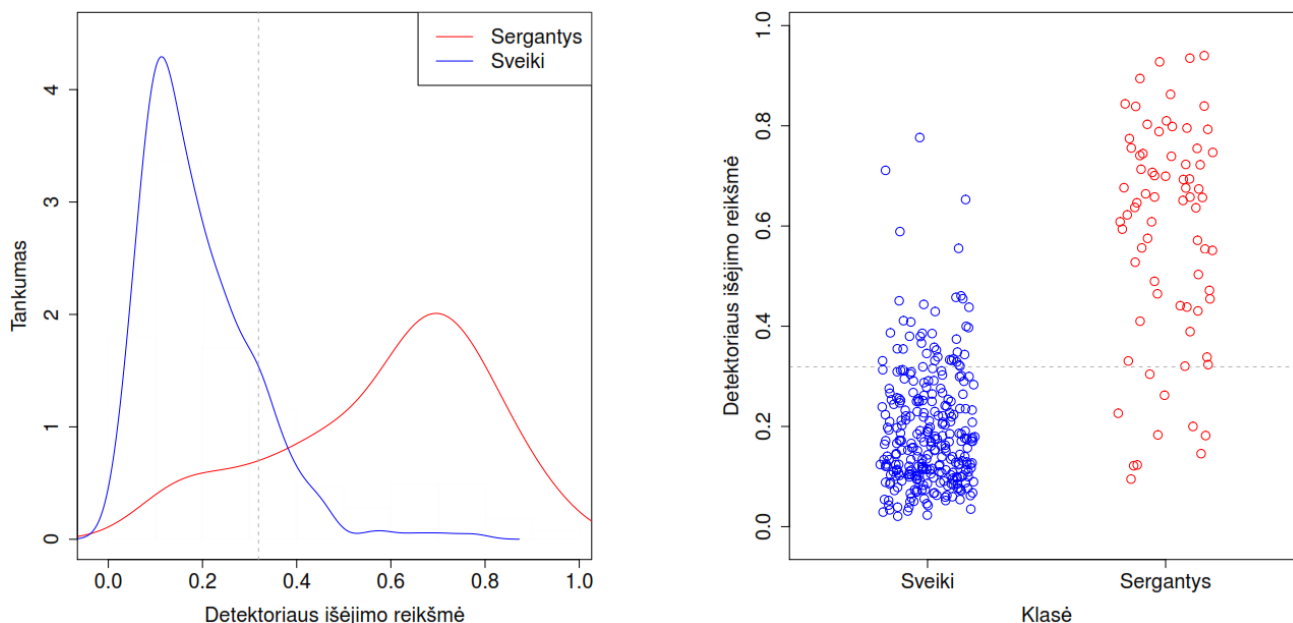
(I)	(J)	AUC(I)	AUC(J)	I-J	SE(I-J)	z	p-reikšmė
13 statistikų	32 centrų GMM	0.9232	0.9091	0.0141	0.0311	0.453	0.6505

Aukšta ($p > 0.05$) p-reikšmė 0.651 rodo, jog gautas AUC reikšmių skirtumas nėra statistiškai reikšmingas tarp šių dviejų metodų. ROC kreivių analizės metu, 13 statistikų ir GMM apskaičiuoti diagnozės parinkimo slenksčiai taikant metodą „Jautrumas = Specifiškumui“. Slenkstis yra parenkamas taške, kuriame kertasi gaunamos jautrumo ir specifiškumo kreivės (žr. 4.4 pav.). Naudojant jautrumo ir specifiškumo priklausomybę nuo detektoriaus išėjimo rezultato, nustatytas slenkstis 13 statistinių funkcijų – 0.319 arba 31.9%.



4.4 pav. ROC kreivė (kairėje), jautrumo ir specifiškumo kreivės (dešinėje) naudojant 13 statistinių funkcijų

GMM atveju slenkstis sprendimo priėmimui – 0.328, o ROC, jautrumo ir specifiškumo priklausomybės, bei duomenų pasiskirstymas pateikiami 8.2 priede. Duomenų pasiskirstymas prie nustatytos slenkščio reikšmės 13 statistinių funkcijų atveju pateikiamas 4.5 paveiksle. Duomenų pasiskirstymo kreivės persidengia, todėl parenkant slenkstį stengiamasi, jog kiekvienos klasės klaidų tikimybė būtų minimali.



4.5 pav. Detektoriaus išėjimo reikšmės pasiskirstymas priklausomai nuo klasės bei optimalus slenkstis (punktyrinė linija), prie kurio klasių klaidos susilygina naudojant 13 statistinių funkcijų

Abiem analizuojamiems metodams, prie apskaičiuoto slenkščio sudarytos sumaišymo matricos pateikiamos 4.3 - 4.4 lentelėse. GMM atveju atpažįstant sveikų subjektų klasę, suklystama vienu subjektu mažiau, tas pastebima ir iš aukštesnės 0.339% jautrumo reikšmės lyginant su 13 matematinių statistikų iš 4.5 lentelės.

4.3 lentelė. Sumaišymo matrica naudojant 13 matematinių statistikų kalbos signalo kadro suspaudimui

		Tikra klasė		Iš viso
		Sveiki	Sergantys	
Priskirta klasė	Sveiki	255	10	265
	Sergantys	40	64	104
Iš viso		295	74	369

4.4 lentelė. Sumaišymo matrica naudojant 32 centrų GMM kalbos signalo kadro suspaudimui

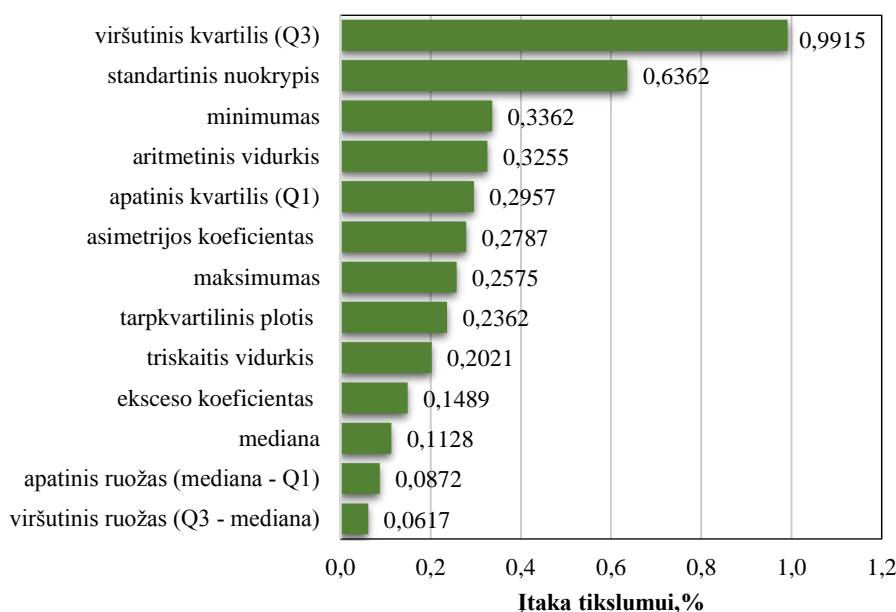
		Tikra klasė		Iš viso
		Sveiki	Sergantys	
Priskirta klasė	Sveiki	256	10	266
	Sergantys	39	64	103
Iš viso		295	74	369

Atlikti sumaišymo matricų skaičiavimų apibendrinti rezultatai pateikti 4.5 lentelėje. GMM atveju gautos jautrumo, PPV, bendro tikslumo ir Koheno kapos mato (Kappa) reikšmės yra nežymiai geresnės nei 13 statistinių funkcijų. Abiejų metodų Kappa reikšmės yra didesnės nei 0.6, rodančios statistiškai pakankamai gerą metodų patikimumą [38].

4.5 lentelė. 13 statistikų ir 32 centrų GMM palyginimas pagal tikslumo įverčius, gaunamus iš sumaišymų matricos


Metodas	Jautrumas	Specifiškumas	PPV	NPV	Bendras tikslumas	Kappa
13 statistikų	86.441%	86.486%	96.226%	61.538%	86.450%	0.633
32 centrų GMM	86.780%	86.486%	96.241%	62.136%	86.721%	0.639

Požymių įtaka buvo tiriama naudojant pakeitimais grindžiamą požymių svarbos analizę, kur požymių svarbos matavimas atitinka vidutinį tikslumo sumažėjimą nesant tam požymiui. 13 statistikų įtaka galutiniam tikslumui, t. y. vidutinis tikslumo sumažėjimas procentais nesant naudotai statistikai pateikiamas 4.6 – 4.7 paveiksluose, kur atitinkamai pirmame paveiksle vaizduojama statistikų įtaka naudojant standartinį požymių įtakos metodą, o antrame – plotu po kreive grindžiamą požymių įtakos metodą.




4.6 pav. Atsitiktinio miško ER skaičiavimais grindžiama 13 statistinių funkcijų įtaka detekcijos tikslumui

Abiem skaičiavimo atvejais iš naudotų 13 statistikų kalbos signalo kadru suspaudimui matome, jog didžiausią įtaką detektoriaus rezultatų tikslumui daro viršutinis kvartilis ir standartinis nuokrypis, o mažiausią viršutinis tarpkvartilinio pločio ruožas.

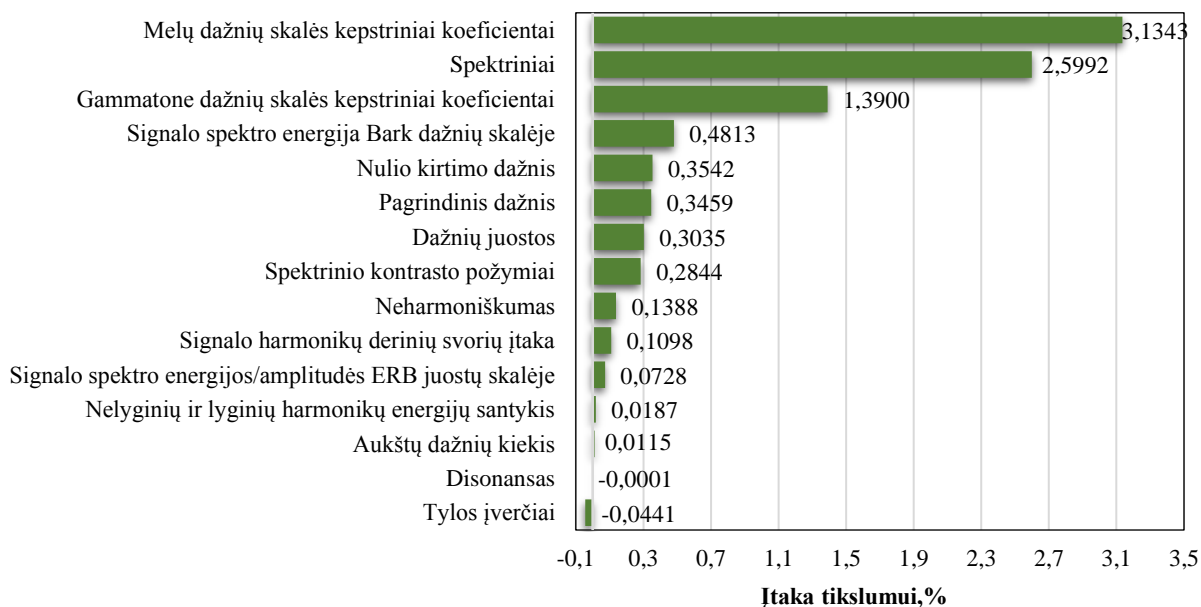


4.7 pav. Atsitiktinio miško AUC skaičiavimais grindžiama 13 statistinių funkcijų įtaka detekcijos tikslumui

Kalbos signalo įrašo analizei naudoti požymiai buvo susumuoti į reikšmingas grupes, kur tų požymių grupių įtaka galutiniam tikslumui pateikiama 4.8 – 4.9 paveiksluose. Atliekant skaičiavimus, požymiai buvo apjungti į didesnes pagrindines požymių grupes tokias kaip MFCC, GFCC koeficientai ir kitas, siekiant nustatyti požymių grupės įtaką atpažinimo tikslumui. Pirmame paveiksle atitinkamai vaizduojami rezultatai, naudojant standartinę klaidos įverčio požymių svarbos analizę, o antrame gauti rezultatai panaudojant plotu po kreive grindžiamą požymių įtakos apskaičiavimo metodą. Abiem skaičiavimo atvejais gaunama, jog didžiausią įtaką detekcijai darančios *Essentia* požymių grupės yra MFCC ir spektriniai, o mažiausią įtaką rezultatų tikslumui daro tylos įverčiai, aukštųjų dažnių komponentių kiekis ir disonansas.




4.8 pav. Atsitiktinio miško ER skaičiavimais grindžiama susumuota požymių įtaka detekcijos tikslumui




4.9 pav. Atsitiktinio miško AUC skaičiavimais grindžiama susumuota požymių įtaka detekcijos tikslumui

Sveikų ir sergančių subjektų įrašų išsibarstymas dviejų dimensijų erdvėje, taikant daugiamačių skalių algoritmą kai naudojami 13 statistinių funkcijų ir GMM metodai kalbos signalo kadru suspaudimui pateikiami 4.10 - 4.11 paveiksluose.



4.10 pav. Įrašų išsibarstymas 2D erdvėje, taikant MDS algoritimą (naudojamas 13 statistikų suspaudimas)

Iš gautų charakteristikų galima pastebėti, jog Gauso mišinių modelio sveikų subjektų klasės objektų išsibarstymas mažėja, labiau koncentruojantis apie klasės centrą (4.11 pav.).




4.11 pav. Įrašų išsibarstymas 2D erdvėje, taikant MDS algoritimą (naudojamas 32 centrų GMM suspaudimas)


Kadangi vizualizacijai ir gautų rezultatų (EER, AUC ir kt.) skaitinėms reikšmėms gauti naudojami skirtingi algoritmai, gautos rezultatų reikšmės nepriklauso nuo objektų išsibarstymo taikant MDS algoritimą, tačiau šis algoritmas leidžia patogiausiai stebėti objektų išsibarstymą erdvėje ir skirtumus, gaunamus taikant skirtingus metodus kalbos signalo kadrų suspaudimui.

4.3. Tyrimo rezultatų palyginimas naudojant akustinį ir išmanaus telefono mikrofonus

Atliktas triukšmingesnio signalo (gaunamo iš mobiliojo telefono mikrofono) įtakos detekcijos tikslumui eksperimentas. Korektiškam palyginimui skirtingų mikrofonų duomenų bazių įrašų skaičius buvo suvienodintas, t. y. akustiniu mikrofону įrašytų įrašų skaičius buvo sumažintas iki tokio paties įrašų skaičiaus gauto naudojant išmanaus telefono mikrofoną (naudojami tų pačių subjektų įrašai). Detektoriaus tikslumo palyginimas naudojant DET kreives vaizduojamas 4.12 paveiksle.



4.12 pav. RF detektoriaus DET kreivės naudojant akustinį mikrofoną



4.13 pav. RF detektoriaus DET kreivės naudojant išmanaus telefono mikrofoną

Mažiausias lygių klaidų lygis 21.32% pasiektas naudojant 13 statistikų suspaudimą akustinio mikrofono atveju, o naudojant išmanaus telefono mikrofoną – 26.65% su 16 centrų GMM. Atliekant

sumažintos akustinio mikrofono duomenų bazės palyginimą su pilna duomenų baze (4.1 ir 4.12 pav.) pastebima, jog sumažinus įrašų skaičių nuo 369 iki 98 (~3.765 karto) EER padidėjo nuo 13.43% iki 21.32%, kai naudojamas 13 statistikų suspaudimas, o GMM 32 centrų atveju EER padidėjo nuo 13.41% iki 25.52%. Naudojant išmanaus telefono mikrofoną, mažiausias EER 26.65% pasiektas su 16 centrų GMM suspaudimu.

ROC kreivių (pateikiamos 8.3 priede) analizė ir gautų kreivių palyginimo įverčiai, kurie pateikiami 4.6 lentelėje parodė, jog naudojant prastesnės kokybės įrašus, geresni rezultatai pasiekiami su 16 centrų GMM nei su 13 matematinių statistikų suspaudimu. Gautas AUC skirtumas 0.071 rodo geresnes prognostines savybes 16 centrų GMM, tačiau kaip ir akustinio mikrofono atveju, aukšta ($p > 0.05$) p-reikšmė – 0.371 rodo, jog gautas AUC reikšmių skirtumas taip pat nėra statistiškai reikšmingas tarp lyginamų metodų.

4.6 lentelė. ROC kreivių palyginimo įverčiai, antros duomenų bazės atveju

(I)	(J)	AUC(I)	AUC(J)	I-J	SE(I-J)	z	p-reikšmė
13 statistikų	16 centrų GMM	0.6898	0.7605	0.0707	0.0791	0.8949	0.3709

Nustatyti diagnozės parinkimo slenksčiai 13 statistikų ir 16 centrų GMM: atitinkamai 0.554 ir 0.552. Gauti slenksčių įverčiai ir duomenų pasiskirstymai grafiškai abiem metodams pateikti 8.4 priede. Sumaišymo matricos sudarytos prie apskaičiuoto slenksčio pateikiamos 4.7 – 4.8 lentelėse. Naudojant GMM suspaudimą, detektorius geriau suklasifikavo vienu objektu sveikų ir dviem objektais sergančių klasėse lyginant su 13 statistikų suspaudimu.

4.7 lentelė. Sumaišymo matrica naudojant 13 matematinių statistikų kalbos signalo kadru suspaudimui

		Tikra klasė		Iš viso
		Sveiki	Sergantys	
Priskirta klasė	Sveiki	24	21	45
	Sergantys	11	42	53
Iš viso		35	63	98

4.8 lentelė. Sumaišymo matrica naudojant 16 centrų GMM kalbos signalo kadru suspaudimui

		Tikra klasė		Iš viso
		Sveiki	Sergantys	
Priskirta klasė	Sveiki	25	19	44
	Sergantys	10	44	54
Iš viso		35	63	98

Atlikti sumaišymo matricų skaičiavimų apibendrinti rezultatai pateikti 4.9 lentelėje. Remiantis gautais papildomais sumaišymo matricos parametrais, gauta mažiausia EER reikšmė, apskaičiuotais AUC įverčiais, prastesnės kokybės įrašams būtų rekomenduojama naudoti 16 centrų GMM.

4.9 lentelė. 13 statistikų ir 16 centrų GMM palyginimas pagal tikslumo įverčius, gaunamus iš sumaišymų matricos

Metodas	Jautrumas	Specifiškumas	PPV	NPV	Bendras tikslumas	Kappa
13 statistikų	68.571%	66.667%	53.333%	79.245%	67.347%	0.331
16 centrų GMM	71.429%	69.841%	56.818%	81.481%	70.408%	0.390

Abiem lyginamiems metodams Kappa įverčiai yra riboje tarp 0.21 ir 0.40, rodantys statistiškai silpną metodų patikimumą [38]. Mažą patikimumą lemia sąlyginai mažos duomenų imtys, todėl būtų rekomenduojama didinti įrašų skaičių abiem klasėms siekiant didesnio rezultatų patikimumo, bei

atsižvelgiama į tai, jog sumažinus duomenų imtį EER įvertis didėja, todėl didinant įrašų skaičių sistemos tikslumas didėtų.

Prototipo galutinei realizacijai, dėl duomenų bazės dydžio ir mažiausių EER reikšmių bus naudojami akustiniu mikrofonu gauti įrašai, o dėl nedidelio EER skirtumo tarp lyginamų metodų naudojamų kadrų suspaudimui, realizacijos paprastumo ir skaičiavimų greಿತaveikos kalbos signalo kadrų suspaudimui pasirinkta naudoti 13 statistinių funkcijų.

4.4. Eksperimentinės dalies rezultatai

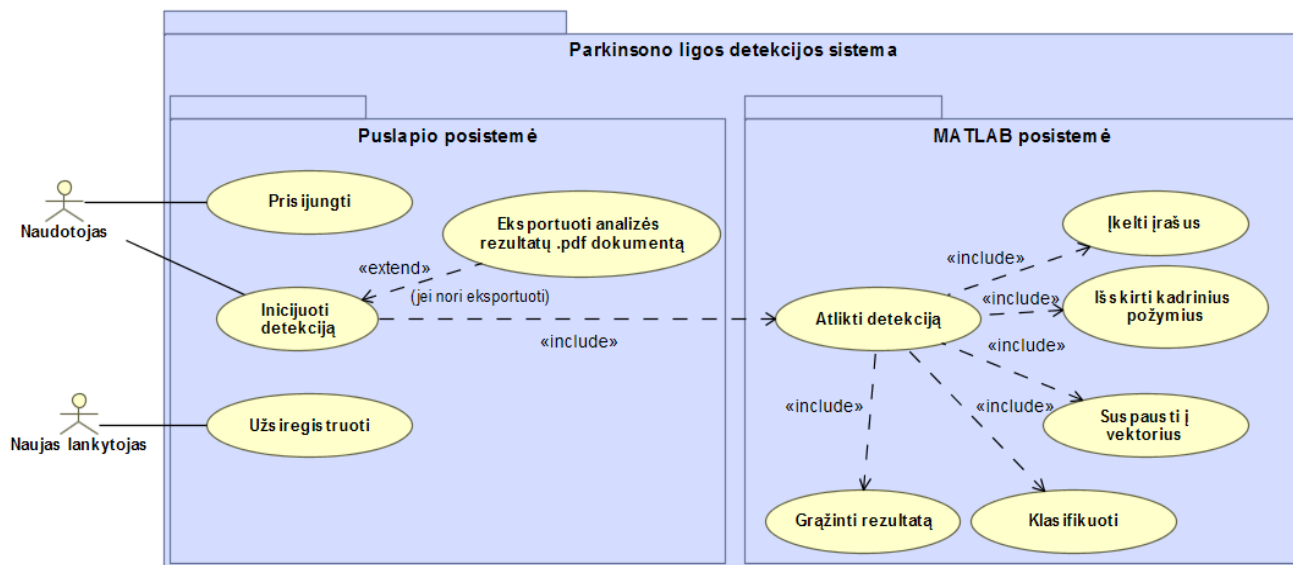
1. Eksperimentai atlikti kalbos signalo kadrų suspaudimui naudojant du metodus: 13 statistinių funkcijų ir GMM (8, 16, 32, 64 centrų). Pirmajai duomenų bazei sudarytai iš akustiniu mikrofonu gautų įrašų, EER siekė 13.43% naudojant 13 statistinių funkcijų ir 13.41% naudojant 32 centrų GMM.
2. GMM skaičiavimų korekcijos parametro *tau* įtakos detektoriaus tikslumui analizė parodė, jog mažiausias EER pasiekiamas kai parametro *tau* reikšmė yra 10, todėl visiems atliktiems GMM skaičiavimams pasirinkta naudoti ši vertė.
3. Atlikus ROC kreivių analizę nustatyta, jog nors AUC reikšmės skiriasi statistinėms funkcijoms ir GMM, tačiau dėl aukštų ($p > 0.05$) p-reikšmių gaunamas skirtumas nėra statistiškai reikšmingas tiek išmanaus, tiek akustinio mikrofonų atvejais.
4. Sumaišymo matricos skaičiavimai parodė, jog bendras atpažinimo tikslumas akustiniu mikrofonu gautiems įrašams siekė 86.5% naudojant 13 statistinių funkcijų ir 86.7% naudojant 32 centrų GMM. Išmanaus telefono mikrofonu gautiems įrašams bendras atpažinimo tikslumas 67.3% gautas su 13 statistinių funkcijų ir 70.4% su 16 centrų GMM.
5. Atlikta požymių svarbos analizė naudojant ER ir AUC metodus parodė, jog didžiausią įtaką sprendimo priėmimui daro MFCC ir spektriniai požymiai, o mažiausią tylos įverčiai, aukštųjų dažnių harmonikų skaičius ir disonansas. Didelę svarbą sprendimo priėmimui, spaudžiant informacijos kadrus su 13 statistinių funkcijų, daro viršutinis kvartilis ir standartinis nuokrypis, o mažiausią įtaką tikslumui daro viršutinis tarpkvartilinio pločio ruožas.
6. Išmanaus telefono mikrofonu gautų įrašų įtakos detektoriaus tikslumui analizė atskleidė, jog naudojant 13 statistinių suspaudimą pasiekiamas 31.58% EER, o mažiausias 26.65% EER pasiektas naudojant 16 centrų GMM.
7. Suvienodinus sveikų įrašų skaičių iki atveju, kada asmuo turėjo ir akustinio mikrofono ir išmanaus mikrofono įrašus, tyrimo rezultatai parodė, jog naudojant 13 statistinių suspaudimą EER reikšmė pakilo per 7.89 procentinius punktus, o 32 centrų GMM atveju EER pakilo per 12.11 procentinių punktų.

5. PROTOTIPINĖS SISTEMOS KŪRIMAS IR TESTAVIMAS

5.1. Reikalavimų specifikacija

5.1.1. Funkciniai reikalavimai

Funkciniams sistemos reikalavimams nustatyti sudaroma panaudojimo atvejų diagrama, kuri rodo visus vartotojų veiksmus sistemoje. Parkinsono ligos detekcijos sistemos panaudojimo atvejų diagrama pateikiama 5.1 paveiksle.

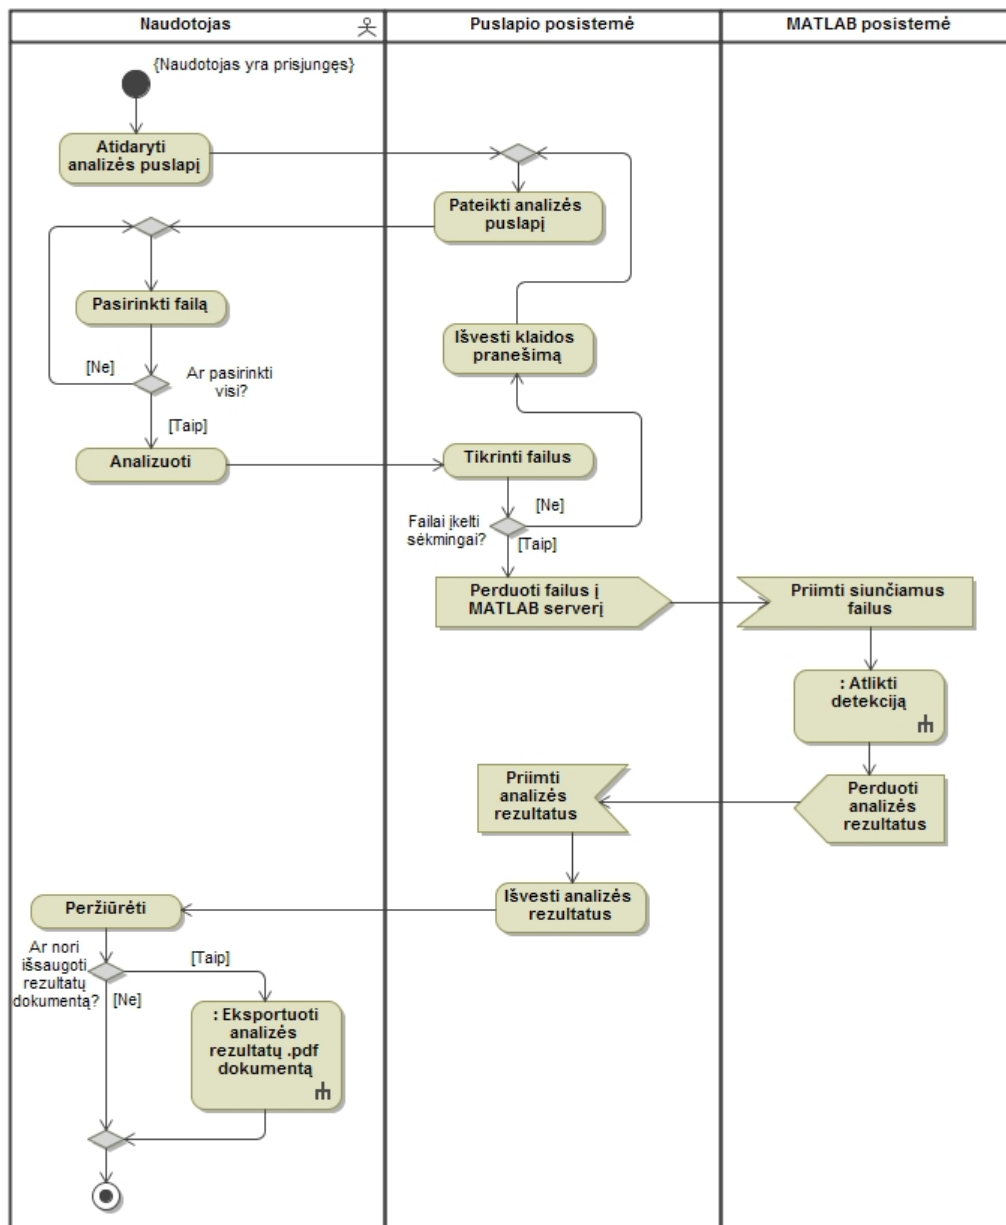


5.1 pav. Parkinsono ligos detekcijos sistemos panaudojimo atvejų diagrama

Panaudojimo atvejo „Inicijuoti detekciją“ specifikacija pateikiama 5.1 lentelėje, o veiklos diagrama pateikiama 5.2 paveiksle.

5.1 lentelė. PA „Inicijuoti detekciją“ specifikacija

PA 1. „Inicijuoti detekciją“		
Tikslas/uždavinys. Įgalinti atlikti detekciją.		
Aprašymas. Pasirenkami sakinio įrašo failai ir gaunamas atliktos analizės rezultatas.		
Prieš-sąlyga	Atidarytas „Analizės“ puslapis.	
Aktorius	Sistemos naudotojas.	
Sužadinimo sąlyga	Sistemos naudotojas prisijungia prie sistemos.	
Susiję panaudojimo atvejai	Išplečia PA	-
	Apima PA	1.1. „Atlikti detekciją“.
	Specializuoja PA	-
Pagrindinis įvykių srautas		
Sistemos reakcija		
1. Sistemos naudotojas pasirenka failus.	1.1. Sistema išsaugo kelį iki pasirinktų failų.	
2. Sistemos naudotojas pasirenka analizės paleidimą.	1.1. Sistema patikrina pasirinktus failus; 1.2. Sistema atlieka failų analizės procesą; 1.3. Sistema išveda gautus rezultatus.	
Po-sąlyga	-	
Alternatyvūs scenarijai		
-	-	



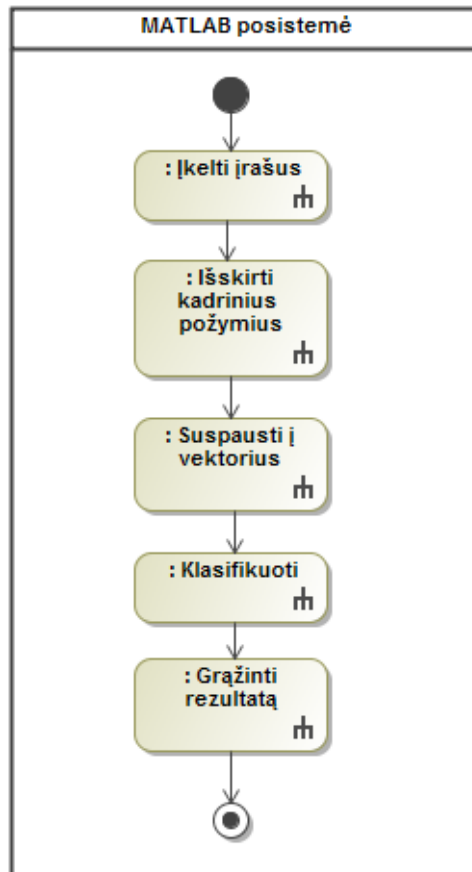
5.2 pav. PA „Inicijuoti detekciją“ veiklos diagrama

Panaudojimo atvejo „Atlikti detekciją“ specifikacija pateikiama 5.2 lentelėje, o veiklos diagrama pateikiama 5.3 paveiksle.

5.2 lentelė. PA „Atlikti detekciją“ specifikacija

PA 1.1. „Atlikti detekciją“		
Tikslas/uždavinys. Nustatyti Parkinsono ligos tikimybę.		
Aprašymas. MATLAB posistemė atlieka tekstinės įrašų informacijos analizę ir gražina rezultatų žemėlapi tekstiniu formatu.		
Prieš-sąlyga		Į sistemą įkelti įrašai yra užkoduoti.
Aktorius		-
Sužadinimo sąlyga		Puslapio posistemė kreipiasi į MATLAB posistemę.
Susiję panaudojimo atvejai	Išplečia PA	-
	Apima PA	1.1.1. „Įkelti įrašus“. 1.1.2. „Išskirti kadrinius požymius“. 1.1.3. „Suspausti į vektorius“. 1.1.4. „Klasifikuoti“. 1.1.5. „Gražinti rezultatą“.
	Specializuoja PA	-

Pagrindinis įvykių srautas	Sistemos reakcija
	1.1. Apdoroja tekstinę įrašo informaciją ir išsiunčia gautų rezultatų informaciją tekstiniu formatu į puslapio posistemę.
Po-sąlyga	-
Alternatyvūs scenarijai	
-	-

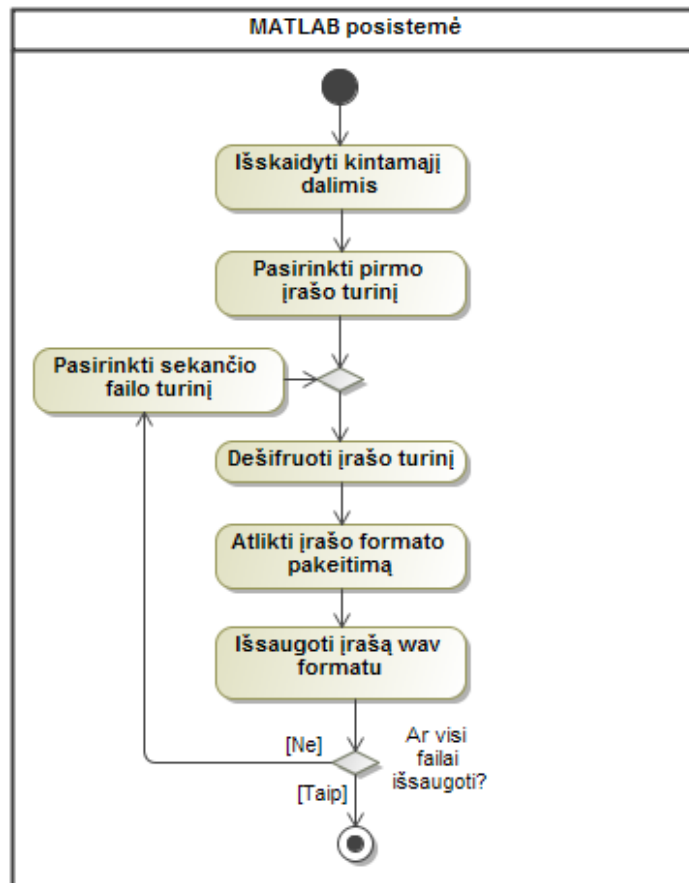


5.3 pav. PA „Atlikti detekciją“ veiklos diagrama

Panaudojimo atvejo „Įkelti įrašą“ specifikacija pateikiama 5.3 lentelėje, o veiklos diagrama pateikiama 5.4 paveiksle.

5.3 lentelė. PA „Įkelti įrašus“ specifikacija

PA 1.1.1. „Įkelti įrašus“		
Tikslas/uždavinys. Įkelti sakinio įrašus į sistemą.		
Aprašymas. Dešifruojama įrašų informacija ir įrašai išsaugomi MATLAB posistemėje.		
Prieš-sąlyga	Puslapio posistemė siunčia įrašo informaciją.	
Aktorius	-	
Sužadinimo sąlyga	MATLAB posistemė gauna įrašo informaciją.	
Susiję panaudojimo atvejai	Išplečia PA	-
	Apima PA	-
	Specializuoja PA	-
Pagrindinis įvykių srautas		
Sistemos reakcija		
	1.1. Sistema apdoroja tekstinę įrašo informaciją, suformuoja ir išsaugo įrašo failą wav tipo formatu.	
Po-sąlyga	Išsaugoti įrašai wav formatu.	
Alternatyvūs scenarijai		
-	-	

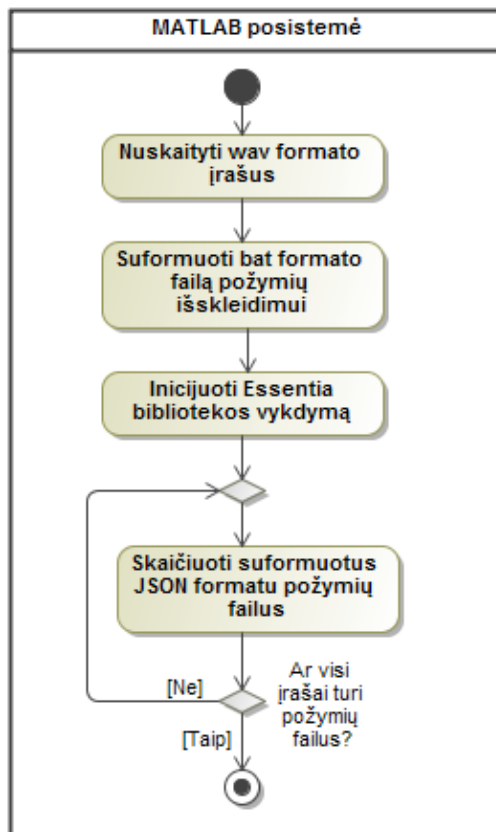


5.4 pav. PA „Įkelti įrašus“ veiklos diagrama

Panaudojimo atvejo „Išskirti kadrinius požymius“ specifikacija pateikiama 5.4 lentelėje, o veiklos diagrama pateikiama 5.5 paveiksle.

5.4 lentelė. PA „Išskirti kadrinius požymius“ specifikacija

PA 1.1.2. „Išskirti kadrinius požymius“		
Tikslas/uždavinys. Gauti sakinio įrašo požymius.		
Aprašymas. Kiekvienam wav formato sakinio įrašui suformuojamas požymių failas JSON formatu.		
Prieš-sąlyga	Išsaugoti MATLAB posistemėje įrašai wav formatu.	
Aktorius	-	
Sužadinimo sąlyga	Procesas inicijuojamas PA „Įkelti įrašus“ veiklos pabaiga.	
Susiję panaudojimo atvejai	Išplečia PA	-
	Apima PA	-
	Specializuoja PA	-
Pagrindinis įvykių srautas	Sistemos reakcija	
	1.1. Suformuoja kiekvienam wav įrašui požymių failą JSON formatu.	
Po-sąlyga	Išsaugoti požymiai kiekvienam įrašui JSON formatu.	
Alternatyvūs scenarijai		
-	-	

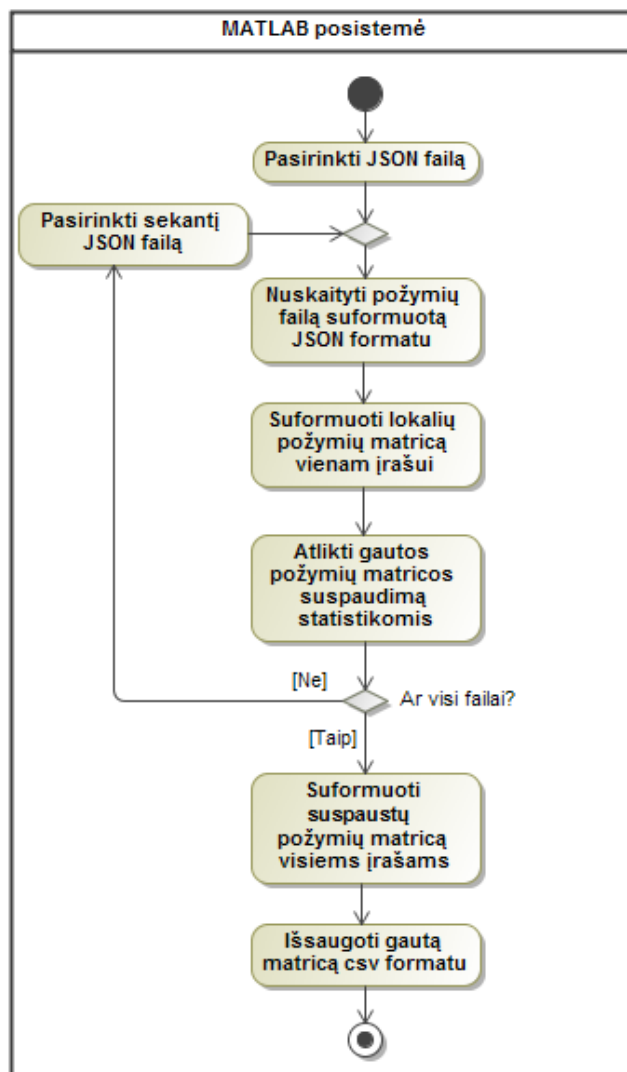


5.5 pav. PA „Iskirti kadrinius požymius“ veiklos diagrama

Panaudojimo atvejo „Suspausti į vektorius“ specifikacija pateikiama 5.5 lentelėje, o veiklos diagrama pateikiama 5.6 paveiksle.

5.5 lentelė. PA „Suspausti į vektorius“ specifikacija

PA 1.1.3. „Suspausti į vektorius“		
Tikslas/uždavinys. Suformuoti požymių matricą detekcijos atlikimui.		
Aprašymas. Išsaugoti požymiai JSON formatu suspaudžiami statistikomis ir suformuota visų įrašų matrica išsaugoma csv formatu.		
Prieš-sąlyga	MATLAB posistemėje suformuoti visų įrašų požymių failai JSON formatu.	
Aktorius	-	
Sužadinimo sąlyga	Procesas inicijuojamas PA „Iskirti kadrinius požymius“ veiklos pabaiga.	
Susiję panaudojimo atvejai	Išplečia PA	-
	Apima PA	-
	Specializuoja PA	-
Pagrindinis įvykių srautas	Sistemos reakcija	
	1.1. Suformuoja bendrą požymių matricą visiems įrašams; 1.2. Išsaugo sudarytą matricą csv formatu.	
Po-sąlyga	Išsaugoti požymiai visiems įrašams csv formatu.	
Alternatyvūs scenarijai		
-	-	

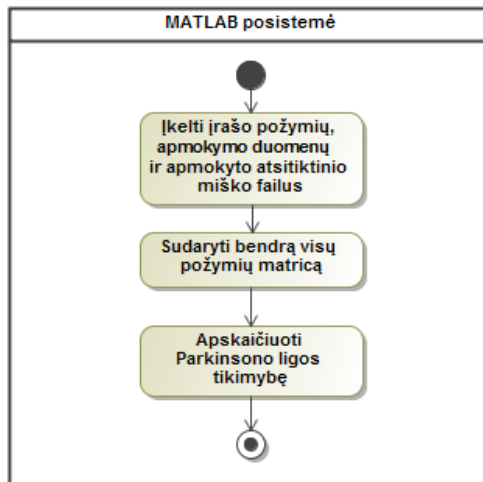


5.6 pav. PA „Suspausti į vektorius“ veiklos diagrama

Panaudojimo atvejo „Klasifikuoti“ specifikacija pateikiama 5.6 lentelėje, o veiklos diagrama pateikiama 5.7 paveiksle.

5.6 lentelė. PA „Klasifikuoti“ specifikacija

PA 1.1.4. „Klasifikuoti“		
Tikslas/uždavinys. Apskaičiuoti Parkinsono ligos tikimybinus įverčius.		
Aprašymas. Kiekvienam įkeltam sakinio įrašui apskaičiuojama Parkinsono tikimybė.		
Prieš-sąlyga	Išsaugoti MATLAB posistemėje įrašų požymiai csv formatu.	
Aktorius	-	
Sužadinimo sąlyga	Procesas inicijuojamas PA „Suspausti į vektorius“ veiklos pabaiga.	
Susiję panaudojimo atvejai	Išplečia PA	-
	Apima PA	-
	Specializuoja PA	-
Pagrindinis įvykių srautas	Sistemos reakcija	
	1.1. Apskaičiuoja kiekvienam įrašui Parkinsono ligos tikimybinus įverčius.	
Po-sąlyga	-	
Alternatyvūs scenarijai		
-	-	

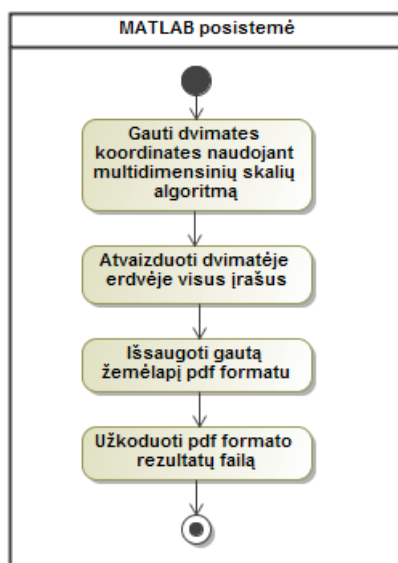


5.7 pav. PA „Klasifikuoti“ veiklos diagrama

Panaudojimo atvejo „Grąžinti rezultatą“ specifikacija pateikiama 5.7 lentelėje, o veiklos diagrama pateikiama 5.8 paveiksle.

5.7 lentelė. PA „Grąžinti rezultatą“ specifikacija

PA 1.1.5. „Grąžinti rezultatą“		
Tikslas/uždavinys. Suformuoti rezultatų failą.		
Aprašymas. Sudaromas rezultatų dvimatis žemėlapis ir išsaugomas pdf formatu.		
Prieš-sąlyga	Apskaičiuoti Parkinsono ligos tikimybiniai įverčiai.	
Aktorius	-	
Sužadinimo sąlyga	Procesas inicijuojamas PA „Klasifikuoti“ veiklos pabaiga.	
Susiję panaudojimo atvejai	Išplečia PA	-
	Apima PA	-
	Specializuoja PA	-
Pagrindinis įvykių srautas		
Sistemos reakcija		
1.1. Suformuoja dvimatį žemėlapi erdvėje; 1.2. Išsaugo žemėlapi pdf formatu; 1.3. Užkoduoja pdf dokumentą išsiuntimui.		
Po-sąlyga	Išsaugotas rezultatų failas pdf formatu.	
Alternatyvūs scenarijai		
-	-	



5.8 pav. PA „Grąžinti rezultatą“ veiklos diagrama

5.1.2. Nefunkciniai reikalavimai

Kuriamos Parkinsono ligos detekcijos prototipinės sistemos funkcionalumui keliami šie nefunkciniai reikalavimai:

Reikalavimai naudotojo sąsajai:

- sistemos naudotojo sąsaja turi būti realizuota lietuvių kalba;
- sistema turi būti suderinama su *Microsoft Internet Explorer*, *Mozilla FireFox*, *Opera*, *Chrome* naršyklėmis ir sistemos naudotojui, darbu su sistema, turi užtekti turėti įdiegtą vieną iš šių naršyklių;
- įvairūs mechanizmai (pvz. mygtukai, rodyklės, meniu ir kt.) turi turėti naudotojui įprastus ir/arba intuityvius funkcijų ir objektų pavadinimus arba žymėjimus;
- jei yra žinoma, kad sistemoje vykdomas procesas truks ilgiau nei 5 sekundes, naudotojui turi būti rodomas proceso vykdymo indikatorius.
- įkeliant įrašus į sistemą, sistema turi leisti atlikti įkėlimui naudojamų įrašų paiešką naudotojo įrenginyje.

Reikalavimai naudotojo duomenims:

- turi būti tikrinama prisijungimo ir registracijos duomenų sintaksė;
- sistemos naudotojas gali peržiūrėti tik savo atliktos analizės rezultatus;
- sistemos naudotojo registracijos (prisijungimo) duomenys turi būti saugomi *MS SQL Server* duomenų bazėje.

Reikalavimai patikimumui ir prieinamumui:

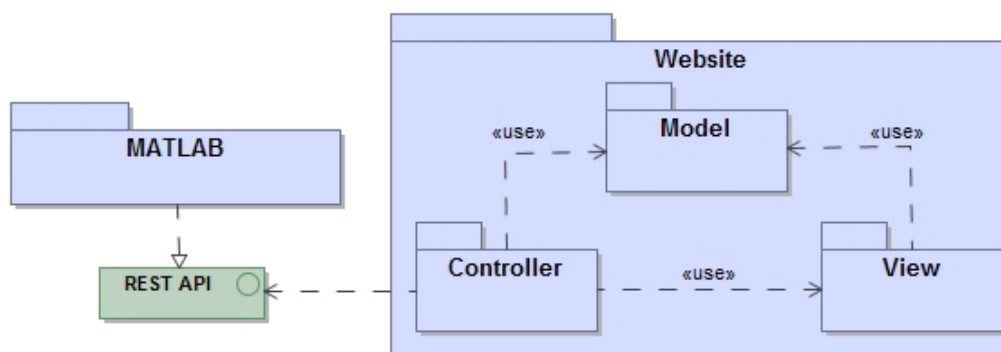
- sistema turi užtikrinti nepertraukiamą veikimą visą parą;
- sistemos vidutinis metinis pasiekiamumas turėtų būti ne mažesnis nei 95%.

Reikalavimai saugumui:

- sistemos naudotojai gali naudoti tik tas funkcijas, kurioms turi suteiktas teises;
- duomenų pateikimui įrankio naudotojams, sistema turi naudoti *SSL* per *HTTP* protokolą;
- Naudotojų slaptažodžiai duomenų bazėje turi būti šifruojami nustatytu algoritmu.

5.2. Loginė sistemos architektūra

Apibendrintas sistemos architektūros modelis pateikiamas 5.9 paveiksle. Sistema yra sudaryta iš kelių posistemų: *Matlab* posistemio (atlieka sakinio įrašo analizę ir pateikia analizės rezultatus) ir puslapio posistemio (leidžia sistemos naudotojui atlikti įrašo analizę naudojant interneto naršyklę). Duomenų apsikeitimas tarp šių posistemų vykdomas naudojant *REST API*.



5.9 pav. Sistemos architektūros modelis

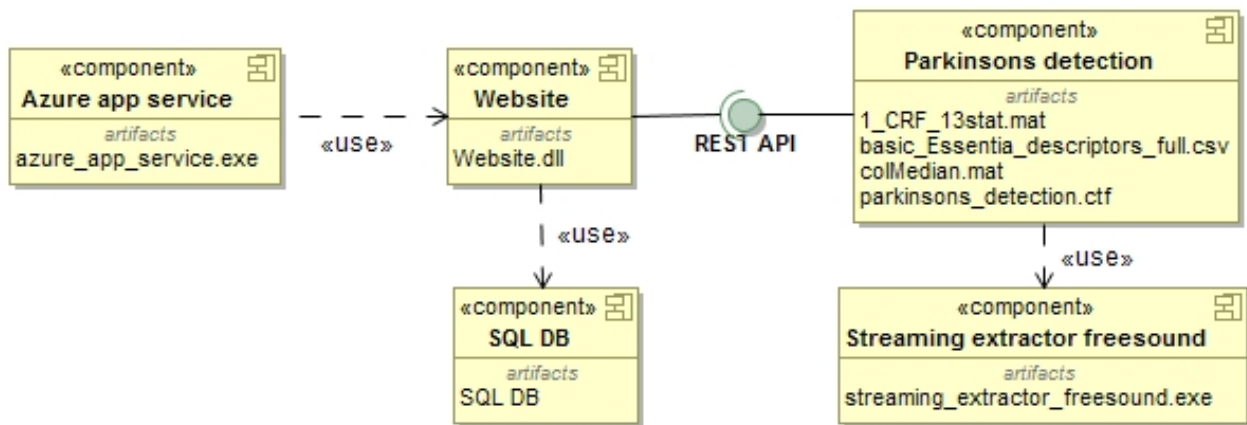
Internetiniam puslapiui taikomas *MVC* (angl. *Model View Controller*) modelis, atskiriantis taikymą į tris pagrindines grupes: modelį, vaizdą ir valdiklį. Naudojant šį modelį, vartotojo užklausa nukreipiamos į valdiklį kuris atsakingas už darbą su modeliu atliekant vartotojo užduotis ir/ar gaunant užklausių rezultatus. Valdiklis parenka reikiamą vaizdą vartotojui ir pateikia reikiamus modelio duomenis. Toks atsakomybių apibrėžimas leidžia lengviau rašyti programinį kodą, atlikti derinimą, testavimą. Ši architektūra *MS Visual Studio* programiniame įrankyje yra siūloma kaip numatytoji. Toliau detalizuojamas kiekvienas architektūros komponentas atskirai:

- modelis – saugo programos veiklos logiką (validacijos proceso logika, duomenų perdavimo logika ir kt.), dažniausiai modelio objektai turi arba pateikia duomenis kuriais dirba naudotojai;
- valdiklis – priklausomai nuo naudotojo veiksmų, šis sluoksnis apdoroja gaunamas užklausas, atlieka operacijas modelyje ir pateikia reikiamus vaizdus sistemos naudotojui;
- vaizdas – pateikia sistemos duomenis sistemos naudotojui suprantamu pavidalu.

5.3. Realizacijos modelis

5.3.1. Komponentų modelis

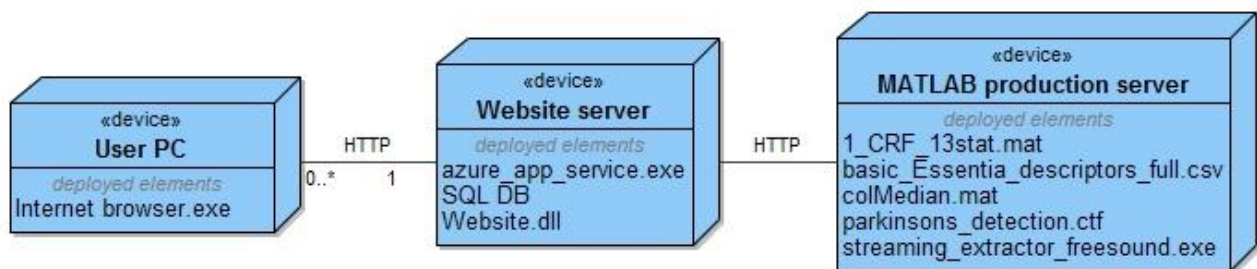
Parkinsono ligos diagnostikos sistemos komponentų modelis pateikiamas 5.10 paveiksle.



5.10 pav. Sistemos komponentų diagrama

5.3.2. Diegimo modelis

Parkinsono ligos detekcijos sistemos diegimo diagrama pateikiama 5.11 paveiksle. Sukurti artefaktai reikalingi informacinės sistemos veikimui talpinami *MS Azure* debesyse, o visi reikalingi artefaktai ekspertinės sistemos veikimui talpinami *Matlab* produkcijos serveryje.



5.11 pav. Sistemos diegimo diagrama

5.4. Sistemos naudotojo dokumentacija

5.4.1. Pagrindinis puslapis

Pagrindinis sistemos puslapis vaizduojamas 5.12 paveiksle, pasiekiamas viršutinėje meniu juostoje esančia nuoroda „Parkinsono ligos detekcijos sistema“. Šį puslapį sistemos naudotojas mato iš karto prisijungęs prie puslapio, jame pateikiama trumpa informacija apie šią sistemą bei darbo autoriaus ir vadovo kontaktinė informacija.



Parkinsono ligos detekcijos sistema

Registruotis Prisijungti

Parkinsono ligos detekcijos sistema

Parkinsono ligos aptikimo sistemos tyrimas remiasi kalbos sakinio analize.

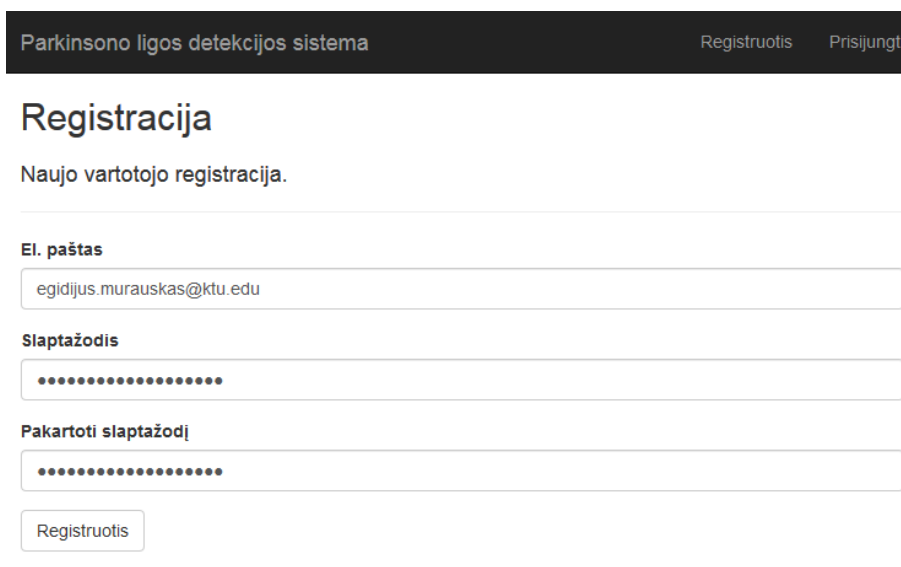
Darbo autorius:
Kauno technologijos universitetas
Informatikos fakultetas
Informacijos sistemų katedra
IFM-6/4 gr. stud. Egidijus Murauskas
El.paštas: egidijus.murauskas@ktu.edu
Kaunas, Lietuva

Darbo vadovas:
Kauno technologijos universitetas
Informatikos fakultetas
Informacijos sistemų katedra
Doc. dr. Evaldas Vaičiukynas
El.paštas: evaldas.vaiciukynas@ktu.lt
Kaunas, Lietuva

© 2018 - Parkinsono ligos detekcijos sistema

5.12 pav. Sistemos pagrindinis puslapis

Detekcijos atlikimui sistemos naudotojas turi atlikti prisijungimą prie sistemos užpildydamas prisijungimo formą kuri pateikiama 5.14 paveiksle, bet prieš tai turi užsiregistruoti registracijos puslapyje, kurio forma pateikiama 5.13 paveiksle.



Parkinsono ligos detekcijos sistema

Registruotis Prisijungti

Registracija

Naujo vartotojo registracija.

El. paštas

egidijus.murauskas@ktu.edu

Slaptažodis

.....

Pakartoti slaptažodį

.....

Registruotis

© 2018 - Parkinsono ligos detekcijos sistema

5.13 pav. Registracijos forma

Prisijungimas

El. paštas

Slaptažodis

Prisiminti?

[Negaliu prisijungti](#)

[Registruoti naują vartotoją](#)

© 2018 - Parkinsono ligos detekcijos sistema

5.14 pav. Prisijungimo forma

5.4.2. Įrašo apdorojimo ir rezultatų išvedimo puslapis

Sistemos naudotojas prisijungęs prie sistemos mato naują papildomą puslapį „Analizė“ kuris pateikiamas 5.15 paveiksle. Norėdamas atlikti įrašo analizę, naudotojas turi turėti vieną ar kelis įrašus (sistemoj numatytas maksimalus 10 įrašų apdorojimo vienu metu skaičius), kurie būtų *wav* ar *mp3* tipų formatų. Paspaudus mygtuką „Parinkti...“, naudotojas savo failų sistemoje pasirenka norimus failus tyrimui. Pasirinkimo metu failai nėra įkeliami į sistemą, todėl naudotojas antrą kartą paspaudęs tą patį mygtuką gali atnaujinti savo pasirinkimą. Atlikus failų pasirinkimą ir paspaudus mygtuką „Analizuoti“, į sistemą įkeliami įrašai ir iš karto pradedamas tyrimo procesas. Nepasirinkus nei vieno failo ar pasirinkus didesnę skaičių nei numatytas, naudotojui naujame puslapyje išvedamas klaidos tekstinė informacija.

Parkinsono ligos detekcijos sistema
Analizė
Sveiki egidijus.murauskas@ktu.edu!
Atsijungti



Įrašo reikalavimai

- Įrašui turi būti įrašytas sakiny: „Turėjo senėlė žilą oželį“;
- Tiksliesiems rezultatams gauti, įrašas turi būti įrašytas naudojant akustinį kardioidinį mikrofoną;
- Įrašo formatas .wav arba .mp3 tipo (mono arba stereo, diskretizacijos dažnis: 44 kHz);
- Galite įkelti nuo 1 iki 10 įrašų failų;
- Įrašų dydis negali viršyti 28 MB;

Analizės rezultatai

Skaičiavimai trunka apie 1 minutę. Rezultatai bus išvedami atlikus skaičiavimus. Jei rezultatų tikimybė patenka į ribą [0 ; 32] %, skiriama diagnozė - sveikas, jei patenka į ribą [32 ; 100] %, skiriama diagnozė - sergantis.

Pasirinkite failus ir spauskite „Analizuoti“

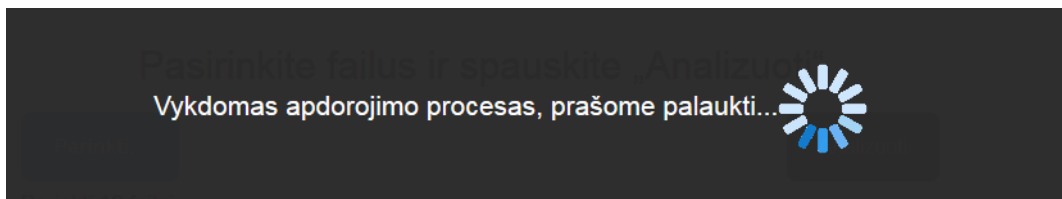
Parinkti...

Analizuoti

© 2018 - Parkinsono ligos detekcijos sistema


5.15 pav. Garso įrašo ir apdorojimo procesų pasirinkimas sistemoje

Įrašo analizės metu, sistemos naudotojui rodoma tekstinė informacija ir animacija kurie pateikiami 5.16 paveiksle. Proceso vykdymo indikatorius informuoja naudotoją apie vykdoma procesą. Įrašo įkėlimas į sistemą ir pačio įrašo analizavimas užtrunka iki minutės.



5.16 pav. Sistemos įrašo apdorojimo proceso vykdymo indikatorius

Atlikus sakinio įrašo apdorojimo procesą, atskirame puslapyje išvedami analizės rezultatai. Sistemos naudotojui išvedamas sėkmingos arba nesėkmingos analizės tekstas, o sėkmingos analizės rezultatai atvaizduojami diagrama su simbolių paaiškinimais ir gautų įrašų rezultatų procentiniais įverčiais rodančiais Parkinsono ligos tikimybę. Jei procentais išreikšta tikimybė patenka į ribą: [0 – 32)%, tuomet subjektas vertinamas kaip sveikas, jei patenka į ribą: [32 – 100]%, tuomet kaip sergantis. Sėkmingos analizės tekstinis pranešimas ir gautų rezultatų diagrama pateikiami 5.17 paveiksle.



© 2018 - Parkinsono ligos detekcijos sistema

5.17 pav. Sistemos gražinamų rezultatų langas

Ligos progreso stebėjimui, numatyta galimybė į sistemą įkelti ir apdoroti vienu metu iki 10 įrašų. Kiekvienas papildomas įrašas atvaizduojamas skirtingu simboliu, o lentelėje šalia diagramos


kiekvienam įrašui suformuojamas pavadinimas (pasirinkus 2 ir daugiau įrašų) atitinkantis įkelto į sistemą įrašo pavadinimą ir atitinkamai pateikiamas Parkinsono ligos tikimybės procentinis įvertis.

5.5. Prototipo testavimas

Realizuoto prototipo testavimas vykdomas iš internetinio puslapio siekiant įsitikinti, jog sukurtas sprendimas veikia patikimai. Testavimo metu bus nustatoma analizės trukmės priklausomybė nuo įrašų skaičiaus ir jų dydžio. Gautose rezultatuose bus vertinama tik įrašo apdorojimo trukmė ir nevertinami naudotojo veiksmai (įrašo pasirinkimas) bei veiksmai, kuriuos atlieka puslapio serveris (įrašo įkėlimas, rezultatų išvedimas). Serverio naudojamo įrašo analizei techninės ir programinės įrangos resursai:

- Procesorius: *Intel Core i7-8700* 3.20 GHz;
- Operatyvioji atmintis: 32 GB;
- Operacinė sistema: 64-bit *Windows Server 2016*;


Pirmojo eksperimento metu atliekama įrašo analizės priklausomybė nuo įkeliamų įrašų skaičiaus pateikiama 5.18 paveiksle. Sukurtame puslapyje pasirenkant skirtingą įrašų skaičių (pvz. 1,2,...,10) atliekamas apdorojimo proceso trukmės matavimas.



5.18 pav. Įrašo analizės trukmės priklausomybė nuo įrašų skaičiaus

Eksperimento metu pasirinkti du įrašo failai: mažiausias ir didžiausias iš esamų duomenų bazės įrašų (133 KB ir 505 KB). Iš gaunamų charakteristikų galima pastebėti tiesinę priklausomybę, todėl sukuriant tiesinę regresiją, surandami koeficientai kiekvienam iš įrašų failų rodantys, kiek sekundžių padidėja analizės trukmė įkeliant kiekvieną papildomą įrašą. Iš gautų charakteristikų matome, jog 133 KB dydžio įrašo analizė trunka apie 11.6 s, o kiekvienas papildomas tokio dydžio failas prailgina analizę per 0.8 s. Didžiausio turimo failo atveju kiekvienas papildomas tokio paties dydžio failas analizę prailgina per 1.5 s. Taip pat iš gaunamų charakteristikų galime matyti kokiose ribose svyruoja analizės trukmė priklausomai nuo įrašų skaičiaus esant skirtingam failo dydžiui.

Antrojo eksperimento metu atlikta analizės trukmės priklausomybė nuo įrašo dydžio, kuri pateikiama 5.19 paveiksle. Papildomai išskaičiuota analizės spartos priklausomybė, rodanti kiek duomenų apdorojama per 1s. Galime pastebėti, jog didėjant failo dydžiui, apdorojimo sparta taip pat didėja, todėl analizės trukmės pokytis (nuo 11.4 s iki 12.7 s) mažiausiam ir didžiausiam (133 KB ir 505KB) įrašo failams yra nedidelis. Iš grafiko galime matyti tiesines priklausomybes, todėl taikant tiesinę regresiją surandame koeficientus, parodančius kiek padidėja analizės trukmė ar sparta, kai įrašo dydis padidėja 1 KB. Galime pastebėti, jog failo dydžiui padidėjus 1 KB, analizės trukmė padidėja per 0.004 s, o sparta per 0.076 KB/s.



5.19 pav. Įrašo analizės trukmės ir apdorojimo spartos priklausomybė nuo įrašo dydžio

Sistemos testavimo metu nustatyta įrašo apdorojimo trukmės priklausomybė nuo įrašų skaičiaus ir jų dydžio. Įvertintas bendras sistemos veikimas po visų numatytų metodų realizacijai apjungimo ir įsitinkinta, jog sistema veikia tinkamai ir atitinka sistemai keltus reikalavimus. Ateityje, realizuoto prototipo funkcionalumas gali būti plečiamas.

6. IŠVADOS

1. Atlikta Parkinsono ligos detekcijos iš balso ir kalbos signalų literatūros analizė parodė, jog įrašo apdorojimo procesas ligos aptikimui susideda iš šių pagrindinių žingsnių: požymių išskyrimo, gautų požymių suspaudimo, klasifikavimo ir sprendimo priėmimo etapų. Ankstesniuose tyrimuose naudotos mažos duomenų imtys yra vienas iš pagrindinių rezultatų patikimumą kvestionuojančių aspektų.
2. Esamų kalbos signalo apdorojimo priemonių ir metodų analizė atskleidė, jog analizės procesui naudojami labai įvairūs požymiai ar požymių rinkiniai. Požymių išskyrimui pasirinkta *Essentia* atviro kodo biblioteka, pasižyminti didele požymių įvairove. Požymių suspaudimui naudotas populiarus ir dažnai naudojamas GMM, o gauti rezultatai lyginti su paprastesniu sprendimu – 13 statistinių funkcijų. Detekcijai pasirinktas atsitiktinio miško klasifikatorius, pasižymintis atsparumu persimokymui, bei dažnai naudojamas turint dideles duomenų imtis.
3. Atliktų eksperimentų rezultatai parodė, jog duomenų bazei sudarytai iš akustiniu mikrofonu įrašytų įrašų, naudojant 32 centrų GMM metodą EER siekė 13.41%, o 13 statistinių funkcijų 13.43%. Mobilaus telefono mikrofonu įrašyti duomenų bazei 26.65% EER pasiektas naudojant 16 centrų GMM, o naudojant statistines funkcijas EER siekė 31.58%. ROC kreivių analizė atlikta naudojant skirtingų tipų mikrofonais gautus įrašus parodė, jog gauti AUC skirtumai lyginamiems požymių suspaudimo metodams nėra statistiškai reikšmingi. Eksperimentiškai parinktas optimalus GMM centrų skaičius akustinio mikrofono atveju – 32, išmanaus telefono atveju – 16, didinant ar mažinant šį skaičių EER didėja.
4. Sukurtas programinis prototipas – neinvazinis įrankis realizuojantis pasirinktus metodus – pasiekiamas Internetu, leidžiantis sistemos naudotojui nesunkiai atlikti savo kalbos įrašo analizę ir gauti procentinę Parkinsono ligos tikimybę iš akustinės analizės. Rezultatų pateikimas dvimatėje erdvėje pagerina medicininių sprendimų palaikymą, leidžia patogiai rasti panašius atvejus, stebėti ligos progresą. Ekspertinės sistemos realizacija panaudojant *Matlab* produkcijos serverį, leidžia sprendimą integruoti į jau egzistuojančius sukurtus puslapius ar sistemas.
5. Darbo metu palyginti du metodai – pagrindinės statistinės funkcijos ir GMM naudojami kalbos signalo kadru suspaudimui bei nustatyta, jog GMM metodas labiau pagerina detekcijos tikslumą, kai naudojami išmanaus telefono mikrofonu gauti įrašai. Tačiau skirtumai, remiantis AUC įverčiu iš ROC kreivių, nepasirodė statistiškai reikšmingi.

7. LITERATŪRA


- [1] O. Hornykiewicz, „Biochemical aspects of Parkinson's disease,“ *Neurology*, t. 51, nr. 2, pp. 2-9, 1998.
- [2] M. C. de Rijk, L.J. Launer, K. Berger, A. Hofman, „Prevalence of Parkinson's disease in Europe: A collaborative study of population-based cohorts,“ *Neurology*, t. 54, nr. 11, pp. 21-23, 2000.
- [3] J. A. Logemann, H. B. Fisher, B. Boshes, E. R. Blonsky, „Frequency and cooccurrence of vocal tract dysfunctions in the speech of a large sample of Parkinson patients,“ *Speech and Hearing Disorders*, t. 43, pp. 47-57, 1978.
- [4] A. K. Ho, R. Iansek, C. Marigliani, J. L. Bradshaw, S. Gates, „Speech impairment in a large sample of patients with Parkinson's disease,“ *Behavioural Neurology*, t. 11, nr. 3, pp. 131-137, 1998.
- [5] S. Perez-Lloret, L. N`egre-Pag`es, A. Ojero-Senard, „Orobuccal symptoms (dysphagia, dysarthria, and sialorrhea) in patients with Parkinson's disease: preliminary analysis from the French COPARK cohort,“ *European Journal of Neurology*, t. 19, nr. 1, pp. 28-37, 2012.
- [6] N. Miller, L. Allcock, D. Jones, E. Noble, A. J. Hildreth, and D. J. Burn, „Prevalence and pattern of perceived intelligibility changes in Parkinson's disease,“ *Journal of Neurology, Neurosurgery and Psychiatry*, t. 78, nr. 11, pp. 1188-1190, 2007.
- [7] F. L. Darley, A. E. Aronson, J. R. Brown, „Differential diagnostic patterns of dysarthria,“ *Journal of Speech and Hearing Research*, t. 12, nr. 2, pp. 246-269, 1969.
- [8] G. J. Canter, „Speech characteristics of patients with Parkinson's disease. 3. Articulation, diadochokinesis, and over-all speech adequacy,“ *The Journal of Speech and Hearing Disorders*, t. 30, pp. 217-224, 1965.
- [9] A. P. Zarzur, A. C. Duprat, G. Shinzato, C. A. Eckley, „Laryngeal electromyography in adults with Parkinson's disease and voice complaints,“ *Laryngoscope*, t. 117, nr. 5, pp. 831-834, 2007.
- [10] C. G. Goetz, S. Fahn, P. Martinez-Martin, „Movement Disorder Society-Sponsored Revision of the Unified Parkinson's Disease Rating Scale (MDS-UPDRS): Process, Format, and Clinimetric Testing Plan,“ *Movement Disorders*, t. 22, pp. 41-47, 2007.
- [11] C. G. Goetz, W. Poewe, O. Rascol, „Movement Disorder Society Task Force Report on the Hoehn and Yahr Staging Scale: Status and Recommendations,“ *Movement Disorders*, t. 19, p. 1020-1028, 2004.
- [12] J.M. Fearnley, A.J. Lees, „Ageing and Parkinson's disease: substantia nigra regional selectivity,“ *Brain*, t. 114, nr. 5, p. 2283-2301, 1991.
- [13] J. H. Kordower, C. W. Olanow, H. B. Dodiya, Y. Chu, T. G. Beach, C. H. Adler, G. M. Halliday, R. T. Bartus, „Disease duration and the integrity of the nigrostriatal system in Parkinson's disease,“ *Brain*, t. 136, nr. 8, p. 2419-2431, 2013.
- [14] M. A. Little, P. E. McSharry, E. J. Hunter, J. Spielman, L. O. Ramig, „Suitability of dysphonia measurements for telemonitoring of Parkinson's disease,“ *IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING*, t. 56, nr. 4, pp. 1015-1022, Balandis 2009.
- [15] A. Tsanas, M. A. Little, P. E. Mcsharry, J. L. Spielman, L. O. Ramig, „Novel speech signal processing algorithms for high-accuracy classification of Parkinson's disease,“ *IEEE Transactions on Biomedical Engineering*, t. 59, nr. 5, pp. 1264-1271, 2012.
- [16] J. R. Orozco-Arroyave, J. D. Arias-Londoio, J. F. Vargas-Bonilla, E. Noth, „Analysis of speech from people with Parkinson's disease through nonlinear dynamics,“ *Lecture Notes in Computer Science*, t. 7911, pp. 112-119, 2013.
- [17] E. Vaičiukynas, A. Verikas, A. Gelžinis, M. Bačasuskienė, K. Vaškevičius, V. Uloza, E. Padervinskis, J. Čičelienė, „Fusing Various Audio Feature Sets for Detection of Parkinson's Disease from Sustained Voice and Speech Recordings,“ įtraukta *18th International Conference on Speech and Computer*, Budapest, Hungary, 2016.

- [18] E. Vaičiukynas, A. Verikas, A. Gelžinis, M. Bačauskienė, „Detecting Parkinson's disease from sustained phonation and speech signals,“ *Plos One*, 5 Spalis 2017. [Tinkle]. Available: <http://journals.plos.org/plosone/article?id=10.1371/journal.pone.0185613>. [Kreiptasi 30 Sausis 2018].
- [19] A. Šimulis, E. Vaičiukynas, „Exploiting voice signal decomposition in expert system for Parkinson's disease detection,“ įtraukta *IVUS*, Kaunas, 2017.
- [20] S. Sapir, L. O. Raming, J. L. Spielman, C. Fox, „Formant centralization ratio (FCR): A proposal for a new acoustic measure of dysarthric speech,“ *Journal of Speech Language and Hearing Research*, t. 53, nr. 1, pp. 114-125, 2010.
- [21] S. Skodda, W. Gronheit, U. Schlegel, „Intonation and speech rate in Parkinson's disease: General and dynamic aspects and responsiveness to Levodopa admission,“ *Journal of Voice*, t. 25, nr. 4, pp. 199-205, 2011.
- [22] J. Ruzs, R. Cmejla, H. Ruzickova, E. Ruzicka, „Quantitative acoustic measurements for characterization of speech and voice disorders in early untreated Parkinson's disease,“ *Acoustical Society of America*, t. 129, nr. 1, p. 350–367, 2011.
- [23] T. Bocklet, S. Steidl, E. Noth, S. Skodda, „Automatic Evaluation of Parkinson's Speech - Acoustic, Prosodic and Voice Related Cues,“ įtraukta *Proceedings of the 14th Annual Conference of the International Speech Communication Association (INTER-SPEECH)*, 2013.
- [24] J.R. Orozco-Arroyave, F. Honig, J. D. Arias-Londono, J.F. Vargas-Bonilla, K. Daqrouq, S. Skodda, J. Ruzs, E. Noth, „Automatic detection of Parkinson's disease in running speech spoken in three different languages,“ *The Journal of the Acoustical Society of America*, t. 139, nr. 1, p. 481–500, 2016.
- [25] E. Vaičiukynas, A. Gelžinis, A. Verikas, M. Bačauskienė, „Parkinson's disease detection from speech using convolutional neural networks,“ įtraukta *Social Informatics and Telecommunications Engineering*, Lecture Notes of the Institute for Computer Sciences, 2018, p. 206–215.
- [26] G. Muhammad, „Voice pathology detection using vocal tract area,“ įtraukta *European Modelling Symposium*, 2013, p. 164–168.
- [27] D.A. Reynolds, T.F. Quatieri, R.B. Dunn, „Speaker verification using adapted Gaussian mixture models,“ *Digital Signal Processing*, t. 10, nr. 1–3, pp. 19-41, 2000.
- [28] T. Kinnunen, H. Li, „An overview of text-independent speaker recognition: From features to supervectors,“ *Speech Communication*, t. 52, nr. 1, pp. 12-40, 2010.
- [29] L. Breiman, „Random forests,“ *Machine Learning*, t. 45, nr. 1, p. 5–32, 2001.
- [30] N. S'aenz-Lech'on, J. I. Godino-Llorente, V. Osma-Ruiz, P. G'omez-Vilda, „Methodological issues in the development of automatic systems for voice pathology detection,“ *Biomedical Signal Processing and Control*, t. 1, nr. 2, pp. 120-128, 2006.
- [31] J.A. Hanley, B.J. McNeil, „The meaning and use of the area under a receiver operating characteristic (ROC) curve,“ *Radiology*, t. 143, nr. 1, pp. 29-36, 1982.
- [32] N. Brümmer, E. de Villiers, „The BOSARIS Toolkit: Theory, Algorithms and Code for Surviving the New DCF,“ arXiv 1304(2865v1), Gruodis 2011. [Tinkle]. Available: <http://sites.google.com/site/bosaristoolkit/>.
- [33] D. Goksuluk, S. Korkmaz, G. Zararsiz, A. E. Karaagaoglu, „easyROC: An Interactive Web-tool for ROC Curve Analysis Using R Language Environment,“ *The R Journal*, t. 8, nr. 2, pp. 213-230, 2016.
- [34] D. M. W. Powers, „Evaluation: From Precision, Recall and F-Factor to ROC, Informedness, Markedness & Correlation,“ *Journal of Machine Learning Technologies*, t. 2, nr. 1, pp. 37-63, 2011.
- [35] T. Fawcett, „An introduction to ROC analysis,“ *Pattern Recognition Letters*, t. 27, nr. 8, pp. 861-874, 2006.

- [36] S. Janitza, C. Strobl, A. L. Boulesteix, „An AUC-based Permutation Variable Importance Measure for Random Forests,“ *BMC Bioinformatics*, t. 14, nr. 119, pp. 1-11, 2013.
- [37] L. Breiman, A. Cutler, „RFtools—for predicting and understanding data,“ Technical Report, Berkeley University, Berkeley, USA, 2004.
- [38] H. L. Kundel, M. Polansky, „Measurement of Observer Agreement,“ *Radiology*, t. 228, nr. 2, pp. 303-308, 2003.


8. PRIEDAI

8.1. priedas. Klasifikavimo klaidų pasiskirstymas priklausomai nuo RF medžių skaičiaus





8.1 pav. Klasifikavimo klaidų (OOB) lygio pasiskirstymo priklausomybė nuo medžių skaičiaus

8.2. priedas. Slenksčio parinkimo vertinimas akustinio mikrono atveju




8.2 pav. ROC kreivė (kairėje), jautrumo ir specifiškumo kreivės (dešinėje) naudojant 32 centrų GMM



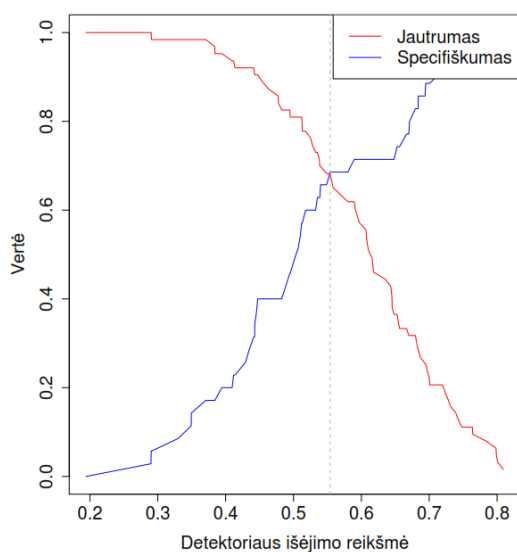

8.3 pav. Detektoriaus išėjimo reikšmės pasiskirstymas priklausomai nuo klasės bei optimalus slenktis (punktyrinė linija), prie kurio klasių klaidos susilygina naudojant 32 centrų GMM

8.3. priedas. ROC kreivių palyginimas naudojant išmanaus telefono mikrofona


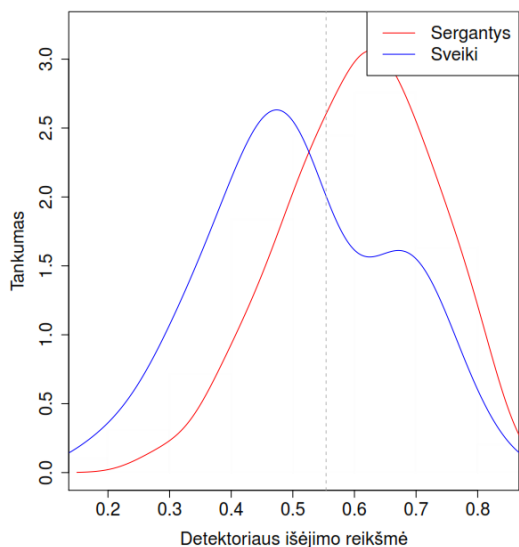


8.4 pav. 13 statistinių funkcijų ir 16 centrų GMM palyginimas naudojant ROC kreives



8.4. priedas. Slenksčio parinkimo vertinimas mobilaus telefono mikrono atveju



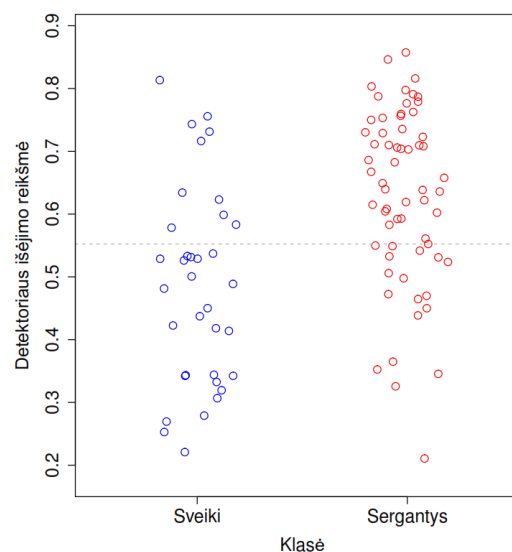

8.5 pav. ROC kreivė (kairėje), jautrumo ir specifiškumo kreivės (dešinėje) naudojant 13 statistinių funkcijų



8.6 pav. Detektoriaus išėjimo reikšmės pasiskirstymas priklausomai nuo klasės bei optimalus slenktis (punktyrinė linija), prie kurio klasių klaidos susilygina naudojant 13 matematinių statistikų



8.7 pav. ROC kreivė (kairėje), jautrumo ir specifiškumo kreivės (dešinėje) naudojant 16 centrų GMM



8.8 pav. Detektoriaus išėjimo reikšmės pasiskirstymas priklausomai nuo klasės bei optimalus slenktis (punktyrinė linija), prie kurio klasių klaidos susilygina naudojant 16 centrų GMM