



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Automatizuotos elektros variklio diagnostikos sistemos tyrimas

Baigiamasis magistro projektas

Edgaras Butvila

Projekto autorius

Lekt. Dr. Vytautas Gargasas

Vadovas

Kaunas, 2020



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Automatizuotos elektros variklio diagnostikos sistemos tyrimas

Baigiamasis magistro projektas

Valdymo technologijos (6211EX014)

Edgaras Butvila

Projekto autorius

Lekt. Dr. Vytautas Gargasas

Vadovas

Prof. Dr. Vytautas Galvanauskas

Recenzentas

Kaunas, 2020



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Edgaras Butvila

Automatizuotos elektros variklio diagnostikos sistemos tyrimas

Akademinio sąžiningumo deklaracija

Patvirtinu, kad mano, Edgardo Butvilos, baigiamasis projektas tema „Automatizuotos elektros variklio diagnostikos sistemos tyrimas“ yra parašytas visiškai savarankiškai ir visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs.

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

(vardą ir pavardę įrašyti ranka)

(parašas)

Butvila, Edgaras. Automatizuotos elektros variklio diagnostikos sistemos tyrimas. Magistro baigiamasis projektas vadovas lekt. dr. Vytautas Gargasas; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

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

Reikšminiai žodžiai: *gedimų diagnostika, signalų transformavimas, klasifikavimo algoritmai*

Kaunas, 2020. 81 p.

Santrauka

Darbe aprašomi elektros variklių gedimų diagnostikos metodai. Pirmiausiai, aprašomas tyrimui atlikti naudojamas objektas: jo konstrukcija, dažniausi gedimai. Taip pat aprašoma, kokie metodai mokslinėje literatūroje naudojami jutikliais gauto signalo apdorojimui, apibūdinami signalo transformacijos metodai ir jų pagrindinės lygtys. Darbe pateikiama informacija apie tyrimui atlikti parinktus jutiklius, kuriais gaunamas signalas ir perduodamas tolesnei kompiuterinei diagnostikos įrangai. Apibūdinamas kiekvienas iš tyrime naudojamų jutiklių ir pateikiamos pagrindinės fizikinės išraiškos šių jutiklių apdorojamo fizikinio kintamojo dėsniais. Tolimesnėje darbo dalyje yra pateikiamas detalus aprašymas apie atliktą tyrimą. Taip pat aprašoma kita tyrimui atlikti naudota įranga ir aprašomi gedimai, kurie buvo imituojami nuolatinės srovės variklyje diagnostikos galimybių tyrimo tikslais. Vėliau pateikiami jutikliais gauti signalai, kurie po signalo transformacijos gali būti palyginami tarpusavyje bei randamas tinkamiausias būdas signalams transformuoti. Įvairūs mašininio mokymosi klasifikatoriai ir tiesioginis neuroninis tinklas su grįžtamuoju ryšiu yra panaudojami nepakeistų jutiklių signalų ir transformuotų signalų klasifikavimui. Klasifikavimo tikslumas taip pat yra įvertinamas. Galiausiai, darbe pateikiamos išvados ir pasiūlymai gauti įvertinus atlikto darbo rezultatus.

Butvila, Edgaras. Investigation of Automated Electric Motor Diagnostic System. Master's Final Degree Project supervisor Lect. Dr. Vytautas Gargasas; Faculty of Electrical and Electronics Engineering, Kaunas University of Technology.

Study field and area (study field group): *electronics engineering, engineering science*.

Keywords: *fault diagnosis, signal transformation, classification algorithms*

Kaunas, 2020. 81 p.

Summary

This work covers the topic of fault diagnostic methods used for fault detection in electrical motors. First of all, the object, which was used for the investigation, is examined: it's construction, main faults, which occur in the electrical machine. Also, the scientific literature has been thoroughly examined for methods used for raw sensor signal transformation. The methods for these transformations are then investigated and the main equations used in these methods for calculations are shown in the work. The information is given about the sensor types used in the work, the process is described of data transmission between these sensors and other computer diagnostic equipment. Every of the sensors used in the work is thoroughly examined and the main physical characteristics and equations are given for the properties of the fluctuating physical signal, which is captured by sensors. Further in the work a detailed overview of the scope of the work is given. Additionally, other equipment used for the investigation is described and the malfunctions, which were created in the direct current motor in order to investigate the possibilities of a diagnostic system, are explained. Afterwards signals are presented, which were taken from sensors. These signals after a signal transformation can be compared to each other and the best type of transformation can be found. Various machine classifiers and a feedforward backpropagation neural network have been used to classify raw and transformed signals into distinct categories. The accuracy of this categorisation has also been evaluated. In the final part of the work a summary is given about the results and suggestions are made according to the results of the investigation.

Turinys

Santrumpų ir terminų sąrašas	7
Įvadas.....	8
1. Variklių diagnostika.....	10
1.1. Nuolatinės srovės variklių konstrukcija	11
1.2. Nuolatinės srovės variklių gedimai	13
1.3. Signalų apdorojimas	17
1.3.1. Furjė transformacija.....	18
1.3.2. Kepstro analizė	20
1.3.3. Walsh–Hadamard transformacija	21
1.3.4. Koreliacijos funkcija	22
1.4. Signalų klasifikavimas.....	23
1.4.1. Mašininio mokymosi algoritmai.....	23
1.4.2. Neuroniniai tinklai.....	25
2. Gedimų diagnostikos įranga.....	26
2.1. Tyrimo stendas ir naudota įranga	27
2.2. Variklio srovės diagnostika	28
2.3. Variklio akustinė diagnostika	31
2.4. Variklio vibracijų diagnostika	34
3. Automatizuoto gedimų identifikavimo tyrimas.....	37
3.1. Tirti nuolatinės srovės variklių gedimai	38
3.2. Darbo planas ir gautos signalų kreivės	40
3.3. Signalų klasifikavimo rezultatai	56
3.3.1. Neuroninio tinklo atpažinimo rezultatai	57
3.3.2. Klasifikatorių atpažinimo rezultatų palyginimas.....	60
Išvados ir rezultatai	69
Literatūros sąrašas	70
Priedai.....	74
1 Arduino programinis kodas įtampos nuskaitymui.....	74
2 Signalų transformacijų programinis kodas	75
3 Autokoreliacijos funkcijos ir grafikų pateikimo programinis kodas.....	78
4 Programinis kodas gedimų grupių klasifikavimui.....	80

Santrumpų ir terminų sąrašas

Santrumpos:

FFT – greitoji Furjė transformacija;
DFT – diskretinė Furjė transformacija;
WHT – Walsh-Hadamard transformacija;
FWHT – greitoji Walsh-Hadamard transformacija;
SVM – pagalbinių vektorių mašininio mokymosi algoritmas;
KNN – artimiausio kaimyno mašininio mokymosi algoritmas;
FFBPNN – tiesioginis neuroninis tinklas su grįžtamuju ryšiu;
GB – garso signalo tyrimas esant ašies disbalansui;
GS – garso signalo tyrimas varikliui be defektų;
GT – garso signalo tyrimas esant trumpam jungimui tarp variklio apvijų;
GU – garso signalo tyrimas, kai variklio viduje yra pašalinių medžiagų;
SB – srovės signalo tyrimas esant ašies disbalansui;
SS – srovės signalo tyrimas varikliui be defektų;
ST – srovės signalo tyrimas esant trumpam jungimui tarp variklio apvijų;
SU – srovės signalo tyrimas, kai variklio viduje yra pašalinių medžiagų;
VB – vibracijų signalo tyrimas esant ašies disbalansui;
VS – vibracijų signalo tyrimas varikliui be defektų;
VT – vibracijų signalo tyrimas esant trumpam jungimui tarp variklio apvijų;
VU – vibracijų signalo tyrimas, kai variklio viduje yra pašalinių medžiagų;
NS – nuolatinė srovė;
G – garso jutiklio duomenys;
S – srovės jutiklio duomenys;
V – vibracijos jutiklio duomenys

Įvadas

Darbo aktualumas:

Atliekamas tyrimas yra pagrįstas poreikiu iširti galimus ir tinkamiausius gedimų diagnostikos būdus elektromechaninėje įrangoje. Uždaviniui atlikti panaudojami skirtingi jutikliai, kurie fiksuoja fizikinius aplinkos signalus, kompiuterinė įranga bei pasirinktas uždavinio atlikimui tyrimo objektas – nuolatinės srovės variklis. Nuolatinės srovės variklis panaudojamas tyrimo atlikimui, tačiau tyrimo būdas gali būti pritaikomas ir kitų tipų elektros varikliams. Jutikliais gauti signalai yra apdorojami signalų analizės būdais. Tai suteikia galimybę lyginti signalus vizualiai ir panaudoti klasifikavimo algoritmus. Tokiu būdu galima sukurti automatizuotą gedimų diagnostikos sistemą.

Daug dėmesio įvairiuose mechanizmuose yra skiriama gedimų prevencijai, tam yra investuojama daug lėšų ir mokslininkų laiko, nustatant ir pritaikant gedimų diagnostikos būdus [2;4;5]. Gedimų diagnostika yra labai svarbus uždavinys daugelyje sričių, nes ankstyvas gedimo atpažinimas ir tikslus jo nustatymas suteikia galimybę gedimą greitai panaikinti, nelaukiant, kol objektas suges. Atliekamame darbe yra nagrinėjama tokio pobūdžio problema: kaip nustatyti gedimą, diagnozuoti jo rūšį ir atskirti jį nuo kitų gedimo rūšių. Tyrime bandoma rasti tinkamus fizikinius parametrus: garsą, elektros srovę, vibracijas, atsirandančius elektrinėje įrangoje ir juos palyginti tarpusavyje, nustatyti, kurio fizikinio parametro kitimas gali geriau prognozuoti tam tikros rūšies gedimą. Atliekamas tyrimas yra skirtas tinkamų diagnostikos būdų radimui. Darbo apimtyje yra atliekamas ir klasifikavimo algoritmų tyrimas, kurių pagalba gedimai yra atskiriami į skirtingas kategorijas. Tyrime yra nustatoma, kokie diagnostiniai būdai pateikia geriausias rezultatus ir kuriuos iš jų yra tikslinga naudoti praktikoje.

Uždavinio atlikimui panaudotas nuolatinės srovės variklis su nuolatinė magnetų žadinimu. Tokio tipo variklis yra vis dar populiarus įvairiuose įrenginiuose kaip vienas iš komponentų. Tyrimai atliekami su šiuo pasirinktu objektu gali būti pritaikyti ir kitų tipų elektros mašinoms su tam tikromis modifikacijomis priklausomai nuo tiriamo įrenginio. Darbe aprašomi jutikliai yra naudojami gedimų diagnostikai ir kituose moksliniuose darbuose, tačiau mokslinėje literatūroje visų trijų jutiklių efektyvumo tiriant gedimus palyginimo nepavyko rasti. Daugumoje mokslinių darbų tiriamas vieno iš jutiklių efektyvumas, bet jie nėra lyginami tarpusavyje. Taip pat, kita svarbi darbo dalis yra jutikliais gautų signalų analizė. Jutikliais gautų signalų analizė suteikia galimybę laiko ašyje kintantį signalą perkurti dažnio srityje ir pastebėti esminius signalo požymius. Toks transformuotas signalas turi tam tikrus išryškintus esminius bruožus, kurie gali būti lyginami tiek grafine forma, tiek matematine išraiška. Panaudojant skirtingais jutikliais gautų signalų ir jų transformacijų kombinacijas bei klasifikavimo metodus galima gauti optimalią automatizuotos sistemos kombinaciją. Tyrimas yra reikalingas ir gali padėti sprendžiant automatizuotų elektromechaninių sistemų diagnostikos uždavinius, pateikti pasiūlymus, kokios jutiklių, signalų transformacijų bei klasifikatorių kombinacijos gali būti geriausios gedimo tyrimo uždaviniui atlikti.

Tyrimo objektas:

Pagrindinis tyrimo objektas yra diagnostikos galimybių analizė ir tyrimo sistemos sudarymas.

Darbo tikslas:

Remiantis teorine informacija ir naudojamomis praktinėmis gedimų nustatymo priemonėmis rasti gedimų diagnostikos būdus, kurie pateiktų patikimiausius rezultatus gedimų diagnostikos uždaviniui.

Darbo uždaviniai:

1. atlikti mokslinės literatūros analizę ir sužinoti, kokios gedimų diagnostikos priemonės yra populiarios ir pasiteisinančios;
2. parinkti įrangą ir jos komponentus tyrimo atlikimui;
3. išsiaiškinti, kaip geriausia dirbti su gautais signalų duomenis ir juos transformuoti;
4. atlikti bandymus su nuolatinės srovės varikliu;
5. analizuoti gautus rezultatus ir parinkti geriausius gedimų diagnostikos būdus

Darbo metodai:

- mokslinės literatūros analizė;
- tinkamų priemonių gedimų diagnostikos uždaviniui parinkimas;
- garso, srovės ir vibracijų jutiklių panaudojimas;
- programinės įrangos parengimas signalų apdorojimui;
- greitosios Furjė, Kepstro ir greitosios Walsh-Hadamard transformacijų panaudojimas;
- signalų autokoreliacijos funkcijos panaudojimas;
- transformuotų signalų klasifikavimas

Darbo turinys ir struktūra:

Darbas suskirstytas į keletą pagrindinių dalių, kuriose aprašoma tyrimo eiga ir atlikti bandymai, jų rezultatai. Darbas pradedamas literatūros analize ir baigiamas išvadomis, gautomis atlikus visus tyrimus ir pateikiami pasiūlymai, kurie gaunami įvertinus darbo rezultatus.

Pirmoje darbo dalyje pateikiama mokslinės literatūros analizė, kurioje aprašomi galimi gedimai nuolatinės srovės varikliuose ir kas juos paveikia. Pateikiami gedimų tipai, kuo jie skiriasi ir kaip jie paveikia nuolatinės srovės variklio darbą. Aprašoma, kokios priemonės gali padėti sumažinti gedimų žalą. Taip pat išsamiai aptariami signalų transformacijos būdai, kurie leidžia gaunamą signalą transformuoti į kitą formą, leidžiančią skirtingo tipo signalus palyginti tarpusavyje.

Antroje darbo dalyje aptariami paruošiamieji darbai, kurie atlikti prieš atliekant tyrimą, ir sudaromas tyrimo eigos planas, pateikiami pirminiai darbo rezultatai bei teorinis darbo pagrindimas. Pirmiausiai, aprašoma tai, kokia įranga buvo naudojama, kaip tokia įranga paveikia tyrimo kokybę ir ar įrangos galimybės yra pakankamos tyrimo atlikimui. Be to, pateikiama išsami informacija apie panaudotus jutiklius, jų veikimo principus ir kaip šie metodai yra pritaikomi gedimų diagnostikai bei kodėl juos buvo nuspręsta panaudoti atliekamo gedimų diagnostikos uždavinio atlikimui.

Paskutinėje trečioje darbo dalyje yra pateikiami darbo rezultatai. Palyginami skirtingi transformuoti signalai, po signalų transformacijos gautos kreivės, klasifikavimo tikslumas. Pateikiamos išvados, aprašomi potencialūs gedimų diagnostikos būdai.

1. Variklių diagnostika

Gedimai visų tipų elektros varikliuose yra neišvengiama problema, kuri atsiranda dėl variklio eksploatacijos ir išorinio aplinkos poveikio. Nuolatinės srovės varikliai yra ne išimtis ir jų gedimai taip pat atsiranda po tam tikro eksploatacijos laiko. Variklių gedimai gali sugadinti elektros variklį arba pakeisti nominalias variklio charakteristikas. Tai yra nepageidautina, nes tokiu atveju elektros variklis dirba neoptimaliu režimu ir negali tinkamai įgyvendinti darbinės užduoties. Tai gali trukdyti visos bendros variklio sistemos darbui.

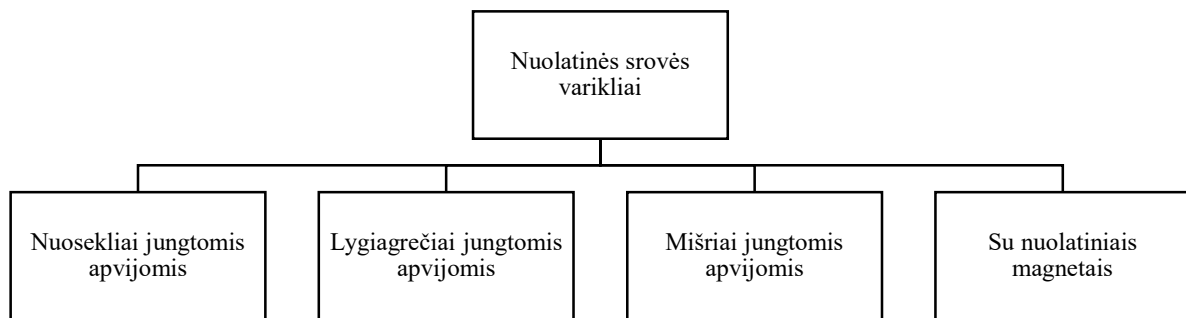
Darbe tyrimui naudojami nuolatinės srovės elektros varikliai su nuolatiniais magnetais variklio stacionarioje dalyje. Tokio tipo elektros varikliai yra plačiai naudojami daugelyje sričių, nors dėl šepėčių mazgo, kuris laikomas dažnai gendančia nuolatinės srovės variklio dalimi [3;5], jie praranda dalį patikimumo. Tokių variklių gedimai gali būti įvairūs, ne vien atsirandantys dėl gedimų šepėčių mazge. Nuolatinės srovės varikliai turi daug judančių grandžių, kurios sąveikauja tarpusavyje. Be to, nuolatinės srovės elektros mašiną galima skirstyti į elektrinę dalį ir mechaninę dalį, kurios yra tarpusavyje susietos. Magnetinių laukų sąveika tarp nuolatinės srovės variklių magnetų magnetinio lauko ir magnetinio lauko, kuriame srovės, tekančios nuolatinės srovės variklio rotoriaus apvijomis, sukuria sukimo momentą, dėl kurio sukasi nuolatinės srovės variklio rotorius. Dėl tokios sąveikos galimi gedimai tiek elektrinėje, tiek mechaninėje nuolatinės srovės variklio grandyje, tačiau gedimai elektrinėje grandyje gali būti matomi ir variklio mechaniniuose parametruose, o mechaniniai gedimai – elektriniuose. Aplinkos poveikis taip pat yra labai svarbus tinkamam variklių veikimui. Elektros varikliai turi būti tinkamai įrengiami ir parenkami, nes varikliai nepritaikyti aplinkai, kurioje yra, negalės tinkamai dirbti ir po kurio laiko atsiras jų gedimai. Aplinkos poveikio sukelti gedimai taip pat yra matomi tiek elektriniuose parametruose, tiek mechaniniuose parametruose. Taip yra todėl, kad aplinkos poveikio sukelti gedimai gali pažeisti elektrines ar mechanines grandis, kurių parametru pokyčiai pastebimi variklio darbo pokyčiuose. Elektrinių parametru kitimas dėl mechaninių variklio parametru ir atvirkštinis kitimas tarp šių parametru yra įmanomas dėl minėto ryšio tarp elektrinės ir mechaninės variklio grandžių.

Gedimai elektros variklyje atsiranda po tam tikro eksploatacijos laiko dėl natūralaus elektrinių ir mechaninių variklio grandžių nusidėvėjimo. Vis dėlto svarbu tinkamai prižiūrėti elektros variklius. Netinkama variklių priežiūra ir neatliekamas arba netinkamai atliekamas techninis variklių aptarnavimas suteikia galimybes varikliams sugesti anksčiau negu jie sugestų dėl nusidėvėjimo. Nuolatinės srovės varikliams tai yra itin aktualu, nes dėl anksčiau minėto šepėčių mazgo, galima tikėtis šio variklio gedimų po tam tikro eksploatacijos periodo. Svarbu galimus gedimus stebėti ir sugedusias grandis pakeisti ar pakeisti visą variklį, kol dar neįvyko gedimas. Netinkamas variklio įrengimas arba netinkama priežiūra yra dažnos variklių gedimų priežastys, bet taip pat gedimai atsiranda ir dėl netinkamų aplinkos sąlygų, užterštumo aplinkoje. Svarbi užduotis įrengiant variklius yra nustatyti aplinkos sąlygas, kuriomis įranga dirbs ir pritaikyti variklius šiai aplinkai. Kitu atveju išvengti gedimų po tam tikro laikotarpio bus sudėtinga. Dėl pamintų priežasčių yra itin svarbu gedimus tinkamai ir greitai diagnozuoti ankstyvoje gedimo stadijoje ir panaikinti, kad būtų sumažintas atsiradusio gedimo sukiamas poveikis. Tokiam uždaviniui atlikti reikia tinkamos variklio diagnostikos sistemos. Tai yra itin svarbu šiuolaikinėse automatikos sistemose kaip ir laiku atliekama variklio techninė apžiūra. Tokios priemonės leidžia išvengti gedimų arba sumažinti jų poveikį elektros sistemai.

1.1. Nuolatinės srovės variklių konstrukcija


Nedidelės galios nuolatinės srovės elektros variklį sudaro keletas pagrindinių konstrukcinių dalių: šepečių mazgas, komutatorius, armatūra su apvijomis besisukančioje variklio dalyje ir nuolatiniai magnetai, esantys variklio stacionarioje dalyje ir sudarantys pastovų magnetinį lauką. Rotoriaus apvijose kuriamo magnetinio lauko sąveika su nuolatinėmis magnetų kuriama magnetiniu lauku realizuoja nuolatinės srovės elektros mašinos veikimą. Tokia konstrukcija atitinka nuolatinės srovės elektros variklį su nuolatiniais magnetais vietoje apvijų stacionarioje nuolatinės srovės variklio dalyje (statoriuje) [1].

Nuolatinės srovės elektros variklius galima skirstyti į keturias pagrindines rūšis: nuolatinės srovės variklius su nuosekliai jungiamomis apvijomis, su lygiagrečiai jungiamomis apvijomis, variklius su mišraus jungimo apvijomis ir anksčiau minėtus nuolatinės srovės variklius su magnetais statoriuje. Kiekviena iš šių variklio rūšių turi tam tikrų pranašumų ir trūkumų lyginant su kitomis variklių rūšimis ir yra pritaikoma skirtingiems uždaviniams atlikti.



1.1 pav. Nuolatinės srovės variklių rūšys [4]

Nuolatinės srovės varikliai su nuolatiniais magnetais yra labiausiai paplitę šiuolaikiniuose įrenginiuose, nes jų paprastesnė konstrukcija ir mažesni priežiūros reikalavimai lyginant su kitomis nuolatinės srovės variklių pagrindinėmis rūšimis. Paskutiniu metu nuolatinės srovės varikliai gaminami ir be šepečių mazgo. Tai yra vadinamieji bešepečiai nuolatinės srovės varikliai, kurie plačiai paplitę įvairiose srityse, kur norima išvengti galimų gedimų dėl nuolatinės srovės variklių šepečių mazgo. Atliekamame darbe tiriamas nuolatinės srovės variklio su nuolatiniais magnetais ir šepečių mazgu veikimas. Tokio tipo variklis buvo pasirinktas, nes jis yra vis dar plačiai naudojamas ir pritaikomas. Tokio variklio maitinimui nereikalinga speciali valdymo įranga, kuri būtų reikalinga nuolatinės srovės varikliui be šepečių mazgo. Nuolatinės srovės varikliai su nuolatiniais magnetais yra pakankamai efektyvūs ir plačiai paplitę įvairiose srityse. Nuolatinės srovės varikliai yra itin plačiai naudojami robotų įrangos sistemose, mažuose elektronikos įrenginiuose, elektros mašinose bei įvairiuose kituose įrenginiuose, kur panaudojama nuolatinė srovė. Nuolatinės srovės panaudojimas yra vienas iš šių variklių privalumų, nes dabartiniame nuolatinės srovės įrangos atgimimo laikotarpyje, tokio tipo elektros varikliai tampa vėl itin populiarūs. Nuolatinės srovės įrangai elektros energija gali būti tiekiamas iš elektros baterijų ar kitų atsietų nuo elektros tinklo elementų. Tai leidžia tokią elektros įrangą lengviau pritaikyti ir panaudoti įvairioms užduotims atlikti.



1.2 pav. Nuolatinės srovės variklio su nuolatiniais magnetais konstrukcija [1]



1.3 pav. Išardytas nuolatinės srovės variklis: kairėje – nuolatiniai magnetai (statorius); dešinėje – variklio besisukanti dalis (rotorius) [1]

Nuolatinės srovės variklio konstrukcija yra sąlyginai paprasta lyginant su kitų tipų elektros varikliais, išskyrus nuolatinės srovės variklius be šepečių mazgo, kuriems reikia papildomos srovės komutacijos, naudojant išorinę įrangą. Tai leidžia nuolatinės srovės variklius panaudoti daugelyje sričių. Vis dėlto, šie varikliai tiek dėl konstrukcijos, tiek dėl veikimo principo turi pranašumų ir trūkumų. Todėl šie varikliai negali būti pritaikyti visose srityse. Kaip jau anksčiau minėta, kiekviena nuolatinės srovės variklio rūšis turi tam tikrą pritaikymo sričių. Tai sąlygoja šių variklių charakteristikų ypatumai priklausomai nuo variklio konstrukcijos. Paprasti nuolatinės srovės varikliai su nuolatiniais magnetais yra plačiausiai paplitę, nes jie lengvai pritaikomi ir yra neatsiejami nuo daugelio automatikos, elektronikos įrenginių ir juose vykstančių vidinių procesų. Tai daro šiuos variklius svarbiais ir aktualiais dabartinėje pramonėje.

1.2. Nuolatinės srovės variklių gedimai

Iš mažos galios nuolatinės srovės variklio konstrukcijos (žr. 1.2 ir 1.3 pav.) bei praktinės gedimų analizės galima išskirti keletą galimų gedimų šaltinių [4;5]: gedimai šepečių mazge, trumpi jungimai tarp apvijų nuolatinės srovės variklio rotoriuje dėl izoliacijos pažeidimo, guolių nusidėvėjimas, nuolatinės srovės variklio veleno pažeidimai dėl netinkamos eksploatacijos, bei kitus gedimus, atsirandančius tiek dėl vidinių variklio gedimų, tiek dėl išorinių priežasčių [2]. Toks skirstymas tikslingas, kai reikia nuspręsti, koks buvo poveikio šaltinis ir kaip pakeisti variklio sąlygas, norint išvengti pakartotino variklio gedimo dėl minėtų priežasčių.

Nuolatinės srovės varikliuose su šepečiais dažniausiai gendančia grandimi yra laikomas šepečių mazgas. Gedimas šepečių mazge pasireiškia kibirkščiavimu. Kibirkščiaavimo priežastys gali būti variklio perkrova, netinkamas šepečių instaliavimas, nelygus komutatoriaus paviršius, netinkamai parinkta šepečių anglies klasė, defektai armatūroje ar statoriaus apvijose, per stiprus ar per silpnas šepečių įtvirtinimas laikikliuose [5]. Šepečiai yra silpnoji nuolatinės srovės variklių grandis. Tai trukdo šiuos variklius plačiai pritaikyti ir ši dalis dažnai pakeičiama naudojant NS variklius be šepečių mazgo. Tai leidžia išspręsti dalį nuolatinės srovės variklio trūkumų.

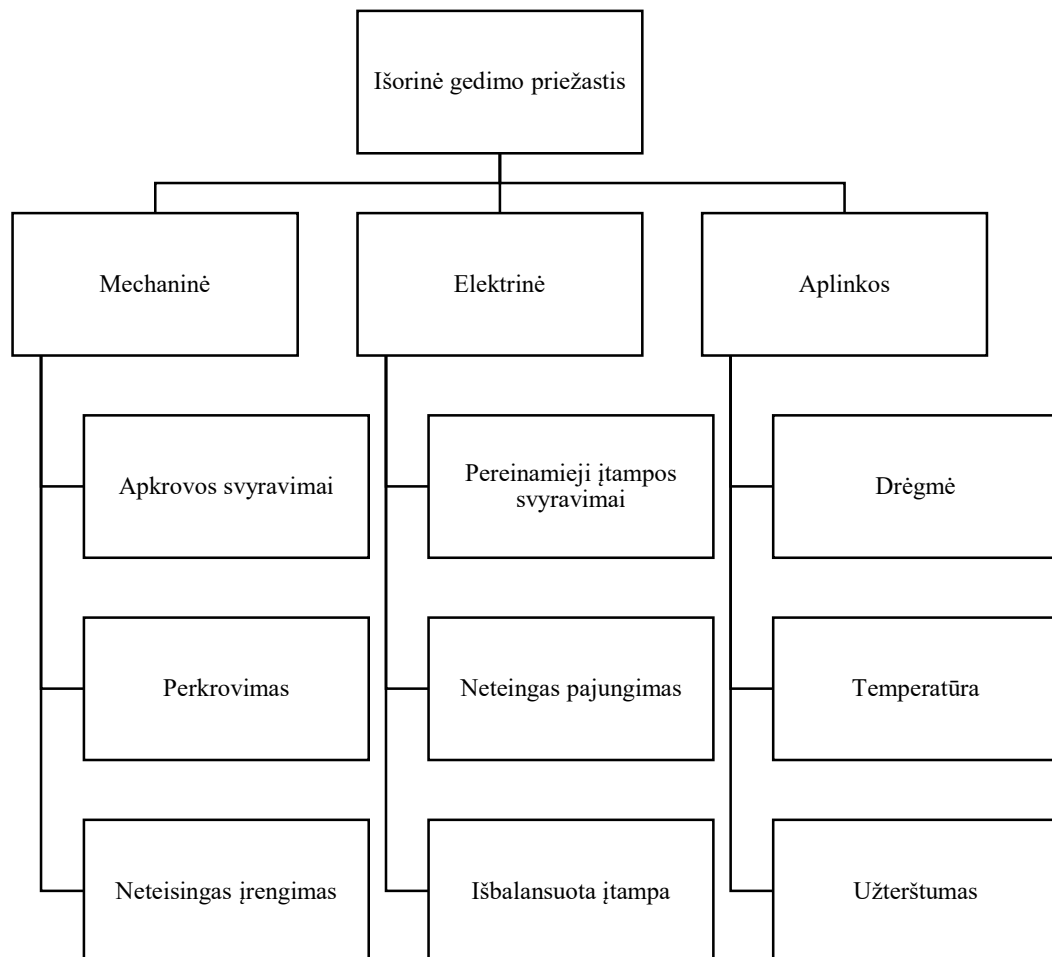
Kiti galimi gedimai atsiranda dėl nutrūkusių elektros laidininkų. Nutrūkęs laidininkas sudaro atvirą elektros grandinę. Taip pat galimos nusidėvėjusios izoliacijos tarp laidininkų, dėl kurių atsiranda trumpi jungimai tarp variklio apvijų. Galimi ir kiti gedimai, kai elektros laidininko izoliacija nusidėvi ir srovė pradeda tekėti nuolatinės srovės variklio korpusu. Tai sukelia įžemėjimo gedimus [5]. Daugelis gedimų taip pat gali atsirasti dėl mechaninių priežasčių, perkrovų, netinkamos variklių priežiūros. Svarbu tinkamai variklį prižiūrėti, kad neatsirastų gedimų dėl aplinkos sukkelto poveikio. Tokio tipo gedimai yra kenksmingi visoms variklio grandims, nes naudojant ir eksploatuojant variklį netinkamoje aplinkoje atsiranda tiek mechaninio, tiek elektrinio pobūdžio gedimų elektros įrangoje.

Kadangi nuolatinės srovės varikliai su nuolatiniais magnetais yra naudojami daugelyje buitinių elektros įrenginių, kur jie dažnai gali būti perkraunami, svarbi šių variklių savybė yra ta, kad jie gali atlaikyti perkrovas sąlyginai ilgiau lyginant su kitų tipų varikliais [3], tačiau po tam tikro laiko šių variklių mechaninė konstrukcija neatlaiko apkrovų kaip ir kitų tipų varikliai. Vis dėlto, pranašumas atlaikyti didesnes perkrovas yra naudingas dėl šių variklių pritaikymo sričių, kurios šiais laikais dažniausiai yra elektronikoje ir automatikos įrenginiuose. Tai suteikia šio tipo varikliams pranašumą ir padidina jų paklausą.

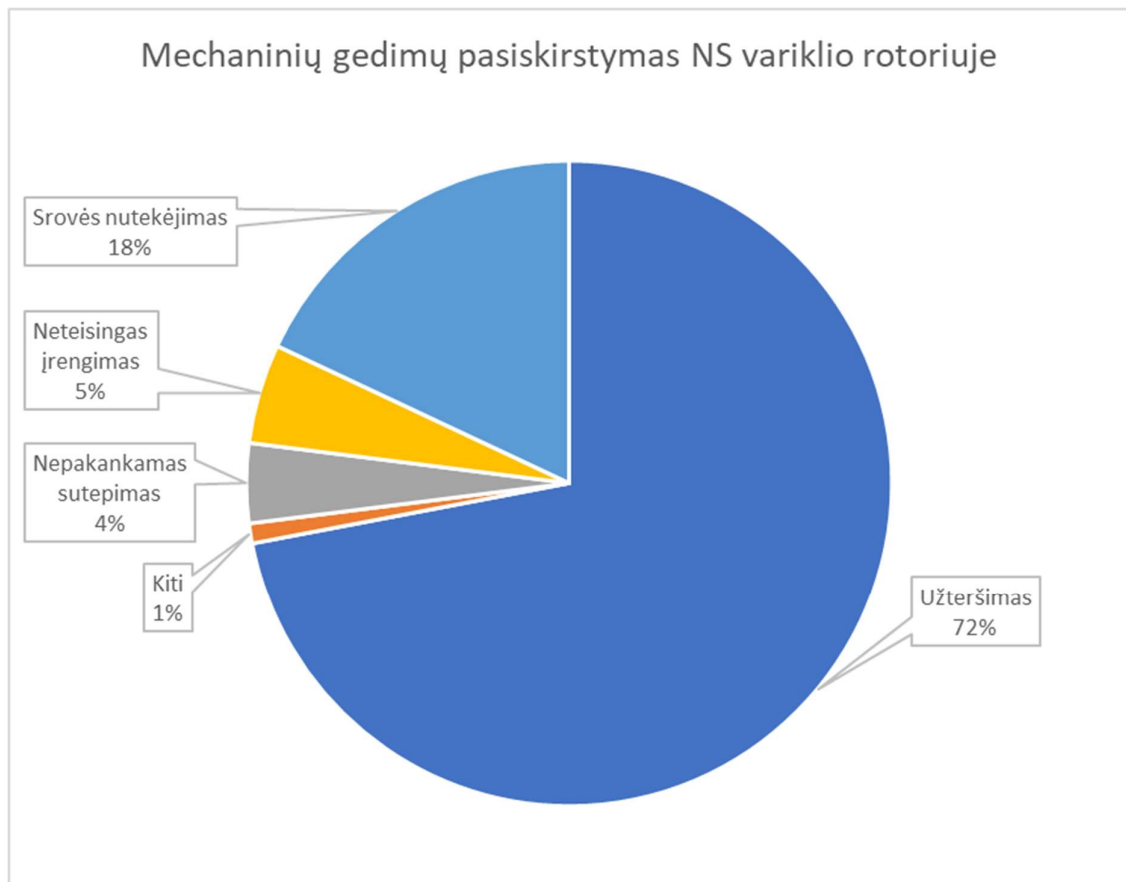
1.1 lentelė. Variklio rotoriaus gedimų klasifikavimas [2]:

Rotoriaus gedimai	Šiluminiai
	Elektromagnetiniai
	Liekamieji
	Dinaminiai
	Mechaniniai
	Išorinio poveikio

Gedimai nuolatinės srovės elektros varikliuose kaip ir kitų tipų varikliuose gali atsirasti dėl įvairių priežasčių. Gedimai galimi tiek dėl vidinių gedimų nuolatinės srovės variklyje, tiek dėl išorinio aplinkos poveikio ar netinkamo variklio įrengimo. Išorinių gedimo priežasčių gali būti įvairių tipų. Pagrindinės šių gedimų rūšys gali būti skirstomos į mechaninius, elektrinius bei aplinkos poveikio sukeltus gedimus. Vidiniai gedimai nuolatinės srovės elektros mašinoje atsiranda dėl nusidėvėjimo, variklio perkrovų, dėl ko pažeidžiama vidinė variklio konstrukcija ir sutrikdomas normalus variklio veikimas. Nepastovus nuolatinės srovės variklio veikimas gali sustabdyti mechanizmą, kurio dalis yra nuolatinės srovės variklis arba pabloginti mechanizmo veikimo charakteristikas. Tai yra nepageidautina visų tipų pritaikymo srityse. Norint išvengti tokių pasekmių, turi būti taikomos kompleksinės priemonės profilaktiniai variklių techninei apžiūrai ir ankstyvai gedimų diagnostikai. Kompleksinėmis priemonėmis galima laikyti tinkamos gedimų diagnostikos sistemos pritaikymą, techninio personalo parengimą gedimų analizei, kompiuterinės įrangos paruošimą gedimų atpažinimui. Svarbu stebėti variklio veikimo parametrus ir automatizuoti gedimų diagnostiką, nes techninis personalas ne visada gali pastebėti gedimą, o ilgą laiką nepastebėtas gedimas gali neigiamai paveikti elektros sistemos darbą.



1.4 pav. Išorinių variklio gedimo priežasčių klasifikavimas [2]



1.5 pav. Mechaninių gedimų pasiskirstymas NS variklio rotorijoje [2]

Kaip matyti iš pateiktų gedimų pavyzdžių nuolatinės srovės varikliuose ir jų priežasčių, gedimų nuolatinės srovės variklio darbo cikle po tam tikro laiko sunku išvengti. Todėl svarbi užduotis yra laiku diagnozuoti gedimą ir jį panaikinti pakeitus pažeistas nuolatinės srovės variklio grandis arba patį variklį. Nuolatinės srovės varikliai dažnai naudojami įvairioje buitinėje įrangoje bei pramonės srityse, kur reikia geros šių variklių greičio reguliavimo charakteristikos. Kita svarbi šio variklio galimybė yra atlaikyti didesnes perkrovas tam tikrą laiką [3]. Taip pat nuolatinės srovės varikliai yra lengviau įrengiami, jiems dažnai nereikalinga sudėtinga valdymo įranga. Be to, nuolatinės srovės varikliai pradėti plačiai taikyti elektrinėse mašinose bei įvairioje automatikos įrangoje, nes šie varikliai naudoja nuolatinę elektros srovę. Tai yra patogu daugelyje sričių, nes šiems varikliams elektros energiją galima tiesiogiai tiekti iš baterijų ir juos nebūtina tiesiogiai jungti prie elektros tinklo.

Taip pat svarbu paminėti, kad kita dalis variklių gedimų gali būti sukeliama dėl netinkamai parinktos variklio apkrovos ar netinkamai parinktų variklio charakteristikų. Tam, kad variklis atitiktų optimalias darbinės charakteristikas ir būtų išvengiama gedimų kaip įmanoma ilgiau yra svarbu tinkamai parinkti nuolatinės srovės variklį atitinkamai pritaikymo sričiai. Skirtingi nuolatinės srovės varikliai ir nuolatinės srovės variklių tipai: nuoseklus jungimo, lygiagretaus jungimo, mišraus jungimo ar nuolatinės srovės varikliai su nuolatiniais magnetais stacionarioje variklio dalyje turi skirtingas charakteristikas ir parametrus, pagal kuriuos galima šiuos variklius pritaikyti skirtingiems uždaviniams, kuriems atitinkamo tipo varikliai yra geriausiai tinkami.

Norint išvengti netikėtų gedimų, svarbi sritis, į kurią investuoja daugelis gamybos įmonių yra išankstinė gedimų diagnostika, gedimų atpažinimas [4]. Naudojant išankstinę gedimų diagnostiką galima prieš atsirandant gedimui identifikuoti elektros mašinos pakitimus arba, atsiradus gedimui, jį kaip įmanoma tiksliau ir greičiau identifikuoti ir panaikinti. Tai itin aktualu nuolatinės srovės varikliams, nes, kaip jau anksčiau minėta, šio tipo varikliai genda ganėtinai dažnai dėl tam tikrų variklio silpnųjų grandžių. Todėl rekomenduojama nuolatos tikrinti pakitimus šepėčių mazge, patikrinti nuolatinės srovės variklio izoliacijos kokybę atitinkamais laiko tarpais [4]. Taip pat svarbu tinkamai gedimus atpažinti. Tai suteikia galimybę greitai panaikinti gedimus. Laiku pastebėti gedimai tiek nuolatinės srovės, tiek kitų tipų elektros varikliuose leidžia laiku taikyti gedimų prevencijos priemones, kai naudojama išankstinės gedimų diagnostikos įranga, o gedimui atsiradus, jį greičiau pašalinti ir atstatyti normalų nuolatinės srovės variklio ar kito tipo sistemos darbą ir sumažinti galimus nuostolius, kurie gali atsirasti dėl gedimo.

Plačiai naudojama paprasta variklių apžiūra ne visada identifikuoja visas variklio problemas. Be to, mažesnio dydžio variklių patikra gali būti sudėtinga ir patikros metu galima pažeisti variklio konstrukciją. Todėl populiarėja kitos variklių patikros rūšys, iš kurių populiariausia laikoma vibracijos analizė, kuri atliekama naudojant specialią vibracijos analizės įrangą ir kuri suteikia galimybę nepažeidžiant variklio konstrukcijos tinkamai identifikuoti gedimą ir net sustabdyti tolesnių gedimų atsiradimą. Tai galima, nes tam tikri pakitimai elektros variklio vibracijose pastebimi, kai gedimas yra pradinėje būsenoje ir nesugadino elektros mašinos ar nepakeitė jos veikimo parametrų. Vibracijų analizė yra informatyvus ir plačiai pritaikomas metodas, naudojamas tiek kintamos, tiek nuolatinės srovės varikliams [4;5].

Be vibracijos analizės naudojami ir kiti metodai, kuriais galima nustatyti ir klasifikuoti elektros mašinų gedimus. Mokslinėje praktikoje tyrinėjami metodai, kuriais stebimos kitos nuolatinės srovės elektros mašinos fizikinių signalų charakteristikos kaip maitinimo srovės kitimas priklausomai nuo gedimų elektros variklyje bei elektros mašinų skleidžiamo garso kitimai priklausomai nuo elektros mašinos gedimų. Dauguma gedimų, sukeltų dinaminių, mechaninių pokyčių atsispindi ir srovės bei garso signaluose. Šie metodai yra patogūs, nes galima panaudoti paprastas variklio charakteristikas nuolatinės srovės variklio gedimų atpažinimui. Tai suteikia galimybę, naudojant įvairius jutiklius užfiksuoti variklio fizikinių signalų pokyčius, kuriuos galima panaudoti diagnozuojant ir tinkamai klasifikuojant signalų pakitimus. Tokiu būdu galima greitai atpažinti gedimus ankstyvoje stadijoje.

Gedimų diagnostika yra aktuali ir vis daugiau svarbos šiuolaikinėje pramonėje įgyjanti tyrimų sritis. Tinkama ir gerai pritaikoma gedimų diagnostikos sistema suteikia galimybę greitai ir efektyviai diagnozuoti gedimus ir atlikti techninius sprendimus šių gedimų pašalinimui. Automatikos uždaviniuose yra svarbu automatizuoti ir šį gedimų diagnostikos procesą. Anksčiau gedimų diagnostika buvo atliekama daugiausia techninių apžiūrų metu, kada techninis personalas testuodavo techninę įrangą dėl gedimų arba gedimų būdavo ieškoma jau atsiradus netinkamiems elektros įrangos parametrams. Vis dėlto, toks tik organizacinėmis priemonėmis paremtas variklių gedimų diagnozavimas nebėra optimalus šiuolaikiniame ketvirtosios pramonės revoliucijos kontekste, kai automatiniam veiksmų atlikimui teikiamas vis didesnis dėmesys ir stengiamasi automatizuoti visus gamybos procesus. Toks automatizavimas yra taikytinas ir gedimų diagnostikai, kuri yra neatsiejama nuo tinkamo elektros sistemos darbo, nes visa elektros įranga po tam tikro tarnavimo laiko turės techninių gedimų. Svarbus uždavinys yra šių gedimų greitas atpažinimas, kai gedimas yra pradinėje būsenoje, ir jo pašalinimas.

1.3. Signalų apdorojimas

Analoginiai signalai, kurie yra gaunami tiriant mus supančią aplinką yra sudaryti iš daug šalutinių komponentių, kurios sudaro bendrą signalą. Tokios komponentės gali būti nepastovios ir sunku iš jų nustatyti informaciją apie signalo pobūdį, palyginti skirtingus signalus. Norint to išvengti, yra naudojama daugelis signalo apdorojimo priemonių, leidžiančių matuojamą signalą transformuoti informatyviu transformuotu signalu, kurį galima panaudoti palyginimo bei kitiems uždaviniams, kai signalo pagrindinės komponentės yra aiškiai matomos.

Signalų apdorojimo uždaviniams yra naudojama daug analizės priemonių. Pagrindine ir dažniausiai naudojama priemone yra laikoma Furjė transformacija, nuo kurios pritaikymo pradžios daugelis signalų apdorojimo uždavinių yra sprendžiami naudojant šią transformaciją. Furjė transformacijos veikimo principą galima trumpai paaiškinti kaip signalo kitimo laike transformaciją į signalo kitimą pagal dažnį [6]. Panaudojus tokią metodiką išryškinami esminiai signalo aspektai ir yra lengviau analizuoti bei palyginti signalus. Išmatuotas analoginis signalas yra sunkiai skaitomas ir turi daug skirtingų komponentių ir šalutinių triukšmų, kurie signalo analizę daro sudėtinga. Tam reikia atlikti signalo spektrinę transformaciją, kuriai dažnai yra naudojamas Furjė transformacijos metodas. Yra ir kitų metodikų kaip Kepstro analizė bei Walsh–Hadamard transformacija ir kitos, kurios taip pat naudojamos signalų spektrinėse transformacijose, nors nėra taip dažnai naudojamos kaip Furjė transformacija. Šios transformacijos gali pasiekti tokių pačių ar net geresnių rezultatų lyginant su Furjė transformacija, tačiau nėra taip plačiai taikomos moksliniuose darbuose. Skirtingos signalų transformacijos gali būti efektyvios skirtingų užduočių atlikimui. Svarbu signalo analizės būdus išmėginti įvairiems tyrimams.

Signalai dažnai turi esmines struktūrines dalis, kurios lyginant signalus sutampa. Tai galima vadinti signalų koreliacija arba sutapimu [7]. Tai yra itin svarbu pašalinant nenorimas signalo komponentes, kurios neatitinka bendros signalo charakteristikos. Koreliaciją dar galima skaidyti pagal signalų lyginimo metodiką: kai lyginama su pačiu signalu praėjus laiko tarpui autokoreliacijos atveju ir kai lyginama su kitu signalu kryžminės koreliacijos atveju [7]. Autokoreliacijos panaudojimas yra naudingas, kai žinomas signalas ir tai, kad jis turi panašių bruožų laikui kintant, kryžminę koreliaciją tikslinga panaudoti, kai imami keli signalai ir yra žinoma pageidautina signalo forma, kuri laikoma etalonu. Tokios priemonės reikalingos tinkamam signalų apdorojimui ir tam, kad būtų išryškinama bendra signalo forma be šalutinių trumpalaikių triukšmų. Tai suteikia galimybę pastebėti esminius signalo bruožus be šalutinių signalo komponentių.

Signalų analizei yra naudinga panaudoti signalų transformacijos būdų kombinacijas su signalų koreliacija. Tai tikslinga daryti, nes pakeitus signalą tam tikra transformacija kartu su koreliacija galima panaikinti šalutines signalo komponentes, palikti pačius esminius signalo bruožus, kurie toliau gali būti lyginami su kitais signalais ir nustatomi signalo pokyčiai. Tai yra aktualu, kai norima palyginti skirtingus gedimų signalų spektrus ir nustatyti pokyčius signalo spektre po skirtingų gedimų, išryškinti esminius signalų bruožus. Esminiai signalų bruožai gali būti apibūdinami kaip kreivės, gautos po atliktų signalų transformacijos veiksmų. Tada galima gauti transformuotus signalus, kuriuos lengva palyginti ir klasifikuoti. Pagal tokio palyginimo rezultatus sprendžiama apie transformavimo būdų efektyvumą bei jų pritaikomumą atliekantiems diagnostikos uždaviniams.

1.3.1. Furjė transformacija

Furjė transformacija yra signalų analizės būdas, kurio pagalba iš neaiškaus ir sunkiai analizuojamo signalo galima gauti naują signalo formą, kurioje pradinio signalo kitimas laike transformuojamas į signalo kitimą pagal dažnį [6]. Taip išryškunami atskiri signalo aspektai, kurie gali būti panaudoti signalo esminių bruožų atpažinimui ir atskyrimui. Tai yra itin svarbu lyginant skirtingus signalus tarpusavyje ir analizuojant signalo bruožus. Furjė transformacija yra labai populiarius signalų transformacijos būdas, kuris yra dažnai randamas įvairioje mokslinėje literatūroje, kai atliekama signalų transformacija. Šis signalų transformacijos būdas plačiai ir sėkmingai pritaikomas ir yra naudojamas kaip pagrindinis spektrinės analizės įrankis daugelyje įrenginių, atliekančių greitą signalų transformaciją ir duomenų apdorojimą. Taip pat Furjė transformacija turi keletą skirtingų atmainų kaip diskretinę Furjė transformaciją ir itin populiarią jos atmainą greitąją Furjė transformaciją, kuri efektyviai ir plačiai pritaikoma įvairiuose moksliniuose uždaviniuose. Greitoji Furjė transformacija yra efektyvesnis diskretinės Furjė transformacijos pritaikymo būdas, leidžiantis pasiekti geresnių rezultatų.

Norint atlikti Furjė transformaciją pirmasis žingsnis yra Furjė analizės atlikimas, kurios metu tiriamas signalas yra palyginamas su įvairių dažnių sinusoidiniais signalais. Taip kiekvienam dažniui patenkančiam į $w \in R$ surandamas intensyvumo koeficientas $d_w = R \geq 0$. Priklausomai nuo tiriamo signalo sutapimo su sinusoidiniu signalu gaunamas skirtingas intensyvumo lygis: d_w didelis, kai sutapimas tarp signalų didelis ir mažas, kai sutapimas mažas. Tuomet koeficientai d_w gali būti atvaizduojami pagal įvairius dažnius.

Sinusoidinio signalo principinė lygtis [6]:

$$g(t) = A \cdot \sin 2\pi(2\pi(wt - \varphi)) \quad (1.1)$$

Čia: $g(t)$ – sin signalas; A – amplitudė; w – dažnis, Hz; t – laikas, s; φ – fazė, rad.

Kiekvienam dažnio parametru w ir φ fazės parametru yra gaunama funkcija [6]:

$$\cos_{w,\varphi}(t) = \sqrt{2} \cdot \cos(2\pi(wt - \varphi)) \quad (1.2)$$

Šioje lygtyje pateikiama kosinuso signalo reprezentacija: $\cos_{w,\varphi}(t)$. Amplitudė Furjė analizėje atitinka $\sqrt{2}$ taip optimizuojant funkcijos svyravimus su jų intensyvumu.

Norint įvertinti signalų panašumą yra įvertinamas jų bendras integralas [6]:

$$\int_{t \in R} f(t) \cdot g(t) dt \quad (1.3)$$

Lygtyje pateikiamas tiriamos funkcijos $f(t)$ ir sinusoidinio signalo $g(t)$ integralas, kai $t \in R$.

Intensyvumo koeficiento ir fazės koeficiento apskaičiavimas [6]:

$$d_w = \max_{\varphi \in [0,1)} \left(\int_{t \in R} f(t) \cos_{w,\varphi}(t) dt \right) \quad (1.4)$$

$$\varphi_w = \operatorname{argmax}_{\varphi \in [0,1)} \left(\int_{t \in R} f(t) \cos_{w,\varphi}(t) dt \right) \quad (1.5)$$

Šiose lygtyse: d_w – intensyvumo koeficientas; φ_w – fazės koeficientas. Šiais koeficientais apibrėžiama signalo transformacija atitinkamai pagal sinusoidinį signalą. Intensyvumo koeficientas parodo dažnio intensyvumą signale, o fazės koeficientas parodo kaip signalas turi būti pastumtas laike sinusoidinio signalo atžvilgiu.

Furjė transformacijos lygtis ir Furjė lygties atvaizdavimas [6]:

$$f^{\wedge}(w) = \int_{t \in R} f(t) \exp(-2\pi i w t) dt = \\ = \int_{t \in R} f(t) \cos(-2\pi i w t) dt + i \int_{t \in R} f(t) \sin(-2\pi i w t) dt \quad (1.6)$$

$$f(t) = \int_{w \in R_{\geq 0}} d_w \sqrt{2} \cdot \cos(2\pi(wt - \varphi)) dw = \quad (1.7)$$

$$= \int_{w \in R} c_w \exp(2\pi i w t) dw \quad (1.8)$$

Pateiktose lygtyse pateikiama pilna Furjė transformacijos išraiška ir Furjė transformacijos atvaizdavimas realia ir kompleksine komponentėmis (žr. atitinkamai 1.6, 1.7, 1.8 formules).

Diskretinė Furjė transformacija [6]:

$$X(k) = x^{\wedge}\left(\frac{k}{N}\right) = \sum_{n=0}^{N-1} x(n) \exp\left(\frac{-2\pi i k n}{N}\right) \quad (1.9)$$

Šioje lygtyje N - kompleksiniai skaičiai; k – įvertis tam tikrame taške.

Diskretinė Furjė transformacija yra naudojama daug plačiau signalų apdorojimo uždaviniams, nes tokia transformacija tiria ne visą analoginį signalą, o tiria jį tam tikrais laiko intervalais. Tai palengvina signalų transformavimo uždavinį. Itin plačiai paplitusi ir atliekamame tyrime taip pat panaudojama greitoji Furjė transformacija (FFT), kuri yra diskretinės Furjė transformacijos atmaina. Greitoji Furjė transformacija panaudoja skaičiavimo palengvinimus, kurie gali sudėtingus skaičiavimo uždavinius atlikti greičiau negu su diskretine Furjė transformacija. Greitoji Furjė transformacija yra pajėgi sumažinti skaičiavimo uždavinį kompiuterinei įrangai, nes vietoje N^2 duomenų imties apdorojimo, greitajai Furjė transformacijai užtenka apdoroti $N \log N$ duomenų imtį. Dėl šios priežasties didelės imties duomenų apskaičiavimas yra atliekamas daug efektyviau, kai naudojama greitoji Furjė transformacija vietoje diskretinės Furjė transformacijos.

Furjė transformacija gali būti laisvai pritaikoma įvairių uždavinių sprendimui, nes, naudojant šią transformaciją, galima surasti įvairius pakitimus signale ir juos išryškinti iš bendros signalo kreivės. Furjė transformacija sėkmingai panaudojama ir atliekamam tyrimui reikiamuose gedimų analizės uždaviniuose [8;9]. Panaudojus Furjė transformaciją tiriamas signalas pakeičiamas į naują signalo formą, kurioje matomi esminiai signalo bruožai, kuriuos galima panaudoti įvairiems tyrimams atlikti: signalus galima panaudoti neuroniniuose tinkluose, kurie gali lyginti signalus ir priskirti juos atitinkamai kategorijai arba vizualiai lyginti signalus, nes po Furjė transformacijos iš daugelio pradinio signalo svyravimų lieka tik kelios aukštos amplitudės signalo komponentės, kurios gali būti lyginamos tarpusavyje. Šių komponentių palyginimas suteikia galimybę įvertinti įvairias tiriamų objektų savybes ir pabrėžti esminius įvairių signalų bruožus.

Furjė transformacija nėra vienintelis metodas signalų analizei [10]. Tačiau ši transformacija yra greita ir efektyvi. Tai jai dažnai suteikia pranašumą prieš kitus analizės metodus. Furjė transformacija turi daug atšakų, kaip ir minėta diskretinė Furjė transformacija ar jos atmaina – greitoji Furjė transformacija. Plačiausiai pritaikoma Furjė transformacijos atmaina galima laikyti greitąją Furjė transformaciją. Gedimų diagnostikos uždaviniams tokią transformaciją galima lengvai ir efektyviai panaudoti [6;8;9;10]. Greitoji Furjė transformacija (FFT) dėl jos galimybių transformuoti diskretinį signalą į spektrą suteikia plačias galimybes greitai ir efektyviai atlikti sudėtingus signalų transformavimo uždavinius. Tai yra itin svarbu įvairioje automatikos įrangoje, kur signalų palyginimui ir atpažinimui dažnai naudojami etaloniniai signalai gauti panaudojus šią transformaciją.

1.3.2. Kepstro analizė

Kepstro analizė yra kitas signalų transformacijos metodas, kuris gali aptikti pasikartojimą dažnio spektre. Dėl to Kepstro analizė daugiausia naudojama garso signalų apdorojimui [11], bet gali būti sėkmingai panaudota ir kitų tipų signalams, pavyzdžiui, tokiuose uždaviniuose kaip gedimų diagnostika [12]. Kepstro analizė turi keletą atmainų, kurios yra skirtingai apskaičiuojamos ir pritaikomos skirtingų uždavinių atlikimui. Pagrindinės Kepstro rūšys yra realioji ir kompleksinė Kepstro transformacijos. Kompleksinės Kepstro funkcijos transformuotame signale yra išlaikoma tiek fazės, tiek amplitudės informacija, pagal kurią prieš tai buvęs signalas gali būti atkuriamas. Realiosios Kepstro transformacijos atveju fazės informacija nėra išsaugoma, o yra išsaugoma informacija tik apie signalo amplitudę. Kepstro analizė daugiausia pritaikoma garso transformavimo uždaviniuose, vis dėlto šį signalų analizės būdą galima pritaikyti ir gedimų diagnostikai [12].

Kepstro analizę galima laikyti Furjė transformacijos atmaina, nes abi transformacijos yra susietos. Atlikus signalo Kepstro analizę signalas yra transformuojamas į dirbtinio laiko sritį [13]. Tai suteikia galimybę Kepstro transformacijai ganėtinai tiksliai transformuoti įvairius signalus, ką galima panaudoti daugelyje sričių, ne vien tradicinėse Kepstro analizės pritaikymo srityse kaip garso analizė [11], bet tokiose kaip gedimų diagnostika. Tai aktualu atliekamame darbe. Taip pat tokį signalą galima papildomai transformuoti laikant jį paprastu signalu.

Realiosios Kepstro funkcijos išraiška [12]:


$$C_r(n) = \frac{1}{2\pi} \int_{-\pi}^{\pi} \log X(e^{jw}) |e^{jwn} dw \quad (1.10)$$

Šioje lygtyje $C_r(n)$ – reali Kepstro funkcija; X – realus signalas; w – dažnis, Hz.

Kompleksinės Kepstro funkcijos išraiška [12]:

$$C_k(n) = \frac{1}{2\pi} \int_{-\pi}^{\pi} \log X(w) |e^{jwn} dw \quad (1.11)$$

Šioje lygtyje $C_k(n)$ – kompleksinė Kepstro funkcija.



1.6 pav. Ryšys tarp spektro ir Kepstro [12]

Kepstro analizę galima naudoti kaip vieną iš signalo transformacijos metodų tiriant gedimus elektros sistemose dėl jos plačių galimybių aptikti įvairius dėsningumus signalo spektre bei to, kad toks signalų transformavimo būdas yra panaudojamas gedimų diagnostikos uždaviniuose mokslinėje literatūroje [12]. Galima atlikti tiek realiąją, tiek kompleksinę Kepstro analizę (žr. 1.10; 1.11 formules) tiriant signalus. Be to, kadangi Kepstro funkcija signalą pakeičia į dirbtinio laiko erdvę [13], šiam signalui galima atlikti pakartotinę Furjė transformaciją. Tiek realioji ar kompleksinė Kepstro transformacijos, tiek jų pakartotina kombinacija su Furjė transformacija gali būti naudingos tiriant signalus. Naudojant tokius būdus galima efektyviai rasti esminius signalo požymius.

1.3.3. Walsh–Hadamard transformacija

Walsh–Hadamard transformacija yra, kaip ir anksčiau minėta Kepstro analizė, panaši į Furjė transformaciją. Walsh-Hadamard transformaciją galima apibūdinti kaip 2 vienetų dydžio diskretinę Furjė transformacijos matricą, kuri priklauso nuo šios transformacijos funkcijų [14]. Walsh – Hadamard transformacija yra panaudojama daugelyje įvairių uždavinių kaip vaizdų apdorojimas, duomenų analizė, įvairių bruožų apdorojimui. Walsh – Hadamard transformacija yra vienas iš nedaugelio signalų transformacijos būdų, nenaudojančių sinusoidinio signalo transformacijai. Vietoje to yra atliekama tiesinė operacija 2^m dydžio matricai, kurioje yra apdorjami duomenys, reikalingi signalų apdorojimo uždaviniui atlikti.

Walsh-Hadamard transformacija yra 2×2 dydžio matrica, sudaryta iš kintamųjų: $H_0=1$ ir H_m , kuris turi būti didesnis už nulį $H_m > 0$. Esant tokioms sąlygoms galima užrašyti Walsh-Hadamard transformacijos matematinę išraišką.

WHT matematinė išraiška [14]:

$$H_1 = \frac{1}{\sqrt{2}} \begin{pmatrix} H_{m-1} & H_{m-1} \\ H_{m-1} & -H_{m-1} \end{pmatrix} \quad (1.12)$$

Šioje matematinėje išraiškoje H_1 – Walsh-Hadamard transformacija; $1/\sqrt{2}$ – normalizavimo koeficientas, kuris galima būti keičiamas priklausomai nuo pritaikymo.

Walsh-Hadamard transformacijos kintamieji [14]:

$$H_0 = +1 \quad (1.13)$$

$$H_1 = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \quad (1.14)$$

$$(H_n)_{ij} = \frac{1}{2^{n/2}} (-1)^{i*j} \quad (1.15)$$

Šiose lygtyse $i*j$ atitinka skaičių i ir j bitų reprezentaciją; n – apskaičiuojami taškai.

Walsh-Hadamard transformacija sėkmingai panaudojama daugelyje skirtingų sričių, tarp kurių yra gedimų diagnostika [14] bei analoginių signalų analizė [15]. Gedimų analizei naudojama Walsh-Hadamard transformacijos atmaina – greitoji Walsh-Hadamard transformacija. Tokia transformacija, kaip ir greitosios Furjė transformacijos atveju, yra optimizuotas algoritmas signalų spektrinei analizei. Greitoji Walsh- Hadamard transformacija kaip ir greitoji Furjė transformacijai reikia $N \log N$ skaičiavimų vietoje N^2 skaičiavimų WHT atveju. Toks būdo supaprastinimas leidžia apdoroti didesnį duomenų kiekį per tą patį laiką ir padidina būdo našumą.

Walsh-Hadamard transformacija skirtingai nei Furjė transformacija signalą išskaido į stačiakampius komponentus. Furjė transformacija signalą skaido į sinusoidės ir kosinusoidės komponentes. Dėl šios priežasties Furjė transformacijos apskaičiavimas yra sudėtingesnis lyginant su Walsh-Hadamard transformacija [14]. Tai suteikia šiai transformacijai tam tikrų pranašumų prieš Furjė transformaciją spartos atžvilgiu, ypač tada, kai naudojama greitoji Walsh-Hadamard transformacijos versija, kuri, vertinant efektyvumą ir tikslumą, yra tinkama daugeliui signalų apdorojimo uždavinių. Greitosios Walsh-Hadamard transformacijos panaudojimas įvairių tipų uždaviniuose gali būti kaip alternatyva kitiems signalų spektrinės transformacijos būdams.

1.3.4. Koreliacijos funkcija

Koreliacija yra būdas, skirtas palyginti signalus ir nustatyti jų panašumą. Koreliacijos pagalba galima panaikinti nenorimas signalo komponentes ir koreliaciją panaudoti kartu su kitomis signalų analizės priemonėmis kaip Furjė transformacija. Naudojant tokias priemones galima gauti esminius signalo bruožus ir panaikinti šalutines komponentes. Tai svarbu, nes tik taip pakeistas signalas gali būti palyginamas ir turėti aiškius bruožus, nes šalutiniai triukšmai, esantys signale, neleidžia tinkamai įvertinti signalų spektrą, nes, atlikus signalo spektrinę transformaciją ir nepašalinus triukšmų, yra sunku vizualiai palyginti keletą skirtingų signalo spektrų.

Signalų koreliaciją galima išskirti į kelias skirtingas rūšis: koreliaciją tarp to paties signalo po tam tikro laiko tarpo ir skirtingų signalų palyginimą [7]. Pirmuoju atveju tokia koreliacija yra vadinamoji autokoreliacija, o antru atveju gaunama kryžminė koreliacija. Autokoreliacija tikslinga tada, kai signalas yra pastovus ir neturi nuolatinių pokyčių, o kryžminė koreliacija patogi tada, kai yra lyginami keli skirtingai signalai tarpusavyje. Autokoreliacija ir kryžminė koreliacija sprendžia tą pačią problemą, skiriasi tik komponentas, su kuriuo yra lyginama tiriamą signalo dalis. Autokoreliacijos atveju yra lyginama su pačiu signalu po tam tikro laiko tarpo, o kryžminės koreliacijos atveju su kitu signalu, kurį galima laikyti etaloniniu signalu. Pagal tai galima parinkti, kokią koreliacijos funkciją reikia panaudoti atitinkamo uždavinio atlikimui.

Autokoreliacijos ir kryžminės koreliacijos lygtys [7;18]:

$$r_x[l] = x[l] \cdot x[-l] \quad (1.16)$$

$$r_{xy}[l] = \sum_{n=-\infty}^{\infty} x[n] \times y[n - l] \quad (1.17)$$

Šiose lygtyse pateikiama autokoreliacijos (žr. 1.16 formulę) ir kryžminės koreliacijos (žr. 1.17 formulę) funkcijos. Pirmoje funkcijose signalas lyginamas su pačiu savimi po tam tikro laiko pokyčio l , o antru atveju signalas yra lyginamas su kitu signalu, kai $-\infty < n < \infty$.

Koreliacijos metodika yra naudojama uždaviniuose, kuriuose tiriami įvairūs gedimai mechaninėse ir elektrinėse sistemose [16;17]. Koreliacija naudinga gedimų analizei, nes jos pagalba galima lengvai ir greitai nustatyti signalų bruožus. Koreliacijos skaičiavimų didelis pranašumas yra maži reikalavimai skaičiavimo kompiuterinei įrangai ir sąlyginai paprasta skaičiavimo metodika [16]. Tai suteikia galimybę greitai atlikti signalų tyrimus. Gedimų signalai turi tam tikrą sutapimą, kurį galima išryškinti koreliacijos metodu [17]. Šis sutapimas koreliacijos funkcijoje yra esminis ir gali būti įvertinamas juos palyginant ir klasifikuojant.

Koreliacijos funkcijos panaudojimas kartu su signalų spektrinėmis transformacijomis suteikia galimybę atlikti visapusišką signalo transformaciją ir palikti tik esminius bruožus, kuriuos galima palyginti ir klasifikuoti. Spektrinė transformacija yra panaudojama pradinei signalo analizei, o autokoreliacija naudojama tolesnei signalo analizei ir koreliuojančių komponentių radimui transformuotame signalo spektre. Spektro x ašies įverčiai yra pakeičiami ir nebeatitinka spektrinės funkcijos dažnio ir yra gaunama nauja skaičių matrica. Taip pašalinami triukšmai, kurie trukdo matyti spektro formą. Panaudojant tokį signalų analizės būdą galima gauti esminius signalo bruožus. Skirtingi signalai yra sunkiai palyginami neatlikus jų transformavimo veiksmų, todėl signalų transformavimo uždavinys išlieka svarbus.

1.4. Signalų klasifikavimas

Signalų klasifikavimo uždavinys yra svarbus žingsnis kiekvienoje gedimų diagnostikos automatizavimo sistemoje. Tokio uždavinio sprendimas yra svarbus, norint automatiškai atpažinti sistemoje esančius gedimus ir juos pateikti tam tikroje gedimų kategorijoje. Tokiems uždaviniams atlikti yra naudojami klasifikavimo algoritmai. Šiais laikais labiausiai paplitę klasifikavimo metodai yra mašininio mokymosi algoritmai ir neuroniniai tinklai, kurie turi skirtingas klasifikavimo galimybes ir dažnai yra pritaikomi skirtingų uždavinių sprendimui. Nėra universalaus pačio geriausio klasifikavimo sprendimo, kuris visais atvejais būtų tinkamiausias, todėl dažnai tiriama, koks klasifikavimo metodas yra tinkamiausias atskiram uždaviniui.

Pagrindiniai metodai, naudojami dabartinių klasifikavimų uždavinių atlikimui, yra mašininio mokymosi paremti algoritmai ir neuroninių tinklų klasifikavimo sistemos. Mašininis algoritmus galima apibūdinti kaip dirbtinio intelekto atšaką, kurioje automatinė sistema mokosi iš atliekamų užduočių ir tobulėja. Neuroniniai tinklai veikia panašiu principu, nes kaip ir mašininiai algoritmai ieško geriausio sprendimo klasifikavimo problemai. Jie yra mašininio mokymosi atšaka, pritaikanti kitokio modelio mokymo principą. Neuroniniai tinklai iš dalies atitinka ir bando imituoti žmogaus smegenų veikimą ir natūralų mokymosi procesą. Mašininiai algoritmai yra apmokomi ir naudoja įgytą patirtį klasifikavimo uždavinių atlikimui, o neuroniniai tinklai nuolatos mokosi iš gaunamos informacijos ir yra pajėgūs atpažinti savo klaidas. Tokie klasifikavimo būdai yra plačiai naudojami klasifikavimui įvairiuose uždaviniuose, tarp kurių yra ir gedimų klasifikavimo uždaviniai.

1.4.1. Mašininio mokymosi algoritmai

Mašininis mokymasis yra populiarus įvairiuose klasifikavimo uždaviniuose. Mašininio mokymosi algoritmai yra plačiai pritaikomi įvairiose sistemose. Jos naudojamos ir pramoninėse srityse kaip gedimų diagnostika.

Mašininio mokymosi algoritmai yra įvairūs ir naudojami skirtingose srityse, nes kiekvienas turi tam tikrų pranašumų skirtingose pritaikymo srityse. Vieni populiariausių mašininio mokymosi algoritmų, panaudojamų gedimų diagnostikos uždaviniuose yra k-NN (k-artimiausio kaimyno algoritmas) [20;21;23], SVM (pagalbinių vektorių algoritmas) [20;22;23] ir sprendimų medžio algoritmas [20;22;23]. Šie algoritmai yra efektyvūs gedimų klasifikavimo uždaviniuose ir leidžia sėkmingai ir efektyviai atpažinti gedimus.

Pirmasis iš minėtų mašininio mokymosi algoritmų yra k-NN arba k-artimiausio kaimyno paieškos metodas. K-NN algoritmo veikimas yra paremtas artimiausių reikšmių paieška nuo tam tikros reikšmės, kuriai buvo priskirta atitinkama atpažinimo klasė. Atpažinimo erdvės ašys yra išskaidomos į atitinkamo dydžio dalis su tam tikra tikimybe, kad šiose dalyse yra tam tikros klasės nustatomas objektas.

Tikimybės pasiskirstymo funkcija [20]:

$$p_i = \frac{n_i}{N\Delta_i} \quad (1.18)$$

Šioje lygtyje p_i - tikimybinio pasiskirstymo funkcija, s.v., n_i – duomenų pavyzdžių kiekis, s.v., N – visų duomenų kiekis, s.v., Δ_i – dalys, į kurias skaidoma atpažinimo erdvė, s.v.

Tikimybės priskyrimo funkcija, naudojama priskirti tikimybę atsitiktiniam pavyzdžiui [20]:

$$p(C_k/Z) = \frac{K_k}{K} \quad (1.19)$$

Šioje lygtyje p – tikimybė, kad tyrimo pavyzdys atitinka tam tikrą klasę, s.v., K_k – duomenų taškų kiekis k laipsnio skalėje, K – klasifikavime naudojamų duomenų kiekis.

Distancijai tarp skirtingų reikšmių nustatyti naudojama Euklido funkcija [20;21]:

$$d(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1.20)$$

Šioje lygtyje x ir y yra duomenų pavyzdžiai, naudojami nustatyti Euklidinius atstumus iki kitų elementų ir įvertinti, kuriai klasei, atpažinimo sistemai, pateikiami duomenys yra artimiausi.

K-NN algoritmas naudoja keletą skirtingų modifikacijų ir todėl turi skirtingų atpažinimo algoritmo atšakų, nors joms visoms taikomas bendras artimiausio kaimyno paieškos principas. Tokių algoritmų pavyzdžiai yra standartinis k-NN, vidutinis k-NN ir didelis k-NN, kurie skiriasi įvertinamų kaimynų skaičiumi. Atitinkamai įvertinami 1, 10 ir 100 kaimynų minėtų k-NN atvejais. Kiti k-NN algoritmai naudoja kitokią metodiką artimiausių kaimynų paieškai. Pavyzdžiui, kosinuso k-NN naudoja kosinuso funkciją distancijos įvertinimui, kubinis k-NN naudoja kubo formos distancijos įverčius, o svertinis k-NN suteikia skirtingiems taškams skirtingus svertinius įverčius pagal jų svarbą. Visos k-NN modifikacijos yra naudojamos praktikoje tik pritaikomos skirtinguose uždaviniuose.

Kitas plačiai naudojamas klasifikavimo algoritmas yra SVM arba pagalbinių vektorių algoritmas. Naudojant šį algoritmą yra pritaikomas tam tikras statistinės ribos įvertinimas statistinėje mokymosi teorijoje. SVM apmokymas yra paremtas išgaubtos kvadratinės funkcijos sprendimu. Šiame algoritme atpažinimo erdvė yra skaidoma į atskiras dalis. Algoritmo tikslas yra klasifikuojamą objektą priskirti tam tikrai atpažinimo žemėlapiu daliai panaudojant netiesinį atpažinimo žemėlapi. SVM algoritmo svarbiausias uždavinys yra atskirti turimą klasifikuojamą informaciją į tam tikras atskiras sekcijas erdvėje ir maksimaliai atitolinti atpažinimo taškus nuo pačios atskyrimo linijos [20;22;23].

Kaip ir k-NN atveju, taip ir SVM atveju, yra daug skirtingų SVM algoritmo atšakų. Kaip keletą efektyvesnių galima paminėti tiesinį SVM, kvadratinį, kubinį SVM, standartinį, vidutinį ir didelį gausinį SVM algoritmus. Kiekviena iš šių SVM algoritmų atmainų turi skirtingą sprendimo metodiką tam pačiam erdvės atskyrimo uždaviniui ir klasifikavimui, tačiau metodo esmė naudojama ta pati.

Dar vienas svarbus ir plačiai naudojamas mašininio klasifikavimo algoritmas yra sprendimų medis [20;22;23]. Tai klasifikavimo algoritmas, kuris atpažinimo erdvę išskaido į struktūrą, kuri yra panaši į medį ir yra su atskiromis atpažinimo šakomis. Tam panaudojamas rekursinis erdvės skaidymas. Pradinis atpažinimo medis gali būti skaidomas į mažesnes atšakas, kol pasiekiamas norimas rezultatas. Šio metodo tikslas yra sudaryti tokį medį, kurio klasės pereina į šakas, lapus ir taip atitinka medžio struktūrą, kuri atitinka norimą klasifikavimą, kur medžio šakos yra atskiros atpažinimo klasės, o lapai atitinka galutinius klasifikavimo sprendimus. Pačiame klasifikavimo viršuje yra medžio šaknis. Pagal ją vykdomas tolesnis skaidymas ir klasifikavimas. Šaknimi galima laikyti klasifikuojamų objektų pradinius bruožus. Atpažinimo medžiai gali būti standartiniai, vidutinio dydžio bei dideli.

Mašininio mokymosi algoritmai yra plačiai naudojami ir turi daug skirtingų atšakų net vieno algoritmo atveju. Tai matyti iš pateiktų pavyzdžių. Kiekvienas iš šių metodų turi pranašumų ir trūkumų, kurie turi būti nustatomi ir jų efektyvumas įvertinamas gedimų diagnostikos uždaviniuose.

1.4.2. Neuroniniai tinklai

Neuroniniai tinklai imituoja žmogaus smegenų darbą, nes jie yra sudaryti iš atskirų jungčių, kurios yra panašios į žmogaus smegenyse esančius neuronus. Šie neuronai gali būti apmokinami atpažinti įvairius objektus ir priskirti juos atitinkamoms klasėms. Tai atliekama panašiu principu kaip vyksta natūralus žmogaus mokymosi procesas, kai pagal įgytą patirtį žmogus gali atskirti tam tikrus objektus, juos atpažinti.

Kiekvieną neuroninį tinklą sudaro:

- vienas įėjimo sluoksnis, kuriame neuroniniam tinklui yra pateikiami klasifikavimui skirti duomenys;
- vienas ar keli paslėpti sluoksniai, kurie yra apmokinami ir nuo didesnių paslėptų sluoksnių skaičiaus priklauso neuroninio tinklo gilumas, tačiau per gilus tinklas gali būti nepajėgus atlikti apibendrintų sprendimų [26];
- išėjimo sluoksnis, kuriame gaunami klasifikavimo rezultatai.

Plačiausiai paplitęs yra tiesioginio atpažinimo neuroninis tinklas su grįžtamuju ryšiu (FFBPNN) [24;25;26], nors yra daug kitų skirtingų neuroninių tinklų modifikacijų. Toks tinklas papildomai be standartinio mokymosi naudoja skirtingus įvertinimo algoritmus, kurie leidžia pakeisti atpažinimo įverčius pagal tai, kaip gerai tinklas atskiria nustatytas atpažinimo klases. Tai suteikia galimybę neuroniniam tinklui koreguoti klaidingus atpažinimus ir efektyviau mokintis tiek iš patirties, tiek iš klaidų. Tokia neuroninio tinklo mokymosi metodika leidžia šį metodą pritaikyti plačiai įvairių uždavinių sprendimui. Neuroninių tinklų klasifikavimas taip pat yra naudojamas ir gedimų diagnostikos uždaviniuose, kur reikia atskirti skirtingas elektros variklių gedimo klases pagal signalų kreives arba pradinį gedimo signalą.

Vis dėlto, vienu iš neuroninių tinklų trūkumų galima laikyti tai, kad tinklui apmokinti dažniausiai reikia didelės duomenų imties, ką kartais yra sunku gauti dėl tam tikro tyrimo ribotumo. Be to, neuroninių tinklų apmokinimas užtrunka ilgiau negu atliekant klasifikavimo uždavinius paprastais mašininiais algoritmais. Tai ypač pastebima, kai naudojamas gilus neuroninis tinklas, kuriame yra ne vienas arba keli paslėpti sluoksniai, o dešimtys ar net šimtai paslėptų sluoksnių. Todėl neuroninių tinklų panaudojimas ne visada gali būti pats efektyviausias, nes galimas rezultato gavimas užtruktų daug ilgiau negu naudojant paprastą mašininį algoritmą kaip k-NN, SVM ar sprendimų medį, ar kitą mašininį algoritmą.

Tam tikriems uždaviniams neuroniniai tinklai yra itin svarbūs, nes paprasti mašininiai algoritmai nėra pajėgūs šiuos uždavinius spręsti efektyviai. Neuroninių tinklų galimybės yra itin ženklios dėl to, kad tinklas gali būti apmokinamas dideliu duomenų kiekiu ir mokintis iš savo klaidų. Tai leidžia tinklui nuolatos tobulėti ir pasiekti itin gerų rezultatų įvairiuose klasifikavimo uždaviniuose.

Neuroniniai tinklai tiek FFBPNN tinklo atveju, tiek kitais neuroninio tinklo atvejais yra vieni geriausių šiuo metu naudojamų klasifikatorių, tačiau visada reikia įvertinti jų efektyvumą pasirinktam uždaviniui, nes šie tinklai yra ilgai apmokinami ir netinkamai parinktas paslėptų sluoksnių skaičius gali pabloginti tyrimo rezultatus. Vis dėlto, tinkamai pritaikyti ir parinkti neuroniniai tinklai yra itin efektyvūs ir svarbūs įvairiuose uždaviniuose, tarp kurių yra ir gedimų diagnostika [24;25;26].

2. Gedimų diagnostikos įranga


Gedimai gali būti nustatomi daugeliu įvairių būdų. Diagnostikos metodų kombinacija dažnai yra naudinga visapusiškai gedimų analizei. Elektros variklių būklė gali būti nustatoma įvairiais būdais [19]. Tyrime nuspręsta panaudoti garso, srovės ir vibracijų jutiklius, kurie yra plačiai naudojami gedimų diagnostikos uždaviniuose [25;27]. Populiariausiu laikomas vibracijos diagnostikos būdas, kuris yra efektyviai naudojamas daugelyje gedimų diagnostikos uždavinių [43;44;45]. Vis dėlto, kiti būdai kaip srovės diagnostika taip pat parodo gerus tyrimų rezultatus [29;33]. Srovės diagnostika yra populiari pavarų sistemose, kur tai yra efektyvus gedimų diagnostikos būdas [25;31;32]. Srovės diagnostika yra pritaikoma ir kintamos srovės elektros sistemose [28], tačiau tikslinga šio būdo galimybes iširti ir tyrime naudojami nuolatinės srovės įrangai. Be to, vibracijos diagnostikai alternatyva gali būti ir garso diagnostika [36]. Toks diagnostikos būdas dažnai laikomas netinkamu, nes gali neužfiksuoti duomenų triukšmingoje aplinkoje. Vis dėlto, literatūroje galima rasti pavydžių, kur tai atliekama sėkmingai [37]. Garso analizė gali parodyti tinkamus rezultatus lyginant su vibracijos analize [38] ir būti panaudojama gedimų diagnostikos uždaviniuose [39;40;41]. Taip yra dėl to, kad vibracijos ir garso šaltiniai elektros sistemose gali būti įvairūs ir gerai perteikia atsiradusio gedimo pobūdį [42]. Minėti diagnostikos būdai taikomi kintamosios srovės elektros sistemose, tačiau retai nuolatinės srovės elektros sistemose [29]. Svarbus uždavinys yra iširti šių būdų galimybes tyrimui naudojamoje nuolatinės srovės sistemoje.

Jutiklių duomenų apdorojimui naudoti įvairūs signalo transformacijos metodai. Vienas iš jų yra spektrinė transformacija, kuri signalą transformuoja į jo dažnines komponentes. Šiuo metodu paremti daugelis transformavimo būdų: Furjė, Walsh-Hadamard, Kepstro ir kitos transformacijos. Po to, signalas buvo koreliuojamas su pačiu savimi ir buvo pašalinti pašaliniai trikdžiai. Signalų transformacijai naudojami būdai plačiau aptariami 1.3 skyriuje. Tikimasi, kad tokia veiksmų seka leis gauti kreivės formą, kuri bus aiški ir suteiks galimybę signalus lengvai palyginti tarpusavyje. Tyrimas buvo atliekamas duomenis nuskaitant 1000 Hz dažniu. Duomenys buvo perduodami „Arduino UNO“ mikrovaldiklio plokštei su „ATmega328“ mikrovaldikliu. Šie komponentai leidžia duomenis nuskaityti iš jutiklių ir duomenis skaitmeninio signalo forma perduoti tolimesnei kompiuterinei įrangai, kurioje galima atlikti tolimesnius skaičiavimus su gautais signalais. Tokia įranga kiek apriboja signalo keitiklio perdavimo spartą, todėl kartu galima iširti gedimų diagnostikos galimybes su turima įranga ir padėti surasti geriausius būdus gedimų diagnostikai. Tai suteiktų galimybę toliau šį būdą panaudoti ir analogišką įrangą pritaikyti įvairiuose praktiniuose uždaviniuose. Pagal turimą įrangą tyrimui naudojamas 1000 Hz dažnis ir 8 bitų perdavimas. Vėliau atliktų tyrimų metu buvo nustatyta, kad to atliekamam tyrimui pakanka, nes tiriamoje nuolatinės srovės įrangoje srovės kitimas yra ženkliai mažesnis negu kintamosios srovės įrangoje: nuolatinė srovė nekeičia savo krypties ir reikalingas mažesnis tyrimo diapazonas. Galima teigti, kad turima įranga yra pajėgi ir tinkama atliekamam tyrimui ir jo rezultatų apdorojimui.

Tyrimui pritaikyta įranga yra lengvai prieinama kiekvienam ir, nepaisant įrangos parametrų ribotumo, tyrimo rezultatai yra aktualūs daugeliu atveju. Tyrimo sistemą ir skaičiavimo būdus turi būti galima pritaikyti įvairiose srityse ir skirtingų techninių uždavinių sprendimui. Naudojamas elektros variklis yra mažų apimčių, tačiau viena iš tyrimo prielaidų yra, kad gedimų diagnostikos rezultatai tokio tipo elektros varikliui turėtų būti pritaikomi ir galingesniems bei didesnių matmenų elektros varikliams. Tyrimas yra universalus ir su pakeitimais jo rezultatai turi būti pritaikomi įvairiai elektros įrangai.

2.1. Tyrimo stendas ir naudota įranga

Norint atlikti gedimų diagnostikos uždavinį buvo naudojamas darbo stendas, kurio pagrindiniai komponentai buvo nuolatinės įtampos šaltinis, nuolatinės srovės variklis, jutikliai bei „ATmega328“ mikrovaldiklis su „Arduino UNO“ mikrovaldiklio plokštė [47] (žr. atitinkamai 1, 3, 5, 6; 7 iš 2.1 pav.). Tokia įranga buvo reikalinga tam, kad atlikti suplanuotą tyrimą. Buvo panaudoti trijų tipų jutikliai: srovės, garso ir vibracijų. Duomenų fiksavimui panaudotas „ATmega328“ mikrovaldiklis ir „Arduino UNO“ mikrovaldiklio plokštė, o duomenų perdavimui kompiuterinei įrangai panaudotas USB kabelis.



2.1 pav. Tyrimo naudotas darbo stendas: 1 – nuolatinės 12V įtampos šaltinis; 2 – įj./išj. jungiklis; 3 – nuolatinės srovės variklis; 4 – sujungimų plokštė; 5 – jutikliai (iš kairės į dešinę): srovės, garso, vibracijų; 6 – „ATmega328“ mikrovaldiklis ir „Arduino UNO“ mikrovaldiklio plokštė; 7 – darbo stendo pagrindas; 8 – USB kabelis


Tokia įranga buvo pritaikyta atliekamam gedimų diagnostikos galimybių tyrimo uždaviniui. Vienas iš tyrimo uždavinių buvo pamatyti, kokius rezultatus galima gauti naudojant turimą įrangą, nes tokia įranga nebūtinai yra pati optimaliausia ir tiksliausia. Darbe naudojama įranga buvo tik priemonės pasirinktam gedimų diagnostikos tyrimui atlikti ir pati nebuvo tyrimo objektas. Naudota techninė įranga buvo pritaikyta vieno uždavinio atlikimui: diagnostikos sistemos sukūrimui ir tyrimo sistemos sudarymui. Teigiama, kad net ir su techninės įrangos apribojimais tyrimo rezultatai turi būti universalūs. Vietoje didelės vertės ir gabaritų įrangos tyrimas yra atliekamas su paprastu mikrovaldikliu, mažu nuolatinės srovės elektros varikliu, maitinimo įranga ir jutikliais. Tikėtina, kad naudojant brangesnę įrangą tyrimo rezultatai būtų pasiekiami geresni, bet svarbu nustatyti perspektyvas įvairiems gedimų diagnostikos būdams su paprasta technine įranga.

2.2. Variklio srovės diagnostika

Variklių srovės diagnostika yra populiarus metodas įvairių variklių gedimų prevencijai. Šis metodas patrauklus tuo, kad jį galima atlikti netrukdamat įrenginio veikimo proceso. Taip pat variklio maitinimo srovės analizė naudinga tuo, kad ji yra universali – gali būti panaudojama daugeliui skirtingų elektros įrenginių: kintamos bei nuolatinės srovės varikliams, transformatoriams bei įvairiai kitai elektros įrangai. Srovės diagnostikos būdas yra sėkmingai pritaikomas įvairiose pavarų sistemose. Taip pat tyrimais nustatyta, kad srovės diagnostikos metodu galima tirti ir variklius, kai variklio greitis kinta. Nuolatinės srovės elektros mašinų atveju nėra atlikta daug tyrimų su srovės analizės metodika lyginant su kintamosios srovės elektros mašinomis. Todėl tikslinga tirti šios metodikos panaudojimą ir pritaikymą nuolatinės srovės elektros įrangai.

Srovės diagnostikos metodo veikimo principas paremtas tuo, kad variklio maitinimo srovė yra išmatuojama atitinkama srovės matavimo įranga ir perduodama srovės analizavimo sistemai, kur gauti duomenys apdorojami ir renkami. Dažnai neužtenka vienkartinį matavimų gedimo nustatymui, nes svarbu stebėti gedimo tendencijas. Todėl svarbu rinkti ir saugoti išsaugotą informaciją apie variklio srovės kitimo ypatumus ir kaupti duomenų bazę, kaip srovė variklyje kinta esant tam tikram gedimui. Kiekvienas atskiras gedimas paveikia variklio maitinimo srovę skirtingai, iš ko ir galima atpažinti atsiradusį gedimą. Be to, srovės analizės būdu galima nustatyti ne vien gedimo atsiradimą, bet ir jo intensyvumą. Tai leidžia spręsti apie variklio būklę ir tai, kaip greitai reikia imtis priemonių: ar matomi tik pirmieji gedimo požymiai, ar gedimas jau pažengęs ir reikalingas greitas gedimo šalinimas, norint išvengti variklio sugadinimo.

Idealiomis sąlygomis kintamos srovės varikliui srovė turėtų būti kaip įmanoma artimesnė sinusoidei, o nuolatinės srovės variklio atveju pirmiausia reikėtų surinkti duomenis apie variklio srovės kitimą normaliomis sąlygomis, nes tokia srovė bus laikoma kaip atskaitos taškas gedimų analizei. Nuolatinės srovės variklis gali būti testuojamas tiek apkrautas, tiek neapkrautas, nes gedimas nuolatinės srovės variklio grandyse bus matomas abiem atvejais.



2.2 pav. Srovės jutiklio veikimo ir duomenų apdorojimo blokinė diagrama

Tyrimė naudojama nuolatinė elektros variklio srovė. Jos kitimas yra daug mažesnis negu kintamosios elektros srovės, kuri keičia savo kryptį periodiškai. Tai yra naudinga atliekamam tyrimui, nes dėl šios priežasties gedimai nuolatinėje srovėje yra geriau matomi ir atpažįstami. Kita svarbi priežastis yra tai, kad mažai tyrimų yra atliekama su nuolatinės srovės elektros įranga. Didžioji dalis srovės diagnostikos įrangos yra naudojama kintamosios srovės varikliams. Kadangi nuolatinės srovės varikliai naudojami įvairių gabaritų ir įvairiose srityse, yra tikslingas ir jų tyrimas bei gedimų diagnostika. Be to, didėjant nuolatinės srovės elektros įrangos paklausai įvairiuose įrenginiuose, svarbiu uždaviniu tampa ir šių variklių srovės pokyčių gedimų metu tyrimas. Tai suteikia galimybę greitai ir efektyviai diagnozuoti įvairaus pobūdžio gedimus iš srovės signalo.

Nuolatinės srovės variklio srovės lygtys [30]:


$$I_a = \frac{E - E_{at}}{R_a} \quad (2.1)$$

$$I_a = \frac{E}{R_a} \quad (2.2)$$


2.1 ir 2.2 formulėse yra pateikiamos nuolatinės srovės variklio srovės lygtys darbinio (žr. 2.1 formulę) ir pradiniu (žr. 2.2 formulę) laiko momentais: I_a – variklio srovė, A; E – variklio maitinimo įtampa, V; E_{at} – variklio atgalinė įtampa, V; R_a – variklio armatūros varža, Ω .

Srovės analizė gali padėti potencialiai nustatyti daugelį nuolatinės srovės variklio gedimų šepėčių mazge, kolektoriuje, nustatyti trumpus gedimus, įžemėjimus, guolių gedimus bei daugelį kitų galimų elektrinių ir mechaninių gedimų. Srovės analizė taip pat yra sąlyginai paprastai atliekamas tyrimo būdas, nes jo atlikimui dažniausiai nereikia papildomų tyrimo sąlygų, nes tyrimui nėra didelio poveikio iš aplinkos ir galima tyrimą atlikti, ir duomenų bazę kaupti tiek varikliui veikiant apkrautu režimu, tiek tada, kai nėra variklio apkrovos. Variklio srovė dažnai yra laikoma vienu iš informatyvesnių variklio parametrų, nes bet kokie pokyčiai variklio darbe turėtų turėti poveikį variklio srovei, dėl ko turėtų būti galimybė šiuos gedimus atpažinti ir atskirti. Toks gedimų diagnostikos būdas gali būti pritaikytas įvairių gedimų prevencijai, analizei ir kaupimui duomenų, kurie vėliau gali būti panaudojami kompiuterinės įrangos, kuri automatiškai atpažintų gedimą.

Nuolatinės srovės variklių ir kitų variklių gedimų nustatymas maitinimo srovės tyrimo būdu yra dažnai patikimesnis ir efektyvesnis už šiuo metu pramonėje plačiai naudojamą vibracijų analizės būdą. Taip yra, nes srovės analizės būdas nėra toks jautrus gamyklinei aplinkai, kurioje, dirbant varikliui, variklio darbo metu kuriamos vibracijos gali atsispindėti ir gautame vibracijų signale. Todėl vėliau šias pašalines vibracijas reikia išfiltruoti. Srovės analizės metodo atveju trikdžiai srovės signale dažniausiai nėra tokie ryškūs. Be to, didelis metodo pranašumas yra tas, kad nebūtina variklio labai apkrauti. Variklio gedimų atpažinimo kokybė nesuprastėja net sumažinus apkrovą iki 50% maksimalios apkrovos arba net testuojant variklį be apkrovos. Tai leidžia testavimą esant visokiems variklio darbo režimams neprarandant testavimo tikslumo. Ši savybė yra svarbi, nes varikliai gali dirbti skirtingais režimais, o jų testavimas turi išlikti nuolatinis ir kaip įmanoma geresnio tikslumo.



2.3 pav. Srovės jutiklis, naudojamas tyrime



2.4 pav. Nuolatinės srovės variklio be defektų srovės signalas


2.4 paveiksle yra pateikiamas pavyzdys nuolatinės srovės variklio be defektų elektros srovės signalo, gauto naudojant srovės jutiklį (žr. 2.3 pav.). Signalas yra gaunamas įtampos pavidalu ir vertės yra matomos y ašyje 2.4 paveiksle. 5V atitinka srovės kitimo ribas nuo $-20A < 0 < 20A$ (0.1V atitinka 0.8A). Pagal gautą įtampos signalą galima apskaičiuoti srovę atitinkamu laiko momentu. Kaip matyti iš 2.4 paveikslo, srovė startuojant nuolatinės srovės variklį ženkliai išauga pradiniu momentu. Tai yra būdinga visoms elektros mašinoms. Toliau signalas nusistovi ir galima pamatyti tam tikrą periodiškumą jame. Signalas buvo nuskaitomas 1000 Hz dažniu ir gauta reikšmių seka, kuri pateikiama x ašyje. Pagal atitinkamos nuskaitytos reikšmės įtampos įverčius suformuotas srovės signalas. Pavertus į laiko reikšmes gaunamas įvertis, kad vienas periodo nuskaitymas atliekamas per 1 ms.

Srovės diagnostika tyrime atlikta panaudojant srovės jutiklį, kuris gali matuoti srovę nuo $\pm 20A$. Srovės jutiklio veikimas paremtas tuo, kad srovės jutiklio matuojama srovė elektros grandinėje yra transformuojama į atitinkamo dydžio įtampos signalą, kuris gali būti toliau apdorojamas kompiuterinės įrangos. Srovė, tekėdama elektros grandine pro srovės jutiklį, sukuria magnetinį lauką, kuris panaudojamas srovės jutiklyje esančio Holo efekto jutiklio ir srovės jutiklio analoginiame išėjime perduodamas įtampos signalas, proporcingas grandinei tekančiai srovei [34]. Srovės jutiklio signalas gali būti analoginis arba skaitmeninis. Signalo tipas ir reikiamas srovės jutiklio signalas pasirenkamas pagal reikalingą pritaikymo tipą. Darbe naudojamas analoginis srovės jutiklio išėjimas, nes darbe reikalinga stebėti srovės kitimą laike ir taip gauti srovės jutiklio signalą, kuris kistų laike ir atitiktų realų srovės kitimą. Srovės kitimo laike įvertinimas yra svarbus, nes kaip ir matoma 2.4 paveiksle po tam tikro srovės nusistovėjimo įverčių skaičiaus galima matyti tam tikrus srovės kitimo dėsningumus, kurie atitinka elektros įrangos darbo režimą. Pokyčiai srovės signale teoriškai turi atitikti ir gedimus, kurių diagnostika yra atliekamo tyrimo esmė. Gedimai teoriškai turi keisti srovės signalo formą, keisti signalo amplitudę, daryti signalą mažiau stabilų ir kintantį. Visi tokie galimi signalo pokyčiai gerai atsispindi po signalo transformacijos, kada šie bruožai yra išryškunami ir pateikiami paprastos kreivės forma, kuri gali būti palyginama su kitų gedimų kreivėmis. Toliau tokiam pakeistam signalui gali būti atliekamas klasifikavimas panaudojant įvairius klasifikavimo algoritmus, kurie pagal tam tikrus srovės požymius gali atskirti skirtingus gedimus ir jiems priskirti tam tikrą kategoriją.

2.3. Variklio akustinė diagnostika

Akustinė (garso) diagnostika yra elektros mašinų ir kitų elektros įrenginių gedimų analizės būdas, kai gedimo atpažinimui naudojamas elektros įrenginio skleidžiamas garsas. Akustinė arba garso analizė yra patraukli tuo, kad ją galima atlikti sąlyginai paprastai, nes tokiam tyrimui reikalinga paprasta garso įrašymo įranga kaip mikrofonas. Įrašytas signalas toliau gali būti apdorojamas kompiuterine įranga, kurią panaudojant galima atlikti tolesnį signalo apdorojimą, atlikti signalo transformaciją. Tai leidžia paprastą garso signalą paversti transformuotu signalu, kuris turi pateikti įvairių gedimų bruožus, ir tai suteikia galimybę palyginti skirtingus elektros įrangos gedimus.

Svarbu paminėti, kad elektros variklių ir kitų elektros įrenginių skleidžiamas garsas gali būti įrašinėjamas net triukšmingoje aplinkoje, kurioje yra pašalinių triukšmų. Tokį rezultatą galima gauti tokiu atveju, kai akustinės analizės tyrimas atliekamas taip, kad pirmiausia yra nustatoma, iš kur yra skleidžiamas tiriamas garsas, jį lokalizuojant. Taip galima gauti sąlyginai tikslius duomenis net aplinkoje, kur yra kiti triukšmo šaltiniai. Pritaikymo sritims, kai nėra išorinio triukšmo arba jis nėra ryškus, pakanka tinkamai konfigūruoti garso priėmimo ir įrašymo įrangą. Reikia padėti garso įrašymo įrangą taip, kad ji būtų tinkamai pastatyta tiriamo objekto atžvilgiu ir kad būtų galima ją greitai ir lengvai įrengti. Tinkamas įrangos įrengimas yra svarbus. Vis dėlto, skirtingi elektros įrangos gedimai pateiks skirtingo pobūdžio bruožus, kurie turi būti matomi garso signalė. Svarbiausia yra visus tyrimus atlikti tomis pačiomis sąlygomis. Tai leidžia teigti, kad tyrimas yra efektyvus ir kokybiškas. Tyrimą atliekant skirtingomis sąlygomis gali būti gaunami šiek tiek skirtingi signalai priklausomai nuo garso intensyvumo ar atstumo iki objekto. Todėl, norint gauti tokius pačius rezultatus su garso įranga yra svarbu naudoti tą pačią įrangą ir įrengimo sąlygas. Vis dėlto, dėsniumai, kurie gaunami po gedimų akustinės analizės yra universalūs, nes jie, kad ir pakeitus elektros įrangą ar pačius garso jutiklius turėtų būti to paties pobūdžio.



2.5 pav. Elektros mašinų akustinės diagnostikos blokinė diagrama

Pagal blokinę diagramą elektros mašinų akustinei diagnostikai (2.5 pav.) galima matyti, kad akustinei analizei reikalinga įvairi įranga skirtingiems gautų duomenų apdorojimo etapams atlikti. Akustinės analizės atlikimui dažniausiai naudojama įranga: mikrofona – garso priėmimui, analoginio signalo į skaitmeninį keitikliai – duomenų konvertavimui, kompiuteriai – duomenų saugojimui bei tolesnei analizei. Mikrofonais įrašomas garso slėgis aplinkoje, kurioje yra tiriamas elektros įranga. Tai yra analoginis signalas, kuris vėliau turi būti konvertuojamas analoginio signalo į skaitmeninį signalą keitiklio tam, kad perduodamą garsinį signalą suprastų kompiuterinė įranga, kurioje duomenys apdorojami skaitmeninio signalo forma. Todėl, būtina tinkamai parinkti akustinės diagnostikos sistemos elementus tam, kad būtų gaunama tinkama informacija ir kaip įmanoma tikslesni duomenys gaunami iš akustinės diagnostikos. Pasitelkus visas tinkamas diagnostikos priemones ir paruošus jas garso įrašymui galima gauti garso signalą, kuris yra pateikiamas įtampos forma ir perduodamas kompiuterinei įrangai, kurioje šį signalą galima transformuoti ir panaudoti įvairius klasifikavimo algoritmus signalo klasifikavimui.

Akustinės diagnostikos tikslumas yra ganėtinai geras: daugumą gedimų galima atpažinti su dideliu patikimumu. Gedimo atpažinimo tikslumas priklauso nuo gedimų kreives tiriančių ekspertų žinių apie skirtingų gedimų akustines kreives bei kompiuterinės įrangos, atpažįstančios gedimus, tikslumo. Norint tinkamai atpažinti gedimus kompiuterine įranga reikia tinkamai klasifikuoti gedimus ir sudaryti tipinių gedimo signalų duomenų bazę, su kuria kompiuterinė įranga galėtų lyginti esamus gedimus.

Gaunami garsiniai signalai iš mikrofono yra perduodami signalą apdorojančiai kompiuterinei įrangai. Svarbu tinkamai parinkti įrangą garso priėmimui ir įrašymui bei tinkamai apdoroti gaunamą signalą. Kai kuriose pritaikymo srityse galimas garso filtravimas, jei yra daug panašių garso šaltinių arba garso šaltinio lokalizacijos panaudojimas. Gedimai variklio signalo spektre yra ryškiai matomi dėl signalo amplitudės šuolių lyginant su variklio signalų be defektų spektrais.

Akustinės diagnostikos automatizuota sistema realizuojama tokiais etapais [41]:

- sistema paleidžiama, suteikiamas elektros maitinimas;
- atpažįstami sistemoje esantys įrenginiai;
- priimamas garso signalas iš variklio;
- nustatoma, ar pastebimas variklio gedimas, ar ne;
- nesant gedimo toliau stebimas garso signalas;
- gedimo atveju gedimas turi būti identifikuojamas kompiuterine įranga;
- kompiuterine įranga atpažintas gedimas pateikiamas kvalifikuotam personalui, kuris gali greitai sužinoti apie atsiradusį gedimą ir jį pašalinti pradinėse gedimo stadijose.


Garso lygtis [35]:

$$G = 10 \cdot \log \left(\frac{P}{P_0} \right)^2 \quad (2.3)$$


Lygtyje: G – garso slėgio lygis, dB; P – garso slėgis, Pa; P_0 – atskaitos garso slėgis, Pa.

Tyrime naudojamas garso jutiklis (žr. 2.6 pav.), kuris garso slėgį, esantį aplinkoje, transformuoja į išėjimo įtampos signalą nuo 0 iki 5V. Naudojamas jutiklis, galintis skirti garso slėgio lygį (žr. 2.3 formulę) nuo 48 iki 66 dB, kuris vėliau yra transformuojamas į įtampos signalą mikrofono pagalba. Toliau išėjimo įtampos analoginis signalas yra transformuojamas į skaitmeninį signalą ir perduodamas kompiuterinei įrangai. Garso jutiklio jautrumas gali būti reguliuojamas naudojant potenciometrą, kuris yra garso jutiklio dalis, taip parenkant maksimalų jautrumą atliekamai užduočiai atlikti.

Garso arba akustinė gedimų diagnostika yra gedimų diagnostikos būdas, kuris potencialiai turi nemažai pritaikymo galimybių. Garsas yra universalus signalas, kuris gali būti įrašomas ir pagal jį daromos išvados. Tyrime naudojamas mikrofonas yra paprastas ir neturi pačių geriausių jautrumo charakteristikų. Svarbu iširti, ar tokiu mikrofonu galima gauti gerus gedimų diagnostikos rezultatus. Tai svarbu, nes dažnai gedimų diagnostikos įranga yra brangi ir reikalauja daug resursų. Vienas iš tyrimo uždavinių yra nustatyti, ar galima gauti gerus rezultatus su paprastais gedimų diagnostikos elementais, tarp kurių yra ir garso jutiklis arba mikrofonas. Tyrimas atliktas aplinkoje, kurioje nėra triukšmo. Vis dėlto, tokio tyrimo rezultatai turėtų būti pritaikomi ir triukšmingoje aplinkoje panaudojant garso lokalizaciją, tinkamai nustatant garso kryptį ir garso šaltinį. Tai svarbu žinoti, jei tyrimas būtų atliekamas kitoje aplinkoje, kurioje yra daug pašalinių garso šaltinių. Be to, svarbu tinkamai sureguliuoti srovės jutiklio jautrumą, kad nebūtų per daug pašalinio triukšmo.



2.6 pav. Tyrime naudojamas garso jutiklis




2.7 pav. Nuolatinės srovės variklio be defektų garso signalas

Akustinės diagnostikos būdas gali būti pritaikomas tiek nuolatinės, tiek kintamosios srovės variklių diagnostikai. Kaip matoma 2.7 paveiksle, garso signalas turi atpažįstamą periodiškumą ir aiškią amplitudę. Toks signalas gaunamas su naudotu garso jutikliu (žr. 2.6 pav.). Didžioji dalis tyrimų variklių gedimų diagnostikai yra atliekama kintamosios srovės elektros mašinoms (daugiausia asinchroniniams varikliams). Tačiau kaip ir srovės diagnostikos atveju yra tikslinga išmėginti akustinės diagnostikos galimybes nuolatinės srovės įrangai. Be to, tie tyrimai, kurie yra atliekami, naudojant akustinę diagnostiką nuolatinės srovės įrangos gedimų analizei, įrodo, kad akustinė diagnostika gali būti naudinga tiriant įvairių gabaritų nuolatinės srovės elektros mašinas bei pritaikoma įvairiose srityse kaip pavarų sistemose, kurių dalimi gali būti ir nuolatinės srovės elektros įrenginiai. Akustinė diagnostika gali būti greitai įrengiama elektros sistemoje ir šiam būdai skirtingai nei kitiems minėtiems būdams nereikia kontakto su elektros įranga. Tai daro šį būdą greitai pritaikomu.

2.4. Variklio vibracijų diagnostika

Variklio vibracijų diagnostika yra vibracijų matavimu paremtas gedimų charakteristikų tyrimo metodas. Vibracijos yra būseną, kai stacionarus objektas patiria tam tikrą judėjimą dėl veikimo ar dėl išorės sukeltų priežasčių. Šį judėjimą ir jo intensyvumą galima nustatyti vibracijos matavimo prietaisais. Dauguma vibracijos jutiklių viduje turi pjezoelektrines plokšteles, kurių pagalba galima iš mechaninio vibracijų poveikio gauti įtampos signalą proporcingą mechaninei jėgai, paveikusiai vibracijų jutiklį.

Pjezoelektrinis efektas paremtas tam tikrų medžiagų savybe keisti mechaninį poveikį į elektros signalą. Tokia savybė plačiai naudojama vibracijų jutikliuose, kurie yra plačiai naudojami pramonėje įvairių gedimų diagnostikoje. Šis efektas patogus tuo, kad tyrimai atlikti šiuo būdu yra patogūs ir gali būti atliekami darbinėje tiriamos įrangos aplinkoje, nes vibracijos matuojamos tiesiogiai pritvirtinus vibracijų matavimo įrangą prie tiriamo įrenginio.



2.8 pav. Pjezoelektrinis efektas: a) ir b) atitinkamai srovės atsiradimas iš pjezo elemento veikiant jį jėga skirtingomis kryptimis [46]

Vibracijų jutikliai naudojami daugelyje sričių: įvairių gedimų diagnostikoje. Šie jutikliai patogūs dėl savo montavimo galimybių: jie nuolat kontaktuoja su tiriamu varikliu. Tai leidžia išvengti pašalinių triukšmų. Tyrimuose gedimai varikliuose yra matomi jutiklio išėjimo signale. Tai leidžia sukurti tinkamas gedimų atpažinimo priemones, leidžiančias pagal pokyčius jutiklio išėjimo signale nustatyti galimą gedimą. Pramoniniai vibracijos jutikliai (akselerometrai) turi jautrumą apie 10-100 mV/g. Vibracijos jutikliai yra paprastesnė alternatyva akselerometrams, kurie taip pat gali būti naudojami tokiai analizei. Maža vibracijos jutiklių kaina ir sąlyginai nedideli reikalavimai kompiuterinei įrangai vibracijų analizę daro patogiu gedimų tyrimo metodu.

Dėl mechaninio poveikio pjezo elemento masės centras skyla į dvi atskiras dalis, atsiranda poliarizacija. Elemento viduje naujai sukurtas dipolių krūvis vienas kitą panaikina, tačiau elemento paviršiuje susidaro poliarizacija (žr. 2.4 formulę). Dėl poliarizacijos atsiradimo susidaro įtampa, kuri yra proporcinga pjezo elementą paveikusiai jėgai (žr. 2.5 formulę). Dėl tokio pokyčio pradeda tekėti srovė, kurios kryptis sutampa su paveikusios jėgos kryptimi.

Pjezo elemento poliarizacijos ir išėjimo įtampos lygtys [46]:


$$P = d \cdot T = d \cdot \frac{F}{A} \quad (2.4)$$

$$V = \frac{L \cdot P}{\epsilon_0 \cdot \epsilon_r} = d \cdot \frac{L \cdot F}{\epsilon_0 \cdot \epsilon_r \cdot A} \quad (2.5)$$

Lygtyse P – poliarizacija, C/m^2 ; T – mechaninis poveikis, d – pjezoelektrinis koeficientas, s.v.; A – plotas, veikiamas jėgos, m^2 ; F – jėga, N; L – pjezo elemento ilgis, m; C – talpa, F; ϵ_0 – vakuumo pralaidumas, s.v.; ϵ_r – santykinis pralaidumas, s.v.




2.9 pav. Tyrime naudojamas vibracijų jutiklis



2.10 pav. Nuolatinės srovės variklio be defektų vibracijos signalas

2.9 ir 2.10 paveiksluose yra pateikiami atitinkamai panaudotas vibracijos jutiklis ir nuolatinės srovės variklio be defektų signalas. Signalas gautas dėl anksčiau minėto pjezoelektrinio efekto (žr. 2.8 pav.). Vibracijos jutiklio jautrumas reguliuojamas ir atitinka 300 mV/g. 0V reikšmė atitinka variklio veikimą be vibracijų. Vibracijos jutiklis buvo įrengtas taip, kad turėtų nuolatinį tiesioginį kontaktą su elektros varikliu. Dėl vibracijų, atsirandančių elektros variklio darbo metu, ir dėl pjezoelektrinio efekto vibracijos jutikliu pradėjo tekėti elektros krūvis, kuris įtampos forma buvo perduotas tolesnei duomenų analizės ir apdorojimo įrangai.



2.11 pav. 45 kHz (a) ir 1kHz (b) dažniais kvantuoto vibracijos signalo pusė po signalo apdorojimo spektrine transformacija ir autokoreliacija

2.10 paveiksle yra pateikiamas nuolatinės srovės be defektų variklio vibracijų signalas, gautas su naudojamu vibracijų jutikliu (žr. 2.9 pav.). Vibracijos signalas turi tam tikrą periodiškumą, tačiau sumažėjant vibracijų intensyvumui atsiranda signalo pikai. 2.11 paveiksle pateikiamas vibracijos signalas su aukštesniu dažniu, 45 kHz kvantavimo dažniu ir 12 bitų vertikalios ašies tikslumu. Toks vibracijos signalas buvo gautas, panaudojant osciloskopą. Vibracijos signalo gavimas aukštesniu dažniu buvo svarbus dėl to, kad būtų galima įvertinti, ar neprarandama signalo informacija su turimomis signalų apdorojimo priemonėmis. Kaip minėta, tyrimas atliekamas, naudojant 1 kHz dažnį ir 8 bitų tikslumą. Tai aktualu tiek vibracijos signalui, tiek prieš tai minėtiems srovės bei garso signalams. Kaip matyti iš 2.11 paveikslo, didžioji dalis signalo informacijos yra pačiuose pirmuose signalo įverčiuose. Taigi, galima spręsti, kad naudojant ir turimą įrangą svarbi informacija apie signalo pobūdį neturėtų būti prarandama. Gedimo signalams dažnai pati informatyviausia yra signalo žemesnių dažnių sritis. Žemų dažnių signalo srityje esanti informacija atitinka esminius signalo bruožus. Tai dažnai nėra matoma aukštų dažnių srityje, ką galima matyti ir gautame 45 kHz dažniu kvantuotame signale, kuris yra 2.11 paveiksle. Tai leidžia daryti prielaidą, kad turima įranga turėtų leisti atlikti tyrimą ir neprarasti esminių duomenų.

Pagal mokslinę literatūrą galima spręsti, kad vibracijų analizė yra efektyvus būdas gedimų analizei. Vibracijų analizė gedimų diagnostikoje yra plačiausiai paplitęs gedimų analizės būdas, kuris panaudojamas ir atliekamame tyrime. Šis būdas taikomas daug dažniau negu anksčiau paminėti srovės analizės ir garso analizės būdai. Vis dėlto, kai kuriuose moksliniuose šaltiniuose matyti, kad kiti tyrimų metodai taip pat gali būti efektyvūs ir net geresni už vibracijų analizę. Todėl svarbus atliekamo tyrimo tikslas yra, naudojant skirtingus tyrimo metodus skirtingiems nuolatinės srovės variklių gedimams, nustatyti tinkamiausius tyrimo būdus skirtingiems gedimams. Kiekvienas iš šių būdų turi tam tikrų pranašumų ir trūkumų, kurie yra plačiai aptariami gedimus tiriančioje mokslinėje literatūroje ir įvairių atliekamų tyrimų analizėje. Atskiri gedimų diagnostikos būdai arba galimos jų kombinacijos leidžia automatizuoti ir optimizuoti gedimų diagnostikos uždavinį.

3. Automatizuoto gedimų identifikavimo tyrimas

Atliekamam gedimų nustatymo ir analizės uždaviniui atlikti reikėjo panaudoti įvairius tyrimo būdus. Signalų fiksavimas, kaip ir minėta ankstesniuose skyriuose, buvo atliktas panaudojant trijų tipų jutiklius: srovės, garso ir vibracijų. Tokie jutikliai užfiksuotą signalą transformuoja į analoginį įtampos signalą, kuris perduodamas tolesniam apdorojimui kompiuterinei įrangai, kurioje atliekamos tolesnės signalo transformacijos.

Jutiklių duomenys buvo įrašomi tiek esant varikliui be defektų, tiek įvairių gedimų atvejais tam, kad patikrinti signalo pasikartojimą atliekant tą patį bandymą tomis pačiomis sąlygomis ir tam, kad patikrinti pačio bandymo kokybę. Bandymai buvo atlikti esant įvairiems nuolatinės srovės variklio gedimams ir pagal gautus duomenis, ir atliktas transformacijas buvo stebimi gedimams būdingi signalai, kurie tapo ryškūs po atliktų signalo transformacijų.

Darbo stende buvo panaudotas „ATmega328“ mikrovaldiklis, kuriuo kartu su naudota „Arduino UNO“ mikrovaldiklio plokšte galima nuskaityti analoginius ir skaitmeninius signalus ir, naudojant analoginio signalo keitiklį į skaitmeninį signalą, perduoti duomenis kompiuteriui, kuriame galima atlikti skaičiavimus su gautais rezultatais ir atlikti signalų transformacijas, norint išryškinti esminius signalų bruožus ir pateikti juos tokia forma, kurią būtų galima tiek vizualiai, tiek panaudoti klasifikavimo algoritmus ir nustatyti tinkamiausius tyrimo būdus atliekamam darbui.

Mikrovaldikliui buvo parašyta programa, kurią panaudojant būtų galima nuskaityti analoginį signalą ir jį perduoti kompiuteriui. Taip pat, panaudota papildoma programinė įranga „Terra Term“, kuri yra skirta patogiam duomenų nuskaitymui iš kompiuterio USB jungčių ir duomenų perdavimui pagal atitinkamą nuskaitymo spartą.

Signalų transformacijai ir duomenų apdorojimui buvo naudojama „Matlab“ programinė įranga, kuria įgyvendintos signalų transformacijos: greitoji Furjė transformacija, Kepstro realioji ir kompleksinė analizės, Kepstro analizės kombinacija su greitąja Furjė transformacija ir greitoji Walsh-Hadamard transformacija. Po atliktų transformacijų panaudota autokoreliacijos funkcija, kuri pateikia esminius signalo panašumus ir pagerina bruožų matomumą signalo spektre.

Gauti signalų spektrai buvo skirtingų formų ir pobūdžio ir ne visi buvo tinkami atliekamam gedimui tirti, todėl svarbi tyrimo dalis buvo nustatyti, kuris signalų apdorojimo būdas yra tinkamiausias kuriam gedimui ir skirtingo jutiklio duomenims apdoroti. Taip pat buvo svarbu nustatyti, kuris jutiklis tinkamiausias tam tikram gedimui ir kokią jutiklių kombinaciją būtų galima panaudoti, norint gauti geriausius ir patikimiausius tyrimo rezultatus.

Galiausiai, tyrime buvo pateiktas pirminis gedimų diagnostikos būdų įvertinimas pagal gautas transformuotų signalų kreives. Taip pat yra pateikiamas ir gautų rezultatų klasifikavimas panaudojant klasifikavimo algoritmus. Transformuoti signalai, pagal užfiksuoto diagnostikos signalo prigimtį, ar jų kombinaciją yra patys patikimiausi gedimų diagnostikos uždavinio atlikimui. Tyrimai pakartojami su didesne bandymų imtimi tam, kad parodyti, jog darbo rezultatai yra patikimi ir gali būti atkartojami. Pagal gautus rezultatus pateikiami pasiūlymai ir sprendimai, kokie gedimų diagnostikos būdai yra potencialūs ir tinkami praktiniam panaudojimui.

3.1. Tirti nuolatinės srovės variklių gedimai

Gedimų diagnostikos uždaviniui pasirinkta panaudoti nuolatinės srovės variklį. Gedimai šiame variklyje buvo sukelti naudojant priemones, kurios leido sukelti tokias pačias sąlygas kaip ir normalaus gedimo atveju. Darbe naudotas „Redox“ 12V nuolatinės srovės variklis [48]. Šiame variklyje buvo sukelti kelių tipų darbo režimai: variklio veikimas be gedimo, ašies disbalansas, trumpas jungimas tarp variklio apvijų, variklio užteršimas pašalinėmis medžiagomis.



3.1 pav. Nuolatinės srovės variklis be defektų

Pirmiausiai, tirtas nuolatinės srovės variklis be gedimo (3.1 pav.). Tai buvo svarbu, norint gauti tipines variklio charakteristikas ir duomenis, kurie atitinka normalų variklio veikimą. Šio variklio duomenis galima naudoti kaip pavyzdį, su kuriuo gali būti lyginami nuolatinės srovės variklio gedimai.



3.2 pav. Nuolatinės srovės variklio apvijų trumpas jungimas

Pirmasis gedimas, kuris buvo sukeltas nuolatinės srovės variklyje buvo trumpas jungimas tarp variklio apvijų (3.2 pav.). Tokiam gedimui imituoti buvo panaudota $1k\Omega$ varža. Varžos kontaktai buvo prilituoti prie atskirų variklio apvijų ir tokiu būdu imituojant beveik trumpąjį jungimą ar pablogėjusią izoliacijos varžą.



3.3 pav. Nuolatinės srovės variklio ašies disbalanso imitavimas

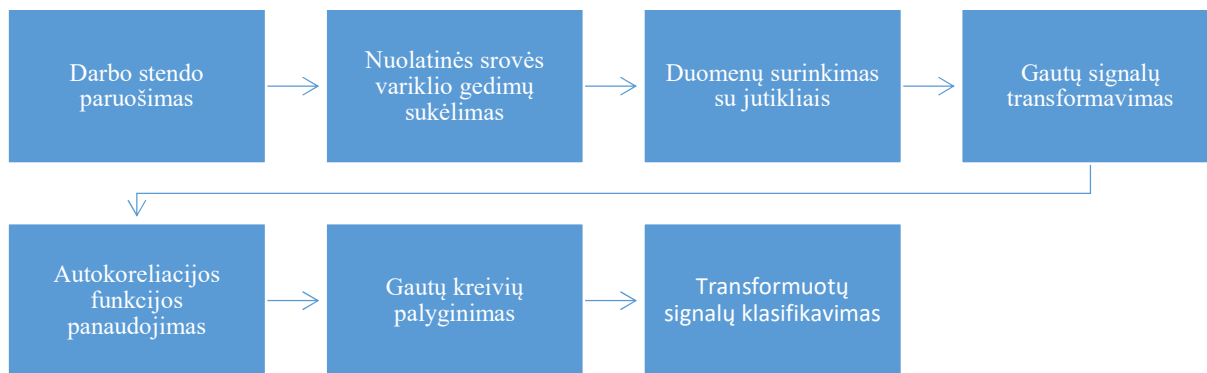
Kitas gedimas, kuris buvo imituojamas nuolatinės srovės variklyje - ašies disbalansas, dalinai atitinkantis ašies sulinkimo defektą (3.3 pav.). Tokiam gedimui imituoti ant nuolatinės srovės variklio veleno buvo uždėtas kamštis su veržle, kuri buvo vienoje kamščio pusėje ir buvo kaip išbalansuojanti priemonė, dėl kurios didesnis svoris buvo vienoje veleno vietoje. Atlikus tokią modifikaciją nuolatinės srovės varikliui šio variklio veleno ašis nebuvo lygi ir darbinio režimu nejudėjo tolygiai.

Norint imituoti užteršimą nuolatinės srovės variklio viduje buvo atliktas tyrimas, kurio metu į nuolatinės srovės variklį buvo įpilta kvarcinio smėlio. Smėlis yra medžiaga, kuri yra nelaidi elektros srovei ir kuria galima imituoti medžiagas, užteršiančias variklio vidų gamybinio proceso metu. Tai, kad pasirinkta medžiaga yra nelaidi elektros srovei yra svarbi tuo, kad atsiradus šios pašalinės medžiagos variklio viduje nebūtų sukeliamas elektrinio pobūdžio gedimas. Užteršimo tyrimo tikslas yra ištirti, kaip šios medžiagos atsiradimas variklio viduje paveiks tiriamus garso, srovės ir vibracijų signalus ir ar toks poveikis bus matomas ir ryškus gaunamose signalų transformacijose.

Tokiu būdu tyrime numatyta ištirti tris nuolatinės srovės variklio gedimų rūšis: variklio ašies disbalansą, kuris imituoja ašies sulinkimo defektą, trumpą jungimą tarp nuolatinės srovės apvijų ir variklio užteršimą pašalinėmis medžiagomis. Šie gedimai atitinka 1.2 skyriuje minėtas variklių gedimų rūšis, atitinkamai: mechaninio, elektrinio ir aplinkos poveikio sukeltus gedimus. Taip pat atliekami tyrimai su nuolatinės srovės varikliu be defektų, kurio rezultatai laikomi etalonu minėtiems nuolatinės srovės variklio gedimams. Pagal skirtumus tarp nuolatinės srovės variklio be defektų signalų transformacijų ir gedimų signalų transformacijų bus atliekami tyrimai ir palyginami gauti rezultatai, pagal kuriuos bus galima spręsti apie gedimo pobūdį ir kaip tas gedimas paveikia nuolatinės srovės variklį. Šie duomenys toliau panaudoti transformuotų signalų klasifikavimui.

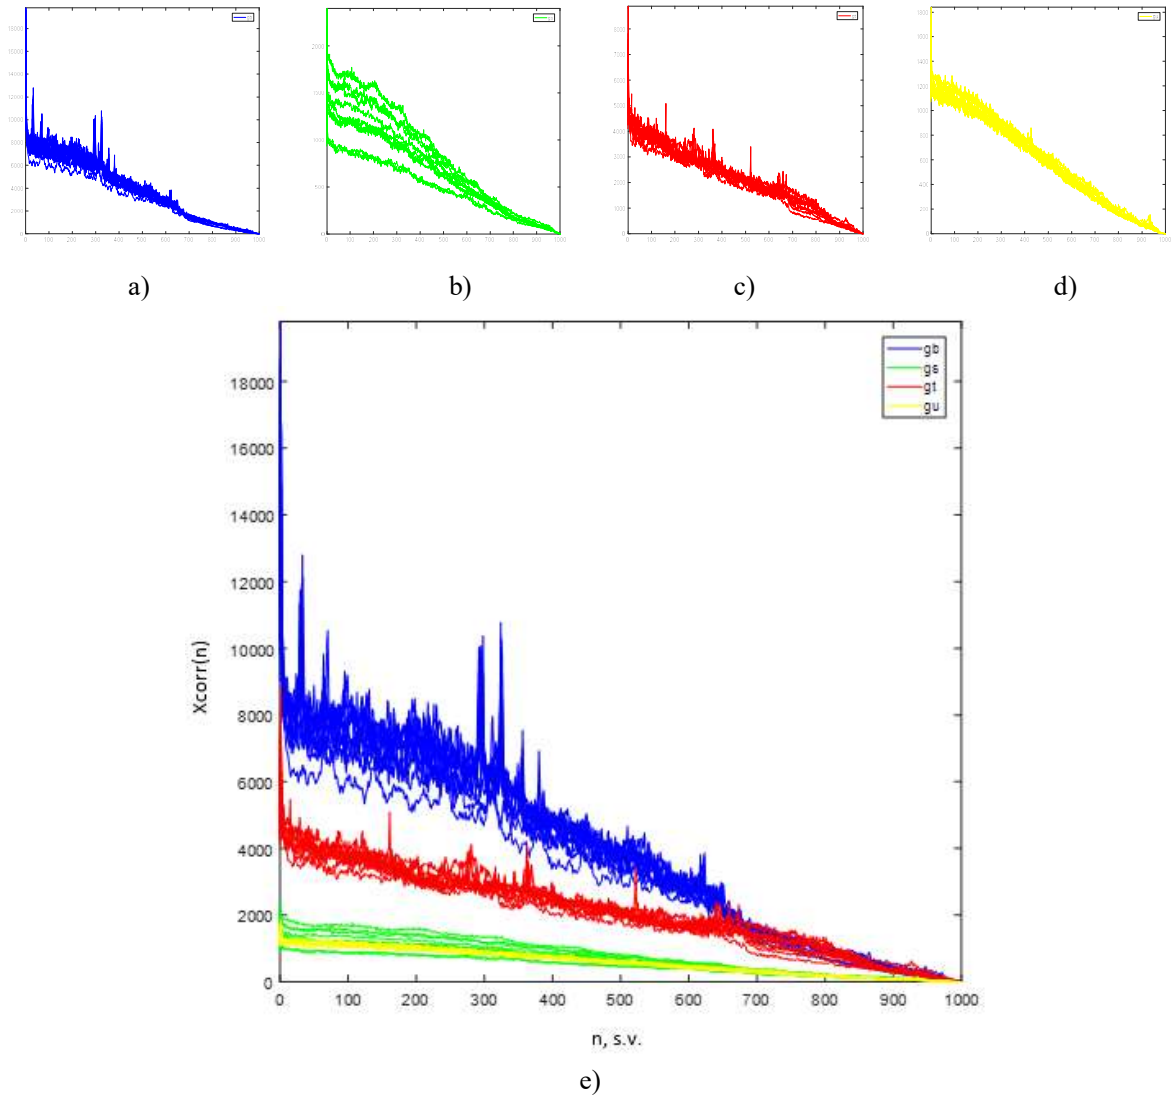
3.2. Darbo planas ir gautos signalų kreivės

Gedimų diagnostikos tyrimo atlikimui reikėjo nuspręsti, koks tyrimo būdas bus naudojamas su turimomis tyrimo priemonėmis, kurios aprašomos **Klaida! Nerastas nuorodos šaltinis.** skyriuje. Pirmasis tyrimo žingsnis buvo tinkamas darbo stendo paruošimas, elektrinių sujungimų parengimas tarp elektros energiją naudojančių komponentų. Taip pat svarbu buvo tinkamai sudėti komponentus ant montavimo plokštės ir paruošti stendą darbui. Kitas darbo etapas buvo galimų nuolatinės srovės gedimų imitavimas, panaudojant papildomas priemones. Tai detalai aprašoma 3.1 skyriuje.



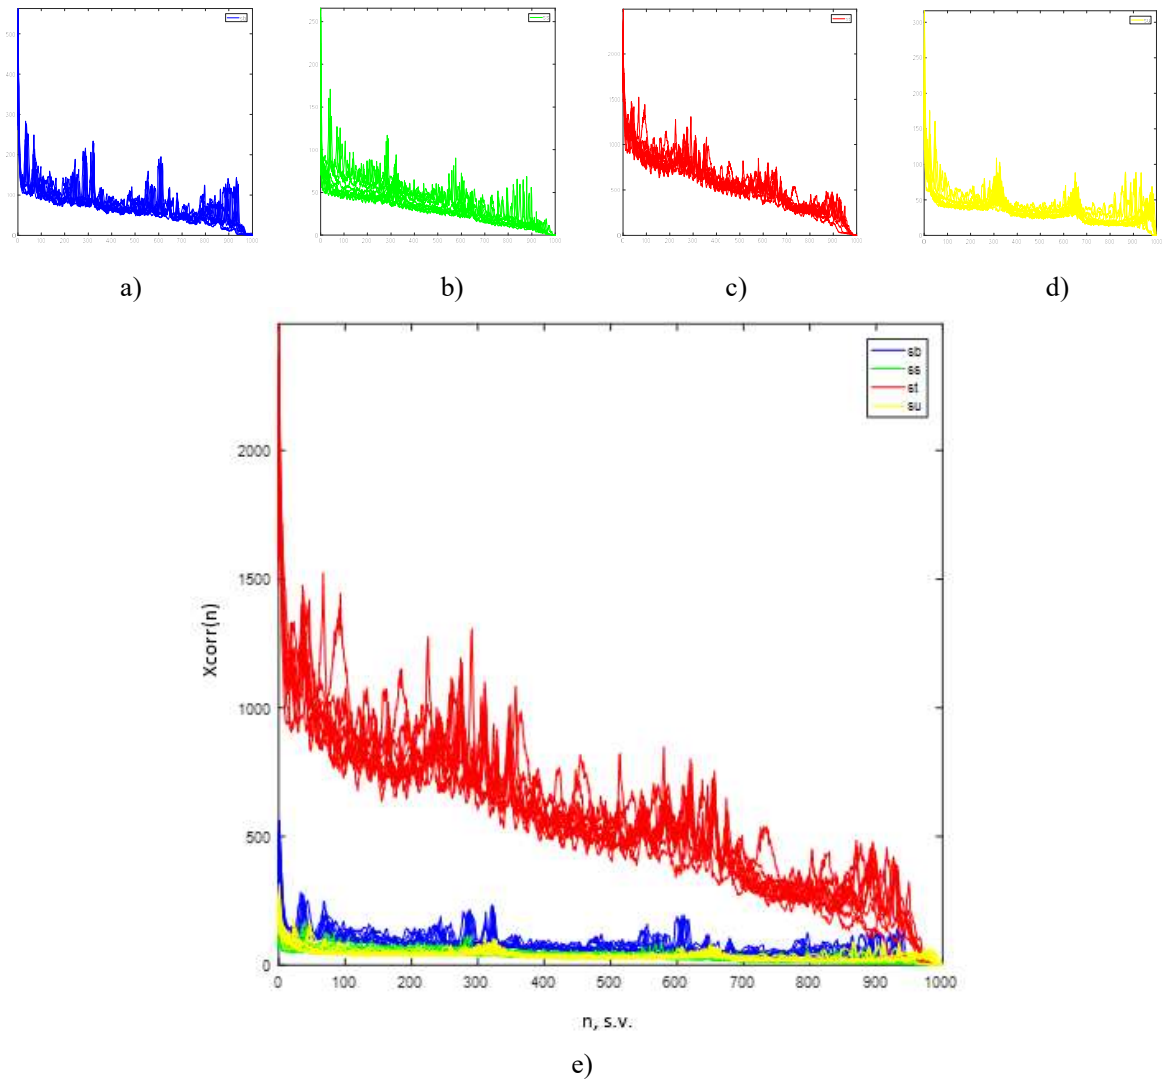
3.4 pav. Atlikto tyrimo eigos blokinė diagrama

Atlikus pradinį pasiruošimo darbą kitas tyrimo etapas buvo nuspręsti, kaip bus apdorojami duomenys gauti jutikliais tiriant veikiančio nuolatinės srovės variklio garso, srovės ir vibracijų signalus. Kiekvienas nuolatinės srovės variklio darbo režimas buvo tiriamas signalą gaunant minėtais jutikliais. Taip pat kiekvieno gedimo tyrimas su tuo pačiu jutikliu buvo pakartojamas tam, kad gauto rezultato tikslumą būtų galima patikrinti. Taip gauta po porą duomenų paketų kiekvienam nuolatinės srovės variklio darbo režimui: 100 atskirų duomenų kiekvienam darbo režimui su kiekvienu iš trijų jutiklių. Duomenys nuskaityti 1000 Hz dažniu ir su 8 bitų duomenų apdorojimo galimybėmis. Norint apdoroti tokius gautus duomenis buvo naudojamos signalo transformacijos signalo transformavimui ir autokoreliacijos funkcija tam, kad panaikinti signalo spektre esančius šalutinius triukšmus, kurie trukdo matyti tiriamo signalo spektro formą. Toks signalo pakeitimas tyrime yra vadinamas tyrimo būdu. Po duomenų apdorojimo buvo gauta skaičių eilutė iš kurios imta 1000 antros kreivės pusės duomenų su jų x ir y ašių vertėmis. Tai padaryta, nes kreivės, gautos po autokoreliacijos funkcijos buvo simetriškos ir kiekviena kreivės pusė pateikia identišką tyrimo rezultatą. Visos gedimų kreivės buvo pateikiamos tuose pačiuose grafikuose. Kreivėse x ašies informacija atitinka imties vienetų skaičių, o y ašies duomenys atitinka rezultatus po autokoreliacijos funkcijos ($X_{corr}(n)$), kai gautas signalo spektras buvo lyginamas su pačiu savimi esant skirtingoms pradinio signalo transformacijoms. Skirtingais jutikliais gauti rezultatai buvo grupuojami atskirai ir pateikiami kartu su panaudotu signalų transformacijos metodu. Pagal kreivių formą buvo galima daryti sprendimus apie tai, kokie gedimų diagnostikos būdai atliekamam tyrimui pasiteisina, o kurie ne, ir pagal tai daryti išvadas, kokius metodus tikslinga naudoti klasifikavimui.



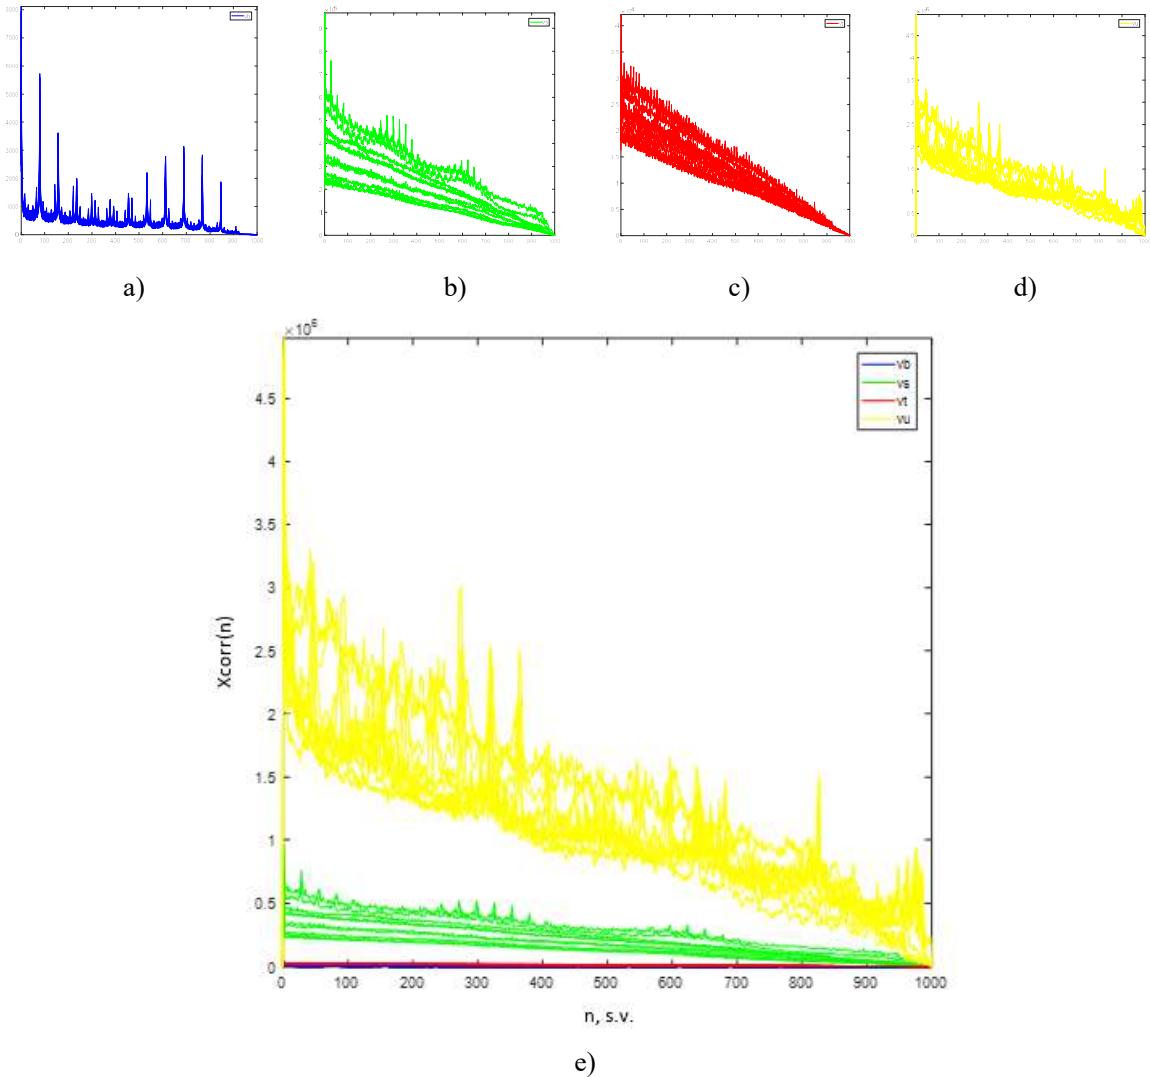
3.5 pav. Garso signalo kreivės gautos po greitos Furjė transformacijos: a) ašies disbalansas; b) variklis be defektų; c) trumpas jungimas tarp apvijų; d) užteršimas; e) kreivių palyginimas

Iš kreivių pateikiamų 3.5 paveiksle matyti, kad gedimai po garso jutiklio panaudojimo ir greitos Furjė transformacijos yra aiškiai matomi. Tai galima vizualiai įvertinti iš 3.5 e paveikslo, kuriame ašies disbalanso gedimo kreivės yra pačiame viršuje, trumpo jungimo kreivės yra viduryje, o užteršimo ir variklio be defektų kreivės yra atitinkamai apačioje. Variklio be defektų darbo kreivės ir variklio užteršimo kreivės kertasi tarpusavyje, tai yra nepageidautinas bruožas atliekamam tyrimui, nes šiuos gedimus sunku atskirti iš grafinės reprezentacijos. Tačiau, galima teigti, kad greitoji Furjė transformacija atskiria kitus tirtų gedimų bruožus ganėtinai efektyviai: tarp ašies disbalanso ir trumpojo jungimo gedimų matomas skirtumas iš jų kreivių formos. Pakartotiniai visų darbo režimų bandymai yra vizualiai panašūs. Geriausi rezultatai gauti ašies disbalanso gedimui įvertinti ir trumpo jungimo atveju. Variklio be defektų ir užteršimo atveju skirtingų darbo režimų kreivės kertasi, nors užteršimo kreivių pasiskirstymas yra didesnis. Vis dėlto, pagal gautus rezultatus matyti, kad Furjė transformacijos panaudojimas garso signalo analizei yra efektyvus ir tinkamas būdas įvairiems gedimams atskirti ir jį naudojant yra gaunamos skirtingos gedimų kreivės, kurios sutampa tarpusavyje atliekant pakartotinius bandymus. Toks tyrimo būdas leidžia atpažinti skirtingus variklio darbo režimus ir atskirti skirtingus gedimus pagal šių gedimų tipines kreives.



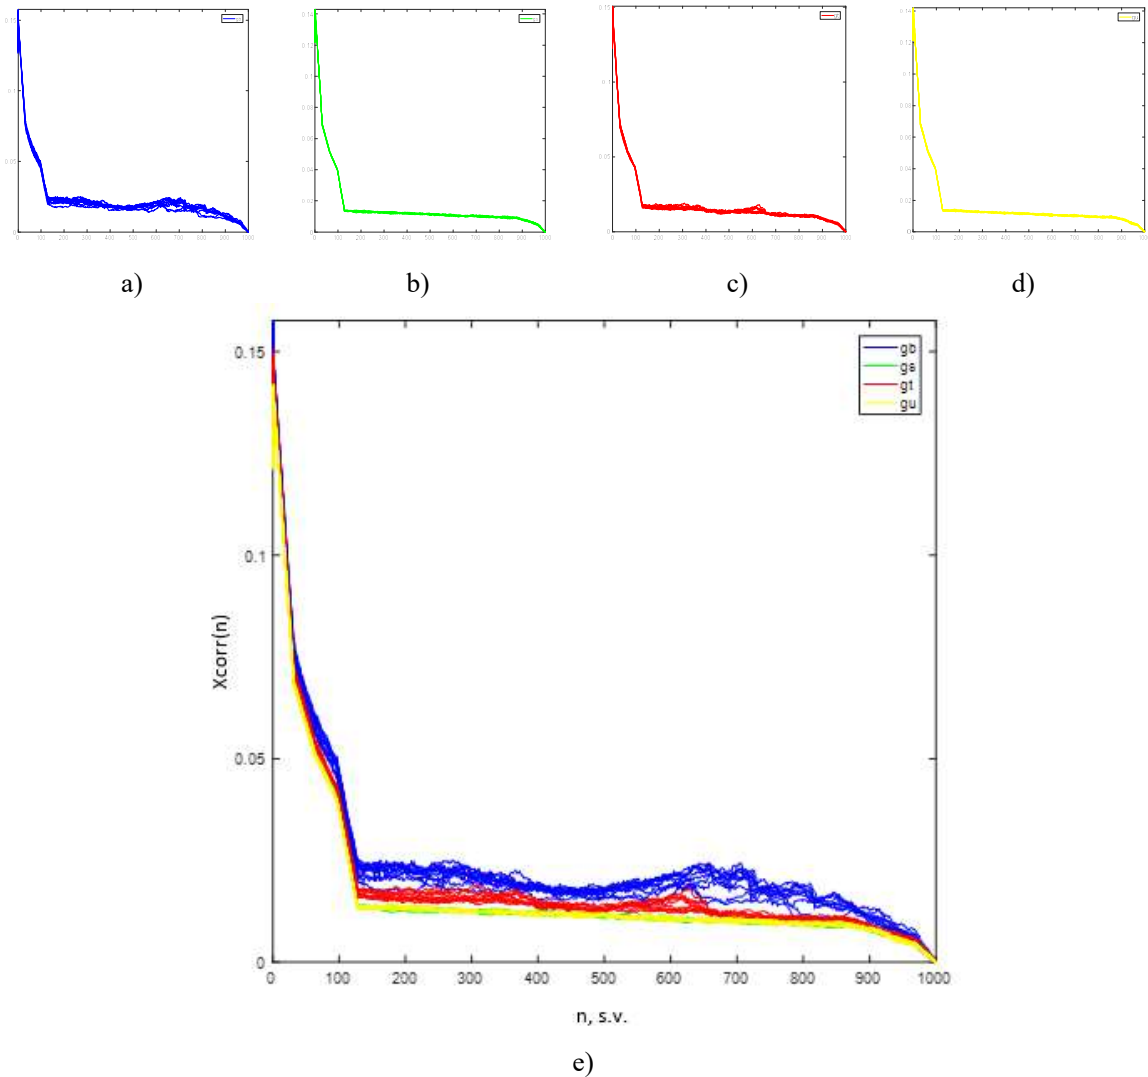
3.6 pav. Srovės signalo kreivės gautos po greitosios Furjė transformacijos: a) ašies disbalansas; b) variklis be defektų; c) trumpas jungimas tarp apvijų; d) užteršimas; e) kreivių palyginimas

Kreivės pateikiamos 3.6 paveiksle yra gautos naudojant srovės jutiklį ir panaudojant greitąją Furjė transformaciją. Iš 3.6 e paveikslo galima pamatyti, kad panaudojus šį gedimo tyrimo būdą geriausiai matomas yra trumpas jungimas tarp nuolatinės srovės variklio apvijų. Toks gedimas yra pačiame 3.6 e paveikslo viršuje ir yra aiškiai atskiriamas nuo ašies disbalanso (žr. 3.6 a pav.), variklio be defektų (žr. 3.6 b pav.) ir užteršimo (žr. 3.6 d pav.). Ašies disbalanso, nuolatinės srovės variklio be defektų ir užteršimo atvejais gauti paveikslai atitinkamai 3.6 a, b, d, kurie parodo, kad pakartotiniai to paties gedimo arba variklio be defektų darbo režimo bandymai sutampa ir tai yra geras šio būdo rezultatas. Vis dėlto, palyginant visas kreives 3.6 e paveiksle matyti, kad vienintelės aiškiai matomos kreivės yra trumpo jungimo gedimo atveju (žr. 3.6 e pav. viršutinės kreivės). Jų amplitudė yra daug didesnė už kitų variklio gedimų būdų. Tai gali būti paveikiama to, kad trumpasis jungimas yra pirmiausiai elektrinio pobūdžio gedimas. Tai yra gerai matoma iš srovės signalo. 3.6 e grafiko apačioje vizualiai sunku atskirti variklio darbo režimą be defektų, ašies disbalansą ir užteršimą, nes šių darbo režimų kreivių panašumas yra ganėtinai didelis lyginant su trumpo jungimo gedimu. Šie gedimai nėra taip aiškiai matomi, tačiau jie skiriasi tarpusavyje, nors ir ne taip žymiai kaip trumpo jungimo atveju. Vis dėlto, ši jutiklio ir signalų transformacijos kombinacija yra potenciali ir bus panaudojama tolimesniam tyrimui.





3.7 pav. Vibracijos signalo kreivės gautos po greitosios Furjė transformacijos: a) ašies disbalansas; b) variklis be defektų; c) trumpas jungimas tarp apvijų; d) užteršimas; e) kreivių palyginimas

3.7 paveiksle pateikiamos kreivės gautos panaudojant vibracijos jutiklį ir po greitosios Furjė transformacijos. Iš 3.7 e paveikslo matyti, kad aiškiausiai matomos ir vizualiai lengvai atskiriamos yra variklio užteršimo ir variklio be defektų kreivės. Tiek 3.7 b ir 3.7 d paveiksluose matyti, kad šie variklio darbo režimai yra panašūs tarp to paties darbo režimo net atliekant daug pakartotinių bandymų. Kiti variklio darbo režimai: trumpas jungimas (žr. 3.7 c pav.) ir ašies disbalansas (žr. 3.7 a pav.) yra sunkiai atskiriami 3.7 e paveiksle ir jų kreivės yra pačioje 3.7 e paveikslo apačioje. Variklio be defektų darbo režimo atveju (žr. 3.7 b pav.) ir variklio užteršimo (žr. 3.7 d pav.) atvejais matyti, kad tarp pakartotinių gedimų atsiranda tam tikras nesutapimas, kuris vizualiai yra žymus stebint atskirų darbo režimų kreives. Trumpas jungimas turi panašų signalo pobūdį ir amplitudę kaip ir variklio ašies disbalansas ir juos yra sunku atskirti. Tyrimo būdas sunkiai atskiria šiuos du darbo režimus, todėl jį būtų sudėtinga pritaikyti trumpo jungimo ar variklio ašies disbalanso atpažinimui. Vis dėlto, jis gali būti gerai pritaikomas variklio be defektų veikimo atpažinimui ir variklio užteršimo atskyrimui. Tokį tyrimo būdą būtų galima panaudoti kartu su kitais jutikliais ar signalo transformacijos būdais norint atskirti trumpą jungimą ir variklio ašies disbalansą. Tai suteiktų galimybę panaudoti skirtingų būdų kombinaciją sėkmingai atskiriant minėtus gedimus kartu su variklio be defektų darbu bei variklio užteršimu.



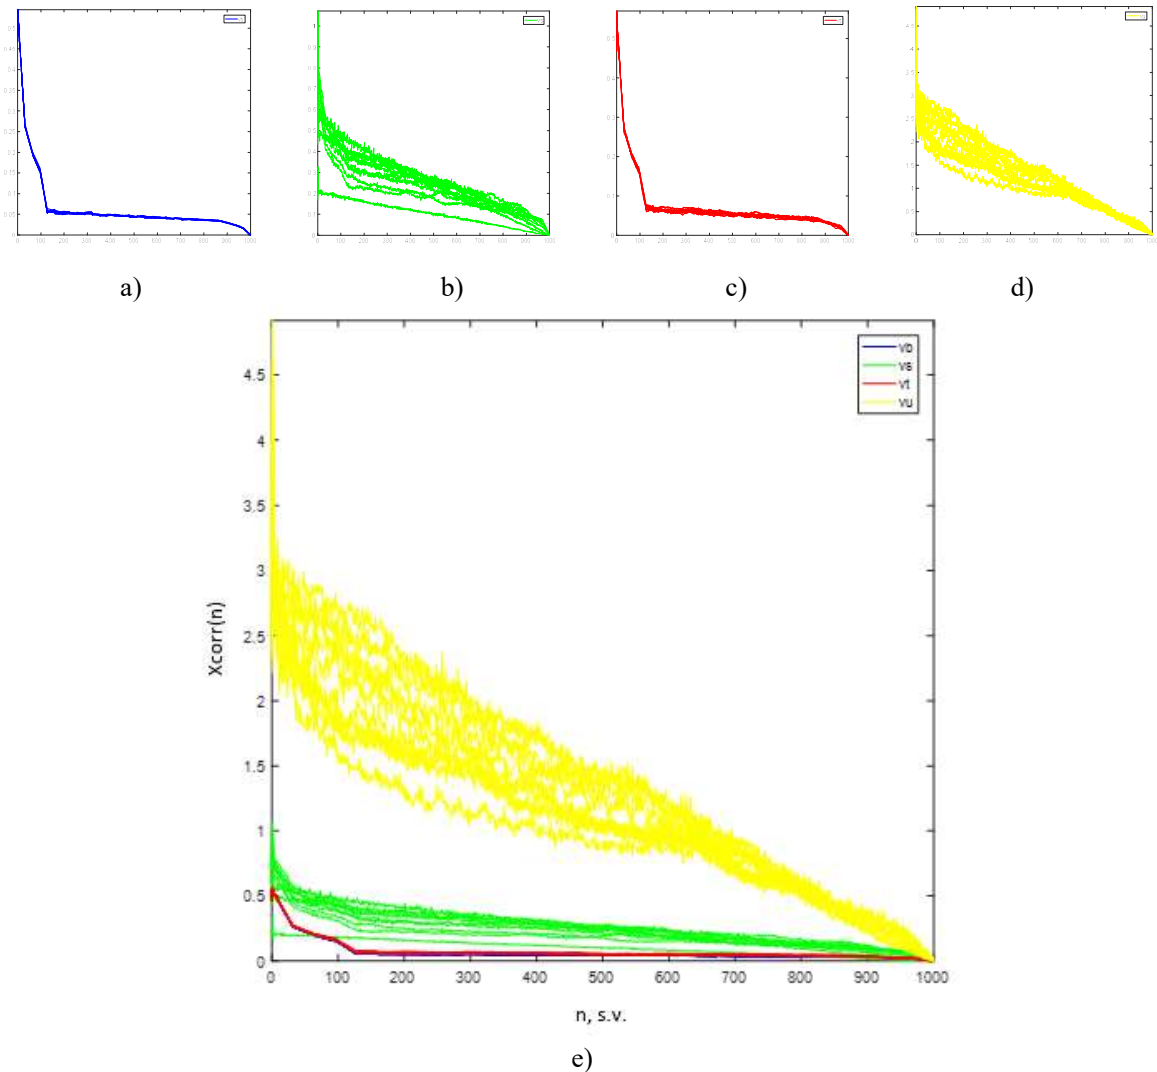
3.8 pav. Garso signalo kreivės gautos po FWHT transformacijos: a) ašies disbalansas; b) variklis be defektų; c) trumpas jungimas tarp apvijų; d) užteršimas; e) kreivių palyginimas

3.8 paveiksle pateikiamos garso signalo kreivės gautos po greitosios Walsh-Hadamard transformacijos. 3.8 e paveiksle matyti, kad šio tyrimo būdo atveju aiškiausiai vizualiai matomas ašies disbalanso ir trumpo jungimo kreivės (žr. 3.8 e pav. viršutinės kreivės). Užteršimo kreivės yra labai panašios į variklio be defektų darbo režimo kreives. Greitoji Walsh-Hadamard transformacija nėra pajėgi atskirti šių darbo režimų skirtumų. Visi darbo režimai turi ganėtinai didelį sutapimą tarpusavyje tarp to paties variklio darbo režimo. Galima teigti, kad būdas tinkamas dviejų gedimų: ašies disbalanso ir trumpojo jungimo tarp variklio apvijų atpažinimui. Variklio be defektų darbo režimo atveju ir variklio užteršimo atvejais jų atpažinimui būtų tikslinga panaudoti kitus tyrime naudotus gedimų diagnostikos būdus, norint juos tinkamai atpažinti ir atskirti vieną nuo kito. Vis dėlto, būdas turi potencialo, nes gerai atskiria du gedimų tipus: ašies disbalansą ir trumpąjį jungimą tarp variklio apvijų. Dėl šios priežasties šiuo metodu gauti rezultatai bus toliau analizuojami atliekamame tyrime, nes pagal šį tyrimo būdą galima gauti potencialiai gerus rezultatus ir juos panaudoti gedimų diagnostikos uždaviniuose. Taip pat šio būdo pranašumas yra aiškus sutapimas tarp to paties darbo režimo, kuris yra itin svarbus gedimo atpažinimo kokybės įvertinimui. Garso signalo panaudojimas, kaip matoma ir Furjė transformacijos atveju, gerai atskiria skirtingus gedimus ir yra tinkamas gedimų diagnostikos uždaviniams.




3.9 pav. Srovės signalo kreivės gautos po FWHT transformacijos: a) ašies disbalansas; b) variklis be defektų; c) trumpas jungimas tarp apvijų; d) užteršimas; e) kreivių palyginimas

3.9 paveiksle pateikiamos kreivės gautos panaudojus srovės jutiklį ir greitąją Walsh-Hadamard transformaciją. Kaip matyti iš 3.9 e paveikslo visos nuolatinės srovės variklio darbo režimų kreivės yra beveik identiškios ir tarp jų sunku pamatyti esminių skirtumų. Walsh-Hadamard transformacija nėra pajėgi atskirti signalus, gautus panaudojant srovės jutiklį. Skirtingi variklio darbo režimai yra ganėtinai panašūs tarp to paties gedimo kreivių. Tai yra matoma 3.9 a-d paveiksluose, tačiau taip pat vizualiai nėra beveik jokių skirtumų tarp skirtingų variklio darbo režimų. Tai matoma 3.9 e paveiksle ir dėl ko gedimų diagnostikos uždavinys, kai norima atpažinti gedimą pagal gedimo tipines kreives, tampa sudėtingas. Greitoji Walsh-Hadamard transformacija neatskiria skirtingų gedimų bruožų, gaunamų pagal srovės signalą ir šiuo atžvilgiu atsilieka nuo greitosios Furjė transformacijos, kurios atveju 3.6 e paveiksle yra aiškiai matomi tam tikrų gedimų (ypač trumpojo jungimo) bruožai, ko nematyti greitosios Walsh-Hadamard transformacijos atveju. Svarbu paminėti, kad greitoji Walsh-Hadamard transformacija gerai atpažįsta skirtingus variklio gedimus panaudojant garso bei vibracijų jutikliais gautus signalus, tačiau signalai, gauti panaudojant srovės jutiklį, nėra tinkami gedimų diagnostikai, bet pats greitosios Walsh-Hadamard transformacijos būdas yra potencialus ir kartu su kitais garso bei vibracijų jutikliais yra toliau naudojamas atliekamame tyrime.



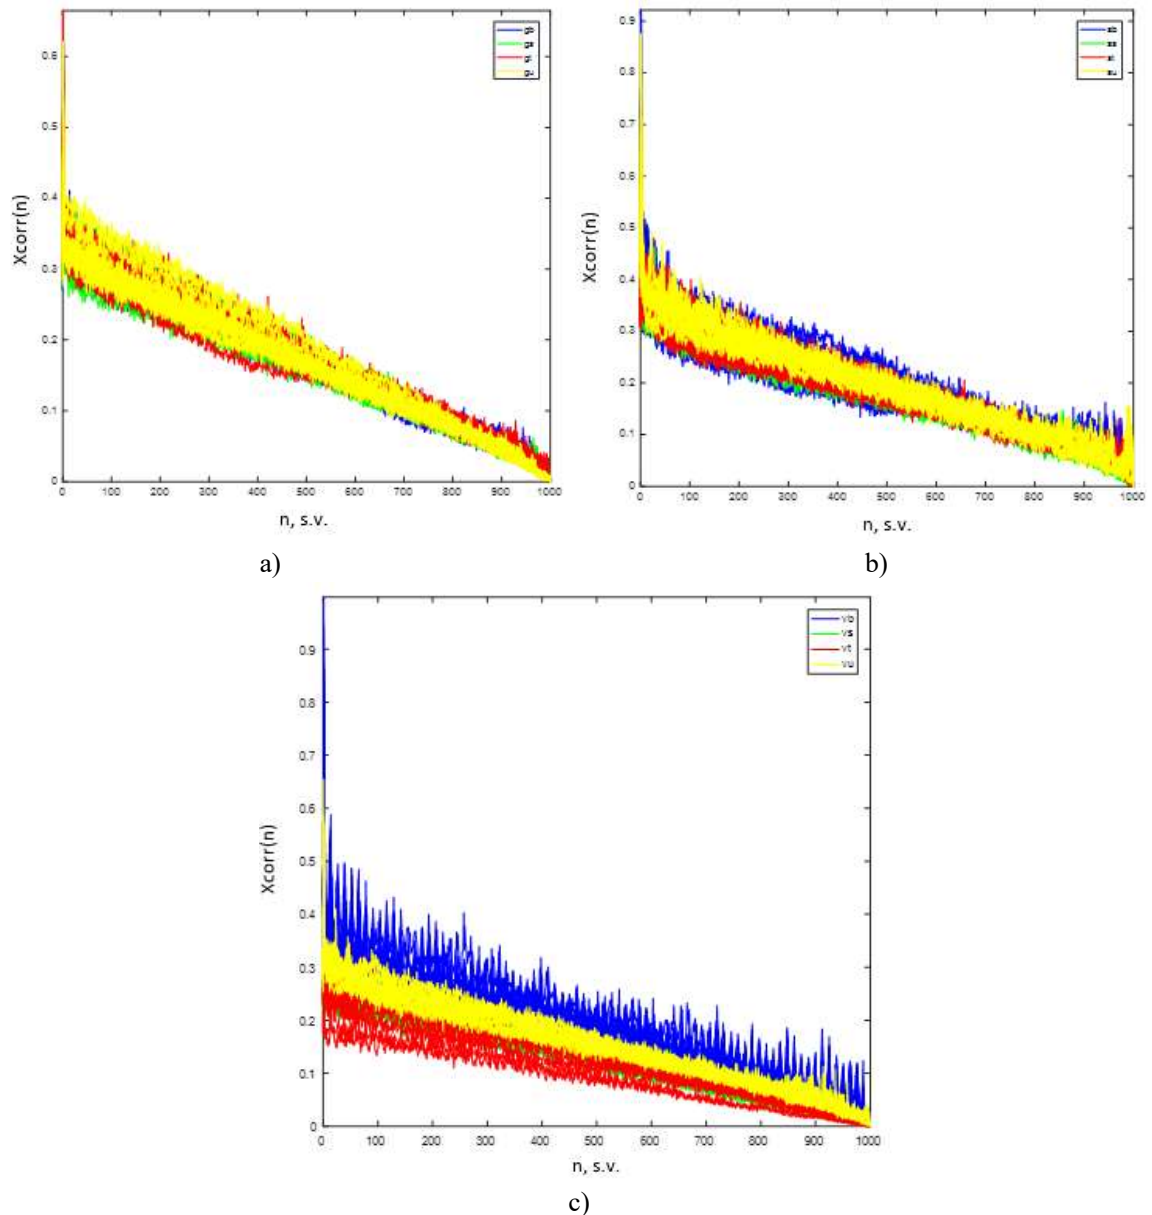
3.10 pav. Vibracijos signalo kreivės gautos po FWHT transformacijos: a) ašies disbalansas; b) variklis be defektų; c) trumpas jungimas tarp apvijų; d) užteršimas; e) kreivių palyginimas

3.10 paveiksle pateikiamos kreivės gautos po greitosios Walsh-Hadamard transformacijos ir naudojant vibracijų jutiklį. Iš 3.10 e paveikslo matyti, kad šiuo tyrimo būdu lengviausiai atskiriamos yra variklio be defektų darbo režimo ir variklio užteršimo kreivės. Jos yra 3.10 e paveikslo viršuje. Šios kreivės yra panašios tarpusavyje tarp to paties darbo režimo. Tai matoma 3.10 b ir 3.10 d paveiksluose. Kitos nuolatinės srovės variklio kreivės sutampa tarpusavyje (žr. 3.10 a ir 3.10 c pav.), tačiau trumpojo jungimo kreivės yra sunkiai atskiriamos nuo ašies disbalanso kreivių. Didesnis nesutapimas tarp pakartotinių bandymų yra matomas variklio užteršimo ir itin aiškiai matomas variklio be defektų kreivėse, tačiau šie darbo režimai lengvai atskiriami vienas nuo kito. Pagal gautus rezultatus galima teigti, kad vibracijos jutiklio ir FWHT kombinaciją galima panaudoti, norint nustatyti nuolatinės srovės variklio skirtingus darbo režimus: variklio užteršimą, variklio be defektų darbo režimą. Sunku būtų atskirti trumpojo jungimo ir ašies disbalanso gedimus. Tyrimo būdas turi potencialo, nes rezultatai yra patenkinami. Tai yra matoma iš 3.10 e paveikslo. Tikėtina, kad su didele signalų imtimi ir nuolatiniais gedimų stebėjimais tyrimo būdas būtų pajėgus sėkmingai atpažinti skirtingus gedimus elektros variklyje. Taip pat galima panaudoti šio tyrimo būdo kombinaciją su kitais jutiklių signalais ar signalo apdorojimo būdais, kurie patikimiau atskiria variklio trumpo jungimo ir ašies disbalanso kreives.



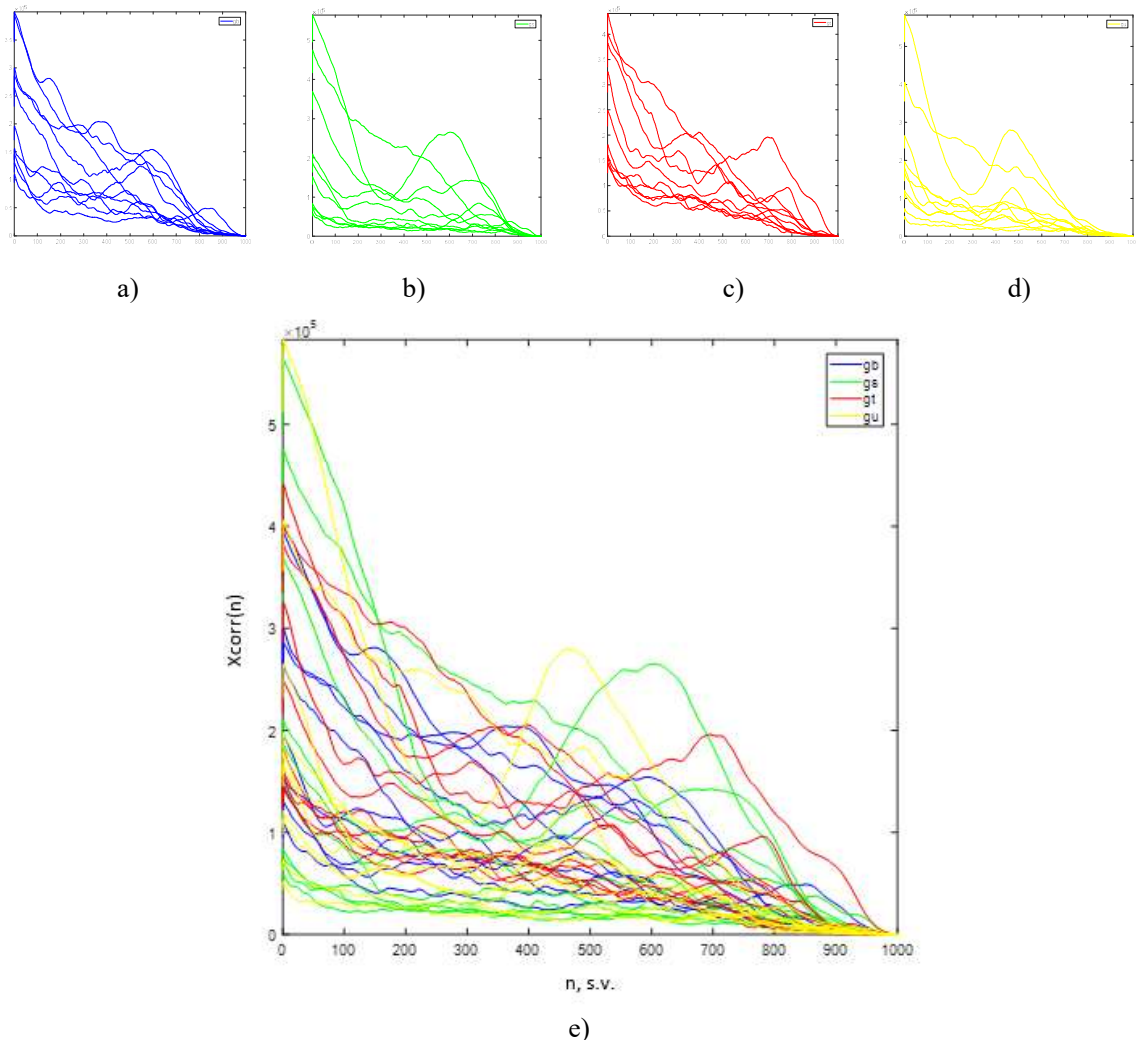
3.11 pav. Kreivės gautos po kompleksinės Kepstro transformacijos: a) garso jutiklio rezultatai; b) srovės jutiklio rezultatai; c) vibracijos jutiklio rezultatai

3.11 paveiksle pateikiamos kreivės gautos po kompleksinės Kepstro transformacijos panaudojant garso (žr. 3.11 a pav.), srovės (žr. 3.11 b pav.) ir vibracijų (žr. 3.11 c pav.) jutiklius. Kaip matyti iš šių paveikslų yra sunku atskirti skirtingus gedimus ir nuolatinės srovės variklio darbo režimus. Kompleksinė Kepstro transformacija pakeitė pradinio signalo formą, tačiau nepadarė jo lengviau atskiriamo. Šiam tyrimo būdui kaip ir kitiems buvo naudojama ir autokoreliacijos funkcija, tačiau ir po jos panaudojimo esminiai gedimų bruožai nėra gerai matomi. Iš gautų kreivių matyti, kad rezultatai panaudojant vien tik kompleksinę Kepstro funkciją negali pateikti skirtumų tarp skirtingų gedimų ir šio būdo panaudojimas yra netikslingas tolimesniame tyrime.



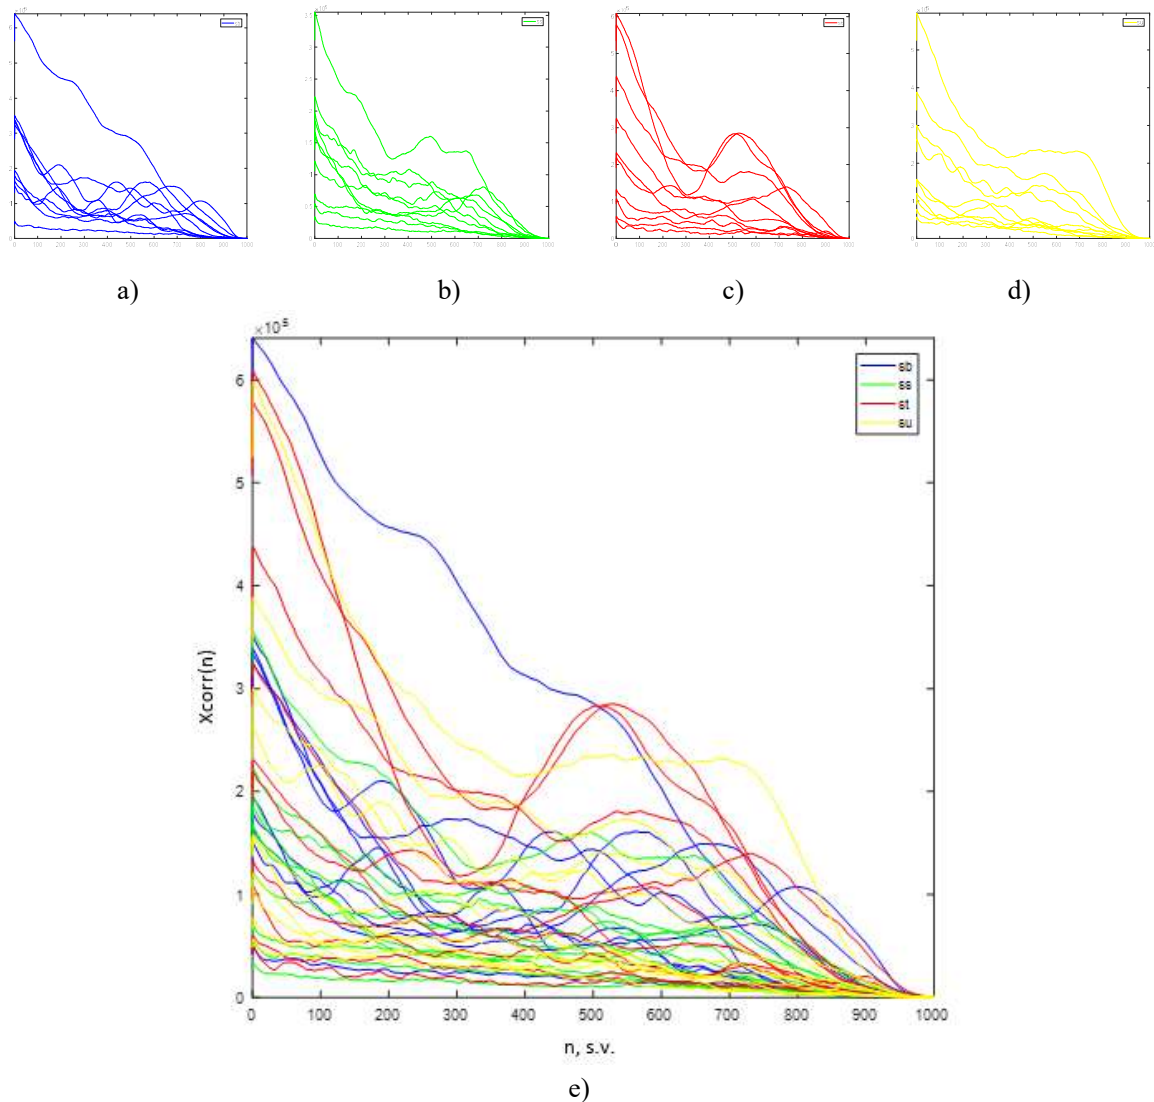
3.12 pav. Kreivės gautos po realiosios Kepstro transformacijos: a) garso jutiklio rezultatai; b) srovės jutiklio rezultatai; c) vibracijos jutiklio rezultatai

3.12 paveiksle yra pateikiamos kreivės gauti po realiosios Kepstro transformacijos panaudojant garso (žr. 3.12 a pav.), srovės (žr. 3.12 b pav.) ir vibracijų (žr. 3.12 c pav.) jutiklius. Kaip matyti iš paveikslų yra sunku atskirti skirtingus nuolatinės srovės variklio veikimo režimus. Vis dėlto, 3.12 c paveiksle matyti, kad nuolatinės srovės variklio ašies disbalanso gedimo kreivės turi didesnę amplitudę lyginant su kitais gedimais. Pagal gautus rezultatus matyti, kad naudojant tik realiąją Kepstro transformaciją galima gauti daug geresnių rezultatų negu kompleksinės Kepstro transformacijos atveju. Vis dėlto, be pagalbinių signalo transformacijų toks tyrimo būdas nėra efektyvus.



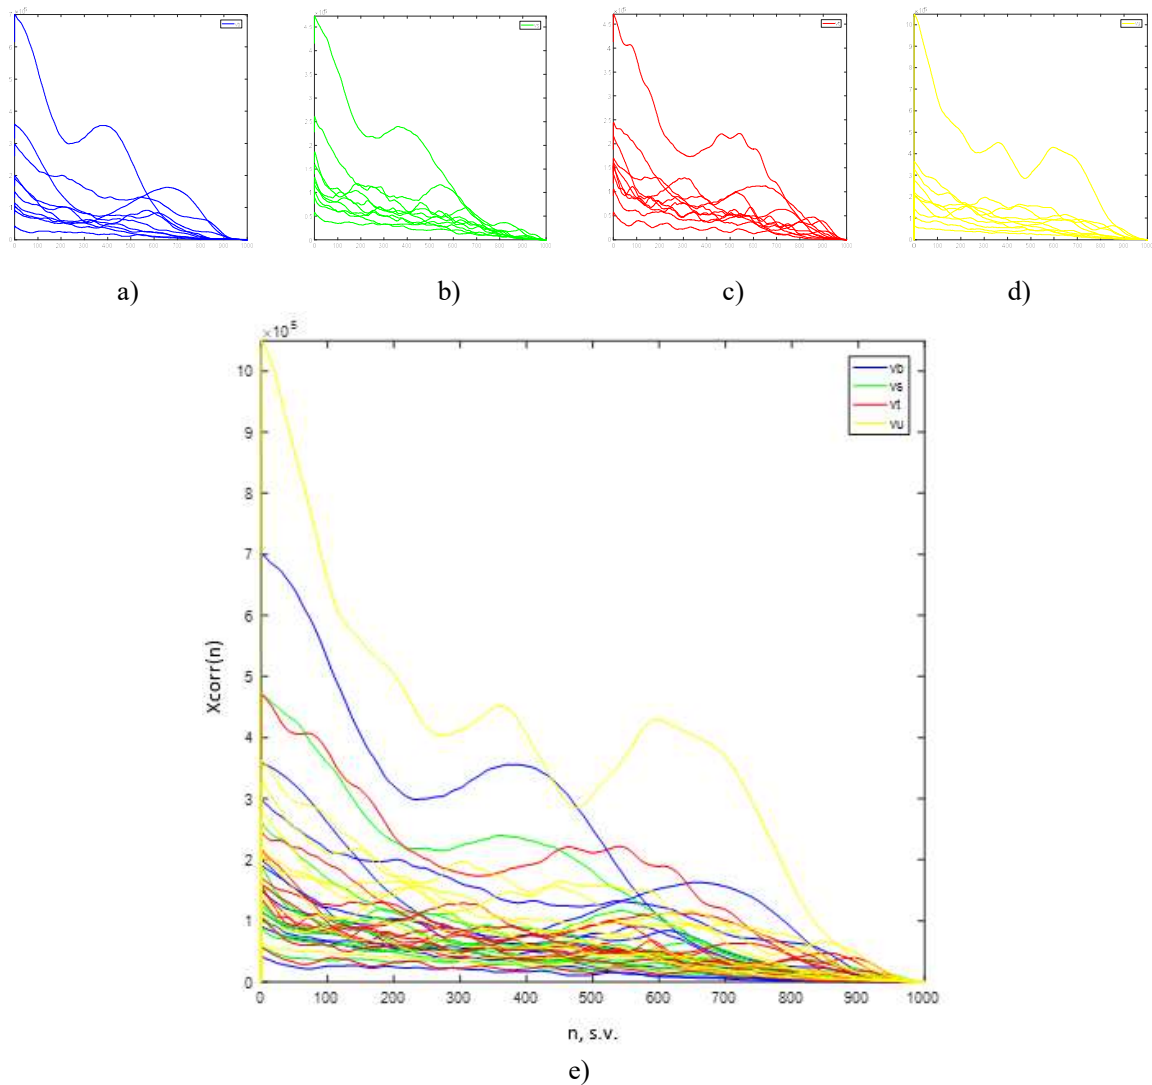
3.13 pav. Garso signalo kreivės gautos po kompleksinės Kepstro ir FFT transformacijų kombinacijos:
a) ašies disbalansas; b) variklis be defektų; c) trumpas jungimas tarp apvijų; d) užteršimas;
e) kreivių palyginimas

3.13 paveiksle pateikiamos garso signalo kreivės gautos po kompleksinės Kepstro transformacijos ir Furjė transformacijos, panaudojant garso jutikliu gautus duomenis. Iš 3.13 e paveikslo matyti, kad gautos kreivės kertasi tarpusavyje. 3.13 e paveiksle atvaizduotose kreivėse yra sunku atskirti skirtingus nuolatinės srovės variklio gedimus. Gedimų kreivės yra panašios ir jos kertasi viena su kita, nėra matoma esminių skirtumų tarp skirtingų gedimų. Net ir to paties variklio darbo režimo kreivės yra ganėtinai skirtingos. Tai matyti 3.13 a-d paveiksluose. Tai itin gerai matoma 3.13 b ir d paveiksluose, kai to paties darbo režimo kreivės turi itin skirtingas amplitudes. Matyti, kad panaudojant Furjė transformaciją pakartotinai signalo analizei gauti rezultatai nėra patenkinami. Skirtingai negu kitų diagnostikos būdų atveju, gautos kreivės po signalų transformacijos kertasi tarpusavyje, nėra lengvai atskiriamos nuo kitų gedimų. Galima teigti, kad toks tyrimo būdas nėra tikslingas ir nėra aktualu tolesniam tyrimui panaudoti šį gedimų diagnostikos būdą, nes gauti rezultatai yra blogesni negu naudojant kitus diagnostikos būdus. Kompleksinė Kepstro transformacija, greitoji Furjė transformacija ir autokoreliacijos funkcija kartu nėra pajėgios tinkamai atskirti gedimų. Vis dėlto, matyti, kad pakartotinas greitosios Furjė transformacijos panaudojimas leidžia gauti geresnius rezultatus negu 3.11 a paveiksle, kai nėra matoma jokių skirtumų tarp skirtingų signalų ir nematomi jų požymiai.




3.14 pav. Srovės signalo kreivės gautos po kompleksinės Kepstro ir FFT transformacijų kombinacijos:
a) ašies disbalansas; b) variklis be defektų; c) trumpas jungimas tarp apvijų; d) užteršimas;
e) kreivių palyginimas

3.14 paveiksle matyti srovės jutiklio duomenys pakeisti kompleksinės Kepstro transformacijos ir Furjė transformacijos. 3.14 e paveiksle matyti, kad kreivės, gautos po įvairių nuolatinės srovės variklio gedimų ir nuolatinės srovės variklio be defektų darbo režimo yra sunkiai atskiriamos viena nuo kitos ir skirtingų variklio darbo režimų kreivės kertasi tarpusavyje. Tai yra nepageidautina, nes tokiu atveju sunku vizualiai pamatyti, kada koks nuolatinės srovės variklio darbo režimas matomas ir ar yra kokio nors tipo gedimas nuolatinės srovės variklyje. Dėl šios priežasties galima teigti, kad toks gedimų nustatymo būdas nepateikia galimybės lengvai atskirti skirtingų gedimų. Tai matoma iš 3.14 e paveikslo. Tai yra svarbu, norint atskirti skirtingus gedimus iš jų kreivių ir tai būtų sudėtinga taikant šį būdą. Kaip ir garso jutiklio atveju, kompleksinės Kepstro transformacijos, FFT ir autokoreliacijos funkcijos kombinacija nepasiteisina ir naudojant srovės jutiklį. Rezultatai gauti 3.14 paveiksle įrodo, kad toks tyrimo būdas nėra pajėgus atskirti, kokie gedimai yra nuolatinės srovės variklyje, nes skirtingų gedimų kreivės yra susikertančios tarpusavyje ir sunkiai atskiriamos. Gedimų kreivės nėra net panašios ir tarp to paties gedimo. Tai yra itin aiškiai matoma ir yra priešingai, naudojant kitus tyrimo būdus.



3.15 pav. Vibracijos signalo kreivės gautos po kompleksinės Kepstro ir FFT transformacijų kombinacijos:
a) ašies disbalansas; b) variklis be defektų; c) trumpas jungimas tarp apvijų; d) užteršimas;
e) kreivių palyginimas

3.15 paveiksle matomos kreivės gautos po kompleksinės Kepstro transformacijos ir Furjė transformacijos panaudojus vibracijos jutikliu gautus duomenis. Iš 3.15 e paveikslo galima matyti kaip skirtingų gedimų kreivės pasiskirstę tarpusavyje. Skirtingų gedimų kreivės sutampa tarpusavyje ir tai yra požymis, kuris yra nepageidautinas atliekamam tyrimui. Tai matoma itin aiškiai visais variklio darbo režimų atvejais, kurie pateikiami 3.15 e paveiksle. Nei vieno gedimo kreivės neturi ženklaus sutapimo atliekant pakartotinus bandymus. Galima daryti išvadą, kad taikant tokį gedimų nustatymo būdą būtų sudėtinga efektyviai atskirti skirtingus gedimus nuolatinės srovės variklyje. Tai yra matoma visais atvejais, kai panaudojama kompleksinė Kepstro funkcija. Atskiri gedimai ir nuolatinės srovės variklio be defektų darbo režimas turi panašias kreives, kurių forma nėra itin išskirtinė, pagal kurią būtų galima greitai ir patikimai atpažinti gedimą iš jo kreivių. Vibracijos jutiklio rezultatai gaunami tokie patys kaip ir prieš tai minėtuose garso jutiklio ir srovės jutiklio kombinacijos su FFT bei autokoreliacijos funkcija variantuose. Todėl šis tyrimo būdas nėra pajėgus atskirti skirtingų gedimų elektros variklyje taip, kad pagal gautus rezultatus tiek grafiškai, tiek matematine išraiška būtų galima spręsti, kokio tipo gedimas yra elektros variklyje. Kreivių forma yra itin įvairi: tas pats gedimas turi skirtingo pobūdžio kreives, gedimų atpažinimas tampa sudėtingas.

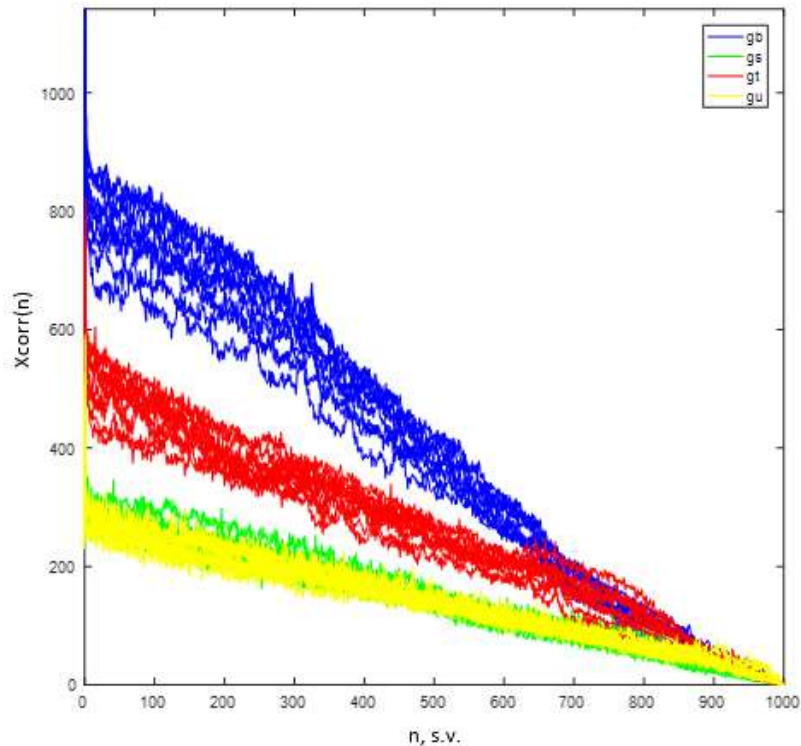


a)

b)

c)

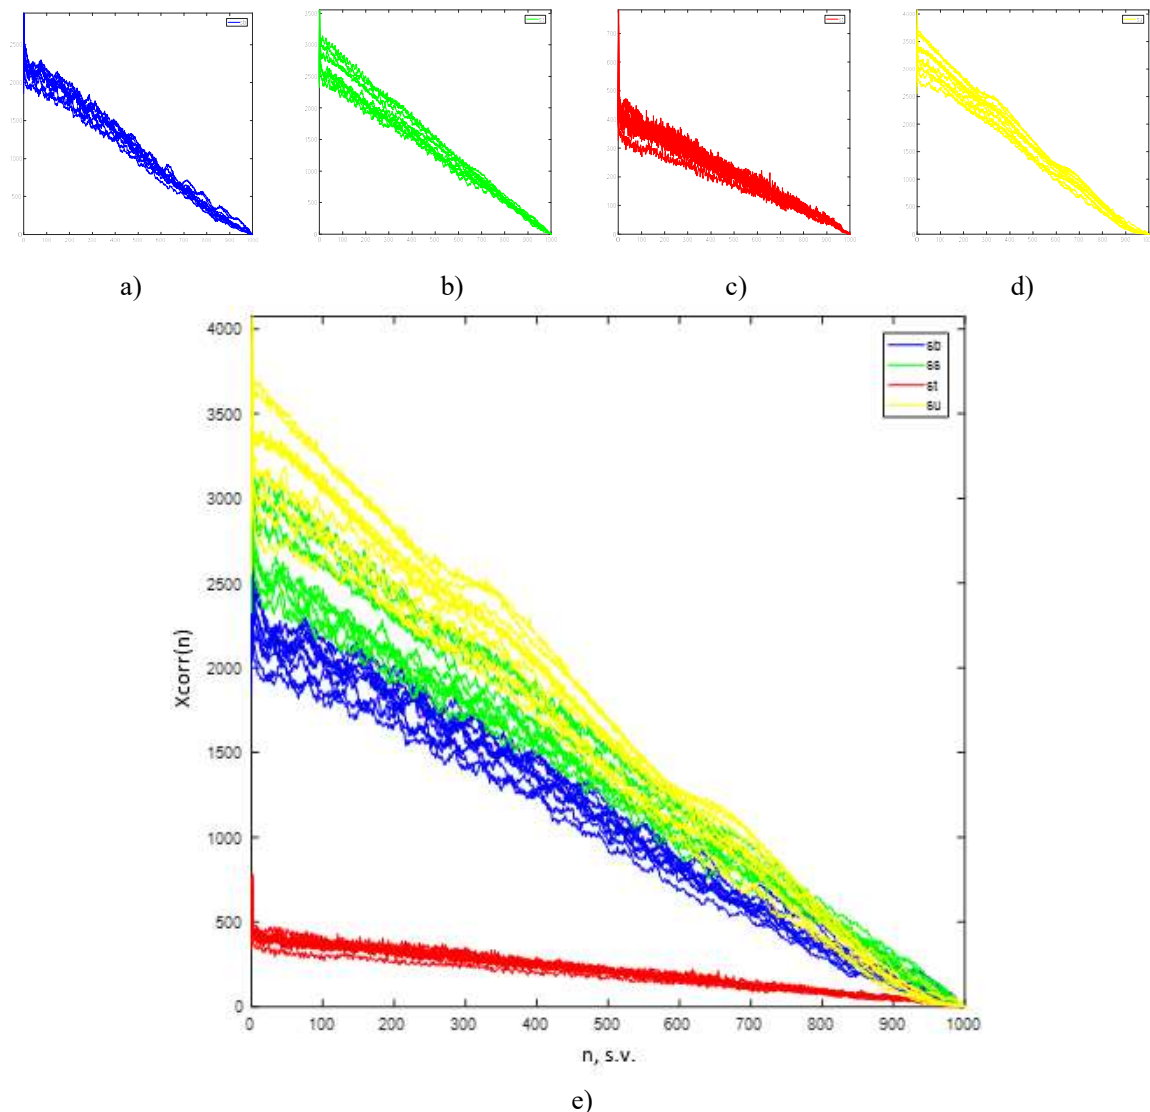
d)



e)

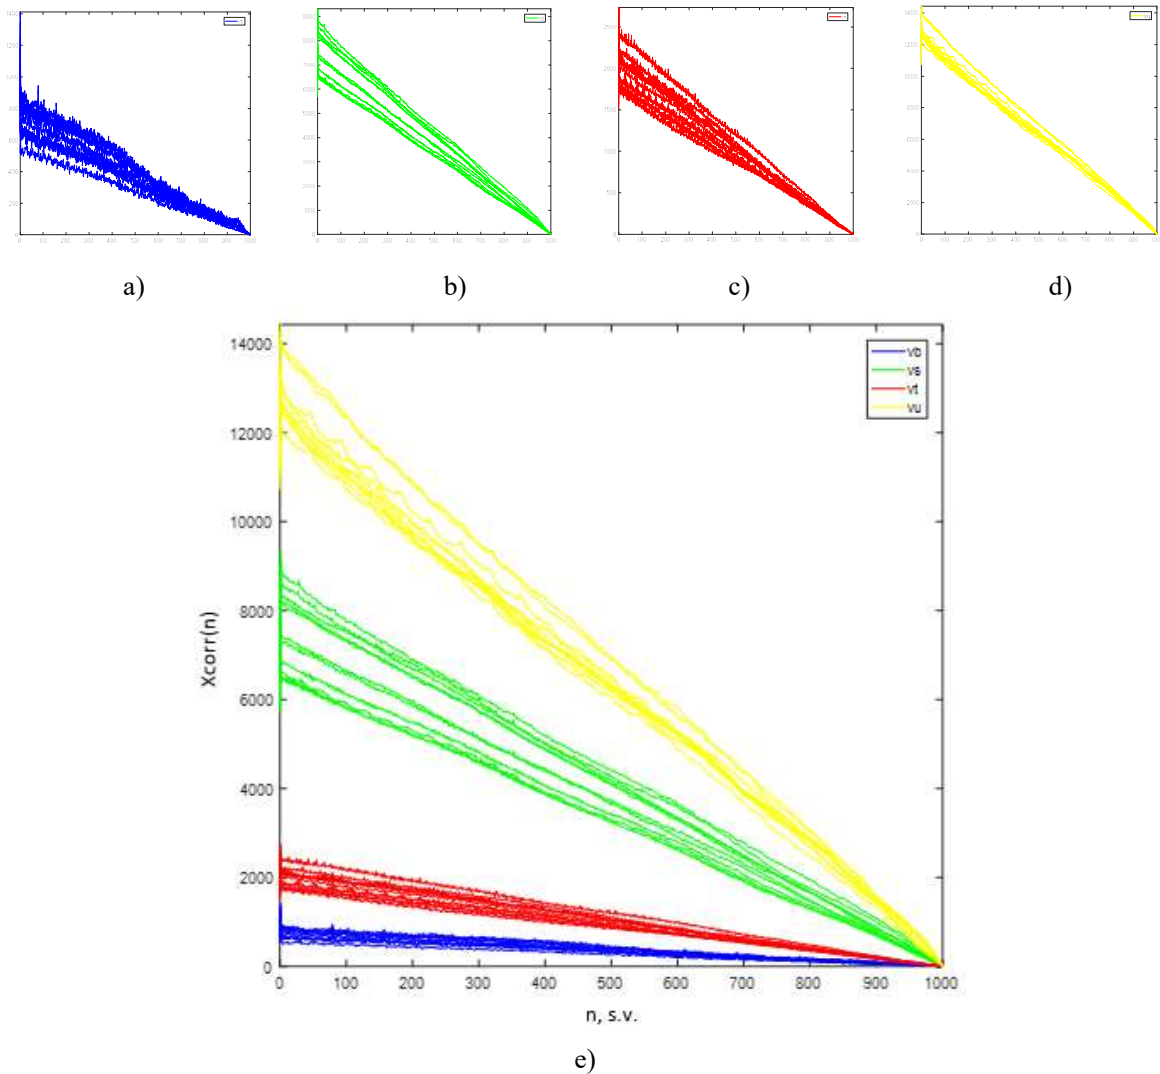
3.16 pav. Garso signalo kreivės gautos po realiosios Kepstro ir FFT transformacijų kombinacijos: a) ašies disbalansas; b) variklis be defektų; c) trumpas jungimas tarp apvijų; d) užteršimas; e) kreivių palyginimas

3.16 paveiksle pateikiamos kreivės gautos po realiosios Kepstro analizės ir FFT panaudojant garso jutikliu gautus duomenis. Kaip matyti iš kreivių 3.16 e paveiksle ašies disbalanso ir trumpojo jungimo tarp variklio apvijų atvejais kreivės yra aiškiai matomos ir atskiriamos. Tai galima teigti apie ašies disbalanso gedimą, kurio kreivės yra 3.16 e paveikslo viršuje. Šios kreivės yra tarpusavyje labai panašios. Tai matoma tiek 3.16 a paveiksle, tiek 3.16 e paveiksle. Ašies disbalanso gedimas yra atskiriamas nuo kitų nuolatinės srovės variklio darbo režimų: variklio be defektų veikimo (3.16 b pav.), trumpo jungimo tarp nuolatinės srovės variklio apvijų (3.16 c pav.) ir užteršimo (3.16 d pav.). Taip pat lengvai atskiriamas trumpasis jungimas (3.16 e pav.). Variklio be defektų darbas ir variklio užteršimas yra sunkiai atskiriami. Galima daryti išvadą, kad tyrimo būdas yra tinkamas nustatyti ašies disbalanso gedimą nuolatinės srovės variklyje ir trumpąjį jungimą tarp apvijų, nes šių gedimų kreivės yra lengvai atskiriamos nuo kitų variklio darbo režimų ir šių gedimų kreivės tarp to paties gedimo yra panašios. Tyrimo būdas yra potencialus ir su juo galima gauti gerus rezultatus. Su šiuo tyrimo būdu bus atliekama daugiau tyrimų darbe ir įvertinamas jo efektyvumas lyginant su kitais diagnostikos būdais. Kaip ir paprastos FFT transformacijos atveju, taip ir FFT kombinacijos su realiąja Kepstro transformacija atveju, ašies disbalanso ir trumpojo jungimo informaciją gerai matoma.



3.17 pav. Srovės signalo kreivės gautos po realiosios Kepstro ir FFT transformacijų kombinacijos: a) ašies disbalansas; b) variklis be defektų; c) trumpas jungimas tarp apvijų; d) užteršimas; e) kreivių palyginimas

3.17 paveiksle pateikiamos kreivės gautos po realiosios Kepstro analizės ir FFT panaudojant duomenis, gautus srovės jutikliu. Kaip matyti iš 3.17 e paveikslo nuolatinės srovės variklio kreivės yra atskiriamos viena nuo kitos. Itin gerai atskiriamas trumpas jungimas, kuris yra 3.17 paveikslo apačioje. Kiti gedimai kertasi tam tikrose vietose, tačiau matoma tendencija, pagal kurią ašies disbalanso, variklio be defektų veikimo ir užteršimo kreivės pasiskirsto (žr. 3.17 pav. atitinkamai iš apačios mėlynos, žalios ir geltonos spalvos kreivės). Iš šiuo tyrimo būdu gautų rezultatų matyti, kad šiuo tyrimo būdu galima lengviausiai atskirti trumpą jungimą tarp apvijų. Šis gedimas atskiriamas nuo įvairių kitų darbo režimų: ašies disbalanso, variklio be defektų veikimo ir užteršimo. Kitų gedimų kreivės yra aiškiai matomos paveikslo viršuje ir yra pasiskirsčiusios tarpusavyje, nors ir persidengia kai kuriose vietose. Galima daryti išvadą, kad toks tyrimo būdas gali būti pritaikytas nustatyti, kada nuolatinės srovės variklyje įvyko trumpas jungimas tarp apvijų bei su ne tokiu aukštu patikimumu galima atskirti ir kitus darbo režimus. Tikėtina, kad galima efektyviai atpažinti visus gedimus imant didesnę signalų imtį ir stebint, kurioje grafiko srityje kreivės atsiranda. Vis dėlto, šis tyrimo būdas yra geresnis trumpo jungimo nustatymui negu kitiems darbo režimams, nes trumpo jungimo kreivės yra lengviau atskiriamos vizualiai lyginant su kitais variklio darbo režimais.



3.18 pav. Vibracijos signalo kreivės gautos po realiosios Kepstro ir FFT transformacijų kombinacijos:
a) ašies disbalansas; b) variklis be defektų; c) trumpas jungimas tarp apvijų; d) užteršimas;
e) kreivių palyginimas

3.18 paveiksle matomos kreivės gautos po realiosios Kepstro analizės ir FFT, kai naudojami vibracijos jutikliu gauti duomenys. 3.18 e paveiksle matoma, kad variklio be defektų veikimo bei gedimų: ašies disbalanso, trumpojo jungimo ir variklio užteršimo kreivės yra lengvai atskiriamos. Lyginant kreivių atvaizdus su kitais prieš tai aptartais gedimų tyrimo būdais vibracijos jutiklio ir realiosios Kepstro bei Furjė transformacijų kombinacija pateikia vienus geresnių rezultatų. Taip galima teigti, nes nėra susikirtimų tarp skirtingų variklio darbo režimų kreivių bei tie patys darbo režimai, atliekant pakartotinius bandymus, turi kreives, kurios yra itin panašios. Tai matyti iš 3.18 a-d paveikslų. Mažesnis skirtumas matomas tik tarp trumpojo jungimo ir ašies disbalanso kreivių, tarp kurių yra ne toks ženklus skirtumas kaip tarp variklio be defektų veikimo ir variklio užteršimo kreivių. Įvertinus grafinę informaciją iš 3.18 paveikslo galima teigti, kad tyrimo būdas yra tinkamas atliekamam tyrimui ir tyrimo būdu gaunama informacija yra aktuali ir gali būti panaudota tolimesniame tyrime bei palyginama su kitais gedimų diagnostikos būdais. Šis gedimų diagnostikos būdas gali būti palyginamas su kitais tyrimo būdais ir įvertinamas jo efektyvumas įvairių gedimų atpažinimui. Tyrimo būdas gerai atskiria visus darbo režimus, tačiau gali būti ne pats tinkamiausias atskirų gedimų atpažinimui. Tačiau, tyrimo būdas yra potencialus ir naudojamas tolimesniame darbe.

Iš grafinės informacijos pateikiamos 3.5 – 3.18 paveiksluose galima daryti tam tikras pirmines išvadas apie būdus, kurie galėtų būti naudingi tiriant gedimus ir juos diagnozuojant. Pagal gautus grafikus pastebėta, kad tam tikri signalų apdorojimo būdai atliekamam tyrimui ir tiriamiems gedimams yra pranašesni už kitus dėl to, kad šių signalų kreivės sutampa tarpusavyje to paties gedimo atveju ir yra skirtingos nuo kitų gedimų taip, kad juos galima lengvai atskirti iš jų kreivių. Kai kurie naudoti tyrimo būdai negalėjo tinkamai atskirti gedimų nuolatinės srovės variklyje. Tai buvo kompleksinė ir realioji Kepstro transformacijos (žr. atitinkamai 3.11 ir 3.12 pav.) bei kompleksinė Kepstro transformacija kartu su greitąja Furjė transformacija (žr. 3.13-15 pav.). Visais jutiklių atvejais Kepstro transformacija be pakartotinos Furjė transformacijos panaudojimo nepateikė aiškių rezultatų, leidžiančių atskirti gedimų kreives. Taip pat tyrimui toliau nenaudojama srovės jutiklio signalo ir greitosios Walsh-Hadamard transformacijos kombinacija (žr. 3.9 pav.).

Galima išskirti kelis pasiteisinusius tyrimo būdus, su kuriais gauti patys geriausi rezultatai: greitosios Furjė transformacijos panaudojimas (žr. 3.5-3.7 pav.), greitosios Walsh-Hadamard transformacijos panaudojimas su garso (žr. 3.8 pav.) ir vibracijų (žr. 3.10 pav.) jutikliais bei realiosios Kepstro transformacijos kartu su greitąja Furjė transformacija panaudojimas (žr. 3.16-3.18 pav.). Šie tyrimo būdai pasiteisino, nes jais gautos kreivės atitiko prieš tai minėtus šiam tyrimui reikalingus tyrimo būdo kokybės kriterijus: kreivės turi būti kaip įmanoma panašesnės tam pačiam gedimui ir kuo daugiau skirtis nuo kitų tiriamo objekto darbo režimų. Minėti būdai šiuos kriterijus atitinka. Vis dėlto, matomi aiškūs skirtumai net tarp to paties tyrimo būdo, kai naudojami skirtingi jutikliai. Pavyzdžiui, naudojant greitąją Furjė transformaciją su garso jutikliu geriausiai aptinkami ašies disbalansas ir trumpasis jungimas tarp variklio apvijų, bet su srovės jutikliu geriausiai matomas yra trumpasis jungimas, o su vibracijų jutikliu – variklio užteršimas ir variklio be defektų darbas. Kito metodo, greitosios Walsh-Hadamard transformacijos atveju, matomi kitokie rezultatai: naudojant garso jutiklį gerai matomi ašies disbalanso ir trumpo jungimo gedimai, srovės jutikliu visi gedimai panašūs ir nėra galima jų atskirti, o naudojant vibracijų jutiklį geriausiai matomi yra variklio užteršimas ir variklio be defektų darbo režimas. Trumpasis jungimas bei variklio ašies disbalansas yra sunkiai atskiriami. Panaudojus realiosios Kepstro transformacijos ir greitosios Furjė transformacijos kombinaciją gauti taip pat kitokie rezultatai: garso jutikliu gauti rezultatai gerai atskiria ašies disbalanso ir trumpo jungimo gedimus nuo kitų darbo režimų, srovės jutikliu gaunami rezultatai leidžia atskirti visus variklio darbo režimus, nors ir ne taip efektyviai kaip kitų būdų atveju. Šio būdo ir srovės jutiklio panaudojimo atveju geriausiai atskiriamas yra trumpasis jungimas, o su vibracijų jutikliu lengvai atskiriami visi variklio darbo režimai, tačiau nėra tokio žymaus skirtumo tarp atskirų darbo režimų kaip kitų būdų atveju, kai kuris nors vienas iš gedimų yra itin gerai atskiriamas nuo kitų. Įvertinant signalų transformavimo būdų efektyvumą taip pat svarbu įvertinti ir jų veikimo greitį. Greičiausiai atliktuose tyrimuose veikė greitosios Furjė transformacijos metodas, antroje vietoje pagal greitį buvo realiosios Kepstro transformacijos ir greitosios Furjė transformacijos metodų kombinacija, o paskutinis pagal greitį iš šių metodų buvo greitosios Walsh-Hadamard transformacijos metodas. Tolimesniame skyriuje gauti rezultatai bus palyginami juos klasifikuojant neuroniniu tinklu ir mašininiais klasifikatoriais. Klasifikavimo algoritmų panaudojimas aktualus norint pasiūlyti automatizuotą diagnostikos sistemą. Taip pat svarbu išrinkti bei pasiūlyti tinkamiausią tyrimo būdų kombinaciją ar tyrimo būdą gedimų diagnostikos uždaviniui.

3.3. Signalų klasifikavimo rezultatai

Atlikus signalų transformavimo uždavinį, naudojant signalų transformavimo metodus, kitas svarbus uždavinys yra gautų rezultatų klasifikavimas. Klasifikavimą galima apibūdinti kaip priemonės, kurias panaudojant galima suskirstyti tam tikrus bruožus turinčius parametrus į atitinkamas grupes, panaudojant įvairius klasifikavimo algoritmus.

Šiame darbe gedimo signalų klasifikavimui panaudojami mašininiai atpažinimo algoritmai: sprendimų medis, pagalbinių vektorių algoritmas (SVM) ir artimiausio kaimyno algoritmas (KNN) (1.4 skyrius). Kiekvienas iš šių mašininų algoritmų taip pat turi atskiras atšakas, kurios skirtingai apskaičiuoja įverčius skirtingiems požymiams. Tyrime panaudotos pagrindinės šių mašininų algoritmų atšakos. Sprendimų medžiai: paprastas, vidutinis ir didelis; pagalbinių vektorių algoritmai: tiesus, kvadratinis, kubinis, paprastas gausinis, vidutinis gausinis ir didelis gausinis; artimiausio kaimyno algoritmai: paprastas, vidutinis, didelis, kosinusinis, kubinis, pasvertas. Visi šie algoritmai buvo apmokinti pasinaudojant „Matlab“ programinės įrangos programiniu paketu „Classification Learner“. Šio paketo pagalba galima apmokinti mašininio mokymosi algoritmus su nurodyta duomenų imtimi. Apmokimui buvo panaudoti 400 duomenų stulpelių, kurių paskutinė eilutė nurodė duomenų paketo klasę. Atlikus apmokinimą, gauti rezultatai buvo įkeliami į „Matlab“ darbinę aplinką ir su apmokintais algoritmais buvo testuojami atskiri duomenų paketai, kuriuose buvo nurodytos tyrimui reikalingos klasės. Testavimo duomenų paketas buvo sudarytas iš 40 stulpelių duomenų. Gauti klasifikavimo tikslumo rezultatai, pagal kuriuos galima įvertinti kaip kiekvienas iš algoritmų yra pajėgus atlikti darbe tiriamą elektros variklio gedimų klasifikavimo uždavinį pagal jutiklių duomenis.

Taip pat atpažinimui ir klasifikavimui buvo panaudotas ir neuroninis tinklas. Šiam uždaviniui atlikti buvo panaudotas „Matlab“ programinės įrangos programinis paketas „nntool“ arba neuroninių tinklų apmokymo įrankis. Tyrime panaudotas tiesioginis neuroninis tinklas su grįžtamuju ryšiu. Panaudoti du neuroninio tinklo sluoksniai – vienas mokymuisi, kitas klasių nustatymui. Mokinimosi neuroniniame tinkle buvo 10 neuronų. Duomenys apmokimui buvo išskaidomi atsitiktine tvarka, o apmokimui panaudotas Levenberg–Marquardt algoritmas. Rezultatų tikslumo įvertinimui panaudotas vidutinių kvadratų metodas, o rezultatų apskaičiavimui panaudotas MEX algoritmas, kuris apskaičiuoja mažiausią įvertį iš duomenų grupės, taip nustatydamas geriausią atpažinimo rezultatą. Apmokintas neuroninis tinklas buvo eksportuotas į „Matlab“ darbalaukį ir su juo atliktas duomenų klasifikavimas. Kaip ir mašininų algoritmų atveju, 400 duomenų stulpelių buvo panaudoti mokymuisi ir 40 atskirų duomenų klasifikavimo tikslumo nustatymui.

Klasifikavimas atliktas su nepakeistais jutiklių duomenimis, taip pat su duomenimis iš 3.2 skyriaus, kai buvo nustatomi perspektyvūs signalų transformavimo būdai. Iš viso panaudoti 3 signalų transformavimo būdai: greitoji Furjė transformacija, realioji Kepstro ir greitoji Furjė transformacija, greitoji Walsh-Hadamard transformacija. Šios transformacijos tirtos su visais jutiklių duomenimis, išskyrus greitąją Walsh-Hadamard transformaciją, kuriai nenaudoti srovės jutiklio duomenys, nes 3.2 skyriuje visos signalų kreivės sutapo ir jos nėra tinkamos klasifikavimui. Klasifikavimo rezultatai skyriaus gale pateikiami lentelių pavidalu, kur matoma kokie mašininio algoritmo ar neuroninio tinklo rezultatai gauti esant atitinkamam signalo tipui: nepakeistas signalas ar signalas transformuotas viena iš anksčiau minėtų trijų signalų transformacijų.

3.3.1. Neuroninio tinklo atpažinimo rezultatai

Pirmiausiai, darbe atliktas įvairių signalų klasifikavimas panaudojant tiesioginį neuroninį tinklą su grįžtamoju ryšiu. Rezultatai gauti su nepakeistais jutikliais: garso, srovės ir vibracijų duomenimis, taip pat su šių signalų transformacijomis, pritaikant FFT, realiąją Kepstro ir FFT bei FWHT transformacijas. Šiame skyriuje rezultatai yra pateikiami atpažinimo matricių (Confusion Matrix) pavidalu. Jose matomi neuroninio tinklo išėjimo klasės rezultatai (Output Class), norimos klasės rezultatai (Target Class). Rezultatai gauti procentine išraiška. Šiose atpažinimo matriciose gedimai skirstomi į 4 atpažinimo atskiras klases: 1 klasė – imituojamas ašies disbalanso gedimas, 2 klasė – variklio be defektų veikimas, 3 klasė – trumpasis jungimas tarp variklio apvijų, 4 klasė – variklis užterštas pašalinėmis medžiagomis.

Confusion Matrix

Output Class	1	5 12.5%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	2 5.0%	8 20.0%	8 20.0%	1 2.5%	42.1% 57.9%
	3	3 7.5%	1 2.5%	2 5.0%	0 0.0%	33.3% 66.7%
	4	0 0.0%	1 2.5%	0 0.0%	9 22.5%	90.0% 10.0%
		50.0% 50.0%	80.0% 20.0%	20.0% 80.0%	90.0% 10.0%	60.0% 40.0%
		Target Class				

a)

Confusion Matrix

Output Class	1	8 20.0%	0 0.0%	1 2.5%	0 0.0%	88.9% 11.1%
	2	0 0.0%	10 25.0%	5 12.5%	9 22.5%	41.7% 58.3%
	3	0 0.0%	0 0.0%	4 10.0%	1 2.5%	80.0% 20.0%
	4	2 5.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
		80.0% 20.0%	100% 0.0%	40.0% 60.0%	0.0% 100%	55.0% 45.0%
		Target Class				

b)


Confusion Matrix

Output Class	1	10 25.0%	0 0.0%	8 20.0%	0 0.0%	55.6% 44.4%
	2	0 0.0%	1 2.5%	0 0.0%	5 12.5%	16.7% 83.3%
	3	0 0.0%	0 0.0%	2 5.0%	0 0.0%	100% 0.0%
	4	0 0.0%	9 22.5%	0 0.0%	5 12.5%	35.7% 64.3%
		100% 0.0%	10.0% 90.0%	20.0% 80.0%	50.0% 50.0%	45.0% 55.0%
		Target Class				

c)

3.19 pav. Garso (a), srovės (b) ir vibracijų (c) jutikliais gautų signalų kreivių atpažinimo tikslumas tiesioginiu neuroniniu tinklu su grįžtamoju ryšiu ir dviem neuroninio tinklo sluoksniais

Pagal 3.19 paveikslo duomenis matyti, kad neuroninis tinklas nėra pajėgus efektyviai atpažinti skirtingų gedimų iš pradinių nepakeistų jutiklio duomenų. Gaunamas atpažinimo tikslumas, kuris garso jutiklio atveju atitinka 60%, srovės jutiklio atveju – 55%, o vibracijų jutiklio atveju 45%.



3.20 pav. Garso (a), srovės (b) ir vibracijų (c) jutikliais ir greitąja Furjė transformacija gautų signalų kreivių atpažinimo tikslumas tiesioginiu neuroniniu tinklu su grįžtamoju ryšiu ir dviem neuroninio tinklo sluoksniais

Panaudojus greitąją Furjė transformaciją 3.20 paveiksle gaunami žymiai geresni rezultatai negu atliekant klasifikavimą su pradiniais jutiklių duomenimis. Garso ir vibracijų jutiklių duomenys pakeisti su greitąja Furjė transformacija yra atpažįstami 100%, o srovės jutiklio duomenys 92,5% tikslumu. Galima teigti, kad greitoji Furjė transformacija efektyviai atpažįsta šiame darbe nagrinėjamus variklio gedimus ir yra pajėgi juos tinkamai klasifikuoti.

	1	2	3	4	
1	10 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	10 25.0%	0 0.0%	6 15.0%	62.5% 37.5%
3	0 0.0%	0 0.0%	8 20.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	2 5.0%	4 10.0%	66.7% 33.3%
	100% 0.0%	100% 0.0%	80.0% 20.0%	40.0% 60.0%	80.0% 20.0%
	1	2	3	4	
	Target Class				

a)

	1	2	3	4	
1	3 7.5%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	7 17.5%	7 17.5%	0 0.0%	0 0.0%	50.0% 50.0%
3	0 0.0%	0 0.0%	10 25.0%	0 0.0%	100% 0.0%
4	0 0.0%	3 7.5%	0 0.0%	10 25.0%	76.9% 23.1%
	30.0% 70.0%	70.0% 30.0%	100% 0.0%	100% 0.0%	75.0% 25.0%
	1	2	3	4	
	Target Class				

b)

	1	2	3	4	
1	10 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	9 22.5%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	10 25.0%	0 0.0%	100% 0.0%
4	0 0.0%	1 2.5%	0 0.0%	10 25.0%	90.9% 9.1%
	100% 0.0%	90.0% 10.0%	100% 0.0%	100% 0.0%	97.5% 2.5%
	1	2	3	4	
	Target Class				

c)

3.21 pav. Garso (a), srovės (b) ir vibracijų (c) jutkliais ir realiaja Kepstro funkcija kartu su greitąja Furjė transformacija gautų signalų kreivių atpažinimo tikslumas tiesioginiu neuroniniu tinklu su grįžtamoju ryšiu ir dviem neuroninio tinklo sluoksniais

Pagal gautus duomenis 3.21 paveiksle matyti, kad realiosios Kepstro transformacijos panaudojimas kartu su greitąja Furjė transformacija neduoda geresnių rezultatų lyginant su FFT. Rezultatai yra prastesni negu greitosios Furjė transformacijos atveju, nors iš kreivių gautų 3.2 skyriuje galima manyti kitaip, nes gaunami didesni skirtumai tarp gedimų kreivių. Realioji Kepstro transformacija kartu su greitąja Furjė transformacija sumažina atpažinimo tikslumą lyginant su FFT. Galima teigti, kad neuroninio tinklo atveju tokio transformavimo būdo naudojimas būtų netikslingas, nes su sudėtingesniu transformavimo būdu yra gaunami prastesni rezultatai.

Output Class	1	2	3	4	
1	10 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	10 25.0%	1 2.5%	1 2.5%	83.3% 16.7%
3	0 0.0%	0 0.0%	9 22.5%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	9 22.5%	100% 0.0%
	100% 0.0%	100% 0.0%	90.0% 10.0%	90.0% 10.0%	95.0% 5.0%
	1	2	3	4	
	Target Class				

a)

Output Class	1	2	3	4	
1	10 25.0%	0 0.0%	1 2.5%	0 0.0%	90.9% 9.1%
2	0 0.0%	10 25.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	9 22.5%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	10 25.0%	100% 0.0%
	100% 0.0%	100% 0.0%	90.0% 10.0%	100% 0.0%	97.5% 2.5%
	1	2	3	4	
	Target Class				

b)

3.22 pav. Garso (a) ir vibracijų (b) jutkliais ir greitąja Walsh-Hadamard transformacija gautų signalų kreivių atpažinimo tikslumas tiesioginiu neuroniniu tinklu su grįžtamoju ryšiu ir dviem neuroninio tinklo sluoksniais

3.22 paveiksle gauti rezultatai su greitąja Walsh-Hadamard transformacija su garso ir vibracijų jutklių duomenimis. Šis transformavimo būdas efektyviai atpažįsta skirtingas gedimo klases, nes gaunamas artimas 100% tikslumas, tačiau nėra toks tikslus kaip tada, kai panaudojama greitoji Furjė transformacija signalų transformavimui.

3.3.2. Klasifikatorių atpažinimo rezultatų palyginimas

Tyrime klasifikavimui taip pat panaudoti mašininio mokymosi algoritmai. Išmėginta didelė įvairovė skirtingų algoritmų su įvairiomis skaičiavimo metodikomis. Išmėginti trijų tipų sprendimų medžio mašininiai algoritmai: paprasto medžio (Fine Tree), vidutinio medžio (Medium Tree) ir didelio medžio (Coarse Tree) metodai. Taip pat išmėginti SVM pagalbinių vektorių ir KNN artimiausio kaimyno mašininiai algoritmai: tiesinis SVM (Linear SVM), kvadratinis SVM (Quadratic SVM), kubinis SVM (Cubic SVM), gausinis SVM (Fine Gaussian SVM), vidutinis gausinis SVM (Medium Gaussian SVM), didelis gausinis SVM (Coarse Gaussian SVM) bei paprastas KNN (Fine KNN), vidutinis KNN (Medium KNN), didelis KNN (Coarse KNN), kosinusinis KNN (Cosine KNN), kubinis KNN (Cubic KNN), įvertintas KNN (Weighted KNN). Visi šie mašininiai algoritmai yra panaudoti garso, srovės ir jutklių vibracijų duomenims klasifikuoti į vieną iš keturių kategorijų: 1 kategorija – variklio ašies disbalanso gedimas, 2 kategorija – variklis be defektų, 3 kategorija – trumpas jungimas tarp variklio apvijų, 4 kategorija – variklio užteršimas pašalinėmis medžiagomis. Šios kategorijos atitinkamai sužymėtos visose lentelėse. Pirmiausiai klasifikavimas atliktas su paprastais jutklių duomenimis be papildomo signalų apdorojimo. Toliau klasifikavimas atliktas su skirtingomis signalų transformacijomis, kurios buvo aptartos 3.2 skyriuje. Rezultatų palyginimui lentelėse taip pat pridėti rezultatai gauti su tiesioginiu dviejų sluoksnių neuroniniu tinklu su grįžtamoju ryšiu. Lentelėse pateikiamas atitinkamo algoritmo apmokinimo laikas, atpažinimo laikas bei atpažinimo tikslumas procentais kiekvienai klasei bei bendras atpažinimo tikslumas.

3.1 lentelė. Garso signalo atpažinimo tikslumas

Metodas	Mokinimo laikas (s)	Atpažinimo laikas (s)	1	2	3	4	Bendras tikslumas
Paprastas medis	10,25	0,0509	40%	60%	40%	30%	42,5%
Vidutinis medis	9,28	0,0494	40%	0%	60%	60%	40,0%
Didelis medis	10,95	0,0638	50%	0%	20%	100%	42,5%
Tiesinis SVM	9,16	0,0641	10%	100%	0%	100%	52,5%
Kvadratinis SVM	8,71	0,0793	0%	100%	0%	100%	50,0%
Kubinis SVM	13,71	0,0757	0%	100%	0%	100%	50,0%
Gausinis SVM	13,45	0,0762	100%	100%	0%	100%	75,0%
Vidutinis gaus. SVM	18,38	0,0665	30%	100%	100%	100%	82,5%
Didelis gausinis SVM	18,21	0,0783	0%	100%	0%	100%	50,0%
Paprastas KNN	4,07	0,0725	10%	100%	0%	60%	42,5%
Vidutinis KNN	4,34	0,0771	0%	100%	0%	50%	37,5%
Didelis KNN	6,54	0,0841	0%	10%	0%	100%	27,5%
Kosinusinis KNN	6,93	0,0759	60%	100%	30%	80%	67,5%
Kubinis KNN	26,84	0,4466	0%	100%	0%	70%	42,5%
Įvertintas KNN	8,78	0,0702	0%	100%	0%	70%	42,5%
Tiesioginis NT su g.r.	297,00	0,0104	50%	80%	20%	90%	60,0%

3.2 lentelė. Srovės signalo atpažinimo tikslumas

Metodas	Mokinimo laikas (s)	Atpažinimo laikas (s)	1	2	3	4	Bendras tikslumas
Paprastas medis	14,20	0,0637	50%	50%	60%	60%	55,0%
Vidutinis medis	12,39	0,0573	50%	70%	60%	60%	60,0%
Didelis medis	15,77	0,0672	40%	100%	60%	0%	50,0%
Tiesinis SVM	15,89	0,0693	30%	80%	40%	0%	37,5%
Kvadratinis SVM	16,97	0,0750	50%	100%	20%	70%	60,0%
Kubinis SVM	22,51	0,0796	40%	100%	0%	60%	50,0%
Gausinis SVM	22,87	0,0858	0%	100%	100%	0%	50,0%
Vidutinis gaus. SVM	30,24	0,0790	70%	100%	100%	100%	92,5%
Didelis gausinis SVM	30,28	0,0799	20%	100%	100%	0%	55,0%
Paprastas KNN	5,80	0,0714	30%	100%	0%	0%	32,5%
Vidutinis KNN	5,35	0,0688	0%	100%	0%	0%	25,0%
Didelis KNN	9,17	0,0961	80%	100%	0%	0%	45,0%
Kosinusinis KNN	8,95	0,0861	100%	30%	0%	100%	57,5%
Kubinis KNN	36,83	0,4490	0%	100%	0%	0%	25,0%
Įvertintas KNN	11,72	0,0926	0%	100%	0%	0%	25,0%
Tiesioginis NT su g.r.	204,00	0,0222	80%	100%	40%	0%	55,0%

3.3 lentelė. Vibracijų signalo atpažinimo tikslumas

Metodas	Mokinimo laikas (s)	Atpažinimo laikas (s)	1	2	3	4	Bendras tikslumas
Paprastas medis	12,84	0,0587	80%	40%	50%	80%	62,5%
Vidutinis medis	11,44	0,0527	80%	40%	30%	80%	57,5%
Didelis medis	13,52	0,0577	100%	40%	0%	90%	57,5%
Tiesinis SVM	11,13	0,0633	100%	0%	100%	100%	75,0%
Kvadratinis SVM	10,53	0,0820	100%	100%	100%	100%	100,0%
Kubinis SVM	15,76	0,0848	100%	100%	100%	100%	100,0%
Gausinis SVM	15,35	0,0829	100%	50%	100%	100%	87,5%
Vidutinis gaus. SVM	20,17	0,0812	100%	100%	100%	100%	100,0%
Didelis gausinis SVM	20,56	0,0805	100%	0%	100%	100%	75,0%
Paprastas KNN	7,29	0,0795	100%	10%	0%	100%	75,0%
Vidutinis KNN	6,85	0,0803	100%	100%	0%	10%	52,5%
Didelis KNN	10,71	0,0806	100%	0%	0%	100%	50,0%
Kosinusinis KNN	10,47	0,0857	100%	100%	0%	0%	50,0%
Kubinis KNN	32,77	0,4387	100%	100%	0%	20%	55,0%
Įvertintas KNN	13,67	0,0778	100%	100%	0%	10%	52,5%
Tiesioginis NT su g.r.	496,00	0,0079	100%	10%	20%	50%	45,0%

Iš gautų klasifikavimo rezultatų su garso, srovės ir vibracijų jutikliais matyti, kad naudotiems klasifikatoriams nėra paprasta atpažinti skirtingas gedimų klases. Didelė dalis mašininio mokymosi algoritmų pasiekia nepatenkinamą atpažinimo tikslumą su garso ir srovės jutikliais. Geriausi rezultatai nepakeistų garso ir vibracijų jutiklių atveju yra gaunami su vidutiniu gausiniu SVM algoritmu, atitinkamai 82,5% ir 92,5%. Tokie rezultatai yra daug geresni už kitus atpažinimo rezultatus 3.1 ir 3.2 lentelėse, tačiau nepasiekia 100% su duota 40 neapdorotų signalų imtimi. Vibracijos signalo atveju gaunami žymiai geresni rezultatai, nes net keli mašininio mokymosi algoritmai buvo pajėgūs pasiekti 100% atpažinimo tikslumą. Tai buvo kvadratinis, kubinis ir vidutinis gausinis SVM. Įdomus yra vidutinio gausinio SVM atvejis. Šis mašininio mokymosi algoritmas geriausiai iš kitų tyrime naudotų klasifikavimo metodų sugeba atpažinti neapdorotus jutiklių duomenis. Todėl esant atvejui, kai jutiklių duomenys nėra pakeičiami ir nėra sudaromi jų spektrai, būtų galima rekomenduoti vidutinio SVM algoritmo panaudojimą.

3.4 lentelė. Garso signalo kreivių atpažinimo tikslumas panaudojus greitąją Furjė transformaciją

Metodas	Mokinimo laikas (s)	Atpažinimo laikas (s)	1	2	3	4	Bendras tikslumas
Paprastas medis	8,81	0,0539	70%	100%	100%	100%	92,5%
Vidutinis medis	8,37	0,0533	70%	100%	100%	100%	92,5%
Didelis medis	9,95	0,0528	70%	100%	100%	100%	92,5%
Tiesinis SVM	7,99	0,0626	100%	90%	100%	100%	97,5%
Kvadratinis SVM	8,31	0,0624	100%	100%	100%	100%	100,0%
Kubinis SVM	11,48	0,0663	100%	100%	100%	100%	100,0%
Gausinis SVM	11,91	0,0703	100%	100%	100%	100%	100,0%
Vidutinis gaus. SVM	15,42	0,0628	100%	100%	100%	100%	100,0%
Didelis gausinis SVM	15,23	0,0644	100%	80%	100%	100%	95,0%
Paprastas KNN	4,12	0,0777	100%	100%	100%	100%	100,0%
Vidutinis KNN	3,78	0,0670	100%	100%	100%	100%	100,0%
Didelis KNN	6,56	0,0682	70%	20%	100%	100%	72,5%
Kosinusinis KNN	6,91	0,0731	100%	100%	100%	100%	100,0%
Kubinis KNN	28,30	0,4512	100%	100%	100%	90%	97,5%
Įvertintas KNN	8,72	0,0836	100%	100%	100%	100%	100,0%
Tiesioginis NT su g.r.	565,00	0,0096	100%	100%	100%	100%	100,0%

3.5 lentelė. Srovės signalo kreivių atpažinimo tikslumas panaudojus greitąją Furjė transformaciją

Metodas	Mokinimo laikas (s)	Atpažinimo laikas (s)	1	2	3	4	Bendras tikslumas
Paprastas medis	8,40	0,0525	80%	100%	100%	10%	72,5%
Vidutinis medis	7,47	0,0565	80%	100%	100%	10%	72,5%
Didelis medis	9,93	0,0524	80%	100%	100%	0%	70,0%
Tiesinis SVM	7,75	0,0699	60%	100%	100%	100%	90,0%
Kvadratinis SVM	7,22	0,0775	70%	100%	100%	100%	92,5%
Kubinis SVM	11,25	0,0658	70%	100%	100%	100%	92,5%
Gausinis SVM	11,02	0,0721	100%	100%	100%	100%	100,0%
Vidutinis gaus. SVM	14,89	0,0732	70%	100%	60%	100%	82,5%
Didelis gausinis SVM	14,73	0,1040	70%	100%	100%	100%	92,5%
Paprastas KNN	4,10	0,0723	80%	100%	100%	80%	90,0%
Vidutinis KNN	3,71	0,0668	10%	100%	100%	20%	57,5%
Didelis KNN	6,60	0,0740	70%	100%	100%	0%	67,5%
Kosinusinis KNN	6,47	0,0935	10%	100%	100%	10%	55,0%
Kubinis KNN	27,27	0,4415	10%	100%	100%	0%	52,5%
Įvertintas KNN	8,68	0,0699	50%	100%	100%	40%	72,5%
Tiesioginis NT su g.r.	695,00	0,0083	70%	100%	100%	100%	92,5%

3.6 lentelė. Vibracijų signalo kreivių atpažinimo tikslumas panaudojus greitąją Furjė transformaciją

Metodas	Mokinimo laikas (s)	Atpažinimo laikas (s)	1	2	3	4	Bendras tikslumas
Paprastas medis	10,23	0,0526	100%	100%	100%	100%	100,0%
Vidutinis medis	8,82	0,0600	100%	100%	100%	100%	100,0%
Didelis medis	10,94	0,0520	100%	100%	100%	100%	100,0%
Tiesinis SVM	9,89	0,0657	100%	100%	100%	100%	100,0%
Kvadratinis SVM	9,33	0,0722	100%	100%	100%	100%	100,0%
Kubinis SVM	13,59	0,0765	100%	100%	100%	100%	100,0%
Gausinis SVM	13,37	0,0784	100%	100%	100%	100%	100,0%
Vidutinis gaus. SVM	17,78	0,0710	100%	100%	100%	100%	100,0%
Didelis gausinis SVM	17,61	0,0679	100%	100%	100%	100%	100,0%
Paprastas KNN	4,70	0,0771	100%	100%	100%	100%	100,0%
Vidutinis KNN	4,85	0,0719	100%	100%	100%	100%	100,0%
Didelis KNN	7,54	0,0706	100%	100%	100%	100%	100,0%
Kosinusinis KNN	7,98	0,0867	100%	80%	100%	100%	95,0%
Kubinis KNN	32,25	0,4733	100%	100%	100%	100%	100,0%
Įvertintas KNN	11,19	0,0817	100%	100%	100%	100%	100,0%
Tiesioginis NT su g.r.	5799,00	0,0085	100%	100%	100%	100%	100,0%

Pagal 3.4-3.6 lentelių duomenis matyti, kad signalo transformacija, panaudojant greitąją Furjė transformaciją, yra efektyvi. Rezultatai, gaunami panaudojus šį signalų transformacijos metodą yra geresni už gautus su nepakeistais signalų duomenimis. Panaudojus Furjė transformaciją dauguma mašininų klasifikatorių yra pajėgūs atpažinti skirtingas gedimų klases elektros variklyje ganėtinai tiksliai. Tai pastebima su visų jutiklių rezultatais. Nepakeistų jutiklių duomenų garso ir srovės jutiklių duomenų nebuvo galima klasifikuoti su 100% tikslumu. Tai matoma 3.1 ir 3.2 lentelėse, tačiau pakeitus šių jutiklių duomenis greitąja Furjė transformacija, tai tapo įmanoma. Vis dėlto, srovės jutiklio duomenis atpažinti 100% tikslumu buvo pajėgus tik vienas mašininio mokymosi algoritmas – vidutinis gausinis SVM. Šis algoritmas kaip ir neapdorotų jutiklio duomenų atveju, pasižymi geromis klasifikavimo galimybėmis. Tai yra matoma taip pat ir su vibracijų jutiklio duomenimis. Šis metodas buvo pajėgus nepakeistus vibracijų jutiklio duomenis atpažinti 100% tikslumu. Vis dėlto, pakeitus vibracijų jutiklio duomenis su greitąja Furjė transformacija atsirado daug kitų mašininio mokymosi algoritmų, kurie yra pajėgūs atpažinti skirtingus gedimus taip pat 100% tikslumu ir veikia sparčiau negu vidutinis gausinis SVM. Tokie pavyzdžiai gali būti sprendimų medžiai, kurių atpažinimo laikas yra trumpesnis lyginant su vidutiniu gausiniu SVM. Atpažinimo laikas yra proporcingas naudojamos kompiuterinės įrangos pajėgumams, todėl senesnei įrangai greitesnis atpažinimo laikas gali būti svarbus, norint realiu laiku atpažinti gedimus. Sprendimų medžiai nepakeistus jutiklių duomenis buvo pajėgūs atpažinti tikslumu, kuris nesiekė net 75% arba 3/4 tikslumo. Tai matoma 3.1, 3.2 ir 3.3 lentelėse. Galima teigti, kad papildoma signalų transformacija ženkliai pagerino atpažinimo rezultatus ir buvo tikslinga.

3.7 lentelė. Garso signalo kreivių atpažinimo tikslumas su realiaja Kepstro ir FFT transformacijomis

Metodas	Mokinimo laikas (s)	Atpažinimo laikas (s)	1	2	3	4	Bendras tikslumas
Paprastas medis	9,32	0,0531	100%	70%	100%	80%	87,5%
Vidutinis medis	8,20	0,0638	100%	70%	100%	80%	87,5%
Didelis medis	10,40	0,0573	100%	90%	100%	100%	97,5%
Tiesinis SVM	7,96	0,0641	100%	80%	100%	80%	90,0%
Kvadratinis SVM	8,22	0,0816	100%	70%	100%	80%	87,5%
Kubinis SVM	11,48	0,0674	100%	80%	100%	90%	92,5%
Gausinis SVM	11,89	0,0811	100%	80%	100%	100%	95,0%
Vidutinis gaus. SVM	15,34	0,0674	100%	80%	100%	90%	92,5%
Didelis gausinis SVM	15,20	0,0661	100%	70%	100%	70%	85,0%
Paprastas KNN	4,24	0,0719	100%	90%	100%	70%	90,0%
Vidutinis KNN	3,79	0,0799	100%	100%	100%	70%	92,5%
Didelis KNN	6,10	0,0721	80%	90%	100%	50%	80,0%
Kosinusinis KNN	6,43	0,0802	100%	90%	100%	60%	87,5%
Kubinis KNN	26,35	0,4565	100%	90%	100%	70%	90,0%
Įvertintas KNN	8,29	0,0743	100%	90%	100%	70%	90,0%
Tiesioginis NT su g.r.	316,00	0,0105	100%	100%	80%	40%	80,0%

3.8 lentelė. Srovės signalo kreivių atpažinimo tikslumas su realiaja Kepstro ir FFT transformacijomis

Metodas	Mokinimo laikas (s)	Atpažinimo laikas (s)	1	2	3	4	Bendras tikslumas
Paprastas medis	9,42	0,0609	80%	20%	100%	100%	75,0%
Vidutinis medis	8,66	0,0520	80%	20%	100%	100%	75,0%
Didelis medis	10,41	0,0515	80%	20%	100%	90%	72,5%
Tiesinis SVM	8,07	0,0680	20%	80%	100%	100%	75,0%
Kvadratinis SVM	7,60	0,0631	80%	90%	100%	90%	90,0%
Kubinis SVM	11,12	0,0682	80%	90%	100%	90%	90,0%
Gausinis SVM	10,90	0,0759	80%	100%	100%	100%	95,0%
Vidutinis gaus. SVM	14,26	0,0729	80%	90%	100%	90%	90,0%
Didelis gausinis SVM	14,66	0,0649	80%	50%	100%	90%	80,0%
Paprastas KNN	4,08	0,0772	60%	100%	100%	100%	90,0%
Vidutinis KNN	3,74	0,0708	80%	100%	100%	80%	90,0%
Didelis KNN	6,65	0,0806	80%	60%	100%	10%	62,5%
Kosinusinis KNN	6,47	0,0787	50%	100%	100%	100%	87,5%
Kubinis KNN	27,31	0,4665	70%	100%	100%	70%	85,0%
Įvertintas KNN	8,73	0,0705	70%	100%	100%	90%	90,0%
Tiesioginis NT su g.r.	475,00	0,0084	30%	70%	100%	100%	75,0%

3.9 lentelė. Vibracijų signalo kreivių atpažinimo tikslumas su realiaja Kepstro ir FFT transformacijomis

Metodas	Mokinimo laikas (s)	Atpažinimo laikas (s)	1	2	3	4	Bendras tikslumas
Paprastas medis	7,53	0,0517	100%	100%	100%	100%	100,0%
Vidutinis medis	7,36	0,0520	100%	100%	100%	100%	100,0%
Didelis medis	7,95	0,0578	100%	100%	100%	100%	100,0%
Tiesinis SVM	8,03	0,0606	100%	100%	100%	100%	100,0%
Kvadratinis SVM	8,31	0,0627	100%	100%	100%	100%	100,0%
Kubinis SVM	11,12	0,0638	100%	100%	100%	100%	100,0%
Gausinis SVM	10,94	0,0667	100%	100%	100%	100%	100,0%
Vidutinis gaus. SVM	14,44	0,0665	100%	100%	100%	100%	100,0%
Didelis gausinis SVM	14,29	0,0734	100%	100%	100%	100%	100,0%
Paprastas KNN	4,10	0,0700	100%	100%	100%	100%	100,0%
Vidutinis KNN	3,75	0,0757	100%	100%	100%	100%	100,0%
Didelis KNN	6,54	0,0867	100%	100%	100%	100%	100,0%
Kosinusinis KNN	6,97	0,0816	100%	50%	100%	100%	87,5%
Kubinis KNN	26,35	0,4571	100%	100%	100%	100%	100,0%
Įvertintas KNN	9,30	0,0797	100%	100%	100%	100%	100,0%
Tiesioginis NT su g.r.	676,00	0,0114	100%	90%	100%	100%	97,5%

Iš rezultatų pateikiamų 3.7-3.9 lentelėse matyti, kad realiosios Kepstro transformacijos panaudojimas kartu su greitąja Furjė transformacija duoda gerus rezultatus atpažįstant įvairias gedimų klases. Vis dėlto, gaunami atpažinimo rezultatai yra ženkliai prastesni negu atveju, kai buvo naudojama tik greitoji Furjė transformacija. Pirmiausiai, su šiuo signalo transformacijos būdu, naudojant garso ir srovės jutiklių duomenis nebuvo galimybės gauti 100% atpažinimo rezultatų. Kai kuriems atpažinimo algoritams duomenys pakeisti realiosios Kepstro transformacijos ir greitos Furjė transformacijos buvo tinkamesni, nes gauti geresni atpažinimo rezultatai, ką galima pamatyti lyginant 3.4-3.6 lentelių duomenis su 3.7-3.9 lentelių duomenimis. Tačiau, įvertinant šių lentelių duomenis bendrai galima teigti, kad realiosios Kepstro transformacijos panaudojimas kaip papildomo transformacijos metodo efektyvumas nėra ženklus ir net pablogina klasifikavimo rezultatus. To nebūtų galima teigti iš pradinių signalo kreivių, gautų po signalų transformavimo. Tai matyti 3.16, 3.17 ir 3.18 paveikslus lyginant su 3.5, 3.6 ir 3.7 paveikslais, kurie buvo gauti su greitąja Furjė transformacija. Iš gautų signalų kreivių būtų galima daryti prielaidą, kad geriau turėtų būti atpažįstami duomenys, pakeisti realiosios Kepstro transformacijos kartu su greitąja Furjė transformacija. Tokiu atveju kreivės yra labiau išsidėsčiusios grafikų plotmėje ir turėtų teikti geresnius klasifikavimo rezultatus. Vis dėlto, rezultatas gaunamas kitoks ir greitoji Furjė transformacija yra efektyvesnis signalų transformavimo būdas kartu su tyrime panaudotais klasifikatoriais. Todėl galima manyti, kad papildomai naudoti realiąją Kepstro transformaciją yra netikslinga.

3.10 lentelė. Garso signalo kreivių atpažinimo tikslumas su greitąja Walsh-Hadamard transformacija

Metodas	Mokinimo laikas (s)	Atpažinimo laikas (s)	1	2	3	4	Bendras tikslumas
Paprastas medis	11,61	0,0520	100%	90%	100%	90%	95,0%
Vidutinis medis	10,40	0,0523	100%	90%	100%	90%	95,0%
Didelis medis	12,42	0,0615	100%	90%	100%	100%	97,5%
Tiesinis SVM	8,84	0,0664	100%	100%	100%	90%	97,5%
Kvadratinis SVM	8,33	0,0703	100%	100%	100%	90%	97,5%
Kubinis SVM	12,62	0,0751	100%	100%	100%	90%	97,5%
Gausinis SVM	12,42	0,0833	100%	100%	90%	50%	85,0%
Vidutinis gaus. SVM	16,33	0,0635	100%	100%	100%	90%	97,5%
Didelis gausinis SVM	16,18	0,0706	100%	100%	100%	70%	92,5%
Paprastas KNN	4,85	0,0654	100%	90%	100%	40%	82,5%
Vidutinis KNN	4,41	0,0703	100%	100%	100%	90%	97,5%
Didelis KNN	7,62	0,0757	100%	40%	100%	70%	77,5%
Kosinusinis KNN	7,46	0,0778	100%	60%	90%	100%	87,5%
Kubinis KNN	30,84	0,4470	100%	100%	100%	90%	97,5%
Įvertintas KNN	9,75	0,0658	100%	100%	100%	100%	100,0%
Tiesioginis NT su g.r.	296,00	0,0111	100%	100%	90%	90%	95,0%

3.11 lentelė. Vibracijų signalo kreivių atpažinimo tikslumas su greitąja Walsh-Hadamard transformacija

Metodas	Mokinimo laikas (s)	Atpažinimo laikas (s)	1	2	3	4	Bendras tikslumas
Paprastas medis	10,15	0,0508	100%	90%	100%	100%	97,5%
Vidutinis medis	8,86	0,0609	100%	90%	100%	100%	97,5%
Didelis medis	10,89	0,0511	100%	90%	100%	100%	97,5%
Tiesinis SVM	10,10	0,0692	100%	50%	100%	100%	87,5%
Kvadratinis SVM	9,36	0,0725	100%	100%	100%	100%	100,0%
Kubinis SVM	13,10	0,0695	100%	90%	100%	100%	97,5%
Gausinis SVM	12,87	0,0815	100%	100%	100%	100%	100,0%
Vidutinis gaus. SVM	17,35	0,0730	100%	80%	100%	100%	95,0%
Didelis gausinis SVM	17,13	0,0739	100%	50%	100%	100%	87,5%
Paprastas KNN	5,18	0,0901	100%	100%	100%	100%	100,0%
Vidutinis KNN	4,78	0,0811	100%	50%	100%	100%	87,5%
Didelis KNN	8,10	0,0731	100%	40%	100%	100%	85,0%
Kosinusinis KNN	7,85	0,0827	100%	90%	90%	100%	95,0%
Kubinis KNN	31,18	0,4814	100%	50%	100%	100%	87,5%
Įvertintas KNN	11,09	0,0709	100%	90%	100%	100%	97,5%
Tiesioginis NT su g.r.	1637,00	0,0095	100%	100%	90%	100%	97,5%

Rezultatai pateikiami 3.10 ir 3.11 lentelėse atitinka rezultatus, gautus su greitąja Walsh-Hadamard transformacija ir naudotais klasifikatoriais. Matyti, kad šis signalų transformavimo metodas yra efektyvus ir su šiuo metodu galima gauti gerus klasifikavimo rezultatus. Vis dėlto, šie rezultatai nėra tokie efektyvūs kaip greitosios Furjė transformacijos atveju. Kai kuriais atvejais greitosios Walsh-Hadamard būdas pateikia efektyvesnius klasifikavimo rezultatus kartu su naudotais klasifikatoriais. Tai matyti 3.10 lentelėje su garso jutikliu, kai, pavyzdžiui, spendimų medžių algoritmai pateikia geresnius klasifikavimo rezultatus negu 3.4 lentelėje. Vis dėlto, vibracijų jutiklio klasifikavimo rezultatai gaunami neefektyvūs lyginant su greitosios Furjė transformacijos duomenimis, realiosios Kepstro ir greitosios Furjė transformacijos duomenimis. Todėl galima manyti, kad kai kuriais atvejais greitoji Walsh-Hadamard transformacija yra efektyvi, bet yra ne tokia efektyvi kaip greitoji Furjė transformacija.

Taip pat greitoji Furjė transformacija yra greičiausias iš trijų tirtų signalų transformacijos metodų ir kartu su kai kuriais klasifikatoriais gali pateikti pačius tiksliausius ir greičiausius klasifikavimo rezultatus. Kai kurie mašininio mokymosi algoritmai yra pajėgūs efektyviai atpažinti ir nepakeistus jutiklių duomenis, tačiau toks atpažinimo būdas nebūtinai yra pats greičiausias, nes greitoji Furjė transformacija atliekama per 10^{-5} laipsnio sekundės dalis, autokoreliacija atliekama taip pat per 10^{-5} laipsnio sekundės dalis ir didžioji dalis laiko yra panaudojama klasifikavimui, kuris atliekamas per 10^{-2} laipsnio sekundės dalis. Be to, nepakeistų duomenų tikslus atpažinimas pagal gautus rezultatus yra galimas tik vibracijų jutiklių duomenims, jei gedimų atpažinimui naudojami garso arba srovės jutiklių duomenys, tai jų efektyviam klasifikavimui papildoma signalo transformacija yra būtina, norint gauti efektyvius klasifikavimo rezultatus ir tinkamai atlikti klasifikavimo ir gedimų atpažinimo uždavinį.

Išvados ir rezultatai

Pagal gautus tyrimo rezultatus galima daryti išvadas apie gedimų signalus ir jų klasifikavimą:

1. Visų trijų tipų panaudoti jutikliai: garso, srovės ir vibracijų pateikia signalus, kuriuos transformavus gauti diagnostikai tinkami klasifikavimo rezultatai.
2. Tyrime nustatyta, kad efektyviausias signalų transformacijos metodas buvo greitoji Furjė transformacija, nes šios transformacijos gautų rezultatų klasifikavimas buvo efektyvus su visų trijų tipų jutiklių duomenimis ir didžiausias kiekis naudotų klasifikatorių buvo pajėgūs pasiekti 100% atpažinimo tikslumą (400 duomenų apmokinimui, 40 testavimui). Greitosios Furjė transformacijos efektyviausio klasifikatoriaus klasifikavimo rezultatai lyginant su kitų tyrimo būdų efektyviausiu klasifikavimo algoritmu:
 - a) garso jutiklio duomenims – +17,5% lyginant su netransformuotu signalu; +2,5% lyginant su realiąja Kepstro ir greitąja Furjė transformacija; lygus rezultatas su greitąja Walsh-Hadamard transformacija;
 - b) srovės jutiklio duomenims - +7,5% lyginant su netransformuotu signalu; +5% lyginant su realiąja Kepstro ir greitąja Furjė transformacija; greitoji Walsh-Hadamard transformacija buvo netinkama klasifikuoti, nes transformuoti signalai neparodė ženklų skirtumų tarpusavyje;
 - c) vibracijos jutiklio duomenims – visi tyrimo metodai turėjo bent po porą klasifikatorių, kurie pasiekė 100% atpažinimo tikslumą, bet sparčiausiai veikiantis klasifikatorius panaudotas tyrime buvo tiesioginis neuroninis tinklas su grįžtamuju ryšiu (0,0085 s FFT rezultatas), kuris pajėgė klasifikuoti 100% tikslumu tik naudojant greitąją Furjė transformaciją.
3. Tyrime nustatyta, kad nepakeistiems jutiklio duomenims efektyviausias yra vidutinis gausinis SVM klasifikatorius: 82,5% tikslumas garso jutiklio duomenims, 92,5% tikslumas srovės jutiklio duomenims, 100 % tikslumas vibracijos jutiklio duomenims. Tačiau šis klasifikatorius nėra greičiausias ir ženkliai atsilieka nuo greičiausio klasifikavimo metodo – tiesioginio neuroninio tinklo su grįžtamuju ryšiu: +0,0727 s lyginant nepakeistus vibracijos jutiklio duomenis klasifikuojamus vidutiniu gausiniu SVM su vibracijos jutiklio duomenimis pakeistais greitąja Furjė transformacija ir klasifikuojamais tiesioginiu neuroniniu tinklu su grįžtamuju ryšiu.
4. Mašininio mokymosi algoritmai ir tiesioginis neuroninis tinklas su grįžtamuju ryšiu pateikia efektyvesnius klasifikavimo rezultatus po signalo transformacijos.
5. Atlikus tyrimą nustatyta, kad efektyviausia tyrimo sistema, kurią būtų galima panaudoti gedimų atpažinimui ir klasifikavimui pagal gautus rezultatus būtų su vibracijos jutikliu, kurio duomenys būtų pakeičiami greitąja Furjė transformacija ir klasifikuojami su tiesioginiu neuroniniu tinklu su grįžtamuju ryšiu. Vis dėlto, jei norima duomenis klasifikuoti be papildomos signalo transformacijos tai efektyviausia sistema būtų su vibracijos jutikliu ir vidutinio gausinio SVM mašininio mokymosi klasifikatoriumi. Tokios sistemos atpažinimo greitis būtų 0,0727 s lėtesnis už aukščiau siūlomą sistemą, bet tikslumas prilygtų greitajai Furjė transformacijai.

Literatūros sąrašas

1. LabVolt, “Permanent Magnet DC Motor”, 2014 m.,
http://web.csulb.edu/~lrodrig/testEquip/labvolt/Permanent_Magnet_DC_Motor.pdf
2. Alvaro Jose Bazurto, Enrique C. Quispe, Rosaura DEL PILAR Castrillon, “Causes and failures classification of industrial electric motor”, Universidad del Valle, Kolumbija, 2016 m.,
<https://ieeexplore.ieee.org/document/7836190>
3. Stijn Derammelaere , Michiel Haemers , Jasper De Viaene , Florian Verbelen , Kurt Stockman, „A quantitative comparison between BLDC, PMSM, Brushed DC and Stepping Motor Technologies”, Ghent University, Belgija, 2016 m., <https://ieeexplore.ieee.org/document/7837471>
4. U.S. Department of Energy, “Improving Motor and Drive System Performance”, 2014 m., https://www.energy.gov/sites/prod/files/2014/04/f15/amo_motors_sourcebook_web.pdf
5. K. Mahesh Kumar, A.Krishnaveni, D. Edison Selvaraj, T. Gunasekaran, P.Manikandan, Lieutenant. J.Ganesan, “A Review on Maintenance and Troubleshooting of DC Machines”, Sethu Institute of Technology, P.S.R Engineering College, Panimalar Engineering College, Sree Sowdambika College of Engineering, Indija, 2016 m.,
https://www.researchgate.net/publication/334783780_A_Review_on_Maintenance_and_Troubleshooting_of_DC_Machines
6. Meinard Müller, “The Fourier Transform in a Nutshell”, Friedrich-Alexander-University of Erlangen-Nürnberg, Vokietija, 2015 m.,
https://www.researchgate.net/publication/290440858_The_Fourier_Transform_in_a_Nutshell
7. Pouyan Ebrahimbabaie, “Correlation of signals”, MATLAB tutorial series, 1.2 dalis, University of Liège, Belgija, 2019 m.,
http://www.montefiore.ulg.ac.be/~ebrahimbabaie/applieddigital_fichiers/TPS/TP1/Final/Slides/Correlation%20of%20signals.pdf
8. Trieu Quang Huy, “Fault Detection and Prediction In Elevators Using FFT-Based Features”, Tampere University, Suomija, 2019 m.,
<https://trepo.tuni.fi/bitstream/handle/10024/116305/TrieuQuangHuy.pdf?sequence=4&isAllowed=y>
9. Jing Zhou, Yong Qin, Linlin Kou, Mitchell Yuwono, “Fault detection of rolling bearing based on FFT and classification”, University of Technology Sydney, Beijing Jiaotong University, 2015 m.,
https://www.researchgate.net/publication/283156328_Fault_detection_of_rolling_bearing_based_on_FFT_and_classification
10. Peter J. Olver, “Topics in Fourier Analysis: DFT & FFT, Wavelets, Laplace Transform”, University of Minnesota, JAV, 2018 m., http://www-users.math.umn.edu/~olver/ln_fal.pdf
11. Robert B.Randall, “A history of cepstrum analysis and its application to mechanical problems”, University of New South Wales, Australija, 2016 m.,
<https://www.sciencedirect.com/science/article/pii/S0888327016305556>
12. Kiran Vernekar, Hemantha Kumar, K. V. Gangadharan, „Fault Detection of Gear Using Spectrum and Cepstrum Analysis”, NITK, Indija, 2015 m.,
https://www.insa.nic.in/writereaddata/UpLoadedFiles/PINSA/Vol81_2015_4_Art01.pdf
13. Katariina Mahkonen, “Cepstrum”, SGN-14006 Audio and Speech Processing, 2013 m.,
<http://www.cs.tut.fi/~sgn14006/PDF2015/S04-cepstrum.pdf>
14. Vipul K. Dave, Vinay Vakharia, Sukhjeet Singh, “Ball Bearing Fault Diagnosis Using Mutual Information and Walsh–Hadamard Transform”, “Reliability, Safety and Hazard Assessment for Risk-Based Technologies”, Proceedings of ICRESH 2019, 2019 m.,
<https://link.springer.com/content/pdf/10.1007%2F978-981-13-9008-1.pdf>

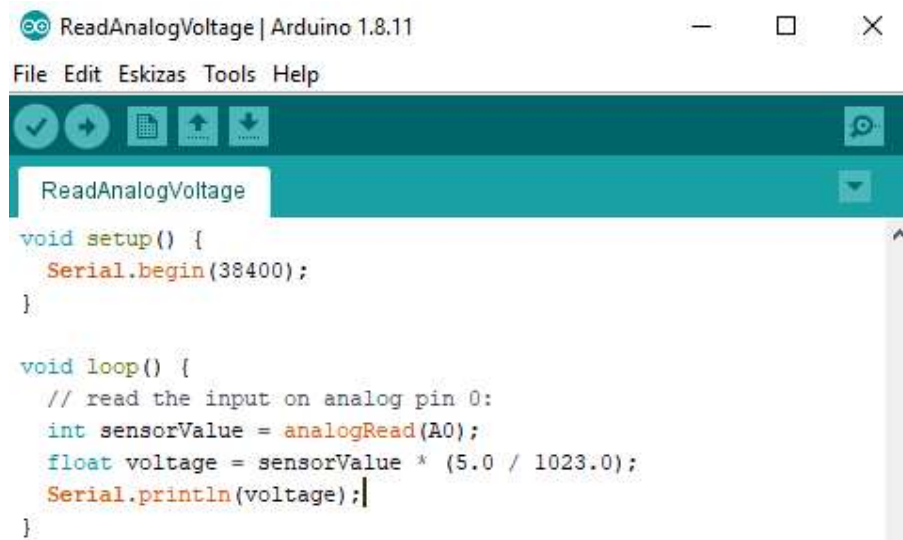
15. Tomasz Golonek, Jan Machniewski, “Analog Circuit Specification Testing by Means of Walsh–Hadamard Transform and Multiple Regression Supported by Evolutionary Computations”, Silesian University of Technology, Lenkija, 2017 m.,
<https://link.springer.com/content/pdf/10.1007%2Fs00034-017-0708-1.pdf>
16. Jordan McBain, Markus Timusk, “Cross Correlation for Condition Monitoring of Variable Load and Speed Gearboxes”, Journal of Industrial Mathematics, 2014 m.,
<https://www.hindawi.com/journals/jim/2014/543056/>
17. Mădălina Dumitriu, “Fault detection of damper in railway vehicle suspension based on the cross-correlation analysis of bogie accelerations”, UPB, Rumunija, 2018 m.,
<https://search.proquest.com/openview/91b3e1d785c0872cc00b8c9d2193e751/1?pq-origsite=gscholar&cbl=1586340>
18. Imperial College London, “Fourier Series and Transforms”, 8 skyrius, “Koreliacija”, Imperial College London, Jungtinė Karalystė, 2015 m.,
http://www.ee.ic.ac.uk/hp/staff/dmb/courses/E1Fourier/00800_Correlation.pdf
19. Hardik H. Rava, Aakash M. Kubavat, “Condition Monitoring of DC Motor using Artificial Intelligence Technique”, G.E.C, Indija, 2013 m.,
https://www.academia.edu/6801444/Condition_Monitoring_of_DC_Motor_using_Artificial_Intelligence_Technique
20. Rodrigo H. Cunha Palácios, Ivan Nunes da Silva, Alessandro Goedtel, Wagner F. Godoy, “A comprehensive evaluation of intelligent classifiers for fault identification in three-phase induction motors”, University of São Paulo, Federal Technological University of Paraná, Brazilija, 2015 m., <https://www.sciencedirect.com/science/article/pii/S0378779615001832>
21. Adrienn Dineva, Amir Mosavi, Mate Gyimesi, Istvan Vajda, Narjes Nabipour, Timon Rabczuk, “Fault Diagnosis of Rotating Electrical Machines Using Multi-Label Classification”, Obuda University, Bauhaus Universität-Weimar, Duy Tan University, King Saud University, Vengrija, Vokietija, Vietnamas, Saudo Arabija, 2019 m.,
https://www.researchgate.net/publication/337496980_Fault_Diagnosis_of_Rotating_Electrical_Machines_Using_Multi-Label_Classification
22. Ndeye Lo, Jean-Marie Flaus, Olivier Adrot, „Review of Machine Learning Approaches In Fault Diagnosis applied to IoT System”, International Conference on Control, Automation and Diagnosis ICCAD’19, Jul 2019, Grenoblis, Prancūzija, 2019 m., <https://hal.archives-ouvertes.fr/hal-02344344>
23. Marcel Jung, Octavian Niculita, Zakwan Skaf, “Comparison of Different Classification Algorithms for Fault Detection and Fault Isolation in Complex Systems”, 6th International Conference on Through-life Engineering Services, TESConf 2017, 7-8 November 2017, Bremenas, Vokietija, 2017 m., <https://www.sciencedirect.com/science/article/pii/S2351978918300167>

24. Kalpesh J. Chudasama, Vipul Shah, “Noninvasive External Faults Detection of Induction Motor using Feedforward Neural Network”, Gujarat Technological University, Gujaratas, Indija, 2013 m., <http://inpressco.com/noninvasive-external-faults-detection-of-induction-motor-using-feedforward-neural-network/>
25. Mehmet Simsir, Raif Bayir, Yilmaz Uyaroglu, “Real-Time Monitoring and Fault Diagnosis of a Low Power Hub Motor Using Feedforward Neural Network”, Sakarya University, Karabuk University, Turkija, 2016 m., <https://www.hindawi.com/journals/cin/2016/7129376/>
26. Shaina Grover, Amandeep Sharma, Lini Mathew, Shantanu Chatterji, “Induction Motor Fault Classification using Pattern Recognition Neural Network”, NITTTTR Chandigarh, Indija, 2019 m., <https://www.ijitee.org/wp-content/uploads/papers/v8i9/I7591078919.pdf>
27. T Praveenkumar, M Saimurugan, K I Ramachandran, “Comparison of Vibration, Sound and Motor Current Signature Analysis for Detection of Gear Box Faults”, Amrita School of Engineering Coimbatore”, Indija, 2017 m., <https://pdfs.semanticscholar.org/0ae2/95bd629a05d230018c33d5cab58cf226f431.pdf>
28. Dubravko Miljković, “Brief Review of Motor Current Signature Analysis”, HEP, Kroatija, 2015 m., https://www.researchgate.net/publication/304094187_Brief_Review_of_Motor_Current_Signature_Analysis
29. Mariana Iorgulescu, Robert Beloiu, “Study of DC Motor Diagnosis Based on the Vibration Spectrum and Current Analysis”, University of Pitesti, Rumunija, 2012 m., <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6403430>
30. Abe Michelen, “DC Motor Calculations—Part 1”, Electronics 360, 2017 m., <https://electronics360.globalspec.com/article/8631/dc-motor-calculations-part-1>
31. Bravo-Imaz, Hossein Davari Ardakani, Zongchang Liu, Alfredo García-Arribas, Aitor Arnaiz, Jay Lee, “Motor current signature analysis for gearbox condition monitoring under transient speeds using wavelet analysis and dual-level time synchronous averaging”, University of Cincinnati, JAV, 2017 m., <https://reader.elsevier.com/reader/sd/pii/S0888327017300791?token=6FC8A0A4CF7AF57240293F1A8A7BCDEA70F2CA354D6A6AD90EF58608801D3C19F370B04D8C3D3866CDF5A7E26E05261F>
32. Dingguo Lu, Wei Qiao, Xiang Gong, „Current-Based Gear Fault Detection for Wind Turbine Gearboxes”, IEEE Transactions on Sustainable Energy, 8 tomas, 4 numeris, 2017 m., <https://ieeexplore.ieee.org/document/7892035>
33. A. Roque, J. M. F. Calado, J.M. Ruiz, “Vibration Analysis versus Current Signature Analysis”, Polytechnic Institute of Lisbon, Portugalija, 2012 m., <https://reader.elsevier.com/reader/sd/pii/S1474667016348522?token=EF944227F38F2483FEC68F960C875B197FA6CA1D8FB11C63A8EF1360D0644A4BBB1CF9AC54BCF8755867D35323F95FDA>
34. Elprocus, “ACS712 Current Sensor Working and Applications”, 2019 m., <https://www.elprocus.com/acs712-current-sensor-working-and-applications/>
35. Patrick N. Breysse, Peter S.J. Lees, “Noise”, Johns Hopkins University, JAV, 2006 m., <http://ocw.jhsph.edu/courses/PrinciplesIndustrialHygiene/PDFs/Lecture6.pdf>
36. Pramod Sharma, Neelam Saraswat, “Diagnosis of Motor Faults Using Sound Signature Analysis”, RBS Engineering Technical Campus, Indija, 2015 m., <https://www.ijireeice.com/upload/2015/may-15/IJIREEICE%2024.pdf>

37. Maciej Orman, Cajetan T. Pinto, "Acoustic analysis of electric motors in noisy industrial environment", ABB Corporate Research Center, Kinija, 2013 m.,
https://www.researchgate.net/publication/286273695_Acoustic_analysis_of_electric_motors_in_noisy_industrial_environment
38. Paulo Antonio, Delgado-Arredondo, Daniel Morinigo-Sotelo, Roque Alfredo Osornio-Rios, Juan Gabriel Avina-Cervantes, Horacio Rostro-Gonzalez, Rene de Jesus Romero-Troncoso, "Methodology for fault detection in induction motors via sound and vibration signals", Universidad de Guanajuato, University of Valladolid, Universidad Autonoma de Queretaro, Meksika, Ispanija, 2017 m., <https://www.sciencedirect.com/science/article/pii/S0888327016302151>
39. Adam Glowacz, "Fault diagnostics of DC motor using acoustic signals and MSAF-RATIO30-EXPANDED", AGH University of Science and Technology, Lenkija, 2016 m.,
<https://www.degruyter.com/downloadpdf/j/ae.2016.65.issue-4/ae.2016-0051/ae.2016-0051.pdf>
40. Siju K. Abraham, V. Sugumaran, M. Amarnath, "Acoustic Signal Based Condition Monitoring of Gearbox using Wavelets and Decision Tree Classifier", VIT University, Indian Institute of Information Technology Design and Manufacturing Jabalpur, Indija, 2016 m.,
<https://pdfs.semanticscholar.org/21a4/d18214832f5922136ac6303894be4a9bbbf7.pdf>
41. Bhushan patil, Sagar hadape, Abhijit kesarkar, "Motor Fault Detection Using Sounds Signals Analysis in DC Motor", DY Patil Knowledge City, Indija, 2017 m.,
http://ijariie.com/AdminUploadPdf/MOTOR_FAULT_DETECTION_USING_SOUNDS_SIGNALS_ANALYSIS_IN_DC_MOTOR_ijariie5384.pdf
42. Yong Thung Cho, "Characterizing Sources of Small DC Motor Noise and Vibration", Kongju National University, Pietų Korėja, 2018 m.,
<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6187501/>
43. Boštjan Dolenc, Pavle Boškosi, Đani Juričić, "Distributed bearing fault diagnosis based on vibration analysis", Jožef Stefan Institute, Liubliana, Slovėnija, 2016 m.,
<https://reader.elsevier.com/reader/sd/pii/S0888327015002939?token=F1E3E70AC6FAE04DA44ACADED29EBA463C6BF1437488AB66694BFF40C238F551A7E5F9611C2BEDE2E6C9C83E4AD55D5D>
44. Adam Glowacz, Witold Glowacz, "Vibration-Based Fault Diagnosis of Commutator Motor", AGH University of Science and Technology, Krokua, Lenkija, 2018 m.,
<https://www.hindawi.com/journals/sv/2018/7460419/>
45. Sadykov Ravil, "Asinchronio variklio mechaninių ir elektrinių virpesių tyrimas ir taikymas", magistro darbas, 54 psl., KTU, Kaunas, Lietuva, 2015 m.
46. Engineering Libre Texts, "Piezoelectricity", 2019 m.,
[https://eng.libretexts.org/Bookshelves/Materials_Science/Supplemental_Modules_\(Materials_Science\)/Electronic_Properties/Piezoelectricity](https://eng.libretexts.org/Bookshelves/Materials_Science/Supplemental_Modules_(Materials_Science)/Electronic_Properties/Piezoelectricity)
47. Mikrovaldiklio plokštė Arduino Uno, https://www.lemona.lt/?page=item&i_id=173054
48. Variklis Redox, <https://www.anodas.lt/variklis-redox-dc-12v-12000rpm?search=dc%20variklis&page=2>

Priedai

1 Arduino programinis kodas įtampos nuskaitymui

The image shows a screenshot of the Arduino IDE interface. The window title is "ReadAnalogVoltage | Arduino 1.8.11". The menu bar includes "File", "Edit", "Eskizas", "Tools", and "Help". Below the menu bar is a toolbar with icons for saving, running, uploading, and downloading. The main editor area shows the following C++ code:

```
void setup() {  
  Serial.begin(38400);  
}  
  
void loop() {  
  // read the input on analog pin 0:  
  int sensorValue = analogRead(A0);  
  float voltage = sensorValue * (5.0 / 1023.0);  
  Serial.println(voltage);  
}
```

0.1 pav. Arduino programinis kodas, naudotas analoginio išėjimo fiksavimui

2 Signalų transformacijų programinis kodas

```
fft_code.m x +          fft_code.m x +
1 - x1=abs(fft(vb1));    21 - x21=abs(fft(vt1));
2 - x2=abs(fft(vb2));    22 - x22=abs(fft(vt2));
3 - x3=abs(fft(vb3));    23 - x23=abs(fft(vt3));
4 - x4=abs(fft(vb4));    24 - x24=abs(fft(vt4));
5 - x5=abs(fft(vb5));    25 - x25=abs(fft(vt5));
6 - x6=abs(fft(vb6));    26 - x26=abs(fft(vt6));
7 - x7=abs(fft(vb7));    27 - x27=abs(fft(vt7));
8 - x8=abs(fft(vb8));    28 - x28=abs(fft(vt8));
9 - x9=abs(fft(vb9));    29 - x29=abs(fft(vt9));
10 - x10=abs(fft(vb10)); 30 - x30=abs(fft(vt10));
11 - x11=abs(fft(vs1));  31 - x31=abs(fft(vu1));
12 - x12=abs(fft(vs2));  32 - x32=abs(fft(vu2));
13 - x13=abs(fft(vs3));  33 - x33=abs(fft(vu3));
14 - x14=abs(fft(vs4));  34 - x34=abs(fft(vu4));
15 - x15=abs(fft(vs5));  35 - x35=abs(fft(vu5));
16 - x16=abs(fft(vs6));  36 - x36=abs(fft(vu6));
17 - x17=abs(fft(vs7));  37 - x37=abs(fft(vu7));
18 - x18=abs(fft(vs8));  38 - x38=abs(fft(vu8));
19 - x19=abs(fft(vs9));  39 - x39=abs(fft(vu9));
20 - x20=abs(fft(vs10)); 40 - x40=abs(fft(vu10));
```

0.2 pav. Greitosios Furjė transformacijos programinis kodas

```
fft_code.m x +          fft_code.m x +          fft_code.m x +          fft_code.m x +
41 - for i=2:1000;        71 - for i=2:1000;        101 - for i=2:1000;       131 - for i=2:1000;
42 -   xs1(i)=x1(i);      72 -   xs11(i)=x11(i);   102 -   xs21(i)=x21(i);  132 -   xs31(i)=x31(i);
43 - end                  73 - end                  103 - end                  133 - end
44 - for i=2:1000;        74 - for i=2:1000;        104 - for i=2:1000;       134 - for i=2:1000;
45 -   xs2(i)=x2(i);      75 -   xs12(i)=x12(i);   105 -   xs22(i)=x22(i);  135 -   xs32(i)=x32(i);
46 - end                  76 - end                  106 - end                  136 - end
47 - for i=2:1000;        77 - for i=2:1000;        107 - for i=2:1000;       137 - for i=2:1000;
48 -   xs3(i)=x3(i);      78 -   xs13(i)=x13(i);   108 -   xs23(i)=x23(i);  138 -   xs33(i)=x33(i);
49 - end                  79 - end                  109 - end                  139 - end
50 - for i=2:1000;        80 - for i=2:1000;        110 - for i=2:1000;       140 - for i=2:1000;
51 -   xs4(i)=x4(i);      81 -   xs14(i)=x14(i);   111 -   xs24(i)=x24(i);  141 -   xs34(i)=x34(i);
52 - end                  82 - end                  112 - end                  142 - end
53 - for i=2:1000;        83 - for i=2:1000;        113 - for i=2:1000;       143 - for i=2:1000;
54 -   xs5(i)=x5(i);      84 -   xs15(i)=x15(i);   114 -   xs25(i)=x25(i);  144 -   xs35(i)=x35(i);
55 - end                  85 - end                  115 - end                  145 - end
56 - for i=2:1000;        86 - for i=2:1000;        116 - for i=2:1000;       146 - for i=2:1000;
57 -   xs6(i)=x6(i);      87 -   xs16(i)=x16(i);   117 -   xs26(i)=x26(i);  147 -   xs36(i)=x36(i);
58 - end                  88 - end                  118 - end                  148 - end
59 - for i=2:1000;        89 - for i=2:1000;        119 - for i=2:1000;       149 - for i=2:1000;
60 -   xs7(i)=x7(i);      90 -   xs17(i)=x17(i);   120 -   xs27(i)=x27(i);  150 -   xs37(i)=x37(i);
61 - end                  91 - end                  121 - end                  151 - end
62 - for i=2:1000;        92 - for i=2:1000;        122 - for i=2:1000;       152 - for i=2:1000;
63 -   xs8(i)=x8(i);      93 -   xs18(i)=x18(i);   123 -   xs28(i)=x28(i);  153 -   xs38(i)=x38(i);
64 - end                  94 - end                  124 - end                  154 - end
65 - for i=2:1000;        95 - for i=2:1000;        125 - for i=2:1000;       155 - for i=2:1000;
66 -   xs9(i)=x9(i);      96 -   xs19(i)=x19(i);   126 -   xs29(i)=x29(i);  156 -   xs39(i)=x39(i);
67 - end                  97 - end                  127 - end                  157 - end
68 - for i=2:1000;        98 - for i=2:1000;        128 - for i=2:1000;       158 - for i=2:1000;
69 -   xs10(i)=x10(i);    99 -   xs20(i)=x20(i);   129 -   xs30(i)=x30(i);  159 -   xs40(i)=x40(i);
70 - end                  100 - end                 130 - end                 160 - end
```

a) b) c) d)

0.3 pav. Imties nustatymo programinis kodas

2.1 paveiksle pateikiamas kodas greitajai Furjė transformacijai. 2.2 a-d paveiksluose kodas paima 1000 imčių iš gautos rezultatų imties. Tai buvo daroma, norint gauti vienodą skaičių apdorojamų duomenų. Ši kodo dalis yra vienoda visoms transformacijoms: greitajai Furjė transformacijai, greitajai Walsh-Hadamard transformacijai bei visiems Kepstro transformacijos variantams.

fwht_code.m		fwht_code.m	
1 -	x1=abs (fwht (vb1)) ;	21 -	x21=abs (fwht (vt1)) ;
2 -	x2=abs (fwht (vb2)) ;	22 -	x22=abs (fwht (vt2)) ;
3 -	x3=abs (fwht (vb3)) ;	23 -	x23=abs (fwht (vt3)) ;
4 -	x4=abs (fwht (vb4)) ;	24 -	x24=abs (fwht (vt4)) ;
5 -	x5=abs (fwht (vb5)) ;	25 -	x25=abs (fwht (vt5)) ;
6 -	x6=abs (fwht (vb6)) ;	26 -	x26=abs (fwht (vt6)) ;
7 -	x7=abs (fwht (vb7)) ;	27 -	x27=abs (fwht (vt7)) ;
8 -	x8=abs (fwht (vb8)) ;	28 -	x28=abs (fwht (vt8)) ;
9 -	x9=abs (fwht (vb9)) ;	29 -	x29=abs (fwht (vt9)) ;
10 -	x10=abs (fwht (vb10)) ;	30 -	x30=abs (fwht (vt10)) ;
11 -	x11=abs (fwht (vs1)) ;	31 -	x31=abs (fwht (vu1)) ;
12 -	x12=abs (fwht (vs2)) ;	32 -	x32=abs (fwht (vu2)) ;
13 -	x13=abs (fwht (vs3)) ;	33 -	x33=abs (fwht (vu3)) ;
14 -	x14=abs (fwht (vs4)) ;	34 -	x34=abs (fwht (vu4)) ;
15 -	x15=abs (fwht (vs5)) ;	35 -	x35=abs (fwht (vu5)) ;
16 -	x16=abs (fwht (vs6)) ;	36 -	x36=abs (fwht (vu6)) ;
17 -	x17=abs (fwht (vs7)) ;	37 -	x37=abs (fwht (vu7)) ;
18 -	x18=abs (fwht (vs8)) ;	38 -	x38=abs (fwht (vu8)) ;
19 -	x19=abs (fwht (vs9)) ;	39 -	x39=abs (fwht (vu9)) ;
20 -	x20=abs (fwht (vs10)) ;	40 -	x40=abs (fwht (vu10)) ;

0.4 pav. Greitosios Walsh-Hadamard transformacijos programinis kodas

Greitoji Walsh-Hadamard transformacija buvo atlikta su garso ir vibracijos jutiklių duomenimis. Šios transformacijos programinis kodas pateikiamas 2.3 paveiksle. Naudotos absoliutinės reikšmės kaip ir kitoms transformacijoms atlikti. Pavyzdys pateikiamas su vibracijos jutiklio duomenimis kaip ir kitais atvejais.

Buvo naudoti keturi skirtingi Kepstro transformacijos variantai: kompleksinė Kepstro transformacija, realioji Kepstro transformacija, kompleksinės Kepstro transformacijos ir greitosios Furjė transformacijos kombinacija ir realiosios Kepstro transformacijos ir greitosios Furjė transformacijos kombinacija. Kai buvo naudojamos kelios transformacijos, pirmiausiai buvo atliekama Kepstro transformacija, o tada greitoji Furjė transformacija. Šiuo atveju po Kepstro transformacijos gautas rezultatas buvo laikomas nauju signalu, kuris buvo transformuojamas antrą kartą su greitąja Furjė transformacija.

Kodo pavyzdžiai:

Kompleksinei Kepstro transformacijai: `x1=abs(cceps(vb1));`

Realiajai Kepstro transformacijai: `x1=abs(rceps(vb1));`

Kompleksinės Kepstro ir greitosios Furjė transformacijų kombinacija: `x1=abs(fft(cceps(vb1)));`

Realiosios Kepstro ir greitosios Furjė transformacijų kombinacija: `x1=abs(fft(rceps(vb1)));`

Aukščiau pateikiami kodo pavyzdžiai yra naudojami signalo transformacijai. Žemiau pateikiamas kodas atitinka realiosios Kepstro ir greitosios Furjė transformacijų kombinaciją, kuri buvo panaudota tyrime. Norint panaudoti kitus tyrime naudotus transformacijos metodus, reikia pakeisti signalo transformacijai naudojamą kodo dalį, kuri pateikiama 2.4 pav. a ir b dalyse.

<pre> rceps_code.m x + 1 - x1=abs(fft(rceps(vb1))); 2 - x2=abs(fft(rceps(vb2))); 3 - x3=abs(fft(rceps(vb3))); 4 - x4=abs(fft(rceps(vb4))); 5 - x5=abs(fft(rceps(vb5))); 6 - x6=abs(fft(rceps(vb6))); 7 - x7=abs(fft(rceps(vb7))); 8 - x8=abs(fft(rceps(vb8))); 9 - x9=abs(fft(rceps(vb9))); 10 - x10=abs(fft(rceps(vb10))); 11 - x11=abs(fft(rceps(vs1))); 12 - x12=abs(fft(rceps(vs2))); 13 - x13=abs(fft(rceps(vs3))); 14 - x14=abs(fft(rceps(vs4))); 15 - x15=abs(fft(rceps(vs5))); 16 - x16=abs(fft(rceps(vs6))); 17 - x17=abs(fft(rceps(vs7))); 18 - x18=abs(fft(rceps(vs8))); 19 - x19=abs(fft(rceps(vs9))); 20 - x20=abs(fft(rceps(vs10))); </pre> <p style="text-align: center;">a)</p>	<pre> rceps_code.m x + 21 - x21=abs(fft(rceps(vt1))); 22 - x22=abs(fft(rceps(vt2))); 23 - x23=abs(fft(rceps(vt3))); 24 - x24=abs(fft(rceps(vt4))); 25 - x25=abs(fft(rceps(vt5))); 26 - x26=abs(fft(rceps(vt6))); 27 - x27=abs(fft(rceps(vt7))); 28 - x28=abs(fft(rceps(vt8))); 29 - x29=abs(fft(rceps(vt9))); 30 - x30=abs(fft(rceps(vt10))); 31 - x31=abs(fft(rceps(vu1))); 32 - x32=abs(fft(rceps(vu2))); 33 - x33=abs(fft(rceps(vu3))); 34 - x34=abs(fft(rceps(vu4))); 35 - x35=abs(fft(rceps(vu5))); 36 - x36=abs(fft(rceps(vu6))); 37 - x37=abs(fft(rceps(vu7))); 38 - x38=abs(fft(rceps(vu8))); 39 - x39=abs(fft(rceps(vu9))); 40 - x40=abs(fft(rceps(vu10))); </pre> <p style="text-align: center;">b)</p>
---	---

0.5 pav. Realiosios Kepstro ir greitosios Furjė transformacijų kombinacijos programinis kodas

3 Autokoreliacijos funkcijos ir grafiškų pateikimo programinis kodas

```
xcorr_code.m x + xcorr_code.m x +
1 - xk1=xcorr (xs1); 21 - xk21=xcorr (xs21);
2 - xk2=xcorr (xs2); 22 - xk22=xcorr (xs22);
3 - xk3=xcorr (xs3); 23 - xk23=xcorr (xs23);
4 - xk4=xcorr (xs4); 24 - xk24=xcorr (xs24);
5 - xk5=xcorr (xs5); 25 - xk25=xcorr (xs25);
6 - xk6=xcorr (xs6); 26 - xk26=xcorr (xs26);
7 - xk7=xcorr (xs7); 27 - xk27=xcorr (xs27);
8 - xk8=xcorr (xs8); 28 - xk28=xcorr (xs28);
9 - xk9=xcorr (xs9); 29 - xk29=xcorr (xs29);
10 - xk10=xcorr (xs10); 30 - xk30=xcorr (xs30);
11 - xk11=xcorr (xs11); 31 - xk31=xcorr (xs31);
12 - xk12=xcorr (xs12); 32 - xk32=xcorr (xs32);
13 - xk13=xcorr (xs13); 33 - xk33=xcorr (xs33);
14 - xk14=xcorr (xs14); 34 - xk34=xcorr (xs34);
15 - xk15=xcorr (xs15); 35 - xk35=xcorr (xs35);
16 - xk16=xcorr (xs16); 36 - xk36=xcorr (xs36);
17 - xk17=xcorr (xs17); 37 - xk37=xcorr (xs37);
18 - xk18=xcorr (xs18); 38 - xk38=xcorr (xs38);
19 - xk19=xcorr (xs19); 39 - xk39=xcorr (xs39);
20 - xk20=xcorr (xs20); 40 - xk40=xcorr (xs40);
```

a)

b)

0.6 pav. Autokoreliacijos funkcijos programinis kodas

```
xcorr_code.m x + xcorr_code.m x + xcorr_code.m x + xcorr_code.m x +
41 - for u=999:1999; 71 - for u=999:1999; 101 - for u=999:1999; 131 - for u=999:1999;
42 - xkp1 (u)=xk1 (u); 72 - xkp11 (u)=xk11 (u); 102 - xkp21 (u)=xk21 (u); 132 - xkp31 (u)=xk31 (u);
43 - end 73 - end 103 - end 133 - end
44 - for u=999:1999; 74 - for u=999:1999; 104 - for u=999:1999; 134 - for u=999:1999;
45 - xkp2 (u)=xk2 (u); 75 - xkp12 (u)=xk12 (u); 105 - xkp22 (u)=xk22 (u); 135 - xkp32 (u)=xk32 (u);
46 - end 76 - end 106 - end 136 - end
47 - for u=999:1999; 77 - for u=999:1999; 107 - for u=999:1999; 137 - for u=999:1999;
48 - xkp3 (u)=xk3 (u); 78 - xkp13 (u)=xk13 (u); 108 - xkp23 (u)=xk23 (u); 138 - xkp33 (u)=xk33 (u);
49 - end 79 - end 109 - end 139 - end
50 - for u=999:1999; 80 - for u=999:1999; 110 - for u=999:1999; 140 - for u=999:1999;
51 - xkp4 (u)=xk4 (u); 81 - xkp14 (u)=xk14 (u); 111 - xkp24 (u)=xk24 (u); 141 - xkp34 (u)=xk34 (u);
52 - end 82 - end 112 - end 142 - end
53 - for u=999:1999; 83 - for u=999:1999; 113 - for u=999:1999; 143 - for u=999:1999;
54 - xkp5 (u)=xk5 (u); 84 - xkp15 (u)=xk15 (u); 114 - xkp25 (u)=xk25 (u); 144 - xkp35 (u)=xk35 (u);
55 - end 85 - end 115 - end 145 - end
56 - for u=999:1999; 86 - for u=999:1999; 116 - for u=999:1999; 146 - for u=999:1999;
57 - xkp6 (u)=xk6 (u); 87 - xkp16 (u)=xk16 (u); 117 - xkp26 (u)=xk26 (u); 147 - xkp36 (u)=xk36 (u);
58 - end 88 - end 118 - end 148 - end
59 - for u=999:1999; 89 - for u=999:1999; 119 - for u=999:1999; 149 - for u=999:1999;
60 - xkp7 (u)=xk7 (u); 90 - xkp17 (u)=xk17 (u); 120 - xkp27 (u)=xk27 (u); 150 - xkp37 (u)=xk37 (u);
61 - end 91 - end 121 - end 151 - end
62 - for u=999:1999; 92 - for u=999:1999; 122 - for u=999:1999; 152 - for u=999:1999;
63 - xkp8 (u)=xk8 (u); 93 - xkp18 (u)=xk18 (u); 123 - xkp28 (u)=xk28 (u); 153 - xkp38 (u)=xk38 (u);
64 - end 94 - end 124 - end 154 - end
65 - for u=999:1999; 95 - for u=999:1999; 125 - for u=999:1999; 155 - for u=999:1999;
66 - xkp9 (u)=xk9 (u); 96 - xkp19 (u)=xk19 (u); 126 - xkp29 (u)=xk29 (u); 156 - xkp39 (u)=xk39 (u);
67 - end 97 - end 127 - end 157 - end
68 - for u=999:1999; 98 - for u=999:1999; 128 - for u=999:1999; 158 - for u=999:1999;
69 - xkp10 (u)=xk10 (u); 99 - xkp20 (u)=xk20 (u); 129 - xkp30 (u)=xk30 (u); 159 - xkp40 (u)=xk40 (u);
70 - end 100 - end 130 - end 160 - end
```

a)

b)

c)

d)

```

xcorr_code.m x +
161 - plot(xkp1,'color','blue','DisplayName','vb');hold all;
162 - plot(xkp2,'color','blue','DisplayName','no legend');hold all;
163 - plot(xkp3,'color','blue','DisplayName','no legend');hold all;
164 - plot(xkp4,'color','blue','DisplayName','no legend');hold all;
165 - plot(xkp5,'color','blue','DisplayName','no legend');hold all;
166 - plot(xkp6,'color','blue','DisplayName','no legend');hold all;
167 - plot(xkp7,'color','blue','DisplayName','no legend');hold all;
168 - plot(xkp8,'color','blue','DisplayName','no legend');hold all;
169 - plot(xkp9,'color','blue','DisplayName','no legend');hold all;
170 - plot(xkp10,'color','blue','DisplayName','no legend');hold all;
171 - plot(xkp11,'color','green','DisplayName','vs');hold all;
172 - plot(xkp12,'color','green','DisplayName','no legend');hold all;
173 - plot(xkp13,'color','green','DisplayName','no legend');hold all;
174 - plot(xkp14,'color','green','DisplayName','no legend');hold all;
175 - plot(xkp15,'color','green','DisplayName','no legend');hold all;
176 - plot(xkp16,'color','green','DisplayName','no legend');hold all;
177 - plot(xkp17,'color','green','DisplayName','no legend');hold all;
178 - plot(xkp18,'color','green','DisplayName','no legend');hold all;
179 - plot(xkp19,'color','green','DisplayName','no legend');hold all;
180 - plot(xkp20,'color','green','DisplayName','no legend');hold all;
181 - plot(xkp21,'color','red','DisplayName','vt');hold all;
182 - plot(xkp22,'color','red','DisplayName','no legend');hold all;
183 - plot(xkp23,'color','red','DisplayName','no legend');hold all;
184 - plot(xkp24,'color','red','DisplayName','no legend');hold all;
185 - plot(xkp25,'color','red','DisplayName','no legend');hold all;
186 - plot(xkp26,'color','red','DisplayName','no legend');hold all;
187 - plot(xkp27,'color','red','DisplayName','no legend');hold all;
188 - plot(xkp28,'color','red','DisplayName','no legend');hold all;
189 - plot(xkp29,'color','red','DisplayName','no legend');hold all;
190 - plot(xkp30,'color','red','DisplayName','no legend');hold all;

```

e)

```

191 - plot(xkp31,'color','yellow','DisplayName','vu');hold all;
192 - plot(xkp32,'color','yellow','DisplayName','no legend');hold all;
193 - plot(xkp33,'color','yellow','DisplayName','no legend');hold all;
194 - plot(xkp34,'color','yellow','DisplayName','no legend');hold all;
195 - plot(xkp35,'color','yellow','DisplayName','no legend');hold all;
196 - plot(xkp36,'color','yellow','DisplayName','no legend');hold all;
197 - plot(xkp37,'color','yellow','DisplayName','no legend');hold all;
198 - plot(xkp38,'color','yellow','DisplayName','no legend');hold all;
199 - plot(xkp39,'color','yellow','DisplayName','no legend');hold all;
200 - plot(xkp40,'color','yellow','DisplayName','no legend');hold off;
201 - xlim([999 1999]);
202 - xticks(999:100:1999);
203 - xticklabels(0:100:1999);
204 - ylim([0 inf])
205 - set_leg_off = findobj('DisplayName','no legend');
206 - for k = 1:numel(set_leg_off)
207     set_leg_off(k).Annotation.LegendInformation.IconDisplayStyle = 'off';
208 - end
209 - legend show

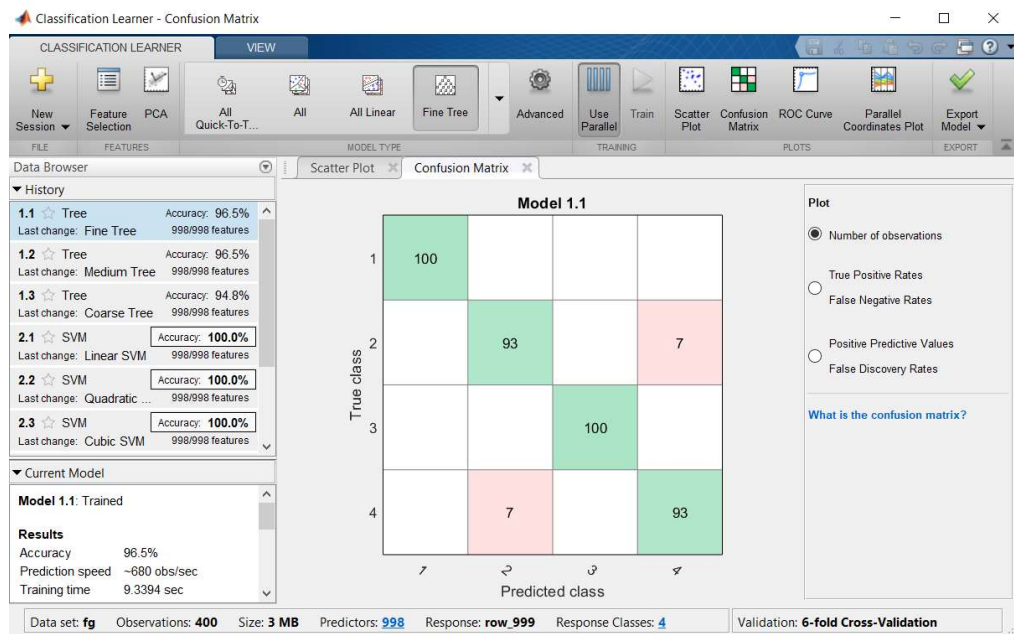
```

f)

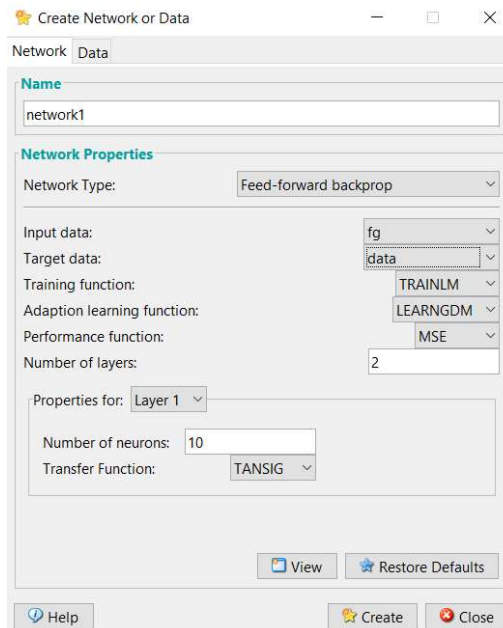
0.7 pav. Programinis kodas, skirtas duomenų imties sutapatinimui ir grafinės informacijos pateikimui

4 Programinis kodas gedimų grupių klasifikavimui

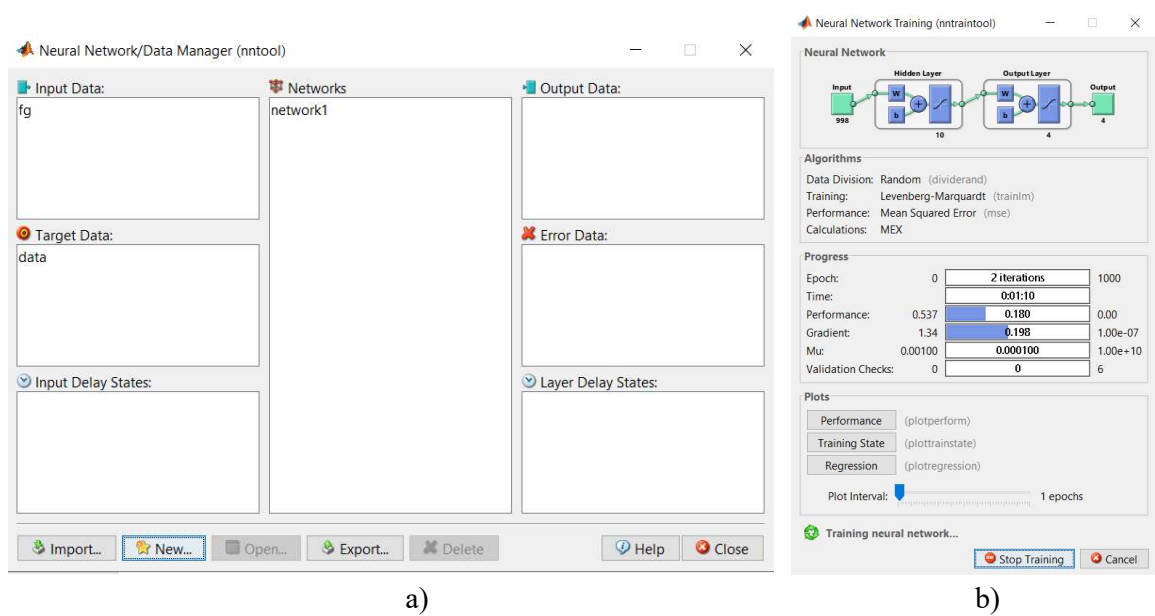
Mašininiai algoritmai gauti „Matlab“ programinės įrangos „Classification Learner“ ir „nntool“ pagalbiniais įrankiais buvo panaudoti klasifikavimui ir eksportuoti į „Matlab“ darbinę aplinką, kur jie buvo panaudoti klasifikavimo uždavinio atlikimui.



0.8 pav. „Classification Learner“ programa



0.9 pav. Naujo neuroninio tinklo kūrimas „nntool“ programa



0.10 pav. a) neuroninio tinklo kūrimas „nntool“ programa, b) neuroninio tinklo mokymo procesas „nntraintool“

Klasifikavimui panaudoti rezultatai gauti iš „Classification Learner“ ir „nntool“ su apmokintais klasifikatoriais. Norint šiuos klasifikatorius panaudoti, jie buvo eksportuoti į „Matlab“ darbinę aplinką ir jie panaudoti nepakeistų ir signalų transformacijomis pakeistų duomenų klasifikavimui. Žemiau pateikiamas kodas klasifikatorių panaudojimui ir klasifikatorių atpažinimo trukmės įvertinimui.

Kodas neuroninio tinklo panaudojimui ir atpažinimo matricos pateikimui:
 Atpažinta klasė=network1(duomenys);
 time(1)=timeit(@()network1(duomenys));
 plotconfusion(teisingos klasės,atpažintos klasės);

Kodas mašininio algoritmo panaudojimui ir atpažinimo matricos pateikimui:
 Atpažinta klasė=mašininis algoritmas.predictFcn(duomenys);
 time(1)=timeit(@()mašininis algoritmas.predictFcn(duomenys));
 plotconfusion(teisingos klasės,atpažintos klasės)