Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Elektromechaninių sistemų vibracijos signalų klasifikavimo būdų tyrimas

Baigiamasis magistro projektas

Andrius Dūda

Projekto autorius

Asist. dr. Vytautas Gargasas

Vadovas

Kaunas, 2026

Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Elektromechaninių sistemų vibracijos signalų klasifikavimo būdų tyrimas

Baigiamasis magistro projektas

Valdymo technologijos (6211EX014)

Andrius Dūda

Projekto autorius

Asist. dr. Vytautas Gargasas

Vadovas

Lekt. prakt. Kęstutis Brazauskas

Recenzentas

Kaunas, 2026

Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Andrius Dūda

Elektromechaninių sistemų vibracijos signalų klasifikavimo būdų 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 sąraše;

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.

Andrius Dūda

Patvirtinta elektroniniu būdu

Dūda, Andrius. Elektromechaninių sistemų vibracijos signalų klasifikavimo būdų tyrimas. Magistro baigiamasis projektas / vadovas asist. dr. Vytautas Gargasas; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): elektronikos inžinerija (inžinerijos mokslai).

Reikšminiai žodžiai: elektromechaninės sistemos, vibracijos signalai, klasifikavimas.

Kaunas, 2026. 74 p.

Santrauka

Šio darbo tikslas yra ištirti signalų klasifikavimo metodus, tinkamus įvairių elektromechaninių sistemų vibracijos signalams klasifikuoti ir įvertinti jų klasifikavimo tikslumą skirtinguose duomenų rinkiniuose. Buvo aprašyti vibracijos signalų matavimo būdai, signalų analizės ir klasifikavimo metodai. Darbe naudoti trys skirtingi duomenų rinkiniai. Vienas iš jų buvo CWRU guolių duomenų bazėje užfiksuoti guolių, su skirtingais gedimų tipais, vibracijos signalai. Taip pat naudota MaFaulDa mašinų gedimų simuliatoriaus duomenų bazė, apimanti skirtingus sistemos su elektros varikliu gedimo atvejus. Dar vienas duomenų rinkinys, naudotas tyrime, buvo gautas laboratorijoje, matuojant variklio, kuriam buvo keičiama apkrova, vibracijos signalus. Šiems duomenims buvo nubraižyti signalų laiko srityje, spektro, kepstro ir autokoreliacijos funkcijos grafikai. Iš jų parinkus informatyvius požymius, sudarytas klasifikatorius, kurio veikimas paremtas Euklido atstumų skaičiavimu tarp taškų požymių erdvėje ir jų klasių centrų. Taip pat išbandytas visų duomenų rinkinių klasifikavimas CNN, RF, SVM ir KNN metodais. CNN metode klasifikavimui naudotos iš vibracijos signalų sudarytos spektrogramos, o RF, SVM ir KNN metodams naudoti iš spektrogramų sudaryti požymių vektoriai. Darbe palygintas šių klasifikavimo metodų klasifikavimo tikslumas ir sudarytos sumaišymo matricos tam, kad būtų galima įvertinti jų tinkamumą elektromechaninių sistemų būklės ir būsenų klasifikavimui.

Dūda, Andrius. Research on vibration signal classification methods for electromechanical systems. Master's Final Degree Project / supervisor asist. dr. Vytautas Gargasas; Faculty of Electrical and Electronics Engineering, Kaunas University of Technology.

Study field and area (study field group): electronics engineering (engineering sciences).

Keywords: electromechanical systems, vibration signals, classification.

Kaunas, 2026. 74 pages.

Summary

The aim of this thesis is to investigate signal classification methods suitable for classifying vibration signals of various electromechanical systems and to assess the accuracy of their classification across different datasets. The methods of vibration signal measurement, signal analysis and classification were described. Three different datasets were used in this thesis. One of them consisted of vibration signals of bearings with different fault types recorded in the CWRU bearing database. The MaFaulDa machinery fault simulator database, containing different fault cases of an electric motor system was also used. Another dataset used in the research was obtained in the laboratory by measuring vibration signals of a motor with varying load conditions. For these data sets, time domain, spectrum, cepstrum and autocorrelation function plots of the signals were generated. Based on selected informative features, a classifier was developed, operation of which was based on calculating Euclidean distances between points in the feature space and the centers of their classes. The classification of all data sets using CNN, RF, SVM and KNN methods was also tested. In the CNN method, spectrograms generated from vibration signals were used for classification, while feature vectors extracted from spectrograms were used for the RF, SVM, and KNN methods. The classification accuracy of these methods was compared, and confusion matrices were obtained in order to evaluate their suitability for the condition and state classification of electromechanical systems.

Turinys

Lentelių sąrašas **8**
Paveikslų sąrašas **9**
Santrumpų ir terminų sąrašas **11**
Įvadas **12**
1. Teorinė dalis **13**
1.1. Vibracijos signalų matavimas 13
1.2. Elektromechaninių sistemų vibracijų tyrimo mokslinių publikacijų analizė 15
1.3. Signalų analizės metodai 17
1.3.1. Furjė transformacija 17
1.3.2. Autokoreliacija 18
1.3.3. Kepstro analizė 19
1.3.4. Spektrogramos 20
1.3.5. Euklido atstumo klasifikatorius 20
1.3.6. Fišerio tiesinis diskriminantas 21
1.3.7. Pagrindinių komponenčių analizė 22
1.4. Klasifikavimo metodai 23
1.4.1. SVM 23
1.4.2. KNN 24
1.4.3. CNN 25
1.4.4. LSTM 26
1.4.5. Random Forest 27
2. Metodologinė dalis **28**
2.1. Duomenų bazės 28
2.1.1. CWRU guolių duomenų bazė 28
2.1.2. MaFaulDa mašinų gedimų simuliatoriaus duomenų bazė 30
2.1.3. Laboratorijos eksperimentas 31
2.2. Matavimo įranga 32
2.3. Metodologija 33
2.3.1. Vibracijos signalų paruošimas 33
2.3.2. Signalų segmentavimas 34
2.3.3. Dažninės analizės metodų taikymas 35
2.3.4. Spektrinė analizė 36
2.3.5. Kepstro funkcija 37
2.3.6. Autokoreliacijos analizė 37
2.3.7. Vibracijos signalų analizė požymių erdvėje ir klasifikavimas 38
2.3.8. Mašininio mokymosi metodų taikymas vibracijos signalų klasifikavimui 39
2.3.9. Spektrogramų sudarymas ir požymių formavimas klasifikavimo metodams 40
2.3.10. CNN taikymas vibracijos signalų klasifikavimui 42
2.3.11. RF taikymas vibracijos signalų klasifikavimui 44
2.3.12. SVM taikymas vibracijos signalų klasifikavimui 44
2.3.13. KNN taikymas vibracijos signalų klasifikavimui 45
3. Tiriamoji dalis **46**
3.1. CWRU rezultatai 46
3.1.1. Spektras 47

3.1.2. Kepstras ... 48
3.1.3. Autokoreliacija ... 49
3.1.4. CNN ... 50
3.1.5. RF ... 51
3.1.6. SVM ... 51
3.1.7. KNN ... 52
3.1.8. Apibendrinimas ... 53
3.2. MaFaulDa rezultatai ... 53
3.2.1. Spektras ... 55
3.2.2. Kepstras ... 56
3.2.3. Autokoreliacija ... 57
3.2.4. CNN ... 58
3.2.5. RF ... 58
3.2.6. SVM ... 59
3.2.7. KNN ... 60
3.2.8. Apibendrinimas ... 60
3.3. KTU laboratorijos eksperimento rezultatai ... 61
3.3.1. Spektras ... 62
3.3.2. Kepstras ... 63
3.3.3. Autokoreliacija ... 64
3.3.4. CNN ... 65
3.3.5. RF ... 66
3.3.6. SVM ... 66
3.3.7. KNN ... 67
3.3.8. Apibendrinimas ... 68
3.4. Tyrimo dalies apibendrinimas ... 68
Išvados ir rezultatai ... 71
Literatūros sąrašas ... 72
Priedai ... 75
1 priedas. Matlab kodo fragmentas spektro skaičiavimui ... 75
2 priedas. Matlab kodo fragmentas kepstro skaičiavimui ... 75
3 priedas. Matlab kodo fragmentas autokoreliacijos skaičiavimui ... 75
4 priedas. Matlab kodo fragmentas signalo laiko srityje, spektro, kepstro ir autokoreliacijos klasifikavimui ir sumaišymo matricų sudarymui ... 75
5 priedas. Matlab kodo fragmentas spektrogramų sudarymui ... 76
6 priedas. Matlab kodo fragmentas CNN ... 77
7 priedas. Matlab kodo fragmentas požymių vektorių sudarymui iš spektrogramų ... 77
8 priedas. Matlab kodo fragmentas RF ... 78
9 priedas. Matlab kodo fragmentas SVM ... 78
10 priedas. Matlab kodo fragmentas KNN ... 79

Lentelių sąrašas

1 lentelė. Jutiklio techninės charakteristikos [36] 32
2 lentelė. Dažninės signalų analizės metodų klasifikavimo tikslumo rezultatai 68
3 lentelė. Mašininio mokymosi metodų klasifikavimo tikslumo rezultatai 68

Paveikslų sąrašas

1 pav. Variklio vibracijos signalų matavimas akselerometru [2] 15
2 pav. Furjė transformacija [12] 18
3 pav. Autokoreliacija [14] 19
4 pav. Kepstro analizė [16] 20
5 pav. Spektrograma [17] 20
6 pav. Fišerio tiesinis diskriminantas [19] 22
7 pav. SVM architektūra [22] 24
8 pav. KNN algoritmo pavyzdys [24] 25
9 pav. CNN [26] 26
10 pav. LSTM architektūra [28] 26
11 pav. RF algoritmo schema [30] 27
12 pav. CWRU bandymų stendas [31] 29
13 pav. MaFaulDa bandymų stendas [32] 31
14 pav. Laboratorijos stendo schema [33] 31
15 pav. Laboratorijos stendas 32
16 pav. Vibracijos signalų dažninės analizės eiga 36
17 pav. Požymių parinkimas 38
18 pav. Vibracijos signalų klasifikavimo mašininio mokymosi metodais eiga 40
19 pav. Apdorota spektrograma 42
20 pav. CWRU vibracijos signalų laiko srityje grafikas. Gedimas 1 – vidinio žiedo riedėjimo takelio defektas; gedimas 2 – riedėjimo kūnų defektas; gedimas 3 – išorinio žiedo riedėjimo takelio defektas. 46
21 pav. CWRU vibracijos signalų laiko srityje sumaišymo matrica. Klasės: 1 – normali būsena; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – riedėjimo kūnų defektas; 4 – išorinio žiedo riedėjimo takelio defektas. 47
22 pav. CWRU spektro grafikas. Gedimas 1 – vidinio žiedo riedėjimo takelio defektas; gedimas 2 – riedėjimo kūnų defektas; gedimas 3 – išorinio žiedo riedėjimo takelio defektas. 47
23 pav. CWRU spektro sumaišymo matrica. Klasės: 1 – normali būsena; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – riedėjimo kūnų defektas; 4 – išorinio žiedo riedėjimo takelio defektas. 48
24 pav. CWRU kepstro grafikas. Gedimas 1 – vidinio žiedo riedėjimo takelio defektas; gedimas 2 – riedėjimo kūnų defektas; gedimas 3 – išorinio žiedo riedėjimo takelio defektas. 48
25 pav. CWRU kepstro sumaišymo matrica. Klasės: 1 – normali būsena; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – riedėjimo kūnų defektas; 4 – išorinio žiedo riedėjimo takelio defektas. 49
26 pav. CWRU autokoreliacijos grafikas. Gedimas 1 – vidinio žiedo riedėjimo takelio defektas; gedimas 2 – riedėjimo kūnų defektas; gedimas 3 – išorinio žiedo riedėjimo takelio defektas. 49
27 pav. CWRU autokoreliacijos sumaišymo matrica. Klasės: 1 – normali būsena; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – riedėjimo kūnų defektas; 4 – išorinio žiedo riedėjimo takelio defektas. 50
28 pav. CWRU CNN sumaišymo matrica. Klasės: 1 – riedėjimo kūnų defektas; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – normali būsena; 4 – išorinio žiedo riedėjimo takelio defektas. 50
29 pav. CWRU RF sumaišymo matrica. Klasės: 1 – normali būsena; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – riedėjimo kūnų defektas; 4 – išorinio žiedo riedėjimo takelio defektas. 51
30 pav. CWRU SVM sumaišymo matrica. Klasės: 1 – riedėjimo kūnų defektas; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – normali būsena; 4 – išorinio žiedo riedėjimo takelio defektas. 52

31 pav. CWRU KNN sumaišymo matrica. Klasės: 1 – riedėjimo kūnų defektas; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – normali būsena; 4 – išorinio žiedo riedėjimo takelio defektas. 52
32 pav. MaFaulDa vibracijos signalų laiko srityje grafikas. Gedimas 1 – 0,5 mm horizontalus ašies nesutapimas. 54
33 pav. MaFaulDa vibracijos signalų laiko srityje sumaišymo matrica. Klasės: 1 – normali būsena; 2 – disbalansas; 3 – horizontalus ašies nesutapimas; 4 – vertikalus ašies nesutapimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – guolio už rotoriaus gedimas. 54
34 pav. MaFaulDa spektro grafikas. Gedimas 1 – 0,5 mm horizontalus ašies nesutapimas. 55
35 pav. MaFaulDa spektro sumaišymo matrica. Klasės: 1 – normali būsena; 2 – disbalansas; 3 – horizontalus ašies nesutapimas; 4 – vertikalus ašies nesutapimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – guolio už rotoriaus gedimas. 55
36 pav. MaFaulDa kepstro grafikas. Gedimas 1 – 0,5 mm horizontalus ašies nesutapimas. 56
37 pav. MaFaulDa kepstro sumaišymo matrica. Klasės: 1 – normali būsena; 2 – disbalansas; 3 – horizontalus ašies nesutapimas; 4 – vertikalus ašies nesutapimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – guolio už rotoriaus gedimas. 56
38 pav. MaFaulDa autokoreliacijos grafikas. Gedimas 1 – 0,5 mm horizontalus ašies nesutapimas. 57
39 pav. MaFaulDa autokoreliacijos sumaišymo matrica. Klasės: 1 – normali būsena; 2 – disbalansas; 3 – horizontalus ašies nesutapimas; 4 – vertikalus ašies nesutapimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – guolio už rotoriaus gedimas. 57
40 pav. MaFaulDa CNN sumaišymo matrica. Klasės: 1 – horizontalus ašies nesutapimas; 2 – disbalansas; 3 – normali būsena; 4 – guolio už rotoriaus gedimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – vertikalus ašies nesutapimas. 58
41 pav. MaFaulDa RF sumaišymo matrica. Klasės: 1 – normali būsena; 2 – disbalansas; 3 – horizontalus ašies nesutapimas; 4 – vertikalus ašies nesutapimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – guolio už rotoriaus gedimas. 59
42 pav. MaFaulDa SVM sumaišymo matrica. Klasės: 1 – horizontalus ašies nesutapimas; 2 – disbalansas; 3 – normali būsena; 4 – guolio už rotoriaus gedimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – vertikalus ašies nesutapimas. 59
43 pav. MaFaulDa KNN sumaišymo matrica. Klasės: 1 – horizontalus ašies nesutapimas; 2 – disbalansas; 3 – normali būsena; 4 – guolio už rotoriaus gedimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – vertikalus ašies nesutapimas. 60
44 pav. KTU laboratorijos eksperimento vibracijos signalų laiko srityje grafikas. 61
45 pav. KTU laboratorijos eksperimento vibracijos signalų laiko srityje sumaišymo matrica. 62
46 pav. KTU laboratorijos eksperimento spektro grafikas. 62
47 pav. KTU laboratorijos eksperimento spektro sumaišymo matrica. 63
48 pav. KTU laboratorijos eksperimento kepstro grafikas. 63
49 pav. KTU laboratorijos eksperimento kepstro sumaišymo matrica. 64
50 pav. KTU laboratorijos eksperimento autokoreliacijos grafikas. 64
51 pav. KTU laboratorijos eksperimento autokoreliacijos sumaišymo matrica. 65
52 pav. KTU laboratorijos eksperimento CNN sumaišymo matrica. 65
53 pav. KTU laboratorijos eksperimento RF sumaišymo matrica. 66
54 pav. KTU laboratorijos eksperimento SVM sumaišymo matrica. 67
55 pav. KTU laboratorijos eksperimento KNN sumaišymo matrica. 67

Santrumpų ir terminų sąrašas

Santrumpos:

MEMS – mikro-elektro-mechaninė sistema (angl. *Micro-Electro-Mechanical System*)

LDV – lazerinis Doplerio vibrometras (angl. *Laser Doppler Vibrometer*)

MBH-LPQ – daugiablokės vietinės fazės kvantavimo histogramos (angl. *Multi-Block Histograms of Local Phase Quantization*)

SCN – stochastinis konfigūracijos tinklas (angl. *Stochastic Configuration Network*)

SVM – atraminių vektorių klasifikatorius (angl. *Support Vector Machine*)

KNN – k-artimiausių kaimynų metodas (angl. *K-Nearest Neighbors*)

FFT – greitoji Furjė transformacija (angl. *Fast Fourier Transform*)

STFT – trumpalaikė Furjė transformacija (angl. *Short-Time Fourier Transform*)

PCA – pagrindinių komponenčių analizė (angl. *Principal Component Analysis*)

CNN – konvoliucinis neuroninis tinklas (angl. *Convolutional Neural Network*)

LSTM – ilgalaikės-trumpalaikės atminties tinklas (angl. *Long Short-Term Memory*)

RF – atsitiktinio miško klasifikatorius (angl. *Random Forest*)

Įvadas

Elektromechaninių sistemų vibracijų tyrimas vis dar išlieka aktualia mokslinių tyrimų sritimi, kadangi atrandama vis naujų inžinerinių šios srities pritaikymų. Mechanizmo virpesių signalo apdorojimas ir klasifikavimas paprastai yra naudojamas kuriant automatizuotas diagnostikos sistemas. Tokios automatizuotos diagnostikos sistemos ypač aktualios techninio aptarnavimo srityje, nes gali aptikti gedimo požymius dar prieš įrenginio gedimą. Dėl to galima atlikti tokios elektromechaninės sistemos, kuri dar veikia, tačiau nesiimant techninio aptarnavimo priemonių greitai suges, techninį aptarnavimą. Toks profilaktinis techninis aptarnavimas leidžia pratęsti eksploatuojamų elektromechaninių sistemų tarnavimo laiką ir padidinti jų efektyvumą.

Vibracijų signalų klasifikavimas taip pat gali būti taikomas ne tik gedimams diagnozuoti, bet ir stebėti bei vertinti elektromechaninės sistemos veikimo režimą. Akivaizdu, kad elektromechaninė sistema skirtingais veikimo periodais gali būti skirtingai apkrauta mechaniškai. Didesne mechanine apkrova veikiami mechanizmai ar elektriniai varikliai, dažniausiai dyla ir sugenda greičiau. Todėl yra aktualu stebėti elektromechaninės sistemos mechaninės apkrovos lygį, siekiant įvertinti eksploatuojamų sistemų mechaninės apkrovos dinamiką. Ši informacija gali padėti kokybiškiau paskirstyti eksploatuojamų mechanizmų mechanines apkrovas bei pastebėti apkrovos kitimo anomalijas ir pagal tai ieškoti būdų apsaugoti eksploatuojamą sistemą.

Be vibracijos signalų analizės yra žinomi ir kiti būdai elektromechaninės sistemos veikimo režimui ar mechaninei apkrovai įvertinti, tačiau dauguma jų reikalauja įsikišimo į variklių maitinimo ar valdymo grandines. Šiame tyrime siūloma reikalingą informaciją apie sistemų apkrovą ir darbo režimą bei techninę būklę gauti analizuojant elektromechaninių sistemų vibracijų signalus. Vibracijos signalų matavimo sistema nereikalauja modifikacijų valdymo grandinėje. Tai yra privalumas, nes daugeliu atvejų valdymo grandinės modifikacijos kelia technines problemas, kadangi pakeista arba papildyta schema praranda pradinį patikimumą.

Darbo tikslas: ištirti signalų klasifikavimo metodus, tinkamus įvairių elektromechaninių sistemų vibracijų signalų klasifikavimui ir įvertinti jų klasifikavimo tikslumą skirtinguose duomenų rinkiniuose.

Darbo uždaviniai:

1. atlikti elektromechaninių sistemų vibracijos signalų klasifikavimo būdų literatūros analizę;
2. išanalizuoti ir parinkti tyrimui tinkamas vibracijos signalų duomenų bazes ir surinkti vibracijos signalus laboratorijoje;
3. pritaikyti skirtingus signalų analizės ir mašininio mokymosi metodus vibracijos signalų klasifikavimui;
4. palyginti skirtingų metodų klasifikavimo tikslumą ir tinkamumą skirtingų elektromechaninių sistemų būsenų ir būklių atpažinimui.

1. Teorinė dalis

Mechaninių vibracijų analizė yra vienas dažniausiai naudojamų prognozuojamos techninės priežiūros metodų. Šis metodas padeda diagnozuoti gedimus ankstyvajame etape bei fiksuoti mechanizmo ar elektromechaninės sistemos veikimo būseną, apkrovos lygį ir kitas savybes. Vibracijos analizė yra svarbi priimant sprendimus dėl įrenginio remonto arba keitimo, norint sumažinti techninės priežiūros sąnaudas ir prastovų laiką. Šis metodas yra veiksmingai taikomas daugelyje pramonės šakų. Jį galima taikyti ir besisukančiai, ir nesisukančiai įrangai, nenutrūkstamiems procesams ar net statybinėms konstrukcijoms. Įprastai veikdamos mašinos sukelia tam tikrus virpesius. Vibracijų amplitudės įvairiose mašinose skiriasi ir priklauso nuo apkrovos sąlygų. Jei amplitudės viršija normalų lygį, šios vibracijos sukelia spartesnį dėvėjimąsi arba ankstyvą gedimą, todėl svarbu nustatyti jų priežastis. Kiekvienas mechaninis gedimas sukuria specifinį vibracijos modelį, priklausantį nuo įrenginio konstrukcijos ir darbo sąlygų [1].

1.1. Vibracijos signalų matavimas

Vibracijos analizė mašinų stebėjimo ir diagnostikos srityje paprastai susideda iš trijų pagrindinių etapų: duomenų rinkimo, signalų apdorojimo ir gedimų klasifikavimo. Duomenų rinkimo etape yra du svarbūs prietaisai: analizatorius ir jutiklis [2].

Analizatorius yra prietaisas, naudojamas mašinų generuojamiems vibracijos duomenims analizuoti. Jį sudaro jutiklis, stiprintuvas, filtras ir analoginis-skaitmeninis keitiklis. Signalas iš vibracijos jutiklio praeina per stiprintuvą, kuris padidina skiriamąją gebą bei signalo ir triukšmo santykį. Sustiprintas signalas prafiltruojamas, kad skaitmeninimo etape nebūtų iškraipymų. Signalas tada suskaitmeninamas analoginiu-skaitmeniniu keitikliu ir patenka į apdorojimo įrenginį, kuriame jis gali būti pavaizduotas laiko bangos forma arba gali būti toliau apdorotas, kad būtų gautas dažnių spektras. Vibracijos analizatorius dar galima suskirstyti į konvencinius ir kompiuterinius vibracijos analizatorius. Konvencinis vibracijos analizatorius yra atskiras prietaisas, specialiai sukurtas vibracijai tirti. Šiuo prietaisu galima nustatyti gedimo priežastį ir mašinos gedimo laiką. Naudojami vieno, dviejų ir keturių kanalų analizatoriai. Kompiuterinis vibracijos analizatorius yra vis plačiau naudojama priemonė, kuria vibracijos duomenys gali būti apdorojami virtualiai, naudojant specialią programinę įrangą ir asmeninį kompiuterį. Kompiuterinių analizatorių privalumas yra tai, kad jie paprastos konstrukcijos, nebrangūs, lengvai remontuojami ir gali atlikti daugumą funkcijų, kurias turi įprasti vibracijos analizatoriai [2].

Jutiklis arba keitiklis yra įrenginys, kuris mechaninius signalus paverčia elektriniais signalais. Naudojamų jutiklių tipas paprastai priklauso nuo dažnių diapazono, jautrumo, konstrukcijos ir eksploatacinių apribojimų. Nesvarbu, kokio tipo jutikliai naudojami, kuo standesnis jutiklio tvirtinimas, tuo didesnis dažnių diapazonas ir jo rodmenų tikslumas. Praktikoje vibracijos signalui gauti dažniausiai naudojami šie jutiklių tipai: akselerometrai, greičio jutikliai ir poslinkio jutikliai [2].

Akselerometras yra prietaisas, naudojamas konstrukcijos pagreičiui matuoti. Jo veikimo mechanizmas toks: kai pjezoelektrinė medžiaga akselerometre yra veikiama jėgos, ji sukuria krūvį, proporcingą veikiančiai jėgai. Kadangi jėga yra tiesiogiai proporcinga pagreičiui, bet koks šio koeficiento pokytis sukelia susidariusio krūvio pokytį, kuris vėliau sustiprinamas. Vienašiai akselerometrai gali nustatyti judėjimą tik vienoje plokštumoje, o triašiai akselerometrai – visose trijose plokštumose. Akselerometrai yra plačiai naudojami jutikliai dėl savo patikimumo, paprastumo ir patvarumo. Akselerometrus dar galima suskirstyti į pjezoelektrinius ir MEMS (angl. *Micro-*

Electro-Mechanical System) akselerometrus. Pjezoelektriniai akselerometrai veikia kvarco arba keraminių kristalų, kurie paprastai yra iš anksto įkrauti, pjezoelektriniu efektu. Jie generuoja elektrinį signalą, proporcingą matuojamam pagreičiui. Pjezoelektriniai akselerometrai turi keletą privalumų, tokių kaip geresnis dažnių ir dinaminis diapazonas, lengvas svoris ir didelis jautrumas. Tačiau jie yra jautrūs išorinės aplinkos trukdžiams [2].

MEMS akselerometrai susideda iš judančios bandomosios masės su plokštelėmis, pritvirtintos prie rėmo mechanine pakabos sistema. Veikiama pagreičio, bandomoji masė dėl savo inercijos priešinasi judėjimui, todėl spyruoklė išsitempia arba susispaudžia. Taip susidaro jėga, proporcinga pagreičiui. MEMS akselerometrų pagrindiniai privalumai yra tai, kad jie yra tinkami žemo dažnio vibracijai matuoti ir pasižymi dideliu jautrumu. Taip pat šiuolaikiniai MEMS akselerometrai užtikrina gana gerą duomenų kokybę iki kelių dešimčių kHz. Jų trūkumas – prastas signalo ir triukšmo santykis [2].

Greičio keitikliai matuoja įtampą, kurią sukuria objekto santykinis judėjimas. Jie veikia elektromagnetinės indukcijos principu ir jiems nereikalingas papildomo maitinimo šaltinio. Paviršius, ant kurio sumontuotas jutiklis, vibruoja, todėl magneto judėjimas ritėje sukuria įtampą, proporcingą vibracijos greičiui. Greičio jutikliai nerekomenduojami naudoti diagnozuojant aukštų apsukų įrenginius, kadangi šių jutiklių veikimo dažnių diapazonas yra ribotas nuo 10 Hz iki 2 kHz. Greičio keitiklių privalumai yra tai, kad jie dažniausiai yra pigesni už kitus panašaus tipo jutiklius ir yra paprastai montuojami. Jų trūkumas yra tai, kad jie būna didelių matmenų, sunkūs ir nepatikimi esant aukštesnei darbinei temperatūrai [2].

Poslinkio jutikliai matuoja ir santykinę veleno vibraciją, ir padėtį. Jie paprastai naudojami matuoti žemo dažnio vibracijas, kurių dažnis mažesnis nei 10 Hz, tačiau taip pat gali matuoti ir vibracijos signalus iki 300 Hz. Šiais jutikliais matuojant vibracijos dažnius, viršijančius 1 kHz, amplitudė paprastai yra prarandama dėl triukšmo. Šie jutikliai yra pakankamai jautrūs ir nereikalauja daug priežiūros. Jų trūkumas yra tai, kad juos sudėtinga sumontuoti. Taip pat jie yra jautrūs smūgiams [2].

Dar vienas signalų matavimui taikomas prietaisas yra LDV (angl. *Laser Doppler vibrometer*). LDV yra nekontaktinis optinis matavimo prietaisas, kuris gali būti naudojamas bet kurio taško virpesių greičiams ant konkretaus įrenginio paviršiaus nustatyti. LDV veikimo mechanizmas pagrįstas lazerinio *Doplerio* principu, kai dažniu moduliuojamas lazerio spindulys atsispindi nuo vibruojančio paviršiaus, o atsispindėjusio spindulio *Doplerio* poslinkis lyginamas su atskaitos spinduliu. Ši technologija padeda atlikti tolimojo nuotolio matavimus nepakenkiant signalo kokybei. Vienas pagrindinių LDV privalumų yra matavimo taško keitimo paprastumas. Tai galima atlikti tiesiog nukreipiant lazerio spindulį. Nepaisant to, LDV taikymas stebint ir diagnozuojant įrenginius kol kas yra ribotas dėl kainos ir sudėtingo pritaikymo praktinėmis sąlygomis [2].

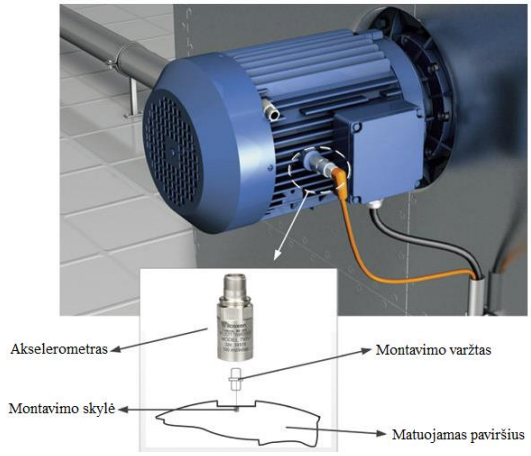

1 pav. Variklio vibracijos signalų matavimas akselerometru [2]

1.2. Elektromechaninių sistemų vibracijų tyrimo mokslinių publikacijų analizė

Vibracijos signalų analizė ir jų klasifikavimas tampa vis svarbesniais metodais diagnozuojant elektromechaninių sistemų techninę būklę ir prognozuojant galimus gedimus. Sparčiai augantis pramonės automatizavimas bei poreikis užtikrinti nepertraukiamą įrangos veikimą skatina ieškoti patikimų, tikslių ir greitų būdų nustatyti įvairius defektus, atsirandančius įrenginių darbo metu. Vibracijos signalai, kaip vieni jautriausių diagnostinių parametrų, padeda rasti gedimus dar ankstyvuose jų etapuose. Pastaraisiais metais vis daugiau tyrimų remiasi šių signalų duomenimis bei taiko pažangius analizės metodus – nuo tradicinių laiko ir dažnio srities technikų iki sudėtingų mašininio mokymosi bei giluminio mokymosi algoritmų. Šioje literatūros analizės dalyje aptariami aktualūs moksliniai tyrimai, kuriuose nagrinėjami vibracijos signalų apdorojimo metodai ir jų pritaikymas elektromechaninių sistemų būklės klasifikavimui keičiantis apkrovai ar esant įvairiems gedimų atvejams.

Chennana ir kt. [3] 2025 m. tyrime pateikė naujovišką riedėjimo guolių defektų diagnozavimo besisukančiose mašinose metodą naudojant giliųjų ir negiliųjų požymių sintezę. Pripažindami tradicinių metodų trūkumus įvairiomis eksploatavimo sąlygomis, autoriai pasiūlė hibridinį modelį, kuriame derinamos daugiablokės vietinės fazės kvantavimo histogramos (angl. *Multi-Block Histograms of Local Phase Quantization, MBH-LPQ*). Tai yra rankiniu būdu sukurti negilių požymių deskriptoriai su giliaisiais požymiais, išgautais iš anksto apmokyto konvoliucinio neuroninio tinklo. Tam, kad būtų padidintas klasifikavimo tikslumas, šis metodas naudoja rezultatų lygmens sintezę taikant svertinę sumą. Išsamūs eksperimentai su keliais duomenų rinkiniais parodė aukštus diagnostikos tikslumo rezultatus, pasiekus atitinkamai 98,95 % ir 100 % tikslumą.

Wang ir kt. [4] 2024 m. tyrime pristatė naują vibracijos signalų gedimų klasifikavimo metodą, taikant stochastinius konfigūracijos tinklus (angl. *Stochastic configuration network, SCN*). Integruojant laiko ir dažnio analizės metodus, iš dažnio ir laiko dažnio sričių išgautos savybės, panaudotos hibridiniams duomenų rinkiniams sukurti. Šie duomenų rinkiniai naudoti apmokyti keliems SCN modeliams, kurių kiekvienas atspindi skirtingas vibracijos signalų charakteristikas. Šis metodas sujungia pagal dažnių spektrą sukurtų modelių rezultatus, todėl pasiekiamas didesnis klasifikavimo tikslumas naudojant palyginti paprastą architektūrą. Eksperimentai su keliais pramoniniais duomenų rinkiniais rodo, kad

siūlomas SCN metodas pasiekia tokį pat arba geresnį našumą kaip gilaus mokymosi modeliai. Taip pat šis metodas pasižymi skaičiavimo efektyvumu ir įgyvendinimo paprastumu.

Zimnickas ir kt. [5] 2020 m. tyrime pristatė metodą statoriaus gedimams bešepetėliuose nuolatinės srovės varikliuose diagnozuoti, derinant pažangią vibracijų stebėsenos sistemą su ilgalaikės atminties neuroniniais tinklais. Tyrime buvo sukurta speciali bandymų platforma, aprūpinta aukšto jautrumo vibracijos jutikliais. Siekiant tiksliau išskirti požymius naudotos signalų spektrogramos, gautos panaudojant Furjė transformaciją. Požymiai buvo išskirti iš vibracijos duomenų naudojant spektrinę entropiją ir momentinį dažnį bei standartizuoti naudojant vidurkį ir standartinį nuokrypį. Tokiu būdu buvo pasiektas 97,10 % tikslumas klasifikuojant normalią veikimo būseną, lankinio išlydžio ir atviros grandinės defektus statoriaus apvijose.

Zhang ir Yang [6] 2017 m. atliktame tyrime, paskelbtame „*Sensors“* žurnale, pasiūlė metodiką, skirtą rotorinės sistemos apkrovos kategorijoms identifikuoti naudojant vibracijos signalų analizę. Eksperimentiniame tyrime buvo taikomos 5 tipinės apkrovos rūšys – smūginės, pastovios, tiesinės, sinusoidinės ir trumpalaikės – siekiant sukurti įvairias vibracijos charakteristikas. Surinkti vibracijos duomenys buvo apdoroti naudojant EEMD (angl. *Ensemble Empirical Mode Decomposition*) metodą, kuris leidžia išskaidyti pradinius signalus į skirtingus dažnius, o mišrius dažnių spektro komponentus atskirti nuo aukštų ir žemų dažnių. Po to gautos savybės buvo įvestos į atgalinio sklidimo neuroninį tinklą, kuris klasifikavo apkrovos tipus. Rezultatai parodė, kad siūlomas metodas gali pasiekti aukštą vidutinį klasifikavimo tikslumą, siekiantį 94,54 %, identifikuojant skirtingas apkrovos sąlygas rotoriaus sistemoje.

Ullah ir kt. [7] 2025 m. „*Sensors“* žurnale paskelbtame tyrime pristatė vibracijų signalais pagrįstą asinchroninių variklių anomalijų aptikimo metodiką, naudojant mašininio mokymosi algoritmus. Tyrime naudota MAFAULDA (angl. *Machinery Fault Database*) duomenų bazė, kurioje sukaupti įvairių variklio būsenų vibracijos duomenys. Iš šių duomenų išgautos statistinės savybės, kurios vėliau naudotos klasifikavimo modelių, tokių kaip atraminių vektorių klasifikatoriaus (angl. *Support Vector Machine, SVM*), k-artimiausių kaimynų (angl. *k-nearest neighbors, KNN*) ir gilieji neuroniniai tinklai. Nustatyta, kad šie modeliai gali efektyviai nustatyti anomalijas asinchroniniuose varikliuose.

Almutairi ir Sinha [8] 2023 m. „*Machines“* žurnale paskelbtame tyrime pristatė vibracijų signalais pagrįstą mašininio mokymosi metodą, skirtą rotoriaus ir guolių defektams klasifikuoti besisukančiose mašinose. Tyrime buvo naudojami laboratorinio bandymų stendo vibracijos duomenys, kuriuose buvo imituoti įvairūs rotoriaus ir guolių gedimai. Iš šių duomenų buvo išgautos optimizuotos laiko ir dažnio sričių charakteristikos, kurios vėliau buvo naudojamos dirbtinių neuroninių tinklų modeliams mokyti. Modeliai buvo testuojami esant skirtingiems rotoriaus sukimosi greičiams, siekiant įvertinti jų patikimumą ir pritaikomumą įvairiomis eksploatacinėmis sąlygomis. Nustatyta, kad siūlomas metodas gali efektyviai klasifikuoti rotoriaus ir guolių defektus.

Liu ir kt. [9] 2023 m. „*Machines“* žurnale paskelbtame tyrime pristatė asinchroninių variklių gedimų diagnostikos metodą, pagrįstą vienmačiu išplėstiniu konvoliuciniu neuroniniu tinklu. Tyrime analizuotos elektromagnetinės jėgos charakteristikos esant rotoriaus ekscentriškumui ir lūžusiam rotoriaus strypui, siekiant nustatyti jų įtaką vibracijos signalams. Pasiūlytas modelis leido efektyviai išgauti svarbias vibracijos signalo ypatybes be rankinio požymių išskyrimo, naudojant aktyvacijos funkciją ir likutinius ryšius, siekiant išvengti gradientų išnykimo ir tinklo efektyvumo mažėjimo.

Eksperimentai, atlikti su keturių polių asinchroniniais varikliais, parodė, kad siūlomas metodas pasiekia aukštą gedimų klasifikavimo tikslumą, viršijantį tradicinių metodų rezultatus.

Gargasas ir kt. [10] 2024 m. straipsnyje taikė mechaninės vibracijos analizės ir signalų klasifikavimo metodus nustatant pažeistą traukinio pantografo paviršių ir identifikuojant skirtingus defektų tipus. Straipsnyje išbandyti keli paprastos statistinės signalų analizės metodai, tokie kaip vidurkis, standartinis nuokrypis, dispersija ir kurtozė. Nustatyta, kad standartinis nuokrypis ir dispersija leidžia atskirti pažeistą paviršių nuo sveiko, tačiau tokiu būdu negalima atskirti skirtingų defektų tipų. Tyrime konvoliuciniam neuroniniam tinklui (CNN) treniruoti ir testuoti naudotos Mel spektrogramos. Požymiams išskirti naudota Furjė transformacija, koreliacijos ir autokoreliacijos funkcijos.

Išanalizavus literatūroje aptariamus tyrimus, akivaizdu, kad vibracijos signalų analizė ir klasifikavimas yra efektyvus metodas pramoninių elektromechaninių sistemų gedimams ir būsenai diagnozuoti. Dauguma autorių taiko pažangius signalų apdorojimo metodus ir mašininio mokymosi algoritmus siekdami atpažinti įvairias gedimų būsenas, remdamiesi vibracijos duomenimis. Vis dėlto šiuose darbuose dažniausiai analizuojamos konkrečios, iš anksto žinomos gedimų rūšys, o vibracijos signalai vertinami kaip statiški, nekintantys priklausomai nuo eksploatacinių parametrų, tokių kaip apkrova. Nors kai kuriais atvejais apkrova minima kaip diagnostikos veiksnys, retai sistemingai tiriama, kaip vibracijos signalų struktūra keičiasi keičiantis variklio apkrovai, ir kaip šie pokyčiai galėtų būti klasifikuojami siekiant išplėsti ar patikslinti diagnostikos galimybes. Be to, dažnai tiriami pavieniai klasifikavimo metodai, nepalyginant jų tikslumo tarpusavyje. Dėl to šiame darbe bus siekiama atsižvelgti ne tik į skirtingų sistemos gedimų klasifikavimą, bet ir kaip apkrovos kaita veikia vibracijos signalus, bei kaip šią informaciją galima panaudoti diagnostikai, pritaikant klasifikavimo algoritmus gedimams atpažinti, siejant juos su mechaninės vibracijos duomenimis, gautais esant skirtingoms apkrovoms. Taip pat tarpusavyje bus lyginami skirtingi klasifikavimo metodai ir vertinamas jų klasifikavimo tikslumas bei gebėjimas atskirti skirtingas elektromechaninių sistemų būkles ir būsenas.

1.3. Signalų analizės metodai

Neapdoroti signalai laiko srityje dažnai yra kompleksiniai ir sunkiai interpretuojami tiesiogiai. Dėl šios priežasties siekiant efektyviai išgauti prasmingą informaciją apie įrenginio būseną ar nuspėti gedimus, būtina laiko srities signalus apdoroti. Tam naudojami signalo analizės metodai, kurie paverčia neapdorotus vibracijos duomenis lengviau interpretuojamu formatu. Dėl to galima paprasčiau identifikuoti unikalius požymius, svarbius variklio būsenai klasifikuoti.

1.3.1. Furjė transformacija

Laiko ir dažnio transformacijos yra matematinių operacijų klasė, kurioje atliekamas duomenų srautų apdorojimas, kad būtų galima rasti kiekvieno dažnio svarbą kiekvienu pradinio signalo laiko momentu. Viena paprasčiausių transformacijų yra Furjė transformacija. Šis algoritmas veikia išskaidant pradinį signalą į tiesinę skirtingų dažnių sinusinių bangų sumą. Kuo didesnė tam tikro dažnio amplitudė, tuo svarbesnis yra tas dažnis pradiniam signalui. Transformacijos rezultatas yra amplitudės priklausomybės nuo dažnio grafikas. Dėl jos naudojimo daugelyje skirtingų sričių, norint atlikti šią operaciją kuo greičiau, buvo sukurti greitosios Furjė transformacijos (angl. fast Fourier transform, FFT) algoritmai.

Bendruoju atveju bet kokios funkcijos Furjė transformacija f(x) arba amplitudžių seka x_n apskaičiuojama ir tolydžiuoju (1), ir diskrečiuoju (2) atveju [11]:

$$\hat{f}(\xi) = \int_{-\infty}^{\infty} f(x) e^{-2\pi i x \xi} dx; \quad (1)$$

$$X_k = \sum_{n=0}^{N-1} x_n e^{-i2\pi k \frac{n}{N}} \quad \mathrm{k} = 0, \ldots, \mathrm{N} - 1. \quad (2)$$

Šiose lygtyse f(x) yra transformuojama tolydinė funkcija, $f(\widehat{\xi})$ yra transformuota funkcija (kai ξ reiškia svyravimų dydį), x_n yra viena iš N duomenų taškų diskrečiosios sekos, o X_k – svyravimų dydis, nustatytas tos sekos k-ajame dažnių ruože. Nors diskrečioji forma paprastai yra naudingesnė realaus pasaulio duomenims, ji vis tiek reikalauja daug skaičiavimo išteklių. Dėl šios priežasties ir buvo sukurti greitosios Furjė transformacijos algoritmai [11].

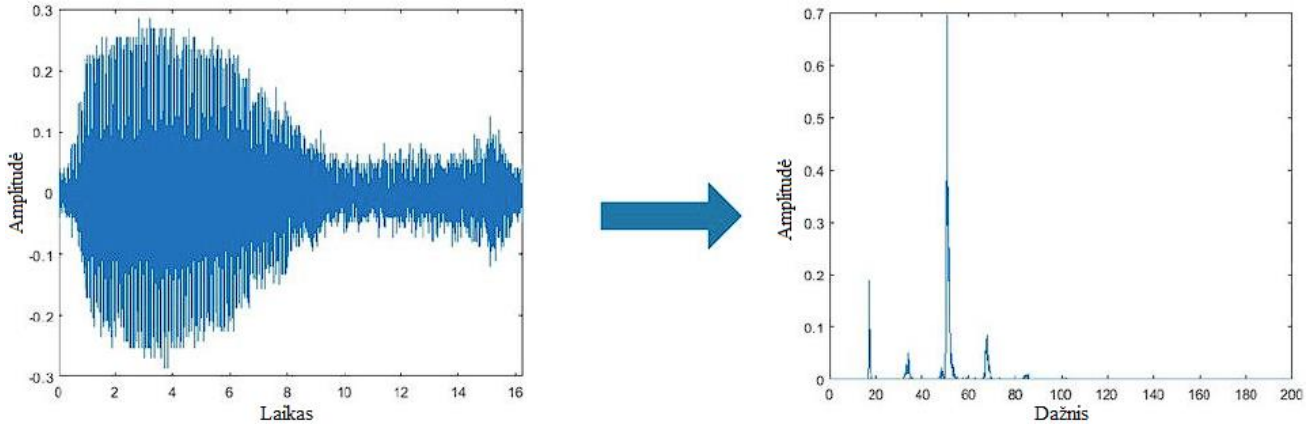

2 pav. Furjė transformacija [12]

1.3.2. Autokoreliacija

Autokoreliacijos funkcija yra svarbi diagnostinė priemonė analizuojant laiko eilutes laiko srityje. Autokoreliacijos diagramos, vadinamos korelogramomis, padeda geriau suprasti proceso raidą laike naudojant ryšio tarp duomenų verčių, kurias skiria tam tikras laiko žingsnių (angl. *lags*) skaičius, tikimybę. Korelogramoje autokoreliacijos koeficientai pavaizduoti vertikalioje ašyje, o atsilikimo reikšmės – horizontalioje ašyje.

Signalo x(t) autokoreliacijos funkcija yra sandaugos x(t)x(t+τ), kur τ yra laiko vėlinimas, vidutinė vertė. Formaliai autokoreliacijos funkcija Rx(τ) apibrėžiama taip [13]:

$$R_x(\tau) = E[x(t)x(t+\tau)] = \lim_{T \to \infty} \int_0^T x(t)x(t+\tau)\, dt. \quad (3)$$

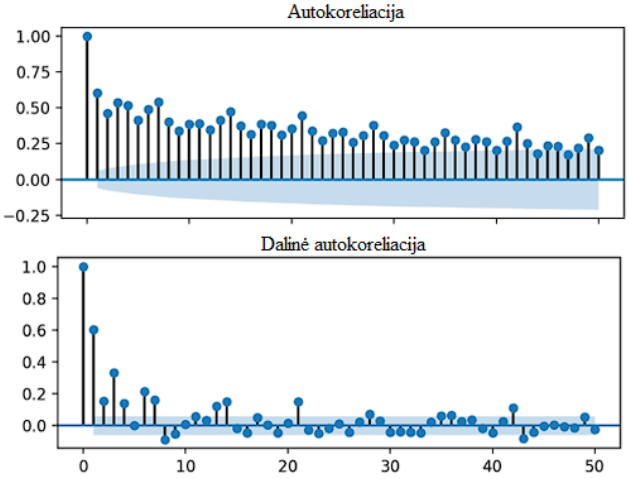

3 pav. Autokoreliacija [14]

1.3.3. Kepstro analizė

Kepstro funkcija padeda išryškinti pasikartojančius spektro komponentus, kad aiškiau matytųsi jų struktūra. Dėl to ją galima naudoti dekonvoliucijai, nes tampa lengviau atskirti signalo sudedamąsias dalis. Dėl šių savybių kepstro funkcija gali būti naudinga elektromechaninių sistemų veikimo būsenos diagnostikai. Atsiradus greitajai Furjė transformacijai, kepstras buvo iš naujo apibrėžtas kaip atvirkštinė Furjė transformacija kompleksinio spektro logaritmui, kuri vėliau pavadinta kompleksiniu kepstru. Tada kepstro analizė pradėta taikyti kalbos signalams apdoroti. Mechaninių sistemų diagnostikos srityje kepstro analizė iš pradžių naudota krumpliaračių gedimams diagnozuoti [15].

Pradinis kepstro apibrėžimas pateiktas lygtyje:

$$C_{1(\lambda)} = \left|\Gamma\{\log(P_{oo}(f))\}\right|^2; \quad (4)$$

kur $P_{oo}(f)$ yra galios spektras. Kepstras apibrėžiamas kaip galios logaritmo spektras. Kepstras gali būti skirstomas į realųjį ir kompleksinį, o realusis kepstras gali būti išvestas iš kompleksinio kepstro. Kompleksinio kepstro apibrėžimas pateiktas lygtyje:

$$C_2(\lambda) = ifft\{\ln(L(f))\} = ifft\{lnA_2(f) + j\phi(f)\}; \quad (5)$$

kur ifft yra atvirkštinė Furjė transformacija, λ yra laiko matas, vadinamas *quefrency*, o C2(λ) yra kepstras, kuris gaunamas iš Furjė transformacijos spektro ir atvirkštinės Furjė transformacijos logaritmo. L(f) yra Furjė transformacijos spektras, realioji dalis A2(f) yra L(f) amplitudė, o įsivaizduojamoji dalis ϕ (f) - fazė. Furjė pradinio signalo L(f) spektras parodytas lygtyje:

$$L(f) = fft\{x(t_1)\} = A_2(f)e^{j\phi(f)}; \quad (6)$$

kur x(t1) yra pradinė vibracijos signalo seka, fft yra Furjė transformacija. L(f) yra amplitudės ir fazės informacija. L(f) fazė nustatoma lygi 0 ir išvedama realiojo kepstro išraiška, kuri pavaizduota lygtyje:

$$C_{3(\lambda)} = i\,fft\{\ln(A_2(f))\} = i\,fft\{\ln|L(f)|\}; \quad (7)$$

Todėl realiojo kepstro esmė yra paimti kompleksinio kepstro Furjė transformacijos modulį ir po to atlikti kitus vėlesnius pertvarkymus [15].

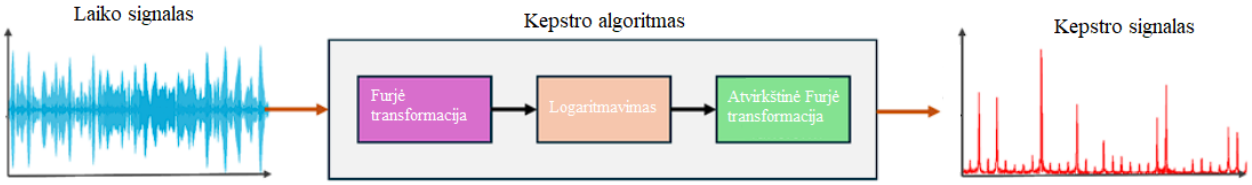

4 pav. Kepstro analizė [16]

1.3.4. Spektrogramos

Iš elektromechaninių sistemų darbo metu gaunami vibracijos signalai yra stochastiniai, nes juose yra gedimų informacija, moduliuota pagal kintamus sukimosi greičius ir aplinkos triukšmą. Gauto signalo dažninės charakteristikos yra tolydžios, o jo statistinės savybės laiko srityje kinta laikui bėgant. Stochastiniams signalams paprastai trūksta naudingos informacijos laiko arba dažnio srityse, tačiau jie turi naudingos informacijos per sujungtą vaizdavimą laiko ir dažnio (t, f) erdvėje.

Esant skirtingoms elektromechaninių sistemų darbo sąlygoms (įvairūs pavienių ir sudėtinių gedimų tipai ir įvairūs nusidėvėjimo lygiai esant kintamiems sukimosi greičiams), yra sudėtinga gauti prasmingą informaciją naudojant tradicinius signalų apdorojimo metodus. Tokiomis sąlygomis signalo spektras labai kinta amplitude ir dažniu. Dėl to sunku atpažinti elektromechaninių sistemų gedimus naudojant įprastus signalų apdorojimo metodus. Trumpalaikė Furjė transformacija (STFT) yra tinkama stochastinių signalų analizei ir sintezei, todėl yra taikoma signalų spektrogramoms sukurti. Spektrograma yra vizualinis signalų atvaizdavimas laiko ir dažnio srityse, naudojant vaizdo spalvų skalę, kad būtų parodyta dažnio amplitudė [17].

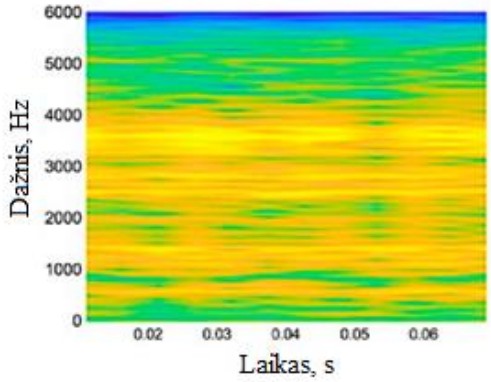

5 pav. Spektrograma [17]

1.3.5. Euklido atstumo klasifikatorius

Signalų klasifikavimo uždaviniuose objektai dažnai būna aprašyti požymiais, o jų panašumas vertinamas skaičiuojant atstumus tarp tų taškų požymių erdvėje. Viena iš dažniausiai naudojamų metrikų tokiuose uždaviniuose yra Euklido atstumas [18]:

$$d_{Euc} = \sqrt{\sum_{i=1}^{d} |P_i - Q_i|^2}; \quad (8)$$

Čia P ir Q – objektų požymių vektoriai;

d – požymių skaičius.

1.3.6. Fišerio tiesinis diskriminantas

Fišerio tiesinis diskriminantas yra metodas, kurio tikslas yra rasti vektorių, kuris maksimaliai padidintų projektuojamų duomenų klasių atskyrimą. Turint sužymėtų duomenų rinkinį, šis klasifikatorius gali rasti svorių rinkinį ir nubrėžti sprendimo ribą duomenų klasifikavimui į klases.
Vienas iš būdų pagerinti tiesinių klasifikavimo modelių veikimą yra matmenų mažinimas. Turint daugiadimensinį įvesties vektorių x, kuris yra projektuojamas į vienmatę erdvę naudojant linijinę projekciją:

$y = w^T x$;

Čia w – projekcijos svorių vektorius;

x – daugiadimensinis įvesties vektorius.

Jei nustatoma riba ties y ir klasifikuojama y ≥ -w kaip C1 klasė, o kitu atveju – kaip C2 klasė, gaunamas standartinis linijinis klasifikatorius. Projekcija į vieną dimensiją lemia didelį informacijos praradimą, o klasės, kurios yra gerai atskirtos pradinėje daugiadimensinėje erdvėje, gali stipriai persidengti vienmatėje dimensijoje. Tačiau koreguojant svorių vektorių w komponentus, galima pasirinkti projekciją, kuri maksimaliai padidina klasių atskyrimą. Dviejų klasių duomenų rinkinyje C_1 klasėje yra N_1 taškų, o C_2 klasėje yra N_2 taškų. Šių dviejų klasių vidurkiai žymimi m_1 ir m_2 [19].
Fišerio pasiūlyta idėja yra maksimizuoti funkciją, kuri suteiktų didelį atskyrimą tarp projektuojamų klasių vidurkių, taip pat suteikdama mažą dispersiją kiekvienoje klasėje, taip sumažinant klasių persidengimą. Fišerio kriterijus apibrėžiamas kaip dispersijos tarp klasių ir dispersijos klasės viduje santykis ir yra pateikiamas taip [19]:

$$J(w) = \frac{(m_2 - m_1)^2}{s_1^2 + s_2^2}; \quad (9)$$

Čia s_1^2 ir s_2^2 – projektuotų klasių dispersijos.

Šis kriterijus gali būti perrašytas naudojant tarpklasinės ir bendros klasės kovariacijos matricas. Tarpklasinė kovariacijos matrica apibrėžia klasių vidurkių skirtumą, o vidinė sklaidos matrica apibūdina duomenų išsibarstymą klasės viduje. Tokiu atveju optimalus projekcijos vektorius yra proporcingas [19]:

$$w \propto S_W^{-1}(m_2 - m_1); \quad (10)$$

Čia S_W^{-1} – bendroji klasių vidinės kovariacijos matrica;

m_1 ir m_2 – klasių vidurkių vektoriai.

Šios išraiškos rezultatas yra žinomas kaip Fišerio tiesinis diskriminantas. Projektuoti duomenys gali būti naudojami diskriminantui sukurti, pasirenkant slenkstį y_0, kad naujas taškas būtų klasifikuojamas kaip priklausantis C_1, jei $y(x) \geq y_0$, o kitu atveju – kaip priklausantis C_2 [19].

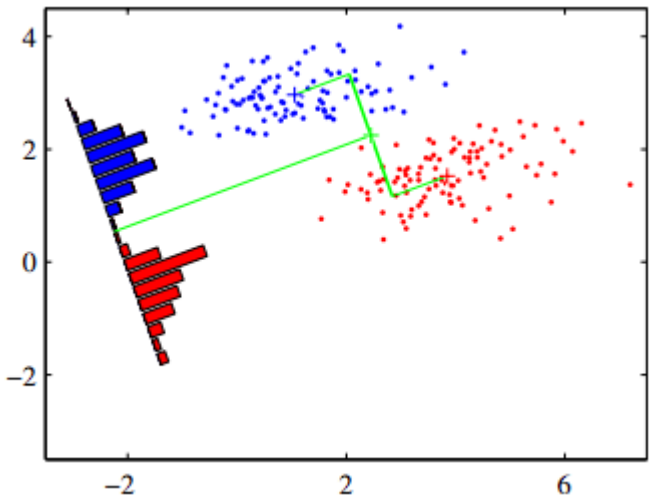

6 pav. Fišerio tiesinis diskriminantas [19]

1.3.7. Pagrindinių komponenčių analizė

Pagrindinių komponenčių analizė (*angl. Principal Component Analysis, PCA*) yra laikoma vienu svarbiausių taikomosios tiesinės algebros metodų. PCA plačiai naudojama įvairiose srityse signalų analizei, nes tai paprastas, neparametrinis metodas svarbiai informacijai išgauti iš painių duomenų rinkinių. PCA supaprastina sudėtingą duomenų rinkinį, kad būtų atskleista paslėpta duomenų struktūra [20].

PCA tikslas yra rasti tokią duomenų reprezentaciją, kad būtų galima aiškiau aprašyti triukšmingą duomenų rinkinį. Tai reikalinga tam, kad būtų pašalintas triukšmas ir lengviau būtų atrasti pagrindinę duomenų struktūrą. Svarbių dimensijų nustatymas padeda atskirti, kurie signalo komponentai yra svarbūs, kurie yra pertekliniai, o kurie susiję tik su triukšmu [20].

Naudojant PCA siekiama nustatyti, ar duomenų rinkinį galima efektyviau pavaizduoti kitoje koordinačių sistemoje, kuri suformuota kaip pradinių vektorių tiesinė kombinacija. Metodas remiasi pagrindine tiesiškumo prielaida, kuri riboja transformaciją į pradinių kintamųjų tiesines kombinacijas. Ši prielaida riboja galimų transformacijų skaičių, tačiau suteikia matematiškai suprantamą sistemą duomenims transformuoti į naują koordinačių sistemą. Atlikus tokią transformaciją galima duomenis pateikti taip, kad būtų išryškintos svarbiausios jų struktūros kryptys [20].

Darant prielaidą apie tiesiškumą, problema supaprastėja iki tinkamos koordinačių sistemos pakeitimo paieškos. Šios transformacijos eilučių vektoriai tampa pagrindiniais duomenų komponentais. Šie vektoriai apibrėžia naują koordinačių sistemą, kurioje duomenys gali būti pateikti forma, kad būtų išryškintos svarbiausios duomenų erdvės kryptys [20].

Pagrindinis analizės tikslas yra nustatyti, ką reiškia „geriausiai išreikšti“ duomenis. Tiesinėje sistemoje duomenų iškraipymai gali atsirasti dėl triukšmo ar perteklinės informacijos. Triukšmas yra matavimo paklaidos, kurios užgožia pagrindinę duomenų struktūrą, o perteklius atsiranda, kai keli kintamieji perteikia tą pačią arba labai panašią informaciją [20].

Praktiškai daroma prielaida, kad kryptys su didžiausiomis dispersijomis matavimo erdvėje turi reikšmingiausią sistemos informaciją. Todėl PCA ieško krypčių, kuriomis projektuojamų duomenų dispersija yra maksimali. Šios kryptys atitinka pagrindinius duomenų komponentus ir leidžia efektyviai atvaizduoti pagrindinę duomenų struktūrą [20].

Kovariacijos matrica fiksuoja koreliacijas tarp visų galimų matavimų porų. Įstrižainės elementai atspindi atskirų matavimo tipų dispersiją, o ne įstrižainės elementai atspindi kovariaciją tarp matavimo tipų. Didelės ne įstrižainės vertės rodo didelį perteklių tarp matavimų, o mažos vertės rodo mažą perteklių [20].

Taigi, PCA tikslą galima apibendrinti kaip perteklinės informacijos sumažinimą, tuo pačiu maksimaliai padidinant signalo dispersiją. Optimizuotoje kovariacijos matricoje ne įstrižainės elementai yra lygūs nuliui, o tai reiškia, kad transformuoti kintamieji yra nekoreliuojami. Šiuo atveju kovariacijos matrica tampa įstrižaine, o gautos kryptys atitinka pagrindinius komponentus [20].

1.4. Klasifikavimo metodai

Nepaisant pažangių dažninės signalų analizės metodų, dažnai vien tik jų nepakanka analizuojant variklio darbą prie skirtingų apkrovų. Norint panaudoti surinktą vibracijos signalų informaciją, svarbu ne tik surinkti skirtingoms įrenginio būsenoms būdingus požymius, bet ir priskirti juos tam tikroms kategorijoms. Tam reikalingas signalų klasifikavimas – procesas, kurio metu signalų analizės metu gauti požymiai naudojami skirtingų būsenų atpažinimui. Naudojant klasifikavimo metodus galima atskirti, kada variklis ar įrengimas veikia įprastinėje būsenoje, o kada yra gedimas. Tai galima panaudoti planuojant profilaktinius įrangos priežiūros darbus. Klasifikuojant duomenis taip pat galima ne tik atpažinti gedimą, bet ir priskirti jį tam tikrai konkrečiai kategorijai. Tai svarbu, norint atskirti, kurie gedimai yra kritiniai, kurie reikalauja greito techninio aptarnavimo, nuo tokių gedimų, kurie nėra pavojingi veikimui ir gali būti aptarnauti po tam tikro laiko. Skirtingi klasifikavimo metodai turi savo pranašumų ir trūkumų, priklausomai nuo signalų sudėtingumo ir analizės tikslų. Populiariausi metodai, naudojami gedimų diagnostikoje yra atraminių vektorių mašinos (angl. *Support Vector Machine, SVM*), k-artimiausių kaimynų (angl. *K-Nearest Neighbors, KNN*), konvoliuciniai neuroniniai tinklai (angl. Convolutional Neural Networks, *CNN*), ilgalaikės-trumpalaikės atminties tinklai (angl. *Long Short-Term Memory, LSTM*) ir atsitiktinio miško (angl. *Random Forest, RF*) algoritmai [21].

1.4.1. SVM

Vienas iš dažniausiai naudojamų klasifikavimo metodų elektros variklių komponentų būklės stebėjime ir gedimų diagnostikoje yra atraminių vektorių mašinos (angl. *Support Vector Machine, SVM*) metodas. Šis metodas naudoja prižiūrimus mašininio mokymosi modelius kartu su statistiniais ir prognozavimo metodais regresinei analizei ir klasifikavimui. Jis dažniausiai naudojamas sprendžiant didelių duomenų ir daugialypės terpės klasifikavimo problemas šiuolaikinėje pramoninėje aplinkoje. Šis metodas gali būti apmokomas su palyginti nedideliu kiekiu duomenų. Hiperplokštuma yra sprendimo riba, tiesiškai klasifikuojanti duomenis; atraminiai vektoriai - tai duomenys, esantys arčiausiai šios plokštumos [22].

SVM teorinis pagrindas remiasi optimalaus sprendimo paviršiaus paieška. Dvejetainės klasifikacijos atveju siekiama rasti tokią ribą, kuri geriausiai atskirtų skirtingų klasių duomenis su kuo mažesniu klaidų skaičiumi [22]:

$$min_{w,b,\xi}\frac{1}{2}|w|^2 + C\sum_{i=1}^{N}\xi_i; \quad (11)$$

Čia w – sprendimo plokštumos svorių vektorius;

b – poslinkis;

C – reguliavimo parametras;

ξi – leidžiamos klasifikavimo klaidos dydį nusakantys kintamieji.

Hiperplokštuma SVM išreiškiama formule:

$$d(x) = wx_i + b; \quad (12)$$

kur x_i yra įvesties duomenys, w yra svorio vektorius, vertikalus hiperplokštumai, o b yra svorio vektorius, hiperplokštumos poslinkis. Sprendimo ribos plotis apskaičiuojamas pagal šią lygtį [22]:

$$M = \frac{2}{|w|} + C\sum_{i=1}^{n}\xi_i; \quad (13)$$

Čia M yra sprendimo ribos plotis, ξi yra laisvas kintamasis, pridedamas siekiant pakoreguoti neteisingo klasifikavimo lygį, kai duomenų negalima tiesiškai suklasifikuoti SVM, o C yra naudotojo nustatytas parametras. Kuo didesnė C reikšmė, tuo mažesnis leistinas klaidingo klasifikavimo laipsnis [22].

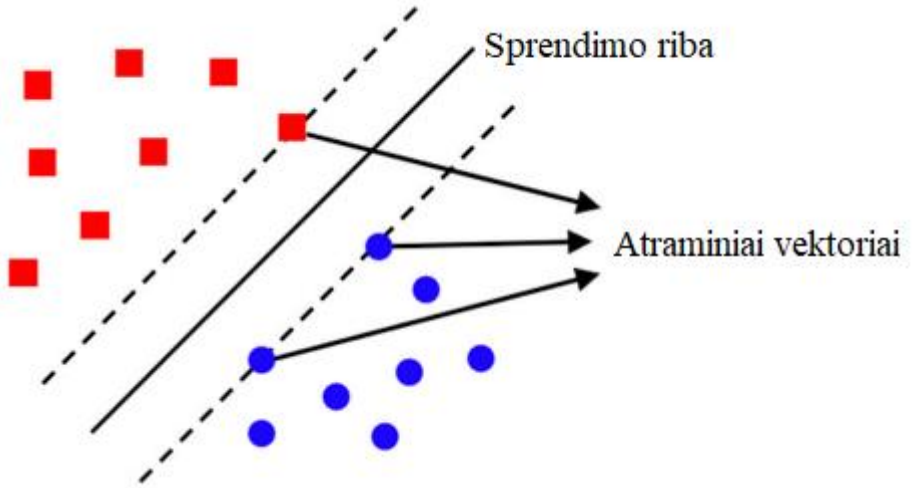

7 pav. SVM architektūra [22]

1.4.2. KNN

Kitas svarbus mašininio mokymosi metodas, naudojamas klasifikavimui, yra k-artimiausių kaimynų (*angl. K-Nearest Neighbors, KNN*) algoritmas. Tai yra neparametrinis „tingus“ mokymosi algoritmas, naudojamas signalų duomenų taškams klasifikuoti pagal „k“ artimiausių mokymo pavyzdžių požymių erdvėje. Tai reiškia, kad jis tik saugo mokymo duomenų rinkinį, o ne pereina mokymo etapą. Visi skaičiavimai atliekami klasifikavimo metu. Jis naudoja duomenų taškų artumą prognozėms arba klasifikacijoms atlikti. KNN yra ypač veiksmingas tokioms užduotims, kaip pereinamųjų elektros

energijos trikdžių klasifikavimas, remiantis iš duomenų išskirtomis signalo savybėmis. KNN algoritme mokomųjų pavyzdžių pozicijos išlieka, o kai įvedamas naujas duomenų taškas, atstumai tarp šio duomenų taško ir pavyzdžių yra fiksuoti. Apskaičiuojami atstumai tarp visų mokymo pavyzdžių. Vėliau išrenkami K taškai, kurių atstumai yra mažiausi. Taškai su mažiausiais atstumais yra nustatomi mokymo aibėje. Nagrinėdamas šiuos atstumus, algoritmas atrenka arčiausiai naujo duomenų pavyzdžio esančius kaimynus [23].

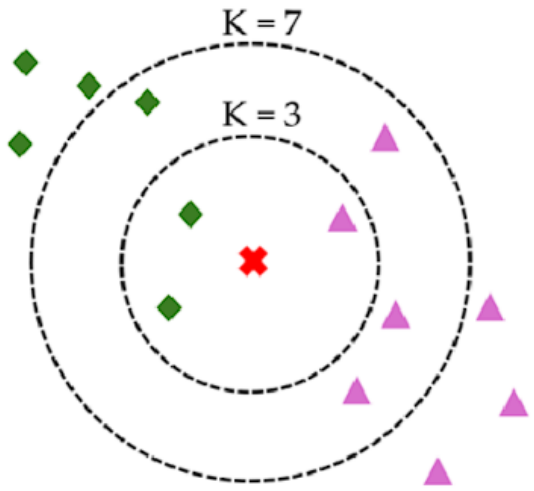

8 pav. KNN algoritmo pavyzdys [24]

1.4.3. CNN

Konvoliuciniai neuroniniai tinklai (*angl. Convolutional Neural networks, CNN*) yra tiesioginio sklidimo (angl. feedforward) dvimačiai neuroniniai tinklai. Konvoliuciniai sluoksniai iš esmės modeliuoja žmogaus smegenų regos žievės ląsteles. CNN siekiama imituoti žinduolių regos sistemą, kuri gali tiksliai atpažinti tam tikrus modelius ir struktūras, pavyzdžiui, objektus regimajame peizaže. Pastaruoju metu CNN tapo standartu „gilaus mokymosi“ užduotims, tokioms kaip objektų atpažinimas dideliuose vaizduose, ir pasiekė pažangiausią lygį rezultatų su dideliu našumu. Adaptyvieji CNN taip pat gali būti sėkmingai naudojami apdorojant vienmačius signalus anomalijų nustatymui, ir pasižymi gerais rezultatais ir tikslumo, ir greičio požiūriu. Pagrindinė to priežastis yra ta, kad mokymo etape CNN konvoliuciniai sluoksniai iš esmės optimizuojami taip, kad išgautų labai diskriminacinius požymius, naudojant didelį vienmačių filtrų branduolių rinkinį. Todėl, tinkamai apmokius tam tikram duomenų rinkinį, galima optimizuoti požymių išskyrimą ir klasifikavimo užduotis pagal sprendžiamą problemą. Paprastai optimizavimo metodas yra gradientinio nusileidimo metodu su atsitiktine iniciacija, vadinamasis klaidos atgalinio sklidimo metodas, kuriuo iteratyviai ieškoma optimalaus tinklo parametrų rinkinio [25].

Ince, Kiranyaz, Eren, Askar ir Gabbouj (2017) savo straipsnyje „Real-Time Motor Fault Detection by 1-D Convolutional Neural Networks“ tyrė 1D CNN taikymą variklių gedimų aptikimui realiuoju laiku. Autorių siūlomas metodas nereikalauja jokio transformavimo, požymių išskyrimo ir tolesnio apdorojimo. Jis gali tiesiogiai naudoti neapdorotus duomenis, t. y. variklio srovės signalą, ir nustatyti anomalijas. Tai leidžia padidinti sistemos efektyvumą ir greičio, ir aparatūrinės įrangos naudojimo atžvilgiu, todėl toks metodas tinka variklio būklės stebėjimui realiu laiku [25].

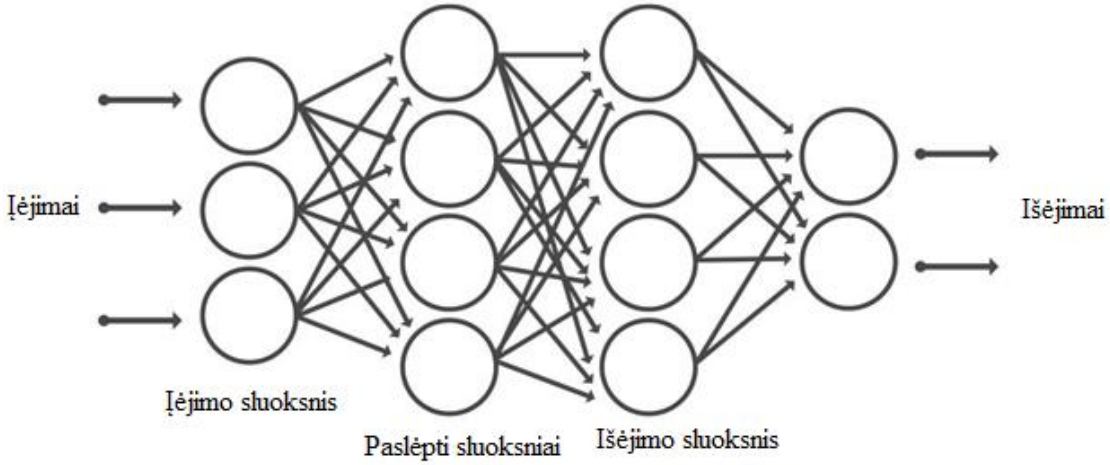

9 pav. CNN [26]

1.4.4. LSTM

Ilgalaikės-trumpalaikės atminties tinklas (angl. *Long Short-Term Memory*) yra pasikartojančio neuroninio tinklo tipas, sukurtas nuoseklių duomenų apdorojimo užduotims signalų apdorojimo srityje spręsti. LSTM yra ypač veiksmingas fiksuojant ilgalaikes priklausomybes ir laiko ryšius signaluose. Jis sukurtas siekiant išspręsti tradiciniuose RNN esančią nykstančio gradiento problemą [27].

Chen ir kt. [27] guolių gedimų diagnostikos tyrime buvo pasiūlė naują metodą, kuris pagrįstas kelių mastelių CNN ir LSTM modeliu, sudarytu iš dviejų modulių. Pirmąjį modulį sudarė du vienmačiai CNN su skirtingo dydžio ir gylio branduoliais, kurie vienu metu buvo taikomi neapdorotiems signalams, kad būtų išgauti požymiai iš skirtingų dažnių sričių. Tada iš CNN gauti požymių vektoriai buvo sujungti naudojant elementų sandaugas. Antrąjį modulį, vadinamą klasifikatoriumi, sudarė hierarchinis LSTM ir visiškai sujungtas sluoksnis, skirtas galutinei klasifikacijai atlikti. Straipsnyje pateiktas kelių mastelių CNN ir LSTM modulis pasiekė 98,46 % klasifikavimo tikslumą.

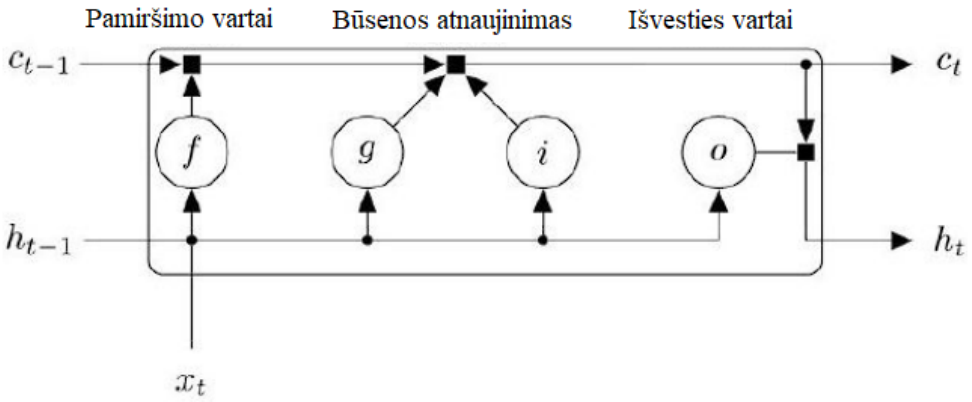

10 pav. LSTM architektūra [28]

1.4.5. Random Forest

Atsitiktinis miškas (angl. *Random Forest, RF*) – tai „ansamblinio mokymosi“ (angl. *Ensemble learning*) metodas, jungiantis kelis sprendimų medžius, siekiant padidinti prognozių tikslumą ir patikimumą. Kiekvienas sprendimų medis individualiai analizuoja signalus, išskiria požymius ir atlieka prognozes remdamasis pateiktais įvesties duomenimis. Galutinė klasifikavimo išvada gaunama sujungiant visų atskirų medžių prognozes, dažniausiai taikant balsavimo (klasifikavimo atveju) arba vidurkio (regresijos atveju) metodą. Toma ir kt [29] analizavo genetinio algoritmo parametrų optimizavimą ir trijų skirtingų klasifikatorių – artimiausių kaimynų, sprendimų medžių ir RF – taikymą guolių gedimų diagnostikai indukciniuose varikliuose. Kiekvienas RF modelio medis buvo apmokytas naudojant atsitiktinai parinktą požymių ir pavyzdžių poaibį iš mokymo duomenų. Atskiri medžiai pateikė prognozes, kurių galutinė klasifikacija buvo nustatoma balsavimo būdu pagal dažniausiai pasitaikančią klasę, o regresijos atveju – apskaičiuojant vidutinę vertę. Tokiu bendradarbiavimo principu paremtu ansambliniu metodu buvo siekiama sumažinti permokymo (angl. *overfitting*) riziką, dažnai pasitaikančią taikant pavienius sprendimų medžius. Eksperimentiniai rezultatai parodė, kad kartu su genetiniu algoritmu RF modelis pasiekė 99,7 % klasifikavimo tikslumą, sprendimų medžių modelis – 98 %, o KNN algoritmas – 97 % [29].

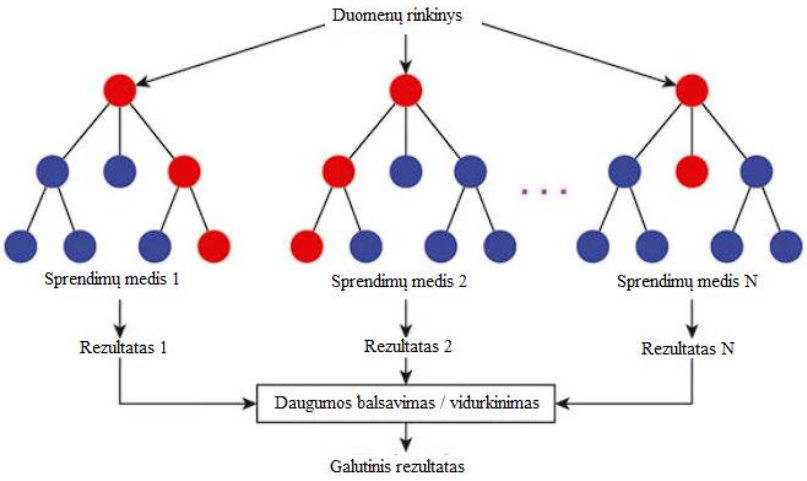

11 pav. RF algoritmo schema [30]

2. Metodologinė dalis

Atlikus literatūros analizę matoma, kad elektromechaninių sistemų vibracijos signalai gali suteikti daug informacijos apie elektromechaninių sistemų techninę būklę. Vibracijos signalų analizė gali būti pritaikyta ne tik nustatyti gedimams, bet ir skirtingų darbo režimų, apkrovos sąlygų ar kitų sistemos būsenų stebėsenai. Šią informaciją galima pritaikyti planuojant techninę priežiūrą ir vertinant sistemos eksploatavimo sąlygas, nes pagal vibracijos signalo pokyčius galima spręsti, ar sistema veikia įprastomis sąlygomis, ar kurie nors atskiri jos komponentai tam tikrais laiko tarpais patiria didesnes apkrovas.

Atlikus literatūros analizę paaiškėjo, kad literatūroje dažniausiai nagrinėjami konkretūs signalų apdorojimo metodai arba pavieniai klasifikavimo algoritmai, skirti tam tikroms būsenoms ar gedimams atpažinti. Daugelyje darbų siekiama padidinti vieno konkretaus pasirinkto metodo tikslumą, pritaikant jo parametrus konkrečiam duomenų rinkiniui. Tačiau skirtinguose tyrimuose signalai dažnai būna atvaizduojami nevienodai, taip pat skiriasi požymių išskyrimo metodai ir klasifikatoriai, todėl jų rezultatus ne visada galima tiesiogiai palyginti. Be to, dažniau nagrinėjamas gedimų atpažinimas, o vibracijos signalų pokyčiai, susiję su skirtingomis eksploatacijos sąlygomis, analizuojami rečiau.

Dėl to šiame darbe buvo pasirinkta daugiau dėmesio skirti ne vieno klasifikavimo metodo optimizavimui, o skirtingų signalų analizės ir klasifikavimo metodų palyginimui. Šio tyrimo tikslas yra įvertinti, kaip skirtingi vibracijos signalų atvaizdavimo ir klasifikavimo metodai gali atskirti skirtingas sistemos būsenas. Tai svarbu praktikoje, nes vibracijos analizę galima naudoti ne tik diagnostikai, bet ir darbo režimų ar netipinių sistemos būsenų nustatymui.

Šiame skyriuje aprašomi atskiri tyrime taikyti metodikos etapai: vibracijos signalų paruošimas, jų segmentavimas, skirtingų dažninės analizės metodų ir klasifikavimo algoritmų palyginimo metodologija. Atlikus literatūros analizę matoma, kad dažninei signalų analizei dažniausiai naudojami spektro, kepstro, autokoreliacijos metodai, o klasifikavimo uždaviniuose plačiai taikomi CNN, SVM, KNN ir RF metodai. Dėl to šiame tyrime buvo pasirinkta tarpusavyje palyginti šiuos metodus.

2.1. Duomenų bazės

Toliau aprašomi tyrime naudoti duomenų rinkiniai – CWRU ir MaFaulDa duomenų bazės bei laboratorijoje atliktas eksperimentas, kurio metu matuoti variklio vibracijos signalai, keičiant jo apkrovą.

2.1.1. CWRU guolių duomenų bazė

Viena iš tyrime naudojamų duomenų bazių yra Case Western Reserve Universiteto (CWRU) guolių duomenų bazė. Ši duomenų bazė pasirinkta todėl, kad kiekvienam eksperimentui buvo dokumentuotos faktinės variklio bandymo sąlygos ir guolių gedimų būsena. Eksperimentai buvo atlikti naudojant 2 AG variklį, o pagreičio duomenys buvo matuojami šalia variklio guolių ir toliau nuo jų. Variklio guoliuose elektroerozinio apdirbimo (angl. electro-discharge machining, EDM) metodu buvo sukelti defektai. Vidinio žiedo riedėjimo takelyje, riedėjimo kūne (rutulyje) ir išorinio žiedo riedėjimo takelyje buvo sukelti defektai, kurių skersmuo buvo nuo 0,007 colio iki 0,04 colio. Defektuoti guoliai buvo vėl sumontuoti bandomajame variklyje, o vibracijos duomenys buvo

registruojami esant 0–3 arklio galių variklio apkrovoms (variklio greitis nuo 1797 iki 1720 aps./min.) [31].

Bandymų stendą (12 pav.) sudaro 2 AG variklis, sukimo momento keitiklis / enkoderis, dinamometras ir valdymo elektronika. Bandomieji guoliai laiko variklio veleną. Defektai bandymų guoliuose buvo sukelti naudojant elektroerozinį apdirbimą, defektų skersmuo buvo 0,007; 0,014; 0,021; 0,028 ir 0,04 colio [31].

Vibracijos duomenys buvo renkami naudojant akselerometrus, kurie buvo pritvirtinti prie korpuso magnetais. Akselerometrai buvo išdėstyti 12 valandos padėtyje pavaros ir ventiliatoriaus variklio korpuso galuose. Vibracijos signalai buvo renkami naudojant 16 kanalų DAT (angl. Digital Audio Tape) įrašymo įrenginį ir vėliau apdorojami Matlab aplinkoje. Visi duomenų failai yra Matlab (*.mat) formatu. Duomenys buvo renkami guoliams be defektų ir defektuotiems guoliams pavaros gale ir ventiliatoriaus gale. Greičio ir galios duomenys buvo renkami naudojant sukimo momento keitiklį/enkoderį ir registruojami rankiniu būdu [31].

Išorinio žiedo riedėjimo takelio defektai yra stacionarūs, todėl defekto vieta guolio apkrovos zonos atžvilgiu turi tiesioginės įtakos variklio / guolių sistemos vibracijos reakcijai. Apkrovos zona buvo centruota 6 valandos padėtyje. Siekiant kiekybiškai įvertinti šį poveikį, eksperimentai buvo atlikti su ventiliatoriaus ir pavaros pusės guoliais, kurių išorinio žiedo riedėjimo takelio defektai buvo 3 valandos padėtyje (statmenai apkrovos zonai), 6 valandos padėtyje (tiesiogiai apkrovos zonoje) ir 12 valandos padėtyje (priešingoje pusėje, nei apkrovos zona) [31].

Duomenų bazė buvo nesubalansuota, skirtingose klasėse buvo nevienodas signalų skaičius. Iš viso yra 64 skirtingi atvejai.

Guolių būsenos klasės, išskirtos šioje duomenų bazėje:
– normalios būklės (be defektų) – 4 atvejai;
– vidinio žiedo riedėjimo takelio defektai – 16 atvejų;
– riedėjimo kūnų defektai – 16 atvejų;
– išorinio žiedo riedėjimo takelio defektai – 28 atvejai.

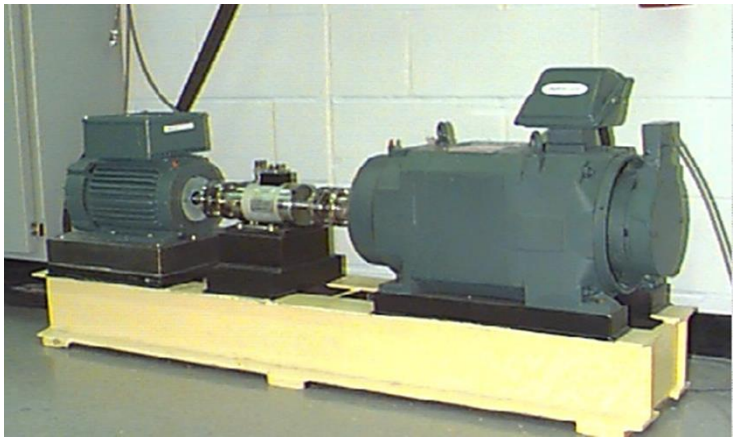

12 pav. CWRU bandymų stendas [31]

2.1.2. MaFaulDa mašinų gedimų simuliatoriaus duomenų bazė

„MaFaulDa“ (Machinery Fault Database) duomenų bazę sudaro daugiamatės laiko eilutės, gautos jutikliais, esančiais „SpectraQuest“ mašinų gedimų simuliatoriaus lygiavimo ir balansavimo vibracijos treniruoklyje (angl. alignment-balance vibration trainer, ABVT). Ši įranga imituoja elektros variklių su dviem veleno atraminiais guoliais dinamiką ir leidžia tirti kelis gedimus, tokius kaip masės disbalansas, horizontalios ir vertikalios ašių nesutapimai ir guolių defektai. Sistema buvo stebima dviem skirtingais jutiklių rinkiniais (po vieną kiekvienam guoliui) iš trijų akselerometrų (ašinės, radialinės ir tangentinės kryptimis), tachometro (sistemos sukimosi greičiui matuoti) ir mikrofono (garsui užfiksuoti sistemos veikimo metu). Signalo gavimo procedūros metu gedimų simuliatoriuje buvo sukelti įvairūs gedimai:

- Normalus veikimas: ši klasė apibūdina sistemą, veikiančią normaliomis sąlygomis be jokių gedimų. Ją sudaro 49 skirtingi atvejai, kurių kiekvienas turi fiksuotą sukimosi greitį diapazone nuo 737 aps./min. iki 3686 aps./min.
- Disbalansas: siekiant imituoti skirtingus disbalanso laipsnius, prie rotoriaus buvo prijungtos skirtingų verčių apkrovos: 6 g, 10 g, 15 g, 20 g, 25 g, 30 g ir 35 g. Kiekvienai apkrovos vertei, mažesnei nei 30 g, buvo taikomas tas pats sukimosi dažnis, kuris buvo naudojamas įprasto veikimo atveju. Tačiau esant 30 g ar didesnėms apkrovoms, dėl susidariusios vibracijos sistemai neįmanoma pasiekti sukimosi dažnių, viršijančių 3300 aps./min., todėl šiais atvejais skirtingų sukimosi dažnių skaičius apribojamas iki tik 44. Todėl duomenų bazėje iš viso yra 333 skirtingi šios klasės atvejai.
- Horizontalus ašies nesutapimas: šio tipo gedimas buvo sukeltas horizontaliai pastumiant variklio veleną 0,5 mm, 1,0 mm, 1,5 mm ir 2,0 mm. Naudojant tą patį sukimosi dažnio diapazoną, kaip ir įprasto veikimo metu kiekvienam horizontaliam poslinkiui, šiai klasei iš viso buvo surinkti 197 skirtingi atvejai.
- Vertikalus ašies nesutapimas: šis gedimas buvo sukeltas MFS variklio veleną vertikaliai pastumiant 0,51 mm, 0,63 mm, 1,27 mm, 1,4 mm, 1,78 mm ir 1,9 mm. Naudojant tą patį sukimosi dažnio diapazoną, kaip ir įprasto veikimo metu, kiekvienam vertikaliam poslinkiui, šiai gedimų klasei iš viso buvo surinktas 301 skirtingas atvejis.
- Guolių gedimai: riedėjimo guoliai, kaip vienas sudėtingiausių mašinos elementų, yra labiausiai jautrūs gedimams. ABVT gamintojas pateikė tris defektinius guolius, kurių kiekvienas turėjo atskirą defektinį elementą (išorinis takelis, riedėjimo elementai ir vidinis takelis), kurie buvo po vieną išdėstyti dviejose skirtingose vietose MFS eksperimentiniame stende: tarp rotoriaus ir variklio arba išorinėje padėtyje, kai rotorius yra tarp guolio ir variklio. Guolių gedimai praktiškai nepastebimi, kai nėra disbalanso. Taigi, siekiant sukelti aptinkamą efektą, buvo pridėti trys 6 g, 10 g ir 20 g masės objektai, kai sukimosi dažniai buvo skirtingi, kaip ir anksčiau, todėl iš viso buvo 558 atvejai, kai guolis tarp rotoriaus ir variklio ir 513 atvejai, kai rotorius yra tarp guolio ir variklio.

Duomenų bazė buvo nesubalansuota, skirtingose klasėse buvo nevienodas signalų skaičius. Sudėjus visas aukščiau aprašytas veikimo sąlygas, „MaFaulDa“ duomenų bazėje iš viso yra 1951 skirtingas atvejis, kurių kiekvieną apibūdina 8 signalai, gauti 50 kHz dažniu per 5 s laiko intervalą [32].

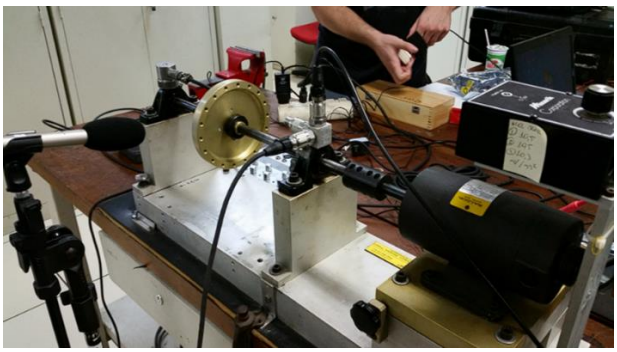

13 pav. MaFaulDa bandymų stendas [32]

2.1.3. Laboratorijos eksperimentas

Dar vienas duomenų rinkinys, naudotas tyrime, buvo gautas eksperimento metu naudojant stendą Kauno Technologijos Universiteto Automatikos katedros Elektros mašinų valdymo laboratorijoje. Stendas susideda iš valdymo bloko, įtampos šaltinio, apkrovimo įrenginio ir bandomojo variklio. Bandymo metu buvo keičiama apkrovimo įrenginio sudaroma apkrova bandomajam varikliui. Nustatyti 5 skirtingi apkrovos lygiai. Prie kiekvienos apkrovos išmatuoti bandomojo variklio vibracijos signalai. Duomenų rinkinyje iš viso yra 105 signalai (po 21 signalą kiekvienai apkrovai). Vieno signalo trukmė 0,3125s.

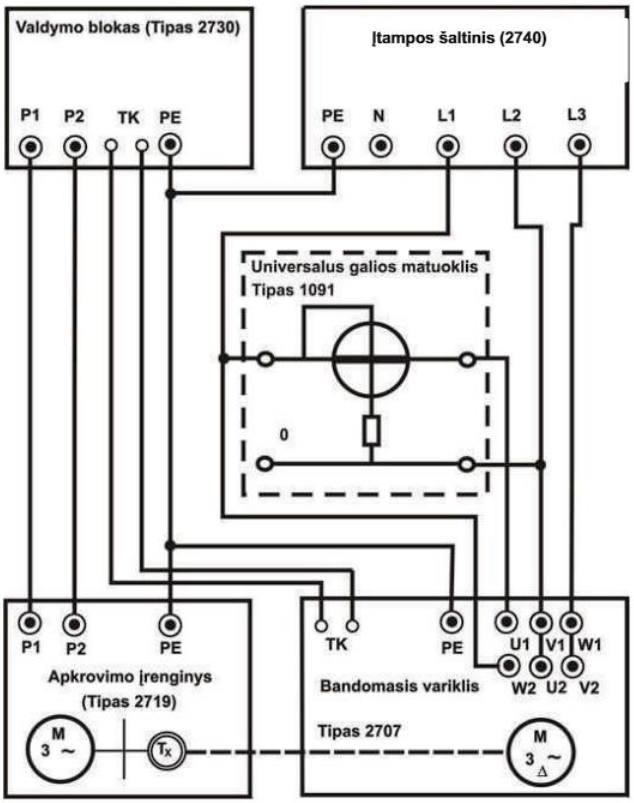

14 pav. Laboratorijos stendo schema [33]

15 pav. Laboratorijos stendas

2.2. Matavimo įranga

Šiame tyrime, siekiant tiksliai ir patikimai surinkti elektros variklio vibracijos duomenis, buvo pasirinkta naudoti pjezoelektrinį jutiklį. Šis pasirinkimas grindžiamas pjezoelektrinių jutiklių fundamentaliomis savybėmis ir jų tinkamumu dinaminei vibracijos analizei.

Pjezoelektrinių jutiklių veikimo principas remiasi pjezoelektriniu efektu – reiškiniu, kai tam tikros medžiagos, veikiamos mechaninės deformacijos (spaudimo, tempimo ar šlyties), generuoja elektrinį krūvį, kuris yra proporcingas veikiančios jėgos dydžiui. Kai pjezoelektrinio jutiklio korpusas yra veikiamas vibracijos, prie pjezoelektrinio elemento pritvirtinta masė veikiama inercijos sukelia jėgą, kuri deformuoja pjezoelektrinį kristalą. Ši deformacija generuoja elektrinį krūvį, kuris yra tiesiogiai proporcingas matuojamo objekto vibracijos pagreičiui [34]. Dėl to pjezoelektriniai jutikliai gali efektyviai paversti mechaninę vibracijos energiją į išmatuojamą elektrinį signalą.

Šiam tyrimui pasirinktas IEPE (angl. *Integrated Electronics Piezo-Electric*) tipo RS PRO jutiklis. IEPE tipo jutikliai turi integruotą signalo apdorojimo grandinę. Šis vidinis stiprintuvas paverčia aukšto impedanso krūvio signalą, generuojamą pjezoelektrinio elemento, į žemo impedanso įtampos signalą [35]. Šis konvertavimas yra itin svarbus, nes žemo impedanso signalas yra daug atsparesnis elektromagnetiniams trikdžiams ir gali būti patikimai perduodamas iki duomenų surinkimo sistemos, neprarandant signalo kokybės. Tai palengvina eksperimentinės sistemos įrengimą ir užtikrina patikimesnį duomenų perdavimą, kas yra itin svarbu atliekant tyrimus laboratorinėmis sąlygomis.

Pasirinkto jutiklio didžiausi privalumai yra aukštas jautrumas (100 mV/g esant 160Hz dažniui) ir platus dažnių diapazonas nuo 1Hz iki 10kHz ± 1dB. Platus dažnių diapazonas svarbus stebint ir diagnozuojant elektromechanines sistemas, nes galima matuoti ir žemo ir aukšto dažnio vibracijos signalus. Jutiklio amplitudės netiesiškumas ± 1 %, o skersinis jautrumas neviršija 5 % [36]. Tai užtikrina pakankamai aukštą matavimų tikslumą.

1 lentelė. Jutiklio techninės charakteristikos [36]

Gamintojas	RS PRO
Modelis	277-7920
Matavimo diapazonas	±80 g

Jautrumas	100 mV/g (160 Hz)
Netiesiškumas	±1 %
Dažnių diapazonas	1Hz–10 kHz ±1dB
Skersinis jautrumas	≤5 %
Maitinimo įtampa	18–28 VDC
Maitinimo srovė	2-10 mA
Išėjimo įtampa	±8 V
Darbinė temperatūra	-40 ℃ ~ + 120 ℃

Tam, kad būtų galima fiksuoti jutiklio išėjimo signalą, reikėjo papildomos matavimo įrangos. Pasirinktas jutiklis yra IEPE tipo, dėl to jo veikimui reikalingas nuolatinės srovės maitinimas. Be to, šio jutiklio išėjimo signalas turi nuolatinę dedamąją. Dėl to tarp jutiklio ir osciloskopo reikia IEPE signalų apdorojimo modulio. Šis modulis užtikrina tinkamą jutiklio maitinimą ir atskiria vibracijos signalo kintamąją dedamąją nuo nuolatinės įtampos komponentės. Buvo naudotas ICP DAS SG-3227 IEPE signalų apdorojimo modulis [37].

Paruoštam signalui stebėti ir analizuoti naudotas skaitmeninis osciloskopas Hantek DS02D10 [38]. Šis osciloskopas turi 100MHz dažnių juostos plotį ir 1GSA/s diskretizavimo dažnį, todėl tinka analizuoti vibracijos signalus, kadangi jų dažnis šiame tyrime neviršija 10 kHz. Toks dažnių juostos plotis ir diskretizavimo dažnis leido išvengti svarbios informacijos praradimo ir pakankamai tiksliai atvaizduoti signalus.

2.3. Metodologija

Šiame skyriuje aprašoma tyrime taikyta vibracijos signalų paruošimo, apdorojimo ir klasifikavimo eiga. Paaiškinamas tyrime naudotų signalų paruošimas ir segmentavimas, dažninės analizės metodų pritaikymas, informatyvių požymių išskyrimas ir klasifikavimas. Taip pat aprašomas spektrogramų sudarymas ir požymių formavimas mašininio mokymosi metodams bei pasirinktų metodų pritaikymas signalų klasifikavimui.

2.3.1. Vibracijos signalų paruošimas

Kadangi tyrime naudotose duomenų bazėse signalai pateikiami skirtingais formatais ir matavimo sąlygomis, prieš tolimesnę analizę duomenys buvo paruošti taip, kad būtų galima palyginti rezultatus.

CWRU duomenų bazėje vibracijos signalai pateikiami Matlab formato (*.mat*) failuose, kuriuose saugomi keli matavimo kanalai. Šiame tyrime naudotas tik pavaros pusės (*angl. Drive-End*) guolio vibracijos signalas, kuris literatūroje dažniausiai taikomas guolių gedimų diagnostikai. Reikalingas kanalas parinktas ieškant kintamojo, kurio pavadinime yra „DE_time“.

MaFaulDa duomenų bazėje signalai pateikiami CSV formato failuose. Juose taip pat saugomi keli matavimo kanalai. Analizei buvo parinktas 2 vibracijos kanalas (signalai iš akselerometro) pagal stulpelio indeksą.

Laboratorijos eksperimento duomenys vienmačių signalų formatu saugoti tekstiniuose failuose.

Visų duomenų bazių nuskaityti signalai konvertuoti į *double* duomenų tipą ir pertvarkyti į vienmačio stulpelio vektorių.

Atliekant spektrinę analizę, kuri pagrįsta Furjė transformacija, iš signalų pašalinta pastovioji signalo dedamoji. Tai įgyvendinta iš signalo atimant jo vidurkio reikšmę. Tai daroma tam, kad būtų sumažinta nulio dažnio komponentės įtaka amplitudės spektrui.

Nevienodo ilgio signalai nebuvo trumpinami ar keičiami. Dažninės analizės metoduose naudoti pilni signalai. Autokoreliacija skaičiuota ne tiesiogiai iš signalo, o iš jo Furjė spektro amplitudės.

CNN, RF, SVM ir KNN metodams signalai suskaidyti į vienodo ilgio segmentus. Šie segmentai naudoti spektrogramų generavimui. Spektrogramos naudotos kaip įėjimas CNN. Tos pačios spektrogramos naudotos formuojant požymių vektorius, naudotus kaip įėjimas RF, SVM bei KNN metoduose.

Abi tyrime naudotos duomenų bazės, nors ir buvo sudarytos laboratorinėmis sąlygomis, skiriasi eksperimentų sąlygomis bei imituojamų gedimų tipais. CWRU duomenų bazėje signalai gauti kontroliuojamomis guolių gedimų modeliavimo sąlygomis, tuo tarpu MaFaulDa duomenų bazėje registruoti signalai apima platesnį mechaninių defektų ir darbo režimų spektrą. Dėl to MaFaulDa duomenų klasifikavimas sudėtingesnis.

2.3.2. Signalų segmentavimas

Iš laboratorijos eksperimento bei iš nagrinėtų duomenų bazių gautų vibracijos signalų stulpeliai yra pakankamai ilgi ir nevienodos trukmės. Dėl to yra neefektyvu tiesiogiai naudoti visą signalą klasifikavimui, nes vienas signalas gali apimti ir kelias skirtingas sistemos būsenas. Todėl tyrime reikėjo segmentuoti signalus.

Daroma prielaida, kad po segmentavimo, kiekviename trumpame segmente vibracijos signalas yra kvazistacionarus, todėl jo statistinės savybės laikomos nekintančiomis ir gali būti taikomi dažninės analizės metodai [39].

Prieš atliekant segmentavimą, duomenys buvo padalinti į treniravimo ir testavimo aibes. Atskirame faile esantis signalas buvo priskirtas tik vienai iš šitų aibių. Tai buvo daroma tam, kad iš to paties signalo suformuoti segmentai vienu metu nepatektų ir į treniravimo, ir į testavimo aibes. Duomenų padalijimas failų lygmeniu neleidžia įvykti informacijos nutekėjimui (*angl. data leakage*), kuris galėtų dirbtinai padidinti klasifikavimo tikslumą.

Segmentavimui buvo panaudotas slenkančio lango metodas. Pradinis diskretinis signalas buvo skaidomas pagal (1) formulę:

$$x_i(n) = x(n + iH), n = 0,1, \dots, L - 1; \quad (14)$$

čia x(n) – pradinis diskretinis signalas;

L – segmento ilgis;

i – segmento numeris;

H – lango poslinkis.

Matlab aplinkoje segmentavimas realizuotas:

for startIdx = 1:segmentStep:(length(sig)-segmentLength+1)

```
        segment = sig(startIdx:startIdx+segmentLength-1);
end
```

Segmentų ilgis tyrime buvo nustatytas 2048 diskretizavimo taškai, o lango poslinkis – 1024 diskretizavimo taškai. Segmento ilgis buvo pasirinktas kaip tarpinis variantas tarp laiko ir dažninės informacijos išsaugojimo. Parinkus per mažą segmentų ilgį prarandama dažninė skiriamoji geba, o parinkus per didelį segmentų ilgį mažėja treniravimo rinkinio imtis. Tyrime pasirinktas segmentų persidengimo dydis (50 %) leido sumažinti informacijos praradimą tarp gretimų analizės langų ir tolygiau atvaizduoti signalą laiko erdvėje.

CWRU duomenų bazėje kiekvienas signalas suskaidytas į 100 segmentų. MaFaulDa duomenų bazėje kiekvienas signalas suskaidytas į 50 segmentų. KTU laboratorijos eksperimento duomenų rinkinyje kiekvienas signalas suskaidytas į 8 segmentus.

Gauti signalų segmentai buvo panaudoti sudaryti spektrogramoms, kurios buvo įvesties duomenys klasifikavimo algoritmuose. Dažninės analizės metodai buvo taikomi nesegmentuotam vibracijos signalui.

2.3.3. Dažninės analizės metodų taikymas

Šiame tyrime duomenims iš KTU laboratorijos eksperimento bei dviejų duomenų bazių apdoroti iš pradžių buvo išbandyti dažninės analizės metodai. Pasirinktos spektro, kepstro ir autokoreliacijos funkcijos. Šie metodai padeda išanalizuoti vibracijos signalą ir įvertinti, kuriuo pasirinktu signalo atvaizdavimo metodu bus pasiekti geriausi klasifikavimo rezultatai. Jie yra dažnai naudojami vibracijos signalų analizėje, nes galima analizuoti skirtingas signalo savybes. Spektrinė analizė naudojama signalo dažninės sudėties ir dominuojančių dažnių nustatymui, kepstro analizė padeda nustatyti periodiškai pasikartojančias spektrines struktūras, o autokoreliacijos funkcija leidžia įvertinti signalo periodiškumą ir jo periodą.

Visi tyrime naudoti dažninės analizės metodai buvo realizuoti Matlab aplinkoje, laikantis nuoseklios signalo paruošimo metodikos.

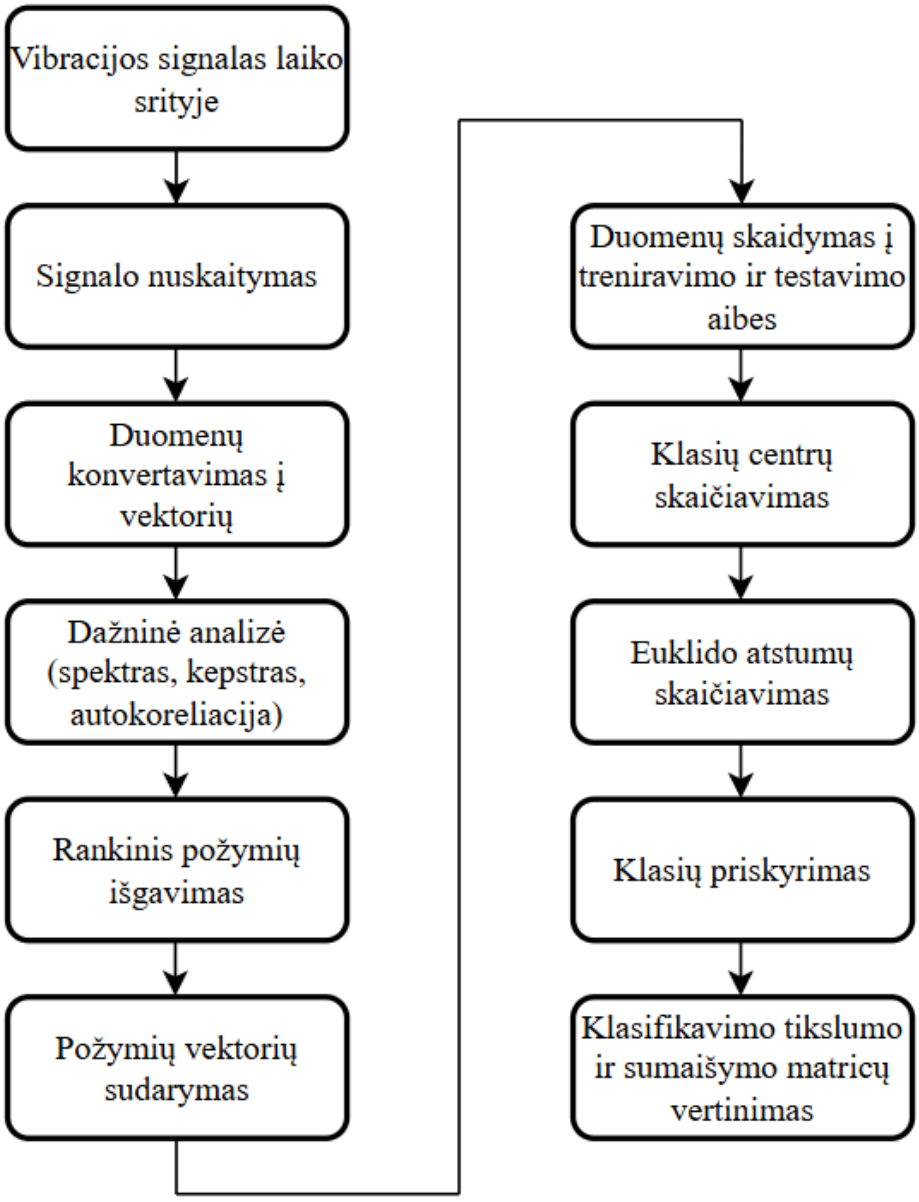

16 pav. Vibracijos signalų dažninės analizės eiga

2.3.4. Spektrinė analizė

Elektromechaninių sistemų vibracijos signalai yra sudaryti iš skirtingų dažninių komponentų, besikeičiančių priklausomai nuo sistemos dinamikos, darbo režimų, apkrovos ir gedimų. Dėl to signalai buvo transformuojami iš laiko į dažnių sritį taikant diskrečiąją Furjė transformaciją [23]:

$$X(k) = \sum_{n=0}^{N-1} x(n)\ e^{-j2\pi kn/N}; \quad (15)$$

čia x(n) – pradinis diskretinis signalas;

X(k) – signalo spektrinė reikšmė dažnių srityje;

N – signalo mėginių skaičius;

n – laiko diskretizacijos indeksas;

k – dažnio komponentės indeksas.

Furjė transformacija padeda nustatyti, kaip signalo energija pasiskirsto skirtinguose dažniuose. Kadangi buvo nagrinėjami realūs vibracijos signalai iš laboratorijos eksperimento ir iš kitų laboratorijų duomenų bazių, jų spektras yra simetriškas. Dėl to signalo analizei buvo naudojamas vienpusis amplitudės spektras.

Prieš Furjė transformaciją iš signalo buvo pašalinta vidutinė reikšmė, kas leido sumažinti nulio dažnio komponentės įtaką.

Spektras Matlab aplinkoje realizuotas normalizuojant greitos Furjė transformacijos rezultatą ir koreguojant amplitudes vienpusiam spektrui:

```
a = a(:);
a = a - mean(a);
N = length(a);
X = fft(a);
P2 = abs(X / N);
P1 = P2(1:floor(N/2)+1);
```

Apskaičiavus Furjė transformaciją, spektro amplitudės buvo normalizuotos pagal signalo ilgį, kad skirtingo ilgio signalų spektrus būtų galima palyginti.

2.3.5. Kepstro funkcija

Nors spektras padeda nustatyti dominuojančius signale dažnius, tačiau kai kurios signalų savybės pasireiškia ne pavieniais dažniais, o periodiškai išsidėsčiusiomis spektrinėmis komponentėmis. Tokiais atvejais yra naudingiau taikyti kepstro funkciją.

Signalo kepstras yra apskaičiuojamas kaip logaritminio amplitudės spektro atvirkštinė Furjė transformacija [39]:

$$c(n) = \mathcal{F}^{-1}\ln(|X(f)|); \quad (16)$$

čia c(n) – kepstro funkcija;

X(f) – signalo Furjė spektras;

$\mathcal{F}^{-1}$ – atvirkštinė Furjė transformacija;

n – kepstro indeksas.

Kepstro funkcija Matlab aplinkoje realizuota:

```
X = fft(a);
logmag = log(abs(X)+eps);
c = real(ifft(logmag));
```

2.3.6. Autokoreliacijos analizė

Signalo periodiškumo įvertinimui buvo pritaikyta autokoreliacijos funkcija, kuri parodo signalo koreliaciją su paties signalo kopija, perstumta laike:

$$R_{xx}(\tau) = \sum_{n=-\infty}^{\infty} x(n)\ x(n+\tau); \quad (17)$$

čia $R_x x(\tau)$ – autokoreliacijos funkcija;

x(n) – analizuojamas signalas;

n – diskretinio laiko indeksas;

τ – poslinkio indeksas.

Šiame tyrime autokoreliacija taikyta signalo greitos Furjė transformacijos moduliui, todėl buvo analizuotas ne signalas laiko srityje, o spektrinių komponentų pasikartojimas:

```
sp = abs(fft(a));
saut = xcorr(sp);
```

Šis metodas leidžia geriau atskirti periodiškai pasikartojančias spektrines struktūras, kurios atitinka skirtingus vibracijos signalo dažninius komponentus.

2.3.7. Vibracijos signalų analizė požymių erdvėje ir klasifikavimas

Tam, kad būtų galima kiekybiškai įvertinti klasių atskyrimą, iš signalo laiko srityje, spektro, kepstro ir autokoreliacijos signalų reikėjo išskirti požymius, kurie bus naudojami klasifikavimui. Analizuojant dažninės analizės metodais gautus signalus, parinkti informatyvūs požymiai. Vizualiai įvertinus kiekvienos duomenų bazės signalo laiko srityje, spektro, kepstro ir autokoreliacijos signalų grafikus pasirinkta po du taškus, kuriuose aiškiausiai atsiskiria skirtingų klasių kreivės. Tokiu būdu signalai aprašyti dviejų požymių vektoriumi. Požymių parinkimo atvaizdavimui požymių erdvėje pavyzdys pavaizduotas 17 pav.

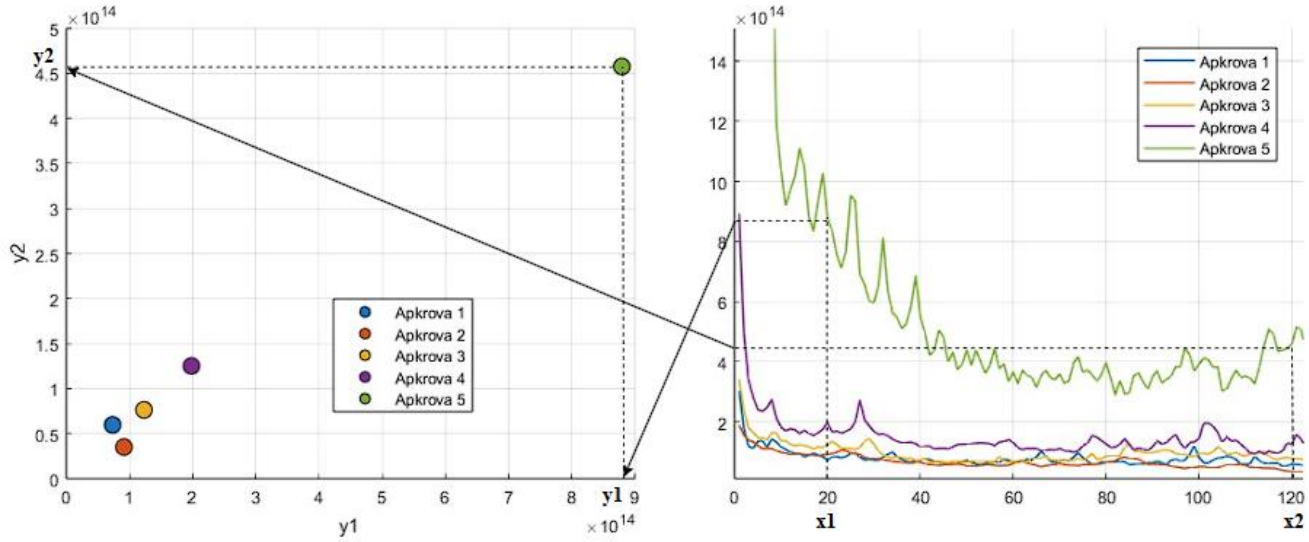

17 pav. Požymių parinkimas

Požymių vektoriai suskirstyti į treniravimo ir testavimo imtis santykiu 50/50. Naudojant treniravimo duomenų dalį kiekvienai klasei apskaičiuotas požymių vektoriaus vidurkis (klasės centras). Klasifikavimas atliktas naudojant testavimo duomenų dalį, skaičiuojant Euklido atstumus (1.3.5. skyrius, formulė nr. 8) nuo kiekvieno taško požymių erdvėje iki klasių centrų. Duomenų taškas

priskirtas tai klasei, iki kurios mažiausias atstumas. Skaičiavimų Matlab kodo fragmentas pridėtas 4 priede.

Klasifikavimo tikslumas skaičiuotas kaip teisingai klasifikuotų duomenų taškų santykis su visais duomenų taškais. Tam, kad būtų galima matyti, kurios klasės labiausiai maišomos tarpusavyje, sudarytos sumaišymo matricos.

Reikia atkreipti dėmesį į tai, kad toks klasifikavimo metodas nėra universalus. Informatyvių požymių parinkimas čia yra atliekamas vizualiai pasirenkant taškus, kuriuose klasių grafikai labiausiai skiriasi tarpusavyje. Dėl to taikant kitą analizės metodą ar naudojant kitą duomenų rinkinį, reikia iš naujo parinkti požymius pagal naujai sudarytus grafikus.

2.3.8. Mašininio mokymosi metodų taikymas vibracijos signalų klasifikavimui

Tyrime vibracijos signalų klasifikavimui buvo taikyti keli mašininio mokymosi metodai: CNN, RF, SVM ir KNN. Šių metodų paskirtis buvo automatiškai priskirti kiekvieną segmentą atitinkamai klasei naudojant iš anksto paruoštą signalo atvaizdavimą.

Tyrime buvo naudojama tokia bendra klasifikavimo metodikos eiga:
1. neapdirbto vibracijos signalo segmentavimas;
2. signalo segmento reprezentacijos sudarymas;
3. klasifikatoriaus mokymas;
4. rezultatų įvertinimas.

Signalo segmento reprezentacijos sudarymo etapas skyrėsi priklausomai nuo naudojamo klasifikavimo metodo. Klasifikuojant CNN signalo segmentai buvo transformuoti į spektrogramų vaizdus. Šie vaizdai buvo pateikti tinklui kaip 2D įėjimo duomenys. Tuo tarpu klasifikuojant RF, SVM ir KNN metodais duomenys buvo paverčiami spektrogramomis ir tada iš tų spektrogramų suformuoti vienmačiai požymių vektoriai išskleidžiant vaizdą į vienmatę seką.

Duomenys buvo skaidomi į treniravimo ir testavimo rinkinius. CWRU duomenų bazės atveju Matlab aplinkoje realizuota taip:

```
idx = randperm(nFiles);
nTrainFiles = max(1, floor(trainRatio*nFiles));

trainIdx = idx(1:nTrainFiles);
testIdx   = idx(nTrainFiles+1:end);
```

MaFaulDa duomenų bazės ir laboratorinio eksperimento duomenys buvo skaidomi analogiškai: failų indeksai sumaišomi ir padalijami į treniravimo ir testavimo aibes. Toks skaidymo principas buvo taikomas siekiant užtikrinti, kad testavime būtų vertinamas modelio gebėjimas apibendrinti naujus duomenis, o ne tik atpažinti segmentus iš jau matytų duomenų.

Kadangi po spektrogramų pavertimo požymių vektoriais jų skaičius išlieka didelis, SVM ir KNN buvo taikytas požymių skaičiaus mažinimas naudojant pagrindinių komponenčių analizę. Matlab realizacija:

```
[coeff, scoreTrain, ~, ~, explained, mu] = pca(XTrainD);
pcaDims = min(pcaDims, size(scoreTrain,2));
```

```
XTrainUse = scoreTrain(:,1:pcaDims);
XTestUse  = (XTestD - mu) * coeff(:,1:pcaDims);
```

Pagrindinių komponenčių analizė buvo skaičiuota tik treniravimo rinkiniui, o testavimo duomenys projektuojami naudojant treniravimo metu apskaičiuotą vidurkį ir koeficientų informaciją. Tai užtikrina, kad testavimo duomenys nedarytų įtakos modelio mokymui ir būtų išvengta informacijos nutekėjimo. Pagrindinių komponenčių analizės panaudojimo tikslas buvo sumažinti požymių skaičių, kas leistų pagerinti SVM ir KNN mokymo stabilumą ir sumažintų skaičiavimo sąnaudas.

Nors failų formatas ir skirtingų klasių dydžiai ir struktūros naudotose duomenų bazėse skirtingi, signalų segmentavimo ir modelių įvertinimo principai visiems duomenų rinkiniams buvo vienodi. Visiems metodams buvo pritaikytos to paties principo duomenų skaidymo procedūros, tam, kad būtų galima tarpusavyje objektyviai palyginti skirtingų klasifikatorių klasifikavimo efektyvumą.

Modelių klasifikavimo tikslumui įvertinti naudoti testavimo duomenys. Tikslumas skaičiuotas kaip teisingai klasifikuotų duomenų dalis. Tam, kad būtų galima matyti, kurios klasės labiausiai maišomos tarpusavyje, sudarytos sumaišymo matricos.

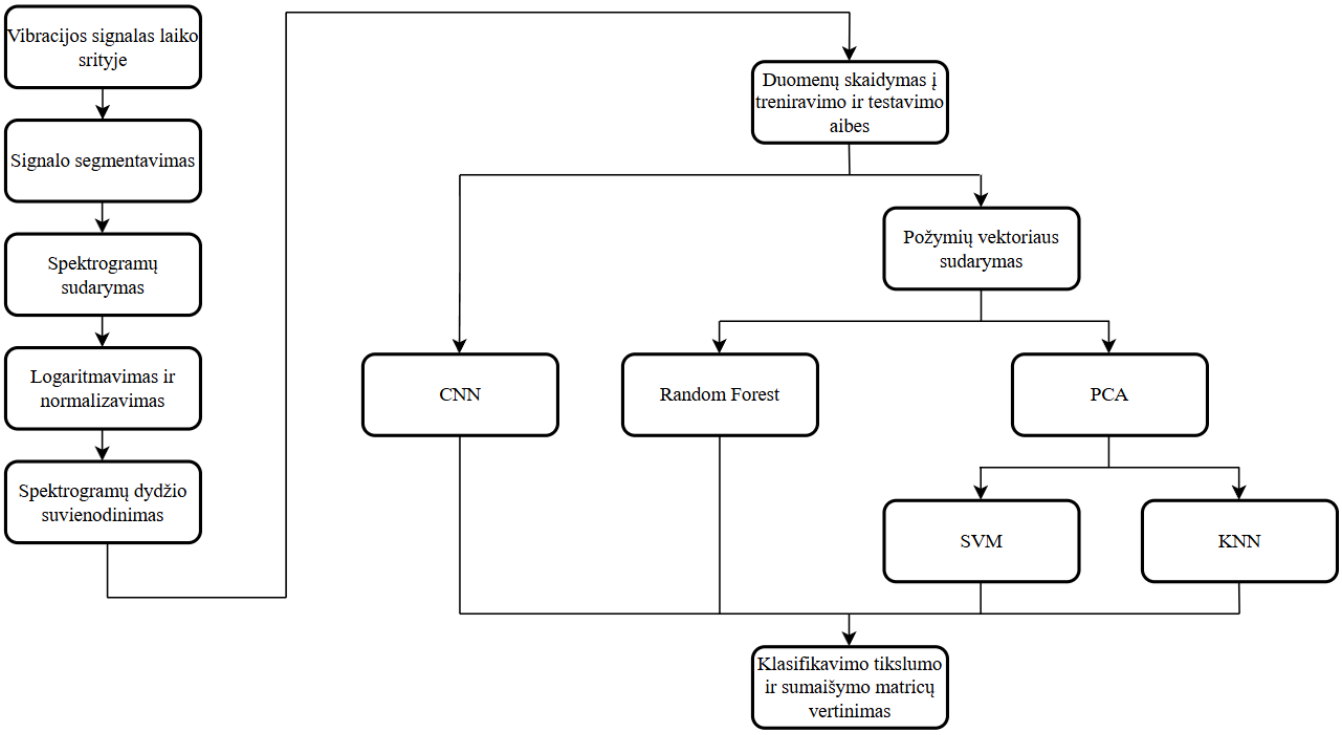

18 pav. Vibracijos signalų klasifikavimo mašininio mokymosi metodais eiga

2.3.9. Spektrogramų sudarymas ir požymių formavimas klasifikavimo metodams

Mašininio mokymosi metodams tyrime buvo naudojamos vibracijos signalų spektrogramos, kadangi jos atvaizduoja ir signalo energijos pasiskirstymą dažnio srityje, ir jo kitimą laike. Toks signalų atvaizdavimas plačiai taikomas diagnostikos uždaviniuose, kai skirtingos sistemos būsenos gali pasireikšti skirtingomis dažninėmis struktūromis.

Prieš sudarant spektrogramas vibracijos signalai buvo suskaidyti į vienodo ilgio segmentus. Spekrogramoms gauti buvo naudojama Matlab funkcija *spectrogram*. Ši funkcija skaičiuoja trumpalaikę Furjė transformaciją (*angl. Short-Time Fourier Transform, STFT*):

$$\mathrm{STFT}(t,f) = \sum_{n=-\infty}^{\infty} x(n)\ w(n-t)\ e^{-j2\pi fn}; \quad (18)$$

Čia x(n) – įėjimo signalas;

$w(n-t)$ – langa funkcija;

t – laiko poslinkis;

f – dažnis.

Spektrogramos skaičiavimui buvo naudojamas 512 diskretizavimo taškų ilgio Hamming langas, 256 taškų persidengimas ir 1024 taškų greitoji Furjė transformacija, taip pat atsižvelgta į signalo diskretizavimo dažnį:

```
win      = hamming(512);
noverlap = 256;
nfft     = 1024;
[Sspec,~,~] = spectrogram(segment, win, noverlap, nfft, fs);
```

Buvo pasirinkta naudoti *Hamming* langą, nes jis gali sumažinti spektrinio nutekėjimo (*angl. spectral leakage*) efektą. Spektrinis nutekėjimas atsiranda tada, kai analizuojamas signalas nėra tiksliai suderintas su analizės lango ilgiu. Tokiu atveju signalo energija gali pasiskirstyti tarp kelių dažninių komponenčių, o tai apsunkina tikrųjų dažnių identifikavimą. Lango funkcijos naudojimas sumažina šį efektą, nes signalo kraštinės reikšmės palaipsniui sumažinamos iki nulio, taip sumažinant staigius signalo pokyčius analizės intervalo ribose.
Hamming lango funkcijos formulė:

$$w(n) = 0{,}54 - 0{,}46\cos\left(\frac{2\pi n}{N-1}\right), \quad 0 \le n \le N-1; \quad (19)$$

Čia N – lango ilgis;

n – diskretizacijos indeksas;

Gauta kompleksinė trumpalaikės Furjė transformacijos matrica buvo konvertuota į logaritminę skalę ir normalizuota:

```
img = log10(abs(Sspec) + eps);
img = mat2gray(img);
```

Ši transformacija sumažina spektro dinaminį diapazoną. Be logaritmavimo silpnesni dažniniai komponentai tampa sunkiai atskiriami, kadangi vibracijos signalų energija dažnai būna pasiskirsčiusi netolygiai.

Tam, kad būtų užtikrintas vienodas intensyvumo intervalas [0,1] buvo panaudota funkcija mat2gray, kuri paverčia matricą į pilkos spalvos vaizdą, kurio reikšmės yra diapazone nuo 0 (juoda) iki 1 (balta).

Tam, kad visi klasifikavimo metodai galėtų naudoti vienodo formato įvesties duomenis, spektrogramos perkeistos į fiksuoto dydžio vaizdus naudojant Matlab funkciją *imresize*. Spektrogramos dydis parinktas priklausomai nuo naudoto klasifikavimo metodo.

CNN atveju naudotos didesnės rezoliucijos (128x128) spektrogramos, nes CNN gali efektyviai aptikti požymius dvimačiuose vaizduose. RF, SVM ir KNN atveju naudoti mažesnės rezoliucijos vaizdai, nes šiems metodams spektrogramos buvo naudojamos požymių vektorių sudarymui. RF naudotos 64x64, SVM ir KNN 32x32 spektrogramos. Per didelė spektrogramų rezoliucija šiems metodams reikštų didesnį sugeneruotų požymių skaičių ir modelio treniravimas būtų apsunkintas.

Klasifikavimui naudojant CNN, klasifikatoriaus įėjime buvo tiesiogiai naudojamos spektrogramos. RF, SVM ir KNN metodų atveju spektrogramos iš pradžių buvo paverstos į vienmačius požymių vektorius, nes šiems klasifikatoriams įėjime turi būti pateikiami vektoriniai duomenys. Dvimatė spektrograma buvo paversta vienmačiu požymių vektoriumi, išskleidžiant dvimatį vaizdą į vienmatę seką:

```
X(i,:) = img(:)';
Y(i)   = categorical(string(imds.Labels(i)), classNames);
```

Tokiu būdu kiekvienas signalo segmentas buvo aprašomas vienodu požymių rinkiniu, kuris vėliau buvo naudojamas klasifikavimo modelių treniravimui ir testavimui.

19 pav. Apdorota spektrograma

2.3.10. CNN taikymas vibracijos signalų klasifikavimui

Konvoliuciniai neuroniniai tinklai (*angl. Convolutional Neural networks, CNN*) yra metodas, leidžiantis tiesiogiai iš signalo reprezentacijos „išmokti“ klasifikavimui reikšmingus požymius. CNN klasifikavimo modeliai, kitaip nei tradiciniai dažninės analizės metodai, nereikalauja požymių atrinkimo, nes tinklas treniravimo metu pats išskiria sudėtingesnes struktūras duomenyse [27].

Tyrime CNN klasifikavimo metodas buvo panaudotas vibracijos signalų klasifikavimui iš spektrogramų, nes taip galima vienu metu įvertinti signalo kitimą ir laiko, ir dažnio srityse. Vibracijos signalų laiko eilutė tyrime transformuota į dvimatį vaizdą, kuris naudotas kaip įėjimo duomenys CNN modeliui. Toks atvaizdavimas tinkamas naudoti CNN, nes CNN architektūra buvo sukurta dvimačių duomenų (vaizdų) analizei. Spektrogramose skirtingos vibracijos būsenos gali pasireikšti skirtingais energijos pasiskirstymais laiko ir dažnio ašyse, todėl CNN gali automatiškai atpažinti skirtingoms sistemos būsenoms būdingas struktūras.

Tyrime panaudota trijų konvoliucinių sluoksnių architektūra. Toks sluoksnių skaičius pasirinktas kaip tarpinis variantas tarp modelio sudėtingumo ir persimokymo rizikos. Mažesnis sluoksnių skaičius gali apriboti modelio galimybes išskirti sudėtingesnius požymius, o didesnis sluoksnių skaičius padidintų modelio parametrų skaičių ir modelio persimokymo tikimybę. Pirmojo konvoliucinio bloko realizavimas Matlab:

```
convolution2dLayer(3,16,'Padding','same')
```

batchNormalizationLayer
reluLayer
maxPooling2dLayer(2,'Stride',2)

Kituose sluoksniuose filtrų skaičius buvo didinamas (16, 32 ir 64 filtrai). Tai leido tinklui palaipsniui išskirti vis sudėtingesnius požymius.

Visuose sluoksniuose naudoti 3x3 dydžio filtrai. Toks dydis parinktas kaip tarpinis variantas tarp tinklo gebėjimo nustatyti lokalias spektrogramų struktūras ir modelio sudėtingumo. Mažesni filtrai leidžia išskirti smulkesnius požymius, o didesni filtrai didina parametrų skaičių ir modelio sudėtingumą.

Naudojant daugiasluoksnę CNN architektūrą modelis palaipsniui gali išmokti vis sudėtingesnes duomenų struktūras. Pirmieji konvoliuciniai sluoksniai išskiria paprastesnius požymius, tokius kaip lokalūs intensyvumo pokyčiai ar dažninės juostos spektrogramoje. Gilesniuose sluoksniuose šie požymiai kombinuojami į sudėtingesnes struktūras, kurios gali atspindėti vibracijos signalo ypatumus, būdingus skirtingoms sistemos būsenoms.

Po kiekvieno konvoliucinio sluoksnio naudoti *batchNormalizationLayer* normalizavimo sluoksniai. Jie naudoti tam, kad būtų pagreitintas tinklo mokymas ir sumažintas jautrumas tinklo pradinėms parametrų reikšmėms. Taip pat naudota ReLU aktyvacijos funkcija, skirta į tinklą įvesti netiesiškumą.

Po konvoliucinių sluoksnių naudoti matricos dydžio mažinimo sluoksniai. Po pirmų dviejų konvoliucinių sluoksnių naudoti maxPooling2dLayer, o po trečio – averagePooling2dLayer. Tai leido pirmiausia išsaugoti svarbiausius požymius ir juos apibendrinti prieš klasifikavimo sluoksnį.
Konvoliuciniame sluoksnyje realizuojama operacija, aprašoma formule [25]:

$$y(i,j) = \sum_m \sum_n x(i+m, j+n)\ h(m,n); \tag{20}$$

Čia x – įėjimo dydis;

H – filtro branduolys;

y – požymių žemėlapis.

Filtras slenkamas per įėjimo duomenis ir kiekvienoje naujoje padėtyje apskaičiuojamos naujos reikšmės, kurios panaudojamos išskirti požymiams. Treniravimo metu automatiškai koreguojami filtrų koeficientai tam, kad būtų geriau atskiriamos skirtingos klasės [25].

Tinklas treniruotas 10 epochų. Treniravimui naudotas Adam optimizavimo algoritmas. Šis algoritmas adaptuoja mokymosi žingsnį kiekvienam parametrui atskirai ir užtikrina stabilesnį gradientinį optimizavimą didelės dimensijos problemose. Mokymo proceso metu tinklas vis atnaujina savo parametrus siekdamas sumažinti nuostolio funkciją. Tam naudojami gradientais pagrįsti optimizavimo metodai, kai modelio svoriai koreguojami pagal apskaičiuotą nuostolio funkcijos gradientą [27].

Tinklo mokymo metu naudotas mini paketų dydis parinktas lygus 32. Toks dydis parinktas kaip tarpinis variantas tarp mokymo stabilumo ir skaičiavimo sąnaudų.

Tinklo išėjime naudotas pilnai sujungtas sluoksnis (f*ullyConnectedLayer*), *softmax* sluoksnis (*softmaxLayer*) ir klasifikavimo sluoksnis (*classificationLayer*), kurie priskiria kiekvieną spektrogramą vienai iš analizuojamų klasių.

2.3.11. RF taikymas vibracijos signalų klasifikavimui

Tyrime taip pat buvo išbandytas dažnai vibracijos signalų klasifikavimo literatūroje aprašomas RF „ansamblinio mokymosi“ klasifikatorius. Šis metodas pasirinktas, nes yra dažnai taikomas praktiniuose diagnostikos uždaviniuose ir yra tinkamas naudoti, kai yra daug skirtingų klasių.

Prieš įgyvendinant skaičiavimus, spektrogramos dydis buvo sumažinamas iki fiksuoto formato panaudojant Matlab funkciją imresize.

Lyginant su CNN metode naudotomis spektrogramomis, RF naudojamų spektrogramų dydis sumažintas 2 kartus. RF algoritme kiekvienas vaizdo taškas traktuojamas kaip atskiras požymis. Spektrograma paverčiama vienmačiu požymių vektoriumi, kuriame kiekvienas pikselis atitinka vieną požymį. Didėjant vaizdo rezoliucijai proporcingai auga požymių skaičius, kas lemia didesnius atminties resursų poreikius ir ilgesnį modelio mokymo laiką. Todėl RF modeliui buvo pasirinkta naudoti mažesnės rezoliucijos spektrogramas.

RF modelis buvo mokomas Matlab funkcija TreeBagger. Nurodytas klasifikavimo režimas, medžių skaičius ir minimalus lapo dydis:

```
rf = TreeBagger(numTrees, XTrain, YTrainCat, ...
'Method','classification', ...
'MinLeafSize', minLeafSize);
```

Sprendimų medžių skaičius buvo nustatytas 300. Didesnis medžių skaičius paprastai pagerina klasifikavimo stabilumą, tačiau didina skaičiavimo sąnaudas. Dėl to buvo pasirinkta tarpinė reikšmė tarp modelio sprendimo stabilumo ir skaičiavimo efektyvumo.

Buvo parinktas minimalus imties dydis lape, lygus 5. Tokia reikšmė parinkta siekiant išvengti per daug smulkaus sprendimų medžio skaidymo ir sumažinti persimokymo tikimybę.

2.3.12. SVM taikymas vibracijos signalų klasifikavimui

Dar vienas iš šiame tyrime pasirinktų naudoti klasifikavimo metodų buvo atraminių vektorių mašinos (angl. *Support Vector Machine, SVM*). Šis prižiūrimo mokymosi metodas gerai tinka klasifikuoti duomenis, turinčius daug požymių ir yra plačiai pritaikomas vibracijos signalų klasifikavimui [22]. Šio metodo tikslas yra rasti tokią sprendimo ribą, kuri atskirtų klases ir paliktų kuo didesnį atstumą tarp artimiausių skirtingų klasių taškų.

Kadangi iš spektrogramų gauta daug požymių, SVM klasifikatoriui taikyta PCA. PCA apskaičiuota treniravimo duomenims, o testavimo duomenys transformuoti naudojant tuos pačius parametrus. Taip sumažintas požymių skaičius iki 150 pagrindinių komponenčių.

Klasifikatoriuje naudota radialinės bazės funkcijos (RBF) branduolio funkcija. Ji leidžia sudaryti netiesinio sprendimo ribas tarp klasių. Prieš klasifikavimą taikytas požymių standartizavimas tam, kad būtų sumažinta skirtingų požymių mastelio įtaka klasifikavimo rezultatams.

SVM modelio mokymas buvo realizuotas naudojant Matlab funkciją *fitcecoc*. Kiekvienai klasei apmokomas atskiras klasifikatorius, kuris atskiria vienos klasės duomenis nuo likusių klasių. Matlab realizacija:

```
svmModel = fitcecoc(XTrainUse, YTrain, ...
'Learners', t, ...
'Coding', 'onevsall', ...
'ClassNames', categorical(classNames));
```

2.3.13. KNN taikymas vibracijos signalų klasifikavimui

Tyrime taip pat buvo panaudotas vienas paprasčiausių neparametrinių klasifikavimo metodų – k-artimiausių kaimynų (*angl. K-Nearest Neighbors, KNN*) algoritmas. Šis metodas naują signalo segmentą klasifikuoja pagal artimiausius mokymo duomenis požymių erdvėje, todėl yra priskiriamas pavyzdžiais paremtiems (angl. *instance-based learning*) algoritmams.

Šiame tyrime vibracijos signalų būsenų klasifikavimui KNN metodu buvo naudojami iš spektrogramų išgautų požymių vektoriai. KNN modelis Matlab aplinkoje realizuotas naudojant funkciją *fitcknn*:

```
knnModel = fitcknn(XTrainUse, YTrain, ...
'NumNeighbors', k, ...
'Distance', distanceMetric, ...
'Standardize', standardizeKNN);
```

KNN klasifikavimas yra pagrįstas atstumų tarp duomenų taškų skaičiavimu požymių erdvėje. Naujas duomenų taškas priskiriamas tai klasei, kuriai priklauso artimiausi mokymo duomenų taškai. Tyrime buvo panaudotas Euklido atstumas:

$$d(x,y) = \sqrt{\sum_{i=1}^{n}(x_i - y_i)^2}; \tag{21}$$

Čia x ir y – požymių vektoriai;

n – požymių skaičius.

Euklido atstumo matas naudojamas panašumo tarp duomenų požymių erdvėje įvertinimui. Kadangi spektrogramų pagrindu suformuoti požymiai pateikiami kaip skaitinės intensyvumo reikšmės, Euklido atstumas padeda palyginti skirtingus vibracijos signalus.

Tyrime naudojamas kaimynų skaičius *k* parodo, kiek artimiausių mokymo duomenų taškų naudojama klasės sprendimui priimti. Mažos *k* reikšmės leidžia modeliui labiau prisitaikyti prie duomenų, tačiau padidina jautrumą triukšmui. Tuo tarpu didesnės *k* reikšmės leidžia pasiekti stabilesnius klasifikavimo rezultatus, tačiau gali lemti nepakankamą prisitaikymą prie duomenų. Šiame tyrime *k* parinktas 5. Tokia reikšmė parinkta kaip tarpinis variantas tarp klasifikavimo tikslumo ir jautrumo triukšmui.

Pritaikius PCA požymių skaičius sumažintas iki 150 pagrindinių komponenčių.

Programoje taip pat buvo panaudotas požymių standartizavimas tam, kad skirtingi požymiai būtų panašaus mastelio ir konkretus požymis neproporcingai nepaveiktų atstumo skaičiavimo.

3. Tiriamoji dalis

Šiame skyriuje analizuojami vibracijos signalų klasifikavimo rezultatai. Kiekvienam duomenų rinkiniui pateikti vibracijos signalo laiko srityje, kepstro, spektro ir autokoreliacijos funkcijų grafikai. Kiekvienam iš šių signalų analizės metodų pateikta sumaišymo matrica. Šiems metodams naudotas klasifikatorius, paremtas Euklido atstumų skaičiavimu tarp parinktų taškų požymių erdvėje ir klasių centrų. Taip pat šiame skyriuje kiekvienam duomenų rinkiniui pateiktos sumaišymo matricos, kurios buvo gautos CNN, RF, SVM ir KNN metodais. CNN klasifikavimui naudotos apdorotos vibracijos signalų spektrogramos, o RF, SVM ir KNN naudoti iš tų apdorotų spektrogramų sudaryti požymių vektoriai.

3.1. CWRU rezultatai

Šiame skyriuje analizuojami skirtingais klasifikavimo metodais gauti rezultatai naudojant duomenis iš CWRU guolių gedimų duomenų bazės. Laiko srities signalų, spektro, kepstro ir autokoreliacijos metodų klasifikavimo tikslumui įvertinti naudota 32 testavimo pavyzdžių imtis. CNN, RF, SVM ir KNN metodų klasifikavimo tikslumui įvertinti naudota 2100 testavimo pavyzdžių imtis.

20 pav. pavaizduoti CWRU duomenų bazės signalai laiko srityje. Lyginant su gedimų signalais, matoma, kad normalios būklės signalas tolygesnis, neturi tokių ryškių trumpų amplitudės šuolių.

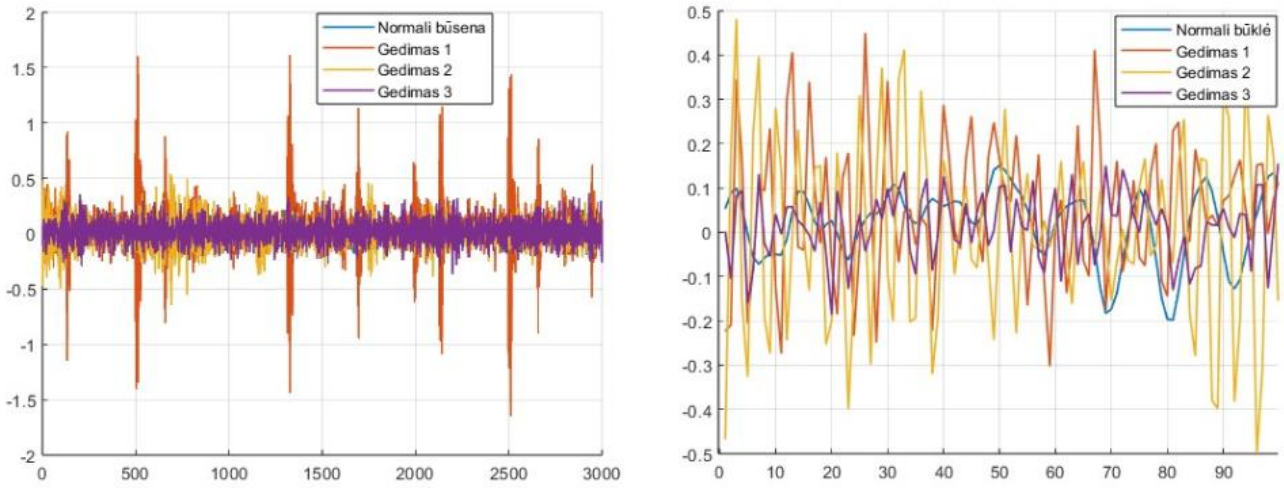

20 pav. CWRU vibracijos signalų laiko srityje grafikas. Gedimas 1 – vidinio žiedo riedėjimo takelio defektas; gedimas 2 – riedėjimo kūnų defektas; gedimas 3 – išorinio žiedo riedėjimo takelio defektas.

Naudojant iš vibracijos signalo grafiko išskirtus požymius gautas 43,75 % klasifikavimo tikslumas. Riedėjimo kūnų defekto ir išorinio žiedo riedėjimo takelio defekto klasių klasifikavimo tikslumas 50 %, dažniausiai jos buvo sumaišytos tarpusavyje. Vidinio žiedo riedėjimo takelio defekto klasės klasifikavimo tikslumas 25 %, ši klasė buvo klaidingai priskirta riedėjimo kūnų defekto ir išorinio žiedo riedėjimo takelio defekto klasėms.

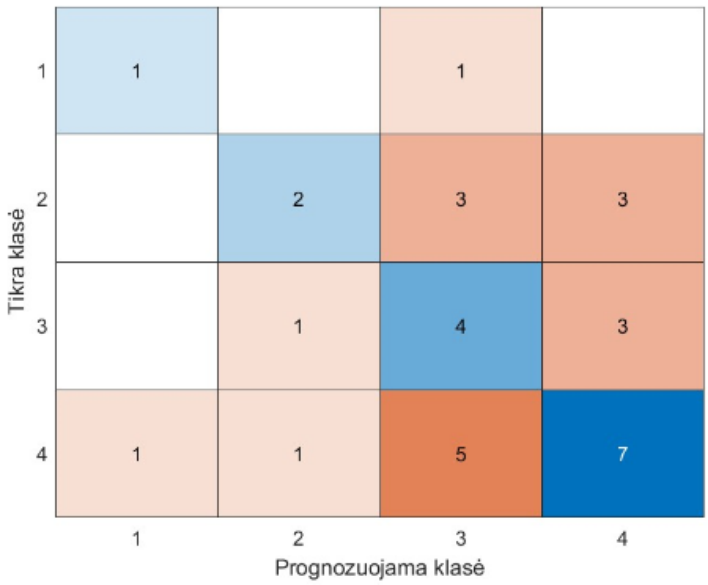

21 pav. CWRU vibracijos signalų laiko srityje sumaišymo matrica. Klasės: 1 – normali būsena; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – riedėjimo kūnų defektas; 4 – išorinio žiedo riedėjimo takelio defektas.

3.1.1. Spektras

22 pav. pavaizduoti signalų spektrai, gauti pritaikius diskrečiąją Furjė transformaciją CWRU duomenų bazės signalams. Matomas skirtingų klasių pasiskirstymas po dažnių juostą. Normalios būsenos ir išorinio žiedo riedėjimo takelio defektuose matomi ryškesni pavieniai pikai. Kitose gedimų klasėse pikai dažnių juostoje pasiskirstę plačiau.

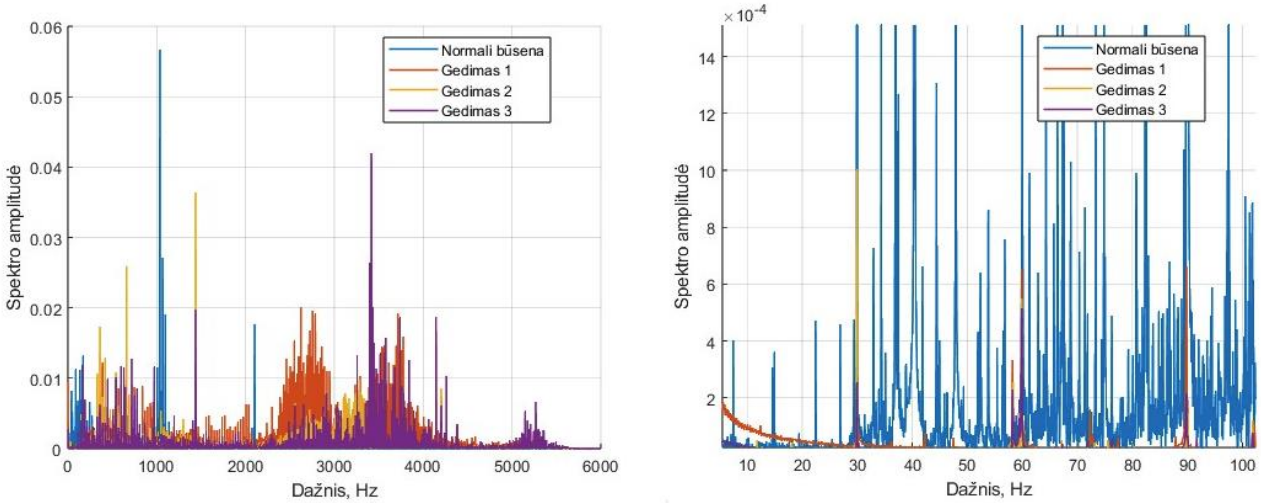

22 pav. CWRU spektro grafikas. Gedimas 1 – vidinio žiedo riedėjimo takelio defektas; gedimas 2 – riedėjimo kūnų defektas; gedimas 3 – išorinio žiedo riedėjimo takelio defektas.

CWRU duomenų bazės duomenims pritaikius spektro funkciją gautas 46,88 % klasifikavimo tikslumo rezultatas. Tai yra 3,13 procentinio punkto aukštesnis tikslumas lyginant su signalo laiko srityje klasifikavimo rezultatu. Vidinio ir išorinio žiedo riedėjimo takelio defektų klasių klasifikavimo tikslumas 50 %. Riedėjimo kūnų defekto klasės klasifikavimo tikslumas 25 %. Šios klasės dažniausiai klaidingai priskirtos normalios būsenos klasei.

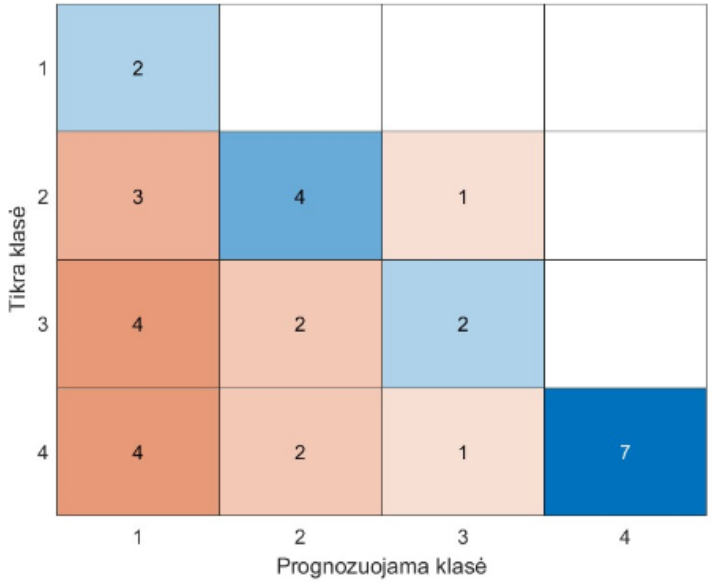

23 pav. CWRU spektro sumaišymo matrica. Klasės: 1 – normali būsena; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – riedėjimo kūnų defektas; 4 – išorinio žiedo riedėjimo takelio defektas.

3.1.2. Kepstras

24 pav. pavaizduotos signalų kepstro funkcijos, gautos skaičiuojant logaritminio amplitudės spektro atvirkštinę Furjė transformaciją CWRU duomenų bazės signalams. Vizualiai sudėtinga išskirti atskiras klases.

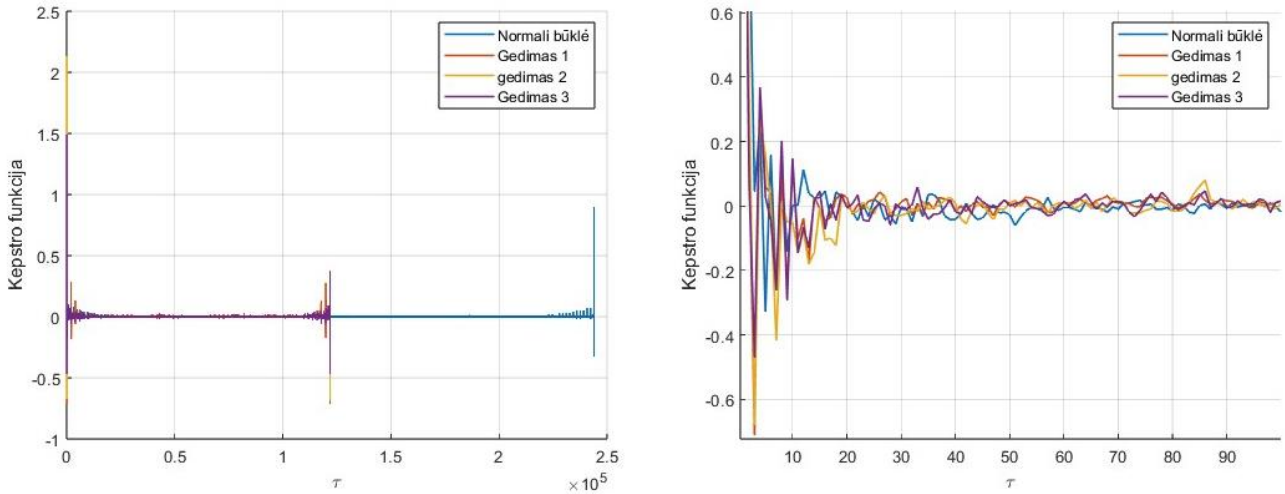

24 pav. CWRU kepstro grafikas. Gedimas 1 – vidinio žiedo riedėjimo takelio defektas; gedimas 2 – riedėjimo kūnų defektas; gedimas 3 – išorinio žiedo riedėjimo takelio defektas.

CWRU duomenų bazės duomenims pritaikius kepstro funkciją gautas 62,5 % klasifikavimo tikslumo rezultatas. Tai yra 15,62 procentiniais punktais aukštesnis tikslumas lyginant su spektro funkcijos klasifikavimo rezultatu. Didžiausias klasifikavimo tikslumas (71,4 %) pasiektas išorinio žiedo riedėjimo takelio defekto klasėje. Dažniausiai tarpusavyje buvo sumaišytos vidinio žiedo riedėjimo takelio defekto ir riedėjimo kūnų defekto klasės.

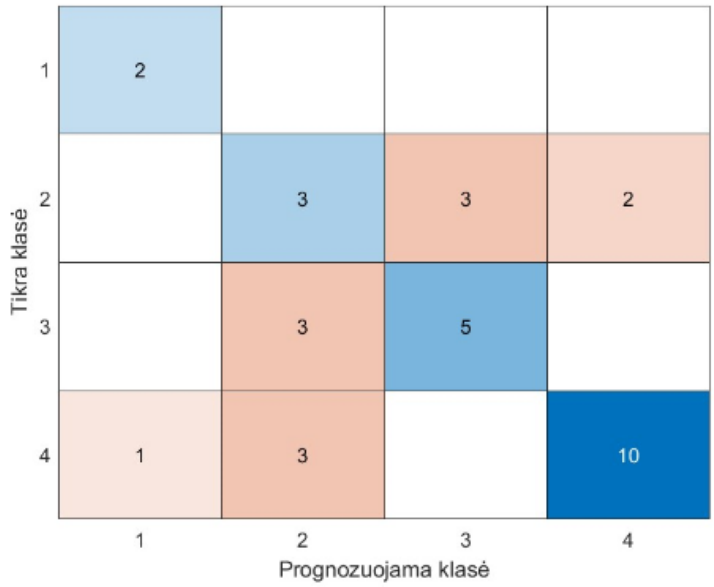

25 pav. CWRU kepstro sumaišymo matrica. Klasės: 1 – normali būsena; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – riedėjimo kūnų defektas; 4 – išorinio žiedo riedėjimo takelio defektas.

3.1.3. Autokoreliacija

26 pav. pavaizduotos signalų spektro autokoreliacijos funkcijos, gautos pritaikius autokoreliaciją CWRU duomenų bazės signalų greitos Furjė transformacijos moduliui. Vidinio žiedo riedėjimo takelio defekto klasėje pastebimi aukštesnės amplitudės periodiški maksimumai. Riedėjimo kūnų defekto, išorinio žiedo riedėjimo takelio defekto ir normalios būklės klasių autokoreliacijos reikšmės vidutiniškai mažesnės. Visų klasių grafikai persidengia, todėl sudėtinga vizualiai atskirti atskiras klases.

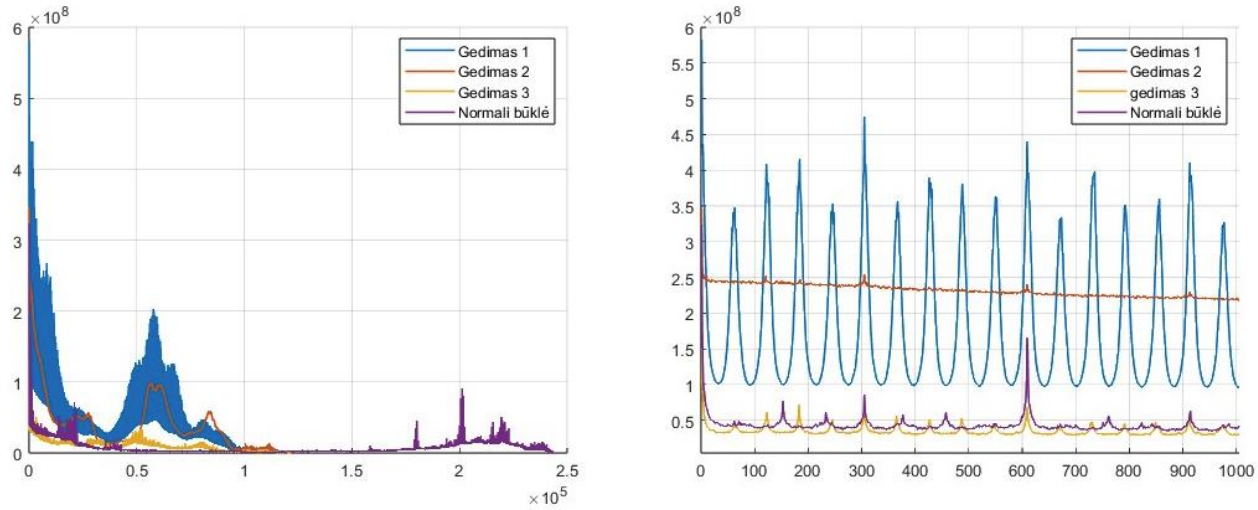

26 pav. CWRU autokoreliacijos grafikas. Gedimas 1 – vidinio žiedo riedėjimo takelio defektas; gedimas 2 – riedėjimo kūnų defektas; gedimas 3 – išorinio žiedo riedėjimo takelio defektas.

CWRU duomenų bazės duomenims pritaikius autokoreliacijos funkciją gautas mažiausias klasifikavimo tikslumas (37,5 %), lyginant su kitais analizės metodais. Didžiausias klasifikavimo tikslumas (37,5 %) pasiektas vidinio žiedo riedėjimo takelio defekto klasėje. Kaip matoma

sumaišymų matricoje, ši, kaip ir kitos defektų klasės dažniausiai klaidingai priskirtos normalios būsenos klasei.

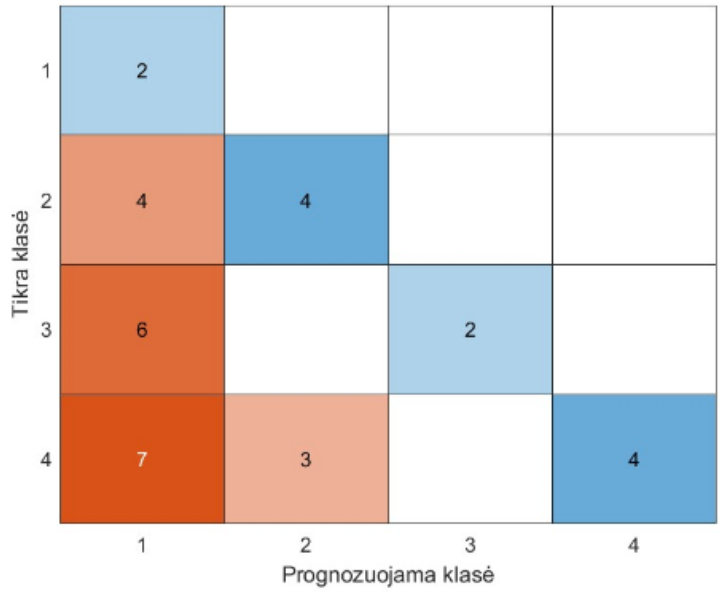

27 pav. CWRU autokoreliacijos sumaišymo matrica. Klasės: 1 – normali būsena; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – riedėjimo kūnų defektas; 4 – išorinio žiedo riedėjimo takelio defektas.

3.1.4. CNN

CNN pritaikius CWRU duomenų bazei buvo pasiektas aukštas klasifikavimo tikslumas – 99,86 %. Beveik visi signalai buvo priskirti teisingoms klasėms. Normalios būsenos ir išorinio žiedo riedėjimo takelio defekto klasės buvo atpažintos be klaidų, o riedėjimo kūnų defekto ir vidinio žiedo riedėjimo takelio defekto klasėse pasitaikė tik keli klaidingi priskyrimai. Galima teigti, kad CNN metodas CWRU duomenų bazėje atskiria normalią būseną ir skirtingus gedimų tipus beveik idealiai.

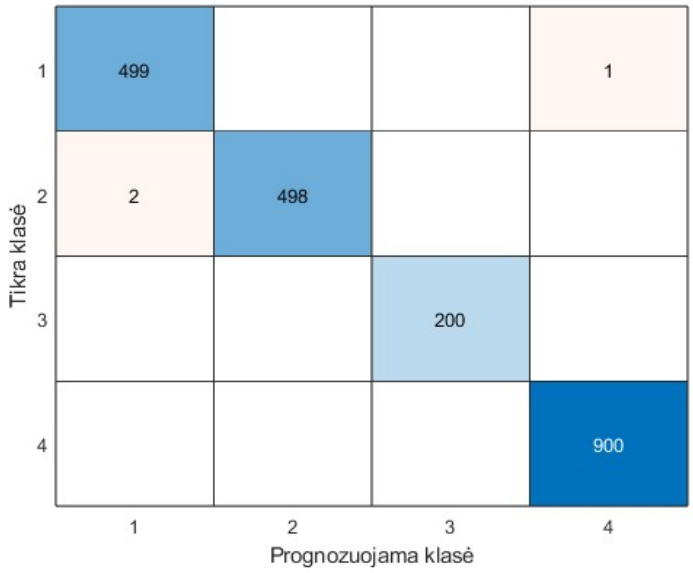

28 pav. CWRU CNN sumaišymo matrica. Klasės: 1 – riedėjimo kūnų defektas; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – normali būsena; 4 – išorinio žiedo riedėjimo takelio defektas.

3.1.5. RF

RF pritaikius CWRU duomenų bazei taip pat buvo pasiektas aukštas klasifikavimo tikslumas – 96,67 %. Normalios būsenos klasė klasifikuota be klaidų. Riedėjimo kūnų defekto klasėje pasitaikė tik kelios klaidos. Daugiausiai neteisingų priskyrimų buvo vidinio ir išorinio žiedo riedėjimo takelio defekto klasėse. Galima daryti išvadą, kad šių dviejų tipų gedimų požymiai yra panašesni ir šiuo metodu kiek sudėtingiau juos tarpusavyje atskirti. Nors šio metodo klasifikavimo tikslumas šiek tiek žemesnis, nei CNN, jis vis tiek išlieka pakankamai aukštas.

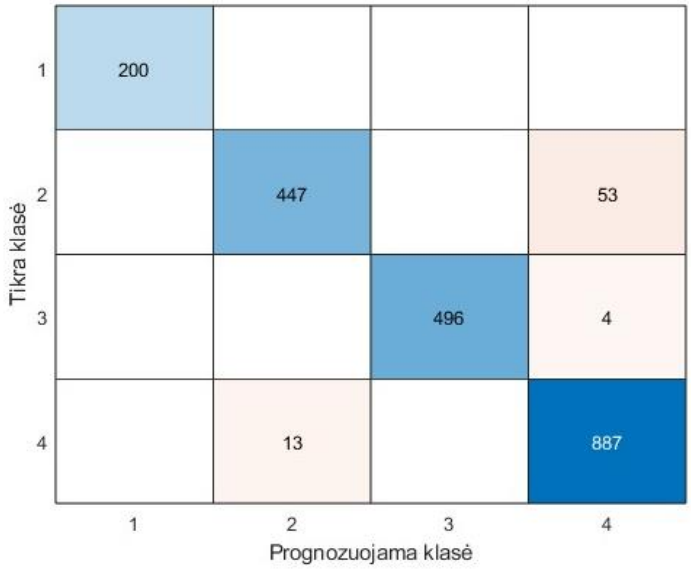

29 pav. CWRU RF sumaišymo matrica. Klasės: 1 – normali būsena; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – riedėjimo kūnų defektas; 4 – išorinio žiedo riedėjimo takelio defektas.

3.1.6. SVM

Naudojant SVM metodą CWRU duomenų bazės duomenims klasifikuoti pasiektas 95,86 % klasifikavimo tikslumas. Sumaišymo matricoje matoma, kad klasės be defektų ir vidinio žiedo riedėjimo takelio defekto klasifikuotos be klaidų. Riedėjimo kūnų defekto klasėje buvo tik keli pavieniai netikslumai. Daugiausiai neteisingai suklasifikuotų atvejų yra klasifikuojant išorinio žiedo riedėjimo takelio defekto klasėje, daugiausiai neteisingai šios klasės signalai priskiriami vidinio žiedo riedėjimo takelio defekto klasei. Galima daryti išvadą, kad šiam metodui sudėtingiau atskirti šiuos panašesnius gedimus.

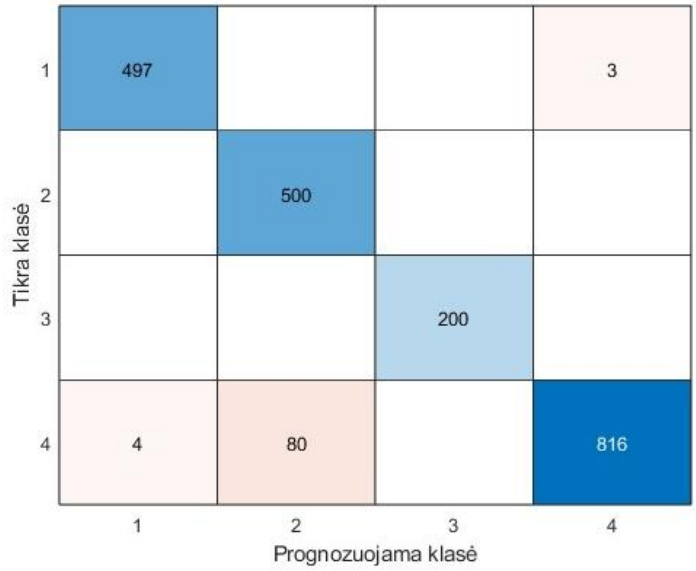

30 pav. CWRU SVM sumaišymo matrica. Klasės: 1 – riedėjimo kūnų defektas; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – normali būsena; 4 – išorinio žiedo riedėjimo takelio defektas.

3.1.7. KNN

Tiriant klasifikavimo metodus su CWRU duomenų baze žemiausias klasifikavimo tikslumas (85,81 %) gautas KNN metodu. Šiuo atveju daugiausia neteisingai priskirtų signalų gauta riedėjimo kūnų defekto klasėje. Ši klasė buvo maišoma su kitų gedimų – išorinio ir vidinio žiedo riedėjimo takelio defektų klasėmis. Nors vidinio žiedo riedėjimo takelio defektų klasė klasifikuojama beveik idealiai, kitose klasėse klaidų pasitaiko daugiau. Atsižvelgiant į tai galima teigti, kad šis metodas, lyginant su kitais nagrinėtais, prasčiausiai klasifikuoja skirtingas gedimų klases.

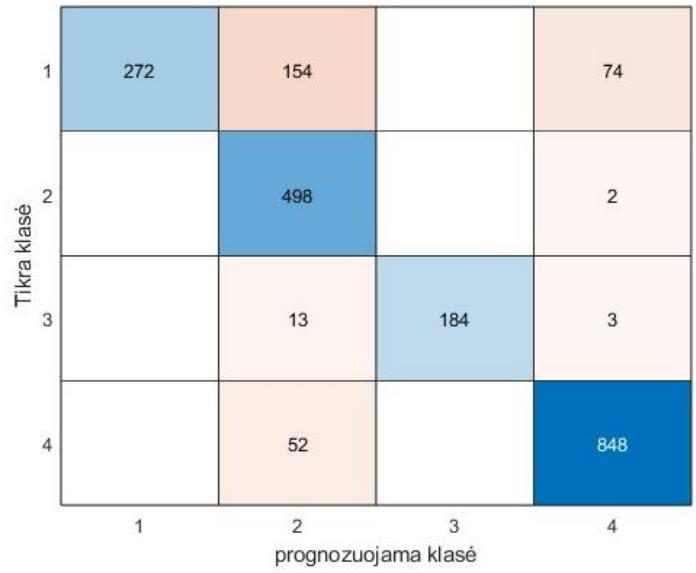

31 pav. CWRU KNN sumaišymo matrica. Klasės: 1 – riedėjimo kūnų defektas; 2 – vidinio žiedo riedėjimo takelio defektas; 3 – normali būsena; 4 – išorinio žiedo riedėjimo takelio defektas.

3.1.8. Apibendrinimas

CWRU duomenų bazės atveju, išskyrus informatyvius požymius iš dažninės analizės metodais gautų grafikų, gauti klasifikavimo rezultatai nėra pakankamai tikslūs. Didžiausias klasifikavimo tikslumas (62,5 %) buvo gautas iš kepstro funkcijos. Pasiektas 18,75 procentinio punkto aukštesnis klasifikavimo tikslumas, nei signalo laiko srityje. Taip pat, lyginant su signalo laiko srityje rezultatais, klasifikavimo tikslumą pavyko pakelti požymių iš spektro funkcijos grafiko atveju. Pasiektas 3,13 procentinio punkto aukštesnis klasifikavimo tikslumas. Autokoreliacijos metodu šiuo atveju pasiektas 6,25 procentinio punkto žemesnis klasifikavimo tikslumas, nei signalo laiko srityje atveju. Sumaišymo matricose matomas dažnas riedėjimo kūnų defekto ir išorinio žiedo riedėjimo takelio defekto klaidingas priskyrimas normalios būsenos ir vidinio žiedo riedėjimo takelio defekto klasėms. Normalios būsenos klasės duomenų taškų buvo per mažai, kad būtų galima patikimai įvertinti šios klasės klasifikavimo rezultatus.

Visi nagrinėti mašininio mokymosi metodai gali pakankamai tiksliai atskirti skirtingas gedimų ar normalios būsenos klases šioje CWRU duomenų bazėje, tačiau jų klasifikavimo tikslumas skiriasi. Didžiausias klasifikavimo tikslumas (99,86 %) pasiektas naudojant CNN metodą. RF metodo klasifikavimo tikslumas žemesnis 3,19 procentinio punkto, nei CNN. SVM metodo klasifikavimo tikslumas žemesnis 4 procentiniais punktais, nei CNN. Šiais dviem metodais daugiausia neteisingų priskyrimų buvo klasifikuojant vidinio ir išorinio žiedo riedėjimo takelio defekto klases. Prasčiausi rezultatai – 85,81 % klasifikavimo tikslumas (kas yra 14,05 procentinio punkto žemiau nei CNN) buvo pasiekti KNN metodu. Čia aiškiausiai išsiskyrė klaidos klasifikuojant riedėjimo kūnų defekto klasėje. Atsižvelgiant į visų nagrinėtų metodų rezultatus su šia duomenų baze, galima daryti išvadą, kad šioje duomenų bazėje skirtingos klasės turi pakankamai aiškiai išreikštus požymius. Dėl to šiuo atveju CNN, RF ir SVM metodai leido pasiekti aukštą klasifikavimo tikslumą.

3.2. MaFaulDa rezultatai

Šiame skyriuje analizuojami skirtingais klasifikavimo metodais gauti rezultatai naudojant duomenis iš MaFaulDa mašinų gedimų simuliatoriaus lygiavimo ir balansavimo vibracijos treniruoklio duomenų bazės. Laiko srities signalų, spektro, kepstro ir autokoreliacijos metodų klasifikavimo tikslumui įvertinti naudota 144 testavimo pavyzdžių imtis. CNN, RF, SVM ir KNN metodų klasifikavimo tikslumui įvertinti naudota 29400 testavimo pavyzdžių imtis.

32 pav. pavaizduoti MaFaulDa duomenų bazės signalai laiko srityje. Paveiksle matoma, kad gedimo signalo amplitudės pikai vietomis aukštesni, lyginant su normalios būklės signalo pikais. Nepaisant to, signalai per daug persidengę tarpusavyje, kad būtų galima atskirti skirtingų klasių signalus.

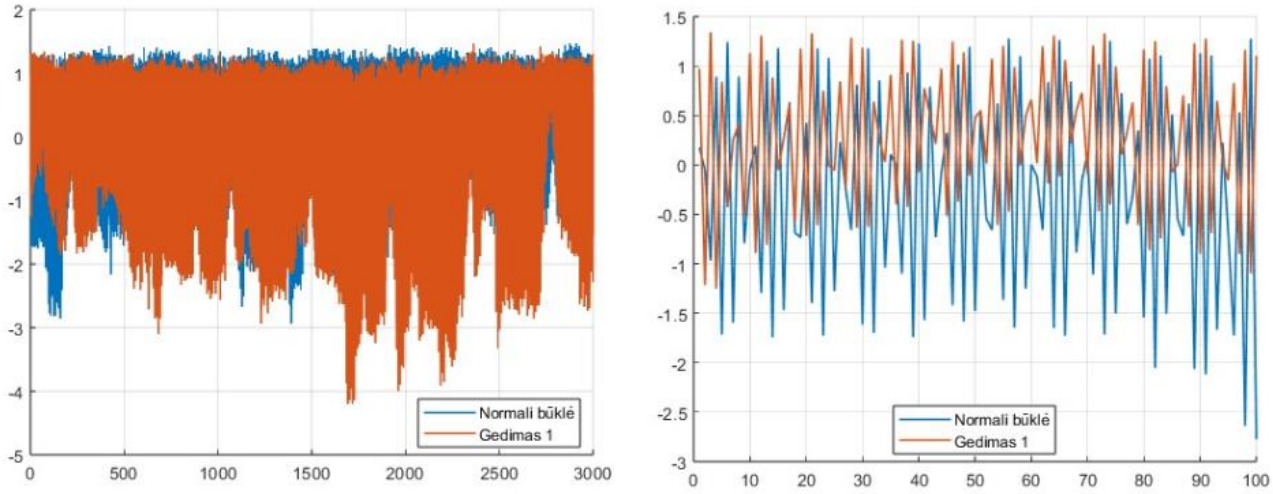

32 pav. MaFaulDa vibracijos signalų laiko srityje grafikas. Gedimas 1 – 0,5 mm horizontalus ašies nesutapimas.

Naudojant iš vibracijos signalo grafiko išskirtus požymius gautas 18,06 % klasifikavimo tikslumas. Visi disbalanso klasės duomenų taškai priskirti klaidingai. Sumaišymo matricoje matomas didelis persidengimas tarp skirtingų klasių. Normalios būsenos, disbalanso, horizontalaus ir vertikalaus ašies nesutapimo klasės klasifikuojamos labai netiksliai (0-12,5 % tikslumu). Didžiausi klasifikavimo tikslumai pasiekti guolio už rotoriaus (33,33 % tikslumas) ir guolio tarp variklio ir rotoriaus (45,83 % tikslumas) gedimų klasėse.

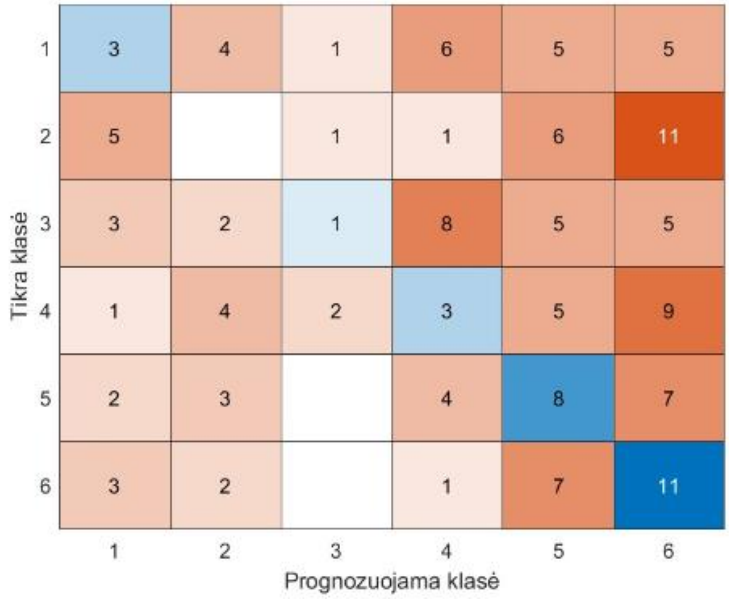

33 pav. MaFaulDa vibracijos signalų laiko srityje sumaišymo matrica. Klasės: 1 – normali būsena; 2 – disbalansas; 3 – horizontalus ašies nesutapimas; 4 – vertikalus ašies nesutapimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – guolio už rotoriaus gedimas.

3.2.1. Spektras

34 pav. pavaizduoti signalų spektrai, gauti pritaikius diskrečiąją Furjė transformaciją MaFaulDa duomenų bazės signalams. Matoma, kad normalios būklės signalo spektras turi aukštesnę amplitudę ties aukštesniais dažniais, tačiau gedimo signalo spektras turi daugiau aiškiai išreikštų pikų platesnėje dažnių juostos dalyje.

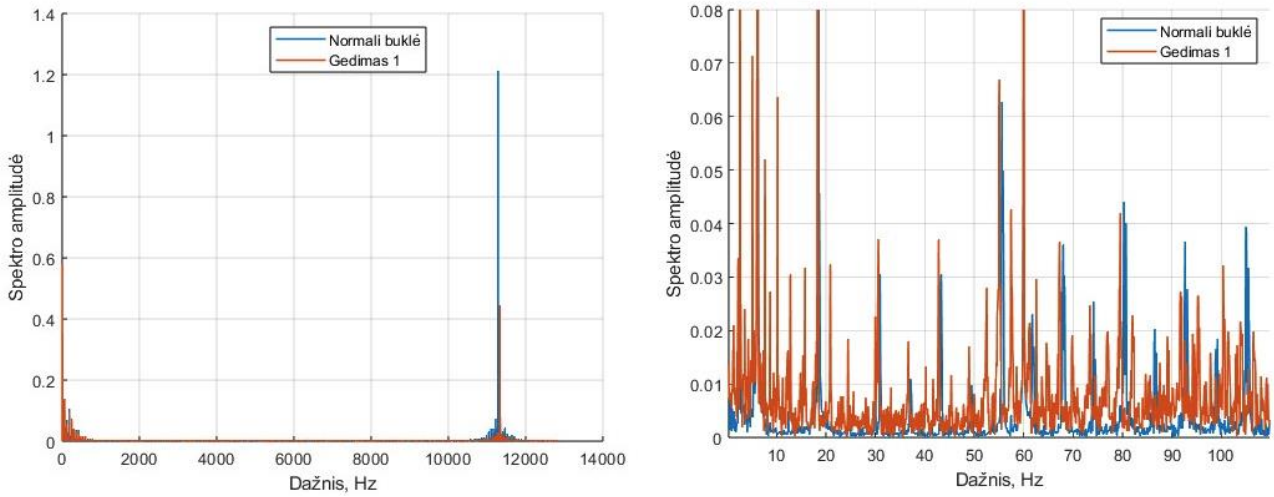

34 pav. MaFaulDa spektro grafikas. Gedimas 1 – 0,5 mm horizontalus ašies nesutapimas.

MaFaulDa duomenų bazės duomenims pritaikius spektro funkciją gautas 31,25 % klasifikavimo tikslumo rezultatas. Tai yra 13,19 procentinio punkto aukštesnis tikslumas lyginant su signalo laiko srityje klasifikavimo rezultatu. Tiksliausiai klasifikuota horizontalaus ašies nesutapimo klasė – tik vienas duomenų taškas priskirtas neteisingai klasei. Ypač daug persidengimo atvejų disbalanso, vertikalaus ašies nesutapimo ir guolio tarp variklio ir rotoriaus gedimo klasėse. Šios klasės dažniausiai maišytos su disbalanso ir horizontalaus ašies nesutapimo klasėmis.

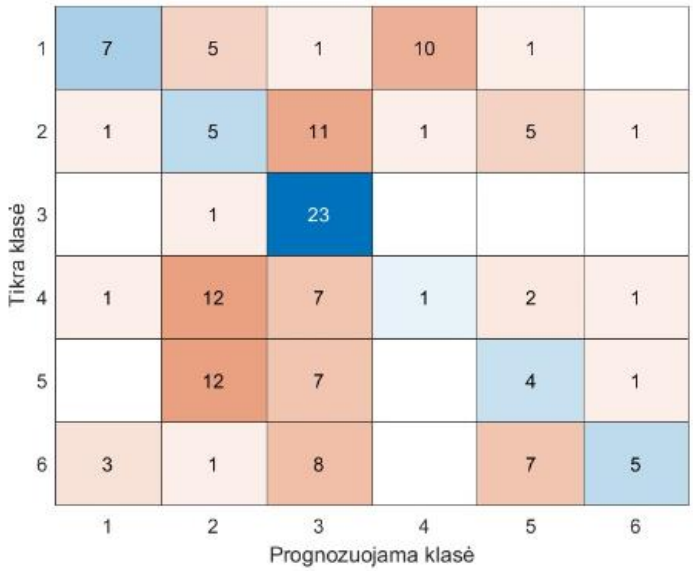

35 pav. MaFaulDa spektro sumaišymo matrica. Klasės: 1 – normali būsena; 2 – disbalansas; 3 – horizontalus ašies nesutapimas; 4 – vertikalus ašies nesutapimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – guolio už rotoriaus gedimas.

3.2.2. Kepstras

36 pav. pavaizduotos signalų kepstro funkcijos, gautos skaičiuojant logaritminio amplitudės spektro atvirkštinę Furjė transformaciją MaFaulDa duomenų bazės signalams. Paveiksle matoma, kad kreivės labai arti viena kitos ir vizualiai išskirti skirtingas klases sudėtinga.

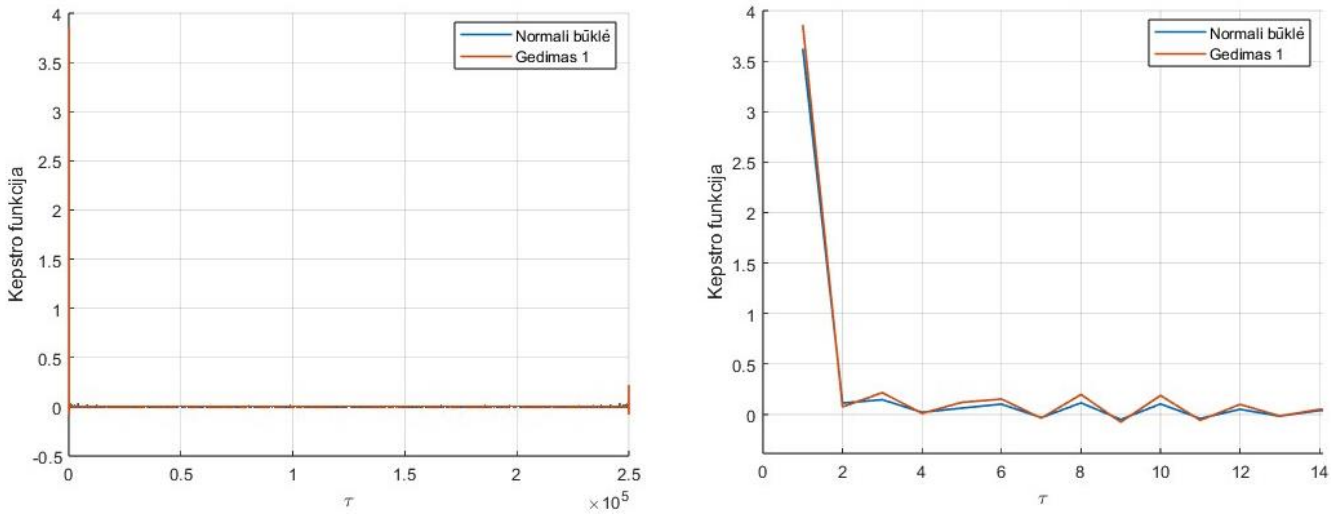

36 pav. MaFaulDa kepstro grafikas. Gedimas 1 – 0,5 mm horizontalus ašies nesutapimas.

MaFaulDa duomenų bazės duomenims pritaikius kepstro funkciją gautas 29,17 % klasifikavimo tikslumo rezultatas. Tai geresnis rezultatas lyginant su signalu laiko srityje, tačiau 2,08 procentinio punkto mažesnis tikslumas lyginant su spektro funkcijos klasifikavimo rezultatu. Geriausiai atskirtos normalios būsenos, vertikalaus ašies nesutapimo ir guolio už rotoriaus gedimo klasės. Nei vienas disbalanso ir guolio tarp variklio ir rotoriaus gedimo duomenų taškas nebuvo priskirtas teisingai klasei.

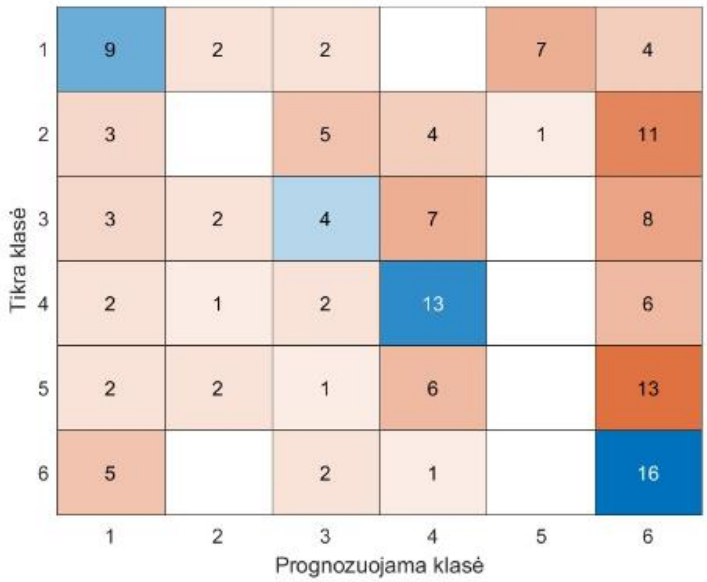

37 pav. MaFaulDa kepstro sumaišymo matrica. Klasės: 1 – normali būsena; 2 – disbalansas; 3 – horizontalus ašies nesutapimas; 4 – vertikalus ašies nesutapimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – guolio už rotoriaus gedimas.

3.2.3. Autokoreliacija

38 pav. pavaizduotos signalų spektro autokoreliacijos funkcijos, gautos pritaikius autokoreliaciją MaFaulDa duomenų bazės signalų greitos Furjė transformacijos moduliui. Matoma, kad gedimo klasės autokoreliacijos reikšmės išlieka didesnės ilgesniame intervale, taip pat pasiekia aukštesnes autokoreliacijos pikų reikšmes, lyginant su normalios būklės klase.

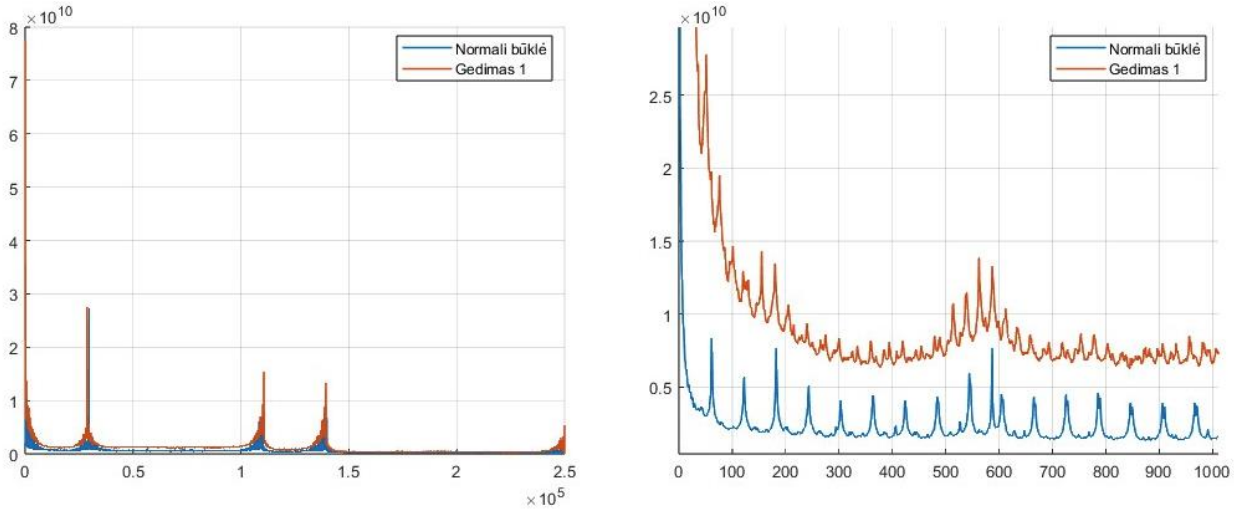

38 pav. MaFaulDa autokoreliacijos grafikas. Gedimas 1 – 0,5 mm horizontalus ašies nesutapimas.

Naudojant MaFaulDa duomenų bazės duomenis didžiausias klasifikavimo tikslumas (38,19 %) pasiektas pritaikius spektro moduliui autokoreliacijos funkciją. Tai 20,13 procentinio punkto didesnis tikslumas lyginant su signalo laiko srityje rezultatu. Sumaišymo matricoje matoma, kad prasčiausiai atskiriama disbalanso klasė – didžiausia dalis jos duomenų taškų priskiriama horizontalaus ašies nesutapimo klasei. Daugiausiai teisingų priskyrimų buvo horizontalaus ašies nesutapimo (58,33 % klasifikavimo tikslumas) ir vertikalaus ašies nesutapimo (62,5 % klasifikavimo tikslumas) klasėse.

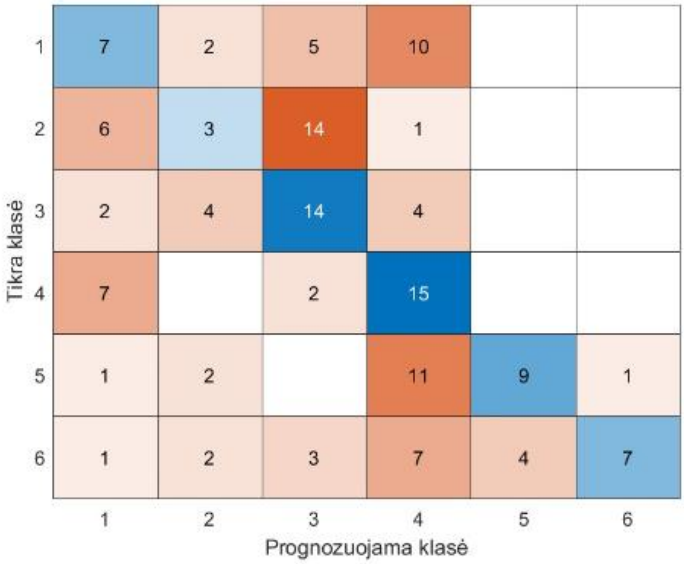

39 pav. MaFaulDa autokoreliacijos sumaišymo matrica. Klasės: 1 – normali būsena; 2 – disbalansas; 3 – horizontalus ašies nesutapimas; 4 – vertikalus ašies nesutapimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – guolio už rotoriaus gedimas.

3.2.4. CNN

MaFaulDa duomenų bazei pritaikius CNN buvo pasiektas 90,9 % klasifikavimo tikslumas. Beveik visi signalai buvo priskirti teisingoms klasėms. Dauguma klasių atpažinta pakankamai tiksliai, tačiau neteisingų priskyrimų visose klasėse daugiau, lyginant su CWRU duomenų baze. Didžiausiu tikslumu klasifikuotos guolio už rotoriaus gedimo ir guolio tarp variklio ir rotoriaus gedimo klasės. Sumaišymo matricoje taip pat matoma, kad daugiausiai neteisingo klasifikavimo atvejų yra horizontalaus ašies nesutapimo ir disbalanso klasės. Jos daugiausiai neteisingai priskiriamos vertikalaus ašių nesutapimo klasei. Taip pat pakankamai daug atvejų, kai disbalanso klasė klasifikuojama kaip normalios būsenos klasė. Iš to galima daryti išvadą, kad šios klasės tarpusavyje pakankamai panašios, nes jas sunkiau atskiria net CNN.

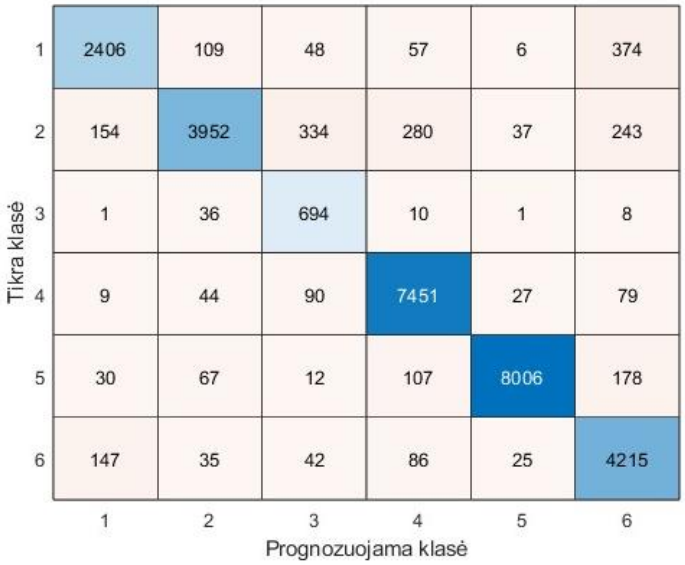

40 pav. MaFaulDa CNN sumaišymo matrica. Klasės: 1 – horizontalus ašies nesutapimas; 2 – disbalansas; 3 – normali būsena; 4 – guolio už rotoriaus gedimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – vertikalus ašies nesutapimas.

3.2.5. RF

Lyginant su CNN, RF su MaFaulDa duomenų baze pasiektas žemesnis klasifikavimo tikslumas – 80,91 %. Sumaišymo matricoje matoma, kad guolio už rotoriaus gedimo ir guolio tarp variklio ir rotoriaus gedimo klasės kaip ir CNN atpažintos pakankamai tiksliai, tačiau kitose klasėse daugiau klasifikavimo klaidų. Žemiausiu tikslumu klasifikuota horizontalaus ašies nesutapimo klasė, kuri buvo labiausiai maišyta su disbalanso ir vertikalaus ašies nesutapimo klasėmis. Taip pat sumaišymų matricoje galima matyti, jog normalios būsenos klasė beveik visada neteisingai priskirta gedimų klasėms, kas reiškia, kad metodas šiuo atveju nėra tinkamas taikyti sistemos gedimų diagnostikai.

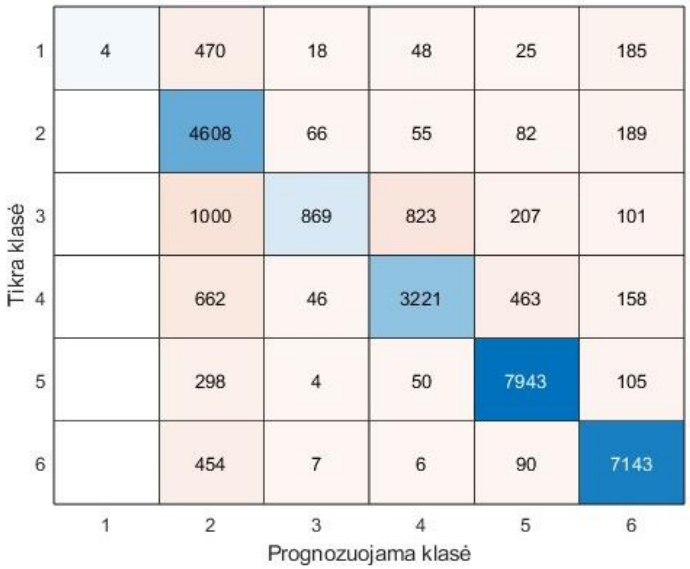

41 pav. MaFaulDa RF sumaišymo matrica. Klasės: 1 – normali būsena; 2 – disbalansas; 3 – horizontalus ašies nesutapimas; 4 – vertikalus ašies nesutapimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – guolio už rotoriaus gedimas.

3.2.6. SVM

MaFaulDa duomenų bazei pritaikius SVM metodą pasiektas 87,8 % klasifikavimo tikslumas. Tai didesnis tikslumas nei buvo pasiektas su RF, bet mažesnis už CNN rezultatą. Sumaišymo matricoje matoma, kad pakankamai tiksliai klasifikuotos guolio už rotoriaus gedimo, guolio tarp variklio ir rotoriaus gedimo ir disbalanso klasės. Kaip ir su kitais metodais, dažniausiai tarpusavyje buvo sumaišytos horizontalaus ašies nesutapimo ir vertikalaus ašies nesutapimo klasės. Normalios būsenos klasifikavimo tikslumas aukštesnis nei RF atveju, tačiau vis tiek žemas.

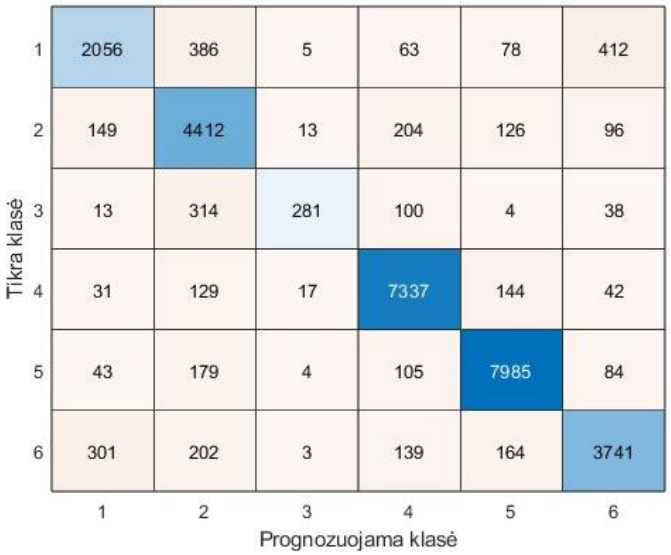

42 pav. MaFaulDa SVM sumaišymo matrica. Klasės: 1 – horizontalus ašies nesutapimas; 2 – disbalansas; 3 – normali būsena; 4 – guolio už rotoriaus gedimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – vertikalus ašies nesutapimas.

3.2.7. KNN

Mažiausias tikslumas (65,91 %), kaip ir CWRU duomenų bazės atveju buvo pasiektas KNN metodu. Sumaišymo matricoje matoma, kad tiksliausiai čia klasifikuotos disbalanso, guolio už rotoriaus gedimo ir guolio tarp variklio ir rotoriaus gedimo klasės. Kaip ir kituose metoduose, dažniausiai tarpusavyje buvo sumaišytos horizontalaus ašies nesutapimo ir vertikalaus ašies nesutapimo klasės. Normalios būsenos klasifikavimo tikslumas taip pat labai žemas.

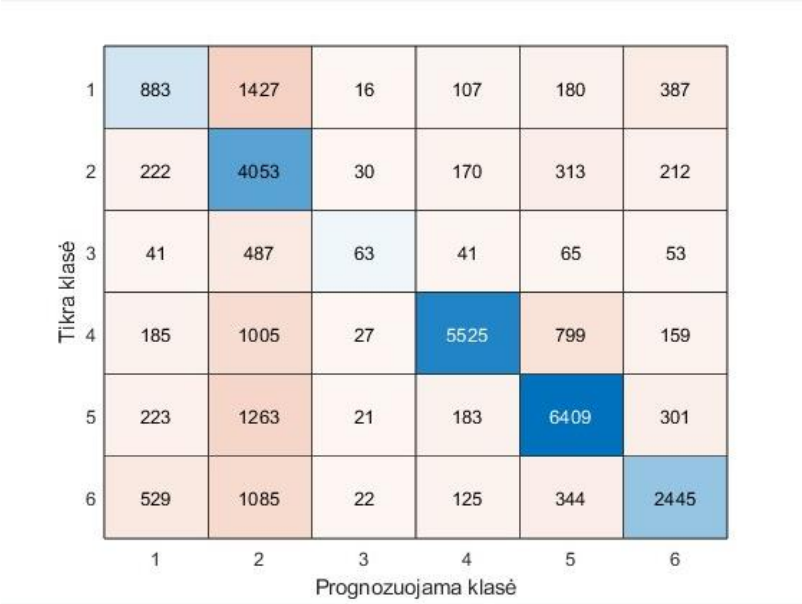

43 pav. MaFaulDa KNN sumaišymo matrica. Klasės: 1 – horizontalus ašies nesutapimas; 2 – disbalansas; 3 – normali būsena; 4 – guolio už rotoriaus gedimas; 5 – guolio tarp variklio ir rotoriaus gedimas; 6 – vertikalus ašies nesutapimas.

3.2.8. Apibendrinimas

MaFaulDa duomenų bazės atveju, išskyrus informatyvius požymius iš dažninės analizės metodais gautų grafikų, gauti klasifikavimo rezultatai nėra pakankamai tikslūs. Lyginant su signalo laiko srityje klasifikavimo tikslumu, rezultatas buvo pagerintas ir spektro, ir kepstro, ir autokoreliacijos metodu. Spektro funkcijos atveju, klasifikavimo tikslumas padidintas 13,19 procentinio punkto. Kepstro funkcijos atveju gautas 2,08 procentinio punkto žemesnis klasifikavimo tikslumas, nei klasifikuojant iš spektro funkcijos gautus požymius. Aukščiausias klasifikavimo tikslumas (38,19 %) pasiektas klasifikuojant autokoreliacijos funkcijos požymius. Sumaišymo matricose matoma, kad daugiausiai klasifikavimo klaidų visais metodais pasitaikė disbalanso klasėje.

Lyginant su CWRU duomenų bazės duomenimis, analizuojant MaFaulDa duomenis visais mašininio mokymosi metodais pasiekti žemesni klasifikavimo tikslumo lygiai. Kaip ir CWRU duomenų bazės atveju, su MaFaulDa duomenų baze geriausias klasifikavimo tikslumo rezultatas (90,9 %) buvo pasiektas CNN metodu. Skirtingai nei CWRU, su SVM buvo pasiektas 6,89 procentinio punkto geresnis rezultatas, nei RF. Analizuojant sumaišymo matricas akivaizdu, kad dažniausiai tarpusavyje buvo maišomos horizontalaus ir vertikalaus ašies nesutapimo bei disbalanso klasės. Taip pat daug neteisingo normalios būsenos klasės priskyrimo atvejų. KNN metodu buvo gautas žemiausias klasifikavimo tikslumo rezultatas – 65,91 %. Ten ypač dideli neteisingų priskyrimų skaičiai tarp panašių klasių ir normalios būsenos klasės. Iš to galima daryti išvadą, kad MaFaulDa duomenų bazėje

skirtingų būsenų signalai yra labiau tarpusavyje panašūs vieni į kitus, lyginant su CWRU duomenų baze. Dėl to klasifikavimas yra sudėtingesnis ir net efektyvesniais metodais sunkiau gauti aukštą klasifikavimo tikslumą.

3.3. KTU laboratorijos eksperimento rezultatai

Šiame skyriuje analizuojami skirtingais klasifikavimo metodais gauti rezultatai naudojant duomenis iš laboratorijos eksperimento, kuriame variklio vibracijos signalai matuoti prie skirtingų variklio apkrovų. Laiko srities signalų, spektro, kepstro ir autokoreliacijos metodų klasifikavimo tikslumui įvertinti naudota 50 testavimo pavyzdžių imtis. CNN, RF, SVM ir KNN metodų klasifikavimo tikslumui įvertinti naudota 280 testavimo pavyzdžių imtis.

44 pav. pavaizduoti laboratorijos eksperimento signalai laiko srityje. Paveiksle matoma, kad aukščiausiomis amplitudėmis išsiskiria „apkrova 5“ klasė. Visų klasių signalai yra skirtingo periodiškumo ir daugelyje vietų persidengia tarpusavyje.

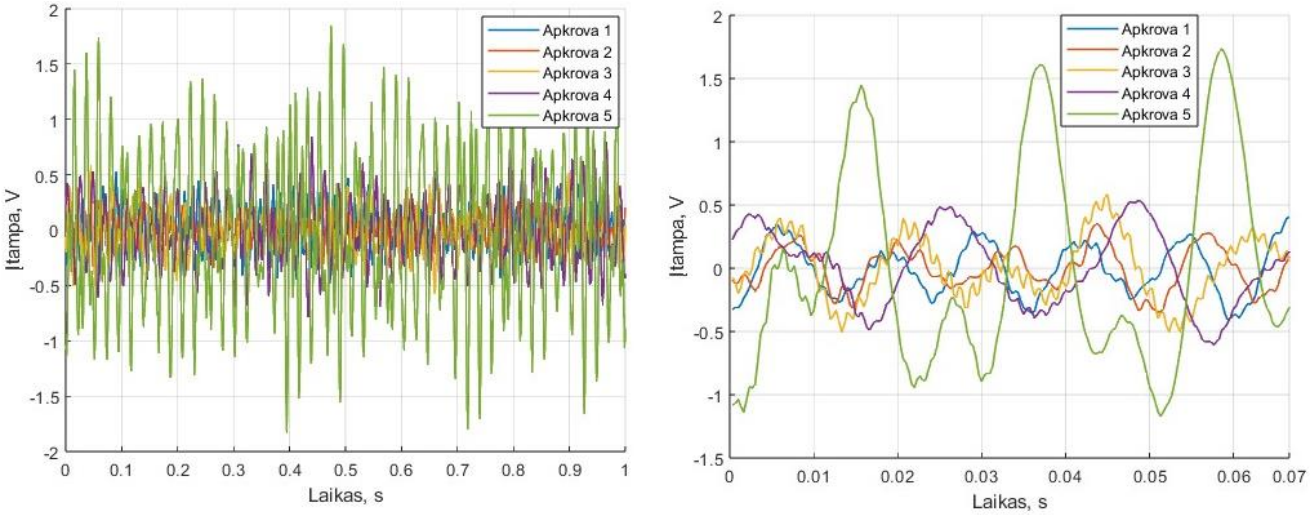

44 pav. KTU laboratorijos eksperimento vibracijos signalų laiko srityje grafikas.

Naudojant iš vibracijos signalo grafiko išskirtus požymius gautas 26 % klasifikavimo tikslumas. Daugiausiai klasifikavimo klaidų pasitaikė, kai „apkrova 1“ ir „apkrova 2“ klasės priskiriamos „apkrova 3“ ir „apkrova 4“ klasėms. Taip pat sunkiai atskiriama „apkrova 4“ klasė, ji dažniausiai klaidingai priskirta „apkrova 3“ ir „apkrova 5“ klasėms.

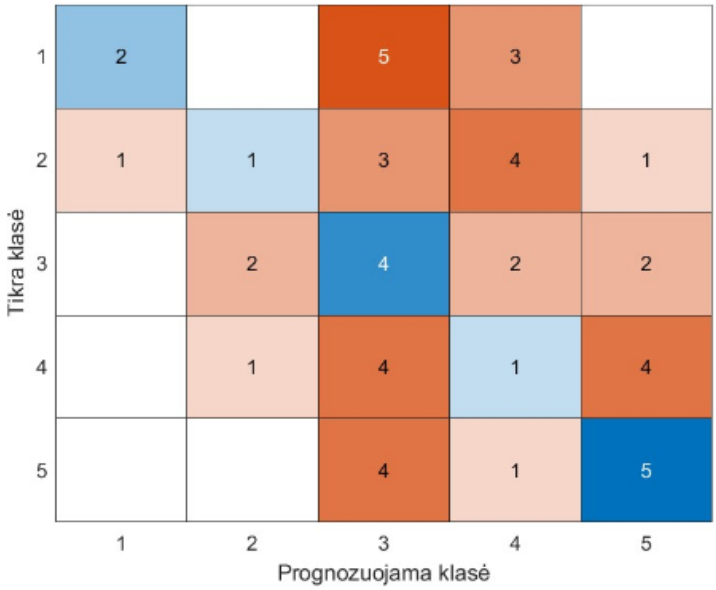

45 pav. KTU laboratorijos eksperimento vibracijos signalų laiko srityje sumaišymo matrica.

3.3.1. Spektras

46 pav. pavaizduoti signalų spektrai, gauti pritaikius diskrečiąją Furjė transformaciją laboratorijos eksperimento signalams. Matoma, kad skirtingos klasės nevienodai pasiskirsčiusios dažnių juostos plotyje. Visose klasėse matoma, kad didesnės amplitudės daugiausiai koncentruotos žemų dažnių srityje.

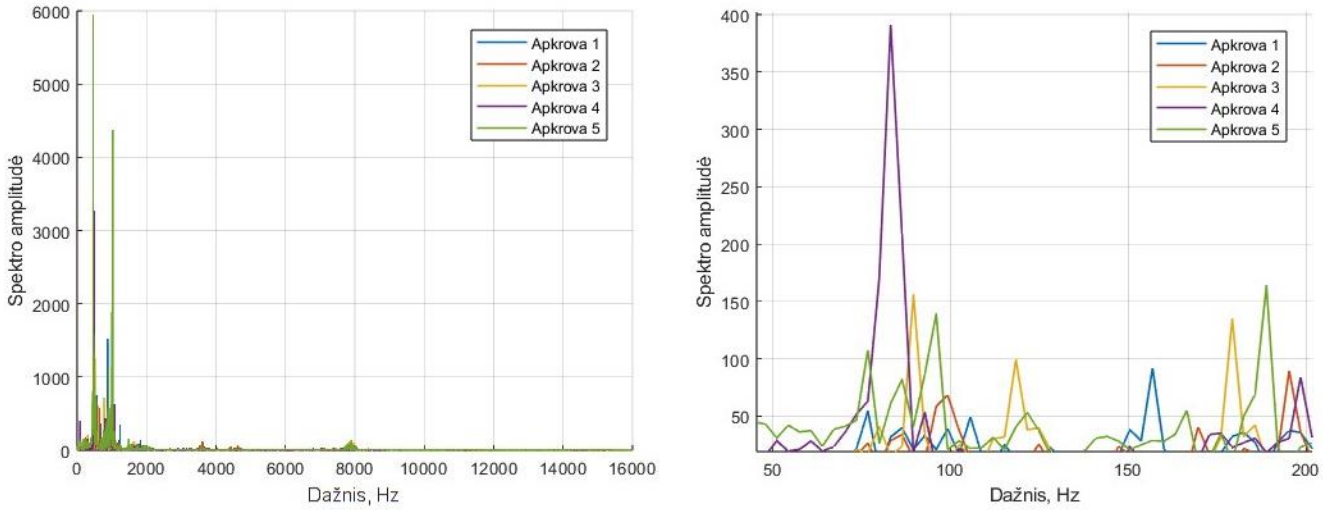

46 pav. KTU laboratorijos eksperimento spektro grafikas.

Laboratorijos eksperimento duomenims pritaikius spektro funkciją gautas 50 % klasifikavimo tikslumo rezultatas. Tai yra 24 procentiniais punktais aukštesnis tikslumas lyginant su signalo laiko srityje klasifikavimo rezultatu. Klasifikuojant „apkrova 1“ ir „apkrova 2“ klases modelis padarė tik po 1 klaidą. „apkrova 5“ klasės klasifikavimo tikslumas 50 %. Sunkiausiai klasifikuotos „apkrova 3“ ir „apkrova 4“ klasės. „apkrova 4“ klasėje tik 2 teisingi klasifikavimo atvejai iš 10, o „apkrova 3“ klasės visi duomenų taškai priskirti neteisingoms klasėms.

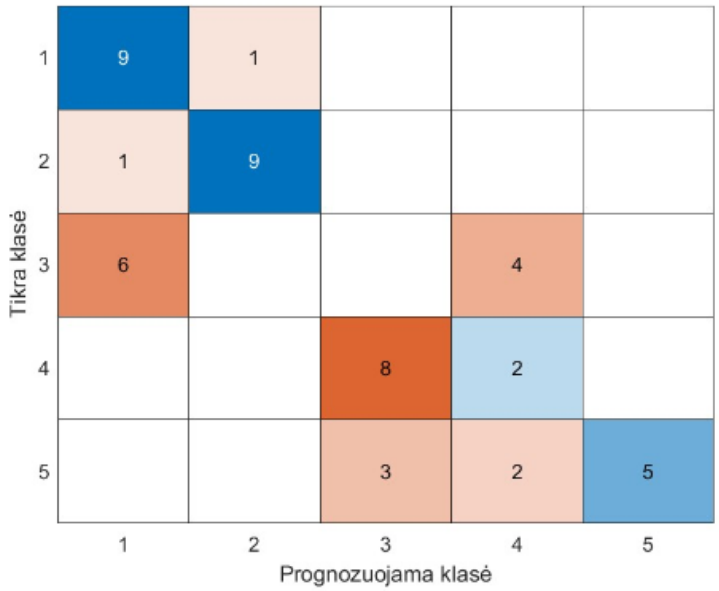

47 pav. KTU laboratorijos eksperimento spektro sumaišymo matrica.

3.3.2. Kepstras

48 pav. pavaizduotos signalų kepstro funkcijos, gautos skaičiuojant logaritminio amplitudės spektro atvirkštinę Furjė transformaciją laboratorijos eksperimento signalams. Paveiksle matoma, kad kreivės labai arti viena kitos ir vizualiai išskirti skirtingas klases sudėtinga.

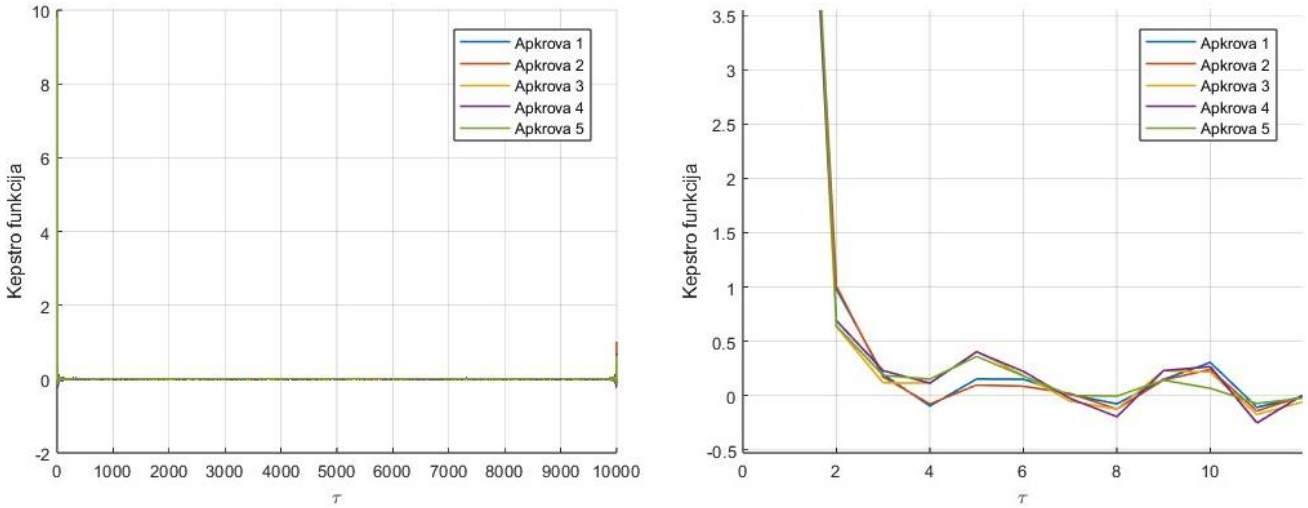

48 pav. KTU laboratorijos eksperimento kepstro grafikas.

Laboratorijos eksperimento duomenims pritaikius kepstro funkciją gautas 56 % klasifikavimo tikslumo rezultatas. Tai yra 6 procentiniais punktais aukštesnis tikslumas lyginant su spektro funkcijos klasifikavimo rezultatu. Mažiausiai tiksliai šiuo atveju klasifikuotos „apkrova 1“ ir „apkrova 2“ klasės. „apkrova 1“ klasė dažniausiai klaidingai priskirta „apkrova 2“ klasei, o „apkrova 2“ klasė dažniausiai klaidingai priskirta „apkrova 4“ klasei.

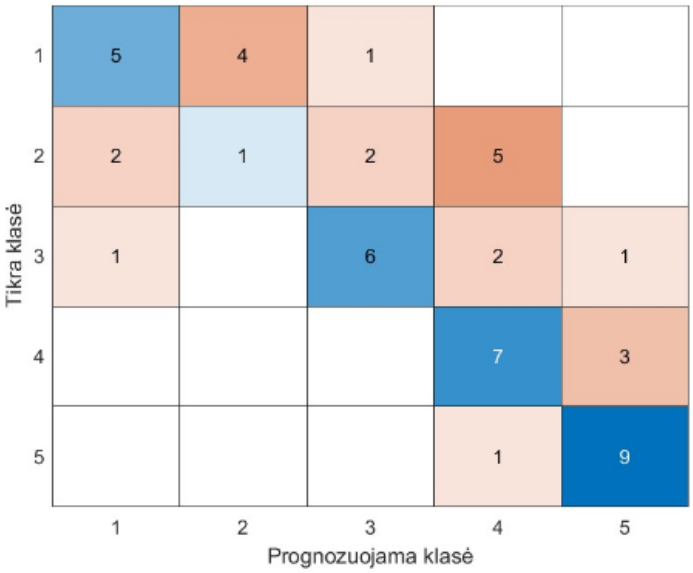

49 pav. KTU laboratorijos eksperimento kepstro sumaišymo matrica.

3.3.3. Autokoreliacija

50 pav. pavaizduotos signalų spektro autokoreliacijos funkcijos, gautos pritaikius autokoreliaciją laboratorijos eksperimento signalų greitos Furjė transformacijos moduliui. Vizualiai aiškiausiai išsiskiria „apkrova 5“ klasė. Jos grafikas pasižymi didžiausiomis autokoreliacijos reikšmėmis. „apkrova 1“, „apkrova 2“ ir „apkrova 3“ klasės vizualiai labai arti viena kitos, sunkiai atskiriamos viena nuo kitos. Aukštesnėmis autokoreliacijos reikšmėmis nuo jų labiau atsiskiria „apkrova 4“ klasė.

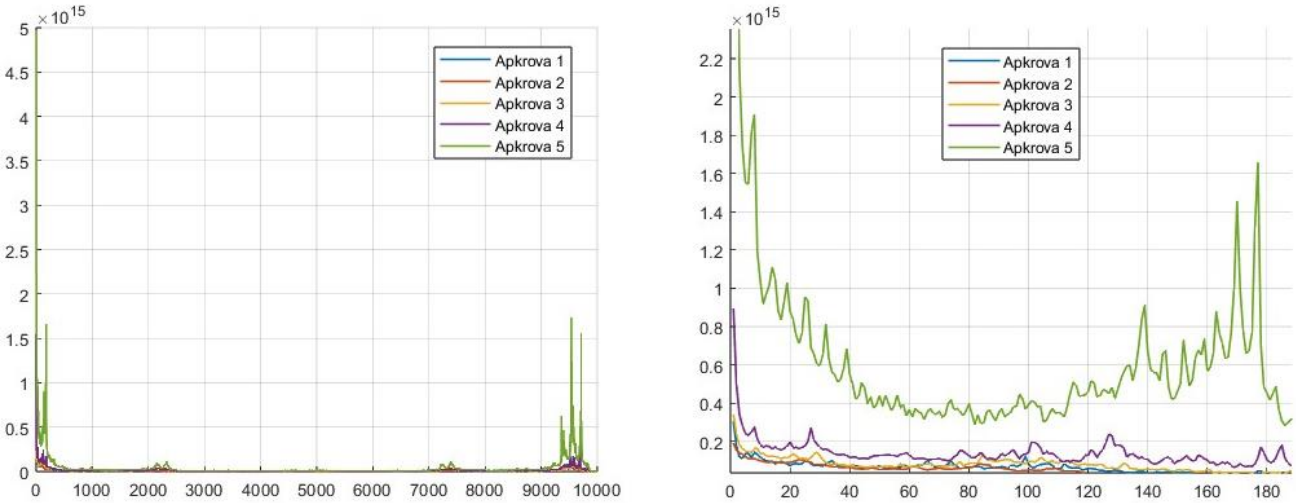

50 pav. KTU laboratorijos eksperimento autokoreliacijos grafikas.

Naudojant laboratorijos eksperimento duomenis didžiausias klasifikavimo tikslumas (94 %) pasiektas pritaikius spektro moduliui autokoreliacijos funkciją. Dvi klasifikavimo klaidos pasitaikė, kai „apkrova 3“ klasės duomenų taškai priskirti „apkrova 1“ klasei ir viena klaida „apkrova 5“ klasę

priskyrus „apkrova 4“ klasei. „apkrova 1“, „apkrova 2“ ir „apkrova 4“ klasės duomenų taškai priskirti tikroms klasėms be klaidų.

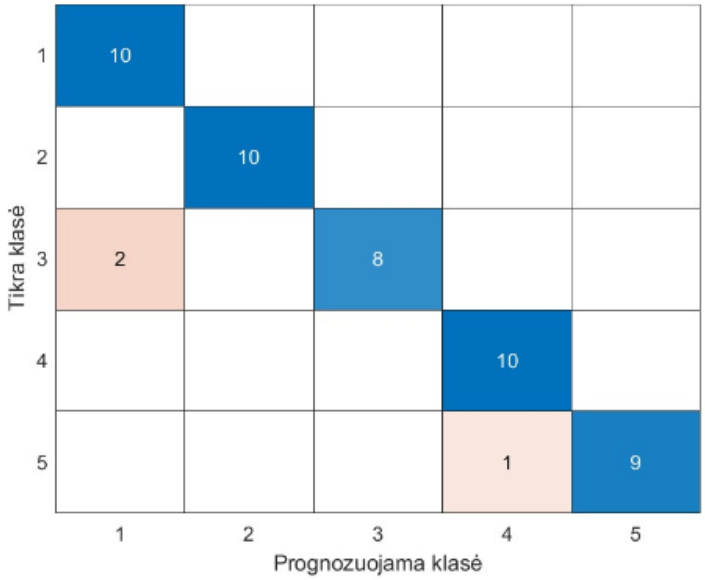

51 pav. KTU laboratorijos eksperimento autokoreliacijos sumaišymo matrica.

3.3.4. CNN

CNN pritaikius laboratorijos eksperimento duomenims buvo pasiektas aukštas klasifikavimo tikslumas – 99,64 %. Sumaišymo matricoje matoma, kad vienintelė pasitaikiusi klaida buvo priskyrus „apkrova 2“ klasę „apkrova 1“ klasei. Visos kitos klasės atskirtos be klaidų. Šiuo atveju skirtingų būsenų klasės yra lengvai atskiriamos ir CNN gali jas efektyviai atskirti beveik be klaidų.

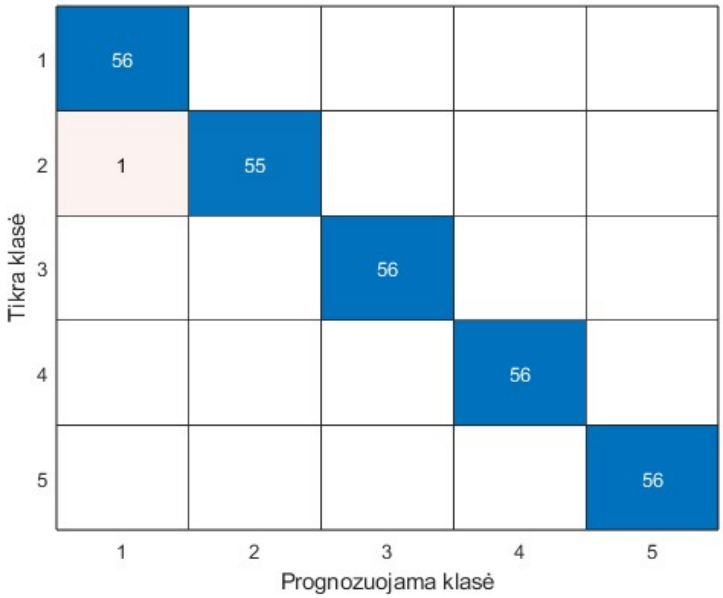

52 pav. KTU laboratorijos eksperimento CNN sumaišymo matrica.

3.3.5. RF

RF pritaikius laboratorijos eksperimento duomenims buvo pasiektas 95,71 % klasifikavimo tikslumas. Nors tai žemesnis rezultatas, nei CNN, tačiau bendras tikslumo lygis vis tiek aukštas. Sumaišymo matricoje matoma, kad yra tik 11 neteisingų „apkrova 2“ klasės priskyrimų „apkrova 1“ klasei ir vienintelis neteisingas „apkrova 4“ klasės priskyrimas „apkrova 5“ klasei. Nepaisant to, RF modelis atskyrė didžiąją dalį klasių teisingai.

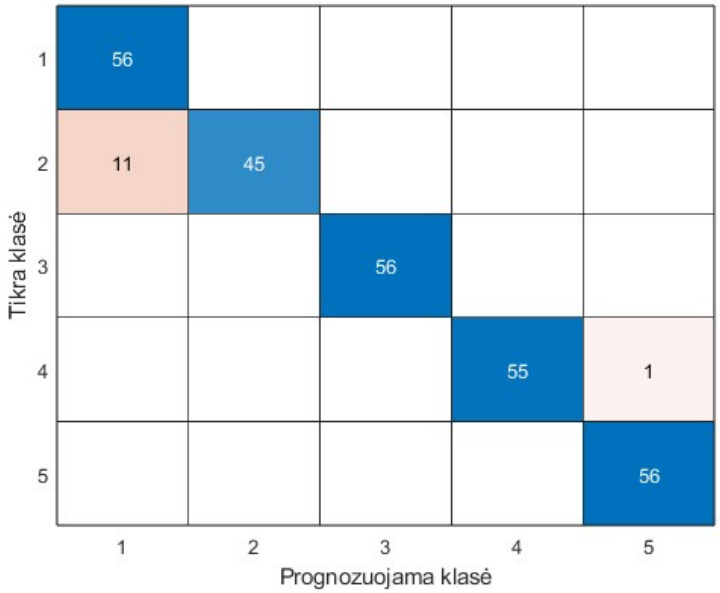

53 pav. KTU laboratorijos eksperimento RF sumaišymo matrica.

3.3.6. SVM

SVM metodu su laboratorijos eksperimento duomenimis buvo pasiektas 100 % klasifikavimo tikslumas. Tai reiškia, kad nebuvo jokių klasifikavimo klaidų. Galima daryti išvadą, kad šiame duomenų rinkinyje skirtingos būsenos aiškiai atskiriamos požymių erdvėje ir SVM metodu galima tiksliai nustatyti ribas tarp jų. Šis metodas labiausiai tinkamas šiam laboratorijos eksperimento duomenų rinkiniui.

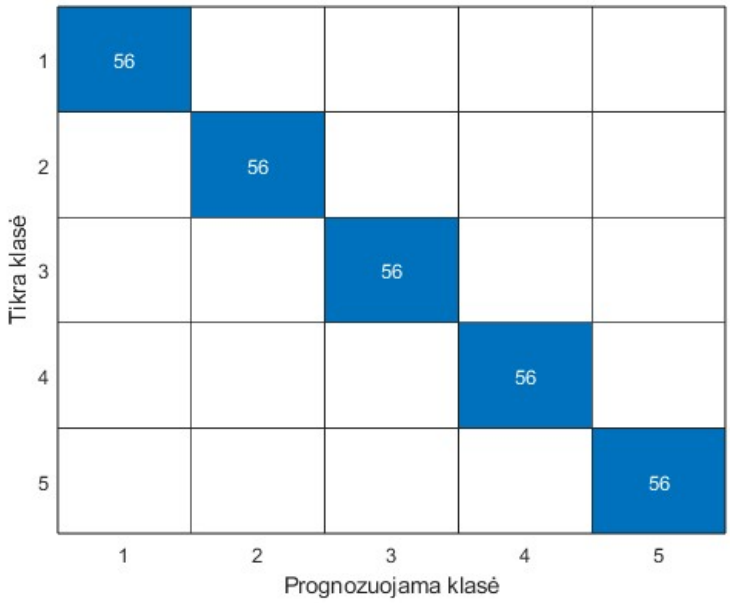

54 pav. KTU laboratorijos eksperimento SVM sumaišymo matrica.

3.3.7. KNN

Su laboratorijos eksperimento duomenų rinkiniu, KNN metodu, kaip ir su kitomis duomenų bazėmis buvo pasiektas mažiausias klasifikavimo tikslumo rezultatas – 61,43 %. Sumaišymo matricoje matoma, kad visiškai teisingai klasifikuota buvo tik „apkrova 1“ klasė. Visos kitos klasės painiojamos tarpusavyje, dalis jų priskiriama „apkrova 1“ klasei. Kiek tiksliau klasifikuota „apkrova 5“ klasė, tačiau ir čia yra keletas neteisingų priskyrimų. Galima daryti išvadą, kad šis metodas nėra tinkamas klasifikuoti laboratorijos eksperimento duomenims.

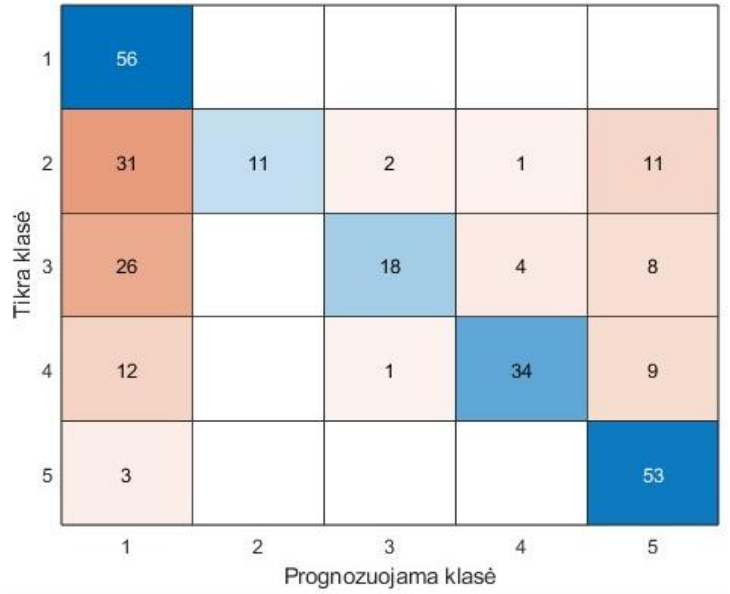

55 pav. KTU laboratorijos eksperimento KNN sumaišymo matrica.

3.3.8. Apibendrinimas

Su laboratorijos eksperimento duomenų rinkiniu, pritaikius dažninės analizės metodus, rezultatuose matomas aiškus skirtumas. Lyginant su vibracijos signalu laiko srityje, visais taikytais dažninės analizės metodais pasiektas aukštesnis klasifikavimo tikslumas. Pritaikius spektro funkciją, tikslumas padidintas 24 procentiniais punktais, kepstro funkcijos atveju – 30 procentinių punktų. Labiausiai klasifikavimo tikslumas pakeltas spektro autokoreliacijos metodu – 68 procentiniais punktais, lyginant su signalo laiko srityje klasifikavimo tikslumu.

CNN, RF ir SVM mašininio mokymosi metodais buvo pasiekti aukšti klasifikavimo tikslumo rezultatai. SVM metodu visos klasės priskirtos teisingai (klasifikavimo tikslumas 100 %). Naudojant CNN pasitaikė tik viena klasifikavimo klaida. Nors RF metodu taip pat buvo neteisingų priskyrimų, tačiau šio metodo klasifikavimo tikslumo lygis vis tiek buvo aukštas – 95,71 %. Kaip ir su kitomis duomenų bazėmis, KNN metodo rezultatai žemiausi – 61,43 % klasifikavimo tikslumas. KNN sumaišymo matricoje matoma, kad tik „apkrova 1“ klasė atskiriama be klaidų. Iš to galima spręsti, kad šis metodas nėra pakankamai tikslus šiai užduočiai spręsti. Tačiau analizuojant kitų metodų rezultatus su šia duomenų baze galima daryti išvadą, kad šiame duomenų rinkinyje atskiros būsenos pakankamai aiškiai išskirtos.

3.4. Tyrimo dalies apibendrinimas

2 lentelė. Dažninės signalų analizės metodų klasifikavimo tikslumo rezultatai

	CWRU (klasifikavimo tikslumas %)	**MaFaulDa (klasifikavimo tikslumas %)**	**KTU laboratorijos eksperimentas (klasifikavimo tikslumas %)**	**Vidurkis (klasifikavimo tikslumas %)**
Signalas laiko srityje	43,75	18,06	26	29,27
Spektras	46,88	31,25	50	42,71
Kepstras	62,5	29,17	56	49,22
Autokoreliacija	37,5	38,19	94	56,56

3 lentelė. Mašininio mokymosi metodų klasifikavimo tikslumo rezultatai

	CWRU (klasifikavimo tikslumas %)	**MaFaulDa (klasifikavimo tikslumas %)**	**KTU laboratorijos eksperimentas (klasifikavimo tikslumas %)**	**Vidurkis (klasifikavimo tikslumas %)**
CNN	99,86	90,9	99,64	96,8
RF	96,67	80,91	95,71	91,1
SVM	95,86	87,8	100	94,55
KNN	85,81	65,91	61,43	71,05

Išanalizavus spektro, kepstro ir autokoreliacijos metodus su trimis nagrinėtais duomenų rinkiniais matoma, kad daugeliu atvejų, vizualiai iš grafikų parinkus požymius nebuvo pasiektas patenkinamas klasifikavimo tikslumas. Lyginant su požymiais, išskirtais iš laiko srities signalų, dažninės analizės metodais daugeliu atvejų pasiektas aukštesnis klasifikavimo tikslumas.

CWRU duomenų bazės atveju aukščiausias klasifikavimo tikslumas (62,5 %) pasiektas kepstro metodu. Spektro metodu klasifikavimo tikslumas buvo 46,88 %. Autokoreliacijos metodu su šia duomenų baze pasiektas tik 37,5 % tikslumas, kas yra 6,25 procentinio punkto mažesnis tikslumas lyginant su iš laiko srities signalo gautu rezultatu.

MaFaulDa duomenų bazės atveju visais metodais gauti pakankamai žemi klasifikavimo tikslumo rezultatai. Aukščiausias klasifikavimo tikslumas (38,19 %) pasiektas autokoreliacijos metodu. Lyginant su laiko srities signalo klasifikavimo rezultatu, spektro metodu klasifikavimo tikslumas padidintas 13,19 procentinio punkto, o kepstro metodu – 11,11 procentinio punkto.

Su laboratorijos eksperimento duomenų rinkiniu klasifikuojant požymius iš dažninės analizės metodų gauti geriausi rezultatai iš visų duomenų bazių. Aukščiausias klasifikavimo tikslumas (94 %) gautas autokoreliacijos metodu. Spektro ir kepstro metodais taip pat gauti aukštesni tikslumo rezultatai, nei klasifikuojant signalo požymius laiko srityje. Spektro metodu klasifikavimo tikslumas aukštesnis 24 procentiniais punktais, kepstro metodu – 30 procentinių punktų.

Sumaišymo matricose matoma, kad klasifikuojant iš dažninės analizės metodų išskirtus požymius daugeliu atvejų nepavyko patikimai atskirti klasių. Dauguma jų persidengia tarpusavyje, o teisingų priskyrimų dalis daugeliu atvejų yra nepakankama. Išimtis buvo tik autokoreliacijos metodas su laboratorijos eksperimento duomenimis, kai pasiektas 94 % klasifikavimo tikslumas.

Išanalizavus šiuos rezultatus galima daryti išvadą, kad naudojant spektro, kepstro ir autokoreliacijos metodus daugeliu atvejų galima padidinti klasifikavimo tikslumą, lyginant su laiko srities signalų požymiais. Nepaisant to, klasifikavimo tikslumas klasifikuojant pagal vizualiai atrinktus požymius dažniausiu atveju buvo nepakankamas patikimam klasių atskyrimui.

Klasifikuojant pagal dažninės analizės metodus, požymiai buvo parenkami vizualiai vertinant grafikus. Toks požymių parinkimas nėra universalus, nes priklauso nuo duomenų rinkinio ir taikomo analizės metodo. Pakeitus duomenis ar metodą, požymius reikia parinkti iš naujo, įvertinus, kuriose grafiko dalyse skirtingos klasės vizualiai labiausiai atsiskiria. Skirtingai parinkti informatyvių požymių taškai gali reikšmingai pakeisti klasifikavimo rezultatus.

Kitaip, nei dažninės analizės metodų atveju, kur klasifikavimas atliktas pagal vizualiai iš grafikų parinktus požymius naudojant Euklido atstumą, mašininio mokymosi metodams buvo naudojamos signalų spektrogramos. Išanalizavus CNN, RF, SVM ir KNN metodus su trimis nagrinėtais duomenų rinkiniais nustatyta, kad geriausi klasifikavimo rezultatai daugeliu atvejų buvo pasiekti naudojant CNN ir SVM.

CWRU duomenų bazėje aukščiausias klasifikavimo tikslumas pasiektas CNN – 99,86 %. Šiek tiek žemesnis (atitinkamai 3,19 ir 3 procentiniais punktais) tikslumas pasiektas su RF ir SVM. Žemiausi rezultatai pasiekti KNN – 14,05 procentinio punkto mažiau, nei CNN. Daugiausiai priskyrimų klaidingoms klasėms buvo tarp išorinio ir vidinio žiedo riedėjimo takelio defekto klasių.

Iš visų duomenų rinkinių sunkiausiai klasifikuojama buvo MaFaulDa duomenų bazė. Kaip ir CWRU duomenų bazėje, čia aukščiausias klasifikavimo tikslumas (90,9 %) buvo pasiektas CNN. Panašus tikslumas, kaip CNN (3,1 procentinio punkto mažiau), pasiektas SVM metodu. RF šioje duomenų bazėje buvo 6,89 procentinio punkto mažiau tikslus, nei SVM. Žemiausi rezultatai (65,91 %

klasifikavimo tikslumas) pasiekti KNN. Daugiausia klasifikavimo klaidų buvo tarp vertikalaus ir horizontalaus ašies nesutapimo bei disbalanso klasių.

Aukščiausias klasifikavimo tikslumas pasiektas su laboratorijos eksperimento duomenų rinkiniu. Naudojant SVM pasiektas 100 % klasifikavimo tikslumas, o CNN metodu padaryta tik viena klasifikavimo klaida. RF klasifikavimo tikslumas 4,29 procentinio punkto žemesnis, nei SVM. KNN, kaip ir kituose duomenų rinkiniuose, pasiektas žemiausias klasifikavimo tikslumas – 61,43 %.

Išanalizavus šiuos rezultatus, galima daryti išvadą, kad stabiliausi rezultatai daugeliu atvejų gauti CNN ir SVM metodais. CNN metodu klasifikavimo tikslumo vidurkis tarp visų duomenų bazių 96,8 %. SVM vidutinis klasifikavimo tikslumas 2,25 procentinio punkto žemesnis už CNN. Nedaug nuo jų atsiliko RF. Šio metodo vidutinis klasifikavimo tikslumas 5,7 procentinio punkto žemesnis už CNN. Žemiausi rezultatai su visais duomenų rinkiniais pasiekti naudojant KNN. KNN klasifikavimo tikslumas vidutiniškai 25,82 procentiniais punktais žemesnis už CNN.

Klasifikavimo tikslumas taip pat priklauso nuo duomenų pobūdžio. Daugeliu nagrinėtų metodų sunkiau atskirti klases, kurios tarpusavyje panašesnės. Dažniau maišomos fiziškai panašios klasės. Daug sutapimų matoma tarp horizontalaus ašies nesutapimo ir disbalanso klasių bei tarp horizontalaus ir vertikalaus ašies nesutapimo klasių MaFaulDa duomenų bazėje. Taip pat šioje duomenų bazėje kai kuriais atvejais buvo matomi guolio už rotoriaus ir guolio tarp variklio ir rotoriaus gedimų klasių persidengimai. CWRU duomenų bazėje dažniausiai tarpusavyje maišytos vidinio ir išorinio žiedo riedėjimo takelio defektų klasės.

Analizuojant gautus rezultatus matoma, kad klasifikavimas, pagrįstas dažninės analizės metodais su vizualiai iš grafikų parinktais požymiais ir Euklido atstumu daugeliu atvejų negali užtikrinti pakankamo klasifikavimo tikslumo. Taikant CNN, RF ir SVM metodus su požymiais iš signalų spektrogramų gauti aukštesni klasifikavimo rezultatai. Tam įtakos turėjo ir tai, kad prieš formuojant spektrogramas, signalai buvo segmentuoti. Dėl to gautas didesnis duomenų kiekis, kas leido modeliams tiksliau atskirti skirtingas klases.

Išvados ir rezultatai

1. Atlikus elektromechaninių sistemų vibracijos signalų klasifikavimo būdų literatūros analizę, apžvelgti literatūroje aprašomi vibracijos signalų matavimo būdai, signalų analizės ir klasifikavimo metodai.
2. Parinktos tyrimui tinkamos vibracijos signalų duomenų bazės. KTU laboratorijoje eksperimento metu išmatuoti vibracijos signalai.
3. Vibracijos signalų klasifikavimui pasirinktuose duomenų rinkiniuose pritaikyti skirtingi signalų analizės ir mašininio mokymosi metodai.
4. Palyginus skirtingų metodų klasifikavimo tikslumą ir tinkamumą skirtingų elektromechaninių sistemų būsenų ir būklių atpažinimui, padarytos šios išvados:

- Atlikus skirtingų guolių gedimų vibracijos signalų klasifikavimo būdų palyginimą naudojant CWRU guolių duomenų bazės duomenų rinkinį nustatyta, kad aukščiausias klasifikavimo tikslumas (99,86 % iš 2100 testavimo pavyzdžių) pasiektas CNN metodu, klasifikavimui naudojant spektrogramas.
- Atlikus skirtingų elektromechaninės sistemos gedimų vibracijos signalų klasifikavimo būdų palyginimą naudojant MaFaulDa mašinų gedimų simuliatoriaus duomenų bazės duomenų rinkinį nustatyta, kad aukščiausias klasifikavimo tikslumas (90,9 % iš 29400 testavimo pavyzdžių) pasiektas CNN metodu, klasifikavimui naudojant spektrogramas.
- Atlikus skirtingai apkrauto variklio vibracijos signalų klasifikavimo būdų palyginimą naudojant duomenis, surinktus laboratorijoje, nustatyta, kad aukščiausias klasifikavimo tikslumas (100 % iš 280 testavimo pavyzdžių) pasiektas SVM metodu, klasifikavimui naudojant požymių vektorius, sudarytus iš spektrogramų.
- Atlikus vibracijos signalų klasifikavimo būdų tyrimą, nustatyta, kad su visais duomenų rinkiniais CNN, SVM ir RF metodais pasiektas aukštesnis klasifikavimo tikslumas nei klasifikuojant pagal požymius, parinktus iš dažninės analizės metodų grafikų.
- Tyrimo metu nustatyta, kad naudojant iš spektro, kepstro ir autokoreliacijos funkcijų grafikų parinktus požymius daugeliu atvejų pasiektas aukštesnis klasifikavimo tikslumas, lyginant su signalu laiko srityje. Išimtis buvo tik autokoreliacija su CWRU duomenų bazės duomenimis.
- Ištyrus skirtingus klasifikatorius duomenų bazėse turimiems ir eksperimento metu gautiems signalams klasifikuoti, nustatyta, kad tyrime išbandytus CNN, SVM ir RF metodus, paremtus vibracijos signalų spektrogramomis, galima naudoti kuriant automatizuotas diagnostikos sistemas elektromechaninių sistemų gedimų ir skirtingų darbo būsenų atpažinimui.

Literatūros sąrašas

1. CHU, T., T. NGUYEN, H. YOO ir J. WANG. A review of vibration analysis and its applications. *Heliyon*, 2024, t. 10, nr. 5, e26282. Prieiga per internetą: https://doi.org/10.1016/j.heliyon.2024.e26282 [žiūrėta 2025-04-19].
2. BOUBAKER, M., M. KHEMIRI, F. CHAARI ir M. HADDAR. Experimental study of vibration measurement using a piezoelectric accelerometer. 2021. Prieiga per internetą: https://www.researchgate.net/publication/354531618 [žiūrėta 2025-04-19].
3. CHENNANA, A., A. C. MEGHERBI, N. BESSOUS ir kt. Vibration signal analysis for rolling bearings faults diagnosis based on deep-shallow features fusion. *Scientific Reports*, 2025, t. 15, straipsnio nr. 9270. Prieiga per internetą: https://doi.org/10.1038/s41598-025-93133-y [žiūrėta 2025-04-20].
4. WANG, Q., D. LIU, H. TIAN, Y. QIN ir D. ZHAO. Vibration Signal Classification Using Stochastic Configuration Networks Ensemble. *Applied Sciences*, 2024, t. 14, nr. 13, straipsnio nr. 5589. Prieiga per internetą: https://doi.org/10.3390/app14135589 [žiūrėta 2025-04-20].
5. ZIMNICKAS, T., J. VANAGAS, K. DAMBRAUSKAS, A. KALVAITIS ir M. AŽUBALIS. Application of Advanced Vibration Monitoring Systems and Long Short-Term Memory Networks for Brushless DC Motor Stator Fault Monitoring and Classification. *Energies*, 2020, t. 13, nr. 4, straipsnio nr. 820. Prieiga per internetą: https://doi.org/10.3390/en13040820 [žiūrėta 2025-04-20].
6. ZHANG, K. ir Z. YANG. Identification of Load Categories in Rotor System Based on Vibration Analysis. *Sensors*, 2017, t. 17, nr. 7, straipsnio nr. 1676. Prieiga per internetą: https://doi.org/10.3390/s17071676 [žiūrėta 2025-04-26].
7. ULLAH, I., N. KHAN, S. A. MEMON, W.-G. KIM, J. SALEEM ir S. MANZOOR. Vibration-Based Anomaly Detection for Induction Motors Using Machine Learning. *Sensors*, 2025, t. 25, nr. 3, straipsnio nr. 773. Prieiga per internetą: https://doi.org/10.3390/s25030773 [žiūrėta 2025-04-26].
8. ALMUTAIRI, K. M. ir J. K. SINHA. Experimental Vibration Data in Fault Diagnosis: A Machine Learning Approach to Robust Classification of Rotor and Bearing Defects in Rotating Machines. *Machines*, 2023, t. 11, nr. 10, straipsnio nr. 943. Prieiga per internetą: https://doi.org/10.3390/machines11100943 [žiūrėta 2025-04-27].
9. LIU, X., J. HONG, K. ZHAO, B. SUN, W. ZHANG ir J. JIANG. Vibration Analysis for Fault Diagnosis in Induction Motors Using One-Dimensional Dilated Convolutional Neural Networks. *Machines*, 2023, t. 11, nr. 12, straipsnio nr. 1061. Prieiga per internetą: https://doi.org/10.3390/machines11121061 [žiūrėta 2025-04-27].
10. GARGASAS, V., K. RIMKUS, M. ALEKNA, A. KNYŠ, M. ŽILYS ir A. VALINEVIČIUS. Research on Pantograph Defect Classification Based on Vibration Signals. *Sensors*, 2024, t. 24, straipsnio nr. 7741. Prieiga per internetą: https://doi.org/10.3390/s24237741 [žiūrėta 2025-04-28].
11. WALD, R., T. KHOSHGOFTAAR ir J. C. SLOAN. Fourier transforms for vibration analysis: A review and case study. In: *2011 IEEE International Conference on Information Reuse & Integration*. Las Vegas, NV, USA, 2011, p. 366–371. Prieiga per internetą: https://www.researchgate.net/publication/224257470_Fourier_transforms_for_vibration_analysis_A_review_and_case_study [žiūrėta 2025-04-28].

12. MATHWORKS. Fast Fourier Transform (FFT) [interaktyvus]. Prieiga per internetą: https://se.mathworks.com/discovery/fft.html [žiūrėta 2025-04-30].
13. RAFIEE, J. ir P. W. TSE. Use of autocorrelation of wavelet coefficients for fault diagnosis. *Mechanical Systems and Signal Processing*, 2009, t. 23, nr. 5, p. 1554–1572. Prieiga per internetą: https://doi.org/10.1016/j.ymssp.2009.02.008 [žiūrėta 2025-05-10].
14. BROWNLEE, J. A Gentle Introduction to Autocorrelation and Partial Autocorrelation. *Machine Learning Mastery*, 2020. Prieiga per internetą: https://machinelearningmastery.com/gentle-introduction-autocorrelation-partial-autocorrelation/ [žiūrėta 2025-05-10].
15. WANG, J., Y. SUN ir W. WANG. Bearing fault diagnosis based on improved cepstrum under variable speed condition. *Engineering Research Express*, 2023, t. 5, nr. 2. Prieiga per internetą: https://www.researchgate.net/publication/370676062_Bearing_fault_diagnosis_based_on_improved_cepstrum_under_variable_speed_condition [žiūrėta 2025-05-11].
16. SIEMENS DIGITAL INDUSTRIES SOFTWARE. Cepstrum Analysis. 2024. Prieiga per internetą: https://community.sw.siemens.com/s/article/Cepstrum-Analysis [žiūrėta 2025-05-13].
17. PHAM, M. T., J.-M. KIM ir C. H. KIM. Accurate bearing fault diagnosis under variable shaft speed using convolutional neural networks and vibration spectrogram. *Applied Sciences*, 2020, t. 10, nr. 18, straipsnio nr. 6385. Prieiga per internetą: https://doi.org/10.3390/app10186385 [žiūrėta 2025-05-26].
18. CHA, S. H. Comprehensive Survey on Distance/Similarity Measures between Probability Density Functions. *International Journal of Mathematical Models and Methods in Applied Sciences*, 2007, t. 1, nr. 4, p. 300–307. Prieiga per internetą: http://www.fisica.edu.uy/~cris/teaching/Cha_pdf_distances_2007.pdf [žiūrėta 2025-05-26].
19. BISHOP, C. M. *Pattern Recognition and Machine Learning*. New York: Springer, 2006. Prieiga per internetą: https://www.microsoft.com/en-us/research/wp-content/uploads/2006/01/Bishop-Pattern-Recognition-and-Machine-Learning-2006.pdf [žiūrėta 2025-05-26].
20. SHLENS, J. A tutorial on principal component analysis. 2005. Prieiga per internetą: https://www.cs.cmu.edu/~elaw/papers/pca.pdf [žiūrėta 2025-05-28].
21. BAGRI, I., K. TAHIRY, A. HRAIBA, A. TOUIL ir A. MOUSRIJ. Vibration Signal Analysis for Intelligent Rotating Machinery Diagnosis and Prognosis: A Comprehensive Systematic Literature Review. *Vibration*, 2024, t. 7, nr. 4, p. 1013–1062. Prieiga per internetą: https://doi.org/10.3390/vibration7040054 [žiūrėta 2025-09-13].
22. KIM, M.-C., J.-H. LEE, D.-H. WANG ir I.-S. LEE. Induction Motor Fault Diagnosis Using Support Vector Machine, Neural Networks, and Boosting Methods. *Sensors*, 2023, t. 23, nr. 5, straipsnio nr. 2585. Prieiga per internetą: https://doi.org/10.3390/s23052585 [žiūrėta 2025-09-13].
23. CAI, L., N. F. THORNHILL, S. KUENZEL ir B. C. PAL. Real-Time Detection of Power System Disturbances Based on k-Nearest Neighbor Analysis. *IEEE Access*, 2017, t. 5, p. 5631–5639. Prieiga per internetą: https://doi.org/10.1109/ACCESS.2017.2679006 [žiūrėta 2025-09-14].
24. CHETCHARUNGKIT, C. Enhancing linear regression through neighbor-based similarity analysis. 2024. Prieiga per internetą: https://www.researchgate.net/publication/384621052_Enhancing_linear_regression_through_neighbor-based_similarity_analysis [žiūrėta 2025-09-15].

25. INCE, T., S. KIRANYAZ, L. EREN, M. ASKAR ir M. GABBOUJ. Real-Time Motor Fault Detection by 1-D Convolutional Neural Networks. *IEEE Transactions on Industrial Electronics*, 2016, t. 63, nr. 11, p. 7067–7075. Prieiga per internetą: https://doi.org/10.1109/TIE.2016.2582729 [žiūrėta 2025-10-18].
26. MATHWORKS. Convolutional Neural Network (CNN) [interaktyvus]. Prieiga per internetą: https://se.mathworks.com/discovery/convolutional-neural-network.html [žiūrėta 2025-10-18].
27. CHEN, X., B. ZHANG ir D. GAO. Bearing fault diagnosis base on multi-scale CNN and LSTM model. *Journal of Intelligent Manufacturing*, 2021, t. 32, p. 971–987. Prieiga per internetą: https://doi.org/10.1007/s10845-020-01600-2 [žiūrėta 2025-10-19].
28. MATHWORKS. Long Short-Term Memory (LSTM) [interaktyvus]. Prieiga per internetą: https://se.mathworks.com/discovery/lstm.html [žiūrėta 2025-10-26].
29. TOMA, R. N., A. E. PROSVIRIN ir J.-M. KIM. Bearing Fault Diagnosis of Induction Motors Using a Genetic Algorithm and Machine Learning Classifiers. *Sensors*, 2020, t. 20, nr. 7, straipsnio nr. 1884. Prieiga per internetą: https://doi.org/10.3390/s20071884 [žiūrėta 2025-10-26].
30. CHEN, Z., C. LI ir R.-V. SÁNCHEZ. Gearbox Fault Identification and Classification with Convolutional Neural Networks. *Shock and Vibration*, 2021. Prieiga per internetą: https://www.researchgate.net/figure/Illustration-of-random-forest-trees_fig4_354354484 [žiūrėta 2025-12-03].
31. CASE WESTERN RESERVE UNIVERSITY Bearing Data Center. Apparatus and procedures [interaktyvus]. Prieiga per internetą: https://engineering.case.edu/bearingdatacenter/apparatus-and-procedures [žiūrėta 2025-12-03].
32. ZHAO, R., R. YAN, Z. CHEN, K. MAO, P. WANG ir R. X. GAO. Improved similarity-based modeling for the classification of rotating-machine failures. *Mechanical Systems and Signal Processing*, 2017, t. 90, p. 337–353.
33. ČERNYS, P., A. LIPNICKAS, G. NARVYDAS, G. PETRAUSKAS ir K. RIMKUS. *Elektros pavaros. Laboratoriniai darbai*. 2024. Prieiga per internetą: https://ebooks.ktu.edu/pdfreader/elektros-pavaros.-laboratoriniai-darbai [žiūrėta 2025-12-15].
34. BAKER HUGHES, BENTLY NEVADA. Accelerometers: How Do They Work? Prieiga per internetą: https://www.bakerhughes.com/bently-nevada/orbit-home/orbit-article/accelerometers-how-dothey-work [žiūrėta 2025-12-15].
35. PCB PIEZOTRONICS. Vibration fundamentals. Prieiga per internetą: https://www.pcb.com/vibration-quickreferenceguide [žiūrėta 2026-01-11].
36. RS PRO. Vibration Sensor. Prieiga per internetą: https://uk.rs-online.com/web/p/vibration-sensors/2777920 [žiūrėta 2026-01-11].
37. ICP DAS. SG-3227: 2-channel IEPE Input Signal Conditioner. 2020. Prieiga per internetą: https://www.icpdas.com/en/product/SG-3227 [žiūrėta 2026-03-24].
38. HANTEK. DSO2000 Series Oscilloscope (Model 17182). 2026. Prieiga per internetą: https://www.hantek.com/products/detail/17182 [žiūrėta 2026-03-24].
39. OPPENHEIM, A. V. ir R. W. SCHAFER. *Discrete-Time Signal Processing*. 3-iasis leid. Upper Saddle River: Prentice Hall, 2010. ISBN 978-0131988422.

Priedai

1 priedas. Matlab kodo fragmentas spektro skaičiavimui

```
fs = 32000;
[f, spec] = spectrum_fft_lab(a, fs);

function [f, mag] = spectrum_fft_lab(x, fs)

    x = x(:);
    x = x - mean(x);
    N = numel(x);
    X = fft(x);
    P2 = abs(X / N);
    P1 = P2(1:floor(N/2)+1);

    if numel(P1) > 2
        P1(2:end-1) = 2 * P1(2:end-1);
    end

    f = fs * (0:floor(N/2)) / N;
    mag = P1;
end
```

2 priedas. Matlab kodo fragmentas kepstro skaičiavimui

```
X = fft(a);
magX = abs(X);
logmag = log(magX + eps);
C = ifft(logmag);
c = real(C);
```

3 priedas. Matlab kodo fragmentas autokoreliacijos skaičiavimui

```
sp = abs(fft(a));
N = length(sp);
grafikas = zeros(1, N);

saut = xcorr(sp);

for i = 1:N
    grafikas(i) = saut(i + (N - 1));
end
```

4 priedas. Matlab kodo fragmentas signalo laiko srityje, spektro, kepstro ir autokoreliacijos klasifikavimui ir sumaišymo matricų sudarymui

```
x1 = input('x1: ');
x2 = input('x2: ');
data = [];
test = [];

for num = 1:20
    for gi = 1:numGroups

        y1 = grafikas(round(x1));
        y2 = grafikas(round(x2));
        klase = gi;
        row = [y1 y2 klase];

        if num <= 10
```

```
            data = [data; row];
        else
            test = [test; row];
        end
    end
end

X1 = data(:,1:2);
Y1 = data(:,3);
X2 = test(:,1:2);
Y2 = test(:,3);
Xtrain = X1;
Ytrain = Y1;
Xtest = X2;
Ytest = Y2;
classes = unique(Ytrain);
k = length(classes);

for i = 1:k
    centers(i,:) = mean(Xtrain(Ytrain == classes(i), :));
end

for n = 1:length(Xtest)

    for i = 1:k
        d(i) = norm(Xtest(n,:) - centers(i,:));
    end

    [~, idx] = min(d);
    Ypred(n) = classes(idx);

end

accuracy = sum(Ypred' == Ytest) / length(Ytest) * 100

figure
cm = confusionchart(Y2, Ypred);
cm.XLabel = 'Prognozuojama klasė';
cm.YLabel = 'Tikra klasė';
cm.Title = '';
```

5 priedas. Matlab kodo fragmentas spektrogramų sudarymui

```
fs = 32000;
segmentLength = 2048;
segmentStep   = 1024;

win      = hamming(512);
noverlap = 256;
nfft     = 1024;
imgSize  = [128 128];

for startIdx = 1:segmentStep:(length(sig)-segmentLength+1)

    segment = sig(startIdx:startIdx+segmentLength-1);

    [Sspec,~,~] = spectrogram(segment, win, noverlap, nfft, fs);

    img = log10(abs(Sspec) + eps);
    img = mat2gray(img);
    img = imresize(img, imgSize);
```

```
end
```

6 priedas. Matlab kodo fragmentas CNN

```
inputSize = [imgSize 1];

classes = categories(imdsTrain.Labels);
numClasses = numel(classes);

layers = [
    imageInputLayer(inputSize,'Normalization','none')

    convolution2dLayer(3,16,'Padding','same')
    batchNormalizationLayer
    reluLayer
    maxPooling2dLayer(2,'Stride',2)

    convolution2dLayer(3,32,'Padding','same')
    batchNormalizationLayer
    reluLayer
    maxPooling2dLayer(2,'Stride',2)

    convolution2dLayer(3,64,'Padding','same')
    batchNormalizationLayer
    reluLayer
    averagePooling2dLayer(2,'Stride',2)

    fullyConnectedLayer(numClasses)
    softmaxLayer
    classificationLayer
];

options = trainingOptions('adam', ...
    'InitialLearnRate', 1e-3, ...
    'MaxEpochs', 10, ...
    'MiniBatchSize', 32, ...
    'Shuffle', 'every-epoch', ...
    'ValidationData', imdsTest, ...
    'Plots', 'training-progress', ...
    'Verbose', false);

net = trainNetwork(imdsTrain, layers, options);

[YPred,~] = classify(net, imdsTest);
YTrue = imdsTest.Labels;

acc = mean(YPred == YTrue) * 100;

figure;
confusionchart(YTrue, YPred);
```

7 priedas. Matlab kodo fragmentas požymių vektorių sudarymui iš spektrogramų

```
function [X, Y] = imageDatastoreToFeatures(imds, featImgSize, classNames)

    n = numel(imds.Files);
    X = zeros(n, prod(featImgSize), 'single');
    Y = categorical(strings(n,1), classNames);
```

```
    for i = 1:n

        img = readimage(imds, i);

        img = im2single(img);
        img = imresize(img, featImgSize);

        X(i,:) = img(:)';
        Y(i)   = categorical(string(imds.Labels(i)), classNames);

    end
end
```

8 priedas. Matlab kodo fragmentas RF

```
featImgSize = [64 64];
classNames  = {'a1','a2','a3','a4','a5'};

numTrees    = 300;
minLeafSize = 5;

[XTrain, YTrain] = imageDatastoreToFeatures(imdsTrain, featImgSize, classNames);
[XTest,  YTest]  = imageDatastoreToFeatures(imdsTest,  featImgSize, classNames);

rf = TreeBagger(numTrees, XTrain, YTrain, ...
    'Method', 'classification', ...
    'MinLeafSize', minLeafSize);

YPredCell = predict(rf, XTest);
YPred = categorical(YPredCell, classNames);

acc = mean(YPred == YTest) * 100;

figure;
confusionchart(YTest, YPred);
```

9 priedas. Matlab kodo fragmentas SVM

```
featImgSize = [32 32];
classNames  = {'a1','a2','a3','a4','a5'};

pcaDims = 150;
boxC      = 1;

[XTrain, YTrain] = imageDatastoreToFeatures(imdsTrain, featImgSize, classNames);
[XTest,  YTest]  = imageDatastoreToFeatures(imdsTest,  featImgSize, classNames);

XTrainD = double(XTrain);
XTestD  = double(XTest);
[coeff, scoreTrain, ~, ~, explained, mu] = pca(XTrainD);
XTrainUse = scoreTrain(:,1:pcaDims);
XTestUse  = (XTestD - mu) * coeff(:,1:pcaDims);

t = templateSVM('KernelFunction','rbf', ...
    'KernelScale','auto', ...
    'BoxConstraint', boxC, ...
    'Standardize', true);

svmModel = fitcecoc(XTrainUse, YTrain, ...
    'Learners', t, ...
    'Coding', 'onevsall', ...
```

```
    'ClassNames', categorical(classNames));

YPred = predict(svmModel, XTestUse);

acc = mean(YPred == YTest) * 100;

figure;
confusionchart(YTest, YPred);
```

10 priedas. Matlab kodo fragmentas KNN

```
featImgSize = [32 32];
classNames  = {'a1','a2','a3','a4','a5'};

pcaDims = 150;
k = 5;
distanceMetric = 'euclidean';
standardizeKNN = true;

[XTrain, YTrain] = imageDatastoreToFeatures(imdsTrain, featImgSize, classNames);
[XTest,  YTest]  = imageDatastoreToFeatures(imdsTest,  featImgSize, classNames);

XTrainD = double(XTrain);
XTestD  = double(XTest);
[coeff, scoreTrain, ~, ~, explained, mu] = pca(XTrainD);
XTrainUse = scoreTrain(:,1:pcaDims);
XTestUse  = (XTestD - mu) * coeff(:,1:pcaDims);

knnModel = fitcknn(XTrainUse, YTrain, ...
    'NumNeighbors', k, ...
    'Distance', distanceMetric, ...
    'Standardize', standardizeKNN);

YPred = predict(knnModel, XTestUse);

acc = mean(YPred == YTest) * 100;

figure;
confusionchart(YTest, YPred);
```