



Kauno technologijos universitetas

Informatikos fakultetas

Parkinsono ligos atpažinimo naudojant balso duomenis tyrimas

Baigiamasis magistro projektas

Justas Buzaitis

Projekto autorius

Prof. Robertas Damaševičius

Vadovas

Kaunas, 2021



Kauno technologijos universitetas

Informatikos fakultetas

Parkinsono ligos atpažinimo naudojant balso duomenis tyrimas

Baigiamasis magistro projektas

Programų sistemų inžinerija (6211BX011)

Justas Buzaitis

Projekto autorius

Prof. Robertas Damaševičius

Vadovas

Prof. Rytis Maskeliūnas

Recenzentas

Kaunas, 2021



Kauno technologijos universitetas

Informatikos fakultetas

Justas Buzaitis

Parkinsono ligos atpažinimo naudojant balso duomenis tyrimas

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdama(s) kitų asmenų autoriaus ar kitų teisių, laikydamasi(s) Lietuvos Respublikos autorių teisių ir gretutinių teisių įstatymo nuostatų, Kauno technologijos universiteto (toliau – Universitetas) intelektinės nuosavybės valdymo ir perdavimo nuostatų bei Universiteto akademinės etikos kodekse nustatytų etikos reikalavimų;
2. baigiamajame projekte visi pateikti duomenys ir tyrimų rezultatai yra teisingi ir gauti teisėtai, nei viena šio projekto dalis nėra plagijuota nuo jokių spausdintinių ar elektroninių šaltinių, visos baigiamojo projekto tekste pateiktos citatos ir nuorodos yra nurodytos literatūros sąrašė;
3. įstatymų nenumatytų piniginių sumų už baigiamąjį projektą ar jo dalis niekam nesu mokėjęs (-usi);
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalinta(s) iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Justas Buzaitis

Patvirtinta elektroniniu būdu

Buzaitis, Justas. Parkinsono ligos atpažinimo naudojant balso duomenis tyrimas. Magistro (pasirinkite) baigiamasis projektas, vadovas prof. Robertas Damaševičius; Kauno technologijos universitetas, informatikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): informatikos mokslai.

Reikšminiai žodžiai: Parkinsono liga, balso analizė.

Kaunas, 2021. 73 p.

Santrauka

Parkinsono liga yra neurologinė liga, kuri kasmet pasireiškia vis daugiau žmonių. Nors liga yra nepagydoma, tačiau galima stabdyti jos progresavimą. Svarbu kuo anksčiau pastebėti ligą bei pradėti gydymą, nes ligos progresavimas gali lemti visišką prikaustymą prie lovos.

Vieni iš pirmųjų simptomų – balso pokyčiai, kurie dažnai gali likti nepastebėti. Tai gali būti sumažėjęs balso stiprumas, tono ir garso vienodumas, nederančios pauzės, netolygūs kalbėjimo paskubėjimai, balso prikimimas.

Šiame darbe nagrinėjama, kaip panaudojant žmogaus balso įrašus bei mašininio mokymosi metodus galima atpažinti Parkinsono ligą, pateikiama probleminės srities analizė, atlikto eksperimento detalės bei gauti rezultatai, aptariama sukurta sistema. Gale pateiktos apibendrintos išvados.

Buzaitis, Justas. Research of Parkinson's Disease Recognition Using Voice Data. Master's Final Degree Project, supervisor prof. Robertas Damaševičius; faculty of informatics, Kaunas University of Technology.

Study field and area (study field group): computing.

Keywords: Parkinson's disease, voice analysis.

Kaunas, 2021. 73 p.

Summary

Parkinson's disease is a neuronal disease that affects more and more people every year. Although Parkinson's disease is incurable, its progression can be stopped or slowed down. It is important to detect this disease as early as possible and take actions as the progression of the disease can lead to complete bedridden.

One of the first symptoms is voice changes which can often go unnoticed. These changes include decreased voice volume, tone and sound monotony, inconsistent pauses, uneven speaking rushes, jitter, shimmer.

In this work we examine how human voice recordings and machine learning methods can be used to recognize Parkinson's disease. In this document you can find the analysis of the problem area, the details of the performed experiment and the obtained results, discussed previously developed system. All conclusions are presented at the end.

Turinys

Lentelių sąrašas	8
Paveikslų sąrašas	10
Santrumpų sąrašas	11
1. Įvadas.....	12
1.1. Dokumento paskirtis.....	12
1.2. Darbo tikslas ir uždaviniai.....	12
1.3. Mokslinis naujumas.....	13
2. Probleminės srities analizė.....	14
2.1. Parkinsono ligos nustatymas ir sprendimų poreikis	14
2.2. Egzistuojančių sprendimų palyginimas	14
2.2.1. „Neural Impairment Test Suite“ apžvalga.....	15
2.2.2. „iPrognosis“ apžvalga	16
2.2.3. „Parkinson Check“	16
2.2.4. Sistemų lyginamoji analizė ir išvados	17
3. Projektinė dalis	18
3.1. Sistemos paskirtis	18
3.2. Apribojimai.....	18
3.2.1. Apribojimai sprendimui.....	18
3.2.2. Prieinama specializuota programinė įranga.....	18
3.2.3. Numatoma darbo vietos aplinka.....	18
3.3. Sistemos sudėtis (panaudojimo atvejų modelis).....	18
3.3.1. Sistemos ribos (panaudojimo atvejų diagrama)	18
3.3.2. Panaudos atvejai	19
3.4. Funkciniai reikalavimai ir reikalavimai duomenims	20
3.4.1. Funkciniai reikalavimai	20
3.4.2. Reikalavimai duomenims	21
3.5. Nefunkciniai reikalavimai	22
3.5.1. Reikalavimai sistemos išvaizdai.....	22
3.5.2. Reikalavimai panaudojamumui	22
3.5.3. Reikalavimai vykdymo charakteristikoms	23
3.5.4. Reikalavimai vykdymo sąlygoms.....	23
3.5.5. Reikalavimai sistemos priežiūrai.....	23
3.5.6. Reikalavimai saugumui	23
3.6. Architektūros specifikacija.....	23
3.6.1. Architektūros tikslai ir apribojimai	23
3.7. Sistemos statinis vaizdas	24
3.7.1. Apžvalga.....	24
3.7.2. Paketų detalizavimas	24
3.8. Sistemos dinaminis vaizdas	26
3.8.1. Veiklos diagramos	26
3.9. Išdėstymo vaizdas.....	28
3.10. Duomenų vaizdas	28
3.11. Balso analizės veikimas iš vartotojo perspektyvos	29
4. Parkinsono ligos atpažinimo naudojant balso duomenis sistemos tyrimas	31

4.1. Parkinsono ligos atpažinimo principai	31
4.1.1. Mašinos mokymui skirtų balso įrašų apdorojimas	31
4.1.2. Balso atributų radimas	33
4.1.3. Klasifikatoriaus parengimas	37
4.1.4. Vartotojo balso įvesties klasifikavimas	39
4.2. Parkinsono ligos atpažinimo trūkumai	40
4.2.1. Algoritmas nėra tikslus	40
4.2.2. Netinkamas mokymui naudojamas duomenų rinkinys bei jo apdorojimas	40
5. Parkinsono ligos atpažinimo naudojant balso duomenis eksperimentinė dalis	42
5.1. Eksperimento tikslai	42
5.2. Pasiruošimas eksperimentams	42
5.2.1. Balso įrašų rinkiniai	42
5.2.2. Reikalinga programinė įranga	42
5.3. Eksperimento metodika	43
5.4. Rezultatų vertinimas	43
5.5. Eksperimentų atlikimas	45
5.5.1. Balso duomenų skirstymas į grupes	45
5.5.2. Balso parametrų radimas	45
5.5.3. Klasifikatoriaus paieška	50
5.5.4. Rezultatai	53
Išvados	65
Literatūros sąrašas	66
Priedai	70
1 priedas. text_reading_cleaned_splitted_benchmarks.csv	70
2 priedas. text_reading_cleaned_full_benchmarks.csv	70
3 priedas. vowels_not_cleaned_benchmark.csv	70
4 priedas. vowels_cleaned_benchmark.csv	70

Lentelių sąrašas

1 lentelė. Programų palyginimo kriterijai.	15
2 lentelė. Programų palyginamoji lentelė („+“ – programa tenkina nurodytą kriterijų).	17
3 lentelė. PA - Nustatyti įrenginio atrakinimą balsu.	19
4 lentelė. PA - Atlikti skaitymo testą.	20
5 lentelė. PA - Peržiūrėti įrašų analizę.	20
6 lentelė. Reikalavimas – sistema turi registruoti įvykusias klaidas.	21
7 lentelė. A. Lauraičio balso duomenų rinkinio aprašymas.	31
8 lentelė. Sistemoje naudotų balso atributų aprašymas.	34
9 lentelė. Sistemos testavimui išbandytų klasifikatorių aprašymas.	37
10 lentelė. Klasifikatorių tikslumo palyginimo lentelė.	39
11 lentelė. Metrikos, kurios bus naudojamos algoritmo įvertinimui.	40
12 lentelė. Naudojamo klasifikatoriaus sumaišymo matrica.	40
13 lentelė. Tyrimui naudojamų duomenų aprašymas.	42
14 lentelė. Sumaišymo matricos šablonas.	44
15 lentelė. Metrikos, kurios bus naudojamos tyrimo metu.	44
16 lentelė. Tyrime naudotų pagrindinių balso atributų aprašymas.	46
17 lentelė. Rastų atributų suvestinė kiekvienai duomenų grupei.	50
18 lentelė. Tyrime naudotų klasifikatorių aprašymas.	51
19 lentelė. 3 geriausi klasifikatoriai pagal bendrą tikslumą naudojant išvalytus bei suskaidytus balso įrašus, kuriuose yra skaitomas tekstas.	53
20 lentelė. 3 geriausi klasifikatoriai pagal jautrumą naudojant išvalytus bei suskaidytus balso įrašus, kuriuose yra skaitomas tekstas.	53
21 lentelė. 3 geriausi klasifikatoriai pagal specifiškumą naudojant išvalytus bei suskaidytus balso įrašus, kuriuose yra skaitomas tekstas.	54
22 lentelė. 3 geriausi klasifikatoriai pagal F įvertį naudojant išvalytus bei suskaidytus balso įrašus, kuriuose yra skaitomas tekstas.	54
23 lentelė. 3 geriausi klasifikatoriai pagal MCC įvertinimą naudojant išvalytus bei suskaidytus balso įrašus, kuriuose yra skaitomas tekstas.	54
24 lentelė. 3 geriausi klasifikatoriai pagal bendrą tikslumą naudojant išvalytus pilnus balso įrašus, kuriuose yra skaitomas tekstas.	55
25 lentelė. 3 geriausi klasifikatoriai pagal jautrumą naudojant išvalytus pilnus balso įrašus, kuriuose yra skaitomas tekstas.	55
26 lentelė. 3 geriausi klasifikatoriai pagal specifiškumą naudojant išvalytus pilnus balso įrašus, kuriuose yra skaitomas tekstas.	55
27 lentelė. 3 geriausi klasifikatoriai pagal F įvertį naudojant išvalytus pilnus balso įrašus, kuriuose yra skaitomas tekstas.	56
28 lentelė. 3 geriausi klasifikatoriai pagal MCC įvertinimą naudojant išvalytus pilnus balso įrašus, kuriuose yra skaitomas tekstas.	56
29 lentelė. 3 geriausi klasifikatoriai pagal bendrą tikslumą naudojant nevalytus balso įrašus, kuriuose yra tariamos balsės.	57
30 lentelė. 3 geriausi klasifikatoriai pagal jautrumą naudojant nevalytus balso įrašus, kuriuose yra tariamos balsės.	57
31 lentelė. 3 geriausi klasifikatoriai pagal specifiškumą naudojant nevalytus balso įrašus, kuriuose yra tariamos balsės.	57

32 lentelė. 3 geriausi klasifikatoriai pagal F įvertį naudojant nevalytus balso įrašus, kuriuose yra tariamos balsės.....	58
33 lentelė. 3 geriausi klasifikatoriai pagal MCC įvertinimą naudojant nevalytus balso įrašus, kuriuose yra tariamos balsės.....	58
34 lentelė. 3 geriausi klasifikatoriai pagal bendrą tikslumą naudojant išvalytus balso įrašus, kuriuose yra tariamos balsės.....	59
35 lentelė. 3 geriausi klasifikatoriai pagal jautrumą naudojant išvalytus balso įrašus, kuriuose yra tariamos balsės.....	59
36 lentelė. 3 geriausi klasifikatoriai pagal specifiškumą naudojant išvalytus balso įrašus, kuriuose yra tariamos balsės.....	59
37 lentelė. 3 geriausi klasifikatoriai pagal F įvertį naudojant išvalytus balso įrašus, kuriuose yra tariamos balsės.....	59
38 lentelė. 3 geriausi klasifikatoriai pagal MCC įvertinimą naudojant išvalytus balso įrašus, kuriuose yra tariamos balsės.....	60
39 lentelė. Bendro tikslumo palyginimas su kitų autorių pasiektais rezultatais	63

Paveikslų sąrašas

1 paveikslėlis. Panaudos atvejų diagrama.....	19
2 paveikslėlis. Esybių diagrama.....	22
3 paveikslėlis. Paketų diagrama.....	24
4 paveikslėlis. Vartotojo paketo klasių diagrama.....	25
5 paveikslėlis. Parkinsono ligos analizės paketo klasių diagrama.....	25
6 paveikslėlis. Parkinsono ligos testų paketo klasių diagrama.....	25
7 paveikslėlis. Spausdinių paketo klasių diagrama.....	26
8 paveikslėlis. Nustatyti įrenginio atrakinimą balsu.....	26
9 paveikslėlis. PA – Atlikti skaitymo testą.....	27
10 paveikslėlis. Išdėstymo vaizdas.....	28
11 paveikslėlis. Esybių-ryšių modelis.....	29
12 paveikslėlis dvibalsių testo atlikimas.....	30
13 paveikslėlis. Balso spektro palyginimas prieš ir po išgryninimo.....	32
14 paveikslėlis. Balso įrašo garso svyravimų palyginimas prieš ir po išskaidymo.....	33
15 paveikslėlis. Balsų atributų sąrašas naudotas mašina mokyt.....	34
16 paveikslėlis. Teksto skaitymo bei balso „a“ tarimo spektrogramų palyginimas.....	41
17 paveikslėlis. Eksperimento darbų sekos diagrama.....	43

Santrumpų sąrašas

LSMU – Lietuvos sveikatos mokslų universitetas.

PD – Parkinsono liga (angl. „Parkinson disease“).

HC – Sveiki kontroliniai asmenys (angl. „healthy control“).

MMC – Matthews koreliacijos koeficientas (angl. „Matthews Correlation Coefficient“).

1. Įvadas

Parkinsono liga – tai nepagydoma ir nuolatos progresuojanti neurologinė liga, dėl kurios nyksta dopaminą gaminančios smegenų ląstelės [1]. Dopaminas yra neurotransmiteris, kuris atsakingas už efektyvų nervinių signalų siuntimą tarp įvairių kūno nervų ląstelių ir smegenų [2]. Šio cheminio junginio mažėjimas sukelia motorikos sutrikimus, tokius kaip įvairių kūno raumenų drebinimai ar virpuliai.

Skaičiuojama, kad Parkinsono liga serga maždaug nuo 7 iki 10 milijonų žmonių visame pasaulyje ir 10848 žmonių Lietuvoje (2015 metų duomenimis) [3] [4]. Liga paprastai diagnozuojama 60 metų ir vyresniems žmonėms, tačiau ji gali pasireikšti ir jaunesnio amžiaus žmonėms [5]. Pastebėta, jog amžiaus vidurkis, kada pasireiškia Parkinsono liga kasmet mažėja.

Nors liga yra nepagydoma ir nuolat progresuoja, tačiau yra priemonių pristabdančių ligos progresavimą. Svarbu pastebėti ankstyvuosius ligos simptomus ir pradėti gydymą. Vieni iš pirmųjų pasireiškiančių simptomų yra balso pokyčiai, kurie dažnai gali likti nepastebėti. Balsas gali tapti švelnesnis, duslesnis, tylesnis, monotoniškas, kalbant gali atsirasti nederančios pauzės, netolygūs paskubėjimai [6].

Metai iš metų yra pastebimas vyresnio amžiaus žmonių skaičius augimas, kurie naudojami išmaniaisiais mobiliuosiuose įrenginiuose. Augantis mobiliųjų technologijų naudojimo skaičius suteikia galimybę pasinaudoti šiais įrenginiais sveikatos priežiūros tikslais ir kuriant ligų atpažinimo sistemas [7]. Didžioji dalis žmonių, kuriems Parkinsono ligos atpažinimo sprendimas yra aktualus, taip pat yra šiek tiek vyresni nei vidutinio amžiaus [8], todėl sprendimas turėtų būti tinkamas mobiliuosiuose įrenginiuose. Dėl šios priežasties šio darbo metu labiau bus orientuojamasi į balso įrašus, kurių įrašymui nebuvo naudojama speciali studija ar aukšto lygio įrašymo įranga.

1.1. Dokumento paskirtis

Šis dokumentas yra magistrantūros studijų baigiamasis darbas, kuriame yra analizuojamos galimybės atpažinti Parkinsono ligą panaudojus tik žmogaus balso įrašą. Bus pateikta Parkinsono ligos atpažinimo naudojant balso duomenis projektinė bei eksperimentinė dalys, probleminės srities analizė.

Gale dokumento aptarti gauti tyrimo rezultatai bei pateiktos galutinės išvados.

1.2. Darbo tikslas ir uždaviniai

Tikslas: iširti Parkinsono ligos atpažinimo naudojant balso duomenis metodus

Uždaviniai:

- atlikti probleminės srities analizę;
- aptarti Parkinsono ligos atpažinimo naudojant balso duomenis sistemą, sukurtą kaip projektinę magistrinio darbo dalį;
- atlikti Parkinsono ligos atpažinimo naudojant balso duomenis eksperimentus;
- rasti tinkamiausią metodą Parkinsono ligai atpažinti panaudojus turimus balso įrašus;
- suformuluoti Parkinsono ligos atpažinimo naudojant balso duomenis rekomendacijas.

1.3. Mokslinis naujumas

1. Pasiūlytas ir aprašytas balso paruošimo analizei metodas išvalant fono triukšmą bei suskaidant balsą į lygias atkarpas, kuriose yra girdimas balsas.
2. Suprojektuota, sukurta ir ištirta Parkinsono ligos atpažinimo naudojant balso duomenis sistema.

2. Probleminės srities analizė

2.1. Parkinsono ligos nustatymas ir sprendimų poreikis

Parkinsono ligos nustatymas šiuo metu yra gana ribotas, nes liga nustatoma pasikliaunant pagrindiniais simptomais: sulėtėję judesiai, drebėjimas, pusiausvyros nestabilumas [10]. Šie simptomai yra gana akivaizdūs ir matomi plika akimi be papildomos įrangos. Pasireiškus šiems simptomams dažnai liga jau būna stipriai pažengusi. Tačiau yra simptomų, kurie nėra pastebimi plika akimi. Vieni tokių yra balso pokyčiai.

Yra atlikta nemažai tyrimų ir eksperimentų, kurių metu buvo analizuojami algoritmai galintys parodyti, kokia tikimybė, kad žmogus turi Parkinsono ligą [43, 53] arba ligas, kurios turi panašius simptomus, pavyzdžiui, Huntingtono ligą [50, 52] arba Alzheimerio ligą [51]. Pavyzdžiui, straipsnio [9] autoriai tyrė 88 vokiškai kalbančius asmenis, kurių visi turėjo Parkinsono ligą. Atrinkti asmenys turėjo atlikinėti įvairius balso pratimus priešais pastatytą mikrofoną. Buvo vertinamos asmenų balso savybės naudojant keturias sistemas bei visas 9 balso savybes gautas įrašų metu. Buvo gautas 81,9 % tikslumas. Tiesa, klasifikatoriai buvo ieškomi eksperimentiniu būdu. Įdomi detalė išryškėjusi analizuojant duomenis buvo ta, jog amžius bei lytis neturi įtakos Parkinsono ligai.

Dar vienas, panašus tyrimas buvo paskelbtas straipsnyje [11]. Jo metu buvo ištirtas 31 žmogus, tarp kurių buvo 23 žmonės turintys Parkinsono ligą. Balso įrašuose žmonės tarė įvairias balse. Tiesa, balso parametrai buvo jau paruošti, o tyrimo tikslas buvo rasti ryšį tarp balso parametrų ir Parkinsono ligos. Taip pat balso pavyzdžiai buvo surinkti naudojant specialią įrangą, todėl buvo išvengta foninio triukšmo. Surinkus įvairių įrašų ir juos analizavus eksperimentiniu būdu (naudojant „Weka“ programinę įrangą) pavyko pasiekti 90,26 % tikslumą su „Random Forest“ algoritmu.

Taip pat verta paminėti tyrimą [12]. Jo metu buvo ieškoma akustinių ir fonetinių savybių žmonių, sergančių Parkinsono liga, balse. Rezultatai parodė, kad F1 ir F2 tipo formantų (viena iš garso savybių) dažnumas tariant balse buvo pastebimai didesnis žmonių, kurių Parkinsono ligos rodiklis buvo didesnis.

Deja, sprendimų, prognozuojančių asmens tikimybę turėti Parkinsono ligą naudojant balso įrašą vis dar trūksta.

2.2. Egzistuojančių sprendimų palyginimas

Šiuo metu yra keletas sistemų, skirtų atpažinti Parkinsono ligai. Siekiant sukurti tinkamą platformą, buvo išanalizuotos kelios Parkinsono ligos atpažinimo sistemos, norint išsiaiškinti jų privalumus ir trūkumus, į kuriuos, kuriant naują sistemą, buvo atsižvelgta ir bandoma patobulinti. Analizavimui pasirinktos sistemos, kurios buvo populiariausios pagal atsisiuntimus.

Prieš atliekant esamų sistemų analizę buvo peržvelgtos įvairios neurologinius sutrikimus vertinančios sistemos ir parinktos labiausiai panašios į mano kuriamą sistemą. Šios sistemos yra: „Neural Impairment Test Suite“ [13], „iPrognosis“ [14], „Parkinson Check“ [15].

Konkurentinių programėlių analizei iškelti kriterijai ir jie paaiškinti 1 lentelėje.

1 lentelė. Programų palyginimo kriterijai.

Palyginimo kriterijus	Aprašymas
Pritaikyta vyresnio amžiaus žmonėms	Grafinė sąsaja yra suprantama senyvo amžiaus asmenims, spalvos ryškios, tekstas įskaitomas, nėra pateikiama perteklinės ir nestruktūrizuotos informacijos.
Analizei naudojamas mašininis mokymasis	Nuspręsti, ar vartotojas turi Parkinsono ligai būdingų savybių, naudojamas mašininis mokymasis.
Analizuojamas žmogaus balsas	Parkinsono ligai atpažinti naudojami vartotojo balso duomenys.
Įrankis geba parašyti išvadas	Įrankis ne tik analizuoja, bet ir geba parašyti aiškias, paprastam vartotojui suprantamas išvadas, pavyzdžiui, skalėje.
Programėlę galima prisitaikyti pagal save	Kadangi programėlė naudosis vyresni žmonės, svarbu, kad programėlėje būtų grafinės sąsajos nustatymai, tokie kaip šrifto dydis, spalvos.

2.2.1. „Neural Impairment Test Suite“ apžvalga

„Neural Impairment Test Suite“ programėlė skirta įsivertinti savo elgsenos pasikeitimu bėgant laikui arba palyginti jas su standartiniais duomenimis, kurie gali signalizuoti apie įvairius nervinius sutrikimus. Tarp šių sutrikimų yra ir Parkinsono liga.

Pirmas išpūdis, kuris susidarė naudojant programėlę, buvo neaiškumas. Nėra jokių paaiškinimų, kaip pradėti naudotis, kaip įsivertinti, kaip gauti rezultatus. Testų, kuriuos reikia atlikti, norint sužinoti ar yra nervinių sutrikimų, yra net 15, tačiau nėra paaiškinimų, kokia seka juos atlikti, ar juos būtina visus atlikti. Taip pat atliekant testus sistema parodė klaidą ir išsijungė net keletą kartų. Nebuvo jokių perspėjimų, kad „Neural Impairment Test Suite“ yra nepritaikyta įrenginiams, kuriais buvo atliekamas testavimas. Tai rodo sistemos nepatikimumą.

Grafinė sąsaja nėra itin patogi. „Neural Impairment Test Suite“ programėlės visą meniu sudaro testų pavadinimai, nustatymų piktograma ir nuoroda į išspręstų testų istoriją, kuri neveikė. Testai sugrupuoti į keturias grupes: drebulio sutrikimams, pažinimo sutrikimams, kalbos sutrikimams bei energijos išlaidoms skaičiuoti. Išsprendus testą pranešama apie sėkmingą testo išsprendimą, tačiau neatveriami langai į analizes ar bet kokius įsivertinimo puslapius.

Sistemoje yra apgalvota svarbi funkcija – šrifto keitimas. Kadangi „Neural Impairment Test Suite“ tikslinė grupė yra vyresni nei vidutinio amžiaus žmonės, kurie gali turėti įvairių sutrikimų, šrifto dydis yra svarbi savybė. Kaip bebūtų, keičiant šriftą keičiasi tik aprašymų ir kai kurių mygtukų dydis. Bekeičiant šrifto dydį, kai kurios piktogramos pradingsta už ekrano ribų.

„Neural Impairment Test Suite“ programėlė nėra pritaikyta prie įvairių ekranų. Sistema buvo testuota naudojant 5, 5.2, 5.5 ir 11 colių ekranus. Tik naudojantis 11 colių ekranu buvo galima matyti nenukirptus užrašus bei sėkmingai atlikti visus testus, net ir pasididinus šriftą.

Kaip nurodyta „Neural Impairment Test Suite“ apraše, šioje programėlėje duomenis interpretuoja pats vartotojas. Jis gali palyginti savo testų rezultatus su rezultatais, kurie yra gauti panaudojus mašininį mokymąsi. Tačiau pati programėlė neapskaičiuoja, kokia tikimybė turėti nervinių sutrikimų, ir neparodo rezultatų su pasiklovimo procentu.

2.2.2. „iPrognosis“ apžvalga

„iPrognosis“ programėlė skirta žmonėms, norintiems prisidėti prie Parkinsono ligos atpažinimo. Ši programėlė kol kas nepateikia išvadų apie sveikatą. Tai tarsi pirmasis „EU H2020“ sveikatos programos žingsnis kovoti su Parkinsono liga. „iPrognosis“ surinkti duomenys keliauja Parkinsono ligos tyrinėtojams, kurie stengiasi rasti tinkamiausia algoritmą, paremtą mašininio mokymusi. Vėliau šį algoritmą planuojama įdėti į programėlę.

„iPrognosis“ didžiausias plusas – duomenų rinkimas fone. Ši programėlė balso duomenis renka analizuodama skambučius, vartotojo judesiai nuolat stebimi naudojant vidinį telefono akselerometrą, nueinama distanciją pagal GPS duomenis. „iPrognosis“ taip pat turi klaviatūrą, kuri stebi įvairius vartotojo netikslumus. Taip pat galima naudojant programėlės kamerą pasidaryti asmenukę, kuri bus naudojama nuotaikų analizei vėlesniems tyrimams. Nors duomenų surenkama daug, tačiau toks platus rinkimas tiesiogiai veikia bendrą telefono sparą – gali greičiau išsikrauti baterija, sulėtėti kitos telefone veikiančios programėlės.

Šiuo metu „iPrognosis“ veikia mažai šalių: Vokietijoje, Portugalijoje, Jungtinėje Karalystėje, Ispanijoje, Austrijoje, Graikijoje, Čilėje ir Australijoje. Per tiek šalių ji turi vos 53 atsisiuntimus, nors buvo sukurta dar 2017 metais. Tai gali reikšti ribotus, nepatikimus duomenis.

2.2.3. „Parkinson Check“

„Parkinson Check“ programėlė skirta piešimo metodu atpažinti Parkinsono ligos simptomus. Atlikus spiralės piešimo testą programėlė įvertina rezultatus ir pateikia penkiabalę skalę su surinktu įverčiu.

„Parkinson Check“ programėlę paprasta naudoti, yra pakankamai paaiškinimų. Grafinės sąsajos nepatogumas yra mažas šriftas, kurio neįmanoma pasididinti. Tai sukeltų sunkumų vyresnio amžiaus žmonėms.

Ne mažiau svarbu ir tai, jog atsidarius „Parkinson Check“ programėlę mus pasitinka slavų kabos meniu, be jokio kalbos pasirinkimo ar kalbos nustatymo pagal vietovę. Tai gali būti itin nepatogu bet kuriam vartotojui, norinčiam išbandyti programėlę.

Dar vienas programėlės trūkumas yra vienintelis spirografijos testas. Spirografija – piešimo metodas skirtas atpažinti drebuliui, kurio metu yra piešiama spiralė. Buvo nustatyta, jog spirografijos metodai koreliuoja su Parkinsono ligos vertinimo skale [16]. Šiam testui tikslių skaičiavimų nėra, todėl spirografijos rezultatas yra subjektyvus. „Parkinson Check“ aprašyme pažymėta, jog rezultatai remiasi būtent parametų apskaičiavimais ir įvertinimais. Tai gali reikšti netikslus rezultatus.

2.2.4. Sistemų lyginamoji analizė ir išvados

Atlikus esamų sistemų, „Neural Impairment Test Suite“, „iPrognosis“, „Parkinson Check“ apžvalgą atlikta lyginamoji analizė, kuri pateikta 2 lentelėje. Šios esamos sistemos lygintos su kuriamą sistema, pagal pasirinktus kriterijus (1 lentelė).

2 lentelė. Programų palyginamoji lentelė („+“ – programa tenkina nurodytą kriterijų).

Palyginimo kriterijus	„Neural Impairment Test Suite“	„iPrognosis“	„Parkinson Check“	Sukurta sistema
Pritaikyta vyresnio amžiaus žmonėms		+		+
Analizei naudojamas mašininis mokymasis	+		+	+
Analizuojamas žmogaus balsas	+	+		+
Įrankis geba parašyti išvadas			+	+
Programėlę galima prisitaikyti pagal save	+			+

Atlikus lyginamąją analizę ir išanalizavus gautus duomenis galime pastebėti, kad panašiausia į kuriamą yra „Neural Impairment Test Suite“ sistema. Ši sistema geba analizuoti žmogaus balso duomenis, o tam naudoja mašininį mokymąsi. Taip pat programėlėje yra nustatymai, kuriais galima keisti šrifto dydį. Kitos lygintos sistemos, „iPrognosis“, „Parkinson Check“, taip pat yra panašios į sukurtą sistemą, tačiau ne tiek, kiek „Neural Impairment Test Suite“. Pažymėtina, kad vienintelė iki galo realizuota ir veikianti sistema buvo „Parkinson Check“.

3. Projektinė dalis

3.1. Sistemos paskirtis

Parkinsono ligos analizės naudojant balso duomenis sistemos paskirtis – padėti programėlės turėtojams pastebėti pirmuosius Parkinsono ligos simptomus ir atpažinti progresuojančią ligą. Ankstyvas ligos pastebėjimas gali padėti sustabdyti ligos progresavimą.

Kadangi ligonių, kurie galėtų pasinaudoti šia sistema artimoje aplinkoje nėra, todėl programėlė yra prototipinė.

3.2. Apribojimai

3.2.1. Apribojimai sprendimui

1. Mažiausia palaikoma „Android“ versija yra 8.0.
2. Mažiausias ekranas, kuris privalo būti palaikomas yra 5 colių.
3. Parkinsono ligos atpažinimo sistema turi veikt naudodama „HTTPS“ protokolą.

3.2.2. Prieinama specializuota programinė įranga

1. Parkinsono ligos atpažinimo sistemos diegimas mašinoje turi būti automatizuotas naudojant „Jenkins“.
2. Parkinsono ligos atpažinimo sistemos duomenų bazė turi naudoti „MySQL“ duomenų bazių valdymo sistemą.

3.2.3. Numatoma darbo vietos aplinka

1. Parkinsono ligos atpažinimo sistemos programėlė bus naudojama asmeniniuose telefonuose, planšetėse. Įrenginys turės turėti prieigą prie interneto.

3.3. Sistemos sudėtis (panaudojimo atvejų modelis)

3.3.1. Sistemos ribos (panaudojimo atvejų diagrama)

Panaudos atvejų diagramoje 1 paveikslėlyje pateikti Parkinsono ligos atpažinimo sistemos visi numatyti vartotojai bei jiems priskirti panaudos atvejai.

1 paveikslėlis. Panaudos atvejų diagrama.



3.3.2. Panaudos atvejai

Panaudos atvejų 3 – 5 lentelėse detalizuoti pagrindiniai panaudos atvejai, kuriuos gali atlikti visi sistemos vartotojai.

3 lentelė. PA - Nustatyti įrenginio atrakinimą balsu.

Tikslas	Nustatyti įrenginio atrakinimą balsu.
Dalyviai	Vartotojas
Ryšiai su kitais PA	Apima PA - Peržiūrėti balso analizės integracijas įrenginyje.
Prieš-sąlygos	<ul style="list-style-type: none"> Vartotojas turi įsidiegęs programėlę; įvykdytas PA – Peržiūrėti balso analizės integracijas įrenginyje.
Sužadinimo sąlyga	Vartotojas nori nustatyti įrenginio atrakinimą balsu.
Po-sąlyga	<ul style="list-style-type: none"> Vartotojas nustato įrenginio atrakinimą balsu; vartotojui pateikiamas balso integracijų sąrašas.
Pagrindinis scenarijus	<ol style="list-style-type: none"> Vartotojas paspaudžia ant įrenginio atrakinimo balsu mygtuko. Jei įrenginio atrakinimas balsu dar nėra nustatytas, sistema pateikia balso įrašymo langą. Vartotojas ištaria garsą ar žodį. Sistema pateikia patvirtinimo formą. Jei vartotojas patvirtina, sistema nustato įrenginio atrakinimą balsu.

	6. Sistema pateikia galimą balso analizės integracijų sąrašą.
Alternatyvūs scenarijai	2. Jei įrenginio atrakinimas balsu jau yra nustatytas, paspaudus ant nustatymo nuorodos, įrenginio atrakinimas balsu yra išjungiamas. 5. Jei vartotojas atmeta patvirtinimo formą dėl įrenginio atrakinimo nustatymo, sistema neatlieka pakeitimų bei pateikia galimą balso analizės integracijų sąrašą.

4 lentelė. PA - Atlikti skaitymo testą.

Tikslas	Atlikti balso analizę skaitymo metu.
Dalyviai	Vartotojas
Ryšiai su kitais PA	-
Prieš-sąlygos	Vartotojas turi įsidiegęs programėlę.
Sužadinimo sąlyga	Vartotojas nori atlikti skaitymo testą.
Po-sąlyga	Vartotojui parodomas langas su testo rezultatu.
Pagrindinis scenarijus	1. Vartotojas inicijuoja skaitymo testo atlikimą. 2. Sistema pateikia tekstą. 3. Vartotojas, nuspaudęs įrašymo mygtuką, perskaito tekstą. 4. Sistema atlieka analizę ir pateikia testo rezultatą.
Alternatyvūs scenarijai	-

5 lentelė. PA - Peržiūrėti įrašų analizę.

Tikslas	Peržiūrėti įrašų analizę.
Dalyviai	Vartotojas
Ryšiai su kitais PA	-
Prieš-sąlygos	Vartotojas turi įsidiegęs programėlę.
Sužadinimo sąlyga	Vartotojas nori peržiūrėti balso įrašų analizę.
Po-sąlyga	Vartotojui pateikiama jo balso įrašų analizė.
Pagrindinis scenarijus	1. Vartotojas inicijuoja balso įrašų analizės peržiūrą 2. Sistema pateikia naujausią vartotojo balso įrašų analizę.
Alternatyvūs scenarijai	-

3.4. Funkciniai reikalavimai ir reikalavimai duomenims

3.4.1. Funkciniai reikalavimai

6 lentelėje detalizuotas pagrindinis funkcinis reikalavimas Parkinsono ligos atpažinimo naudojant balso duomenis sistemai.

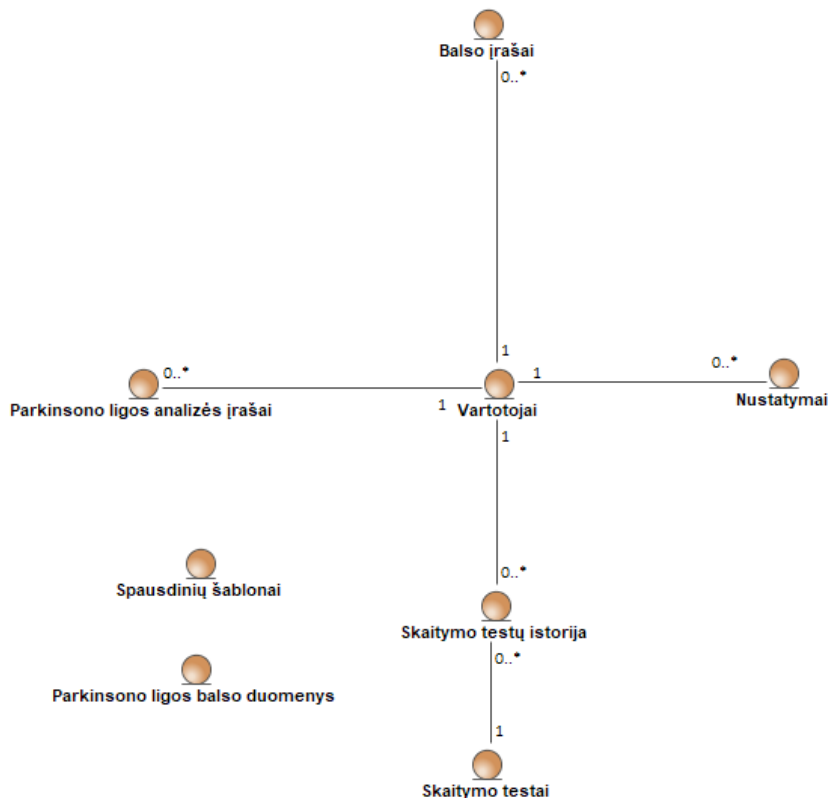
6 lentelė. Reikalavimas – sistema turi registruoti įvykusias klaidas.

Reikalavimas #:	1	Reikalavimo tipas:	9	Įvykis/panaudojimo atvejis #:	1
Aprašymas:	Sistema turi registruoti įvykusias klaidas.				
Pagrindimas:	Jeigu sistemoje įvyksta klaidų, svarbu rasti jų priežastį ir kaip įmanoma greičiau ją išspręsti. Registras padėtų greičiau rasti priežastį.				
Šaltinis:	Užsakovas				
Tinkamumo kriterijus:	Sukuriama atskira duomenų lentelė arba registras, kuriame bus renkama informacija apie klaidą: data, laikas, klaidos pranešimas, kita turima informacija.				
Užsakovo patenkinimas:	5	Užsakovo nepatenkinimas:	3		
Prioritetas:	Aukštas				
Priklausomybės:		Konfliktai:			
Papildoma medžiaga:					
Istorija:					

3.4.2. Reikalavimai duomenims

Reikalavimus duomenims apibrėšime esybių diagrama, kuri pateikta 2 paveikslėlyje. Centre yra vartotojų esybė, kuri yra susijusi su balso įrašų, Parkinsono ligos analizės įrašų, nustatymų, skaitymo testų istorijos esybėmis. Tai esybės, kurios bus tiesiogiai valdomos vartotojo. Taip pat sistemoje yra kelios su niekuo nesusiejamos pagalbinės esybės – spausdinių šablonai bei Parkinsono ligos balso duomenys. Spausdinių šablonai padeda spausdinant balso analizės ataskaitas, o Parkinsono ligos balso duomenys saugo įrašus, kuriais yra mokoma mašina.

2 paveikslėlis. Esybių diagrama.



3.5. Nefunkciniai reikalavimai

3.5.1. Reikalavimai sistemos išvaizdai

Nefunkciniai reikalavimai taikomi sistemos išvaizdai:

- sistemoje turi dominuoti mėlva ir balta spalvos;
- sistemoje turi būti naudojamas „Manrope“ šriftas;
- sistemos išvaizda turi atrodyti patikimai;
- sistema turi būti pakankamai paprasta naudoti, kad ja mokėtų naudotis žmonės, neturintys patirties darbui su kompiuteriu.

3.5.2. Reikalavimai panaudojamumui

Nefunkciniai reikalavimai taikomi sistemos panaudojamumui:

- sistema turi būti pakankamai paprasta naudoti, kad ja mokėtų naudotis žmonės neturintys patirties darbui su kompiuteriu;
- klaidų pranešimai, gaunami atlikus neteisingą veiksmą, turi būti aiškūs bet kuriam vartotojui;
- sistemoje turi būti vartojama taisyklinga anglų kalba;
- sistema turi būti paprasta išmokti naujiems programuotojams naudotis;

- sistema turi vartoti taisyklingą žodyną, rašybą, skyrybą;
- įvykus serverio klaidai, vartotojo sąsajos dalis negali pateikti detalios informacijos, susijusios su sisteminė klaida.

3.5.3. Reikalavimai vykdymo charakteristikoms

Nefunkciniai reikalavimai taikomi sistemos vykdymo charakteristikoms:

- sistemoje vaizduojami skaičiai, kurie nėra sveikieji, turi būti apvalinami;
- sistema turi būti prieinama visą parą;
- sistema turi užtikrinti, kad sistema sugebėtų apdoroti 1000 prisijungimo užklausų vienu metu.

3.5.4. Reikalavimai vykdymo sąlygoms

Nefunkciniai reikalavimai taikomi sistemos vykdymo sąlygoms:

- sistema turi veikti ant „Android“ bei „iOS“ sistemų;
- sistemos diegimas ir paleidimas serveryje turi būti automatizuotas;
- sistemai bus skirti du serveriai: testavimui ir produkcinis.

3.5.5. Reikalavimai sistemos priežiūrai

Vienintelis nefunkcinis reikalavimas taikomas sistemos priežiūrai – sistemos serverinė dalis turi būti pritaikyta veikti serveryje, turinčiame „Linux“ operacinę sistemą.

3.5.6. Reikalavimai saugumui

Nefunkciniai reikalavimai taikomi sistemos saugumui:

- sistema turi užtikrinti, jog nebūtų išsaugomi blogai įvesti duomenys iš vartotojo pusės;
- sistema turi informuoti vartotojus apie pasikeitusią duomenų politiką, jei ši susijusi su asmeniniais duomenimis.

3.6. Architektūros specifikacija

Architektūros specifikacijos paskirtis – išanalizuoti kuriamos sistemos architektūrą, atvaizduoti architektūrą įvairiomis diagramomis, kurios padeda pamatyti sistemą įvairiais pjūviais. Dokumento vartotojai galės lengviau ir greičiau suprasti sistemos veikimo principus.

3.6.1. Architektūros tikslai ir apribojimai

Aprašymas programinės įrangos tikslų ir reikalavimų, turinčių esminį poveikį architektūrai: COTS (angl. „commercial off-the-shelf“) produktų panaudojimas, portabilumas, paskirstymas (angl. „distribution“), pakartotinis panaudojimas (angl. „reuse“) ir t.t. Aprašymas apribojimų kaip:

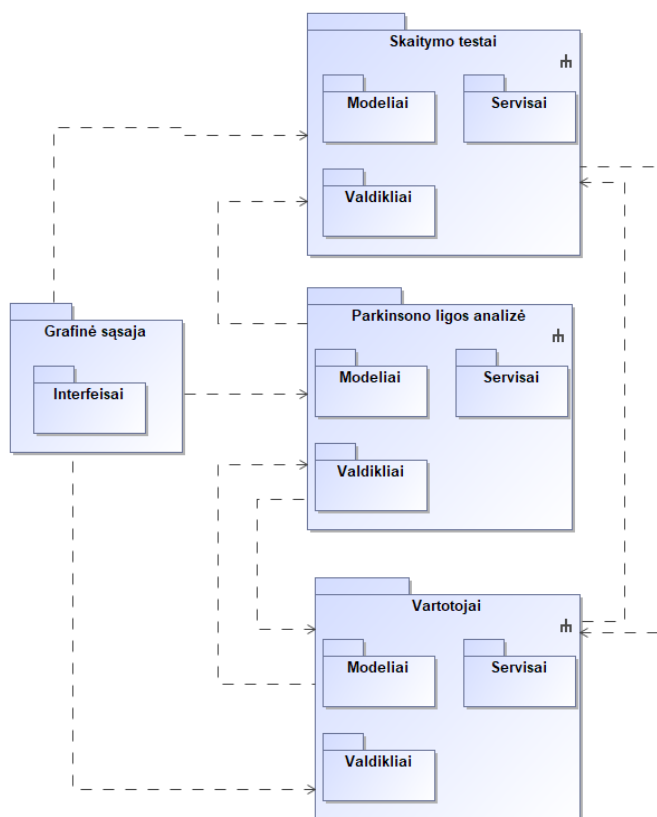
projektavimo ir įgyvendinimo (angl. „implementation“) strategija, projektavimo įrankiai, darbo grupės struktūra, darbo grafikas ir t.t.

3.7. Sistemos statinis vaizdas

3.7.1. Apžvalga

Parkinsono ligos atpažinimo naudojant balso duomenis sistemą sudaro 3 pagrindiniai paketai ir bendras paketas grafinei sąsajai. Tai paketai skirti Parkinsono ligos testams, Parkinsono ligos analizei bei vartotojams. Kiekvienas iš paketų savyje turi modeliams, servisams bei valdikliams skirtus katalogus. Architektūra sudaryta remiantis MVC (angl. „Model-View-Controller“) principu. Paketų sąryšis pavaizduotas 3 paveikslėlyje.

3 paveikslėlis. Paketų diagrama.



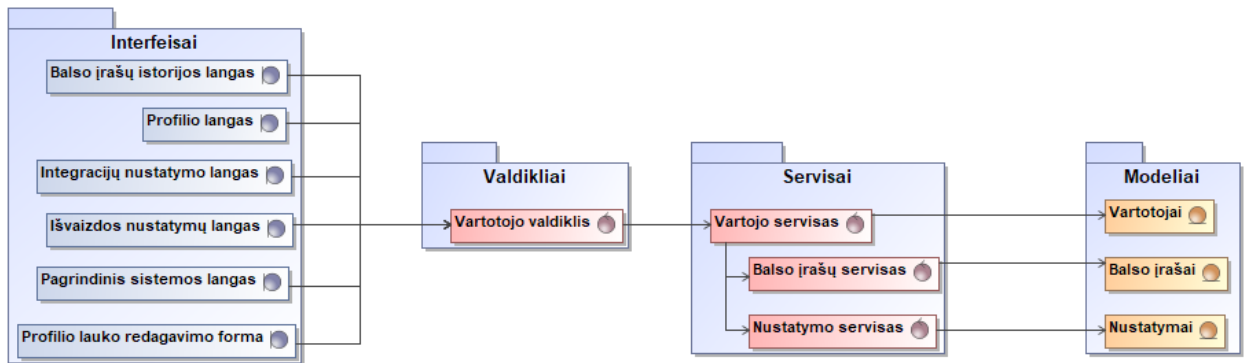
3.7.2. Paketų detalizavimas

Toliau detalizuosime kiekvieną iš paketų.

3.7.2.1. Vartotojo paketas

Vartotojo paketas susijęs su įvairiais vartotojo duomenimis: profilio duomenimis, balso įrašais, nustatymais. Vartotojo paketo klasių diagrama pavaizduota 4 paveikslėlyje.


4 paveikslėlis. Vartotojo paketo klasių diagrama.



3.7.2.2. Parkinsono ligos analizės paketas

Parkinsono ligos analizės paketas skirtas balso įrašų analizei. Parkinsono ligos analizės servise yra logika susijusi su mašininu mokymusi. Mašiniai mokytai naudojami balso duomenys iš anksto įdėti į duomenų bazę. Parkinsono ligos analizės klasių diagrama pavaizduota 5 paveikslėlyje.


5 paveikslėlis. Parkinsono ligos analizės paketo klasių diagrama.



3.7.2.3. Parkinsono ligos testų paketas

Parkinsono ligos testų paketas skirtas valdyti duomenis, susijusius su testais. Parkinsono ligos testai – tai įvairūs pratimai balsui, kurių tikslas išgauti kuo įvairesnius vartotojo balso parametrus. Parkinsono ligos testų klasių diagrama pavaizduota 6 paveikslėlyje.


6 paveikslėlis. Parkinsono ligos testų paketo klasių diagrama.



3.7.2.4. Spausdinių paketas

Spausdinių paketas skirtas pateikti vartotojų duomenis ir analizės rezultatus pdf formatu. Spausdinių klasių diagrama pavaizduota 7 paveikslėlyje.

7 paveikslėlis. Spausdinių paketo klasių diagrama.



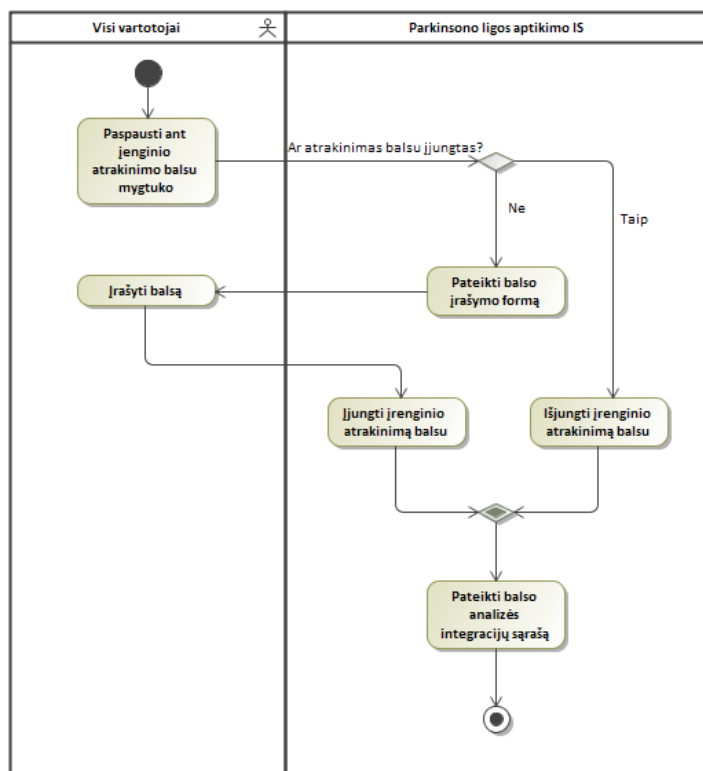
3.8. Sistemos dinaminis vaizdas

3.8.1. Veiklos diagramos

Svarbu atvaizduoti sistemoje atliekamus darbus, jų eiliškumą. Tam panaudosime veiklos diagramas. 8 – 9 paveikslėliuose pateiktos veiklos diagramos pagrindinėms sistemos funkcijoms.

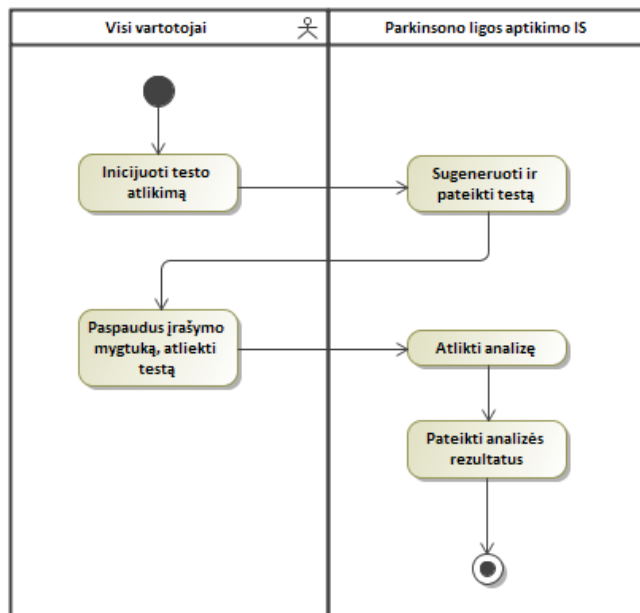
8 paveikslėlyje pateikta seka, kaip vartotojas gali nustatyti atrakinimą balsu. Sistemoje yra galimybė nustatyti, jog tam, kad vartotojas atrakintų savo įrenginį, turėtų pateikti savo balso pavyzdį. Atrakinant įrenginį, jam bus užduodamas klausimas, pavyzdžiui, „kaip tau sekasi?“. Šiuo būdu programėlė gauna dažnus vartotojo balso pavyzdžius. Šios funkcijos įjungimas yra nustatymuose. Paspaudus ant nuorodos, programėlė paprašys vartotojo įrašyti balsą ir ši įjungs įrenginio atrakinimo balsu funkciją.

8 paveikslėlis. Nustatyti įrenginio atrakinimą balsu.



9 paveikslėlyje pateikta seka, kaip atlikti skaitymo testą. Programėlėje pasirenkamas testo atlikimas bei pasirenkamas norimas testo tipas. Tuo metu sistema sugeneruoja testą bei pateikia jį vartotojui. Testą sudaro kelios paprastos užduotys, kurių metu vartotojo yra prašoma įrašyti balsą. Surinkusi balso pavyzdžius sistema juos analizuoja bei pateikia gautus rezultatus – koks vartotojo balso panašumas į Parkinsono liga sergančių žmonių balsą.

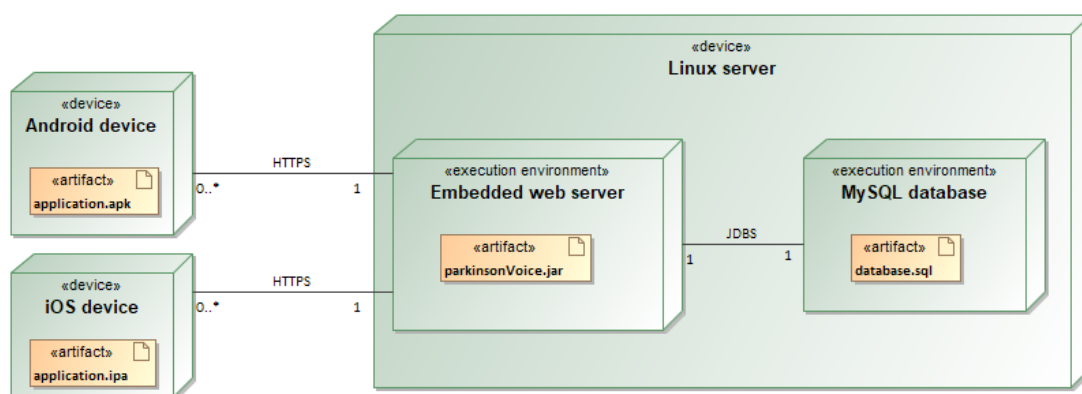
9 paveikslėlis. PA – Atlikti skaitymo testą.



3.9. Išdėstymo vaizdas

Parkinsono ligos atpažinimo naudojant balso duomenis sistemos diegimo architektūra susideda iš tinklo serverio, duomenų bazės serverio ir vartotojo programėlės. Tai vaizduoja 10 paveikslėlis. Tinklo serveris ir duomenų bazė veiks „Linux“ tipo serveryje. Tinklo serveris su duomenų baze komunikuoja naudojant „JDBC“ (angl. „Java Database Connectivity“) technologiją. Ji suteikia galimybę Java programai turėti sąsają su nepriklausoma duomenų baze. Visi tinklo serverio programai reikalingi failai bus sutraukti į „jar“ tipo archyvą, kuris bus paleistas naudojant įterptinį serverį. Įterptinis serveris - tai tam tikras komponentas programoje, kuris suteikia galimybę programai komunikuoti „HTTP“ protokolu. Duomenų bazei skirta informacija bus sudėta į „SQL“ tipo failą. Vartotojui skirta programėlė bus supakuota į „APK“ tipo failą, kuris bus skirtas įdiegti programėlę į „Android“ operacinės sistemos įrenginį. Programėlė su tinklo serveriu komunikuos naudojant „HTTPS“ protokolą.

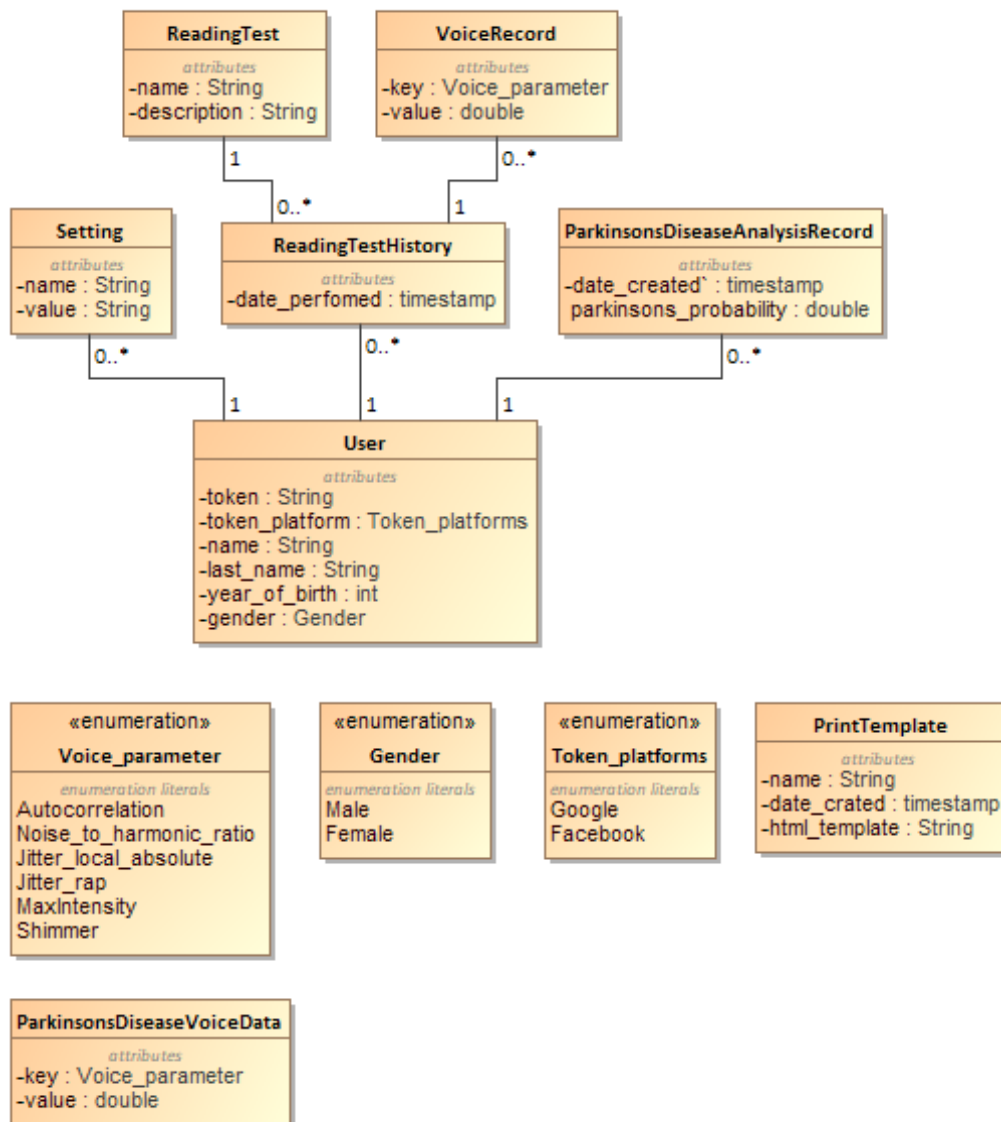
10 paveikslėlis. Išdėstymo vaizdas.



3.10. Duomenų vaizdas

Kad pamatytume, kaip anksčiau minėti modeliai (paketų diagramose) siejasi tarpusavyje, panaudojame esybių-ryšių modelį. Esybių-ryšių modelis pateiktas 11 paveikslėlyje.

11 paveikslėlis. Esysių-ryšių modelis.

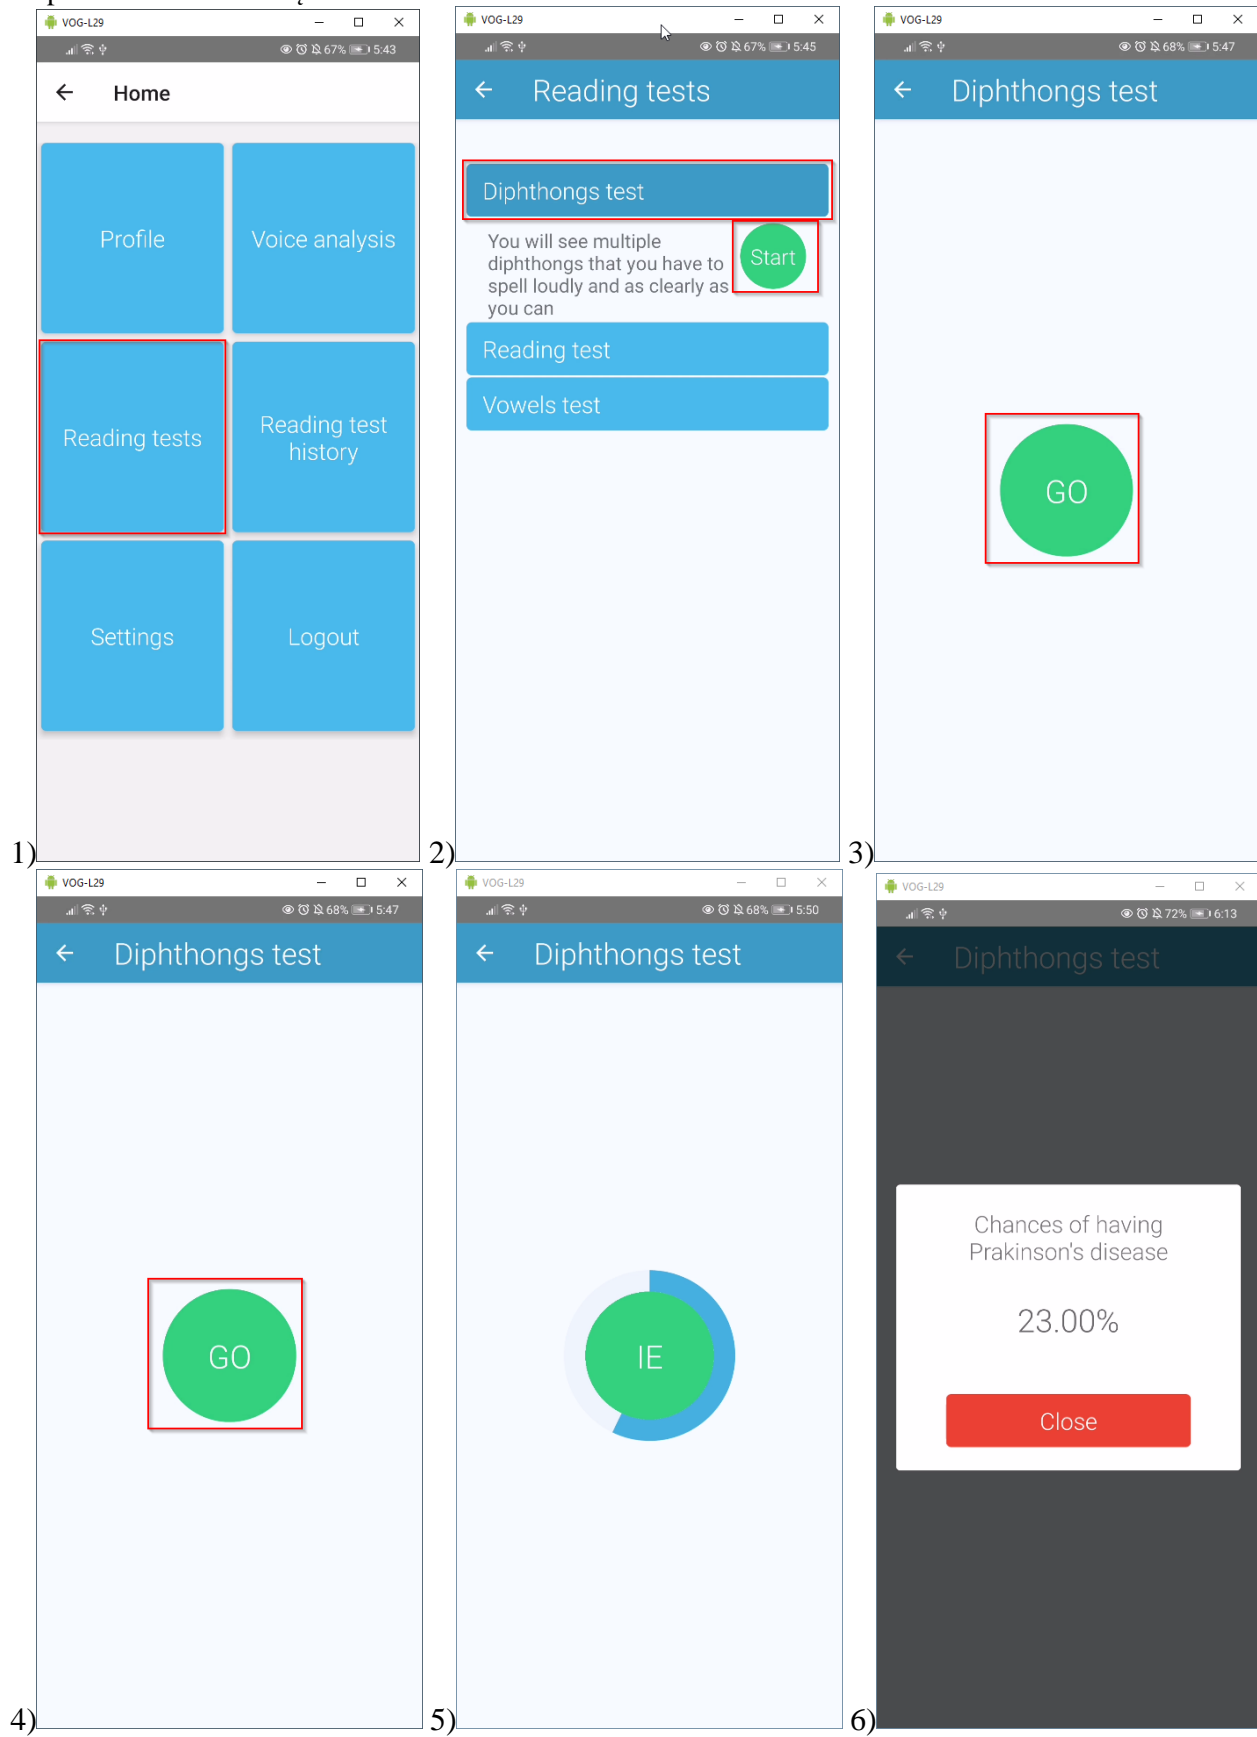


3.11. Balso analizės veikimas iš vartotojo perspektyvos

Pagrindiniame lange pasirenkame „Reading tests“. Atsidariusiame lange pasirenkame testą, kurį norime atlikti. Gauname trumpą aprašymą, kas mūsų laukia teste, spaudžiame mygtuką „Start“. Kai esame pasiruošę atlikti testą, spaudžiame „GO“. Laikydami telefono mikrofona 40 centimetrų atstumu nuo savęs stengiamės kuo aiškiau bei jūsų natūraliu kalbėjimo tonu ištartti ar perskaiityti ekrane matomus garsus ar žodžius (12 paveikslėlis).

Pasibaigus testui paspaudžiame mygtuką „Stop“, jei toks yra, arba tiesiog laukiame, kol pasibaigs analizė bei gausime rezultatus (12 paveikslėlis, 6 kadras).

12 paveikslėlis dvibalsių testo atlikimas.



4. Parkinsono ligos atpažinimo naudojant balso duomenis sistemos tyrimas

4.1. Parkinsono ligos atpažinimo principai

Parkinsono ligos atpažinimas sistemoje yra paremtas mašiniu mokymusi. Mašininis mokymasis – tai studijų sritis, suteikianti galimybę kompiuteriams atlikti užduotį be aiškaus kodo užrašymo [17]. Mašininis mokymasis padeda sudaryti matematinį modelį, kuris priklausys nuo duomenų [18]. Tai reiškia, kad mūsų sukurtas sprendimas bus dinaminis, galės tobulėti priklausomai tik nuo turimų duomenų pavyzdžių, jų skaičiaus.

Sistemoje naudojamą Parkinsono ligos atpažinimo procesą galima suskirstyti: mašinos mokymui skirtų balso įrašų apdorojimas, balso atributų radimas, vartotojo balso įvesties klasifikavimas.

4.1.1. Mašinos mokymui skirtų balso įrašų apdorojimas

Mašiniai mokytis mums reikalingi duomenys, kurie būtų priskirti vienai iš klasių – ar balsas yra žmogaus, kuris serga Parkinsono liga, ar yra sveikas. Apmokymui naudojami balso pavyzdžiai, kuriuos surinko dr. A. Lauraitis. Balso pavyzdžiai aprašyti A. Lauraičio disertacijoje [19] ir straipsniuose [20] [21]. Duomenų aprašymas pateiktas 7 lentelėje.


Turimą balso duomenų rinkinį apibūdina 9 lentelė. Rinkinį sudaro 367 balso įrašai, iš kurių 156 įrašai yra Parkinsono liga sergančių žmonių, o 211 sveikų žmonių. Balso įrašuose žmonės skaito Maironio eilėraščius „Lietuva brangi“ bei „Trakų pilis“.

7 lentelė. A. Lauraičio balso duomenų rinkinio aprašymas.

Žmonių skaičius	Sergantys Parkinsono liga	14
	Sveiki	17
Įrašų skaičius	Sergantys Parkinsono liga	156
	Sveiki	211
Įrašų ilgis	Nuo 3 iki 47 sek.	

Turimi balso įrašai nėra idealiai švarūs – kai kuriuose yra girdimas pašalinių žmonių balsas ar foninis triukšmas. Dėl šios priežasties balso įrašai buvo išvalomi – atskiriamas balsas nuo pašalinių garsų. Vienas populiariesnių ir efektyvių būdų tai padaryti – medianos filtras [22]. Balso įrašas turi būti paverčiamas chromagrama bei taikant nelokalų medianos filtrą (angl. „non-local median filter“) ši yra išvaloma bei konvertuojama atgal į balso įrašo formatą. Balso išgryninimui buvo panaudota „Python“ programavimo kalbos biblioteka „Librosa“ [23] – įrankis skirtas garso failų analizei bei jo funkcija „nn_filter“, kuri ir taiko šį metodą. Pavyzdį, kaip atrodo išgryninto balso spektras galima pamatyti 13 paveikslėlyje.

13 paveikslėlis. Balso spektro palyginimas prieš ir po išgryninimo.



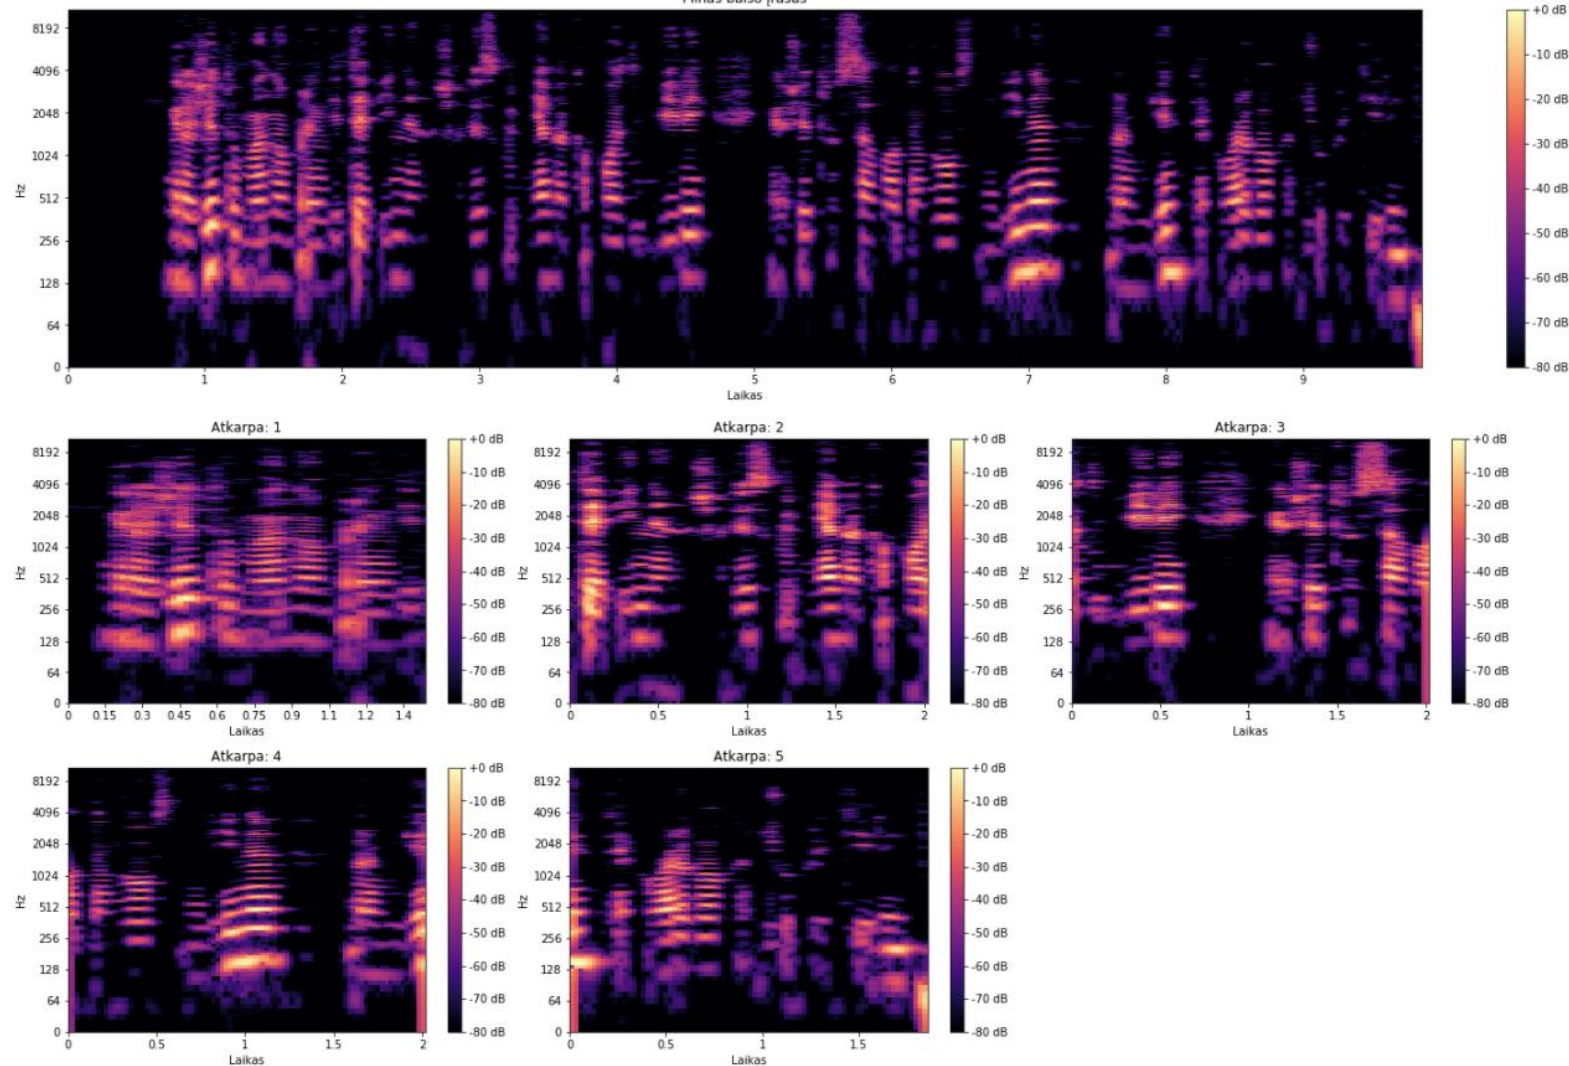
Turimas balso įrašų rinkinys bus naudojamas lyginimui su įvairaus tipo balso įrašais – balsių, dvibalsių tarimas, įvairaus teksto skaitymas. Taip pat svarbu pabrėžti, jog įvairūs balso parametrai yra skaičiuojami laiko momentui. Dėl to, norint naudoti teksto skaitymo balso įrašus lyginimui su balso įrašais, kurie gali būti įvairūs – balsių, dvibalsių pratimai, atsitiktinio teksto skaitymas, mums įrašus reikia skaidyti į nedideles balso atkarpas. Sistemoje pasirinktas atkarpos dydis – 2 sekundės. Tokio dydžio atkarpa buvo pasirinkta išankstinio tyrimo metu: klasifikatoriumi „Random Forest“ (aprašyta 4.1.3 skyriuje) buvo išanalizuotos balso atkarpos 0.5 – 5 sekundžių režiuose, taikant 0.5 sekundės intervalus ir būtent 2 sekundžių ilgio balso atkarpos užfiksavo didžiausią tikslumą.

Tam, kad balso įrašo atkarpos būtų kuo naudingesnės mokymuisi, buvo paliktos tik tos atkarpos, kuriose buvo girdimas bent 39 decibelų garsas. Toks garsumas pasirinktas taip pat išankstinio tyrimo būdu: klasifikatoriumi „Random Forest“ (aprašyta 4.1.3 skyriuje) buvo išanalizuotos 2 sekundžių balso atkarpos, kuriose girdimas balsas turėjo viršyti decibelus 30 – 60 decibelų režiuose, taikant 1 decibelo intervalus.

Balso įrašo, išreikšto garsumu (decibelais), palyginimas prieš ir po suskaidymo į atkarpas pateiktas 14 paveikslėlyje. Balso įrašų skaidymui atkarpomis taip pat panaudota „Python“ biblioteka „Librosa“. Atlikus balso įrašų valymą bei skaidymą šie yra paruošti balso atributų radimui.

14 paveikslėlis. Balso įrašo garso svyravimų palyginimas prieš ir po išskaidymo.

Pilnas balso įrašas



Tas pats balso valymo ir skaidymo procesas yra atliekamas ir su vartotojo įvestu balsu. Kiekviena iš atkarpų tolesniuose žingsniuose yra vertinamos individualiai.

4.1.2. Balso atributų radimas

Tam, kad išvalytus balso įrašus būtų galima panaudoti klasifikatoriaus mokymui, juos reikia paversti į skaitinę formą – būtų rasti įvairių balso atributų įvertinimai. Šiam tikslui buvo panaudoti įrankis „Praat“ [24] bei anksčiau minėta „Python“ biblioteka „Librosa“. Bendrai buvo rasti 62 balso parametrai.

„Praat“ įrankiu buvo randami parametrai susiję su balso intensyvumu, tonu (angl. „pitch“), pulsavimais, skambesiu (angl. „voicing“), pagrindinio tono neperiodiškumas (angl. „jitter“), amplitudės neperiodiškumas (angl. „shimmer“). Naudojant biblioteką „Librosa“ buvo rasti parametrai susiję su spektru. Bendras rastų bei panaudotų atributų sąrašas pateiktas 15 paveikslėlyje. Šiame paveikslėlyje galime pamatyti, jog balso atributai yra suskirstyti į grupes. Šios grupės aprašytos 8 lentelėje.

15 paveikslėlis. Balsų atributų sąrašas naudotas mašinai mokytis.

```

// INTENSITY          // VOICING          // SPECTRUM
minIntensity,        fractionVoicing,    chroma_stft,
maxIntensity,        numVBreaksVoicing,  rmse,
quantile25Intensity, degreeVBreaksVoicing,  spectral_centroid,
quantile33Intensity,                                spectral_bandwidth,
quantile50Intensity, // JITTER          rolloff,
quantile67Intensity, locPctJitter,        zero_crossing_rate,
quantile75Intensity, locAbsJitter,          mfcc1,
meanIntensity,       rapJitter,             mfcc2,
stdDevIntensity,     ppq5Jitter,             mfcc3,
                                ddpJitter,             mfcc4,
                                mfcc5,
// PITCH
medianPitch,         // SHIMMER          mfcc6,
meanPitch,           locShimmer,        mfcc7,
stdDevPitch,         locDbShimmer,     mfcc8,
minPitch,            apq3Shimmer,      mfcc9,
maxPitch,            apq5Shimmer,      mfcc10,
                                apq11Shimmer,       mfcc11,
// PULSES
numPulses,           ddaShimmer,       mfcc12,
numPeriodsPulses,   // HARMONICITY     mfcc13,
meanPeriodPulses,   meanAutoCorrHarmonicity, mfcc14,
stdDevPeriodPulses, meanNoiseToHarmHarmonicity, mfcc15,
                                meanHarmToNoiseHarmonicity, mfcc16,
                                criticalExceptionDetected, mfcc17,
                                mfcc18,
                                mfcc19,
                                mfcc20,

```

8 lentelė. Sistemoje naudotų balso atributų aprašymas.

Balso atributų tipas	Aprašymas
Intensyvumas	<p>Intensyvumas arba garsumas yra garso slėgis, kuris yra matuojamas decibelais (dB).</p> <p>Intensyvumas apibrėžia du požymius. Vienas iš jų yra oro srautas iš plaučių, kitas - atsparumas balso klosčių oro srautui. Kiekvienas žmogus turi bazinį intensyvumo lygį, apibūdinantį jo pokalbio kalbą. [25]</p> <p>Priklausomai nuo balso elgesio, intensyvumo lygis gali būti labai įvairus - nuo šnabždesio, kurio dydis yra maždaug 10 dB, iki garsaus šaukimo, kuris gali siekti iki 90 dB. [26]</p>
Balso tonas (angl. „pitch“)	<p>Tonas yra garso savybė, kuri yra susijusi su dažnių skale, vertinančia balso virpėjimą (pulsavimą). Pagal virpėjimą balsas gali būti aukštas arba žemas. [25]</p> <p>Pagrindinį balso toną nusako periodas T_0, kurio formulė lygi:</p>

	$T_0 = \frac{1}{F_0}$
<p>Pagrindinio tono neperiodiškumas (angl. „jitter“)</p>	<p>Kalbėjimo metu kalbančiojo balso dažnis gali keistis tam tikroje amplitudėje. Balso arba pagrindinio tono neperiodiškumas yra lygus atsitiktinio laikotarpio nepastovumui. Įvairūs balso sutrikimai padidina balso neperiodiškumą bei lemia balso kokybę, girdimą šiurkštumą. Pagrindinio tono neperiodiškumas yra balso stabilumo matas, kuris dažnai naudojamas balso defektams rasti. [25]</p> <p>Pagrindinio tono neperiodiškumas gali būti skirstomas į atskiras metrikas, kurios aprašytos toliau.</p> <p>Absoliutus tono neperiodiškumas (angl. „absolute jitter“) – pagrindinio dažnio kitimas iš ciklo į ciklą. Metrikos formulė:</p> $Jitter (absolute) = \frac{1}{N-1} \sum_{i=1}^{N-1} T_i - T_{i+1} $ <p>Greito kalbėjimo tono neperiodiškumas (angl. „rap jitter“) – vidutinis absoliutus laikotarpio skirtumas ir jo bei dviejų jo kaimynų vidurkis, padalintas iš vidutinio laikotarpio.</p> <p>PPQ5 tono neperiodiškumas (angl. „PPQ5 jitter“) – penkių taškų laikotarpio pertvarkymo koeficientas (angl. „Period Perturbation Quotient“), kuris išreiškiamas kaip vidutinis absoliutus laikotarpio skirtumas ir jo bei keturių artimiausių kaimynų vidurkis, padalytas iš vidutinio laikotarpio.</p>
<p>Amplitudės neperiodiškumas (angl. „shimmer“)</p>	<p>Amplitudės neperiodiškumą galima apibrėžti kaip balso dažnio trikdymą, susijusį su balso amplitude. Amplitudės neperiodiškumas yra balso stabilumo indeksas. Pernelyg didelis amplitudės neperiodiškumas apibrėžia užkimimo sąvoką. [25]</p> <p>Amplitudės neperiodiškumas gali būti skirstomas į atskiras metrikas:</p> <p>Absoliutus amplitudės neperiodiškumas (angl. „absolute shimmer“) yra išreiškiamas amplitudės piko viršūnės kintamumu decibelais, t.y. vidutinio absoliutaus logaritmo pagrindu 10 skirtumo tarp nuoseklaus laikotarpio amplitudžių padauginta iš 20. Metrikos formulė:</p> $Shimmer (absolute) = \frac{1}{N-1} \sum_{i=1}^{N-1} \left 20 \log \frac{A_{i+1}}{A_i} \right $ <p>APQN amplitudės neperiodiškumas (angl. „APQN shimmer“) – N taškų amplitudės pertvarkymo koeficientas (angl. „Amplitude Perturbation Quotient“), kuris išreiškiamas kaip vidutinis</p>

	<p>absolius skirtumas tarp laikotarpio amplitudės ir jo bei N artimiausių kaimynų amplitudžių vidurkis, padalintas iš vidutinės amplitudės. Dažniausiai naudojami N – 3, 5, 11.</p>
<p>Garso harmoniškumas (angl. „harmonicity“)</p>	<p>Harmoniškumas nurodo akustinio periodiškumo laipsnį, dar vadinamą harmonikos ir triukšmo santykiu arba HNR (angl. „Harmonics-to-Noise Ratio“). Harmoniškumas išreiškiamas decibelais ir gali būti apskaičiuojamas pagal formulę:</p> $HNR = 10 \log_{10} \frac{\text{signalo energija periodinėje dalyje \%}}{\text{triukšmas \%}}$ <p>Kai HNR yra lygu 0 reiškia, kad harmonikose ir triukšme yra vienodai energijos. [28]</p>
<p>Garso spektras</p>	<p>Garso spektras rodo skirtingus garse esančius dažnius. Tai yra garso reprezentacija atsižvelgiant į vibracijos kiekį kiekviename atskirame dažnyje [29]. Toliau pateiktos tiesiogiai su balso spektru susijusios metrikos.</p> <p>Spektro centroidas (angl. „spectral centroid“) – spektro „svorio“ centras [30]. I-tojo garso kadro centroido C_i vertė apibrėžiama kaip:</p> $C_i = \frac{\sum_{k=1}^{Wf_L} k X_i(k)}{\sum_{k=1}^{Wf_L} X_i(k)}$ <p>Spektro poslinkis (angl. „spectral rolloff“) apibrėžiamas kaip dažnis, po kuriuo yra koncentruota tam tikra procentinė spektro dalis, pasiskirsčiusi pagal dydį [30]. Spektro poslinkį galima apskaičiuoti naudojant formulę:</p> $\sum_{k=1}^m X_i(k) = C \sum_{k=1}^{Wf_L} X_i(k)$ <p>, kur C yra iš anksto numatytas procentas.</p> <p>MFCC (angl. „Mel Frequency Cepstral Coefficients“) – signalo cepstralinio (angl. „cepstral“) atvaizdavimo tipas, kai dažnio juostos yra paskirstytos pagal melo skalę. Melo skalė – tai skalė, kuri susieja žmogaus ausiai girdimą dažnį su realiu išmatuotu dažniu [30]. Susiejimas atliekamas keičiant dažnio mastelį. MFCC metriką galima apskaičiuoti pasinaudojus formule:</p>

	$c_m(n) = \sum_{i=1}^K \cos \left[n \left(i - \frac{1}{2} \right) \frac{\pi}{K} \right] \log_{10} S(m, i)$ <p>, kur i – filtro indeksas, k – spektro atskaitos indeksas, m – einamas kadro numeris, S – galios funkcija.</p>
--	--

4.1.3. Klasifikatoriaus parengimas

Mašininio mokymosi yra keli būdai, tačiau mums aktualiausias prižiūrimas. Tai mokymosi būdas, kai mokomasi funkcija, kurios įvestis ir išvestis yra žinoma [33]. Turime $y=f(u, \theta)$, kur u yra įvestis θ – žinomi parametrai, o y – rezultatas. Ši funkcija vadinama modeliu [33], o modelį sukurti padeda klasifikatoriai.

Klasifikatoriams mokyti bei testuoti buvo naudojamas kryžminis tikrinimas (angl. „cross validation“), kai mėginių aibė padalinama į mokymo bei testavimo imtis bei vykdomas pasirinktas skaičius iteracijų, kurių metu testavimo bei mokymo imtys sudaromos iš vis skirtingų ėminių. Pasirinkta, kad mokymo rinkinį turėtų sudaryti 70% įrašų bei būtų vykdoma 10 iteracijų.

Klasifikatorių yra daugybė – neuroniniai tinklai, pasirinkimų medžiai ir daug kitų. Išbandytų klasifikatorių aprašymas pateiktas 9 lentelėje.

Panaudojus programinę įrangą „Weka“ [34], buvo atliktas tyrimas ir nustatyta, kad didžiausias tikslumas su turimais duomenimis buvo užfiksuotas naudojant „RandomForest“ klasifikatorių – 74,50 procentų tikslumas. Visų išmėgintų klasifikatorių tikslumas pateiktas 10 lentelėje .

9 lentelė. Sistemos testavimui išbandytų klasifikatorių aprašymas.

Pavadinimas	Aprašymas
„SGD“	Stochastinis gradiento nusileidimas arba „SGD“ (angl. „Stochastic Gradient Descent“) reiškia tam tikras paprastas iteracines struktūras, naudojamas sprendžiant atsitiktines optimizavimo ir šaknų radimo problemas. Identifikuojantis „SGD“ bruožas yra tas, kad kiekvienas paskesnis rekursijos narys nustatomas pridėdam atitinkamai pakeistą gradiento įvertį prie ankstesnio kartotinio. „SGD“ taip pat pasižymi optimaliu vykdymo laiku. [35]
„Logistic“	Paprastoji logistinė funkcija (angl. „SimpleLogistic“) yra populiarus statistinės analizės metodas, kurio tikslas yra rasti tinkamą linijinės logistinės regresijos modelį. Priklausomai nuo logistinės funkcijos, šis algoritmas modeliuoja rezultatų loginius koeficientus, o ne tiesiogiai modeliuoja rezultatą. „SimpleLogistic“ paaiškina ryšį tarp kategoriškai priklausomo kintamojo ir vieno ar daugiau nepriklausomų kintamųjų. [36]
„SMO“	Nuoseklus minimalus optimizavimas arba „SMO“ (angl. „Sequential Minimal Optimization“) yra patobulintas metodas, skirtas palaikomųjų vektorinių mašinų („SVM“, angl. „Support vector machines“) mokymui, kuris rodo gerus rezultatus sprendžiant įvairias problemas. „SVM“ naudojimas yra ribotas dėl jo keblaus naudojimo

	ir mokymo sudėtingumo. Tuo tarpu SMO yra gana paprastas, lengvai naudojamas bei greitesnis nei „SVM“. [36]
„IBk“	Egzemplioriais grįstų k-artimiausių kaimynų algoritmą arba „IBk“ (angl. „Instance-based k-nearest Neighbors“) galima apibrėžti kaip paprastą metodą, kuris praplečia k-artimiausių kaimynų algoritmą („KNN“). „IBk“ algoritmas ieško k artimiausių mokymo egzempliorių ir tada pateikia balą pagal kaimyninių etikečių svertinio panašumo (angl. „similarity-weighted“) vidurkį. [36] [37]
„Decision table“	Sprendimų lentelė (angl. „Decision table“) naudoja įvyniojimo metodą, kad būtų galima rasti gerą atributų pogrupį, kuris būtų įtraukiamas į lentelę. Šiam tikslui naudojamas „best-first“ paieškos metodas. Pašalindamas atributus, kurie mažai arba visiškai neprideda prie rezultato, algoritmas sumažina per didelio pritaikymo tikimybę ir sukuria mažesnę ir glaustą sprendimų lentelę. [38]
„JRip“	„JRip“ metodas sudaro taisyklių aibę (angl. „ruleset“) pakartotinai pridėdamas taisykles į tuščias aibės vietas tol, kol yra panaudojami visi teigiami pavyzdžiai. Naujos taisyklės formuojamos papildant jas pirminės (apriorinės) taisyklės savybėmis kol išsenka neigiami pavyzdžiai. Kai taisyklių aibė yra suformuota, optimizavimo būdu sumažinamas jos dydis, kad sukurtoji aibė kuo geriau tiktų mokymo aibei. [39]
„J48“	„J48“ tai yra naujesnė algoritmo C4.5 versija. C4.5 algoritmas generuoja nurodyto duomenų rinkinio klasifikavimo – sprendimo medį, naudojant rekursyvų duomenų skaidymą. Tuo tarpu „J48“ rekursyviai atlieka klasifikavimą tol, kol kiekvienas lapas yra išgrynintas, tai yra, duomenys yra suklasifikuoti kaip įmanoma geriau, užtikrinant maksimalų tikslumą. [38]
„LMT“	Logistinio modelio medžiai arba „LMT“ (angl. „Logistic Model Trees“) medžio lapuose naudoja regresijos funkcijas. Metodas pasižymi tuo, jog gali būti naudojamas su trūkstamomis atributų reikšmėmis, dvejetainiais ir daugialybiais atributais. Tai sukuria mažus, bet tikslius medžius. „LMT“ naudoja „CART“ apkarpyimo techniką. „LMT“ sukuria vieną medį, kuriame skaitiniai atributai turi dvejetainius skilimus, vartiniai atributai – daugialypius, o lapuose logistinės regresijos modeliai. „LMT“ taip pat užtikrina, kad į medį patektų tik svarbūs atributai. [38]
„Random forest“	Atsitiktinio miško (angl. „Random forest“) mašininis mokymas susideda iš daugybės individualiai besimokančių medžių. Atsitiktinis miškas naudoja keletą atsitiktinių medžių klasifikacijų kurios apsprendžia bendrą klasifikaciją pagal nurodytą įvesties rinkinį. Atsitiktinis miškas naudoja „CART“ apkarpyimo techniką. [38]

10 lentelė. Klasifikatorių tikslumo palyginimo lentelė.

Klasifikatoriaus pavadinimas	Tikslumas
J48	64,74 %
LMT	73,62 %
RandomForest	74,50 %
DecisionTable	62,62 %
JRip	65,56 %
IBk, kai k=15	72,17 %
SGD	69,62 %
SimpleLogistic	68,83 %
SMO	68,38 %

Startuojant Parkinsono ligos atpažinimo sistemos serverinę dalį yra sukuriamas „RandomForest“ klasifikatorius, kuris yra mokomas turimais duomenimis, kurie yra paruošti iš anksto. Papildomai yra pakoreguojami šie klasifikatoriaus parametrai:

- „maxDepth“ = 20;
- „numDecimalPlaces“ = 20;
- „seed“ = 3;
- „numIterations“ = 200.

4.1.4. Vartotojo balso įvesties klasifikavimas

Vartotojui pateikus savo balsą Parkinsono ligos atpažinimo sistemai balsas yra paruošiamas – išvalomas bei suskaidomas į atkarpas pagal 4.1.1 skyriuje aprašytą metodiką. Kiekviena iš balso atkarpų yra pakeičiama atributais, nurodytais 15 paveikslėlyje.

Sistemoje veikia iš anksto išmokytas „RandomForest“ klasifikatorius (aprašytas 4.1.3 skyriuje). Klasifikatorius yra mokytas dr. A. Lauraičio surinktais balso įrašais [19]. Kiekvienos vartotojo balso atkarpos atributai yra pateikiami klasifikatoriui, jog šis apskaičiuotų rezultatą – kiek procentiškai vartotojo balsas yra panašūs į Parkinsono liga sergančių žmonių balsą. Nors iš vartotojo balso gauname keletą balso atkarpų, vartotojui pateikiamas vienas rezultatas – klasifikatoriaus įvertintų atkarpų rezultatų vidurkis (1 formulė).

1 formulė. Rezultato radimas, apskaičiavus balso atkarpų rezultatus.

$$rezultatas = \frac{\sum_{i=1}^n atkarpos_rezultatas_i}{n}$$

4.2. Parkinsono ligos atpažinimo trūkumai

4.2.1. Algoritmas nėra tikslus

Buvo nustatyta, kad tiksliausias klasifikatorius „RandomForest“ geba nustatyti, ar balsas yra Parkinsono liga sergančio žmogaus 74,50 % tikslumu. Deja, tai nėra geras rezultatas. Metrikos, kurios panaudotos algoritmui įvertinti aprašytos 11 lentelėje.

11 lentelė. Metrikos, kurios bus naudojamos algoritmo įvertinimui.

Pavadinimas	Formulė	Aprašymas
Bendras tikslumas (angl. „accuracy“)	$\text{bendras tikslumas} = \frac{TP + TN}{TP + FP + TN + FN}$	Tikimybė, jog klasifikatorius teisingai suklasifikuos objektą.
Jautrumas	$\text{jautrumas} = \frac{TP}{TP + FN}$	Tikimybė, jog klasifikatorius aptiks patologiją, kai objektas iš tikrųjų turi patologiją.
Specifiškumas	$\text{specifiškumas} = \frac{TN}{TN + FP}$	Tikimybė, jog klasifikatorius patologijos neaptiks, kai objektas jos ir neturi.
F įvertis	$F = 2 \times \frac{\text{tikslumas} \times \text{jautrumas}}{\text{tikslumas} + \text{jautrumas}}$	Tikslumo ir jautrumo harmoninis vidurkis, kuris apibendrina abi metrikas.

Ne mažiau svarbūs ir kiti statistiniai rodikliai, kuriuos galime apskaičiuoti panaudoję sumaišymo matricą (angl. „confusion matrix“), pateikta lentelėje. Naudojamo klasifikatoriaus jautrumas (angl. „sensitivity“) – tikimybė, jog sistema aptiks Parkinsono ligą, kai vartotojas iš tikrųjų turi šią patologiją yra 70,1 %. Tuo tarpu specifiškumas (angl. „specificity“) – tikimybė, jog sistema neparodys ligos, kai vartotojas jos ir neturi yra 78,5 %. F įvertis (angl. „F-score“) yra lygus 0,724.

12 lentelė. Naudojamo klasifikatoriaus sumaišymo matrica.

		Realiai Parkinsono ligos diagnozė	
		Teigiama	Neigiama
Algoritmo spėjamas Parkinsono ligos buvimas	Teigiama	1105	370
	Neigiama	471	1353

Taigi naudojamas algoritmas, kuris remiasi „RandomForest“ klasifikatoriumi nėra itin tikslus bei efektyvus.


4.2.2. Netinkamas mokymui naudojamas duomenų rinkinys bei jo apdorojimas

Vartotojas naudodamasis sistema savo balsą gali pateikti net keliais būdais – balsių, dvibalsių tarimas, įvairaus teksto iškarpu skaitymas ar sakymas. Nors klasifikatorius būtų tikslesnis, jis nevienodai efektyvus būtų naudojant klasifikuoti skirtingas balso įvestis. Tai reiškia, jog norint užtikrinti kokybišką sistemos veikimą, mums reiktų skirtingų duomenų rinkinių – balsių įvestį lyginti su duomenų rinkiniu, kuriame būtų tariamos balsės, skaitymo įvestis būtų lyginama su duomenų

rinkiniu, kuriame skaitomas toks pats tekstas. Pastaruoju atveju būtų nereikalingas balso skaidymas į atkarpas.

Taigi dabar naudojamas metodas – balso valymas bei skaidymas efektyviai gali būti naudojamas analizuojant vartotojo balso įvestį, kada skaitomas atsitiktinis tekstas arba natūraliai kalbama. Palyginimui galime pažiūrėti, kaip skiriasi atsitiktinės klasifikatoriuje naudojamos balso atkarpos spektrograma su ištarta balse „a“ 16 paveikslėlyje. Pateiktos atkarpos neturi didelio panašumo nei vizualiai, nei lyginant visus kitus sistemoje naudojamus atributus nors abu pavyzdžiai yra Parkinsono liga sergančio žmogaus. Konkrečiu atveju algoritmas klasifikavo 31 procentų panašumą. Tai reiškia, jog liga neidentifikuota, nors ji yra diagnozuota.

16 paveikslėlis. Teksto skaitymo bei balso „a“ tarimo spektrogramų palyginimas.



5. Parkinsono ligos atpažinimo naudojant balso duomenis eksperimentinė dalis

5.1. Eksperimento tikslai

Išanalizavus sukurtą Parkinsono ligos atpažinimo naudojant balso duomenis sistemą išryškėjo kelios sistemos problemos:

- žemas algoritmo efektyvumas;
- duomenų rinkinys nėra tinkamas lyginti su įvairiomis vartotojo balso įvestimis;
- balso apdorojimas tinkamas ne visoms vartotojo balso įvestims.

Atsižvelgiant į sistemos trūkumus šio eksperimento tikslas yra išnagrinėti Parkinsono ligos atpažinimo naudojant balso duomenis algoritmo didesnio efektyvumo galimybes naudojant skirtingus duomenų rinkinius. Išanalizavus gautus rezultatus rasti tinkamiausius sprendimus bei suformuluoti tezes.

5.2. Pasiruošimas eksperimentams

Eksperimentai atliekami „Windows 10“ aplinkoje, todėl naudojami metodai ir įranga yra pritaikyta būtent šiai operacinei sistemai.

Prieš atliekant eksperimentus reikia atlikti žingsnius:

- rasti tinkamus balso įrašų rinkinius;
- susidiegti programinę įrangą, kuri reikalinga balso parametrų radimui.

5.2.1. Balso įrašų rinkiniai

Viena iš egzistuojančių Parkinsono ligos atpažinimo naudojant balso duomenis sistemos problemų yra skirtingo pobūdžio balso lyginimas tarpusavyje, pavyzdžiui teksto skaitymas su balsių tarimu, mums reikalingi skirtingi duomenų rinkiniai. Pirmasis rinkinys, kurį įtraukiame į eksperimentus yra 4.2.1 skyrelyje minėtas LSMU surinkti balso įrašai, kuriuose žmonės skaito eilėraščius „Trakų pilis“ bei „Lietuva brangi“. Taip pat panaudosime balso įrašų rinkinį, kuriame Parkinsono liga sergantys žmonės taria balsius „a“ bei „i“ [41]. Duomenų rinkiniai, kurie bus naudojami eksperimente aprašyti 13 lentelėje.

13 lentelė. Tyrimui naudojamų duomenų aprašymas

Duomenų rinkinio pavadinimas	Kas pateikiama balso įrašė	Parkinsono liga sergančių asmenų įrašų skaičius	Sveikų kontrolinių asmenų įrašų skaičius	Šaltinis
Vowels.zip	Balsių „a“ bei „i“ tarimas	93	88	[41]
Balsai.zip	Eilėraščių „Trakų pilis“ ir „Lietuva brangi“ skaitymas	156	211	[19]

5.2.2. Reikalinga programinė įranga

Atliekant eksperimentinį tyrimą bus reikalinga ši programinė įranga:

- „Praat“ 6.1.41;
- „Opensmile“ 3.0;

14 lentelė. Sumaišymo matricos šablonas.

		Reali diagnozė	
		Teigiama	Neigiama
Prognozuojamas ligos buvimas	Teigiama	TP	FP
	Neigiama	FN	TN

Metrikos, kuriomis bus vertinama klasifikatoriaus kokybė, metrikų formulės bei aprašymas pateikti 15 lentelėje.

15 lentelė. Metrikos, kurios bus naudojamos tyrimo metu

Pavadinimas	Formulė	Aprašymas
Bendras tikslumas (angl. „accuracy“)	$\text{bendras tikslumas} = \frac{TP + TN}{TP + FP + TN + FN}$	Tikimybė, jog klasifikatorius teisingai suklasifikuos objektą.
Jautrumas	$\text{jautrumas} = \frac{TP}{TP + FN}$	Tikimybė, jog klasifikatorius aptiks patologiją, kai objektas iš tikrųjų turi patologiją.
Specifiškumas	$\text{specifiškumas} = \frac{TN}{TN + FP}$	Tikimybė, jog klasifikatorius patologijos neaptiks, kai objektas jos ir neturi.
F įvertis	$F = 2 \times \frac{\text{tikslumas} \times \text{jautrumas}}{\text{tikslumas} + \text{jautrumas}}$	Tikslumo ir jautrumo harmoninis vidurkis, kuris apibendrina abi metrikas.
MMC įvertinimas	$\text{MMC} = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$	MMC vertina klasifikatoriaus kokybę, kur MMC = 1 reiškia tobulą klasifikavimą.

Klasifikatoriai bus vertinami duomenų imtį padalinant į testavimo ir treniravimo imtis. Treniravimo imtis bus naudojama išmokyti klasifikatorių, o testavimo imtis – patikrinti, kaip gerai klasifikatorius yra išmokytas nustatyti Parkinsono ligai. Svarbu atkreipti dėmesį, kad treniravimo bei testavimo duomenų imtyse nepasitaikytų vienodo balso autoriaus. Tai leistų klasifikatoriui lengviau identifikuoti asmenį kaip turintį Parkinsono ligą, nes to paties asmens balso pavyzdys būtų panaudotas mokant klasifikatorių.

Atlikus klasifikatorių įvertinimą bus galima atsakyti į kelis svarbius klausimus:

- Kokie balso įrašų rinkiniai tinkamiausi analizei: skaitymas ar balsių tarimas?
- Koku būdu balsas turėtų būti apdorojamas, siekiant gauti tikslesnius rezultatus?
- Kokie balso parametrai yra reikšmingiausi siekiant atpažinti Parkinsono ligą?

5.5. Eksperimentų atlikimas

5.5.1. Balso duomenų skirstymas į grupes

Tam, kad rastumėme tinkamiausią balso įvesties bei apdorojimo būdą, turime turėti keletą duomenų grupių, kuriose būtų skirtingas įvedimas bei apdorojimas. Taigi buvo pasirinkta balso duomenis suskirstyti į šias grupes:

- išvalyti pilni balso įrašai, kuriuose yra skaitomas tekstas;
- išvalyti bei padalinti į dviejų sekundžių atkarpas balso įrašai, kuriuose yra skaitomas tekstas;
- išvalyti pilni balso įrašai, kuriuose yra tariamos balsės;
- nevalyti pilni balso įrašai, kuriuose yra tariamos balsės.

Į sąrašą nėra įtrauktos grupės, kuriose skaitomo teksto balso įrašai būtų nevalyti, nes jie turi daug foninio triukšmo: kai kuriuose įrašuose girdimas juokas, kituose garsai primenantys uždromas duris ir panašūs trukdžiai.

Į grupių sąrašą įtraukti nevalyti balso įrašai, kuriuose tariamos balsės grupės rezultatai. Šie įrašai bus lyginami su išvalytais balso įrašais, siekiant sužinoti, ar balso valymas lemia geresnius klasifikatoriaus rezultatus.

Kiekviena pilno balso įrašo grupė turi atitikmenį – grupę, kurioje balso įrašai padalinti į dviejų sekundžių atkarpas. Rezultatų palyginimas tarp tokių grupių parodys, ar balso skaidymas atkarpomis lemia geresnius klasifikatoriaus rezultatus.

5.5.2. Balso parametrų radimas

Toliau kiekvienai iš turimų balso grupių rasime balso parametrus kiekvienam iš įrašų. Tam bus naudojami įrankiai „Praat“, „Opensmile“, „Librosa“. Kiekvienas iš įrankių yra konfigūruojamas skirtingai.

Įrankis „Praat“ turi grafinę sąsają, tačiau kadangi mums reikės nagrinėti daugybę balso įrašų panaudosime specialius „praat“ tipo failus, skirtus įrankio programavimui. Paruošta konfigūracija kiekvienam balso įrašui pateikia 36 parametrų įvėčius bei išspausdina „csv“ tipo failą.

„Python“ kalbos biblioteka „Librosa“ bus naudojama tiek balsui valyti, tiek parametrus susijusiems su balso spektru rasti. Naudodami šią biblioteką gauname 26 parametrų įvėčius kiekvienam balso įrašui, kurie yra pateikiami „csv“ tipo faile.

„Praat“ ir „Librosa“ įrankiai buvo naudoti Parkinsono ligos atpažinimo sistemoje ir anksčiau, tačiau tai neužtikrindavo algoritmo kokybės, dėl to papildomai panaudosime įrankį „Opensmile“. „Opensmile“ – tai atviro kodo įrankis skirtas garsų analizei [42]. Įrankis diegimo direktorijoje turi daugybę iš anksto paruoštų konfigūracijos failų, iš kurių panaudosime šiuos: „avec2013“, „ComParE_2016“, „emobase“, „emobase2010“, „IS09_emotion“, „IS10_paraling“, „IS10_paraling_compat“, „IS11_speaker_state“, „IS12_speaker_trait“, „IS12_speaker_trait_compat“, „IS13_ComParE“.

Kadangi „Opensmile“ turi tik komandinės eilutės paleidimą, balso parametrų paiešką automatuosime panaudoję „Python“. Pateikti konfigūracijos failai turi persidengiančių balso

parametrų, dėl to naudodami biblioteką „Pandas“ užtikrinsime jų originalumą. Bendras parametrų skaičius, kurį gauname panaudoję „Opensmile“, yra net 11020 kiekvienam balso įrašui.

Vienas iš duomenų rinkinių, kurį naudosime, yra sudarytas iš balsių įrašų. Dėl šios priežasties taip pat naudodami „Opensmile“ įrankį rasime formantus (angl. „formants“). Šie ir kiti balso atributai, naudoti tyrime aprašyti 16 lentelėje.

Formantai yra randami laiko momentui, todėl juos įvertinsime kiekvienai 100ms atkarpai. Naudodami „Opensmile“ įrankį bei jo konfigūraciją „GeMAPSv01b“ randame formantus F0, F1, F2, F3, o taip pat kitus su formantais susijusius parametrus. Naudodami „Python“ biblioteką „Numpy“ rasime formantų statistinius įverčius: 10, 25, 50, 75, 90 procentų kvantilius, kai formantai surikiuoti pagal laiką bei pagal dydį, vidurkį, standartinį nuokrypį, minimalią bei maksimalią reikšmes. Gautus 256 balso atributus bei jų įvertinimus spausdiname į „csv“ tipo failą.

Taigi kiekvienai grupei turime po keletą „csv“ tipo failų su skirtingais atributais, tačiau vienodu eilučių skaičiumi. Atsižvelgdami į tai lygiagrečiai sujungiame šiuos failus, panaudoję „Pandas“ biblioteką. Gauname po vieną didelį atributų bei jų įverčių failą kiekvienai grupei.

Kadangi dauguma atributų rezultatui, ar balso autorius turi Parkinsono ligą, įtakos neturi, mes turime išfiltruoti nereikalingus atributus. Šiam tikslui panaudosime įrankį „Weka“. Turimą „csv“ failą konvertuojame į „arff“ formato failą, kurį supranta įrankis. Tam, kad rastume tik su rezultatus koreliuojančius atributus, panaudosime M. A. Hall pasiūlytą metodą [40] – koreliacija pagrįstą atributų pogrupio vertinimą (angl. „Correlation-based Feature subset Evaluation“). Šis metodas apskaičiuoja atributų pogrupio vertę, remdamasis kiekvieno požymio individualia prognozavimo galimybe ir jų pertekliaus laipsniu. Įrankyje „Weka“ šis atributų filtravimo algoritmas sutrumpintai pavadintas „CfsSubsetEval“. Kartu su atributų filtravimo algoritmu naudosime „BestFirst“ atributų paieškos algoritmą. „BestFirst“ yra dirbtinio intelekto paieškos strategija, leidžianti grįžti atgal paieškos kelyje. Šis algoritmas eina per visą paieškos erdvę, o jei tiriamas kelias pradeda atrodyti mažiau perspektyvus, „BestFirst“ gali grįžti į perspektyvesnę ankstesnę pogrupį ir tęsti paiešką iš ten [40].

16 lentelė. Tyrime naudotų pagrindinių balso atributų aprašymas.

Balso atributų tipas	Aprašymas
Intensyvumas/garsumas	<p>Intensyvumas arba garsumas yra garso slėgis, kuris yra matuojamas decibelais (dB).</p> <p>Intensyvumas apibrėžia du požymius. Vienas iš jų yra oro srautas iš plaučių, kitas - atsparumas balso klosčių oro srautui. Kiekvienas žmogus turi bazinį intensyvumo lygį, apibūdinantį jo pokalbio kalbą. [25]</p> <p>Priklausomai nuo balso elgesio, intensyvumo lygis gali būti labai įvairus - nuo šnabždesio, kurio dydis yra maždaug 10 dB, iki garsaus šaukimo, kuris gali siekti iki 90 dB. [26]</p>
Balso tonas (angl. „pitch“)	<p>Tonas yra garso savybė, kuri yra susijusi su dažnių skale, vertinančia balso virpėjimą (pulsavimą). Pagal virpėjimą balsas gali būti aukštas arba žemas. [25]</p>

	<p>Pagrindinį balso toną nusako periodas T_0, kurio formulė lygi:</p> $T_0 = \frac{1}{F_0}$
Pulsavimai (angl. „pulses“)	<p>Norint ištarti garsą, mes išstumiamo orą iš savo plaučių, tuo pačiu metu labiau ar mažiau uždarydami balsaskylę (angl. „glottis“). Tai yra tam tikras apsunkinimas gerklėje, kuris priverčia praeiti orą per siaurą plyšį tarp dviejų balso klostių. Šios balso klostės vibruoja viena priešais kitą. Vibravimo metu, kai klostės prasidaro, atsiranda trumpas oro pliūpsnis, kuris yra vadinamas balsaskylės arba balso pulsu. Kai viskas vyksta sklandžiai, šie pulsavimai atsiranda reguliariai, maždaug nuo 50 iki 600 pulsų per sekundę. [27]</p>
Pagrindinio tono neperiodiškumas (angl. „jitter“)	<p>Kalbėjimo metu kalbančiojo balso dažnis gali keistis tam tikroje amplitudėje. Balso arba pagrindinio tono neperiodiškumas yra lygus atsitiktinio laikotarpio nepastovumui. Įvairūs balso sutrikimai padidina balso neperiodiškumą bei lemia balso kokybę, girdimą šiurkštumą. Pagrindinio tono neperiodiškumas yra balso stabilumo matas, kuris dažnai naudojamas balso defektams rasti. [25]</p> <p>Pagrindinio tono neperiodiškumas gali būti skirstomas į atskiras metrikas, kurios aprašytos toliau.</p> <p>Absolūtus tono neperiodiškumas (angl. „absolute jitter“) – pagrindinio dažnio kitimas iš ciklo į ciklą. Metrikos formulė:</p> $Jitter (absolute) = \frac{1}{N-1} \sum_{i=1}^{N-1} T_i - T_{i+1} $ <p>Santykinis tono neperiodiškumas (angl: „relative jitter“) – vidutinis absoliutus skirtumas tarp nuoseklių periodų, padalintas iš vidutinio laikotarpio. Metrikos formulė:</p> $Jitter (relative) = \frac{\frac{1}{N-1} \sum_{i=1}^{N-1} T_i - T_{i+1} }{\frac{1}{N} \sum_{i=1}^N T_i}$ <p>Greito kalbėjimo tono neperiodiškumas (angl: „rap jitter“) – vidutinis absoliutus laikotarpio skirtumas ir jo bei dviejų jo kaimynų vidurkis, padalintas iš vidutinio laikotarpio.</p> <p>PPQ5 tono neperiodiškumas (angl. „PPQ5 jitter“) – penkių taškų laikotarpio pertvarkymo koeficientas (angl. „Period Perturbation Quotient“), kuris išreiškiamas kaip vidutinis absoliutus laikotarpio skirtumas ir jo bei keturių artimiausių kaimynų vidurkis, padalytas iš vidutinio laikotarpio.</p>
Amplitudės neperiodiškumas (angl. „shimmer“)	<p>Amplitudės neperiodiškumą galima apibrėžti kaip balso dažnio trikdymą, susijusį su balso amplitude. Amplitudės</p>

	<p>neperiodiškumas yra balso stabilumo indeksas. Pernelyg didelis amplitudės neperiodiškumas apibrėžia užkimimo sąvoką. [25]</p> <p>Amplitudės neperiodiškumas gali būti skirstomas į atskiras metrikas:</p> <p>Absoliutus amplitudės neperiodiškumas (angl. „absolute shimmer“) yra išreiškiamas amplitudės piko viršūnės kintamumu decibelais, t.y. vidutinio absoliutaus logaritmo pagrindu 10 skirtumo tarp nuoseklaus laikotarpio amplitudžių padauginta iš 20. Metrikos formulė:</p> $Shimmer (absolute) = \frac{1}{N-1} \sum_{i=1}^{N-1} \left 20 \log \frac{A_{i+1}}{A_i} \right $ <p>Santykinis amplitudės neperiodiškumas (angl. „relative shimmer“) – vidutinis absoliutus skirtumas tarp iš eilės einančių periodų amplitudžių, padalintas iš vidutinės amplitudės. Metrikos formulė:</p> $Shimmer (relative) = \frac{\frac{1}{N-1} \sum_{i=1}^{N-1} \left 20 \log \frac{A_{i+1}}{A_i} \right }{\frac{1}{N} \sum_{i=1}^N A_i}$ <p>APQN amplitudės neperiodiškumas (angl. „APQN shimmer“) – N taškų amplitudės pertvarkymo koeficientas (angl. „Amplitude Perturbation Quotient“), kuris išreiškiamas kaip vidutinis absoliutus skirtumas tarp laikotarpio amplitudės ir jo bei N artimiausių kaimynų amplitudžių vidurkis, padalintas iš vidutinės amplitudės. Dažniausiai naudojami N – 3, 5, 11.</p>
<p>Garso harmoniškumas (angl. „harmonicity“)</p>	<p>Harmoniškumas nurodo akustinio periodiškumo laipsnį, dar vadinamą harmonikos ir triukšmo santykiu arba HNR (angl. „Harmonics-to-Noise Ratio“). Harmoniškumas išreiškiamas decibelais ir gali būti apskaičiuojamas pagal formulė:</p> $HNR = 10 \log_{10} \frac{\text{signalo energija periodinėje dalyje \%}}{\text{triukšmas \%}}$ <p>Kai HNR yra lygu 0 reiškia, kad harmonikose ir triukšme yra vienodai energijos. [28]</p>
<p>Garso spektras</p>	<p>Garso spektras rodo skirtingus garse esančius dažnius. Tai yra garso reprezentacija atsižvelgiant į vibracijos kiekį kiekviename atskirame dažnyje [29]. Toliau pateiktos tiesiogiai su balso spektru susijusios metrikos.</p>

	<p>Spektro centroidas (angl. „spectral centroid“) – spektro „svorio“ centras [30]. I-tojo garso kadro centroido C_i vertė apibrėžiama kaip:</p> $C_i = \frac{\sum_{k=1}^{Wf_L} kX_i(k)}{\sum_{k=1}^{Wf_L} X_i(k)}$ <p>Spektro sklaida (angl. „spectral spread“) – tai antrasis centrinis spektro momentas[6]. Norint jį rasti, reikia pasinaudoti formule:</p> $S_i = \sqrt{\frac{\sum_{k=1}^{Wf_L} (k-C_i)^2 X_i(k)}{\sum_{k=1}^{Wf_L} X_i(k)}}$ <p>Spektrinis srautas (angl. „spectral flux“) – matavimas, skirtas nustatyti, kaip greitai keičiasi galios spektras (angl. „power spectrum“), kuris yra apskaičiuojamas kaip Euklido distancija tarp dviejų normalizuotų spektrų [30]. Spektrinį srautą galima apskaičiuoti naudojant formulę:</p> $Fl_{(i,i-1)} = \sum_{k=1}^{Wf_L} (EN_i(k) - EN_{i-1}(k))^2, \quad EN_i(k) = \frac{X_i(k)}{\sum_{l=1}^{Wf_L} X_i(l)}$ <p>Spektro poslinkis (angl. „spectral rolloff“) apibrėžiamas kaip dažnis, po kuriuo yra koncentruota tam tikra procentinė spektro dalis, pasiskirsčiusi pagal dydį [30]. Spektro poslinkį galima apskaičiuoti naudojant formulę:</p> $\sum_{k=1}^m X_i(k) = C \sum_{k=1}^{Wf_L} X_i(k),$ <p>, kur C yra iš anksto numatytas procentas.</p> <p>MFCC (angl. „Mel Frequency Cepstral Coefficients“) – signalo cepstralinio (angl. „cepstral“) atvaizdavimo tipas, kai dažnio juostos yra paskirstytos pagal melo skalę. Melo skalė – tai skalė, kuri susieja žmogaus ausiai girdimą dažnį su realiu išmatuotu dažniu [30]. Susiejimas atliekamas keičiant dažnio mastelį. MFCC metriką galima apskaičiuoti pasinaudojus formule:</p> $c_m(n) = \sum_{i=1}^K \cos\left[n\left(i - \frac{1}{2}\right) \frac{\pi}{K}\right] \log_{10} S(m, i)$ <p>, kur i – filtro indeksas, k – spektro atskaitos indeksas, m – einamas kadro numeris, S – galios funkcija.</p>
Garso energija	<p>Garso energija – tai energijos forma, kurią gali girdėti gyvos būtybės. Žmonėms girdimos tik tos bangos, kurių dažnis yra nuo 16 Hz iki 20 kHz [30]. Garso energija apibrėžiama kaip potencinės ir kinetinės energijų suma:</p>

	$W = W_{\text{potential}} + W_{\text{kinetic}} = \int_V \frac{p^2}{2\rho_0 c^2} dV + \int_V \frac{\rho v^2}{2} dV$, kur V žymi garsumą, p – garso slėgis, v – dalelių greitis, ρ_0 – terpės tankis be garso; ρ – vidutinis terpės tankis, c – garso greitis.
Garso buvimo/nebuvimo trukmės	Garso buvimo ar nebuvimo trukmė apskaičiuojama iš pradžių apibrėžiant, žemiau kokios decibelų ribos esantis garsas reikš tylą. Dėl naudojamų garso įrašymo priemonių, aplinkos garsų, įrašo garsumas sunkiai gali būti 0 decibelų.
Garso aštrumas	Aštrumas yra klausos pojūtis, susijęs su dažniu ir nepriklausantis nuo garsumo. Aštrumas atitinka aštraus, skausmingo, aukšto dažnio garso pojūtį ir yra aukšto dažnio energijos kiekio palyginimas su visa likusia energija. Garso aštrumą galima apskaičiuoti pagal garso slėgio signalo bangos formą - 1/3 oktavos juostos spektrą, apskaičiuotą dažnių diapazone nuo 25 Hz iki 12,5 kHz, arba specifinį garsumą. [31]
Formantai (angl. „Formants“)	Formantai – tai kalbos trakto rezonansiniai dažniai, akustinės energijos koncentracija apie tam tikrą dažnį kalbos signale. Formantai parodo intensyviausius taškus garso dažnių juostoje. [32]

Kiekvienai duomenų grupei randame labiausiai su rezultato klase koreliuojančius atributus. Taigi gauname „arff“ tipo failus kiekvienai grupei su atrinktais balso parametrais. Rastų atributų suvestinę galime matyti 17 lentelėje.

17 lentelė. Rastų atributų suvestinė kiekvienai duomenų grupei

Balso grupės pavadinimas	Visas atributų skaičius	Atributų skaičius po filtravimo
Išvalyti pilni balso įrašai, kuriuose yra skaitomas tekstas	10926	197
Išvalyti bei padalinti į dviejų sekundžių atkarpas balso įrašai, kuriuose yra skaitomas tekstas	10926	250
Išvalyti pilni balso įrašai, kuriuose yra tariamos balsės	11178	106
Nevalyti pilni balso įrašai, kuriuose yra tariamos balsės	11178	112

5.5.3. Klasifikatoriaus paieška

Klasifikatoriaus paieškai bus panaudotas įrankis „Weka“. „Weka“ turi daugybę klasifikatorių, kuriems galima koreguoti įvairius parametrus, siekiant gauti geresnius rezultatus. Kuriant Parkinsono ligos atpažinimo sistemą klasifikatoriaus paieška buvo atliekama rankomis. Tačiau rankiniu būdu mes negalime patestuoti daug klasifikatorių bei parametų kombinacijų, todėl geriausias rezultatas gali būti nerastas. Dėl šios priežasties buvo nuspręsta klasifikatoriaus paiešką automatizuoti. Šiam tikslui bus panaudota „Java“ programinė įranga.

Buvo pasirinkta, kad automatizuota klasifikatoriaus paieška testuos šiuos klasifikatorius: „SGD“, „Logistic“, „SMO“, „IBk“, „Decision table“, „JRip“, „PART“, „Hoeffding tree“, „J48“, „LMT“, „Random forest“, „Random tree“, „REP tree“. Klasifikatorių aprašymas pateiktas 18 lentelėje.

18 lentelė. Tyrime naudotų klasifikatorių aprašymas.

Pavadinimas	Aprašymas
„SGD“	Stochastinis gradiento nusileidimas arba „SGD“ (angl. „Stochastic Gradient Descent“) reiškia tam tikras paprastas iteracines struktūras, naudojamas sprendžiant atsitiktines optimizavimo ir šaknų radimo problemas. Identifikuojantis „SGD“ bruožas yra tas, kad kiekvienas paskesnis rekursijos narys nustatomas pridėdam atitinkamai pakeistą gradiento įvertį prie ankstesnio kartotinio. „SGD“ taip pat pasižymi optimaliu vykdymo laiku. [35]
„Logistic“	Paprastoji logistinė funkcija (angl. „SimpleLogistic“) yra populiarus statistinės analizės metodas, kurio tikslas yra rasti tinkamą linijinės logistinės regresijos modelį. Priklausomai nuo logistinės funkcijos, šis algoritmas modeliuoja rezultatų loginius koeficientus, o ne tiesiogiai modeliuoja rezultatą. „SimpleLogistic“ paaiškina ryšį tarp kategoriškai priklausomo kintamojo ir vieno ar daugiau nepriklausomų kintamųjų. [36]
„SMO“	Nuoseklus minimalus optimizavimas arba „SMO“ (angl. „Sequential Minimal Optimization“) yra patobulintas metodas, skirtas palaikomųjų vektorinių mašinų („SVM“, angl. „Support vector machines“) mokymui, kuris rodo gerus rezultatus sprendžiant įvairias problemas. „SVM“ naudojimas yra ribotas dėl jo keblaus naudojimo ir mokymo sudėtingumo. Tuo tarpu SMO yra gana paprastas, lengvai naudojamas bei greitesnis nei „SVM“. [36]
„IBk“	Egzemplioriais grįstų k-artimiausių kaimynų algoritmą arba „IBk“ (angl. „Instance-based k-nearest Neighbors“) galima apibrėžti kaip paprastą metodą, kuris praplečia k-artimiausių kaimynų algoritmą („KNN“). „IBk“ algoritmas ieško k artimiausių mokymo egzempliorių ir tada pateikia balą pagal kaimyninių etikečių svertinio panašumo (angl. „similarity-weighted“) vidurkį. [36] [37]
„Decision table“	Sprendimų lentelė (angl. „Decision table“) naudoja įvyniojimo metodą, kad būtų galima rasti gerą atributų pogrupį, kuris būtų įtraukiamas į lentelę. Šiam tikslui naudojamas „best-first“ paieškos metodas. Pašalindamas atributus, kurie mažai arba visiškai neprideda prie rezultato, algoritmas sumažina per didelio pritaikymo tikimybę ir sukuria mažesnę ir glaustą sprendimų lentelę. [38]
„JRip“	„JRip“ metodas sudaro taisyklių aibę (angl. „ruleset“) pakartotinai pridėdamas taisykles į tuščias aibės vietas tol, kol yra panaudojami visi teigiami pavyzdžiai. Naujos taisyklės formuojamos papildant jas pirminės (apriorinės) taisyklės savybėmis kol išsenka neigiami pavyzdžiai. Kai taisyklių aibė yra suformuota, optimizavimo būdu

	sumažinamas jos dydis, kad sukurti aibė kuo geriau tiktų mokymo aibei. [39]
„PART“	„PART“ algoritmas sukuria sutvarkytą taisyklių rinkinį, vadinamą sprendimų sąrašais. Nauji duomenys lyginami su kiekviena sąrašo taisykle ir duomenims priskiriama tos taisyklės kategorijai, kurią duomenys geriausiai atitinka. Tai yra „JRip“ ir „C4.5“ metodų derinys. [38]
„Hoeffding tree“	„Hoeffding tree“ yra pasirinkimų medžiu (angl. „Decision tree“) paremtas algoritmas. „Hoeffding tree“ tikslas subalansuoti atributus medyje taip, kad būtų sukurtas geriausias modelis. [39]
„J48“	„J48“ tai yra naujesnė algoritmo C4.5 versija. C4.5 algoritmas generuoja nurodyto duomenų rinkinio klasifikavimo – sprendimo medį, naudojant rekursyvų duomenų skaidymą. Tuo tarpu „J48“ rekursyviai atlieka klasifikavimą tol, kol kiekvienas lapas yra išgrynintas, tai yra, duomenys yra suklasifikuoti kaip įmanoma geriau, užtikrinant maksimalų tikslumą. [38]
„LMT“	Logistinio modelio medžiai arba „LMT“ (angl. „Logistic Model Trees“) medžio lapuose naudoja regresijos funkcijas. Metodas pasižymi tuo, jog gali būti naudojamas su trūkstamomis atributų reikšmėmis, dvejetainiais ir daugialypiais atributais. Tai sukuria mažus, bet tikslius medžius. „LMT“ naudoja „CART“ apkarpyimo techniką. „LMT“ sukuria vieną medį, kuriame skaitiniai atributai turi dvejetainius skilimus, vartiniai atributai – daugialypius, o lapuose logistinės regresijos modeliai. „LMT“ taip pat užtikrina, kad į medį patektų tik svarbūs atributai. [38]
„Random forest“	Atsitiktinio miško (angl. „Random forest“) mašininis mokymas susideda iš daugybės individualiai besimokančių medžių. Atsitiktinis miškas naudoja keletą atsitiktinių medžių klasifikacijų kurios apsprendžia bendrą klasifikaciją pagal nurodytą įvesties rinkinį. Atsitiktinis miškas naudoja „CART“ apkarpyimo techniką. [38]
„Random tree“	Atsitiktinis medis (angl. „Random tree“) susideda iš N atsitiktinai pasirinktų atributų rinkinio, kurį galima padalinti kiekviename mazge. Atsitiktinis čia reiškia, kad kiekvienas medis iš medžių grupės turi vienodas galimybes būti atrinktas, todėl medžiai pasiskirsto vienodai. Atsitiktiniai medžiai yra sugeneruojami greitai, o su daugybės medžių kombinacija paprastai gaunami tikslūs rezultatai. Atsitiktiniai medžiai neatlieka apkarpyimo. [38]
„REP tree“	Sumažintas klaidų apkarpyimo medis arba „REP“ medis (angl. „Reduced Error Pruning Tree“) yra greitis sprendimų medžio algoritmas, kuris kuria sprendimų / regresijos medį, naudodamas informaciją, gaunamą pagal padalinimo kriterijų. „REP“ medis surūšiuoja skaitinių atributų reikšmes tik kartą. Trūkstamos vertės yra užpildomos taikant trupmenų egzempliorių metodą (angl. „fractional instances method“). „REP“ medis atsižvelgia į visus atributus. [38]

Klasifikatoriams mokyti bei testuoti buvo naudojamas apibrėžtas mokymo bei testavimo rinkinys kiekvienai balso grupei. Pasirinkta, kad mokymo rinkinys turėtų sudaryti apie 70% visos imties, o tas pats balso autorius nepatektų tiek į testavimo, tiek į mokymo imtis. Visos pratestuotos klasifikatorių bei jų parametrų kombinacijos ir gauti rezultatai išspausdinti į „csv“ tipo failą.

5.5.4. Rezultatai

Toliau yra apibendrinami rezultatai, gauti ištestavus 14 klasifikatorių su įvairiais parametrais kiekvienai iš balso duomenų grupei.

5.5.4.1. Išvalyti bei padalinti į dviejų sekundžių atkarpas balso įrašai, kuriuose yra skaitomas tekstas

Išanalizavus išvalytų bei padalintų į dviejų sekundžių atkarpas balso įrašus, kuriuose yra skaitomas tekstas, nustatyta, kad geriausius rezultatus pasiekė „IBk“ („k-nearest neighbors“) klasifikatorius, kai „k“ = 7. Klasifikatoriaus bendras tikslumas 0,8172 (19 lentelė). Taip pat šis klasifikatorius užfiksavo didžiausią F įvertį, kuris lygus 0,8072 (22 lentelė), bei didžiausią MCC įvertinimą – 0,634 (23 lentelė). Nustatyta, jog klasifikatoriaus jautrumas 0,8233, o specifiškumas 0,8118. Šis duomenų rinkinys buvo naudojamas ir Parkinsono ligos atpažinimo sukurtoje sistemoje, kurioje didžiausias pasiektas bendras tikslumas buvo 74,50 %. Taigi papildomų balso parametrų, gautų naudojant „Opensmile“, padėjo pagerinti bendrą tikslumą, o taip pat ir jautrumą, specifiškumą, F įvertį bei MCC įvertinimą (naudoto klasifikatoriaus rezultatai 4.3.2 skyriuje).

Tuo tarpu didžiausią jautrumą (20 lentelė) bei specifiškumą (21 lentelė) užfiksavo „SDG“ klasifikatorius. Nustačius parametras „lambda“ = 0,65536 ir „seed“ = 911 buvo gautas 0,9487 jautrumas, o pakeitus parametras „seed“ = 701 buvo gautas didžiausias specifiškumas 0,9365. Tačiau šis klasifikatorius negalėtų būti taikomas praktikoje dėl per mažo bendro tikslumo, F įvertio bei MCC įvertinimo.

Taigi išvalytų bei padalintų į dviejų sekundžių atkarpas balso įrašų, kuriuose yra skaitomas tekstas, klasifikavimui tinkamiausias klasifikatorius yra „HoeffdingTree“, kai „H“ = 0,01, „E“ = 1,0E-8.

19 lentelė. 3 geriausi klasifikatoriai pagal bendrą tikslumą naudojant išvalytus bei suskaidytus balso įrašus, kuriuose yra skaitomas tekstas.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„IBk“	„k“ = 7	0,8172	0,8233	0,8118	0,8072	0,634
2	„SGD“	„lambda“ = 0,65536 „seed“ = 51	0,7947	0,7692	0,8168	0,7769	0,5869
3	„SMO“	„c“ = 1,1 „epsilon“ = 1,0E-12 „tolerance“=0,16384	0,7841	0,7293	0,8316	0,7585	0,5653

20 lentelė. 3 geriausi klasifikatoriai pagal jautrumą naudojant išvalytus bei suskaidytus balso įrašus, kuriuose yra skaitomas tekstas.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
-----	-----------------	------------	-------------------	-----------	---------------	-----------	-----------------

1	„SGD“	„lambda“ = 0,65536 „seed“ = 911	0,6529	0,9487	0,396	0,7176	0,4050
2	„IBk“	„k“ = 2	0,7324	0,9259	0,5643	0,7629	0,5175
3	„SMO“	„c“ = 1,1 „epsilon“ = 1,0E-12 „tolerance“=0,16384	0,7668	0,7720	0,7623	0,7548	0,5333

21 lentelė. 3 geriausi klasifikatoriai pagal specifiškumą naudojant išvalytus bei suskaidytus balso įrašus, kuriuose yra skaitomas tekstas.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„SGD“	„lambda“= 0,65536 „seed“ = 701	0,7403	0,5156	0,9356	0,6487	0,5045
2	„IBk“	„k“ = 2	0,7324	0,9259	0,5643	0,7629	0,5175
3	„HoeffdingTree“	„H“ = 0,26 „E“ = 1,0E-7	0,5708	0,1538	0,9331	0,25	0,1402

22 lentelė. 3 geriausi klasifikatoriai pagal F įvertį naudojant išvalytus bei suskaidytus balso įrašus, kuriuose yra skaitomas tekstas.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„IBk“	„k“ = 7	0,8172	0,8233	0,8118	0,8072	0,634
2	„SGD“	„lambda“ = 0,65536 „seed“ = 911	0,6529	0,9487	0,3960	0,7176	0,405
3	„SMO“	„c“ = 1,1 „epsilon“ = 1,0E-14 „tolerance“=0,32768	0,7827	0,7407	0,8193	0,7602	0,5625

23 lentelė. 3 geriausi klasifikatoriai pagal MCC įvertinimą naudojant išvalytus bei suskaidytus balso įrašus, kuriuose yra skaitomas tekstas.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„IBk“	„k“ = 7	0,8172	0,8233	0,8118	0,8072	0,634
2	„SGD“	„lambda“ = 0,65536 „seed“ = 911	0,6529	0,9487	0,3960	0,7176	0,405
3	„SMO“	„c“ = 1,1 „epsilon“ = 1,0E-12 „tolerance“=0,16384	0,7841	0,7293	0,8316	0,7585	0,5653

5.5.4.2. Išvalyti pilni balso įrašai, kuriuose yra skaitomas tekstas

Išvalytuose pilnuose balso įrašuose, kuriuose yra skaitomas tekstas, didžiausią bendrą tikslumą 0,8242 užfiksavo klasifikatorius „HoeffdingTree“, kai „H“ = 0,01, „E“ = 1,0E-8 (24 lentelė). Pastebėta, jog klasifikatoriaus jautrumas 0,6428 ir specifiškumas 0,9652 turi nemažą skirtumą. Tai rodo, jog klasifikatorius labiau tiksliau nustatys Parkinsono ligos nebuvimą nei jos buvimą. Tai

atspindi ir F įvertis 0,7619 (27 lentelė), kuris yra žemesnis nei duomenų grupėje, kurioje balso įrašai buvo išskaidyti į dviejų sekundžių atkarpas. „HoeffdingTree“ klasifikatorius užfiksavo ne tik geriausią F įvertį, tačiau ir MCC įvertinimą 0,6578 (28 lentelė).

Didžiausią jautrumą 0,8839 užfiksavo „RandomTree“ klasifikatorius (25 lentelė). Tačiau klasifikatoriaus specifiškumas itin mažas – vos 0,1875. Tai reiškia, kad klasifikatorius pernelyg dažnai nustatys Parkinsono ligą, nors jos nėra. Bendras „RandomTree“ klasifikatoriaus tikslumas taip pat mažas 0,4921.

26 lentelėje matome, jog didžiausią specifiškumą 0,9791 užfiksavo klasifikatorius „RandomForest“. Tačiau klasifikatoriaus bendras tikslumas, F įvertis bei MCC įvertinimas gerokai atsilieka nuo panašų specifiškumą užfiksavusių anksčiau aptartą klasifikatorių „HoeffdingTree“.

Taigi išvalytų pilnų balso įrašų, kuriuose yra skaitomas tekstas, klasifikavimui tinkamiausias klasifikatorius yra „HoeffdingTree“, kai „H“ = 0,01, „E“ = 1,0E-8.

24 lentelė. 3 geriausi klasifikatoriai pagal bendrą tikslumą naudojant išvalytus pilnus balso įrašus, kuriuose yra skaitomas tekstas.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„HoeffdingTree“	„H“ = 0,01 „E“ = 1,0E-8	0,8242	0,6428	0,9652	0,7619	0,6578
2	„IBk“	„k“ = 27	0,8085	0,6428	0,9375	0,7461	0,6190
3	„SGD“	„lambda“ = 0,02048 „seed“ = 161	0,7578	0,5357	0,9305	0,6593	0,5189

25 lentelė. 3 geriausi klasifikatoriai pagal jautrumą naudojant išvalytus pilnus balso įrašus, kuriuose yra skaitomas tekstas.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„RandomTree“	„K“ = 8 „minNum“ = 0,4 „numFolds“ = 14 „seed“ = 221	0,4921	0,8839	0,1875	0,6036	0,0975
2	„IBk“	„k“ = 9	0,7851	0,7857	0,7847	0,7619	0,5673
3	„REPTree“	„minNum“ = 0 „V“ = 1,0E-4 „numFolds“ = 2 „seed“ = 541	0,7031	0,6696	0,7291	0,6637	0,398

26 lentelė. 3 geriausi klasifikatoriai pagal specifiškumą naudojant išvalytus pilnus balso įrašus, kuriuose yra skaitomas tekstas.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„RandomForest“	„iterations“ = 600 „seed“ = 791	0,7304	0,4107	0,9791	0,5714	0,4916

2	„HoeffdingTree“	„H“ = 0,01 „E“ = 1,0E-8	0,8242	0,6428	0,9652	0,7619	0,6578
3	„IBk“	„k“ = 24	0,8085	0,6696	0,9166	0,7537	0,614

27 lentelė. 3 geriausi klasifikatoriai pagal F įvertį naudojant išvalytus pilnus balso įrašus, kuriuose yra skaitomas tekstas.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„HoeffdingTree“	„H“ = 0,01	0,8242	0,6428	0,9652	0,7619	0,6578
2	„IBk“	„k“ = 2	0,7851	0,7857	0,7847	0,7619	0,5673
3	„RandomForest“	„iterations“ = 600 „seed“ = 791	0,7304	0,4107	0,9791	0,5714	0,4916

28 lentelė. 3 geriausi klasifikatoriai pagal MCC įvertinimą naudojant išvalytus pilnus balso įrašus, kuriuose yra skaitomas tekstas.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„HoeffdingTree“	„H“ = 0,01	0,8242	0,6428	0,9652	0,7619	0,6578
2	„IBk“	„k“ = 27	0,8085	0,6428	0,9375	0,7461	0,619
3	„SGD“	„lambda“ = 0,02048 „seed“ = 161	0,7578	0,5357	0,9305	0,6593	0,5189

5.5.4.3. Nevalyti balso įrašai, kuriuose yra tariamos balsės

Nevalytuose balso įrašuose, kuriuose yra tariamos balsės, didžiausią bendrą tikslumą 0,9074 užfiksavo klasifikatorius „RandomForest“, kai „iterations“ = 300, „seed“ = 101 (29 lentelė). Klasifikatorius taip pat užfiksavo didžiausią specifiškumą 1 (31 lentelė) bei didžiausią MCC įvertinimą 0,826 (33 lentelė). „RandomForest“ klasifikatoriaus jautrumas lygus 0,8529, o F įvertis lygus 0,9206 - taip pat geri rezultatai. Pakeitus klasifikatoriaus parametą „seed“ = 641 buvo gautas ir didžiausias F įvertis 0,923 (32 lentelė).

Didžiausią jautrumą 0,9705 užfiksavo klasifikatorius „SGD“, kai „lambda“ = 0,65536, o „seed“ = 181 (30 lentelė). Taip pat klasifikatorius užfiksavo kiek mažesnę specifiškumą 0,65. Tai reiškia, jog klasifikatorius gali gana tiksliai nustatyti, jog vartotojas turi Parkinsono ligą, tačiau tuo pačiu per daug dažnai nustatys ligą, kai jos nėra. Tiesa, „SGD“ klasifikatorius taip pat užfiksavo neblogą bendrą tikslumą, tačiau vis tiek visomis metrikomis, išskyrus jautrumą, nusileidžia anksčiau aptartam „RandomForest“ klasifikatoriui.

Išnagrinėjus nevalytus balso įrašus, kuriuose yra tariamos balsės, galime pastebėti geresnius rezultatus pagal visas stebimas metrikas. Pavyzdžiui, 29 lentelėje matome, jog pirmą kartą buvo užfiksuotas bendras tikslumas didesnis nei 0,9 arba buvo užfiksuotas specifiškumas lygus 1. Tai galėjo nutikti dėl kelių pagrindinių skirtumų lyginant su balso įrašais, kuriuose buvo skaitomas tekstas. Pirmiausiai, duomenų grupę sudarė mažiau įrašų (17 lentelė), kuriuos vėliau suskirsčius į mokymo bei testavimo imtis, testavimui liko 54 įrašai. Antroji priežastis – formantų įtraukimas į klasifikavimui naudotus balso atributus. Jau anksčiau buvo įrodyta, jog formantų rezultatai koreliuoja su Parkinsono ligos turėjimu.

Taigi nevalytų balso įrašų, kuriuose yra tariamos balsės, klasifikavimui tinkamiausi klasifikatoriai yra „RandomForest“ arba „SGD“. Nors „SGD“ klasifikatorius visomis metrikomis išskyrus jautrumą nusileidžia „RandomForest“ klasifikatoriui, tačiau mums gali būti svarbiau, jog Parkinsono liga neliktų nepastebėta. Nuspręsti, kuris iš klasifikatorių tinkamesnis taip pat padėtų didesnis kiekis balso įrašų.

29 lentelė. 3 geriausi klasifikatoriai pagal bendrą tikslumą naudojant nevalytus balso įrašus, kuriuose yra tariamos balsės.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„RandomForest“	„iterations“ = 300 „seed“ = 101	0,9074	0,8529	1	0,9206	0,826
2	„Logistic“	„maxIt“=1,6384E-5	0,8703	0,8823	0,85	0,8955	0,7254
3	„RandomTree“	„K“ = 7 „minNum“ = 0,4 „numFolds“ = 2 „seed“ = 511	0,8703	0,8823	0,85	0,8955	0,7254

30 lentelė. 3 geriausi klasifikatoriai pagal jautrumą naudojant nevalytus balso įrašus, kuriuose yra tariamos balsės.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„SGD“	„lambda“= 0,65536 „seed“ = 181	0,8518	0,9705	0,65	0,8918	0,6838
2	„SMO“	„c“ = 3.1 „epsilon“ = 1,0E-14 „tolerance“=0,16384	0,8333	0,9411	0,65	0,8767	0,6373
3	„IBk“	„k“ = 2	0,8148	0,9411	0,6	0,8648	0,5963

31 lentelė. 3 geriausi klasifikatoriai pagal specifiškumą naudojant nevalytus balso įrašus, kuriuose yra tariamos balsės.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„RandomForest“	„iterations“ = 300 „seed“ = 101	0,9074	0,8529	1	0,9206	0,826
2	„SGD“	„lambda“= 1,0E-5 „seed“ = 211	0,8333	0,7647	0,95	0,8524	0,6902
3	„RandomTree“	„K“ = 7 „minNum“ = 0,4 „numFolds“ = 8 „seed“ = 511	0,7222	0,5882	0,95	0,7272	0,5331

32 lentelė. 3 geriausi klasifikatoriai pagal F įvertį naudojant nevalytus balso įrašus, kuriuose yra tariamos balsės.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„RandomForest“	„iterations“ = 300 „seed“ = 641	0,9074	0,8823	0,95	0,923	0,8128
2	„Logistic“	„maxIt“=1,6384E-5	0,8703	0,8823	0,85	0,8955	0,7254
3	„RandomTree“	„K“ = 7 „minNum“ = 0,4 „numFolds“ = 2 „seed“ = 511	0,8703	0,8823	0,85	0,8955	0,7254

33 lentelė. 3 geriausi klasifikatoriai pagal MCC įvertinimą naudojant nevalytus balso įrašus, kuriuose yra tariamos balsės.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„RandomForest“	„iterations“ = 300 „seed“ = 101	0,9074	0,8529	1	0,9206	0,826
2	„Logistic“	„maxIt“=1,6384E-5	0,8703	0,8823	0,85	0,8955	0,7254
3	„RandomTree“	„K“ = 7 „minNum“ = 0,4 „numFolds“ = 2 „seed“ = 511	0,8703	0,8823	0,85	0,8955	0,7254

5.5.4.4. Išvalyti balso įrašai, kuriuose yra tariamos balsės

Analizuojant išvalytus balso įrašus, kuriuose yra tariamos balsės, didžiausias užfiksuotas bendras tikslumas yra 0,9259 (34 lentelė). Toks tikslumas buvo užfiksuotas naudojant „RandomForest“ klasifikatorių su parametrais: „iterations“ = 400, „seed“ = 571. Šis klasifikatorius taip pat užfiksavo visišką specifiškumą = 1 (36 lentelė), didžiausią F įvertį 0,9375 (37 lentelė), didžiausią MCC įvertinimą 0,8574 (38 lentelė). Klasifikatoriaus jautrumas 0,8823 – didesnis nei tiksliausio klasifikatoriaus nevalytuose balso įrašuose, kuriuose tariamos balsės.

Didžiausią jautrumą 0,9411 užfiksavo klasifikatorius „REPTree“ (35 lentelė). Tačiau kiti klasifikatoriaus rodikliai yra itin prasti, todėl jis negalėtų būti naudojamas praktikoje. Nedaug nuo „REPTree“ atsiliko ir klasifikatorius „JRip“, kurio jautrumas 0,9117, tačiau likusios metrikos daug geresnės – bendras tikslumas = 0,8333, specifiškumas = 0,7, F įvertis = 0,8732, MCC įvertinimas = 0,636. Tačiau šis klasifikatorius vis tiek nusileidžia „RandomForest“ klasifikatoriui.

Taigi išvalytų balso įrašų, kuriuose yra tariamos balsės, klasifikavimui tinkamiausias klasifikatorius yra „RandomForest“, kai „iterations“ = 400, „seed“ = 571. Klasifikatoriaus gautos metrikos yra geresnės už nevalytų balso įrašų rastų klasifikatorių metrikas. Tai rodo, jog balso įrašų valymas pagerina rezultatus bandant atpažinti Parkinsono ligą.

34 lentelė. 3 geriausi klasifikatoriai pagal bendrą tikslumą naudojant išvalytus balso įrašus, kuriuose yra tariamos balsės.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„RandomForest“	„iterations“ = 400 „seed“ = 571	0,9259	0,8823	1	0,9375	0,8574
2	„SGD“	„lambda“= 1,0E-5 „seed“ = 11	0,8703	0,8529	0,9	0,8923	0,7353
3	„JRip“	„folds“ = 2 „O“ = 11 „seed“=181	0,8518	0,8529	0,85	0,8787	0,6908

35 lentelė. 3 geriausi klasifikatoriai pagal jautrumą naudojant išvalytus balso įrašus, kuriuose yra tariamos balsės.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„REPTree“	„minNum“ = 0 „V“ = 1,0E-4 „numFolds“ = 2 „seed“ = 51	0,6666	0,9411	0,2	0,7804	0,2169
2	„JRip“	„folds“ = 2 „O“ = 11 „seed“=1	0,8333	0,9117	0,7	0,8732	0,636
3	„IBk“	„k“ = 10	0,8148	0,9117	0,65	0,8611	0,594

36 lentelė. 3 geriausi klasifikatoriai pagal specifiškumą naudojant išvalytus balso įrašus, kuriuose yra tariamos balsės.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„RandomForest“	„iterations“ = 400 „seed“ = 571	0,9259	0,8823	1	0,9375	0,8574
2	„JRip“	„folds“ = 2 „O“ = 11 „seed“=961	0,8333	0,7352	1	0,8474	0,7121
3	„SMO“	„c“ = 0,1 „epsilon“ = 1,0E-14 „tolerance“= 1,0E-4	0,7777	0,647	1	0,7857	0,6359

37 lentelė. 3 geriausi klasifikatoriai pagal F įvertį naudojant išvalytus balso įrašus, kuriuose yra tariamos balsės.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„RandomForest“	„iterations“ = 400 „seed“ = 571	0,9259	0,8823	1	0,9375	0,8574
2	„SGD“	„lambda“= 1,0E-5	0,8703	0,8529	0,9	0,8923	0,7353

		„seed“ = 11					
3	„JRip“	„folds“ = 2 „O“ = 11 „seed“=181	0,8518	0,8529	0,85	0,8787	0,6908


38 lentelė. 3 geriausi klasifikatoriai pagal MCC įvertinimą naudojant išvalytus balso įrašus, kuriuose yra tariamos balsės.

Nr.	Klasifikatorius	Parametrai	Bendras tikslumas	Jautrumas	Specifiškumas	F įvertis	MCC įvertinimas
1	„RandomForest“	„iterations“ = 400 „seed“ = 571	0,9259	0,8823	1	0,9375	0,8574
2	„SGD“	„lambda“= 1,0E-5 „seed“ = 611	0,8703	0,8529	0,95	0,8888	0,7491
3	„JRip“	„folds“ = 2 „O“ = 11 „seed“=961	0,8333	0,7352	1	0,8474	0,7121

5.5.4.5. Rezultatų palyginimas

Lyginant atliktų bandymų bendro tikslumo rezultatus, didžiausią tikslumą užfiksavo išvalyti balso įrašai, kuriuose buvo tariamos balsės bei panaudotas „RandomForest“ klasifikatorius. Rezultatus galima matyti 1 diagramoje. Ši kombinacija pasiekė 92,59 % tikslumą. Diagramoje taip pat galima pastebėti, jog išvalyti balso įrašų bendras tikslumas gaunamas didesnis nei nevalytų įrašų. Taigi galime teigti, jog balso įrašų valymas lemia didesnę tikslumą.

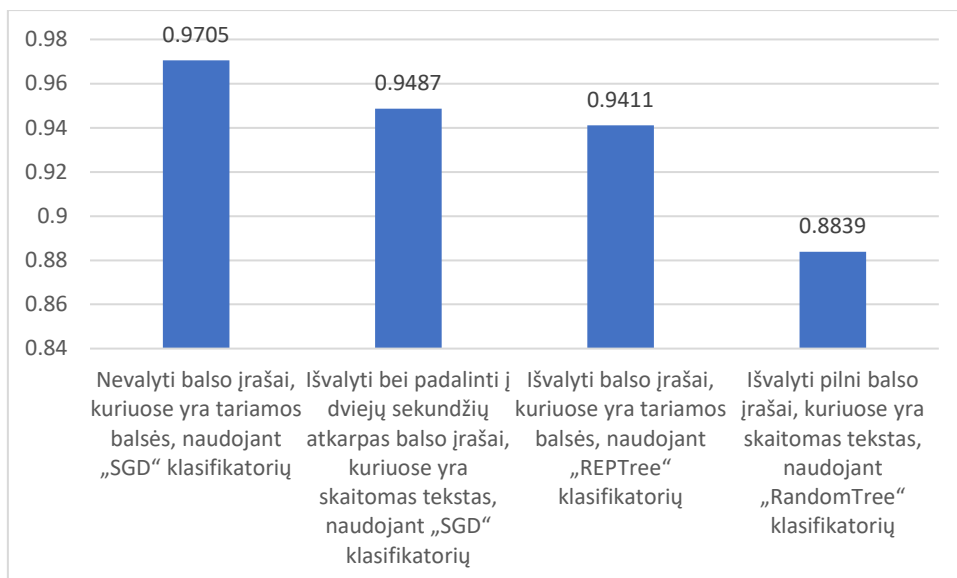
1 diagrama. Bendro tikslumo rezultatų palyginimas.



Lyginant atliktų bandymų jautrumo rezultatus, didžiausią jautrumą užfiksavo nevalyti balso įrašai, kuriuose tariamos balsės bei panaudotas „SGD“ klasifikatorius. Rezultatus galima matyti 2 diagramoje. Ši kombinacija pasiekė 97,05 % jautrumą. Vertinant jautrumą nevalyti balso įrašai gavo


aukštesnius rezultatus nei išvalyti balso įrašai. Taip galėjo nutikti, kadangi klasifikatoriaus specifiškumas buvo itin žemas. Tai rodo, kad klasifikatorius buvo labiau linkęs teigti, jog balso įrašo savininkas turi Parkinsono ligą. Toks klasifikatorius per dažnai pateiktų klaidingai teigiamus rezultatus.

2 diagrama. Jautrumo rezultatų palyginimas.



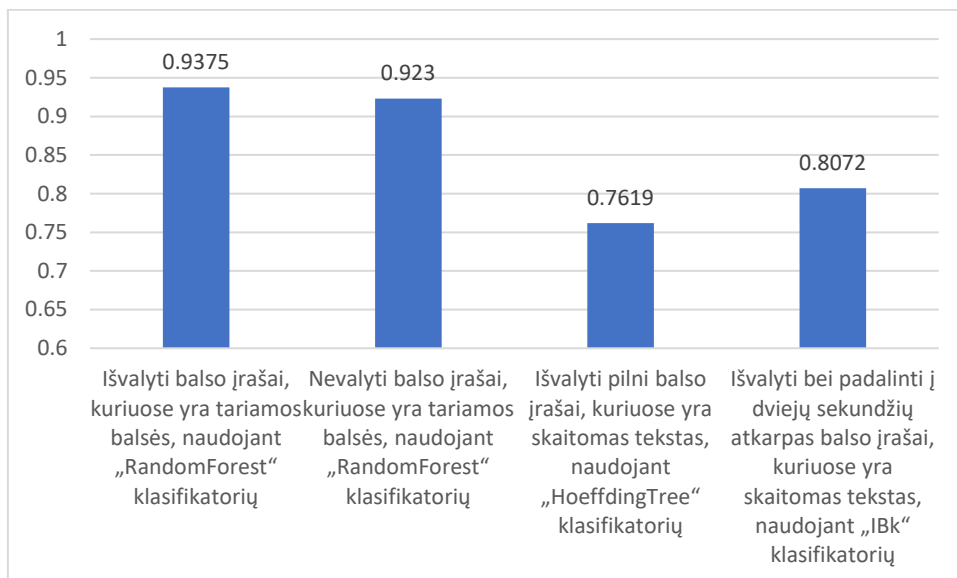
Lyginant atliktų bandymų specifiškumo rezultatus, didžiausią specifiškumą užfiksavo balso įrašai, kuriuose tariamos balsės bei panaudotas „RandomForest“ klasifikatorius. Rezultatus galima matyti 3 diagramoje. Tiek išvalyti tiek nevalyti įrašai pasiekė 100 procentų specifiškumą. Kaip bebūtų, šios kombinacijos jautrumas buvo gerokai mažesnis. Tai rodo, jog algoritmas linkęs neaptikti Parkinsono ligos. Toks algoritmas negalėtų būti naudojamas praktikoje.

3 diagrama. Specifiškumo rezultatų palyginimas.



Lyginant atliktų bandymų F įverčius, didžiausią įvertį užfiksavo išvalyti balso įrašai, kuriuose tariamos balsės bei panaudotas „RandomForest“ klasifikatorius. Rezultatus galima matyti 4 diagramoje. Ši kombinacija pasiekė 0,9375 F įvertį. Diagramoje taip pat galima pastebėti, jog išvalyti balso įrašų F įvertis yra šiek tiek didesnis nei nevalytų įrašų. Nevalytuose balso įrašuose, kuriuose tariamos balsės užfiksuotas 0,923 F įvertis. Taigi galime teigti, jog balso įrašų valymas lemia didesnę tikslumą.


4 diagrama. F įverčių palyginimas.



Lyginant atliktų bandymų MCC įvertinimus, didžiausią įvertinimą užfiksavo išvalyti balso įrašai, kuriuose tariamos balsės bei panaudotas „RandomForest“ klasifikatorius. Rezultatus galima matyti 5 diagramoje. Ši kombinacija pasiekė 0,8574 MCC įvertinimą. Diagramoje taip pat galima pastebėti, jog išvalyti balso įrašų MCC įvertinimas yra šiek tiek didesnis nei nevalytų įrašų. Nevalytuose balso įrašuose, kuriuose tariamos balsės užfiksuotas 0,826 MCC įvertinimas. Taigi galime teigti, jog balso įrašų valymas lemia didesnę tikslumą.

Apibendrinant 1 – 5 diagramas taip galima pastebėti jog išvalyti bei nevalyti balso įrašų, kuriuose yra tariamos balsės, metrikos buvo geresnės nei balso įrašų, kuriuose buvo skaitomas tekstas. Šios metrikos yra bendras tikslumas, specifiškumas, F įvertis, MCC įvertinimas. Galime teigti, jog balso įrašai, kuriuose tariamos balsės, yra labiau tinkami bandant aptikti Parkinsono ligą nei įrašai, kuriuose yra skaitomas tekstas.

5 diagrama. MCC įvertinimų palyginimas.



5.5.4.6. Rezultatų palyginimas su kitų autorių gautais rezultatais

39 lentelėje aprašyti šio tyrimo bei kitų autorių tyrimuose naudoti metodai bei pasiektas bendras tikslumas.

39 lentelė. Bendro tikslumo palyginimas su kitų autorių pasiektais rezultatais

Darbo aprašymas	Pasiektas bendras tikslumas
Šio tyrimo metu geriausias bendras tikslumas buvo pasiektas naudojant atsitiktinio miško (angl. „Random Forest“) klasifikatorių. Aukščiausias rezultatas pasiektas naudojant duomenų pavyzdžius, kuriuose buvo tariamos balsės, o šie įrašai buvo papildomai išvalyti. Tikrinimui duomenų rinkinys buvo padalintas į 70% bei 30% rinkinius taip, kad to paties žmogaus įrašai neatsidurtų abiejuose rinkiniuose.	92,59 %
Tyrimo [43] metu geriausias bendras tikslumas pasiektas panaudojus duomenų rinkinį, kuriame tariamos balsės, panaudotas „Yaffee“ garso atributų rinkinys bei „IBk“ klasifikatorius, kai $k = 1$. Duomenų rinkinį sudarė 291 balso įrašai. Buvo naudojami iš anksto paruoštas duomenų rinkinys.	94,55 %
Tyrimo [44] metu geriausias bendras tikslumas pasiektas naudojant atsitiktinio miško klasifikatorių. Testavimui buvo panaudotas kryžminio tikrinimo technika. Tiesa, naudotas duomenų rinkinys turi kelis to paties žmogaus įrašus, todėl kryžminio tikrinimo technika nėra tinkama – vieno žmogaus balso įrašai gali patekti į treniravimo bei į testavimo rinkinius. Bendrą duomenų rinkinį sudarė net 1040 balso įrašai, kurie buvo paruošti iš anksto.	99,94 %
Tyrimo [45] metu buvo panaudoti 55 žmonių balso duomenys, kuriuose buvo tariamos balsės. Kiekvienas asmuo atliko po 6 įrašus. Panaudojus	100 %

„IMFCC“ garso atributų rinkinį bei kryžminio tikrinimo techniką buvo gautas didžiausias bendras tikslumas.	
Tyrimo [46] metu nustatyta, jog didžiausias bendras tikslumas pasiekiamas naudojant įrašus, kuriuose asmenys kartoja 6 kortelių skiemenų sekas. Klasifikuojant buvo panaudotas priverstinio universalaus fono modelis (angl. „forced universal background model“). Imtį bendrai sudarė 100 žmonių. Tikrinimui buvo naudojama kryžminio tikrinimo technika.	94 ± 6 %
Tyrimo [47] metu didžiausias bendras tikslumas pasiektas naudojant „k-NN“ klasifikatorių bei naudojant 80 žmonių balso pavyzdžius. Buvo panaudoti tokie balso atributai, kaip tonas, triukšmingumas, MFCC bei kitos spektro metrikos. Tikrinimui panaudotas „OGA“ metodas, kai duomenų imtis skaidoma įvairiais režiais taikant „vienas su visais“ strategiją.	89,46 %
Tyrimo [48] metu didžiausias bendras tikslumas buvo pasiektas naudojant neuroninį tinklą „PCA-ANFIS“. Tikrinimui buvo panaudota kryžminio tikrinimo technika. Taip pat buvo naudojamas duomenų rinkinys, kurį sudarė net 5875 įrašai, kuriuose buvo tariamos balsės.	99,72 %
Tyrimo [49] metu didžiausias bendras tikslumas buvo gautas panaudojus „SVM-RBF“ klasifikatorių. Taip pat buvo naudojami „TQWT“ bei „MFCC“ garso atributų rinkiniai. Buvo naudojami sujungti du balso duomenų rinkiniai, kuriuos bendrai sudarė 245 įrašai. Nors tikrinimui buvo naudojamas kryžminis tikrinimas, įrašai buvo atrinkti, jog to paties asmens įrašais nepatektų į testavimo bei mokymo rinkinius vienu metu.	86%

Išvados

1. Parkinsono ligos atpažinimui tinkamesni balso įrašai, kuriuose tariamos balsės, nei įrašai, kuriuose skaitomas tekstas. Įrašų, kuriuose tariamos balsės, tikslumas pasiekė 92,59 %, tuo tarpu įrašų, kuriuose buvo skaitomas tekstas vos 82,42 %.
2. Balso valymas pagerina Parkinsono ligos atpažinimo klasifikatorių tikslumą. Didžiausias bendras tikslumas pasiektas naudojant nevalytus balso įrašus buvo 90,74 %, o o naudojant išvalytus įrašus – 92,59 %.
3. Geriausi rezultatai, siekiant atpažinti Parkinsono ligai, buvo pasiekti naudojant išvalytus balso įrašus, kuriuose yra tariamos balsės. Didžiausias bendras tikslumas siekia 92,59 % naudojant „RandomForest“ klasifikatorių.
4. 2 sekundžių atkarpomis išskaidyti balso įrašai, kuriuose yra skaitomas tekstas, yra mažiausiai tikslūs duomenys norint atpažinti Parkinsono ligą, tačiau vienintelio tipo duomenys, norint atpažinti ligą nurodant vartotojui skaityti atsitiktinį tekstą. Didžiausias bendras tikslumas siekia 81,72 %, kai įrašai buvo išvalyti bei panaudotas „IBk“ klasifikatorius.
5. Naudojant pilnus balso įrašus, kuriuose yra skaitomas tekstas, didžiausias užfiksuotas bendras tikslumas buvo 82,42 %, kai įrašai buvo išvalyti bei panaudotas „HoeffdingTree“ klasifikatorius.
6. Naudojant balso įrašus, kuriuose yra tariamos balsės, didžiausias užfiksuotas bendras tikslumas buvo 92,59%, F – įvertis buvo 0,9375, MCC įvertinimas – 0,8574, kai įrašai buvo išvalyti bei panaudotas „Random Forest“ klasifikatorius.

Literatūros sąrašas

- [1] D. Heisters, "Parkinson's: symptoms, treatments and research," *Br J Nurs*, vol. 20, no. 9, pp. 548–554, May 2011.
- [2] "What is Dopamine? - Definition & Function - Video & Lesson Transcript," *Study.com*. [Online]. Available: <https://study.com/academy/lesson/what-is-dopamine-definition-function.html>. [Accessed: 27-Nov-2019].
- [3] "Parkinson's Disease Statistics," *Parkinson's News Today*. .
- [4] "Sergamumo Parkinsono liga statistiniai duomenys. 2015 m.," *Lietuvos Parkinsono ligos draugija*, 21-Mar-2015. .
- [5] "Parkinson's Disease Information Page | National Institute of Neurological Disorders and Stroke." [Online]. Available: <https://www.ninds.nih.gov/Disorders/All-Disorders/Parkinsons-Disease-Information-Page>. [Accessed: 27-Nov-2019].
- [6] "Symptoms - Speech Difficulties or Changes," *ParkinsonsDisease.net*. [Online]. Available: <https://parkinsonsdisease.net/symptoms/speech-difficulties-changes/>. [Accessed: 27-Nov-2019].
- [7] J. Buzaitis, K. Bondzinskaitė „Senyvo amžiaus žmonių priežiūros sistema“, 2019.
- [8] "Young Onset Parkinson's Disease - Parkinson Canada." [Online]. Available: <https://www.parkinson.ca/about-parkinsons/young-onset-parkinsons-disease/>. [Accessed: 27-Nov-2019].
- [9] T. Bocklet, S. Steidl, E. Noeth, and S. Skodda, "Automatic evaluation of parkinson's speech - Acoustic, prosodic and voice related cues," *Proceedings of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, pp. 1149–1153, Jan. 2013.
- [10] P.-F. Guo, P. Bhattacharya, and N. Kharma, "Advances in Detecting Parkinson's Disease," in *Medical Biometrics*, Berlin, Heidelberg, 2010, pp. 306–314.
- [11] T. V. S. Sriram, M. V. Rao, G. V. S. Narayana, D. Kaladhar, and T. P. R. Vital, "Intelligent Parkinson Disease Prediction Using Machine Learning Algorithms," vol. 3, no. 3, p. 5, 2013.
- [12] J. Proença, A. Veiga, S. Candeias, and F. Perdigão, "Acoustic, Phonetic and Prosodic Features of Parkinson's disease Speech," in *STIL*, 2013.
- [13] "Neural Impairment Test Suite - Apps on Google Play." [Online]. Available: https://play.google.com/store/apps/details?id=com.alauraitis.test_suite&hl=en. [Accessed: 27-Nov-2019].
- [14] "iPrognosis - Apps on Google Play." [Online]. Available: https://play.google.com/store/apps/details?id=com.iprognosis.gdatasuite&hl=en_US. [Accessed: 27-Nov-2019].
- [15] guru, "One Page – ENG," *ParkinsonCheck*. .

- [16] P.-F. Guo, P. Bhattacharya, and N. Kharma, “Advances in Detecting Parkinson’s Disease,” in *Medical Biometrics*, Berlin, Heidelberg, 2010, pp. 306–314.
- [17] A. L. Samuel, *Some Studies in Machine Learning Using the Game of Checkers*. 1959.
- [18] “Pattern Recognition and Machine Learning - Christopher M. Bishop - Google Books.” [Online]. Available: <https://books.google.lt/books?id=qWPwnQEACAAJ&dq=isbn:9780387310732&hl=en&sa=X&ved=0ahUKEwi3j-3iovTIAhXDJFAKHdRaAQAQ6AEIKDAA>. [Accessed: 27-Nov-2019].
- [19] A. Lauraitis, „Neurologinių sutrikimų aptikimo hibridinis klasifikavimo modelis“. Daktaro disertacija, Kauno technologijos universitetas, 2020,
- [20] A. Lauraitis A, Maskeliūnas R, Damaševičius R, Krilavičius T. A Mobile Application for Smart Computer-Aided Self-Administered Testing of Cognition, Speech, and Motor Impairment. *Sensors* (Basel). 2020 Jun 6;20(11):3236. doi: 10,3390/s20113236.
- [21] A. Lauraitis, A., Maskeliūnas, R., Damaševičius, R., & Krilavičius, T. (2020). Detection of speech impairments using cepstrum, auditory spectrogram and wavelet time scattering domain features. *IEEE Access*, 8, 96162-96172. doi:10,1109/ACCESS.2020,2995737
- [22] S. Herzog, T. P. Daf. Crew, J. Fourier, and C. Shannon, “Efficient DSP Implementation of Median Filtering for Real-Time Audio Noise Reduction,” p. 6, 2013.
- [23] “librosa — librosa 0,8.0 documentation.” <https://librosa.org/doc/main/index.html> (accessed Mar. 27, 2021).
- [24] “Praat: doing Phonetics by Computer.” <https://www.fon.hum.uva.nl/praat/> (accessed Mar. 28, 2021).
- [25] “A0708010108.pdf.” Accessed: May 06, 2021. [Online]. Available: [http://www.ijesi.org/papers/Vol\(7\)i8/Version-1/A0708010108.pdf](http://www.ijesi.org/papers/Vol(7)i8/Version-1/A0708010108.pdf).
- [26] “Loudness,” *SLT info*, Jan. 31, 2014. <https://www.sltinfo.com/loudness/> (accessed May 06, 2021).
- [27] “5. The Voice.” <http://msp.ucsd.edu/syllabi/170,13f/course-notes/node5.html> (accessed May 06, 2021).
- [28] “Harmonicity.” <https://www.fon.hum.uva.nl/praat/manual/Harmonicity.html> (accessed May 06, 2021).
- [29] “What is a Sound Spectrum?” <https://newt.phys.unsw.edu.au/jw/sound.spectrum.html> (accessed May 06, 2021).
- [30] T. Giannakopoulos and A. Pikrakis, “Chapter 4 - Audio Features,” in *Introduction to Audio Analysis*, T. Giannakopoulos and A. Pikrakis, Eds. Oxford: Academic Press, 2014, pp. 59–103.
- [31] “Loudness and sharpness in psychoacoustics,” May 11, 2016. <https://www.johndcook.com/blog/2016/05/11/loudness-and-sharpness/> (accessed May 06, 2021).

- [32] R. Grigaitė, “DVIBALSIŲ SPEKTRO ANALIZĖ.” 2010, [Online]. Available: <https://gs.elaba.lt/object/elaba:1948272/1948272.pdf>.
- [33] Stuart J. Russell, Peter Norvig, *Artificial Intelligence: A Modern Approach*, Third Edition. .
- [34] “Weka 3 - Data Mining with Open Source Machine Learning Software in Java.” <https://www.cs.waikato.ac.nz/ml/weka/> (accessed Mar. 28, 2021).
- [35] S. Sossi Alaoui, Y. Farhaoui, and B. Aksasse, “Classification algorithms in Data Mining,” *International Journal of Tomography and Simulation*, vol. 31, pp. 34–44, Aug. 2018.
- [36] L. Feremans, B. Cule, C. Vens, and B. Goethals, “Combining Instance and Feature Neighbors for Efficient Multi-label Classification,” in *2017 IEEE International Conference on Data Science and Advanced Analytics (DSAA)*, Oct. 2017, pp. 109–118, doi: [10.1109/DSAA.2017.70](https://doi.org/10.1109/DSAA.2017.70).
- [37] S. Sonawani and D. Mukhopadhyay, “A Decision Tree Approach to Classify Web Services using Quality Parameters,” *arXiv:1311.6240 [cs]*, Nov. 2013, Accessed: May 06, 2021. [Online]. Available: <http://arxiv.org/abs/1311.6240>.
- [38] J. Stupenkaitė, “Srautinių duomenų tyrybos metodai ir taikymai,” *Data stream mining methods and applications*, Jun. 2013, Accessed: May 06, 2021. [Online]. Available: <https://www.vdu.lt/cris/handle/20,500,12259/119004>.
- [39] “IRJET-V4I3615.pdf.” Accessed: May 06, 2021. [Online]. Available: <https://www.irjet.net/archives/V4/i3/IRJET-V4I3615.pdf>.
- [40] M. A. Hall, “Correlation-based Feature Selection for Machine Learning.” Hamilton, New Zealand.
- [41] “Synthetic vowels of speakers with Parkinson’s disease and Parkinsonism.” figshare, Oct. 29, 2019, doi: [10.6084/m9.figshare.7628819.v1](https://doi.org/10.6084/m9.figshare.7628819.v1).
- [42] “openSMILE,” audeERING. <https://www.audeering.com/opensmile/> (accessed Apr. 03, 2021).
- [43] J. S. Almeida *et al.*, “Detecting Parkinson’s disease with sustained phonation and speech signals using machine learning techniques,” *Pattern Recognition Letters*, vol. 125, pp. 55–62, Jul. 2019, doi: [10.1016/j.patrec.2019.04.005](https://doi.org/10.1016/j.patrec.2019.04.005).
- [44] E. Vaiciukynas, A. Verikas, A. Gelzinis, and M. Bacauskiene, “Detecting Parkinson’s disease from sustained phonation and speech signals,” *PLOS ONE*, vol. 12, no. 10, p. e0185613, Oct. 2017, doi: [10.1371/journal.pone.0185613](https://doi.org/10.1371/journal.pone.0185613).
- [45] B. Karan, S. S. Sahu, and K. Mahto, “Parkinson disease prediction using intrinsic mode function based features from speech signal,” *Biocybernetics and Biomedical Engineering*, vol. 40, no. 1, pp. 249–264, Jan. 2020, doi: [10.1016/j.bbe.2019.05.005](https://doi.org/10.1016/j.bbe.2019.05.005).
- [46] L. Moro-Velazquez *et al.*, “A forced gaussians based methodology for the differential evaluation of Parkinson’s Disease by means of speech processing,” *Biomedical Signal Processing and Control*, vol. 48, pp. 205–220, Feb. 2019, doi: [10.1016/j.bspc.2018.10.020](https://doi.org/10.1016/j.bspc.2018.10.020).

- [47] J. R. Orozco-Arroyave *et al.*, “NeuroSpeech: An open-source software for Parkinson’s speech analysis,” *Digital Signal Processing*, vol. 77, pp. 207–221, Jun. 2018, doi: [10.1016/j.dsp.2017.07.004](https://doi.org/10.1016/j.dsp.2017.07.004).
- [48] C. Quan, K. Ren, and Z. Luo, “A Deep Learning Based Method for Parkinson’s Disease Detection Using Dynamic Features of Speech,” *IEEE Access*, vol. 9, pp. 10239–10252, 2021, doi: [10.1109/ACCESS.2021.3051432](https://doi.org/10.1109/ACCESS.2021.3051432).
- [49] C. O. Sakar *et al.*, “A comparative analysis of speech signal processing algorithms for Parkinson’s disease classification and the use of the tunable Q-factor wavelet transform,” *Applied Soft Computing*, vol. 74, pp. 255–263, Jan. 2019, doi: [10.1016/j.asoc.2018.10.022](https://doi.org/10.1016/j.asoc.2018.10.022).
- [50] Lauraitis, A., Maskeliunas, R., & Damaševičius, R. (2018). ANN and fuzzy logic based model to evaluate huntington disease symptoms. *Journal of Healthcare Engineering*, 2018 doi:10.1155/2018/4581272
- [51] Połap, D., Woźniak, M., Damaševičius, R., & Maskeliūnas, R. (2019). Bio-inspired voice evaluation mechanism. *Applied Soft Computing Journal*, 80, 342-357. doi:10.1016/j.asoc.2019.04.006
- [52] Guimaraes, M. T., Medeiros, A. G., Almeida, J. S., Falcao Y Martin, M., Damasevicius, R., Maskeliunas, R., Reboucas Filho, P. P. (2020). An optimized approach to huntington's disease detecting via audio signals processing with dimensionality reduction. *Proceedings of the International Joint Conference on Neural Networks*, doi:10.1109/IJCNN48605.2020.9206773
- [53] Abayomi-Alli, O. O., Damasevicius, R., Maskeliunas, R., & Abayomi-Alli, A. (2020). BiLSTM with data augmentation using interpolation methods to improve early detection of parkinson disease. *Proceedings of the 2020 Federated Conference on Computer Science and Information Systems, FedCSIS 2020*, 371-380. doi:10.15439/2020F188

Priedai

1 priedas. text_reading_cleanedSplitted_benchmarks.csv

Šiame faile pateikti išvalytų bei padalintų į 2 sekundžių atkarpas balso įrašų, kuriuose buvo skaitomas tekstas, eksperimentų rezultatai.

2 priedas. text_reading_cleaned_full_benchmarks.csv

Šiame faile pateikti išvalytų pilnų balso įrašų, kuriuose buvo skaitomas tekstas, eksperimentų rezultatai.

3 priedas. vowels_not_cleaned_benchmark.csv

Šiame faile pateikti nevalytų balso įrašų, kuriuose buvo tariamos balsės, eksperimentų rezultatai.

4 priedas. vowels_cleaned_benchmark.csv

Šiame faile pateikti išvalytų balso įrašų, kuriuose buvo tariamos balsės, eksperimentų rezultatai.