

**УНИВЕРЗИТЕТ „СВ. КИРИЛ И МЕТОДИЈ“ ВО СКОПЈЕ
МАШИНСКИ ФАКУЛТЕТ СКОПЈЕ**



Анастасија Горан Анѓушева Игњатовска

**ПРИМЕНА НА АЛГОРИТМИ НА НАДГЛЕДУВАНО
МАШИНСКО УЧЕЊЕ ЗА ПРОГНОСТИКА И
УПРАВУВАЊЕ СО СОСТОЈБАТА НА РОТИРАЧКИ
МАШИНИ**

Докторски труд

Скопје, 2026

НАСЛОВ: ПРИМЕНА НА АЛГОРИТМИ НА НАДГЛЕДУВАНО МАШИНСКО
УЧЕЊЕ ЗА ПРОГНОСТИКА И УПРАВУВАЊЕ СО СОСТОЈБАТА
НА РОТИРАЧКИ МАШИНИ

ИЗРАБОТИЛ: м-р Анастасија Анѓушева Игњатовска, дипл. маш. инж.

МЕНТОР: проф. д-р Златко Петрески

ОБЛАСТ: Технички науки - Машинство

ДАТА НА ЈАВНА ОДБРАНА: 26.05.2026

КОМИСИЈА ЗА ОДБРАНА НА
ДОКТОРСКАТА ДИСЕРТАЦИЈА

1. Проф. д-р Златко Петрески
Машински Факултет – Скопје
Универзитет „Св. Кирил и Методиј“ во
Скопје

2. Проф. д-р Даме Коруноски
Машински Факултет – Скопје
Универзитет „Св. Кирил и Методиј“ во
Скопје

3. Проф. д-р Виктор Гаврилоски
Машински Факултет – Скопје
Универзитет „Св. Кирил и Методиј“ во
Скопје

4. Проф. д-р Дарко Бабунски
Машински Факултет – Скопје
Универзитет „Св. Кирил и Методиј“ во
Скопје

5. Вон. проф. д-р Јована Јованова, Delft
University of Technology (TU Delft), Faculty of
Mechanical engineering, maritime and transport
technology

АПСТРАКТ

Оваа докторска дисертација претставува прилог во интердисциплинарната научна област прогностика и управување со состојбата на ротирачките машини, со фокус на примена на алгоритми на надгледувано машинско учење за автоматизирана дијагностика и прогностика на дефекти. Истражувањата во оваа докторска дисертација се насочени кон развој на интелигентен систем за следење на состојбата на ротирачки машини преку анализа на вибрациони сигнали, екстракција на релевантни карактеристики и примена на алгоритми за класификација и регресија со цел препознавање на моментални дефекти и предвидување на преостанатиот корисен век.

Мотивацијата, целите и придобивките од истражувањето се дадени во глава 1. Целите на докторската дисертација се дефинирани на почетокот на истражувањето, при што е воспоставена јасна методологија која овозможува систематско следење на сите фази – од избор и подготовка на бази на податоци, преку обработка и анализа на сигналите, до развој и валидација на моделите. Поставени се три хипотези кои во текот на истражувањето се потврдија преку соодветни анализи.

Во глава 2 е извршен избор и подготовка на базата на податоци за тренинг на дијагностичките модели, со детален опис на симулираните дефекти (дебаланс, нецентричност и дефекти во тркалачки лежишта), ротационите брзини и мерните услови. Разработени се основните принципи на примена на стандарди за проценка на состојба на машините, со цел дефинирање на референтна рамка за проценка на нивната механичка исправност.

Во глава 3 е извршена обработка на вибрационите сигнали и екстракција на карактеристики во временски и фреквентен домен, вклучувајќи статистички параметри, спектрални карактеристики, фазно-базирани параметри и карактеристики базирани на физиката на системите. Дополнително, применети се техники за нормализација и организација на карактеристиките во облик на вектори погодни за тренинг на алгоритмите на машинско учење.

Во глава 4 се разработени и имплементирани алгоритми на надгледувано машинско учење за дијагностика на дефекти кај ротирачки машини. Применети се алгоритмот на машини со поддржувачки вектори, алгоритмот на случајни шуми, алгоритмот на градиентно зголемување и комбинирани модели. Извршена е хиперпараметарска оптимизација и крос-валидација со цел постигнување робустни и генерализирачки модели за мултикласна и бинарна класификација.

Во глава 5 е спроведена валидација на дијагностичките модели со примена на бази на податоци снимени во лабораториски и реални услови. Резултатите ја потврдуваат способноста на предложената методологија за генерализација и примена во реални индустриски услови.

Во глава 6 е разработен прогностички модел за предвидување на преостанатиот корисен век на тркалачки лежишта. Извршена е обработка на сигналите, екстракција на деградациски индикатори и примена на алгоритми на надгледувано машинско учење за регресија со хиперпараметарска оптимизација. Добиените резултати покажуваат висока точност при предвидување на преостанатиот корисен век и ја потврдуваат применливоста на предложениот пристап во рамки на дисциплината прогностика и управување со состојба.

Глава 7 ги сумира заклучоците од истражувањето и дава препораки за идни истражувања, со посебен акцент на интеграција на развиениот систем во концептот на паметни фабрики и индустрија 4.0.

SUMMARY

This doctoral dissertation represents a contribution to the interdisciplinary scientific field of prognostics and health management (PHM) of rotating machinery, with a focus on the application of supervised machine learning algorithms for automated fault diagnostics and prognostics. The research presented in this dissertation is directed toward the development of an intelligent condition monitoring system for rotating machines through vibration signal analysis, extraction of relevant features, and application of classification and regression algorithms for the purpose of fault identification and remaining useful life (RUL) prediction.

The motivation, objectives, and expected contributions of the research are presented in Chapter 1. The objectives of the doctoral dissertation were defined at the beginning of the study, and a clear research methodology was established to ensure systematic monitoring of all phases — from selection and preparation of datasets, signal processing and analysis, to model development and validation. Three research hypotheses were formulated and subsequently confirmed through experimental results and statistical analysis.

Chapter 2 presents the selection and preparation of datasets for diagnostic purposes, including a detailed description of simulated faults (imbalance, misalignment, and rolling bearing defects), rotational speeds, and measurement conditions. The fundamental principles of frequency-domain analysis and the application of standards for machine condition assessment are elaborated, providing a reference framework for evaluating mechanical integrity.

In Chapter 3, vibration signal processing and feature extraction in both time and frequency domains are performed, including statistical parameters, spectral features, phase-based indicators, and characteristic fault frequencies for rolling bearings. Additionally, normalization techniques and feature organization into structured feature vectors suitable for training supervised machine learning algorithms are applied.

Chapter 4 focuses on the development and implementation of supervised machine learning algorithms for fault diagnostics of rotating machinery. Support vector machines, random forest, gradient boosting, and ensemble approaches are applied. Hyperparameter optimization and cross-validation procedures are conducted to achieve robust and generalizable models for both multiclass and binary classification.

Chapter 5 presents the validation of the diagnostic models using datasets recorded under laboratory and real operating conditions. The results confirm the capability of the proposed methodology to generalize and perform effectively in real industrial environments.

Chapter 6 develops a prognostic model for predicting the remaining useful life (RUL) of rolling bearings using the FEMTO dataset. Signal processing, extraction of degradation indicators, and application of supervised machine learning regression algorithms with hyperparameter optimization are carried out. The obtained results demonstrate high accuracy in RUL prediction and confirm the applicability of the proposed approach within the PHM framework.

Chapter 7 summarizes the conclusions of the research and provides recommendations for future work, with particular emphasis on integration of the developed system into smart factory and Industry 4.0 concepts.

ПРЕДГОВОР

Ја користам оваа прилика да изразам искрена благодарност до сите кои со својата поддршка, совети и помош придонесоа за успешна реализација на оваа докторска дисертација, како и за мојот досегашен академски и личен развој.

Најголем придонес во реализацијата на докторската дисертација има мојот професор и ментор, проф. д-р Златко Петрески, кому му изразувам искрена благодарност за континуираната поддршка, стручните совети, посветеноста и несебичното споделување на знаење во текот на целиот процес на истражување и изработка на дисертацијата.

Искрена благодарност упатувам до проф. д-р Даме Коруноски, за континуираната поддршка, успешната професионална соработка, како и за корисните совети и насоки, кои значително придонесоа за мојот академски и професионален развој.

Благодарност упатувам и до проф. д-р Виктор Гаврилоски, за корисните совети, искрената поддршка и отвореноста за дискусии и помош при бројните прашања и предизвици во текот на мојот академски развој. Неговите насоки, конструктивни размислувања и професионалната соработка имаа значаен придонес во моето усовршување и научно оформување.

Благодарност и до проф. д-р Дарко Бабунски за внимателното разгледување, корисните забелешки и оценката на докторската дисертација.

Особена благодарност упатувам до вон. проф. д-р Јована Јованова, која е еден од првите луѓе што ми ги отворија вратите кон академскиот развој и со која соработувам уште од студентските денови. Нејзината поддршка, доверба и охрабрување имаа значајно влијание врз мојот професионален развој и академско оформување.

Благодарност упатувам и до проф. д-р Кочо Анѓушев за бројните корисни совети, споделеното практично искуство и поддршката, кои придонесоа за пошироко согледување на практичната примена и значењето на истражувањето.

За огромната поддршка и прекрасната секојдневна соработка, искрена благодарност упатувам и до останатите членови на Институтот за Механика, доцент д-р Симона Домазетовска Марковска и доцент д-р Маја Аначкова, за нивниот технички придонес и споделените искуства, и до доцент д-р Дејан Шишковски и м-р Дамјан Пециоски за помошта при експерименталните мерења.

Благодарност до компанијата БРАКО за изработката и донацијата на симулаторот за вибрации, кој беше клучен за експерименталната валидација на истражувањето.

Голема благодарност изразувам до моите родители, Горан и Оливера, кои уште од најмали нозе ми ја всадија љубовта кон науката, знаењето и образованието. Вашата поддршка, доверба и пожртвуваност беа темелот врз кој се изградив како личност и истражувач.

Благодарност до мојот сопруг Ангел за безрезервната поддршка, љубовта, разбирањето и трпението во текот на изработката на оваа дисертација.

Оваа докторска дисертација со љубов му ја посветувам на моето прекрасно синче Кочо, чии мали рачиња често знаеја да се најдат на тастатурата при нејзиното пишување. Ти си мојата најголема мотивација и секој ден ме инспирираш да бидам подобра верзија од себе.

ЛИСТА НА СЛИКИ

ГЛАВА 1

Слика 1. Стратегии за одржување и нивните главни карактеристики

Слика 2. Активности во состав на дисциплината прогностика и управување со состојба

Слика 3. Шематски приказ на основните чекори при мерење, обработка и анализа на вибрационите сигнали

Слика 4. Поделба на моделите за автоматизација на процесите во состав на дисциплината прогностика и управување со состојба

ГЛАВА 2

Слика 5. Комплетен мерен систем за генерирање на базата на податоци MaFaulda

Слика 6. Спецификации на тркалачки лежишта во состав на симулаторот SpectraQuest

Слика 7. Измерен сигнал од тахометарот во временски домен при различни работни услови на

Слика 8. Измерени сигнали од акцелерометрите во временски домен при присутен дебаланс во машината

Слика 9. Измерен сигнал од тахометар во временски домен

Слика 10. Измерен сигнал од тахометар во фреквентен домен

Слика 11. Хистограм на разлики помеѓу дадените вредности за ротационата фреквенција во рамки на MaFaulda базата на податоци и пресметаните вредности за ротационата фреквенција

Слика 12. Принцип на Фуриева трансформација

Слика 13. Различни типови на дебаланс

Слика 14. Карактеристичен фреквентен спектар за дебаланс (статички, динамички и комбиниран)

Слика 15. Типови на нецентричност

Слика 16. Карактеристичен фреквентен спектар за нецентричност (аголна и паралелна)

Слика 17. Шематски приказ на основните елементи на едно тркалачко лежиште

Слика 18. Карактеристичен фреквентен спектар за сигнал снимен при присутен дефект на внатрешен прстен кај тркалачко лежиште (BPF1)

Слика 19. Карактеристичен фреквентен спектар за сигнал снимен при присутен дефект на надворешен прстен кај тркалачко лежиште (BPF0)

Слика 20. Карактеристичен фреквентен спектар за сигнал снимен при присутен дефект на тркалачки елемент кај тркалачко лежиште (BSF)

Слика 21. Карактеристичен фреквентен спектар за сигнал снимен при присутен дефект на на кафеж кај тркалачко лежиште (FTF)

Слика 22. Амплитуда на вибрации изразена во поместување и забрзување соодветно на константна брзина од 7,6 mm/s

Слика 23. Фреквентен одговор на високопропусен Батервортов филтер (од 2ри, 4ти, 6ти и 8ми ред со гранична фреквенција од 10 Hz)

Слика 24. Фреквентен одговор на дизајнираниот високопропусен Батервортов филтер од бти ред со гранична фреквенција 16,25 Hz ($Fr/3$, $Fr=48,74$ Hz)

Слика 25. Фреквентен спектар на сигналот после интеграција без примена на високопропусен Батервортов филтер (дебаланс од 35 g, ротациона брзина 55,4 Hz)

Слика 26. Фреквентен спектар на сигналот после интеграција со примена на високопропусен Батервортов филтер од бти ред (дебаланс од 35 g, ротациона брзина 55,4 Hz)

Слика 27. а) Вредности на параметарот v_{RMS} при различни ротациони фреквенции на вратилото и по различни оски на измерените вибрации при присутен дебаланс

б) Вредности на параметарот v_{RMS} при различни нивоа на изразеност на дебаланс

Слика 28. Промена на вредности на параметарот v_{RMS} при различни ротациони фреквенции на вратилото и по различни оски на измерените вибрации при различни нивоа на изразеност на дебаланс

Слика 29. а) Вредности на параметарот v_{RMS} при различни ротациони фреквенции на вратилото и по различни оски на измерените вибрации при присутна хоризонтална и вертикална нецентричност

б) Вредности на параметарот v_{RMS} при различни нивоа на изразеност на нецентричност

Слика 30. Промена на вредности на параметарот v_{RMS} при различни ротациони фреквенции на вратилото и по различни оски на измерените вибрации при различни нивоа на изразеност на хоризонтална и вертикална нецентричност

Слика 31. а) Вредности на параметарот v_{RMS} при различни ротациони фреквенции на вратилото и по различни оски на измерените вибрации при присутен дефект во лежиштата

б) Вредности на параметарот v_{RMS} при различни нивоа на изразеност на дебаланс при присутен дефект во лежиштата

Слика 32. Промена на вредности на параметарот v_{RMS} при различни ротациони фреквенции на вратилото и по различни оски на измерените вибрации при различни нивоа на изразеност на дебаланс при присутен дефект во лежиштата

Слика 33. Хистограм на распределба на број на примероци по зони согласно стандардот ISO 10816-1 според v_{RMS} при присутен дебаланс, присутен дефект во лежиште и присутна хоризонтална и вертикална нецентричност

Слика 34. Состојба на машината согласно стандардот ISO 10816-1 според v_{RMS} при при различни ротациони фреквенции на вратилото при различни нивоа на изразеност на дебаланс

Слика 35. Состојба на машината согласно стандардот ISO 10816-1 според v_{RMS} при при различни ротациони фреквенции на вратилото при различни нивоа на изразеност на нецентричност

Слика 36. Состојба на машината согласно стандардот ISO 10816-1 според v_{RMS} при при различни ротациони фреквенции на вратилото при различни нивоа на изразеност на дебаланс при присутен дефект во лежиштата

Слика 37. Процентуална застапеност на сигналите снимени при сите состојби на ротирачката машина во состав на MaFaulda база на податоци

Слика 38. Методологија за балансирање на податоците во состав на MaFaulda базата на податоци – модификации во организација на сигнали снимени при нормална состојба

Слика 39. Процентуална застапеност на сигналите снимени при сите состојби на ротирачката машина во состав на MaFaulda база на податоци по примена на методологија за балансирање

Слика 40. Процентуална застапеност на сигналите снимени при сите состојби на ротирачката машина во состав на MaFaulda база на податоци по примена на методологија за балансирање

Слика 41. Ефекти од користење на Anti-Aliasing филтер при намалување на F_s – фреквентен домен

ГЛАВА 3

Слика 42. Вибрационен сигнал на синусна функција со амплитуда 1 и 100 примероци во временски домен

Слика 43. Дефинирање на параметарот фазна разлика

Слика 44. Манифестација на протекување на сигнал, лево – периодичен сигнал, десно – непериодичен сигнал (Anti-Leakage)

Слика 45. Фреквентен спектар на сигнал снимен при присутен дебаланс во машината со ниво на изразеност од 35 g при ротациона фреквенција од 55,40 Hz (црвена линија)

Слика 46. Фреквентен спектар на сигналот снимен со тахометарот при брзина на ротација на вратилото од 56,7296 Hz

Слика 47. Фреквентен спектар на сигнал снимен при присутна нецентричност во машината со

Слика 48. Концептуален приказ на амплитудно-фреквентен спектар на вибрационен сигнал при присутен дефект во тркалачко лежиште, со појава на резонантен високофреквентен одговор

Слика 49. Концептуален приказ на модулиран сигнал во временски домен снимен при присутен дефект во лежишта

Слика 50. Шематски приказ на основните чекори во состав на методот анализа на енvelopa

Слика 51. Фреквентен спектар на сигнал снимен при присутен дефект на надворешен прстен и дебаланс од 20 g, $f_r = 55,40$ Hz

Слика 52. Фреквентен спектар на сигнал снимен при присутен дефект во топчиња и дебаланс од 20 g, $f_r = 54,80$ Hz

ГЛАВА 4

Слика 53. Шематски приказ на тренирање и тестирање на класификатор базиран на надгледувано машинско учење

Слика 54. Шематски приказ на поделба на податоци при крос-валидација со 5 превиткувања

Слика 55. Бинарна линеарна класификација со линеарен класификатор за машини со поддржувачки вектори

Слика 56. Нелинеарна класификација со Кернел функција за машини со поддржувачки вектори

Слика 57. Шематски приказ на алгоритам на случајни шуми

Слика 58. Шематски приказ на алгоритмот на градиентно зголемување

Слика 59. Дваесет карактеристики со највисоко ниво на значајност по примена на методот на пермутација на вредностите на карактеристиките за хибридниот комбиниран модел со примена на сите шест мерни оски

ГЛАВА 5

Слика 60. Оштетено тркалачко лежиште со локален дефект на надворешен прстен

Слика 61. Оштетено тркалачко лежиште со питинг на надворешен прстен

Слика 62. Оштетено тркалачко лежиште со локални дефекти на кафез и топче

Слика 63. Приказ на симулаторот и поставеноста на едноосниот акцелерометар на куќиштето на надворешното лежиште

Слика 64. Приказ на елементите од кои се состои мерниот систем во состав на експерименталниот систем

Слика 65. Поставеност на едноосниот акцелерометар тип 4526 од V&K при мерење на забрзувањето на вибрациите по вертикална и по хоризонтална оска

Слика 66. Фреквентен спектар на Signal_05 (дебаланс од 5 g, 25 Hz, вертикална оска) пред примена на анализа на нискофреквентен спектар

Слика 67. Фреквентен спектар на Signal_05 (дебаланс од 5 g, 25 Hz, вертикална оска) по примена на анализа на нискофреквентен спектар

Слика 68. Фреквентен спектар на Signal_12 (дебаланс од 10 g, 50 Hz, хоризонтална оска) пред примена на анализа на нискофреквентен спектар

Слика 69. Фреквентен спектар на Signal_12 (дебаланс од 10 g, 50 Hz, хоризонтална оска) по примена на анализа на нискофреквентен спектар

Слика 70. Фреквентен спектар на Signal_17 (локален дефект во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 25 Hz, вертикална оска) пред примена на анализа на енvelopa

Слика 71. Фреквентен спектар на Signal_17 (локален дефект во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 25 Hz, вертикална оска) по примена на анализа на енvelopa

Слика 72. Фреквентен спектар на Signal_18 (локален дефект во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 50 Hz, вертикална оска) пред примена на анализа на енvelopa

Слика 73. Фреквентен спектар на Signal_18 (локален дефект во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 50 Hz, вертикална оска) пред примена на анализа на енvelopa

Слика 74. Фреквентен спектар на Signal_27 (присутен питинг во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 25 Hz, хоризонтална оска) пред примена на анализа на енvelopa

Слика 75. Фреквентен спектар на Signal_27 (присутен питинг во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 25 Hz, хоризонтална оска) по примена на анализа на енvelopa

Слика 76. Фреквентен спектар на Signal_28 (присутен питинг во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 50 Hz, хоризонтална оска) пред примена на анализа на енvelopa

Слика 77. Фреквентен спектар на Signal_28 (присутен питинг во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 50 Hz, хоризонтална оска) по примена на анализа на енvelopa

Слика 78. Временска репрезентација на оригиналниот сигнал и неговите верзии со додаден шум при ниски вредности на SNR

Слика 79. Точност при класификација на со примена на различни нивоа на адитивен бел Гаусов шум

Слика 80. Снимен сигнал со MEMC акцелерометар ADXL335 интегриран со WeMos D1 Mini микроконтролер во временски домен

Слика 81. Фреквентен спектар на оригиналниот сигнал снимен со MEMC акцелерометар ADXL335 интегриран со WeMos D1 Mini микроконтролер

Слика 82. Фреквентен спектар на енvelopата на обработениот сигнал снимен со MEMC акцелерометар ADXL335 интегриран со WeMos D1 Mini микроконтролер

Слика 83. Фреквентен спектар на енvelopата на обработениот сигнал снимен со MEMC акцелерометар ADXL335 интегриран со WeMos D1 Mini микроконтролер – со означени врвни вредности

Слика 84. Снимени вибрациони сигнали 1-5 во временски домен

Слика 85. Фреквентен спектар по примена на FFT на оригиналните сигнали 1-5

Слика 86. Фреквентен спектар на енvelopата на сигналите 1-5

Слика 87. Снимени вибрациони сигнали 6-10 во временски домен

Слика 88. Фреквентен спектар по примена на FFT на оригиналните сигнали 6-10

Слика 89. Фреквентен спектар на енvelopата на сигналите 6-10

Слика 90. Фреквентен спектар по примена на FFT на оригиналниот сигнал – Сигнал 11

Слика 91. Фреквентен спектар на енvelopата – Сигнал 11

Слика 92. Фреквентен спектар по примена на FFT на оригиналниот сигнал – Сигнал 12

Слика 93. Фреквентен спектар на енvelopата– Сигнал 12

Слика 94. Фреквентен спектар по примена на FFT на оригиналниот сигнал - Сигнал 13

Слика 95. Фреквентен спектар на енvelopата– Сигнал 13

Слика 96. Фреквентен спектар по примена на FFT на оригиналниот сигнал – Сигнал 14

Слика 97. Фреквентен спектар на енvelopата– Сигнал 14

ГЛАВА 6

Слика 98. Приказ на промена на амплитудата на сигналите (по двете оски) од базата за тренинг во текот на времето

Слика 99. Приказ на промена на амплитудата на сигналот Bearing1_1 (по двете оски) во текот на времето

Слика 100. Приказ на промена на амплитудата на сигналот Bearing1_2 (по двете оски) во текот на времето

Слика 101. Приказ на промена на амплитудата на сигналот Bearing1_5 (по двете оски) во текот на времето

Слика 102. Приказ на промена на амплитудата на сигналот Bearing1_7 (по двете оски) во текот на времето

Слика 103. Приказ на промена на амплитудата на сигналот Bearing2_1 (по двете оски) во текот на времето

Слика 104. Приказ на промена на амплитудата на сигналот Bearing2_2 (по двете оски) во текот на времето

Слика 105. Приказ на промена на амплитудата на сигналот Bearing3_1 (по двете оски) во текот на времето

Слика 106. Приказ на промена на амплитудата на сигналот Bearing3_2 (по двете оски) во текот на времето

Слика 107. Сигнал Bearing1_1 во текот на времето пред и по примена на вејвлет трансформација

Слика 108. Сигнал Bearing1_2 во текот на времето пред и по примена на вејвлет трансформација

Слика 109. Сигнал Bearing2_1 во текот на времето пред и по примена на вејвлет трансформација

Слика 110. Сигнал Bearing2_2 во текот на времето пред и по примена на вејвлет трансформација

Слика 111. Сигнал Bearing3_1 во текот на времето пред и по примена на вејвлет трансформација

Слика 112. Сигнал Bearing3_2 во текот на времето пред и по примена на вејвлет трансформација

Слика 113. Промена на вредноста параметарот куртоза во текот на времето при снимање на сигналот Bearing1_1

Слика 114. Енvelopa на фреквентен спектар на сигналот Bearing1_1, во текот на трите различни фази на работа на лежиштето

Слика 115. Спектрограм при временска единица 0 и при временска единица 3500

Слика 116. Резултати од хиперпараметарска оптимизација на алгоритмот за регресија со вектор на поддршка - вредности на MAE при различни комбинации на вредности на хиперпараметрите

Слика 117. Резултати од хиперпараметарска оптимизација на алгоритмот за регресија - случајни шуми - вредности на MAE при различни комбинации на вредности на хиперпараметрите

ГЛАВА 7

Слика 118. Концептуална шема на архитектура на интегриран автономен систем за вибрациско-дијагностички мониторинг на ротирачки машини

ЛИСТА НА ТАБЕЛИ

ГЛАВА 1

Табела 1. Индикатори и најчести проблеми кај една ротирачка машина [3]

Табела 2. Најчести дефекти кај машини и приближен процент на нивно појавување [23]

Табела 3. Преглед на истражувања во областа на алгоритми за машинско учење за класификација на дефекти кај машини

ГЛАВА 2

Табела 4. Спецификации на симулаторот SpectraQuest [125,126]

Табела 5. Спецификации на искористените акцелерометри за креирање на MaFaulda [125]

Табела 6. Организација на датотеките по поединечни класи на работни состојби и ниво на изразеност

Табела 7. Проценка на состојба на ротирачки машини според стандард ISO 10816-1

ГЛАВА 3

Табела 8. Екстрахирани карактеристики од MaFaulda база на податоци

Табела 9. Пресметани вредности на статистичките параметри во временски домен по трите оски за двете лежишта, при присутен дефект во топчињата на надворешното лежиште и дебаланс со ниво на изразеност од 6g и брзина на ротација на вратилото 39,73 Hz

Табела 10. Пресметани вредности на статистичките параметри во фреквентен домен по трите оски за двете лежишта, при присутен дефект во топчињата на надворешното лежиште и дебаланс со ниво на изразеност од 6g и брзина на ротација на вратилото 39,3 Hz

Табела 11. Пресметани вредности на фазно-базираните спектрални карактеристики во фреквентен домен по трите оски за двете лежишта, при присутен дефект во топчињата на надворешното лежиште и дебаланс со ниво на изразеност од 6g и брзина на ротација на вратилото 39,3 Hz

Табела 12. Вредности на првите пет хармоници при ротациона фреквенција од 55,40 Hz

Табела 13. Карактеристични фреквенции за дефекти во тркалачки лежишта од MaFaulda база на податоци – изразени во функција од ротационата фреквенција

ГЛАВА 4

Табела 14. Перформанси на чисто податочни и хибридни модели за мултикласна класификација по хиперпараметарска оптимизација со примена на крос-валидација со 10-преклопувања

Табела 15. Перформанси на комбинираниот модел за мултикласна класификација за различни оски и нивни комбинации со примена на хибридни карактеристики

Табела 16. Перформанси на комбинираниот модел за бинарна класификација за различни оски и нивни комбинации со примена на хибридни карактеристики

Табела 17. Кумулативна и релативна пермутациска значајност на различни групи карактеристики

Табела 18. Анализа на чувствителност на фреквенцијата на семплирање: потребно компјутерско време за екстракција на карактеристики и точност на хибридниот комбиниран модел

Табела 19. Потребно компјутерско време за тренинг и тестирање на алгоритмите кои го сочинуваат комбинираниот модел (со 192 екстрахирани карактеристики)

ГЛАВА 5

Табела 20. Параметри на тркалачки лежишта од тип 6205 2RS искористени при снимање на базата на податоци во експериментални услови

Табела 21. Пресметани коефициенти за карактеристичните фреквенции при присутни дефекти во тркалачки лежишта тип 6205 2RS искористени при снимање на базата на податоци во експериментални услови

Табела 22. Вредности за првите четири хармоници на карактеристичните фреквенции за најчестите типови на дефекти на тркалачки лежишта тип 6205 2RS при $f_r = 25 \text{ Hz}$

Табела 23. Вредности за првите четири хармоници на карактеристичните фреквенции за најчестите типови на дефекти на тркалачки лежишта тип 6205 2RS при $f_r = 50 \text{ Hz}$

Табела 24. Организација на лабораториски снимените сигнали според ротациона брзина, мерна оска и состојба на системот

Табела 25. Резултати од валидација на хибриден комбиниран модел ($\text{tg1}+\text{rad1}$) за мултикласна и бинарна класификација – со примена на база на податоци снимена во лабораториски услови

Табела 26. Пресметани коефициенти за карактеристичните фреквенции при присутен дефект во надворешен прстен на тркалачки лежишта тип 6205 2RS искористени при снимање на базата на податоци во експериментални услови

Табела 27. Резултати од валидација на хибриден комбиниран модел ($\text{tg1}+\text{rad1}$) за мултикласна и бинарна класификација – со примена на сигнал снимен во лабораториски услови со MEMC акцелерометар ADXL335 интегриран со WeMos D1 Mini микроконтролер

Табела 28. Организација на базата на податоци снимена во реални услови според ротациона брзина, фреквенција на семплирање и тип и димензии на тркалачко лежиште

Табела 29. Резултати од валидација на хибриден комбиниран модел (rad1) за мултикласна и бинарна класификација со база на податоци снимена во реални услови

ГЛАВА 6

Табела 30. Начин на организација на FEMTO базата на податоци

Табела 31. Начин на организација на датотеките во состав на FEMTO базата на податоци

Табела 32. Параметри на тркалачки лежишта искористени при снимање на FEMTO базата на податоци

Табела 33. Вредности на карактеристични фреквенции при присутни дефекти во лежишта за FEMTO базата на податоци

Табела 34. Екстрахирани карактеристики од FEMTO база на податоци

Табела 35. Вкупни временски интервали на снимање на сигналите во состав на FEMTO базата на податоци – дел за тренинг

Табела 36. Вкупни временски интервали на снимање на сигналите во состав на FEMTO базата на податоци – дел за тестирање

Табела 37. Реални временски интервали за преостанатиот работен век на секое лежиште во состав на FEMTO базата на податоци – дел за тестирање

Табела 38. Вредности на параметрите за евалуација на перформансите на двата алгоритми на надгледувано машинско учење по хиперпараметарската оптимизација

СОДРЖИНА

Апстракт.....	iii
Summary.....	iv
Предговор.....	v
Листа на слики.....	vi
Листа на табели.....	xii
1. Вовед.....	17
1.1 Стратегии за одржување на производни системи.....	18
1.2 Мотивација за истражувањето.....	20
1.3 Преглед на постоечка литература.....	22
1.4 Предмет на истражување.....	31
1.5 Цели на истражувањето.....	31
1.6 Хипотези на истражувањето.....	33
1.7 Методологија на истражување.....	33
1.8 Придобивки од истражувањето.....	35
1.9 Содржина на истражувањето.....	36
2.Избор и подготовка на база на податоци за дијагностички цели.....	38
2.1 Опис на база на податоци за дијагностички цели.....	38
2.2 Фуриева трансформација.....	44
2.3 Ротациона брзина на вратилото.....	45
2.4 Симулирани дефекти и нивни карактеристики.....	47
2.5 Примена на стандарди за проценка на состојба на машини.....	54
2.6 Подготовка на вибрационите сигнали.....	62
3.Обработка на сигнали и екстракција на карактеристики за дијагностички цели	67
3.1 Типови на карактеристики.....	67
3.2 Екстракција на карактеристики.....	76
3.3 Нормализација на екстрахираните карактеристики.....	87
4. Примена на алгоритми на надгледувано машинско учење за дијагностика на дефекти кај ротирачки машини.....	88
4.1 Алгоритми на надгледувано машинско учење.....	89
4.2 Тренинг и тестирање на дијагностички модели.....	101
4.3 Анализа на нивото на значајност на карактеристиките.....	108
4.4 Компјутерска ефикасност и индустриска применливост на предложената дијагностичка методологија.....	109
5.Валидација на дијагностичките модели.....	112
5.1 Валидација со примена на база на податоци снимена во експериментални услови.....	112
5.2 Валидација со примена на база на податоци измерена во реални услови.....	134
6. Прогностика.....	148
6.1 Избор на бази на податоци и опис на база на податоци – FEMTO.....	148
6.2 Обработка на базата на податоци.....	152
6.3 Екстракција на карактеристики.....	157

6.4 Примена на алгоритми на надгледувано машинско учење и хиперпараметарска оптимизација	160
6.5 Преглед на резултати од тестирањето на моделот за прогностика.....	164
7. Заклучоци и препораки за идна работа.....	166
7.1 Главни заклучоци од истражувањето	166
7.2 Препораки за идна работа	1699
Користена литература.....	172
ПРИЛОЗИ.....	184

1. ВОВЕД

Воведното поглавје на оваа докторска дисертација ги прикажува основната идеја и целите на истражувањето и ги претставува чекорите на методологијата за постигнување на тие цели. На почетокот на главата даден е краток преглед на областа на истражување, поконкретно објаснети се основните стратегии за одржување на еден систем со соодветните активности кои треба да се преземат при нивно спроведување, како и можностите за нивна автоматизација со примена на напредни методи базирани на вештачка интелигенција. Особен акцент е ставен на пристапот наречен прогностика и управување со состојбата на системите (Prognostics and Health Management - PHM) кој инкорпорира повеќе стратегии за одржување во единствена целина. Овој пристап вклучува следење на моменталната состојба на системот преку негова дијагностика, како и предвидување на неговата идна состојба преку прогностика и со тоа овозможува понатамошно преземање на соодветни активности во насока на спречување идни дефекти и застои. Истакната е можноста за примена на напредни методи базирани на вештачка интелигенција при имплементација на пристапот прогностика и управување со состојбата за одржување на модерните производни системи.

Современото производство налага примена на ротирачки машини кои се карактеризираат со висока достапност и продуктивност при истовремено постигнување и одржување на високо ниво на квалитет. Токму затоа, во последната деценија извршени се бројни истражувања во насока на оптимизација на стратегиите за одржување и воедно процесот на дијагностика и прогностика на ротирачките машини, што претставува и основна мотивација за изборот на истражувачката област во оваа дисертација. Најпрво се изврши систематски преглед на постоечката литература од оваа област со цел детално проучување на различните области кои ги покрива оваа интердисциплинарна тема.

Прегледот на постоечката литература од областа вклучува проучување на основите на пристапот - прогностика и управување со состојбата на системите, поконкретно со состојбата на ротирачките машини, како и полињата кои таа ги покрива односно дијагностика и прогностика на ротирачки машини. Понатаму, проучени се напредните методи кои се базираат на вештачката интелигенција во насока на нивна примена при спроведување на пристапот за одржување - прогностика и управување со состојбата на ротирачките машини. Поради интердисциплинарната природа на ова истражување, прегледот на литературата е организиран по поодделни области кои треба детално да се проучат со цел искористување на потенцијалот на овие методи за автоматизација на процесот на одржување на модерните производни системи.

Целите кои треба да се достигнат во оваа докторска дисертација се дефинирани на самиот почеток, а методологијата на истражување е организирана на начин кој дава целосен и детален преглед на сите неопходни фази за реализација на целите, како и јасен преглед на добиените резултати.

Поставени се три хипотези, кои се потврдија и докажаа во текот на изработката на докторската дисертација.

На крајот даден е краток преглед на значењето и придобивките од оваа докторска дисертација, како во научно-истражувачкиот свет, така и за решавање на реални проблеми од

индустријата. Воведното поглавје завршува со приказ на начинот на организација на докторската дисертација преку опис на поодделните поглавја.

1.1 Стратегии за одржување на производни системи

Одржувањето се дефинира како постојана контрола на сите работни средства како и извршување одредени поправки и преземање превентивни мерки, со цел обезбедување постојано правилно функционирање на цела опрема. Со други зборови, тоа е динамички процес на проверка и анализа на технолошките постројки со кој се врши предвидување на штета и неуспех со високо ниво на доверба и нивно навремено елиминирање [1]. Во насока на тоа, може да се дефинираат главните цели што треба да се постигнат со процесот на одржување [2]:

- обезбедување технолошка способност на работните средства во рамките на границите на пропишаната технолошка способност во спецификациите и постигнување на проектираниот работен век, без ненадејни дефекти,
- остварување редовни превентивни прегледи и мерки за откривање и елиминирање на потенцијалната штета што може да резултира во неуспех,
- минимизирање на трошоците како резултат на намалување на непроизводното време поради непланирани дефекти,
- обезбедување организирана навремена поправка каде што е потребно одржување и управување со работните средства, при истовремено намалување на залихата на резервни делови,
- постигнување ефективност при што е можно пониски трошоци за истото, бидејќи обично претставува добар дел од вкупните трошоци на животниот циклус на еден производ.

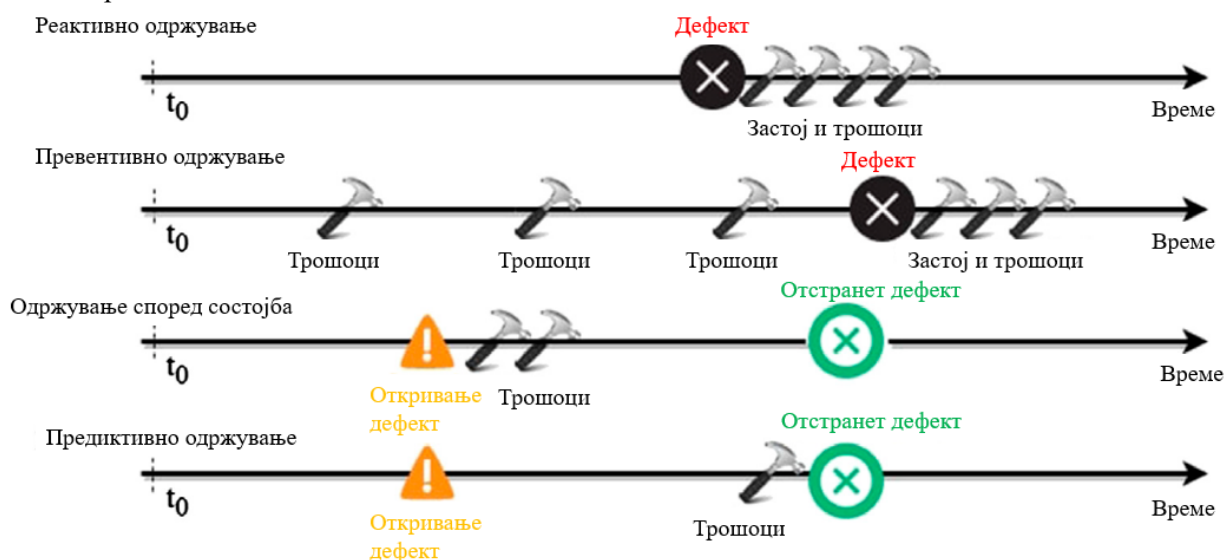
Одржувањето претставува значаен економски фактор кај индустриските системи, бидејќи директно влијае врз оперативните трошоци, расположливоста на опремата, застојот во работата и животниот век на машинските компоненти. Кај производствените системи, значителен дел од вкупните трошоци се поврзани со одржување, при што во литературата се наведува дека тие може да учествуваат со приближно 15–40 % од вкупните производствени трошоци [3]. Ова укажува дека навременото откривање на дефекти и правилното планирање на одржувањето имаат директно економско значење. Според извештаи на McKinsey & Company [4], примената на предиктивно одржување може да го намали непланираниот застој на машините за 30–50 %, да ги намали трошоците за одржување за 10–40 % и да го зголеми работниот век на машините за 20–40 %.

Во насока на исполнување на горенаведените цели при истовремено намалување на трошоците за одржување, развиени се поголем број на стратегии за одржување, слика 1:

- реактивно одржување – одржување после настанат дефект,
- превентивно одржување – редовно одржување кое се извршува според однапред одреден термински план и со дефинирана постапка за работа, пред да настане реален дефект на системот [2],
- одржување според состојба – интервенциите се изведуваат според утврдената моментална состојба на работните средства,
- предиктивно одржување – можниот дефект се предвидува (прогностика) и пред да се случи се изведува соодветен зафат. Дополнително се преземаат активности за да се спречат и идни дефекти.

Прогностика и управување со состојбата на системите (PHM) е дисциплина добиена како симбиоза од двете стратегии одржување според состојба и предиктивно одржување. Целта на оваа дисциплина е управување со состојбата на инженерските системи и нивните критични

компоненти врз база на научни факти. Обединувајќи ги двете стратегии нуди логичен и лесно следлив тек на активностите преку кои тие се имплементираат и овозможува изградба на робустен, економичен и доверлив систем за одржување. Активностите преку кои се спроведува дисциплината прогностика и управување со состојба, генерално може да се поделат во две групи и тоа активности во насока на дијагностика, и активности во насока на прогностика, слика 2. Со други зборови, дисциплината прогностика и управување со состојба подразбира следење и предвидување на состојбата на компонентите на анализираниот систем користејќи соодветни индикатори, слика 2, што овозможува преземање активности за одржување на системот пред појава на дефектите. Согласно, се состои од три главни аспекти: избор на значајни индикатори за следење на моменталната и идната состојба, предвидување на преостанатиот корисен век и преземање активности за управување со состојбата. Преку значајните индикатори се оценува моменталната состојба на системот и неговите критични компоненти. Дополнително, овие индикатори се користат за предвидување на преостанатиот корисен век со цел определување на моментот во кој инженерскиот систем или критичната компонента повеќе нема да ја извршуваат својата функција [5]. На пример, тркалачките лежишта се критични компоненти во ротирачките машини кои откако ќе откажат го забрзуваат појавувањето на дефекти и на други компоненти [6]. Управување со состојбата вклучува планирање на оптимален распоред за одржување во согласност со моменталната и идната состојба на системот и нејзините критични компоненти како и трошоците за замена.

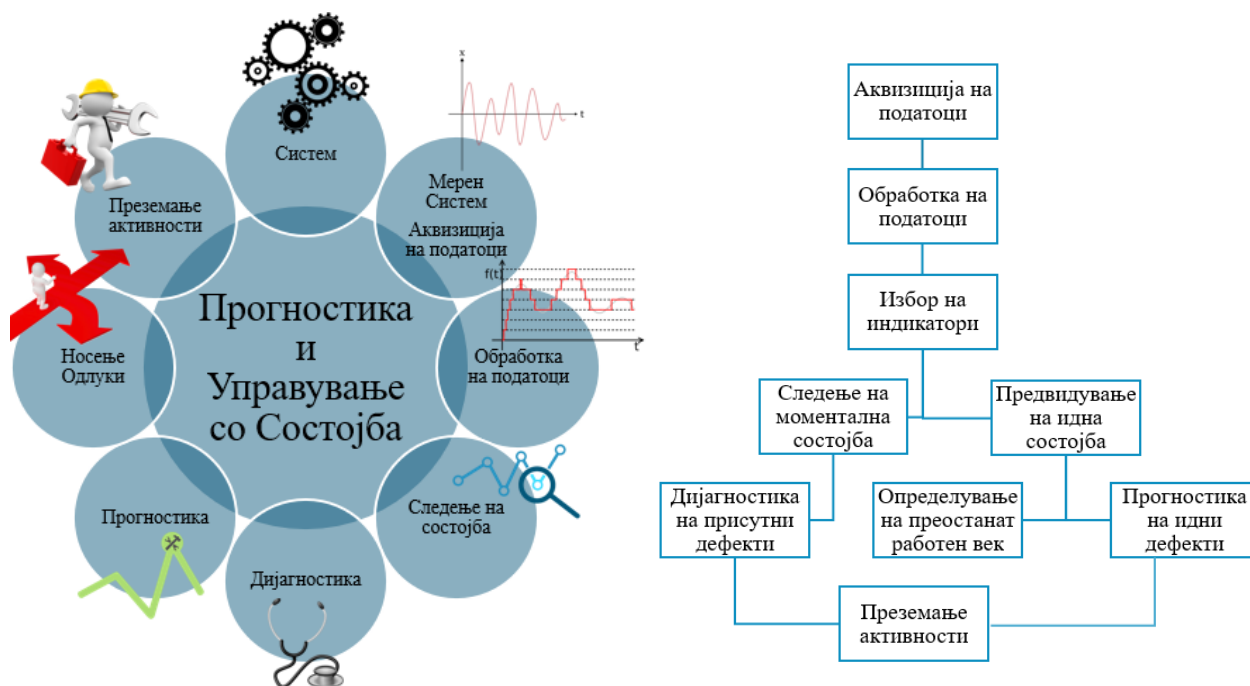


Слика 1. Стратегии за одржување и нивните главни карактеристики

Овие ефекти се особено значајни кај ротирачките машини, кои претставуваат една од најзастапените групи машини во индустриските системи. Во оваа група спаѓаат електромотори, пумпи, компресори, вентилатори, турбини, редуктори, генератори, вретена кај CNC машини и други машински системи кај кои основното движење е ротационо. Поради нивната континуирана работа, присуство во критични производствени процеси и изложеност на различни механички оптоварувања, дефектите кај овие машини може да предизвикаат значителни застои, дополнителни трошоци за поправка и намалена производствена ефикасност.

Оттука произлегува потребата од развој на методологии за автоматизирана дијагностика и прогностика на состојбата на ротирачките машини, кои ќе овозможат рано откривање на дефекти, проценка на преостанатиот корисен век и поддршка при донесување одлуки за одржување. Доколку се применат техниките на вештачката интелигенција, би се изградил робустен, ефикасен и економичен систем за одржување на современите производни системи. На тој начин би се овозможила обработка и анализа на голем број податоци, за што е возможно

пократок временски период. Преку автоматизација на процесот на дијагностика би се елиминирало субјективното мислење и евентуалната човечка грешка на дијагностичарот, особено при ситуации во кои истовремено се присутни поголем број дефекти. Дополнително, преку автоматизација на процесот на прогностика, се зголемува точноста при предвидувањето на состојбата на системот во идниот период и се овозможува навремено преземање на соодветни активности во насока на отстранување на причинителите на идни дефекти.



Слика 2. Активности во состав на дисциплината прогностика и управување со состојба

1.2 Мотивација за истражувањето

Современите производни барања наметнуваат потреба од машински системи кои се карактеризираат со висока доверливост и ефикасност. Затоа, инженерството и науката се во постојан развој на алатки за оптимизација на производствените системи со цел намалување на трошоците на крајниот производ, при истовремено задржување на неговиот висок квалитет. Способноста за прецизна дијагностика и предвидување на дефектите на машините е од суштинско значење за спречување на неочекувани дефекти, минимизирање на времето на застој во производството како и намалување на трошоците за нивно одржување. Традиционалните методи за спроведување на некоја од стратегиите за одржување, како што е анализата на вибрации, покажаа висока ефикасност во идентификувањето на изворот на постоечки дефекти како и прогностика на идни дефекти. Меѓутоа, сложеноста и обемот на податоци генерирани од модерните машински системи налага примена на понапредни аналитички методи. Потребата од ефикасен, доверлив, надежен и робустен систем за одржување на современите машински системи претставува мотив за креирање систем за автоматизирана дијагностика и прогностика, односно систем за автоматизација на активностите во состав на дисциплината прогностика и управување со состојба.

Развојот на системи базирани на вештачка интелигенција и нивна примена е предмет на интерес на научниците и истражувачите ширум светот. Примената на алгоритмите на машинското учење за дијагностика и прогностика на дефекти во машини резултира со

значително намалување на трошоците поради отстранувањето или минимизирањето на неочекуваното време на застој како и продолжување на животниот век на машините [7,8]. Дополнително, овие алгоритми може да послужат како основа за креирање на концептот на паметни фабрики доколку се применат за следење на состојбата на машините во реално време и прогностика на преостанатиот корисен век на машинските компоненти.

Примената на напредните техники базирани на вештачка интелигенција за автоматизиран вибрациско-дијагностички надзор и прогностика претставува мотивација за истражување на потенцијалот на алгоритмите на машинско учење за оптимизација на стратегиите за одржување. Подобрувањето на точноста при дијагностика и прогностика на дефекти која може да се постигне преку соодветно креирање, организација, обработка и анализа на базата на снимени сигнали, соодветен избор на екстрахирани карактеристики кои ја опишуваат суштината на сигналите, како и избор на оптимални алгоритми на машинско учење за класификација и прогностика претставува мотивација за истражување во оваа докторска дисертација.

За креирање на автоматизиран систем за вибрациско-дијагностички надзор и прогностика на ротирачки машини неопходна е база на податоци која се состои од вибрациони сигнали во временски домен, снимени при работа на машината во присуство на дефекти кои се предмет на интерес. Во оваа докторска дисертација ќе се применат повеќе бази на податоци снимени во експериментални и реални услови за тренинг, тестирање и валидација на креираниот систем за вибрациско-дијагностички надзор и прогностика на преостанатиот корисен век на компонентите на ротирачките машини. Процесот на тренирање и тестирање на точноста на системот ќе се изврши со примена на соодветно организирана база на податоци во која сигналите се соодветно поделени во поодделни групи на дефекти. За дијагностика ќе се користат бази на податоци снимени во присуство на најчестите дефекти кои се јавуваат кај ротирачките машини: дебаланс, нецентричност и дефекти на лежиштата. За прогностика на состојбата на ротирачките машини ќе се искористат бази на податоци кои се состојат од вибрациони сигнали снимени во подолг временски период, од вклучување на машината во работа во момент во кој нема присутен дефект, односно при нормална работа на машината, сè до моментот кога се појавува дефектот кој е предмет на интерес. Вибрационите сигнали имаат стохастична природа и не може да се користат директно во нивната оригинална снимена форма за опишување на промената на состојбата на анализираната машина. Поради тоа, пред нивна употреба како влез во алгоритмите на машинско учење, најпрво ќе се обработат применувајќи техники за обработка на дигитални сигнали а потоа ќе се екстрахираат најзначајните карактеристики кои го опишуваат сигналот, во временски и фреквентен домен [9-15]. Екстрахираните карактеристики ќе бидат организирани во облик на вектор на карактеристики со чија помош ќе се тренираат и тестираат алгоритмите за дијагностика и прогностика. При креирање на автоматизиран систем за вибрациско-дијагностички надзор и прогностика со надгледуван пристап на учење, за целите на оваа дисертација, ќе бидат искористени неколку алгоритми на надгледувано машинско учење кои даваат прецизни резултати при класификација и прогностика на дефекти согласно постоечката литература [15-18].

Креирањето автоматизиран систем за дијагностика и прогностика на ротирачки машини користејќи ја вештачката интелигенција претставува привлечно поле за научниците и инженерите со мотив да се намалат трошоците за одржување преку оптимизација на техниките кои се користат за спроведување на избраната стратегија на одржување и примена на истите во реалните производни системи.

1.3 Преглед на постоечка литература

Најпрво, детално беше прегледана и анализирана постоечката литература од областа вклучувајќи книги, трудови објавени во списанија и презентирани трудови на конференции, служејќи се со меѓународно признати бази на податоци. На тој начин продлабочено се проучи интердисциплинарната област како и современите напредоци во истата. Поодделно се проучија сите стратегии за одржување и можностите за нивна комбинација, при што се согледа дека, во минатото а најчесто и денес, во праксата се користат конвенционални методи за нивно спроведување. Меѓутоа, со цел исполнување на современите барања од производството, неопходна е оптимизација на стратегиите за одржување како и методите преку кои истите се спроведуваат. Во таа насока, базирајќи се на конвенционални методи како што е анализата на вибрации за дијагностика и прогностика на состојбата на машинските системи, во последните децении научниците интензивно ги истражуваат можностите за примена на методи за автоматизација на процесите преку кои се имплементира избраната стратегија за одржување. Следствено, и прегледот на постоечката литература е организиран во овие потесни области:

- Конвенционални методи за вибрациско-дијагностички надзор и прогностика на состојбата на машинските системи
- Методи за автоматизација на процесите на вибрациско-дијагностички надзор и прогностика на состојбата на машинските системи

1.3.1 Конвенционални методи за вибрациско-дијагностички надзор и прогностика на состојбата на машинските системи

Како што беше и претходно изнесено, со цел исполнување на барањата кои претстојат пред современото производство, при истовремено намалување на трошоците за одржување, се истражуваат можностите за креирање робустен, економичен и доверлив систем за одржување преку обединување на неколку стратегии. Така, со комбинација на двете стратегии одржување според состојба и предиктивно одржување се добива дисциплината прогностика и управување со состојбата на системите. Оваа дисциплина вклучува следење на моменталната состојба, како и предвидување на идната состојба и преостанатиот работен век на машинските системи врз база на параметри за кои се смета дека се доволно осетливи на промената на механичката состојба на системот, односно на појава на дефекти. Најдобар индикатор за целокупната моментална состојба на машинските системи и индикатор кој најрано може да ја открие појавата и развојот на извесни идни дефекти се вибрациите, табела 1 [3,19-21]. Најчести причини за појава на вибрации во машините се: дебаланс, нецентричност, резонанца, дефекти во лежишта, запченици, лопатки, ремени, макари, кавитација, таложeње на масло, турбуленција, вентили, триење и лабавост, фундаменти, торзиони вибрации, биeње [22]. Како предмет на анализа во оваа докторска дисертација се избрани дефектите кои согласно прегледаната литература најчесто се појавуваат во ротирачките машини, табела 2 [23]. Процентите прикажани во табелата претставуваат приближна фреквенција на појава на различни извори на вибрации кај индустриските ротирачки машини. Потребно е да се нагласи дека во реални работни услови честа е истовремена појава на повеќе извори на вибрации во рамки на истиот машински систем (на пример, дебаланс и нецентричност или дефект во лежиште и лабавост). Поради тоа, наведените проценти не претставуваат меѓусебно исклучиви категории и нивниот збир може да надмине 100 %.

Вибрациско-дијагностичкиот надзор подразбира идентификација и лоцирање на изворот на вибрации и нивна споредба со дозволените отстапувања на вибрационите параметри од нормираните вредности, а со тоа и на дефектите кои ги предизвикуваат тие вибрации.

Вибрационите мерења и анализи имаат посебно значење при дијагностика и прогностика бидејќи даваат голем број информации за состојбата на машините, како во моментот на мерење на вибрациите така и во определен иден период. На слика 3 даден е шематски приказ на основните чекори за обработка и анализа на вибрациониот сигнал по неговото мерење. Параметри кои се мерат се амплитуда, фреквенција и фазен агол на поместувањето, брзината и забрзувањето на вибрациите. Амплитудата ја дефинира големината на вибрациите и се користи како мерка за оптовареност на машината. Фреквенцијата е параметар кој се користи за вибрациско-дијагностички надзор затоа што таа ја покажува причината за појава на вибрациите. Насоката на векторот на вибрациите се дефинира со параметарот фазен агол и преку него се добиваат важни информации при вибрациско-дијагностички надзор на машините [22].

Врз основа на измерените параметри на вибрациите може да се определи состојбата на ротационите машини користејќи стандарди кои ги дефинираат нивните гранични вредности. За оценка на механичките вибрации, во сите стандарди е дадена граничната вредност на параметарот средно квадратна вредност на брзината на вибрации v_{rms} [mm/s] мерена во фреквентен опсег од 10 до 1000 Hz [22,24,25].

По мерењето на вибрационите сигнали се пресметува средно квадратната вредност на брзината на вибрациите v_{rms} и се споредува со граничната вредност од стандардот за соодветната машина, со што се оценува состојбата на машината. Доколку согласно искористениот стандард, механичките вибрации кои ги јавува машината се надвор од дозволеното поле, се пристапува кон вибрациона анализа и вибрациско-дијагностички надзор на состојбата на машината, односно детална дијагностика на машината. Деталната дијагностика се состои од две фази и тоа дијагностика на дефекти [13,15,16] и анализа на динамичко однесување на машината [26]. Дијагностиката на дефекти има за цел лоцирање на изворот на дефект и негово отстранување и како основна алатка ја користи фреквентната анализа [27-30]. Анализата на динамичкото однесување подразбира прогноза и планирање на идни застои и активности за отстранување на дефекти преку покомлексно следење на состојбата и развојот на можни идни дефекти [31-34].

Табела 1. Индикатори и најчести проблеми кај една ротирачка машина [3]

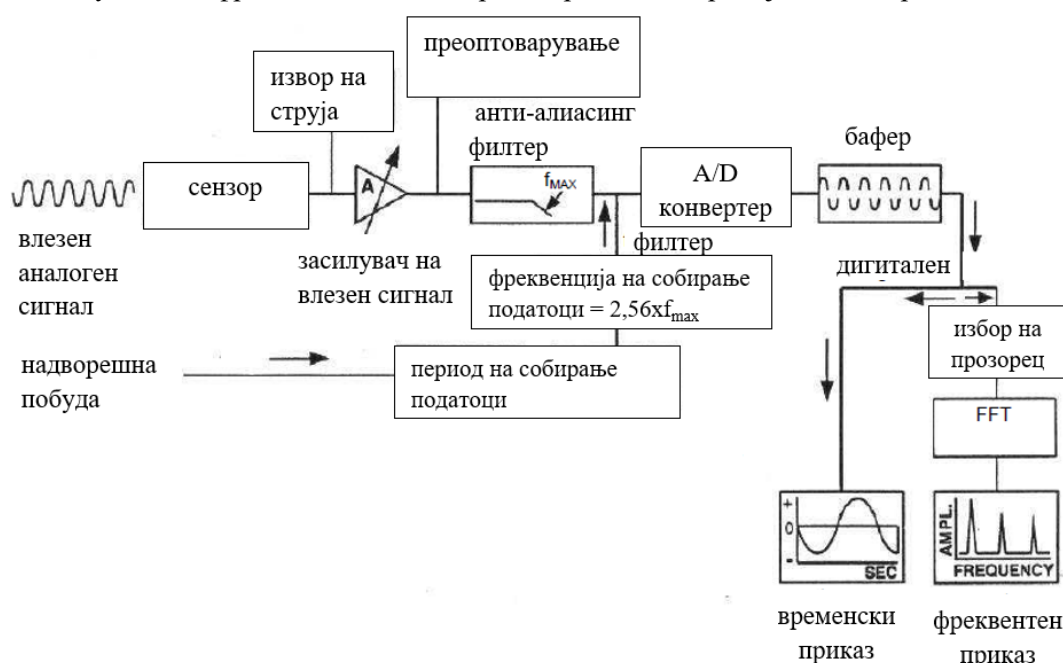
Тип на дефект	Температура	Притисок	Проток	Анализа на средство за подмачкување	Вибрации
Дебаланс					X
Ексцентричност	X				X
Оштетен елемент од тркалачко лежиште	X				X
Оштетен елемент од лизгачко лежиште	X	X	X	X	X
Оштетен запченик					X
Лабавост					X
Бучава					X
Лом					X

Табела 2. Приближна фреквенција на појава на најчестите извори на вибрации кај ротирачки машини [23]

Тип на дефект	Приближна фреквенција на појава	Тип на дефект	Приближна фреквенција на појава
Дебаланс	40%	Турбуленции во вентилатори	5%
Нецентричност	30%	Дефекти во запченици	2%
Резонанца	20%	Триење и лабавост	5%
Дефекти во лежишта	10%	Торзиони вибрации	3%
Вибрации од мотор	8%	Радијално биене	2%
Кавитација во пумпи	2%	Ремени и макари	4%

Измерените вибрациони сигнали се состојат од вибрации кои потекнуваат од повеќе компоненти од машината. Анализата на вибрации подразбира разложување на сигналот на неговите компоненти, односно единечни синусни или хармониски компоненти, користејќи ја Фуриевата трансформација. Секоја компонента на сигналот потекнува од определена компонента од машината. Фреквентната анализа и дефинирањето на дефектите како причинители на компонентите од снимените вибрациони сигнали на машината се спроведува во две фази:

- Креирање мерен систем, мерење на вибрационите сигнали и анализа на вибрациите и генерирање нивни фреквентен спектар,
- Толкување на фреквентниот спектар од страна на вибродиагностичар.



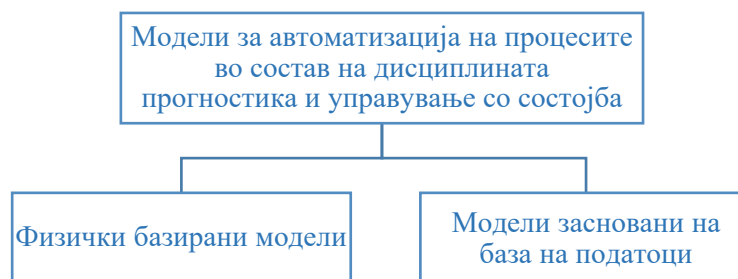
Слика 3. Шематски приказ на основните чекори при мерење, обработка и анализа на вибрационите сигнали

Анализата на вибрации е неинвазивен метод кој овозможува дијагностика на машини во реално време, без застои во производството. Дополнително, овозможува прогностика односно препознавање рани знаци за појава на потенцијални идни дефекти, овозможувајќи превентивно

одржување и намалување на непланираните застои. Меѓутоа, при реализација на дијагностиката и прогностиката од страна на вибродијагностичар, точноста на процесот е детерминирана од неговото знаење, искуство и субјективно расудување. Исто така, како што беше претходно изнесено, современото производство наметнува потреба од обработка и анализа на голем број податоци, за што е возможно пократок временски период. Со други зборови, неопходна е автоматизација на процесот на следење на состојбата, идентификација на моменталните дефекти на машинскиот систем и прогностика на идни дефекти.

1.3.2 Методи за автоматизација на процесите на вибрациско-дијагностички надзор и прогностика на состојбата на машинските системи

Како што беше и претходно изнесено, дисциплината прогностика и управување со состојбата на машинските системи вклучува процеси на дијагностички надзор и прогностика. Методите за автоматизација на процесите на вибрациско-дијагностички надзор и прогностика на состојбата на ротирачките машини, користат модели кои генерално може да се поделат во две големи групи [35] физички базирани модели и модели засновани на база на податоци, слика 4.



Слика 4. Поделба на моделите за автоматизација на процесите во состав на дисциплината прогностика и управување со состојба

Физички базираните модели ја проценуваат моменталната состојба на системот со решавање на збир на равенки базирани на закони од теоретската физика, инженерството и науката и може да се користат за дијагностика и прогностика [36,37]. Овој метод се заснова на креирање на математички модели кои ја опишуваат динамиката, однесувањето и деградацијата на системот. Дополнително, користи и релативно мала база на податоци составена од измерени вредности на избрани значајни индикатори, која е неопходна за определување на параметрите кои се специфични за разгледуваниот систем, како и за валидација на математичките модели. Најпрво, неопходно е дефинирање на референтните вредности на избраните значајни индикатори за избраниот систем во момент кога работи без дефекти. Преку споредба на добиениот одзив од физички базираните модели и измерените вредности за избраните индикатори со нивните референтни вредности, може да се открие присуство на моментални дефекти, развој на идни дефекти или да се определи преостанатиот корисен животен век на компонентите на системот. Најголемата предност при нивна примена е тоа што штом моделот е еднаш развиен, може повторно да се користи за различни системи со соодветно подесување на неговите параметри. Моделите се валидираат со компаративна анализа спроведена при различни работни услови, користејќи измерени вредности за индикаторите кои се предмет на интерес. Меѓутоа, развојот на математички модел бара темелно разбирање на системот, бидејќи доколку некој физички феномен е пропуштен, тогаш тоа може да доведе до грешка во идентификацијата или предвидувањето на некој дефект. Во ова истражување, извршен е преглед на литературата во областа на дијагностика и прогностика базирана на физички модели кои ги користат параметрите на вибрационите сигнали за предвидување на моменталната и идната состојба на системот и определување на корисниот работен век на неговите компоненти. И покрај споменатите предизвици, особено во фазата на математичко моделирање на системите, бројни научници

истражувале и дале свој придонес во ова поле [38]. Научниците и истражувачите користат најразлични теоретски основи и усвоени поедноставувања на реалните системи за дефинирање на физички базирани модели, како во областа на дијагностика [39-46], така и во областа на прогностика [39,46-61].

Физички базирани модели се карактеризираат и со бројни ограничувања, кои се особено изразени при моделирање на сложени системи. Времето за калкулација на решенијата на физички базирани модели е долго дури и при примена на софтверски апликации. Дополнително, често е неопходно итеративно повторување на калкулациите сè со цел извршување на стохастичка анализа. Другото ограничување се однесува на усвоените претпоставки и поедноставувања на физички базираните модели во однос на реалниот систем. Точноста на моделот се намалува кога работи во домен кој не бил опфатен во моделот како резултат на неговото поедноставување. Ефектите од овие ограничувања може да се намалат со имплементирање на вториот тип на модели, односно модели засновани на база на податоци за вибрациско-дијагностички надзор и прогностика на состојбата на ротирачките машини.

Генерираните вибрациони сигнали од ротирачките машини се мерат со помош на инструменти за мерење вибрации и истите најчесто се во временски домен [62]. Генерално, измерените сигнали се состојат од голем број сигнали од неколку извори на вибрации во ротирачката машина и одреден шум во позадина. Затоа, најпрво мора да се изврши анализа на сигналите, филтрирање и екстракција на важните карактеристики на сигналот. Постојат бројни техники за екстракција на карактеристики во временскиот домен во облик на статистички параметри или во фреквентниот домен како карактеристики на фреквентниот спектар.

Така обработените податоци потоа може да се искористат како влезен параметар во алгоритмите на машинско учење кои служат за препознавање, класификација и прогностика на дефекти со цел категоризација на податочните сигнали во различни класи на дефекти и препознавање можност за појава на идни дефекти. Од голема значајност е тоа што моделите засновани на база на податоци можат да препознаат, идентификуваат и класифицираат одреден дефект во ротирачките машини и во ситуации кога се присутни повеќе дефекти истовремено [63].

Научниците користат повеќе алгоритми на машинско учење за идентификација и класификација на дефекти кај ротирачки машини и тоа алгоритми на надгледувано машинско учење како алгоритам на машини со поддржувачки вектори (Support Vector Machine - SVM) [64-71], алгоритам на случајни шуми (Random Forest - RF) [12], алгоритам на k -најблиски соседи [10,73-76], наивен баесов алгоритам [77-80], алгоритам на градиентно зголемување (Gradient Boosting - GB) [81-85]. Исто така, бројни истражувачи комбинираат повеќе алгоритми на надгледувано машинско учење со цел зголемување на точноста и класификација на дефекти [12,86-88].

Во табела 3 даден е преглед на истражувања кои применуваат алгоритми на надгледувано машинско учење за класификација на дефекти кај машини, на која се прикажани анализираните дефекти и бројот на класи на дефекти, димензионалноста на векторот на влезни карактеристики односно бројот на екстрахирани карактеристики, типот на користен алгоритам, како и постигнатата точност при нивното тестирање со примена на соодветен критериум за евалуација.

Екстракцијата на карактеристики кои го опишуваат вибрациониот сигнал применувајќи обемна база на податоци е процес кој бара големо искуство и знаење. Затоа, техниките кои вршат автоматска екстракција на карактеристики како што е длабокото учење привлекуваат големо внимание во научниот свет. Техниката за длабоко учење користи специјализирани алгоритми и длабоки невронски мрежи кои екстрахираат карактеристики од вибрационите сигнали на

автоматизиран начин. Голем е бројот на истражувања се направени во областа на дијагностика на дефекти со примена на алгоритми на длабоко учење [10, 89-100].

Меѓутоа, и моделите засновани на база на податоци исто така се соочуваат со определени ограничувања, како на пример, потребата од големи бази на податоци за тренинг и ниската способност за генерализација. Со цел надминување на овие ограничувања и искористување на предностите од физички базираните модели и моделите засновани на база на податоци, во изминатите неколку години [101,102], се предлага нов метод во областа на вибрациско-дијагностички надзор на состојбата на ротирачки машини кој би претставувал своевиден хибрид на претходните две методи. И покрај фактот што во последната деценија е извршено интензивно проучување на моделите засновани на база на податоци и истите се имплементирани во областа на дијагностика на машините, ограничени напори се посветени во инкорпорирање на физичкото знаење во овие модели [103].

Научниците Sadoughi, M. и Hu, C. [104] се првите истражувачи кои предложиле нова методологија на конволуциска невронска мрежа базирана на физика (Physics-based Convolutional Neural Network - PCNN) за вибрациско-дијагностички надзор на ротирачки машини. Понатаму, истите автори [105] го продолжуваат своето истражување користејќи конволуциска невронска мрежа базирана на физика за дијагностика на дефекти на ротирачки машини, поконкретно на тркалачки лежишта. Создаден е модел на конволуциска невронска мрежа со конволуциски слој заснован на физиката на системот како прв слој за идентификација на дефекти во лежиштето. Применет физички базиран модел во првиот конволуциски слој е моделот на McFadden, P.D. и Smith, J.D. [44] кој ги дефинира вибрациите генерирани од дефект во една точка на внатрешниот прстен на тркалачко лежиште оптоварено со константно радијално оптоварување. Физички базираниот модел ги зема во предвид ефектите на геометријата на лежиштето, брзината на вратилото, распределбата на оптоварувањето на лежиштето, преносната функција и експоненцијалното придушување на вибрациите. Lu, H., Sadoughi, M. и други [106] претставуваат нов метод за екстракција на важните карактеристики на сигналот заснован на физика (PFW) кој покрај пресметаниот тежински фактор врз основа на базата на податоци ги користи и карактеристичките фреквенции на најчестите дефекти на едно тркалачко лежиште. На тој начин PFW методот врши екстракција на оние карактеристики на вибрациите кои во себе содржат значајни информации поврзани со присутните дефекти. Shen, S., Lu, H. и други [107] ја споредуваат точноста на конволуциската невронска мрежа базирана на физика со точноста на алгоритмот на машини со поддржувачки вектори, алгоритмот на случајни шуми и алгоритмот на конволуциски невронски мрежи (Convolutional Neural Network - CNN) при класификација на дефекти на тркалачки лежишта.

Во областа на автоматизација на процесот на прогностика на машинските системи, најголем дел од истражувањата користат модели засновани на база на податоци. За примена на овој метод неопходна е база на податоци снимена во подолг временски период односно од момент кога системот работи без дефекти сè до моментот на појавување на определен дефект. Во литературата применети се разни алгоритми на надгледувано машинско учење [108-116] и длабоко учење [117-124] за откривање на трендови и поврзаност меѓу податоците со цел предвидување на преостанатиот корисен век и појава на потенцијални дефекти во системот.

Докторската дисертација ќе се фокусира на примената на алгоритмите базирани на надгледувано машинско учење за дијагностика и прогностика на ротирачки машини. Ќе бидат применети алгоритмите на надгледувано машинско учење поради неколку значајни предности кои ги имаат во однос на алгоритмите на длабоко учење при решавање на проблем од оваа природа. Најпрво, овие алгоритми покажуваат задоволителни перформанси и при примена на помали бази на податоци. Алгоритмите на длабоко учење бараат големи бази на снимени

податоци, кои не секогаш се достапни во реални услови. Понатаму, алгоритмите на длабоко учење работат на принцип на црна кутија со што интерпретацијата на донесените одлуки не е секогаш јасна и интуитивна. Од друга страна, примената на алгоритмите базирани на надгледувано машинско учење обезбедува поголема транспарентност на самиот процес на донесување одлуки и овозможува примена на техники за екстракција и селекција на влезни карактеристики со што може дополнително да се подобрат нивните перформанси. Исто така, алгоритмите базирани на надгледувано машинско учење бараат помали компјутерски ресурси за тренинг, со што истите се попрактични за дијагностика и прогностика во реално време, што ги прави особено применливи при креирање на концептот на паметни фабрики.

Табела 3 дава преглед на неколку репрезентативни истражувања во кои се применети алгоритми на надгледувано машинско учење за дијагностика на дефекти кај ротирачки машини. Од прикажаните резултати може да се забележи дека бројот на разгледувани класи на дефекти се движи од две до четиринаесет класи, при што анализата е насочена кон идентификација на единечен дефект. Ваквиот пристап често не ја зема предвид комплексноста на реалните индустриски услови, каде е можно истовремено присуство на повеќе извори на вибрации во машинскиот систем. Исто така, бројот на екстрахирани карактеристики значително варира помеѓу различните истражувања, при што во сите истражувања алгоритмите на машинско учење се тренираат со карактеристики кои се екстрахирани директно од податоците, односно статистички и спектрални параметри добиени од вибрационите сигнали во временски и фреквентен домен. Притоа, се користат чисто податочни карактеристики, односно моделите ја учат поврзаноста меѓу влезните карактеристики и класите на дефекти врз основа на достапните експериментални податоци. Меѓутоа, ваквите модели често не ја користат информацијата која произлегува од физичките карактеристики на машинскиот систем.

Табела 3. Преглед на истражувања во областа на алгоритми за машинско учење за класификација на дефекти кај машини

Труд	Тип на дефекти и број на класи	Број на екстрахирани карактеристики	Алгоритам на надгледувано учење	Тип на валидација	Точност
[64]	Дебаланс и нецентричност (2 класи)	7 карактеристики	Машини со поддржувачки вектори	Крос-валидација со 10 преклопувања	96,7 %
[65]	Дебаланс, нецентричност, лабавост (3 класи)	61 карактеристика	Машини со поддржувачки вектори	Поделба на сет за тренинг и за тестирање 80/20 %	96 %
[66]	Дебаланс, нецентричност, триење, лабавост, дефекти во лежишта и запчаници (14 класи)	240 карактеристики	Машини со поддржувачки вектори	Крос-валидација	98 %

[67]	Дефекти во лежишта (4 класи)	18 карактеристики	Машини со поддржувачки вектори	Крос- валидација	97,5 %
[68]	Дефекти во лежишта (4 класи)	24 карактеристики	Машини со поддржувачки вектори	Крос- валидација 70/30 %	98,2 %
[69]	Дефекти во лежишта (6 класи)	30 карактеристики	Машини со поддржувачки вектори	Крос- валидација	96 %
[73]	Дефекти во ротирачки машини (4 класи)	30 карактеристики	Случајни шуми	Поделба на сет за тренинг и за тестирање	97 %
[75]	Дефекти во ротирачки машини (5 класи)	25 карактеристики	k-Најблиски Соседи	Поделба на сет за тренинг и за тестирање	95,6 %
[77]	Дефекти во лежишта (4 класи)	28 карактеристики	Наивен Баесов Алгоритам	Крос- валидација	95 %
[78]	Центрифугална пумпа – различни состојби (4 класи)	20 карактеристики	Наивен Баесов Алгоритам	Крос- валидација со 10 преклопувања	94 %
[80]	Индукциски мотор – дефекти во лежишта (3 класи)	40 карактеристики	Наивен Баесов алгоритам	Крос- валидација со 10 преклопувања	96,4 %
[81]	Дефекти во лежишта (4 класи)	≈ 50 карактеристики	Алгоритам на градиентно зголемување	Поделба на сет за тренинг и за тестирање	98,3 %
[82]	Дефекти во лежишта (5 класи)	36 карактеристики	Алгоритам на градиентно зголемување, Машини со поддржувачки вектори, Случајни шуми	Крос- валидација со 10 преклопувања	98,6 %, 97,3 %, 97,8 %

[84]	Ротирачки машини (6 класи)	50 карактеристики	Алгоритам на градиентно зголемување	Крос- валидација со 5 преклопувања	99,2 %
[85]	Дефекти во лежишта (5 класи)	≈ 60 карактеристики	Алгоритам на градиентно зголемување	Крос- валидација	98,7 %

Постигнатата точност во анализираниите трудови најчесто се движи во интервал од околу 96 % до 98 %, при што перформансите на моделите најчесто се евалуираат со примена на крос-валидација или со поделба на податоците на множества за тренинг и тестирање. Иако ваквите резултати укажуваат на висока способност на алгоритмите за класификација на дефекти, во повеќето случаи моделите се тренираат и тестираат на иста база на податоци, што може да ја ограничи проценката на нивната способност за генерализација при примена на нови податоци или различни работни услови.

Согласно прегледаната литература во оваа област, алгоритми на надгледувано машинско учење кои покажуваат релативно висока точност при дијагностика на дефекти на машини се алгоритмот на случајни шуми, алгоритмот на машини со поддржувачки вектори и алгоритмот на градиентно зголемување, па истите се искористени за креирање на систем за дијагностика на дефекти. Покрај нивната индивидуална примена, алгоритмите се споени во форма на комбинирани модели (Ensemble Model) при што на секој алгоритам му се доделува соодветен тежински фактор, во зависност од неговата постигната точност при тестирањето. Овој тежински систем овозможува оптимизирано донесување одлуки во фазата на валидација, со цел искористување на предностите на секој поединечен модел. При дијагностика односно класификација на дефекти, искористени се карактеристики кои се екстрахирани од искористената база на податоци, но и карактеристики кои произлегуваат од физиката на анализираниот ротирачка машина и од природата на присутните дефекти. На тој начин креиран е и хибриден модел за дијагностика трениран со примена на физички карактеристики и екстрахирани карактеристики од претходно обработената база на податоци. Понатаму, резултатите од хибридниите модели се споредени со резултатите од класичните, чисто податочни модели, врз основа на точноста постигната при тестирањето и при валидација со нов сет на карактеристики екстрахиран од сосема нова база на податоци. Така се оценува робустноста и способноста за генерализација на двата пристапи, со цел идентификација на соодветен метод за реална примена во вибрациско-дијагностички надзор на ротирачки машини.

Дополнително, во значителен број истражувања дијагностиката и прогностиката се разгледуваат како одделни истражувачки проблеми, при што трудовите најчесто се фокусираат или на класификација на дефекти или на предвидување на преостанатиот работен век на компонентите. Во рамки на оваа дисертација анализирани се двата аспекта на управување со состојбата на машинските системи, преку примена на алгоритми на надгледувано машинско учење за дијагностика на дефекти и за прогностика на деградацијата на компонентите.

Во делот на прогностика, применети се алгоритмот на случајни шуми и алгоритмот на машини со поддржувачки вектори за предвидување на кривите на преостанатиот работен век (RUL) на анализираниите лежишта. Предвидените криви се споредени со вистинските RUL криви со цел да се оцени точноста и стабилноста на моделите при долгорочна прогноза на деградацијата.

1.4 Предмет на истражување

Предмет на истражување во оваа докторска дисертација е примената на методите засновани на вештачка интелигенција, поконкретно алгоритмите на надгледувано машинско учење, за автоматизација на процесите на дијагностика и прогностика при имплементација на дисциплината прогностика и управување со состојбата како дел од системот за одржување на ротирачки машини, односно автоматизација на процесите на класификација на постоечки дефекти како и прогностика на преостанатиот корисен век на машинските компоненти, користејќи ги измерените вибрациони сигнали од анализираната машина.

Потребата од развој на робустен, економичен и доверлив систем за одржување на современите производни системи, кој со високо ниво на точност ќе овозможи препознавање и класификација на присутни дефекти, како и прогностика на преостанатиот корисен век на машинските компоненти, го поттикнува ова истражување. Особен акцент ќе биде ставен врз правилен избор и креирање на соодветни бази на измерени вибрациони сигнали од ротирачките машини и нивна обработка со цел добивање информации за нивната моментална и идна состојба. Со цел одговарање на конкретните потреби на ова истражување, ќе биде формирана и нова база на податоци во лабораториски услови и ќе биде изработен експериментален стол на кој ќе се мерат вибрационите сигнали предизвикани од најчестите дефекти кои се јавуваат кај ротационите машини. Предмет на интерес ќе биде и екстракцијата на значајни карактеристики кои ги опишуваат вибрационите сигнали, како и анализата на значајноста на физичките параметри кои произлегуваат од природата на динамичките процеси во машината при дијагностика. Неколку алгоритми на надгледувано машинско учење ќе бидат искористени и ќе се определи нивната точност при класификација на моментални дефекти, како и при прогностика на преостанатиот корисен век на машинските компоненти. Со цел валидација на креираните модели за дијагностика и прогностика, ќе се провери точноста при класификација и прогностика во случај кога како влез ќе бидат искористени, за нив, сосема непознати бази на податоци. На тој начин ќе се согледаат параметрите кои ја детерминираат нивната точност и истите ќе може да се искористат при креирање на систем за одржување применлив во паметните фабрики.

1.5 Цели на истражувањето

Пред да се пристапи кон детално дефинирање на чекорите на методологијата која ќе се применува во рамки на оваа докторска дисертација, потребно е да се дефинираат главните цели на дисертацијата. Основната цел на ова истражување е креирање робустен, економичен и доверлив систем за одржување на ротирачки машини. Применувајќи ги методите на вештачка интелигенција и техниките за дигитална обработка на податоци се очекува да се развие автоматизиран систем за одржување на ротирачки машини кој со висока точност ќе ги извршува активностите на дијагностика и прогностика во состав на дисциплината прогностика и управување со состојба на машините. Неколку клучни цели го предводат ова истражување и секоја придонесува за подобрување на точноста и ефикасноста на автоматизираниот систем за одржување.

Една од примарните цели на ова истражување е автоматизација на вибрациско-дијагностичкиот надзор, односно откривањето дефекти кај ротирачките машини преку анализа на вибрациите кои ги јавува машината. Конвенционалните методи за вибрациско-дијагностички надзор се реализираат мануелно од страна на дијагностичар и се потпираат на неговото знаење, искуство и субјективност и поради тоа одземаат многу време и може да бидат склони кон грешки. Покрај откривање на присутни дефекти, ова истражување исто така има за цел да даде свој

придонес во областа на прогностиката, фокусирајќи се на предвидување на преостанатиот корисен век на машинските компоненти. Процесот на прогностика е од суштинско значење при имплементирање на стратегиите за предиктивно одржување, кои имаат за цел да ги организираат активностите за одржување врз основа на реалната состојба на машините наместо да следат фиксни интервали. Со цел развој на автоматизиран систем за дијагностика и прогностика на дефекти ќе се применат методи базирани на вештачка интелигенција, поконкретно неколку алгоритми на надгледувано машинско учење. За тренинг на овие алгоритми ќе бидат искористени соодветни бази на вибрациони сигнали снимени во временски домен, кои во себе содржат информации за целокупната моментална и идна состојба на анализираните машински системи.

Втората клучна цел на ова истражување е усовршување на техниките за обработка на измерените вибрациони сигнали кои во оригинален облик се состојат од голем број сигнали кои потекнуваат од неколку извори на вибрации во ротирачката машина и одреден шум во позадина. Особено внимание ќе се посвети на развој на методологија за обработка на сигналите која ќе опфати поширок фреквентен спектар, со цел задржување на карактеристичните фреквенции за различни типови дефекти и по обработката на сигналите. Ова е особено важно бидејќи, на пример, дефектите од типот дебаланс и нецентричност се карактеризираат со енергетска содржина во нискофреквентниот опсег, додека дефектите во лежишта се карактеризираат со компоненти со високи фреквенции. Затоа, предизвик претставува обработката на сигналите на начин што ќе ги задржи сите значајни фреквентни информации, без некои да бидат отфрлени при процесот на филтрирање.

Следно, преку соодветни анализи ќе се изберат карактеристики во временски и фреквентен домен кои покажуваат највисоко ниво на значајност при дијагностика на моментални дефекти и прогностика на преостанатиот корисен век на машинските компоненти, со цел обезбедување соодветни влезови во алгоритмите на машинско учење. Неколку алгоритми на надгледувано машинско учење ќе бидат тестирани со цел добивање систем со што повисока точност при класификација на дефекти, односно предвидена крива на преостанат животен век на компонентите која ќе биде што е можно поблиска до реалната крива. За валидација на развиениот систем за одржување ќе бидат применети бази на податоци снимени во лабораториски и реални услови со цел понатамошно продлабочување на теоретските и апликативните цели во оваа област. Во таа насока, за потребите на ова истражување ќе се дизајнира и изработи симулатор на ротирачка машина со најчестите дефекти, и ќе се примени соодветна мерна опрема за вибрациони сигнали со цел креирање на база на податоци во експериментални услови за валидација на развиениот систем за одржување.

Ова истражување има за цел да даде свој придонес во развој на областа на автоматизација на процесите на вибрациско-дијагностички надзор и прогностика на состојбата на ротирачките машини при имплементација на дисциплината прогностика и управување со состојбата на системите преку дигитална обработка на вибрациони сигнали, нивна анализа и екстракција на карактеристики и примена на техники на надгледувано машинско учење. Целите што ќе ги достигне ова истражување претставуваат значаен чекор кон зголемување на доверливоста на машините, намалување на трошоците за одржување и подобрување на оперативната ефикасност во различни индустрии и отворање на можноста за примена на автоматизирани системи за одржување во концептот на паметни фабрики.

1.6 Хипотези на истражувањето

ХИПОТЕЗА 1: Примената на техники на надгледувано машинско учење за автоматизација на активностите на вибрациско-дијагностички надзор на состојбата на ротирачки машини при имплементација на дисциплината прогностика и управување со состојбата овозможува класификација на присутни дефекти со висок степен на точност.

ХИПОТЕЗА 2: Примената на техники на надгледувано машинско учење за автоматизација на активностите на прогностика на состојбата на ротирачки машини при имплементација на дисциплината прогностика и управување овозможува прецизно предвидување на преостанатиот корисен век на компонентите на ротирачките машини.

ХИПОТЕЗА 3: Методологијата за обработка на вибрационите сигнали и типот на екстрахирани карактеристики кои се користат за тренинг на алгоритмите за класификација и прогностика на дефекти ја детерминираат точноста и робустноста на развиениот автоматизиран систем за одржување.

1.7 Методологија на истражување

За остварување на поставените цели на истражувањето во состав на оваа докторска дисертација, реализарана е претходно дефинирана методологија која се состои од чекори кои вклучуваат теоретски и експериментални истражувања, во лабораториски и во реални услови:

- **Теоретски истражувања**

Како што беше изнесено и во точка 1.3 направена е анализа на постоечката литература во областа на вибрациско-дијагностички надзор и прогностика преку преглед на конвенционалните методи и методите за автоматизација, како и стандардите за оценка на моменталната и идната состојба на ротирачките машини и нивните критични компоненти.

Извршено е пребарување и избор на соодветни бази на податоци поделени во класи снимени во присуство на најчесто појавуваните дефекти кај ротирачки машини, кои се применети при тренинг и тестирање на моделите за дијагностика.

Извршено е пребарување и избор на соодветни бази на податоци снимени во подолг временски период на работа на ротирачките машини, од момент на нивно вклучување во работа кога нема присутен дефект, до момент во кој се појавува одреден дефект, кои се применети при тренинг и тестирање на моделите за прогностика.

- **Нумерички метод**

Базата на податоци за тренинг на алгоритмот за класификација на дефекти е соодветно подготвена во насока на: креирање и примена на методологија за балансирање на процентуалната застапеност на бројот на податоци во состав на поединечните класи, примена на методологија за дефинирање на соодветна фреквенција на семплирање на сигналите, примена на анти-алиасинг филтер и примена на методологија за пресметка на вистинската ротациона фреквенција при снимањето на сигналите.

Примената е методологија базирана на напредни методи за дигитална обработка на вибрационите сигнали од базата на податоци за тренинг на алгоритмите за класификација на дефекти. Поконкретно, применети се методи за обработка со цел филтрирање на сигналите во поширок фреквентен спектар и задржување на карактеристичните фреквенции (нискофреквентните и високофреквентните компоненти на сигналот) за различни типови

дефекти и по обработката на сигналите. Од така обработените сигнали екстрахирани се карактеристики (во временски и фреквентен домен) за тренинг на алгоритмите за класификација на дефекти за тренинг на модел заснован на база на податоци. Покрај екстрахираните карактеристики од базата на податоци, екстрахирани се и карактеристики кои произлегуваат од физиката на анализираната ротирачка машина и од природата на присутните дефекти за тренинг на хибриден модел за дијагностика на дефекти. Притоа, секоја карактеристика е екстрахирана од сигналот обработен со онаа методологија од која излезот покажува највисока чувствителност и значајност за идентификација на дефектите, со што се обезбедува поголема точност и робустност на развиениот дијагностички модел. За таа цел, дефинирани се повеќе паралелни методологии за обработка на сигналите, при што секоја група на карактеристики се екстрахира од оној сигнал кој покажува највисока чувствителност кон конкретниот дефект. На крајот, извршена е нормализација на амплитудите на екстрахираните карактеристики, како и проценка на нивото на значајност на различните групи на карактеристики во насока на дијагностика на дефекти.

Применети се следните алгоритми на надгледувано машинско учење: алгоритмот на случајни шуми, алгоритмот на машини со поддржувачки вектори и алгоритмот на градиентно зголемување за креирање на систем за дијагностика на дефекти. Покрај нивната индивидуална примена, извршено е и спојување на овие алгоритми во форма на комбинирани модели при што на секој алгоритам му се доделува соодветен тежински фактор, во зависност од постигнатата точност при тестирањето. Извршена е хиперпараметарска оптимизација на моделите со цел дополнително зголемување на точноста. Добиените резултати од хибридниот модел се споредени со резултатите од класичните, чисто податочни модели, врз основа на постигнатата точност согласно дефинираната техника за евалуација.

Развиена е и применета е методологија базирана на напредни методи за дигитална обработка на вибрационите сигнали од базата на податоци за тренинг на алгоритмите за прогностика на преостанат корисен век на машинските компоненти. Извршена е комбинација на две методи за дигитална обработка на сигнали: вејвлет трансформација (Wavelet Transform) и анализа на енvelopa.

Екстрахирани се карактеристики (во временски, фреквентен и временско-фреквентен домен) од подготвената и обработена база на податоци за тренинг на алгоритмите за прогностика на преостанат корисен век на машинските компоненти.

Применети се алгоритмот на машини со поддржувачки вектори и алгоритмот на случајни шуми за предвидување на преостанатиот работен век и извршена е нивна хиперпараметарска оптимизација. Избраните алгоритми се тренирани и тестирани со примена на вектори на екстрахирани карактеристики и извршена е компаративна анализа на точноста на креираните модели при што избран е оптимален алгоритам. Притоа, дефинирани се и избраните параметри за евалуација на перформансите на моделите.

Извршена е прогностика на кривата на преостанатиот корисен век на критичните компоненти на анализираната ротирачка машина и истата е споредена со вистинската крива на преостанатиот корисен век.

- **Експериментален метод**

Извршен е дизајн и изработка на симулатор на ротирачка машина на кој се снимени генерирани вибрациони сигнали при негова работа во присуство на најчесто појавуваните дефекти кај ротирачките машини.

Креиран е мерен систем и соодветна база на податоци снимена во лабораториски услови со цел примена на бази на податоци снимени во реални услови за валидација на креираните модели.

Обезбеден е пристап до база на податоци снимена во реални индустриски услови.

Креирана е и применета е методологија за обработка на снимените сигнали во лабораториски и реални услови.

Извршена е валидација на креираните модели за автоматизација на процесите во состав на дисциплината прогностика и управување со состојбата на дефекти кај ротирачки машини со примена на база на податоци измерена во реални и експериментални услови со цел нивна примена во концептот на паметни фабрики.

1.8 Придобивки од истражувањето

Современите барања наметнуваат потреба од оптимизација на стратегиите за одржување на производните системи како и на методите преку кои истите се спроведуваат. Во таа насока, базирајќи се на конвенционални методи како што е анализата на вибрации за дијагностика и прогностика на состојбата на машинските системи, се појавува потреба за истражување на можностите за примена на методи за автоматизација на процесите преку кои се имплементира избраната стратегија за одржување.

Истражувањето во состав на оваа докторска дисертација има потенцијал значително да ја унапреди примената на моделите засновани на база на податоци и техниките на вештачка интелигенција за автоматизација на процесите во состав на дисциплината прогностика и управување со состојбата, односно процесите на вибрациско-дијагностички надзор и прогностика на состојбата на ротирачки машини. Очекуваните придобивки вклучуваат развој на автоматизиран систем за одржување на ротирачки машини при што истражувањето има потенцијал да забележи свој придонес во областите на обработка и анализа на вибрациони сигнали, екстракција на карактеристики и тренинг на алгоритми на машинско учење.

Придобивките од автоматизирање на активностите во состав на дисциплината прогностика и управување со состојбата, односно процесите на вибрациско-дијагностички надзор и прогностика на состојбата на ротирачки машини се од големо значење за модерниот производен свет. Преку подобрување на точноста при откривањето на дефекти, се обезбедува навремена идентификација на дефекти, со што се спречуваат скапи поправки и ремонти и се намалува непланираното време за застој. Дополнително, автоматизацијата на дијагностичкиот процес ја отстранува субјективноста на дијагностичарот при идентификација на дефекти, што е особено значајно во ситуации кога се присутни повеќе дефекти истовремено. Автоматизацијата на процесот на прогностика нуди можности за одржување врз основа на реалната моментална состојба на машинските компоненти и определување на нивниот преостанат корисен животен век, што придонесува за оптимизација на распоредот за поправки, го продолжува животниот век на машините и ги намалува вкупните трошоци за одржување. Сето ова придонесува за значително подобрување на ефикасноста и продуктивноста на производните системи и намалување на трошоците за крајниот производ при истовремено задржување на високото ниво на квалитет. Изградбата на ваков автоматизиран систем за одржување може да послужи како основа за концептот на паметни фабрики доколку се примени за следење на состојбата на машините во реално време и прогностика на состојбата на машините во определен иден временски период.

1.9 Содржина на истражувањето

Воведното поглавје на оваа докторска дисертација ги прикажа мотивацијата, основната идеја и целите на истражувањето и ги претстави чекорите и методологијата за постигнување на тие цели, како и поставените хипотези на истражувањето. На почетокот беа наведени основните стратегии за одржување на еден систем со соодветните активности кои треба да се преземат при нивно спроведување, како и можностите за нивна автоматизација со примена на напредни методи базирани на вештачка интелигенција.

Како што беше и претходно изнесено, при креирање на автоматизиран систем за одржување кој користи алгоритми на машинско учење за дијагностика и прогностика на состојбата на машинските системи најпрво неопходно е обезбедување на соодветни бази на податоци. Второто поглавје е посветено токму на изборот на соодветни бази на податоци за тренинг и тестирање на алгоритмите на надгледувано машинско учење кои би служеле за дијагностика на состојбата на ротирачките машини. Даден е целосен опис на искористената база на податоци, начинот на нејзина организација како и искористениот мерен систем, при што детално е прикажана и методологијата за подготовка на влезните податоци.

Третото поглавје посветено е на екстракција на карактеристики од претходно подготвената база на податоци со цел добивање на вектор на карактеристики кој би се искористил за тренинг и тестирање на алгоритмите на надгледувано машинско учење кои би служеле за дијагностика на состојбата на ротирачките машини. Детално се претставени групите на карактеристики што се екстрахираат од подготвените сигнали, методологии за обработка на сигналите од кои истите се екстрахираат.

Четвртото поглавје посветено е на екстракцијата на карактеристики од подготвената и обработена база на податоци за тренинг за тренинг на модел заснован на база на податоци за класификација на присутни дефекти. Покрај екстрахираните карактеристики од базата на податоци, во рамки на ова поглавје се екстрахирани и карактеристики кои произлегуваат од физиката на анализираната ротирачка машина и од природата на присутните дефекти за тренинг на хибриден модел за дијагностика на дефекти. Во вториот дел на ова поглавје применети се и неколку алгоритми на надгледувано машинско учење за креирање на модели засновани на база на податоци и хибридни модели. Добиените резултати се споредени врз основа на постигнатата точност согласно дефинираната техника за евалуација и дефиниран е модел за вибрациско-дијагностички надзор со највисока точност при тестирање, кој натаму е и валидиран.

Во петтото поглавје извршена е валидација на развиениот класифицирачки модел кој претходно покажал највисока точност, со примена на за него непознати бази на податоци, односно база на податоци снимена во лабораториски услови и база на податоци снимена во реални услови. За потребите на ова истражување изработен е експериментален стол и креиран е мерен систем за креирање на база на податоци снимена во лабораториски услови, која би послужила за валидација на дијагностичките модели. Во рамки на ова поглавје повторно се опфатени фазите на организација, подготовка и обработка на податоците кои се применети за валидација.

Шестото поглавје насочено е кон развој на систем за прогностика на преостанатиот корисен век на одредени машински компоненти. Поголавјето започнува со избор на соодветна база на податоци, опис и обработка на базата на податоци, екстракција на вектор на карактеристики и примена на методи за намалување на димензионалноста на векторот на влезни карактеристики. Следно, така добиениот вектор на влезни карактеристики искористен е за тренинг и тестирање на алгоритми на машинско учење, а оној алгоритам постигнува највисока

точност при тестирањето, валидиран е со примена на за него претходно непозната база на податоци. Резултатите од ова поглавје вклучуваат споредба на предвидена крива на преостанатиот корисен век на машинските компоненти, во однос на реалната крива на нивниот преостанат корисен век, која е зададена како податок во самата база на податоци.

Седмото и последно поглавје во ова истражување дава преглед и анализа на добиените резултати. Врз база на генерираните резултати, изведени се заклучоци дали поставените хипотези во воведното поглавје ќе бидат прифатени или отфрлени. Поголавјето завршува со придобивките и применливоста на спроведеното истражување и заклучоците од добиените резултати, како и со насоки за идни продлабочени истражувања во овие области.

2. ИЗБОР И ПОДГОТОВКА НА БАЗА НА ПОДАТОЦИ ЗА ДИЈАГНОСТИЧКИ ЦЕЛИ

При креирање на автоматизиран систем за одржување, кој користи алгоритми на машинско или длабоко учење за дијагностика на состојбата на машинските системи, најпрво неопходно е обезбедување на соодветна база на податоци. Како што беше и претходно изнесено, влезните податоци во ова истражување се вибрационите сигнали добиени од анализираните ротирачки машини.

Изборот или креирањето на соодветна база на податоци претставува значаен чекор во развојот на модели кои се базираат на вибрациона анализа при дијагностика на состојбата на машинските системи. Квалитетот на измерените сигнали и нивото на успешност со кое тие го отсликуваат реалниот систем директно влијаат на точноста и доверливоста на автоматизираниот систем за одржување.

За тренинг и тестирање на алгоритмите на надгледувано машинско учење, базата на податоци мора да вклучува вибрациони сигнали снимени во целиот опсег на работни услови, во присуство на сите дефекти од интерес и при различни нивоа на изразеност на дефектите. Таквата разновидност е неопходна за креирање модели кои ќе се карактеризираат со висока точност при класификација и способност за генерализација при примена на нови, претходно непознати податоци.

Во ова истражување, во делот на дијагностика, ќе бидат анализирани најчестите дефекти кои се јавуваат кај ротирачки машини: дебаланс, нецентричност и дефекти во тркалачки лежишта. Разновидната и структурирана база на податоци овозможува подобра идентификација на различни типови дефекти и ја зголемува робушноста на дијагностичкиот систем.

Откако ќе се избере соодветна база на податоци за тренинг и тестирање на моделот за класификација на дефекти, потребно е истата да се подготви и да се изврши обработка на вибрационите сигнали со цел задржување на значајните информации. Подготовката на базата на податоци вклучува повеќе чекори кои зависат од нејзините карактеристики и структура. Притоа, особено внимание ќе се посвети на балансирањето на базата на податоци, нормализацијата на амплитудата на сигналите, како и дефинирањето на соодветна фреквенција на семплирање. Соодветно подготвената база на податоци обезбедува сигнали кои се погодни за понатамошна обработка и анализа. Обработката на податоците ќе опфати развој и примена на методи за дигитална обработка на вибрационите сигнали, со цел нивно филтрирање во поширок фреквентен спектар и задржување на карактеристичните фреквенции за различни типови дефекти. На тој начин ќе се обезбеди структурирана и информативна база на податоци, која ќе овозможи развој на робустен и прецизен дијагностички модел.


2.1 Опис на база на податоци за дијагностички цели

Податоците собрани од одреден тип на ротирачка машина не се секогаш применливи при анализа на друга машина или при различни работни услови, поради што изборот на соодветна база на податоци што ги одразува реалните услови е од суштинско значење.

За целите на ова истражување за тренинг и тестирање на моделите за дијагностика на дефекти, избрана е базата на податоци MaFaulda (Machine Fault Data) [125]. Во продолжение даден е детален опис на структурата на базата, искористениот мерен систем за нејзино креирање, како и карактеристиките на измерените сигнали.

Сигналите се измерени на SpectraQuest Machine Simulator [126], користејќи го комплетниот мерен систем кој е прикажан на слика 5, а на слика 6 даден е шематски приказ на димензиите на искористените тркалачки лежишта во состав на симулаторот. Во табела 4 дадени се техничките спецификации на симулаторот, додека во табела 5 дадени се спецификациите на акцелерометрите.

Во рамки на оваа база снимени се вибрациони сигнали во присуство на дебаланс, нецентричност и дефекти во тркалачките лежишта на ротирачката машина. Слика 5 ја прикажува структурата на симулаторот, кој се состои од електромотор поврзан преку спојка со вратило кое е поставено на две тркалачки лежишта, а на него се монтирани ротори со навојни отвори по обемот со цел симулација на различни нивоа на изразеност на дебаланс.



Слика 5. Комплетен мерен систем за генерирање на базата на податоци MaFaulda

При изведбата на експериментот за креирање на MaFaulda базата на податоци [127,128], контролирана е брзината на погонскиот мотор, што овозможува снимање на вибрациони сигнали при различни ротациони брзини на вратилото. За мерење на ротационата брзина на вратилото, искористен е тахометар кој генерира напон пропорционален на ротационата брзина на вратилото. Поконкретно како тахометар е искористен модулот MT-190 од Monarch Instrument, кој се состои од магнетен сензор за блискост и засилувач кој ги трансформира овие сигнали во импулси синхронизирани со ротацијата на вратилото. За подобро разбирање на базата на податоци, на слика 7 е прикажан измерениот сигнал од тахометарот во временски домен, при различни состојби на машината, при приближно еднаква влезна ротациона брзина.

Искористените акцелерометри се пиезоелектрични и работат на принцип на пиезоелектричен ефект, односно при изложување на пиезоелектричниот кристал, на механички напон, генерираат пропорционален електричен напон. Во овој процес, механичките вибрации се трансформираат во електричен напон и потоа се испраќаат и собираат во аквизиционата единица. Избраната база на податоци содржи сигнали измерени по три правци: аксијален, радијален и тангенцијален. Аксијалниот правец е паралелен со оската на ротација, радијален е оној од акцелерометарот кон центарот на вратилото (сигналите се измерени по вертикален правец) а


тангенцијалниот е поставен по правец на тангента на вратилото (сигналите се измерени по хоризонтален правец).

Табела 4. Спецификации на симулаторот SpectraQuest [125,126]

Параметар	Вредност	Мерна Единица
Моќност на DC Електромотор	¼	HP
Интервал на ротациони брзини на вратило	700-3600	rpm
Маса на симулаторот	22	kg
Дијаметар на дискови	152,4	mm
Дијаметар на вратило	16	mm
Должина на вратило	520	mm
Растојание помеѓу лежишта	390	mm
Спецификации на лежишта		
Број на топчиња	8	
Дијаметар на топчиња D_B	7,145	mm
Дијаметар на кафез D_C	28,519	mm
$D_P = D_C - D_B$	21,374	mm
Контактен агол φ	41,5	°

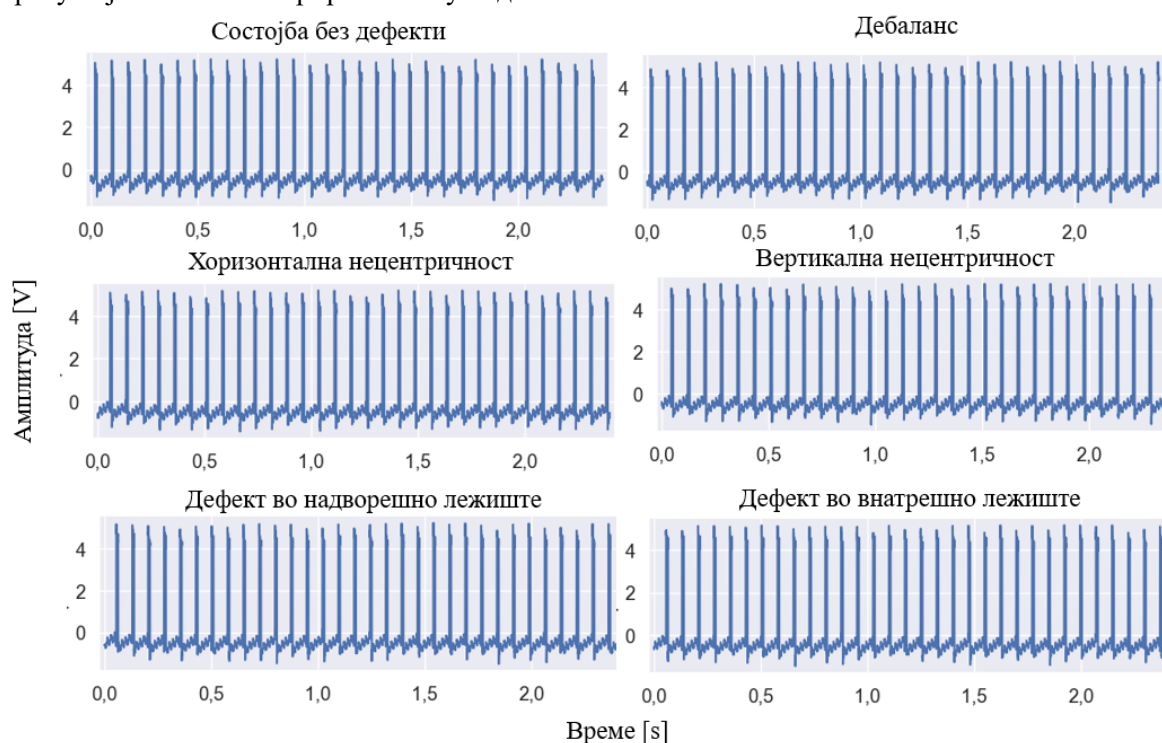
Табела 5. Спецификации на искористените акцелерометри за креирање на MaFaulda [125]

Параметар	Акцелерометри на внатрешно лежиште	Акцелерометар на надворешно лежиште
Модел	Три едноосни IMI 601A01	Еден триосен IMI 604B31
Осетливост	100 mV/g ±20% 10,2 mV / (m/s ²) ±20%	100 mV/g ±20% 10.2 mV / (m/s ²) ±20%
Опсег на фреквенција на семплирање	0,27-10.000 Hz ±3 dB	0,5-5.000 Hz ±3 dB
Опсег на мерење	±50 g (±490 m/s ²)	±50 g (±490 m/s ²)



Слика 6. Спецификации на тркалачки лежишта во состав на симулаторот SpectraQuest


Притоа, поставени се три едноосни акцелерометри на внатрешното лежиште, односно она кое е поставено помеѓу моторот и роторот, и еден триосен акцелерометар на надворешното лежиште, односно она кое е поставено на самиот крај на вратилото, со цел снимање вибрациони сигнали по трите оски. На пример, кај машини што се проверуваат на дефект во лежишта, препорачливо е мерење на вибрационите сигнали на секое лежиште посебно. На внатрешното лежиште е монтиран алуминиумски блок кој овозможува монтажа на трите едноосни акцелерометри со помош на навојна врска, додека триосни акцелерометар е поставен на надворешното лежиште со помош на магнет. Последниот сензор што е искористен е микрофон, преку кој е снимен генерираниот звук од машината.



Слика 7. Измерен сигнал од тахометарот во временски домен при различни работни услови на машината

Сите споменати сензори се поврзани со аквизиционата единица со цел пренос на снимените аналогни сигнали и нивна трансформација во дигитални сигнали. При креирање на оваа база на податоци искористена е аквизициона единица NI 9234 од National Instruments која има четири влезни канали и работи со фреквенција на семплирање до 51.2 kHz од канал. Искористени се две аквизициони единици за собирање на осум сигнали кои се поврзани на NI cDAQ 9178 картичка преку која се напојуваат и се поврзуваат со компјутерот преку УСБ врска. Компјутерот се користи за процесирање, приказ и снимање на сигналите. Авторите [127,128] ги конфигурирале измерените сигнали во софтверот NI LabVIEW и ги снимиле во облик на текстуални датотеки. Мерењата се извршени во времетраење од 5 секунди со фреквенција на семплирање примероци од 50 kHz, односно вкупно 250 000 примероци по сигнал. За секој тип на дефект, тестовите се направени при различни нивоа на изразеност на дефектот и при различни ротациони брзини на вратилото. При секое ниво на изразеност на дефектот, вибрационите сигнали се измерени при различни ротациони брзини, во опсегот од 700-3600 rpm, односно 11,7-60 Hz. Целата база на податоци се состои од 1951 датотеки и е една од пообемните бази на вибрациони сигнали генерирани од ротирачки машини која е достапна на интернет и е од отворен карактер.

На слика 8, со цел визуелизација на оваа база на податоци, како пример се прикажани измерени вибрациони сигнали од споменатите акцелерометри по трите оски, на двете лежишта при присутен дебаланс со додадена маса од 20 g и при ротациона брзина од 13,312 Hz.



Слика 8. Измерени сигнали од акцелерометрите во временски домен при присутен дебаланс во машината

(rad1-вибрационен сигнал по радијалната оска измерен на внатрешното лежиште
rad2- вибрационен сигнал по радијалната оска измерен на надворешното лежиште
tg1- вибрационен сигнал по тангенцијалната оска измерен на внатрешното лежиште
tg2- вибрационен сигнал по тангенцијалната оска измерен на надворешното лежиште
ax1- вибрационен сигнал по аксијалната оска измерен на внатрешното лежиште
ax2- вибрационен сигнал по аксијалната оска измерен на надворешното лежиште)

Секоја датотека е снимена во .csv формат (вредности одделени со заграда) и се состои од осум колони, каде во првата се внесени измерените податоци од тахометарот, во следните три колони измерените податоци од акцелерометрите поставени на внатрешното лежиште, потоа во следните три податоци од акцелерометарот поставен на надворешното лежиште и во осмата колони податоците од микрофонот.

Во ова истражување беа искористени снимените вибрациони сигнали при различните работни услови и во присуство на сите дефекти. Подетално, искористената база на податоци ги опфаќа следните работни услови и дефекти, табела 6:

- Нормална состојба во која нема присутен дефект при снимање на сигналите. Вкупно 49 датотеки се снимени при нормална состојба на машината при различни ротациони брзини на вратилото во интервал од 12,288 до 61,44 Hz.
- Дебаланс, при што сигналите се снимени во присуство на различни нивоа на изразеност на дефектот и со додадена маса од 6 g, 10 g, 15 g, 20 g, 25 g, 30 g и 35 g. При секое ниво на изразеност на дебалансот има од 44 до 49 датотеки, со вкупно 333 датотеки за целата класа на дефектот.
- Хоризонтална нецентричност, при што сигналите се снимени во присуство на различни нивоа на изразеност на дефектот и тоа 0,5 mm, 1,0 mm, 1,5 mm и 2,0 за повеќе ротациони брзини, односно вкупно 197 снимени датотеки во присуство на овој дефект.
- Вертикална нецентричност, при што сигналите се снимени во присуство на различни нивоа на изразеност на дефектот и тоа 0,51 mm, 0,63 mm, 1,27 mm, 1,40 mm, 1,78 mm, 1,90 за

различни ротациони брзини, односно вкупно 301 снимени датотеки во присуство на овој дефект.

- Дефекти во тркалачките лежишта, со тоа што и внатрешните и надворешните лежишта имаат три типа на дефекти и тоа оштетен кафез, оштетен надворешен прстен и оштетено топче и тоа снимени кога нема присутен дебаланс на роторот и при три нивоа на дебаланс на роторот, односно со додадена маса од 6 g, 20 g и 35 g, односно вкупно 558 снимени датотеки во присуство на дефекти кај внатрешното лежиште и 513 снимени датотеки во присуство на дефекти кај надворешното лежиште.

Табела 6. Организација на датотеките по поединечни класи на работни состојби и ниво на изразеност

*во табелата се означени и ознаките кои се користени во кодовите за секоја од состојбите

Дефект	Ниво на изразеност	Број на мерења	Вкупен број на мерења	
Нормална состојба (normal)		49	49	
Дебаланс (imbalance)	6 g	49	333	
	10 g	48		
	15 g	48		
	20 g	49		
	25 g	47		
	30 g	47		
Хоризонтална нецентричност (horizontal-misalignment)	35 g	45	197	
	0,5 mm	50		
	1,0 mm	49		
	1,5 mm	49		
	2,0 mm	49		
Вертикална нецентричност (vertical-misalignment)	0,51 mm	51	301	
	0,63 mm	50		
	1,27 mm	50		
	1,40 mm	50		
	1,78 mm	50		
Дефект на надворешно лежиште	1,90 mm	50	513	
	Дефект во кафез (overhang_cage_fault)	0 g		49
		6 g		49
		20 g		49
		35 g		41
	Дефект во надворешен прстен (overhang_outer_race)	0 g		49
		6 g		49
		20 g		49
		35 g		41
	Дефект во топчиња (overhang_ball_fault)	0 g		49
		6 g		43
		20 g		25
35 g		20		
Дефект на внатрешно лежиште	0 g	49	558	
	Дефект во кафез (underhang_cage_fault)	6 g		48
		20 g		49
		35 g		42
	Дефект во надворешен прстен (underhang_outer_race)	0 g		49
		6 g		49
		20 g		49
		35 g		37
	Дефект во топчиња (underhang_ball_fault)	0 g		50
		6 g		49
20 g		49		
	35 g	38		
Вкупен број на мерења			1951	

Базата на податоци MaFaulDa, која е јавно достапна [125], беше преземена и локално складирана со цел нејзина понатамошна обработка. Во Прилог А-1 прикажан е код за вчитување на метаподатоците за сигналите и дефинирање на ознаките за припадност на класите. Во оваа фаза не се вчитуваат самите измерени сигнали, туку само информациите потребни за нивна организација и понатамошна обработка.

Со цел правилно толкување и обработка на измерените вибрациони сигнали од базата на податоци, неопходно е нивната анализа да се врши и во фреквентен домен. Тоа подразбира примена на математички трансформации кои овозможуваат сигналите од временски да се претстават во фреквентен домен. Една од најкористените техники за оваа цел е брзата Фуриева трансформација (Fast Fourier Transform - FFT), чиј теоретски преглед е даден во следниот дел.

2.2 Фуриева трансформација

Фуриевата трансформација претставува фундаментален математички инструмент кој овозможува анализа на вибрационите сигнали во фреквентен домен. Таа е основа на современата вибрациона дијагностика бидејќи овозможува идентификација на карактеристични фреквенции кои произлегуваат од различни типови дефекти во ротирачките машини.

Во општ случај, Фуриевата трансформација врши декомпозиција на периодичен вибрационен сигнал $x(t)$ на поединечни синусни компоненти, при што секоја компонента има своја амплитуда и фреквенција. Периодичниот сигнал содржи фреквенции кои се цел број хармоници на основната фреквенција $f_0 = 1/T$, каде што T е периодот на сигналот, односно единствените фреквенции присутни во сигналот се $1/T, 2/T, \dots, n/T$. Фуриевата серија на периодичен сигнал $x(t)$ може да се претстави како линеарна комбинација на сите синусни и косинусни функции кои имаат ист период T (2.1):

$$x(t) = \frac{a_0}{2} + \sum_{n=1}^{\infty} [a_n \cdot \cos(n \cdot \omega \cdot t) + b_n \cdot \sin(n \cdot \omega \cdot t)] \quad \omega = \frac{2 \cdot \pi}{T} \quad (2.1)$$

a_n, b_n – Фуриеви или спектрални коефициенти кое може да се пресметаат со (2.2) и (2.3):

$$a_n = \frac{2}{T} \int_0^T x(t) \cdot \cos(n \cdot \omega \cdot t) dt \quad (2.2)$$

$$b_n = \frac{2}{T} \int_0^T x(t) \cdot \sin(n \cdot \omega \cdot t) dt \quad (2.3)$$

$$a_0 = \frac{1}{T} \int_0^T x(t) dt \quad (2.4)$$

ω – основна кружна фреквенција при период T .

При анализа на вибрациони сигнали, се претпоставува дека истите се периодични функции, што најчесто не е случај. Затоа, често се прави дискретизација на сигналот на N конечен број на временски примероци t_k ($k=1 \dots N$). Во тој случај може да се користи дискретната Фуриева трансформација која се дефинира преку следниот израз (2.5):

$$x(t_k) = \frac{a_0}{2} + \sum_{n=1}^{N/2} \left[a_n \cdot \cos\left(n \cdot \frac{2 \cdot \pi}{T} \cdot t_k\right) + b_n \cdot \sin\left(n \cdot \frac{2 \cdot \pi}{T} \cdot t_k\right) \right] \quad (2.5)$$

За пресметка на дискретната Фуриева трансформација со висока ефикасност, се користи алгоритам наречен брза Фуриева трансформација.

При дијагностика на ротирачки машини и анализа на вибрациони сигнали се користи алгоритмот на брза Фуриева трансформација, со цел приказ на вибрациониот сигнал во

фреквентен домен и анализа на неговиот фреквентен спектар што овозможува идентификација на градбените компоненти на иницијалниот сигнал.

Примената на FFT овозможува брза и прецизна идентификација на доминантните фреквентни компоненти во сигналите. Ова претставува клучен чекор во процесот на анализа на сигналот измерен со тахометар, преку кој се определува основната ротациона фреквенција на вратилото. Во следното поглавје детално ќе биде прикажана применетата методологија за определување на ротационата брзина на вратилото со помош на сигналот измерен со тахометар.

2.3 Ротациона брзина на вратилото


За да се овозможи правилна анализа и интерпретација на вибрационите сигнали, неопходна е соодветна обработка на сигналот снимен со тахометарот, кој претставува основа за определување на ротационата брзина на вратилото.

Базата на вибрациони сигнали е снимена при определен опсег на ротациони брзини на вратилото при сите состојби на машината. Доколку ваквите работни услови не се земат во предвид како променлив влезен параметар, истите ќе доведат до неточност на моделот при дијагностика на дефекти. Поконкретно, варијациите во ротационата брзина може да бидат протолкувани како абнормални податоци од страна на моделот и истиот може да идентификува присутен дефект во машината во случај кога во реалноста и нема присутен дефект. Поради тоа, во мерниот систем е вклучен и тахометар како сензор кој би обезбедил доволно податоци со цел креирање на робустен модел за дијагностика на дефекти при променливи работни услови. Дополнително, бидејќи ротационата брзина е еден од првите параметри што покажуваат промена при појава на дефект, нејзиното точно определување претставува неопходен предуслов за екстракција на значајни карактеристики од сигналите и за правилна идентификација на состојбата на машината.

Ротационата брзина на вратилото се определува со примена на снимениот сигнал од тахометарот и предложениот метод од истражувачите [129-131]. Сигналот од тахометарот е снимен во временски домен и најпрво со примена на брза Фуриева трансформација (FFT) истиот се трансформира во фреквентен домен. Примената на FFT овозможува идентификација на доминантната фреквентна компонента во сигналот, која одговара на основната ротациона фреквенција на вратилото. На овој начин, од временски сигнал што претставува серија на пулсови добиени од тахометарот, се добива фреквентен спектар во кој највисокиот пик ја претставува ротационата фреквенција. Со цел попрецизно определување на оваа фреквенција и елиминирање на можни лажни пикови, применета е дополнителна процедура на анализа на спектарот [129-131].

Следно, анализирајќи го фреквентниот спектар на сигналот од тахометарот, се определува фреквенцијата при која се јавува врвна вредност во спектарот (s_a). Откако ќе се определи оваа фреквенција, вредностите на амплитудите во интервалот на фреквенции $(s_a - 3) \leq s \leq (s_a + 3)$ во спектарот се анулираат. Причината за ова е присуството на дефект кај машините кој во некој случаи може да придонесе за појава на врвни вредности во спектарот на сигналот на тахометарот кои содржат повеќе енергија отколку врвната вредност која се јавува при ротационата фреквенција. Оваа постапка се повторува четири пати со што се добиваат четири фреквенции при кои се јавува врвна вредност на амплитудата. Најниската фреквенција од овие четири фреквенции е ротационата фреквенција на вратилото f_r . На слика 9 е прикажан сигналот во временски домен кој е снимен со тахометарот. На прикажаниот пример може да се забележи дека врвните вредности на амплитудата се повторуваат после секоја ротација на вратилото, со период од 0,083 секунди. Доколку се анализира фреквентниот спектар на сигналот снимен со

тахометарот, врвните вредности на амплитудата се повторуваат со фреквенција еднаква на првата врвна вредност во спектарот на сигналот од тахометарот, слика 10. За прикажаниот сигнал на слика 10, кој е снимен при дефект на топчето на внатрешното лежиште и при присутен дебаланс со ниво на изразеност од 6 g, при ротациона брзина на вратилото од 786 rpm, вредноста на пресметаната ротациона фреквенција со примена на објаснетиот метод е 12,8 Hz.

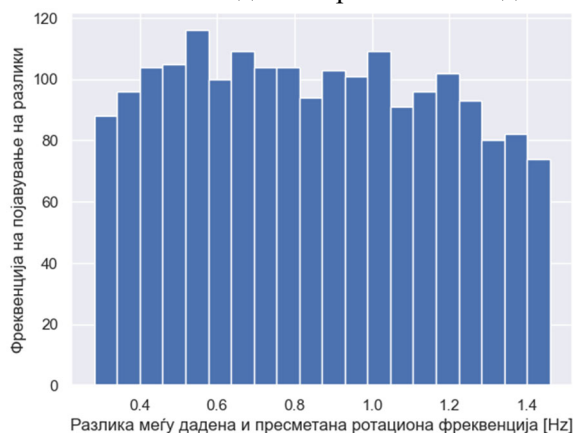


Слика 9. Измерен сигнал од тахометар во временски домен



Слика 10. Измерен сигнал од тахометар во фреквентен домен

Кодот за определување на ротационата фреквенција со примена на сигналот снимен со тахометарот е прикажан во Прилог А-2. На слика 11 даден е хистограм на разликите помеѓу дадените вредности за ротационата фреквенција во рамки на MaFaulda базата на податоци и пресметаните вредности за ротационата фреквенција, следејќи ја методологијата која е опишана во ова поглавје. Анализирајќи го хистограмот може да се заклучи дека вредноста на оваа разлика не надминува 1,5 Hz и фреквенцијата на појавување на разлики се намалува како што се зголемува вредноста на разликата. Согласно разгледаната литература [132] која отстапувањата до 2 Hz ги дефинира како незначителни за овие цели, може да се заклучи дека искористената методологија за пресметка на ротационата фреквенција дава вредности кои незначително се разликуваат од дадените и како такви може да се користат во следните анализи.




Слика 11. Хистограм на разлики помеѓу дадените вредности за ротационата фреквенција во рамки на MaFaulda базата на податоци и пресметаните вредности за ротационата фреквенција

2.4 Симулирани дефекти и нивни карактеристики

Машините се комплексни системи составени од повеќе компоненти кои ротираат или вршат транслација. Дури и наједноставните машини од динамичка гледна точка, може да се опишат како осцилаторни системи со повеќе концентрирани маси меѓусебно поврзани со еластични и елементи за пригушување. Кога машината е во работна состојба, подвижните делови создаваат динамички сили, а како резултат на тоа се појавуваат механички вибрации кои се пренесуваат на целата конструкција [22,133]. Кога машината е во добра состојба, нивоата на вибрации се ниски и константни, додека во случај на присутен дефект, вибрациите се интензивираат и снимениот сигнал има карактеристичен приказ кој соодветствува на присутниот дефект при кој е снимен. Во продолжение ќе бидат прикажани теоретските основи на анализираните дефекти во ова истражување, односно на дебаланс, нецентричност и дефекти во лежишта кај ротирачки машини и ќе биде даден приказ на стандардите кои се користат за проценка на состојбата на машините.

Во пракса, снимениот вибрационен сигнал во временски домен се трансформира во фреквентен домен со помош на алгоритмот на брза Фуриева трансформација и потоа се извршува фреквентна анализа на фреквентниот спектар на сигналот. Притоа, присуството на врвни вредности во фреквентниот спектар може да биде индикатор за присуство на определени дефекти во анализираната машина. Секој дефект кај ротирачките машини има свој карактеристичен фреквентен спектар според кој може да се открие, слика 12. Во продолжение детално ќе бидат објаснети карактеристичните спектри на дефектите кои се предмет на интерес во ова истражување, односно на дебаланс, нецентричност и дефекти во тркалачки лежишта.

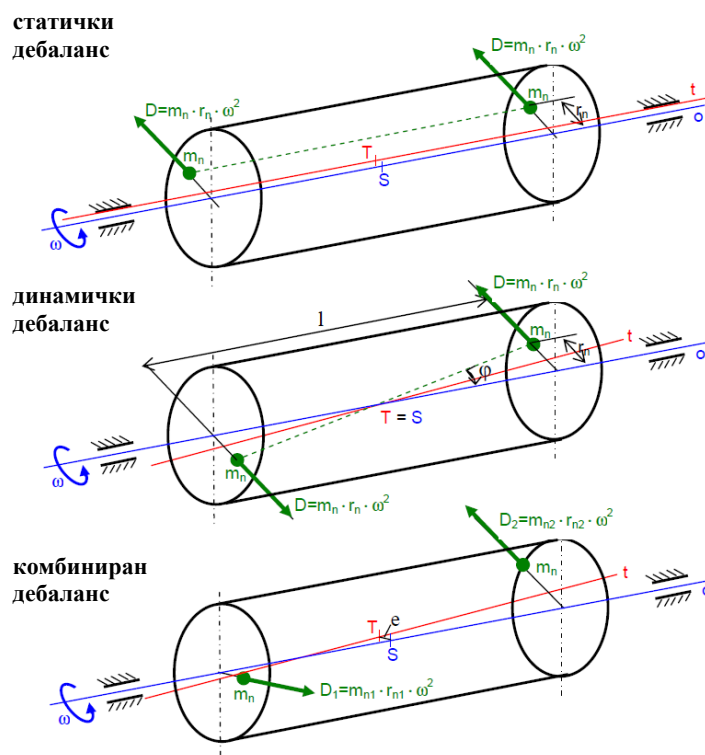


Слика 12. Принцип на Фуриева трансформација

2.4.1 Дебаланс


Вибрации предизвикани од дебаланс на роторот е најчестиот дефект кој се јавува кај ротирачките машини. Дебаланс постои кога главната оска на инерција и оската на ротација на роторот не се поклопуваат при што се појавува центрифугална сила која дејствува на роторот. Постојат три типа на дебаланс во зависност од тоа како е распределена масата на роторот и како

тоа ќе влијае на положбата на главната оска на инерција во однос на оската на ротација, слика 13, и тоа статички, динамички и комбиниран дебаланс.



Слика 13. Различни типови на дебаланс

При анализа на фреквентниот спектар на вибрационен сигнал снимен во присуство на дебаланс се забележува врвна вредност која се јавува точно при фреквенција еднаква на ротационата брзина и амплитуда пропорционална на нивото на изразеност на дебалансот, слика 14. Причината е што центрифугалната сила предизвикана од дебалансот ротира со фреквенција еднаква на ротационата брзина и предизвикува принудни вибрации со иста фреквенција. Оваа врвна вредност во фреквентниот спектар се појавува кај сигналите измерени по радијалниот и тангенцијалниот правец со фазна разлика од 90° помеѓу нив.




Слика 14. Карактеристичен фреквентен спектар за дебаланс (статички, динамички и комбиниран)

Во искористената база на податоци дефектот на роторот е симулиран со додавање маса преку монтирање завртки и подлошки на роторот, на кој се изработени навојни отвори токму за таа цел. Постепеното додавање на завртки и подлошки симулира дебаланс во вредности од 6, 10, 15, 20, 25, 30 и 35 g. Роторот со присутен статички дебаланс е позициониран симетрично помеѓу двете лежишта на симулаторот.

2.4.2 Нецентричност – во хоризонтален и во вертикален правец

Нецентричност се појавува кога вратилата на погонската и гонетата машина не лежат на иста оска. Една погонска и гонета машина имаат правилна центричност доколку отстапувањето на концентричност на нивните вратила, по целата нивна должина и при едно комплетно завртување е во рамки на дозволеното толерантно поле. На слика 15 прикажан е систем со правилна центричност и по хоризонтален и по вертикален правец; систем со паралелна нецентричност и систем со аголна нецентричност.




Слика 15. Типови на нецентричност

Во базата на податоци снимени се сигнали во присуство на два типа паралелна нецентричност и тоа по хоризонтален и по вертикален правец. За да се овозможи мерење на вибрациони сигнали во присуство на нецентричност како дефект, електромоторот и вратилото се споени со крута спојка. Хоризонталната нецентричност е предизвикана преку промена на позицијата на електромоторот и во овој случај е симулирана хоризонтална нецентричност од 0,5 mm, 1 mm, 1,5 mm и 2 mm. Вертикалната нецентричност е симулирана со монтирање на плочки со позната дебелина помеѓу електромоторот и неговата основа со што е симулирана вертикална нецентричност од 0,51 mm, 0,63 mm, 1,27 mm, 1,40 mm, 1,78 mm и 1,90 mm. Моделите за дијагностика на дефекти ќе ги идентификуваат хоризонталната и вертикалната нецентричност како две посебни состојби на ротирачката машина.

Нецентричност помеѓу оските на погонската и гонетата машина доведува до дејство на реактивни сили во лежиштата, вратилата и спојките што резултира со зголемена потрошувачка на енергија за погонување, појава на несакани вибрации и дополнително загревање на лежиштата и спојката.

На слика 16 се прикажани карактеристичните фреквентни спектри за аголна и паралелна нецентричност. Во фреквентниот спектар, паралелната нецентричност се карактеризира преку зголемени нивоа на вибрации на фреквенцијата која одговара на брзината на вратилото и на два пати поголема фреквенција од онаа која одговара на вратилото, и тоа по радијален правец. При присуство на аголна нецентричност врвна вредност се јавува на фреквенцијата која одговара

на брзината на вратилото, на два пати и на три пати поголема фреквенција од онаа која одговара на вратилото, и тоа по аксијален правец. И во двата случаи амплитудата е пропорционална на нивото на изразеност на нецентричноста. Овие карактеристики на фреквентниот спектар при присутна нецентричност се општи и може да варираат во зависност од типот и крутоста на спојката помеѓу користените вратила, брзината на ротација на вратилото и карактеристиките на машината.



Слика 16. Карактеристичен фреквентен спектар за нецентричност (аголна и паралелна)

Друг метод за детектирање на нецентричност е преку анализа на орбиталното движење на вратилото и за него се неопходни два сензори за блискост ортогонално поставени кои ќе го мерат поместувањето на вратилото. Избраната база на податоци не содржи такви сигнали, па затоа овој метод нема да биде користен во ова истражување.


2.4.3 Дефекти во тркалачки лежишта

Истражувањата покажуваат дека релативно висок процент на машински дефекти се јавуваат како резултат на дефекти во лежиштата [3] и затоа истите се дефинираат како критични компоненти кои можат да придонесат за големи застои во работата на машинските системи. Генерално, дефектите во лежиштата се развиваат и постепено прогресираат со што јавуваат соодветни вибрациони сигнали пред да откажат. Карактеристични дефекти кои прогресивно се зголемуваат се гребнатини, пукнатини, оштетувања, корозија или контаминација на надворешниот прстен, внатрешниот прстен или на топчињата. Дефектот може да се појави на некој од прстените, кафезот или топчињата и понатаму да се проширува и на другите компоненти од лежиштето. На слика 17 прикажани се основните елементи на едно тркалачко лежиште.

Во MaFaulda базата на податоци, снимени се вибрациони сигнали во присуство на три типа на дефекти во тркалачки лежишта: дефект во кафез, дефект во надворешниот прстен и дефект во топчињата. Во табела 4 дадени се техничките спецификации на тркалачките лежишта во употребениот симулатор. При снимање на сигналите, дефект е присутен само на внатрешното или само на надворешното лежиште, а не и на двете лежишта истовремено.

Дефектите во тркалачките лежишта се произраени при присутен дебаланс на роторот. Поради тоа, при креирање на MaFaulda базата на податоци и снимање на вибрационите сигнали кои ги јавува системот во присуство на лежишта со дефекти, истовремено е симулиран и дебаланс од 6g, 20g и 35g, и при состојба во која не е присутен дебаланс. При снимање на

вибрациите при присутен дефект кај надворешното лежиште и присутен дебаланс забележани се високи нивоа на вибрации поради што е оневозможена работа на системот при високи брзини на ротација на вратилото. Поради тоа, бројот на мерења во оваа конфигурација е помал споредено со останатите конфигурации.



Слика 17. Шематски приказ на основните елементи на едно тркалачко лежиште

При појава и развој на дефект кај тркалачките лежишта, истите генерираат фреквенции кои се карактеристични за присутниот дефект. Низ годините, изведени се голем број на формули за определување на фреквенциите кои се индикатор за присуство на одредени дефекти кај лежиштата. Кај тркалачките лежишта, генерално дефектите може да се поделат во четири групи зависно од тоа каде се појавува дефектот. За определување на фреквенциите на тие четири групи дефекти неопходно е познавање на геометријата на лежиштето, бројот на лежишта, табела 4, како и ротационата брзина на вратилото. Имајќи ги овие податоци и со примена на изразите (2.6) до (2.9) може да се пресметаат карактеристичните фреквенции за секоја од овие четири групи дефекти:

- Дефект на внатрешен прстен - BPF_I (Ball Pass Frequency Inner)

$$BPF_I = \frac{N}{2} \cdot \left(1 + \frac{D_B}{D_P} \cdot \cos\varphi \right) \cdot f_r \quad (2.6)$$

Кога дефектот е на внатрешниот прстен, во брановиот облик на сигналот во временски домен се јавува импулс секогаш кога внатрешниот прстен поминува над секој тркалачки елемент. Амплитудата на генерираниот импулс зависи од положбата на внатрешниот прстен во моментот кога ќе се случи ударот. Со други зборови, доколку дефектот на внатрешниот прстен во даден момент е во оптоварената зона на лежиштето, амплитудата ќе биде значително поголема отколку кога истиот дефект е во растоварената зона. Ова објаснува зошто фреквенциите на дефектите кај внатрешниот прстен се често опкружени со странични појаси во интервали со големина приближно еднаква на ротационата фреквенција. Според тоа нивната амплитуда е директно детерминирана од ротационата фреквенција.

- Дефект на надворешен прстен - BPF_O (Ball Pass Frequency Outer)

$$BPF_O = \frac{N}{2} \cdot \left(1 - \frac{D_B}{D_P} \cdot \cos\varphi \right) \cdot f_r = N \cdot FTF \quad (2.7)$$

Дефект на надворешниот прстен генерира импулс во брановиот облик на сигналот во временски домен секогаш кога тркалачкиот елемент поминува над дефектот и удира во него (во идеален случај импулсите се со иста големина).

- Дефект на тркалачки елемент - BSF (Ball Spin Frequency)

$$BSF = \frac{D_P}{2 \cdot D_B} \cdot \left(1 - \left(\frac{D_B}{D_P} \cdot \cos\varphi \right)^2 \right) \cdot f_r \quad (2.8)$$

Дефект на тркалачките елементи генерира импулс при секој контакт меѓу тркалачкиот елемент со присутен дефект и внатрешниот и надворешниот прстен. Големината на импулсот повторно зависи од тоа дали контактот се случил во оптоварената или растоварената зона на лежиштето.

- Дефект на кафез - FTF (Fundamental Train Frequency)

$$FTF = \frac{1}{2} \cdot \left(1 - \frac{D_B}{D_P} \cdot \cos\varphi \right) \cdot f_r \quad (2.9)$$

f_r – ротациона фреквенција [Hz]

N – број на тркалачки елементи

D_B – дијаметар на тркалачки елементи [mm]

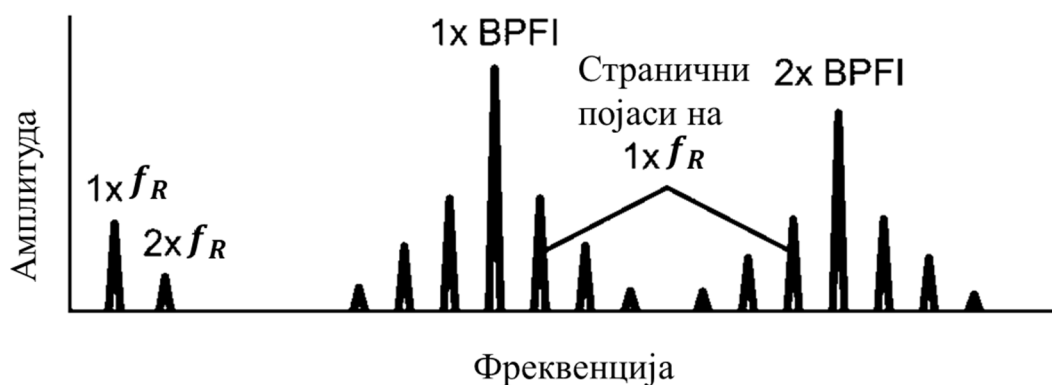
D_C - дијаметар на кафез [mm]

$D_P = D_C - D_B$ [mm]


φ – контактен агол [°]

При изведување на овие теоретски релации за тркалачките лежишта усвоено е дека не постои пролизгување и дека тркалачките елементи вршат чисто тркалање по површините на внатрешниот и надворешниот прстен. Во реални услови оваа претпоставка не е целосно исполнета, бидејќи поради низа фактори тркалачките елементи се движат со комбинација од тркалање и лизгање. Како последица на тоа, очекувано е одредено отстапување на реалните карактеристични фреквенции на дефектите од теоретски пресметаните вредности.

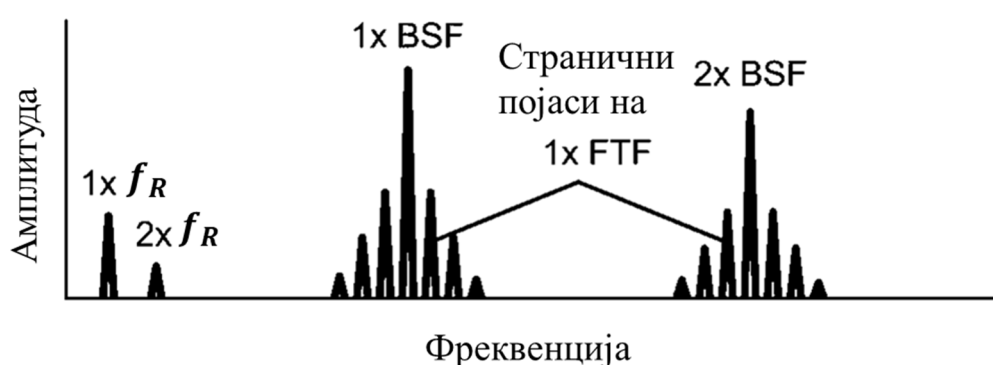
На слики 18-21 дадени се карактеристичните фреквентни спектари за сигнал снимен при присутен дефект на внатрешен прстен кај тркалачко лежиште (BPFI), при присутен дефект на надворешен прстен кај тркалачко лежиште (BPFO), при присутен дефект на тркалачки елемент кај тркалачко лежиште (BPF) и при присутен дефект на кафез кај тркалачко лежиште (FTF), соодветно.



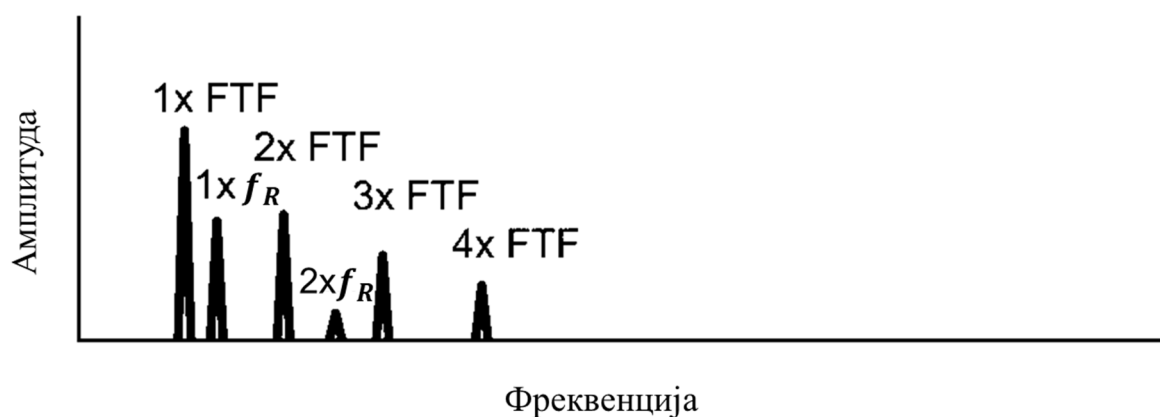
Слика 18. Карактеристичен фреквентен спектар за сигнал снимен при присутен дефект на внатрешен прстен кај тркалачко лежиште (BPFI)



Слика 19. Карактеристичен фреквентен спектар за сигнал снимен при присутен дефект на надворешен прстен кај тркалачко лежиште (BPFO)



Слика 20. Карактеристичен фреквентен спектар за сигнал снимен при присутен дефект на тркалачки елемент кај тркалачко лежиште (BSF)



Слика 21. Карактеристичен фреквентен спектар за сигнал снимен при присутен дефект на на кафез кај тркалачко лежиште (FTF)

Овие фреквенции на дефекти кај тркалачките лежишта се појавуваат само доколку конкретниот дефект е присутен, во спротивно не се присутни во спектарот. Често, врвна вредност на амплитудата се забележува на фреквенцијата која одговара на брзината на вратилото, меѓутоа тоа само по себе не е индикатор за присуство на дефект во лежитето. Потребно е да се потенцира дека фреквенциите на четирите групи дефекти кај тркалачките лежишта не се цел број пати поголеми од фреквенцијата која одговара на брзината на вратилото, односно не се хармоници на ротационата фреквенција.

Дополнително, во фреквентните спектри на сигналите снимени при дефект во тркалачките лежишта може да се појават и странични појаси (sidebands) како резултат на

амплитудна модулација на сигналите. Под модулација на сигнал се подразбира појава при која сигнал со ниска фреквенција (наречен модулациски сигнал) предизвикува периодична промена на амплитудата или фреквенцијата на сигнал со повисока фреквенција (наречен носечки сигнал). Кај тркалчките лежишта, локалните дефекти генерираат краткотрајни импулси кои возбуждаат високофреквентни структурни резонанци на системот лежиште–куќиште–акцелерометар, кои се разгледуваат како носечки сигнал. Амплитудата на овој резонантен одговор може дополнително да биде модулирана од нискофреквентните сигнали поврзани со ротационата динамика на системот, како што се гравитационата сила на вратилото или центрифугалната сила при присутен дебаланс. Како последица на оваа амплитудна модулација, во фреквентниот спектар се појавуваат странични фреквентни појаси околу карактеристичните дефектни фреквенции, најчесто на растојание еднакво на ротационата фреквенција на вратилото.

2.5 Примена на стандарди за проценка на состојба на машини

Откако се дефинирани и накратко опишани поединечните видови на симулираните дефекти и нивната теоретска основа, во овој дел ќе се изврши проценка на нивното влијание врз вибрационата состојба на машината според меѓународните стандарди за вибрациона состојба на ротирачки машини. Примената на пропишани стандарди е неопходна со цел унификација и конзистентност на процесите на дијагностика и прогностика на машинските системи преку мерење и анализа на вибрационите сигнали кои истите ги јавуваат. Најчесто применуван стандард за проценка на состојбата на ротационите машини е стандардот ISO 10816-1:1995 [134], кој денес е заменет со новата верзија ISO 20816-1:2016 [135]. Овој стандард се карактеризира со универзална применливост, односно може да послужи за проценка на состојбата на широк дијапазон ротирачки машини вклучувајќи пумпи, компресори, турбини и мотори. Користи систем за класификација кој вклучува различни големини на машини и работни услови, што го прави овој стандард применлива алатка во голем број индустрии. Исто така обезбедува јасна рамка за проценка на нивото на вибрации во четири зони (добра, задоволителна, незадоволителна и неприфатлива). Овие зони служат за проценка на нивоата на вибрации, односно служи при донесување одлука дали истите се прифатливи или неприфатливи и укажуваат на потенцијален дефект, нудејќи насоки за донесување одлуки. Табела 7 служи за проценка на состојбата на анализираната машина користејќи ја RMS (Root Mean Square) на амплитудата изразена во физичка величина брзина, поконкретно средно квадратна вредност на брзината на вибрации (v_{RMS}) која дефинира четири зони на состојба, во зависност од нејзината класа (I до IV класа).

Како што беше и претходно изнесено, при креирање на MaFaulda базата на податоци измерено е забрзувањето на вибрационите сигнали во текот на времето. Од друга страна, за оценка на механичките вибрации, во сите стандарди дадена е граничната вредност на параметарот средно квадратна вредност на брзината на вибрации v_{RMS} [mm/s] мерена во фреквентен опсег од 10 до 1000 Hz [22, 130, 131] кое е значајно подрачје за вибрациите на ротационите машини, слика 22. Поради тоа, пред примена на овие сигнали во дијагностички цели, потребно е истите да се трансформираат во физичка величина - брзина на вибрации. Забрзувањето на вибрационите сигнали може да се интегрира за да се добие брзината на сигналот по истата оска. Слика 22 покажува дека изразувањето на амплитудата на вибрациониот сигнал во физичка величина забрзување ги засилува високите фреквенции, а ги намалува ниските. Поради тоа, по интеграцијата, возможно е извитоперување на компонентите на сигналот со ниска фреквенција. За да се избегне доминација на компоненти со ниска фреквенција кои не постоеле во оригиналниот сигнал, пред интеграцијата се применува високопропусен Батерворт (Butterworth) филтер.

Табела 7. Проценка на состојба на ротирачки машини според стандард ISO 10816-1

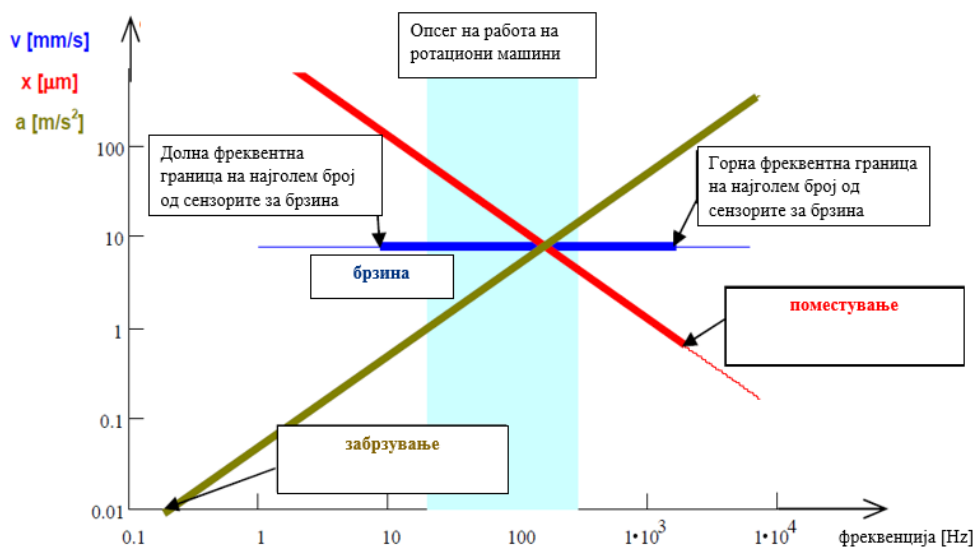
средно квадратна вредност на брзината на вибрации v_{RMS} [mm/s]		Класа на машина			
		I	II	III	IV
-	0,71				
0,71	1,12				добра состојба
1,12	1,8	задоволителна состојба			
1,8	2,8				незадоволителна состојба
2,8	4,5	незадоволителна состојба			
4,5	7,1				неприфатлива состојба
7,1	11,2	неприфатлива состојба			
11,2	18				неприфатлива состојба
18	-	неприфатлива состојба			

I класа на машини – мали машини со моќност до 15 kW

II класа на машини – средни машини со моќност до 15 до 75 kW без посебно финансирање

III класа на машини – големи машини на тешки фундаменти


IV класа на машини – големи и турбо машини со посебно финансирање



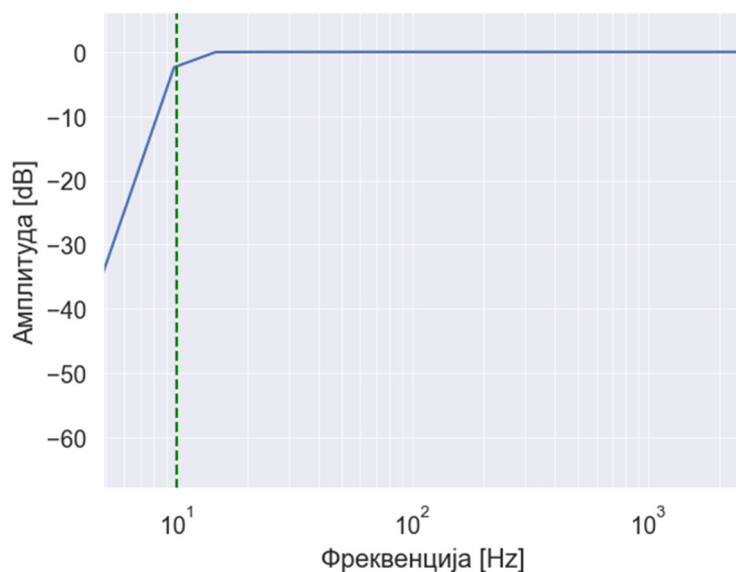
Слика 22. Амплитуда на вибрации изразена во поместување и забрзување соодветно на константна брзина од 7,6 mm/s

Филтерот на Батерворт се карактеризира со мазен одзив при сите фреквенции, а неговиот фреквентен одговор претставува функција која монотонно расте или монотонно опаѓа над дефинираната гранична фреквенција во зависност од тоа дали станува збор за високопропусен или нископропусен филтер. На слика 23 прикажани се фреквентните одговори на високопропусни филтри на Батерворт од 2ри, 4ти, 6ти и 8ми ред со гранична фреквенција од 10 Hz. Овој филтер има за задача да ги пропушти сите фреквенции повисоки од граничната фреквенција (во овој пример повисоки од 10 Hz). Стрмноста на фреквентниот одговор на филтерот е пропорционална со неговиот ред.

Дизајнираниот високопропусен Батерворт филтер за филтрирање на сигналите од MaFaulda има стрмност од 6-ти ред и ги пропушта фреквенциите со вредност еднаква или повисока од $1/3$ од ротационата фреквенција, а ги отстранува фреквенциите со пониска вредност од $1/3$ од ротационата фреквенција. На слика 24 прикажан е фреквентниот одговор на дизајнираниот високопропусен Батерворт филтер. На сликата може да се забележи намалување на амплитудата од приближно 3 dB при граничната фреквенција која во овој пример изнесува 16,25 Hz ($F_r/3$, $F_r=48,74$ Hz), што е карактеристика на филтерот на Батерворт.



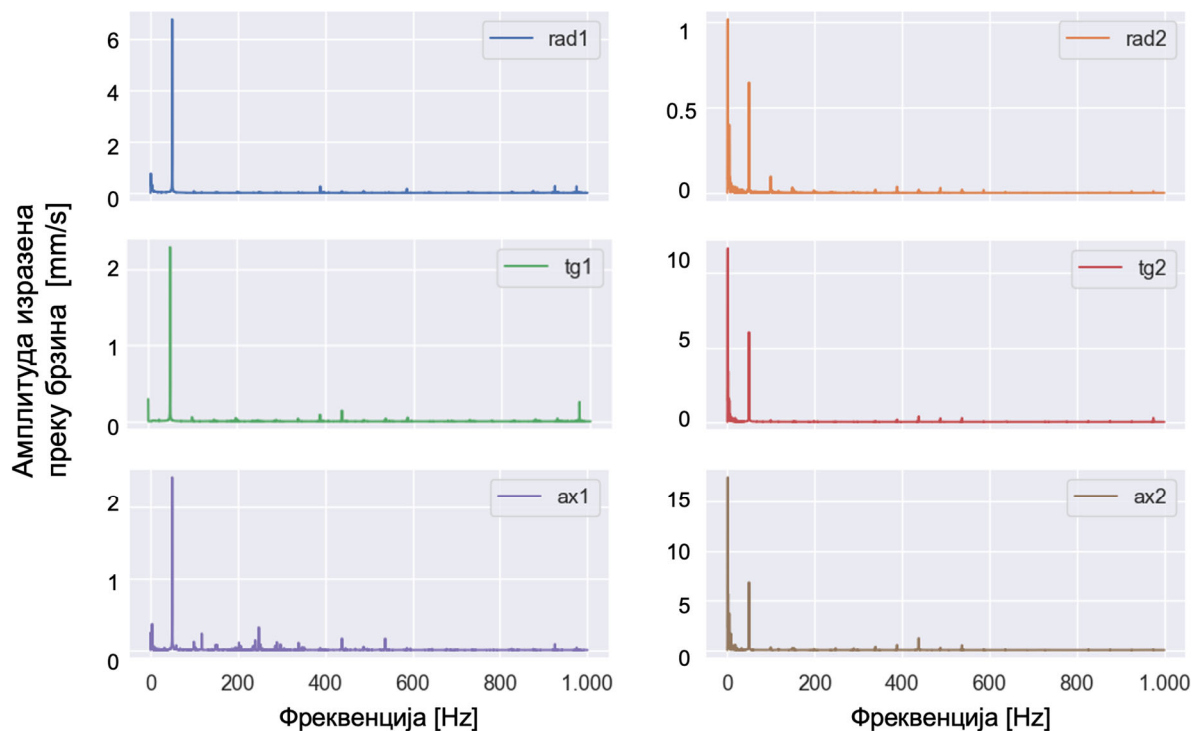
Слика 23. Фреквентен одговор на високопропусен Батерворт филтер (од 2ри, 4ти, 6ти и 8ми ред со гранична фреквенција од 10 Hz)



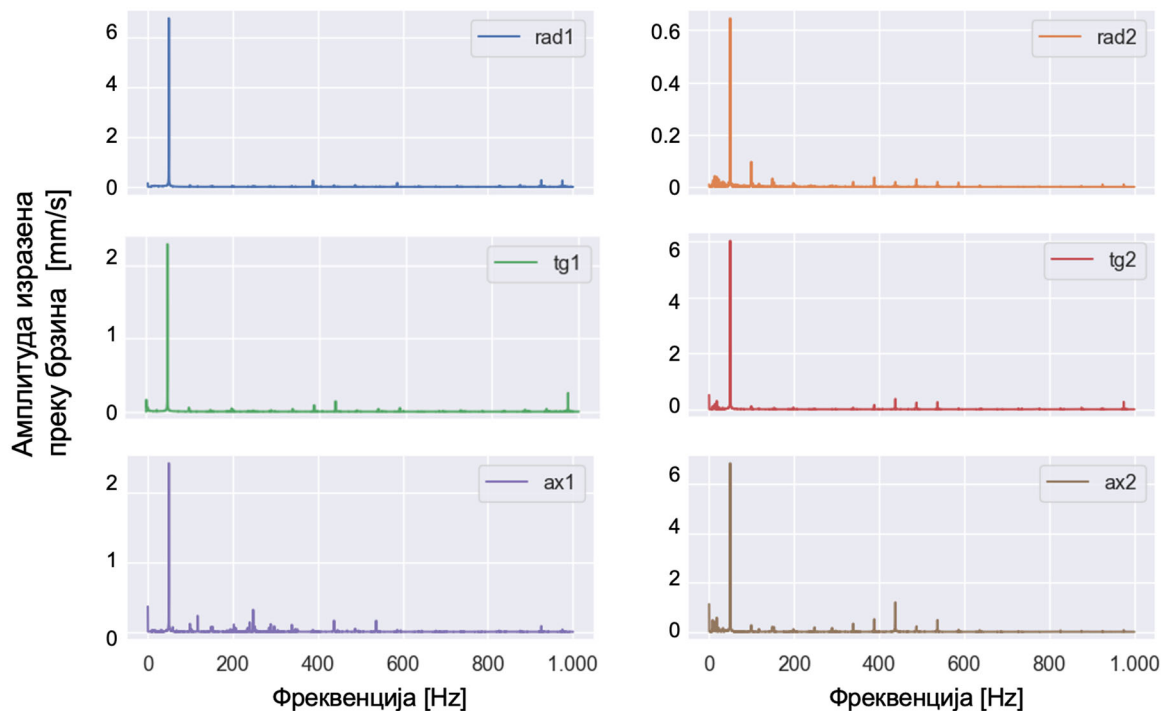
Слика 24. Фреквентен одговор на дизајнираниот високопропусен Батерворт филтер од 6ти ред со гранична фреквенција 16,25 Hz ($F_r/3$, $F_r=48,74$ Hz)

Ефективноста од примената на дизајнираниот високопропусен Батерворт филтер од 6ти ред е прикажана на слики 25 и 26. На слика 25 даден е фреквентниот спектар на сигналот по интеграцијата, без да се примени дизајнираниот филтер, а на слика 26 фреквентниот спектар на сигналот по интеграција и по примена на дизајнираниот филтер. Може да се забележи дека врвните вредности во амплитудата кои се појавиле како резултат на интеграцијата на сигналот, а не постоеле во оригиналниот сигнал, се отстранети од фреквентниот спектар на сигналот по примена на високопропусниот Батерворт филтер. Исто така може да се забележи дека по

филтрирањето на сигналите е задржан пикот во амплитудата при карактеристичната фреквенција која, за присутен дебаланс (со ниво на изразеност 35 g) што е симулиран при снимањето на овој сигнал, е еднаква на ротационата брзина на вратилото која изнесува 55,4 Hz.

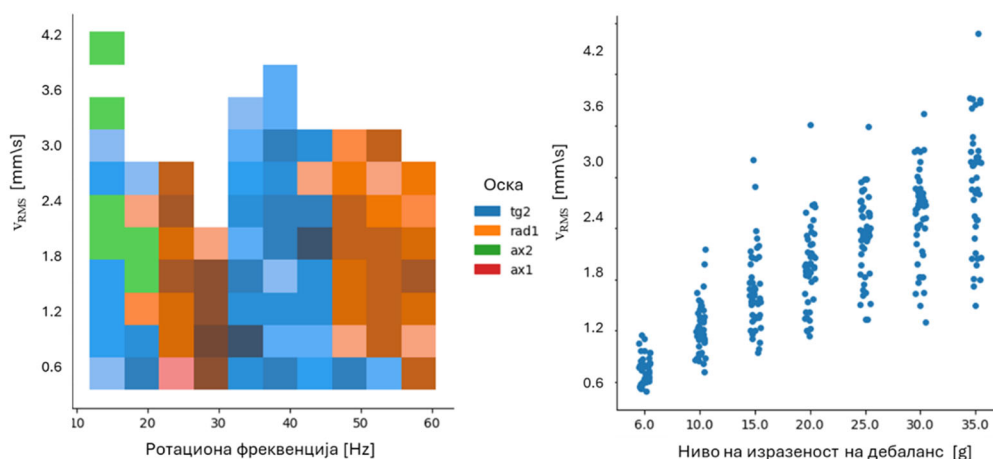


Слика 25. Фреквентен спектар на сигналот после интеграција без примена на високопропусен Батервортов филтер (дебаланс од 35 g, ротациона брзина 55,4 Hz)

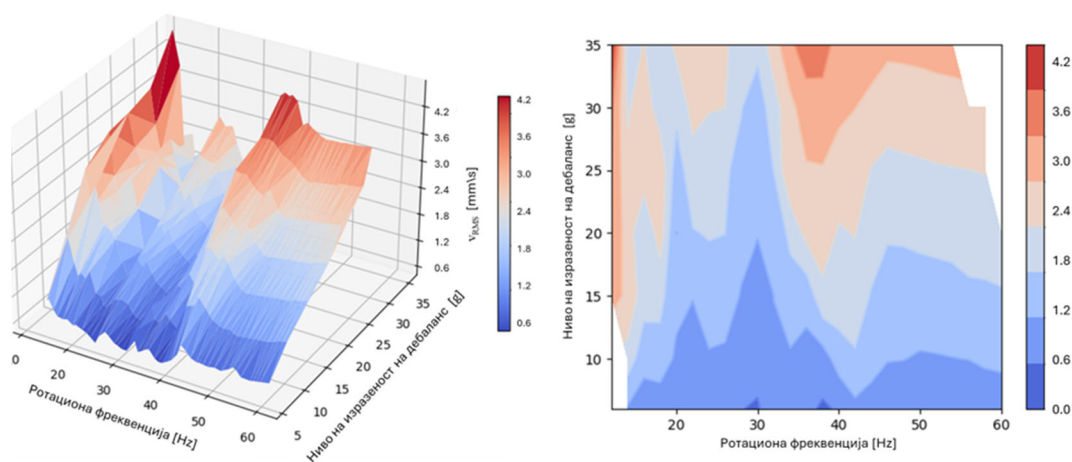


Слика 26. Фреквентен спектар на сигналот после интеграција со примена на високопропусен Батервортов филтер од бти ред (дебаланс од 35 g, ротациона брзина 55,4 Hz)


Откако ќе се заврши филтрирањето и интеграцијата на сигналите, односно нивната амплитуда ќе биде изразена во физичка величина брзина, се пресметува статистичкиот параметар средно квадратна вредност на брзината на вибрации v_{RMS} кој овозможува директна споредливост на вибрационите нивоа со унифицирани зони на состојба на ротирачки машини согласно стандардот ISO 10816-1. На слики 27-32 прикажани се пресметаните вредности на параметарот v_{RMS} при различните ротациони фреквенции на вратилото и по различни оски на измерените вибрации и тоа при различни нивоа на изразеност на дебаланс, при различни нивоа на изразеност на хоризонтална и вертикална нецентричност и при присутен дефект во лежиштата при различни нивоа на изразеност на дебаланс.



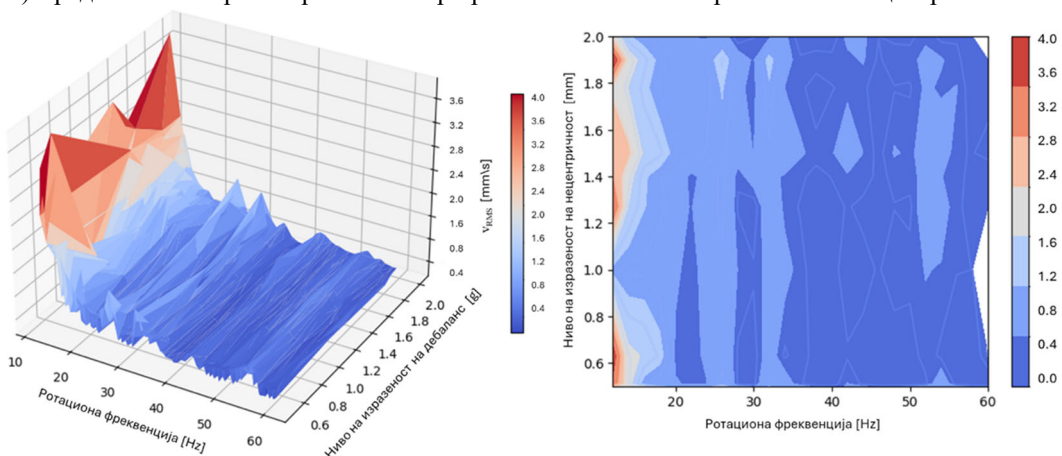
Слика 27. а) Вредности на параметарот v_{RMS} при различни ротациони фреквенции на вратилото и по различни оски на измерените вибрации при присутен дебаланс
 б) Вредности на параметарот v_{RMS} при различни нивоа на изразеност на дебаланс



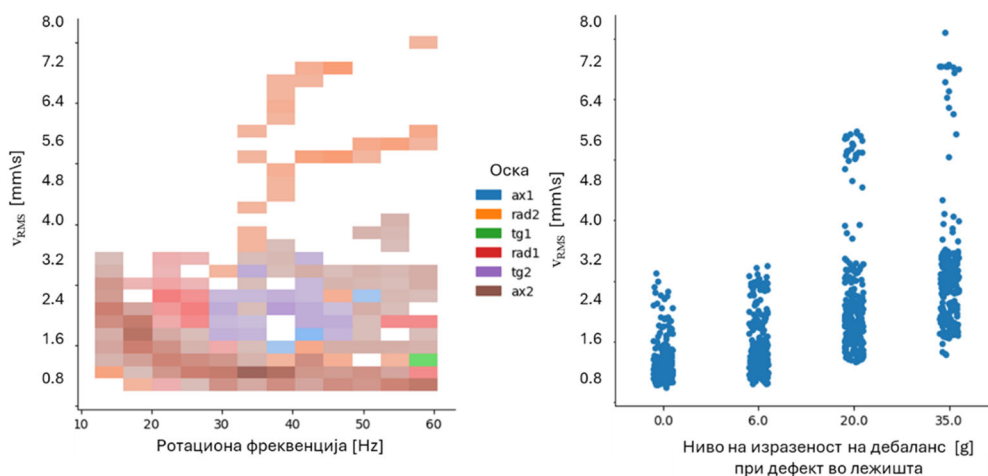
Слика 28. Промена на вредности на параметарот v_{RMS} при различни ротациони фреквенции на вратилото и по различни оски на измерените вибрации при различни нивоа на изразеност на дебаланс




Слика 29. а) Вредности на параметарот v_{RMS} при различни ротациони фреквенции на вратилото и по различни оски на измерените вибрации при присутна хоризонтална и вертикална нецентричност
 б) Вредности на параметарот v_{RMS} при различни нивоа на изразеност на нецентричност



Слика 30. Промена на вредности на параметарот v_{RMS} при различни ротациони фреквенции на вратилото и по различни оски на измерените вибрации при различни нивоа на изразеност на хоризонтална и вертикална нецентричност

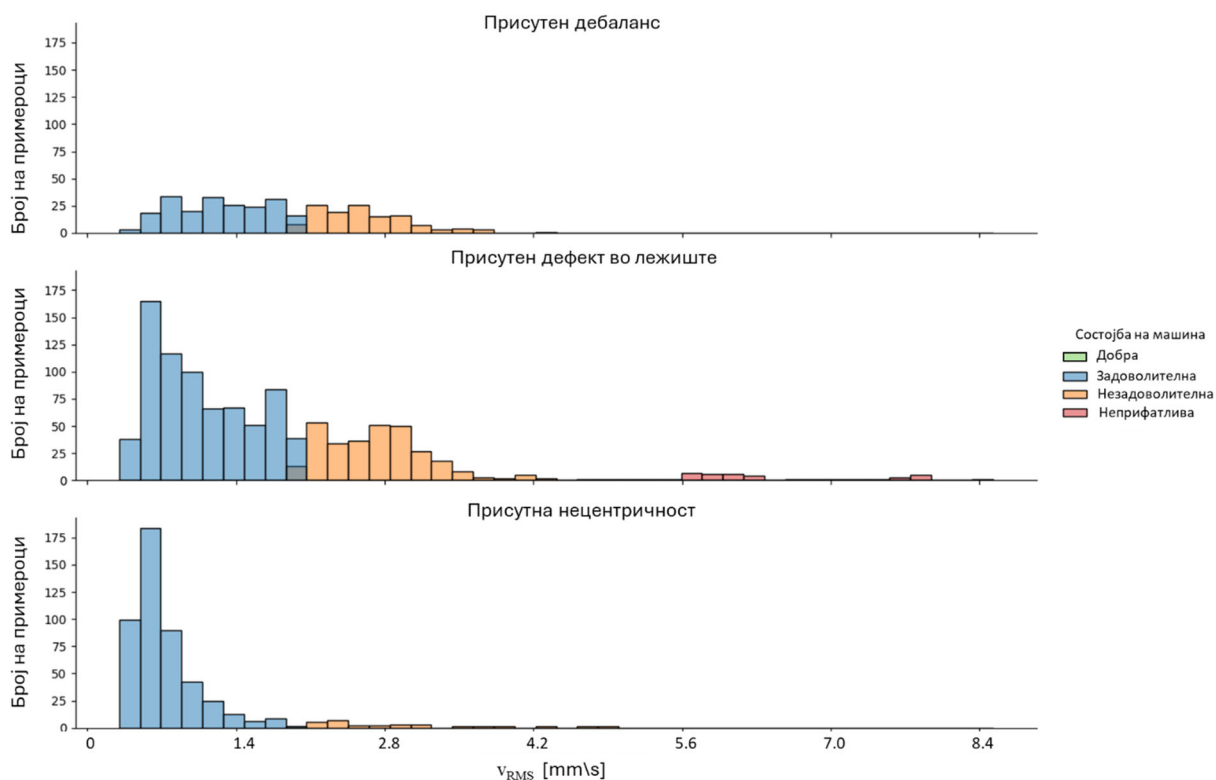


Слика 31. а) Вредности на параметарот v_{RMS} при различни ротациони фреквенции на вратилото и по различни оски на измерените вибрации при присутен дефект во лежиштата
 б) Вредности на параметарот v_{RMS} при различни нивоа на изразеност на дебаланс при присутен дефект во лежиштата




Слика 32. Промена на вредности на параметарот v_{RMS} при различни ротациони фреквенции на вратилото и по различни оски на измерените вибрации при различни нивоа на изразеност на дебаланс при присутен дефект во лежиштата

На слики 33-36 прикажани се резултатите после проценката на состојбата на машината во состав на MaFaulda базата на податоци преку споредба на пресметаните вредности на параметарот v_{RMS} при различни работни услови и при различни присутни дефекти со унифицираните зони на состојба на ротирачки машини согласно стандардот ISO 10816-1.

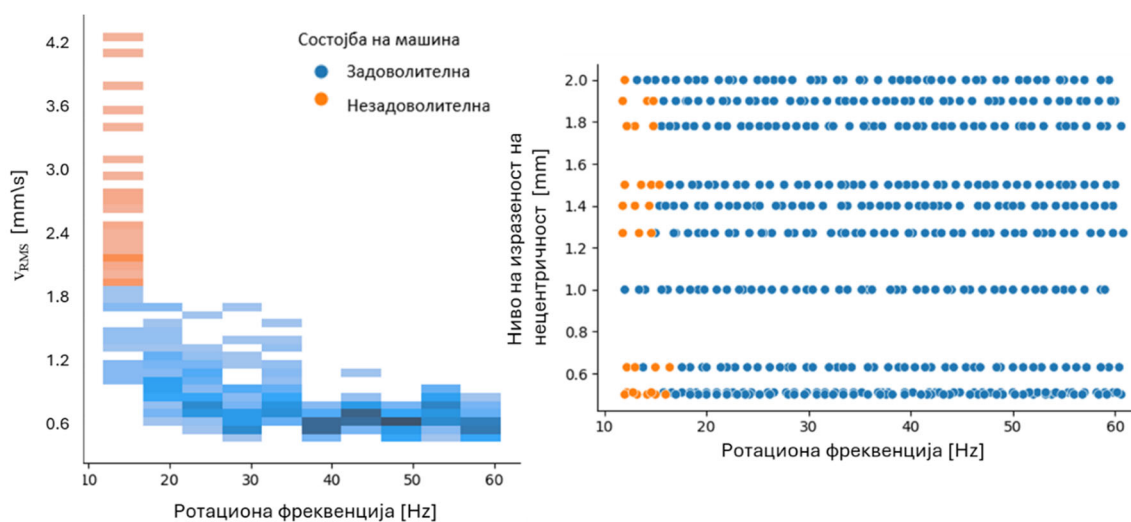


Слика 33. Хистограм на распределба на број на примероци по зони согласно стандардот ISO 10816-1 според v_{RMS} при присутен дебаланс, присутен дефект во лежиште и присутна хоризонтална и вертикална нецентричност


Распределбата на примероци во различни зони на нивоа на вибрации во присуство на различни дефекти се должи на тоа што при креирање на искористената база на податоци, сигналите се снимани при различни нивоа на изразеност на дефектите.



Слика 34. Состојба на машината согласно стандардот ISO 10816-1 според vRMS при при различни ротациони фреквенции на вратилото при различни нивоа на изразеност на дебаланс



Слика 35. Состојба на машината согласно стандардот ISO 10816-1 според vRMS при при различни ротациони фреквенции на вратилото при различни нивоа на изразеност на нецентричност



Слика 36. Состојба на машината согласно стандардот ISO 10816-1 според vRMS при при различни ротациони фреквенции на вратилото при различни нивоа на изразеност на дебаланс при присутен дефект во лежиштата

Важно е да се потенцира дека оваа анализа е направена со цел проценка на нивоата на вибрации на искористената база на податоци за тренинг и тестирање на дијагностичкиот модел. Креираниот алгоритам ќе ја препознава моменталната состојба на анализираната машина независно од зоната во која се наоѓаат. Со други зборови, одреден дефект ќе биде препознаен и во случај кога нивоата на вибрации се такви што се уште спаѓаат во рамки на прифатливите зони согласно стандардите, со што се овозможува и дијагностика на дефекти во раните фази на нивно појавување.

2.6 Подготовка на вибрационите сигнали

Мерењето и анализата на вибрационите сигнали овозможува идентификација на присутни дефекти во рани фази на појавување. Меѓутоа, измерените вибрациони сигнали освен што содржат информации за состојбата на разгледуваниот систем, во себе содржат и шумови поради што во нивната оригинална форма не може да се искористат како влез за алгоритмите за дијагностика и прогностика на дефекти. Претходната обработка на измерените сигнали има суштинско значење при трансформацијата на необработените податоци во карактеристики со високо ниво на значајност при дијагностика и прогностика на дефекти. Меѓутоа, пред да се почне со обработка на сигналите, мора добро да се проучи избраната база на податоци и истата соодветно да се подготви. Методологијата за подготовка и обработка на сигналите се дефинира во зависност од природата на измерените сигнали како и нивната примена.


Подготовката на MaFaulda базата на податоци, која е користена во рамки на ова истражување, опфаќа балансирање на базата на податоци, дефинирање на оптималната стапка на семплирање F_s и примена на соодветни филтри за да се спречи протекување на сигналот.

2.6.1 Балансирање на базата на податоци


На слика 37 прикажана е процентуалната застапеност на сигналите снимени при сите состојби на ротирачката машина во состав на MaFaulda. Може да се види дека базата на податоци содржи најмал број на снимени вибрациони сигнали при нормална работа на машината. Оваа класа е застапена со помалку од 50% од средната вредност на податоците од сигналите снимени при сите други состојби на машината, што значи дека базата на податоци е небалансирана [136]. Примена на небалансирана база на податоци може да биде причина за појава на помала точност при препознавање на состојба без грешки, односно во некои случаи може да биде зголемена можноста за појава на лажни аларми.

За да се избегне потенцијално намалување на точноста на класификаторот поради примена на небалансирана база на податоци, предложен е метод за балансирање на базата на податоци. Методот подразбира намалување на оригиналната вредност на фреквенцијата на семплирање при снимање на вибрационите сигнали (која изнесува 50 kHz), за сигналите кои спаѓаат во класата на нормална состојба на машината. Оригиналната фреквенцијата на семплирање се намалува 10 пати, односно оригиналниот сигнал кој се состои од вкупно 250 000 примероци, снимени во временски интервал од 5 секунди, се модификува во сигнал кој се состои од 25 000 примероци снимени во временски интервал од 5 секунди. Балансирањето на базата на податоци се состои во тоа што останатите 225 000 примероци не се отфрлаат од сигналот туку се складираат во посебни 9 датотеки, секоја со по 25 000 примероци во времетраење од 5 секунди. Накратко, оригиналниот сигнал кој се состои од вкупно 250 000 примероци снимени во временски интервал од 5 секунди се дели на 10 датотеки и секоја се состои од 25 000 примероци снимени во временски интервал од 5 секунди. На тој начин бројот на датотеки од снимени сигнали при нормална состојба на машината би пораснал од 49 на 490, односно вкупниот број на датотеки во тој случај би бил 2392.


Меѓутоа, за да се спречи непотребно зголемување на бројот на податоци во и така веќе обемна база на податоци, се поставува прашањето дали бројот на датотеки од снимени сигнали при нормална состојба на машината мора за се зголеми токму 10 пати за да се постигне балансираност на податоците. Доколку секој втор издвоен сигнал (или секоја втора новоформирана датотека) е отфрлен, слика 38, бројот на датотеки снимени при нормална состојба би бил 245, а вкупниот број на датотеки би бил 2147, односно би се постигнала балансираност на податоците [136]. Ваквата модификација не предизвикува намалување на точноста на класифицирачките алгоритми бидејќи кај сигналите снимени при нормална состојба на машинскиот систем не постои ризик од случајно занемарување на значајни фреквенции. На слика 39 дадена е процентуалната застапеност на ново организираната база на податоци. Доколку целта е да се дијагностицира и дефинира кој тип на дефект во лежиштата е присутен при снимањето на сигналот, тогаш базата на податоци се дели на 10 класи различни работни состојби, слика 40. И при вакви анализи базата на податоци е балансирана после извршената модификација во поглед на бројот на датотеки снимени при нормална состојба. Исто така, тука мора да се потенцираат два важни аспекти. Од една страна новата вредност за фреквенцијата на семплирање при нормална состојба на машината (5 kHz) мора да биде унифицирана за целата база на податоци, односно за сите класи дефекти и мора да биде во согласност со начинот на монтирање на искористените акцелерометри и аквизиционата единица при креирање на базата. Од друга страна, по намалувањето на фреквенцијата на семплирање мора да се внимава да не настане протекување на сигналите, односно мора да се искористи соодветен филтер. Овие аспекти ќе бидат подетално обработени во следните поглавја.




Слика 37. Процентуална застапеност на сигналите снимени при сите состојби на ротирачката машина во состав на MaFaulda база на податоци



Слика 38. Методологија за балансирање на податоците во состав на MaFaulda базата на податоци – модификации во организација на сигнали снимени при нормална состојба



Слика 39. Процентуална застапеност на сигналите снимени при сите состојби на ротирачката машина во состав на MaFaulda база на податоци по примена на методологија за балансирање



Слика 40. Процентуална застапеност на сигналите снимени при сите состојби на ротирачката машина во состав на MaFaulda база на податоци по примена на методологија за балансирање

Кодот за балансирање на базата на податоци согласно опишаната методологија е даден во Прилог А-3.

2.6.2 Дефинирање на фреквенција на семплирање

Фреквенцијата на семплирање го дефинира бројот на снимени примероци во определен временски интервал (најчесто во 1 секунда) при снимање на вибрациониот сигнал во дигитален облик. Горната граница на фреквенцијата на семплирање се определува според видот на користените акцелерометри, начинот на нивно монтирање на куќиштето на лежиштето и типот на искористената аквизициона единица. Доколку сигналите се снимаат со фреквенција на семплирање над препорачаните вредности за користената мерна опрема, постои ризик од

добивање на извитоперени високофреквентни сигнали кои не се поврзани со реалните генерирани вибрации од анализираниот систем. Во тој случај би требало да се изврши соодветна обработка на сигналите и нивно соодветно филтрирање за да се отстранат овие високофреквентни сигнали.


При снимање на сигналите во состав на базата на податоци MaFaulda, едноосните акцелерометри што се монтирани на куќиштето на внатрешното лежиште се навојни и дозволуваат отчитувања до 10 kHz, додека триосниот акцелерометар користи магнет за монтирање на куќиштето на надворешното лежиште, слика 5, и овозможува соодветни отчитувања до 5 kHz [137]. Избраната вредност за фреквенцијата на семплирање при креирање на MaFaulda е блиска до максимално дозволената вредност на аквизиционата единица, т.е. $F_s = 50 \text{ kHz}$. Затоа, пред да се изврши екстракција на карактеристики, фреквенцијата на семплирање е намалена за 10 пати, така што нејзината вредност ја исполнува препорачаната вредност на триосниот акцелерометар. Во поглавје 2.6.1 при балансирање на базата на податоци, фреквенцијата на семплирање кај сигналите снимени при нормална состојба на машината беше намалена исто така 10 пати, односно и после методите за подготовка на базата на податоци, задржана е еднаквоста во фреквенцијата на семплирање од 5 kHz при сите класи дефекти.

Долната вредност на фреквенцијата на семплирање е ограничена согласно Никвистовата теорема (2.10) која ја дефинира највисоката фреквенција што ќе ја содржи фреквентниот спектар:

$$F_{max} = \frac{F_s}{2} \quad (2.10)$$

Односно при $F_s = 5 \text{ kHz}$, највисоката фреквенција F_{max} која може да се сними е 2,5 kHz.

По намалување на фреквенцијата на семплирање, неопходно е да се испита дали настанало протекување на сигналот (Aliasing) поради намалувањето на F_s . На слика 41 прикажано е дека директното намалување на F_s предизвикува појава на врвна вредност при околу 2,5 kHz, која не постои во оригиналниот сигнал.



Слика 41. Ефекти од користење на Anti-Aliasing филтер при намалување на F_s – фреквентен домен

Затоа, пред да се пристапи кон намалување на фреквенцијата на семплирање, се применува нископропусен Батервортов филтер со гранична фреквенција од 2 kHz. Избраната вредност за граничната фреквенција е пониска од новата вредност за максималната фреквенција согласно Никвистовата Теорема (2,5 kHz), со што се обезбедува доволно широка зона за ефикасно филтрирање на високофреквентните компоненти кои би предизвикале преклопување (aliasing) во нискофреквентниот опсег, бидејќи реалните филтри не отсекуваат вертикално. Согласно постоечката литература [16,20,32], оваа вредност за граничната фреквенција целосно

ги опфаќа карактеристичните фреквенции, па нема ризик од губење релевантни дијагностички информации. На слика 41 може да се видат ефектите од примена на Anti-aliasing filter, односно може да се забележи дека врвната вредност во фреквентниот спектар која се појавила како резултат на намалување на фреквенцијата на семплирање, а не постоела во оригиналниот сигнал, сега е елиминирана.

Кодот за намалување на фреквенцијата на семплирање согласно опишаната методологија е даден во Прилог А-4.

Со примената на чекорите опишани во ова поглавје, базата на податоци е целосно подготвена за понатамошна обработка и екстракција на дијагностички значајни карактеристики. Во следното поглавје ќе бидат детално претставени групите на карактеристики што се екстрахираат од подготвените сигнали, како и соодветните методологии за обработка на сигналите од кои истите се екстрахираат.

3. ОБРАБОТКА НА СИГНАЛИ И ЕКСТРАКЦИЈА НА КАРАКТЕРИСТИКИ ЗА ДИЈАГНОСТИЧКИ ЦЕЛИ

Откако базата на податоци е соодветно подготвена, следниот чекор претставува примена на методи за обработка на вибрационите сигнали, со цел нивна понатамошна анализа и екстракција на дијагностички значајни карактеристики. За таа цел ќе бидат применети неколку паралелни методологии за обработка на сигналите, со кои ќе се обезбеди филтрирање на сигналите во поширок фреквентен спектар и задржување на значајните нискофреквентни и високофреквентни компоненти поврзани со различни типови дефекти и по обработката на сигналите. Поради различната природа и чувствителност на различните групи карактеристики што ќе се екстрахираат, секоја група на карактеристики се екстрахира од оној обработен сигнал чија методологија најдобро ја истакнува информацијата релевантна за конкретниот дефект. На овој начин се обезбедува висока точност, стабилност и робустност на развиениот дијагностички модел. Во продолжение детално се опишани групите на карактеристики и соодветните методи за обработка на сигналите од кои тие се екстрахирани.

3.1 Типови на карактеристики

Во ова поглавје се дадени теоретските основи за различните групи карактеристики кои ја опишуваат суштината на вибрационите сигнали од кои се екстрахирани. Генерално, карактеристиките може да се поделат во три големи групи според доменот од кој се екстрахираат: карактеристики во временски домен, карактеристики во фреквентен домен и карактеристики во временско-фреквентен домен. Во рамки на ова истражување се екстрахираат карактеристики во временски домен и во фреквентен домен, кои обезбедуваат различен тип на дијагностичка информација за присутните дефекти. Покрај екстрахираните карактеристики од базата на податоци, ќе се екстрахираат и карактеристики кои произлегуваат од физиката на анализираната ротирачка машина и од природата на присутните дефекти со цел тренинг на хибриден модел за дијагностика на дефекти.

На крајот од овој дел дадена е систематизирана таксономија, со број на екстрахирани карактеристики по групи и соодветни методи за обработка на сигналите од кои тие произлегуваат.

3.1.1 Карактеристики во временски домен

Во општ случај, измерените вибрациони сигнали кај реалните машински системи имаат стохастична природа и потекнуваат од неколку извори кај ротирачката машина. Поради тоа, истите не може да се дефинираат на еднозначен начин со математичка равенка. Еден од начините за нивна анализа е со примена на статистички функции изразени во зависност од времето како независно променлива. Овие функции може да се користат за мануелна инспекција или автоматизирано следење на состојбата. Во литературата се искористени и проучувани голем број на статистички функции со цел екстракција на значајни карактеристики од сигналот во временски домен користејќи ја амплитудата на сигналите [62]. Во продолжение ќе бидат

објаснети најчесто употребуваните статистички функции во временски домен кои се применуваат за дијагностика на дефекти:

- Врвна вредност на амплитудата (Peak Value of Amplitude)

Врвната вредност на амплитудата е максималната девијација на амплитудата на вибрационите сигнали во однос на нултата вредност. Се пресметува како максимум од апсолутните вредности на највисоките (позитивни) и најниските (негативни) вредности.

- Вредност на амплитудата Врв до Врв (Peak to Peak Amplitude)

Оваа вредност ја опишува максималната девијација на вибрационите амплитуди во позитивна и негативна насока. Може да се пресмета како половина од разликата помеѓу максималната и минималната амплитуда на вибрациите, односно максималната позитивна врвна вредност на амплитудата и максималната негативна врвна вредност на амплитудата. Претставува параметар едноставен за пресметка, меѓутоа неговата вредност зависи од избраната фреквенција на семплирање. Математички може да се изрази со релацијата (3.1):

$$x_p = \frac{1}{2} [x_{max}(t) - x_{min}(t)] \quad (3.1)$$

- Средна вредност на амплитудата (Mean Amplitude)

Оваа вредност претставува средна вредност на амплитудата на вибрациониот сигнал за даден временски интервал. За разлика од претходниот параметар, средната вредност е робусен параметар во однос на промената на фреквенцијата на семплирање. Може да се пресмета со следните изрази (3.2) (3.3):

$$\bar{x} = \frac{1}{T} \int x(t) dt \quad (3.2)$$

T – избран временски интервал

$x(t)$ – вибрациониот сигнал во функција од времето

Доколку сигналот е дискретизиран, средната вредност може да се пресмета:

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (3.3)$$

N – број на примероци

x_i – елемент од вибрациониот сигнал x

Кај вибрационите сигнали најчесто има вредност блиска до нула бидејќи вибрациите најчесто се подеднакво застапени во позитивната и негативната насока во однос на референтна вредност.

- Средна квадратна вредност (Root Mean Square Amplitude RMS)

RMS вредноста ја покажува варијацијата во амплитудата на вибрациониот сигнал. Оваа вредност не зависи од фреквенцијата на семплирање и овозможува попрецизна споредба на вибрационите нивоа на два сигнали и е робустна во однос на појава на врвни вредности при работа во нормална состојба и при присуство на шумови во сигналот. Покажува висока ефективност при идентификација на дебаланс како дефект во машинските системи. Слабост е што не е доволно осетлив параметар за откривање на дефекти во раните фази на нивниот развој. Може да се пресмета преку следните изрази (3.4) и (3.5):

$$x_{RMS} = \sqrt{\frac{1}{T} \int |x(t)|^2 dt} \quad (3.4)$$

$$x_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N |x_i|^2} \quad (3.5)$$

○ Квадратен корен од амплитуда (Square Root of the Amplitude SRA)

SRA е вредност која ја претставува ефективната моќност на сигналот во текот на определен временски интервал нагласувајќи ја просечната амплитуда на сигналот и намалувајќи го влијанието на нејзините врвни вредности. Може да се пресмета (3.6):

$$x_{SRA} = \left(\frac{1}{N} \sum_{i=1}^N \sqrt{|x_i|} \right)^2 \quad (3.6)$$

○ Крест Фактор (Crest)

RMS вредноста игра клучна улога при пресметка на уште еден важен параметар – Крест Фактор (CF) кој е дефиниран како соодносот помеѓу вредноста Врв до Врв и RMS вредноста на вибрациониот сигнал. Соодветно, појавата на врвни вредности во сигналот во временски домен резултира во зголемување на Крест Факторот. Овој параметар детектира промени во природата на сигналите како резултат на импулсни извори на вибрации како што се дефектите во лежиштата [142,143]. Доколку вредноста на Крест Факторот е висока, тоа најчесто е индикатор за дефект во лежиште. Неговата вредност може да се пресмета со следниот израз (3.7):

$$x_{CF} = \frac{x_p}{x_{RMS}} \quad (3.7)$$

На пример, за даден временски интервал на сигнал претставен со синусна функција со 100 примероци во временски домен, максимална позитивна амплитуда од 1 и максимална негативна амплитуда од -1, слика 42, вредноста на x_{RMS} е еднаква на 0,707 и x_{CF} е 1,414. Според тоа, сигнал со вредност x_{CF} повисока од 1,414 укажува на абнормална состојба во сигналот, односно присуство или почеток на развој на некој дефект во машинскиот систем.

○ Варијанса и Стандардна девијација


Варијансата ја дефинира девијацијата на енергијата на вибрациониот сигнал од средната вредност и математички може да се изрази како (3.8):

$$\sigma_x^2 = \frac{\sum (x_i - \bar{x})^2}{N - 1} \quad (3.8)$$

Квадратниот корен од варијансата се нарекува стандардна девијација на сигналот и може да се пресмета преку (3.9):

$$\sigma_x = \sqrt{\frac{\sum (x_i - \bar{x})^2}{N - 1}} \quad (3.9)$$

Стандардната девијација ја покажува средната вредност на варијација во базата на податоци како и варијацијата во амплитудата на вибрациониот сигнал.



Слика 42. Вибрационен сигнал на синусна функција со амплитуда 1 и 100 примероци во временски домен

○ Импулсен Фактор (Impulse Factor)

Импулсниот Фактор е дефиниран како сооднос помеѓу вредноста на амплитудата Врв до Врв и просекот од апсолутните вредности на вибрациониот сигнал, односно (3.10):

$$x_{IF} = \frac{x_p}{\frac{1}{N} \sum_{i=1}^N |x_i|} \quad (3.10)$$

Овој фактор е корисен при проценка на влијанието што го има присутниот дефект врз промената на вибрациониот сигнал. Особено се користи при мерење на промената во вибрациониот сигнал при присутен дебаланс или нецентричност, додека неговата вредност не се менува значително при присуство на дефекти во лежишта и не се користи при дијагностика на дефекти во лежишта.

○ Фактор на Маргина (Margin Factor)

Margin Factor може да се пресмета со следниот израз (3.11):

$$x_{MF} = \frac{x_p}{\left(\frac{1}{N} \sum_{i=1}^N \sqrt{|x_i|}\right)^2} \quad (3.11)$$

Вредноста на овој фактор значително се менува со промени во вредноста на амплитудата Врв до Врв, со што е параметар со висока осетливост во однос на дефекти кои предизвикуваат импулсни вибрации.

○ Фактор на Форма (Shape Factor)

Shape Factor е дефиниран како односот помеѓу RMS вредноста и просекот од апсолутните вредности на вибрациониот сигнал, односно (3.12):

$$x_{SF} = \frac{x_{RMS}}{\frac{1}{N} \sum_{i=1}^N |x_i|} \quad (3.12)$$

Овој фактор е корисен при мерење на промената во вибрациониот сигнал при присутен дебаланс или нецентричност, додека неговата вредност не се менува значително при присуство на дефекти во лежишта и не се користи при дијагностика на дефекти во лежишта.

○ Clearance Factor

Овој фактор може да се пресмета со следниот израз (3.13):

$$x_{CLF} = \frac{x_{max}}{\left(\frac{1}{N} \sum_{i=1}^N \sqrt{|x_i|}\right)^2} \quad (3.13)$$

○ Фактор на искривување (Skewness)

Факторот на искривување (Skewness) е мерка за асиметричноста на вибрациониот сигнал со примена на функција за пресметка на веројатноста на густината на распределба. Со други зборови таа мери дали вибрациониот сигнал е искривен на левата или десната страна во однос на дистрибуцијата на вибрациониот сигнал генериран при нормална состојба на системот без присутни дефекти. Вредноста на овој фактор може да се пресмета со следниот израз (3.14):

$$x_{SK} = \frac{\sum_{i=1}^N (x_i - \bar{x})^3}{N \cdot \sigma_x^3} \quad (3.14)$$

○ Куртоза

Куртозата е мерка за врвната вредност на вибрациониот сигнал со примена на функција за пресметка на веројатноста на густината на распределба. Со други зборови, означува дали врвната вредност на сигналот е повисока или пониска од врвната вредност на дистрибуцијата која соодветствува на вибрациониот сигнал снимен при нормална работа на системот односно кога не се присутни дефекти. Претставува мерка за релативната испакнатост или рамност на дистрибуцијата во однос на нормалната дистрибуција. Вредноста на овој параметар може да се пресмета со следниот израз (3.15):

$$x_{KURT} = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{N \cdot \sigma_x^4} \quad (3.15)$$

○ Ентропија

Ентропијата е параметар кој претставува мерка за несигурноста на веројатноста на густината на распределба на вибрациониот сигнал. Може да се определи како (3.16):

$$x_{ENT} = \sum_{i=1}^N p_{x_i} \log p_{x_i} \quad (3.16)$$

p_{x_i} – веројатност пресметана од распределбата на сигналот $x(t)$

Според постоечката литература, статистичката анализа на вибрационите сигнали во временски домен со примена на параметрите дефинирани од Веројатносната распределба се докажува корисна при идентификација на дефекти во машинските системи [144]. Средната вредност, варијансата и факторот на искривување (Skewness) се првиот, вториот и третиот статистички момент на Веројатносната распределба, соодветно. Куртозата е дефинирана како четвртиот статистички момент на распределба и ја проценува релативната рамност или испакнатост на распределбата во споредба со нормалната распределба. Така на пример, за лежишта кои немаат дефекти, најчесто куртозата има вредност до 3, а вредности повисоки од 3 може да послужат како индикатор за присутни дефекти кај лежиштето. Меѓутоа, само овој параметар сам по себе не може да се користи како индикатор за дефекти во лежишта бидејќи како што дефектот се развива, вредноста на куртозата почнува повторно да се стреми кон 3, односно кон вредност која ја имаат и лежиштата без присутни дефекти [144]. Кај лежишта без дефекти најчесто факторот на искривување има вредност нула. Доколку е присутен дефект кај

лежиштето, факторот на искривување ќе добие позитивна или негативна вредност. Голем број истражувања ги користат статистичките функции во временски домен за обработка на вибрационите сигнали како влезни карактеристики при следење на состојбата на системите, индивидуално или во комбинација со други техники. Согласно спроведените истражувања, сите релевантни трудови користат најмалку шест параметри, а во најголем број се користат и десет параметри од наведените статистички функции. Куртозата како параметар се користи во речиси сите трудови, а доста често користени се и факторот на искривување, фактор на форма, фактор на импулс, варијанса, Крест Факторот, Врвната Вредност на амплитудата, RMS и ентропијата.

3.1.2 Карактеристики во фреквентен домен

Карактеристиките во фреквентен домен се добиваат по трансформирање на вибрациониот сигнал од временски во фреквентен домен, најчесто со примена на алгоритмот на брза Фуриева трансформација (FFT). Овие карактеристики ја опишуваат распределбата на енергијата во спектарот и овозможуваат идентификација на доминантни фреквенции поврзани со различни типови дефекти. Во ова истражување, екстрахираните карактеристики во фреквентен домен може да се групираат во две подгрупи: статистички карактеристики и спектрални карактеристики. Во продолжение детално се објаснети двете подгрупи на карактеристики и нивната дијагностичка примена.

- **Статистички карактеристики во Фреквентен домен**

Откако ќе се генерира фреквентен спектар на сигналот, од него може да се извлечат вредности за статистички функции во фреквентен домен кои обезбедуваат брз преглед на состојбата на машината, но не нудат специфична дијагностичка способност. Во продолжение ќе бидат изнесени статистичките функции во фреквентен домен кои се користат за следење на состојбата на ротирачките машини [145,146]:

- **Аритметичка средина на фреквентниот спектар**

Аритметичката средина ја дава просечната амплитуда за даден опсег на фреквенции и може да се пресмета преку следниот израз (3.17):

$$\bar{X}(s) = 20 \cdot \log \left\{ \frac{1}{N} \cdot \sum_{i=1}^N A_i \right\} \quad (3.17)$$

A_i – амплитуда на i -тата компонента од фреквентниот спектар

N – број на компоненти/примероци во фреквентен спектар

- **Геометриска средина на фреквентниот спектар (3.18)**

$$\bar{X}_{geo}(s) = \left\{ \sum_{i=0}^N 20 \cdot \log \left(\frac{A_i}{\sqrt{2}} \right) \right\} \quad (3.18)$$

- **Средна квадратна вредност на фреквентниот спектар (RMSF)**

Средна квадратна вредност на фреквентниот спектар (RMSF - Root Mean Square Frequency) е параметар кој ја претставува вкупната енергија содржана во вибрациониот сигнал, притоа фокусирајќи се на дистрибуцијата на енергија по различни фреквентни компоненти, што е корисно при идентификација на определени дефекти. Најчесто се користи кога високо-фреквентни компоненти доминираат во фреквентниот спектар, односно при дијагностика на дефекти во лежишта. Има аналогно значење како параметарот Средна квадратна вредност на

сигналот во временски домен (RMS), со таа разлика што RMSF (3.19) се однесува за фреквентниот спектар.

$$RMSF = \sqrt{\frac{\sum_{i=2}^N \dot{X}_i^2}{4\pi^2 \sum_{i=1}^N X_i^2}} \quad (3.19)$$

$$\dot{X}_i = X_i - \frac{X_{i-1}}{\Delta} \quad (3.20)$$

X_i – дискретизиран фреквентен спектар

- Фреквентен центар (FC)

Фреквентниот центар (FC - Frequency Center) (3.21) ја означува средната точка од определен фреквентен опсег во фреквентниот спектар на сигналот. Има големо значење при анализа на определени фреквентни интервали со цел дијагностика на присутни дефекти.

$$FC = \frac{\sum_{i=2}^N \dot{X}_i X_i}{2\pi \sum_{i=1}^N X_i^2} \quad (3.21)$$

- Средно квадратна варијанса на фреквентниот спектар (RVF)

Средно квадратна варијанса на фреквентниот спектар (RVF - Root variance frequency) (3.22) е параметар кој ја карактеризира дисперзијата на содржаната енергија по различните фреквенции на сигналот. Со други зборови ја претставува стандардната девијација на фреквентните компонентни прикажувајќи колку широко е распределена содржаната енергија по фреквентниот спектар.

$$RVF = \sqrt{RMSF^2 - FC^2} \quad (3.22)$$

Согласно прегледаната литература, десет статистички параметри во временски и три статистички параметри во фреквентен домен имаат суштинско значење во полето на дијагностика кај ротирачки машини. Во овој дел се екстрахирани најзначајните статистички параметри во временски домен и тоа: Средна квадратна вредност на амплитудата (RMS), Стандардна девијација (Std), Куртоза (Kurtosis), Фактор на искривување (Skewness), Врвна вредност на амплитудата (Peak Value), Крест Фактор (Crest), Импулсен Фактор (Impulse), Фактор на Маргина (Margin), Фактор на Форма (Shape), Ентропија (Entropy) и средно квадратната вредност на брзината на вибрации (v_{RMS}). Во фреквентен домен екстрахирани се трите најзначајни статистички параметри и тоа: Средна квадратна вредност на фреквентниот спектар (Средна квадратна вредност на фреквентниот спектар - RMSF), Фреквентен центар (Фреквентен центар - FC), Средно квадратна варијанса на фреквентниот спектар (Средно квадратна варијанса на фреквентниот спектар - RVF). MaFaulda базата на податоци се состои од измерени сигнали на двете лежишта (надворешно и внатрешно) и по трите оски (раидјална, аксијална и тангенцијална), односно снимени се по шест сигнали при секое мерење. Ако се определат наведените статистички параметри во временски и во фреквентен домен кои имаат значајна улога при дијагностика на дефекти кај ротирачки машини за секој од овие шест сигнали, ќе се екстрахираат 66 карактеристики во временски и 18 карактеристики во фреквентен домен.

- **Спектрални Карактеристики**

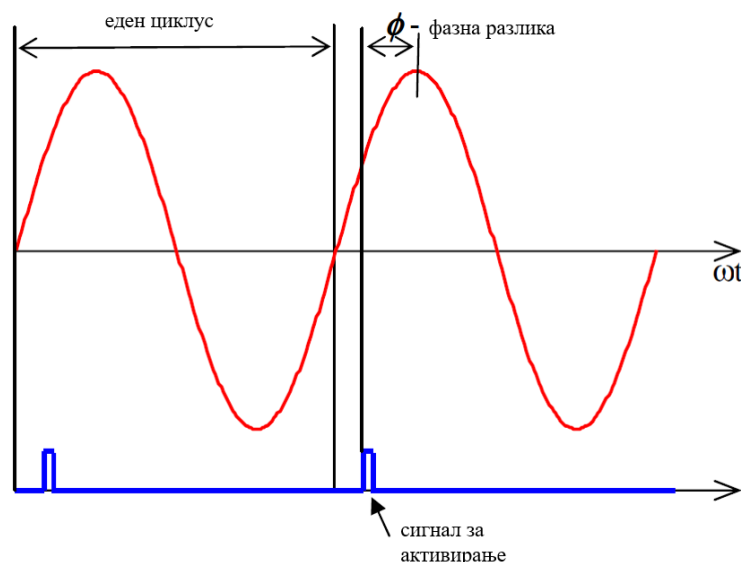
Во овој дел се објаснети спектралните карактеристики кои се добиваат од фазно-фреквентниот спектар на вибрациониот сигнал кои ја опишуваат фазната разлика помеѓу вибрациониот сигнал и референтниот сигнал. Во рамки на ова истражување, како референтен

сигнал е искористен снимениот сигнал со тахометар. Овие карактеристики се особено значајни при дијагностика на присутен дебаланс и присутна нецентричност.

○ Фазен агол

Друг важен параметар при дијагностика на дефекти кај ротациони машини кој овозможува проценка на меѓусебното движење на различни точки од даден систем во текот на времето е фазниот агол. Меѓутоа, терминот фазен агол во дијагностика на машини има различно значење од оној во динамиката. Во теоретската динамика се дефинира како фазна разлика помеѓу поместувањето и побудната сила која ги предизвикува принудните вибрации. Во дијагностика, фазниот агол се определува во однос на определен надворешен сигнал за активирање, слика 43.

Најчесто ја претставува фазната разлика помеѓу две различни точки во машината или помеѓу истата точка меѓутоа мерено при различни работни услови. Најчесто, се зема една точка како референтна во однос на која се определува фазната разлика на сите други мерни точки. На тој начин, фазниот агол прикажува во кој дел од циклусот вибрациите ја достигнуваат својата максимална вредност во дадена мерна точка во однос на сигналот за активирање. Во некои случаи, како сигнал за активирање се користи снимениот сигнал од една од мерните точки.



Слика 43. Дефинирање на параметарот фазна разлика

При анализа на сигналите во состав на MaFaulda базата на податоци, ќе се определи фазната разлика на шесте вибрациони сигнали снимени при секое мерење со акцелерометрите во однос на сигналот снимен со тахометарот. Сигналот од тахометарот се користи како сигнал за активација бидејќи претставува прецизен и стабилен показател за моменталната аголна позиција и ротационата фреквенција на вратилото. На тој начин, фазните агли на вибрационите сигнали се определуваат релативно на ротацијата на вратилото, што овозможува физички значајна интерпретација на фазните односи и нивно поврзување со специфични типови дефекти.

○ Синусна и косинусна функција од фазен агол

Во некои случаи приказот на фазните агли во мерна единица степени или радијани не е соодветен за примена како влез за алгоритмите на машинско учење, па често се врши нивна трансформација во дводимензионален координатен систем, каде апсцисната оска е косинусната вредност од фазниот агол, а ординатната оска неговата синусна функција.

Согласно, во ова истражување се екстрахирани вкупно 18 карактеристики кои се однесуваат на фазниот агол, 6 вредности на фазниот агол и уште 12 вредности од синусната и

косинусната вредност од шесте фазни агли добиени како разлика помеѓу шесте вибрациони сигнали снимени при секое мерење со акцелерометрите и сигналот снимен со тахометарот.

3.1.3 Карактеристики засновани на физиката на ротирачката машина

Покрај статистичките и спектралните карактеристики во временски и фреквентен домен, во ова истражување се екстрахира и посебна група на карактеристики кои произлегуваат од физиката на ротирачката машина и динамиката на тркалачките лежишта како нејзин составен дел. На тој начин се формира хибриден сет од карактеристики кој комбинира знаење од базата на податоци и од теоретските модели за дијагностика на дефекти кај ротирачки системи.

- **Содржана енергија при хармониците во фреквентниот спектар**

Откако ќе се определи ротационата фреквенција на вратилото, може да се пристапи кон определување на хармониците во фреквентниот спектар на сигналите.

Имајќи ги во предвид карактеристичните фреквентни спектри кои беа прикажани во поглавје 2.4, може да се заклучи дека значајна карактеристика при дијагностика е амплитудата на фреквентниот спектар при ротационата фреквенција и амплитудите при нејзините хармоници. Откако ќе се определи ротационата фреквенција, може да се определат и нејзините хармоници кои всушност се цели броеви множители на f_r , односно $2f_r$, $3f_r$ итн. Потоа од фреквентниот спектар се отчитуваат амплитудите односно содржаната енергија при овие фреквенции. Меѓутоа, точноста на пресметаната ротациона фреквенција зависи од резолуцијата на фреквентниот спектар која пак е ограничена од времетраењето на тестовите при креирање на овие бази на податоци (3.23):

$$\Delta f = \frac{F_s}{N} = \frac{1}{\Delta t_{\text{тест}}} \quad (3.23)$$

$\Delta t_{\text{тест}}$ – времетраење на секој тест при снимање на вибрационите сигнали.

Така на пример при креирање на MaFaulda базата на податоци, секој тест е во времетраење од 5 секунди, па резолуцијата на фреквентниот спектар е 0,2 Hz. Вредноста на резолуцијата на фреквентниот спектар влијае врз точноста на пресметаната ротациона фреквенција, а определената несигурност во оваа вредност се пренесува и при пресметката на нејзините хармоници. Поради тоа, вредностите на амплитудите односно содржаните енергии се земаат во определен мал опсег на фреквенции околу f_r , $2f_r$, $3f_r$ наместо при еднозначни фреквентни вредности.

Во ова истражување екстрахирани се неколку карактеристики кои зависат од содржаната енергија при првите три хармоници на секој сигнал:

- **Содржана енергија при првиот хармоник E_{1X}**

Како што беше и претходно наведено, при присутен дебаланс, во фреквентниот спектар се појавува врвна вредност при првиот хармоник. Затоа, како значајна карактеристика која е екстрахирана е енергијата при првиот хармоник E_{1X} . Бидејќи се снимени по 6 вибрациони сигнали при секој тест, екстрахирани се вкупно 6 карактеристики од овој тип за секој тест.

- **Индекс на нецентричност MIS_{index}**

Индексот на нецентричност се пресметува преку содржаната енергија при првите три хармоници:

$$MIS_{index} = \frac{E_{2X} + 0,5 E_{3X}}{E_{1X} + \varepsilon} \quad (3.24)$$

E_{2X}, E_{3X} – содржана енергија при втор односно трет хармоник

Бидејќи се снимени по 6 вибрациони сигнали при секој тест, екстрахирани се вкупно 6 карактеристики од овој тип за секој тест.

- **Однос на содржана енергија околу карактеристичните фреквенции за дефекти во тркалачките лежишта**

Овие карактеристики даваат податок за тоа при кој тип на дефект во тркалачкото лежиште е концентрирана највисока енергија и се пресметуваат на следниот начин:

$$BPFO_{ratio} = \frac{E_{BPFO}}{E_{BPFO} + E_{BSF} + E_{FTF}} \quad (3.25)$$

$$BSF_{ratio} = \frac{E_{BSF}}{E_{BPFO} + E_{BSF} + E_{FTF}} \quad (3.26)$$

$$FTF_{ratio} = \frac{E_{FTF}}{E_{BPFO} + E_{BSF} + E_{FTF}} \quad (3.27)$$

E_{BPFO} – содржана енергија при BPFO карактеристична фреквенција

E_{BSF} – содржана енергија при BSF карактеристична фреквенција

E_{FTF} – содржана енергија при FTF карактеристична фреквенција

Бидејќи се снимени по 6 вибрациони сигнали при секој тест, екстрахирани се вкупно 18 карактеристики од овој тип за секој тест.

- **Енергија при хармоници на карактеристични фреквенции за дефекти во тркалачки лежишта**

Согласно теоретскиот дел кој е детално опишан во точка 2.4.3 и слики 20-22, екстрахирана е енергијата при хармониците на карактеристичните фреквенции за дефекти во тркалачките лежишта, и тоа:

$E_{BPFO_1X}, E_{BPFO_2X}, E_{BPFO_3X}, E_{BPFO_4X}$ - содржана енергија при првите четири хармоници на BPFO карактеристична фреквенција

E_{BSF_1X}, E_{BSF_2X} - содржана енергија при првите два хармоници на BSF карактеристична фреквенција

$E_{FTF_1X}, E_{FTF_2X}, E_{FTF_3X}, E_{FTF_4X}$ - содржана енергија при првите четири хармоници на FTF карактеристична фреквенција

Бидејќи се снимени по 6 вибрациони сигнали при секој тест, екстрахирани се вкупно 60 карактеристики од овој тип за секој тест.

3.2 Екстракција на карактеристики

Преку екстракција на различните групи на карактеристики, ќе се постигне намалување на димензионалноста на податоците, односно од првичните 7 сигнали снимени во состав на MaFaulda, секој снимен во 250 000 примероци, сега влезните податоци се прикажани со матрица со димензии 2147x192 (табела 8), 2147 мерења со 192 екстрахирани карактеристики, односно 2147 мерења со 32 карактеристика по оска. Табела 8 дава краток приказ на екстрахираните карактеристики за тренинг и тестирање на алгоритмите на надгледувано машинско учење, заедно со применетите методи за обработка на сигналите од кои истите произлегуваат. Во следното

поглавје, оваа матрица ќе биде искористена како влез за алгоритмите на надгледувано машинско учење.

Програмскиот код во Python за обработка на сигнали и екстракција на карактеристики согласно табела 8 е даден во Прилог А-5.

Статистичките карактеристики во временски домен се екстрахираат директно од подготвените сигнали во временски домен, без примена на дополнителни филтри или методи за трансформација на сигналите.

Во табела 9 даден е пример за пресметаните вредности на статистичките карактеристики во временски домен по трите оски за двете лежишта, при присутен дефект во топчињата на надворешното лежиште и дебаланс со ниво на изразеност од 6g и брзина на ротација на вратилото 39,73 Hz.

Табела 8. Екстрахирани карактеристики од MaFaulda база на податоци

Тип	Карактеристики	Број на карактеристики	Сигнал од кој се екстрахираат карактеристиките	Метод на обработка
Карактеристики во временски домен	Статистички карактеристики	11 x 6 = 66	Претходно подготвен сигнал во временски домен	Без дополнителна обработка (директно од подготвен временски сигнал)
Карактеристики во фреквентен домен	Статистички карактеристики	3 x 6 = 18	Фреквентен спектар на претходно подготвен сигнал	FFT на претходно подготвен сигнал
	Спектрални карактеристики	3 x 6 = 18		
Карактеристики засновани на физиката на машината	Содржана енергија при хармониците во фреквентниот спектар	2 x 6 = 12	Фреквентен спектар на филтриран сигнал	- Анализа со примена на нископропусен филтер - FFT на филтриран сигнал (Baseband+FFT)
	Содржана енергија околу карактеристичните фреквенции за дефекти во тркалачките лежишта и нивните хармоници	3 x 6 + 10 x 6 = 78	Фреквентен спектар на енvelopa	Анализа на енvelopa (Band-pass + Хилберт-Хуанг + FFT)
		Вкупно по оска		
			32	
		Вкупно		
			192	

Табела 9. Пресметани вредности на статистичките параметри во временски домен по трите оски за двете лежишта, при присутен дефект во топчињата на надворешното лежиште и дебаланс со ниво на изразеност од 6g и брзина на ротација на вратилото 39,73 Hz

Оска	RMS	Станд. Девијација	Куртоза	Фактор на искривување	Врвна вред.	Крест Фактор	Импулсен Фактор	Фактор на Маргина	Фактор на Форма	Ентропија	VRMS [mm/s]
rad1	1,421	0,958	3,181	0,212	11,710	4,419	5,557	6,553	1,258	2,995	1,909
rad2	0,247	0,158	3,735	-0,810	1,554	3,693	4,803	5,764	1,301	3,199	2,276
tg1	0,660	0,446	3,045	0,117	5,053	3,990	5,003	5,907	1,254	3,071	1,613
tg2	1,651	1,112	3,009	0,096	13,164	4,142	5,200	6,149	1,255	3,031	1,633
ax1	2,080	1,443	2,952	-0,466	13,242	3,702	4,582	5,337	1,238	3,229	1,306
ax2	2,064	1,203	5,466	-1,311	14,128	4,518	6,267	7,754	1,387	3,044	1,424

Статистичките карактеристики во фреквентен домен и фазно-базираните спектрални карактеристики во фреквентен домен се екстрахираат од фреквентниот спектар на претходно подготвениот сигнал, со примена на брза Фуриева трансформација (FFT), без примена на дополнителни методи за обработка на сигналот. На овој начин, овие карактеристики ја опишуваат глобалната распределба на спектралната енергија низ целиот фреквентен опсег, независно од типот на присутен дефект. Дополнително, преку карактеристиките кои се засновани на физиката на ротирачката машина се опфатени и подетални информации кои зависат специфично од типот на присутен дефект. Во табела 10 даден е пример за пресметаните вредности на статистичките карактеристики во фреквентен домен по трите оски за двете лежишта, при присутен дефект во топчињата на надворешното лежиште и дебаланс со ниво на изразеност од 6g и брзина на ротација на вратилото 39,73 Hz. Во табела 11 даден е пример за пресметаните вредности на фазно-базираните спектрални карактеристики во фреквентен домен по трите оски за двете лежишта, при присутен дефект во топчињата на надворешното лежиште и дебаланс со ниво на изразеност од 6g и брзина на ротација на вратилото 39,73 Hz.

Табела 10. Пресметани вредности на статистичките параметри во фреквентен домен по трите оски за двете лежишта, при присутен дефект во топчињата на надворешното лежиште и дебаланс со ниво на изразеност од 6g и брзина на ротација на вратилото 39,3 Hz

Оска	FC	RMSF	RVF
rad1	1227,873	77,938	41888,840
rad2	488,238	51,764	31723,491
tg1	1383,045	129,652	38653,991
tg2	1079,394	47,671	61450,099
ax1	1055,075	109,448	34399,185
ax2	546,829	53,874	40722,829

Табела 11. Пресметани вредности на фазно-базираните спектрални карактеристики во фреквентен домен по трите оски за двете лежишта, при присутен дефект во топчињата на надворешното лежиште и дебаланс со ниво на изразеност од 6g и брзина на ротација на вратилото 39,3 Hz

Оска	Фазен агол φ [rad]	$\sin(\varphi)$	$\cos(\varphi)$
rad1	2,200	0,808	-0,589
rad2	2,400	0,675	-0,737
tg1	-2,700	-0,428	-0,904
tg2	-2,000	-0,909	-0,416
ax1	0,500	0,480	0,878
ax2	2,000	0,909	-0,416

Карактеристиките засновани на физиката на ротирачката машина се добиваат преку примена на две различни методологии за обработка на сигналите во фреквентен спектар: (1) анализа на нискофреквентниот спектар на сигналот, со цел идентификација на дефекти како дебаланс и нецентричност, и (2) анализа на енvelopa, која овозможува издвојување на високофреквентните компоненти карактеристични за дефекти кај тркалачките лежишта. Со примената на овие две комплементарни методологии се овозможува екстракција на целосен сет на фреквентни карактеристики кои се значајни при дијагностика на различни типови дефекти. Во продолжение ќе бидат дадени теоретските основи на овие методи, како и начинот на нивна примена во рамки на ова истражување.

3.2.1 Анализа на нискофреквентен спектар на сигналот (Baseband Analysis)

Анализа на нискофреквентен спектар на сигналот (Baseband Analysis) претставува метод на обработка на вибрациони сигнали кој се фокусира на енергетската содржина во нискофреквентниот опсег, односно во фреквентниот интервал каде се присутни ротационата фреквенција и нејзините први хармоници ($1\times$, $2\times$ и $3\times$). Овој метод е особено значаен при дијагностика на присутен дебаланс и присутна нецентричност, бидејќи овие дефекти се

манифестираат преку зголемена амплитуда и енергија токму на првите (првите три, во некои случаи првите четири) хармоници на ротационата фреквенција.

Во основа се состои од примена на соодветен нископропусен филтер за издвојување на нискофреквентниот дел од сигналот, примена на филтер против протекување на сигналот (Anti-Leakage filter), трансформација на филтрираниот сигнал во фреквентен домен со примена на брза Фуриева трансформација и анализа на фреквентниот спектар на обработениот сигнал.

- **Дизајн и примена на нископропусен филтер**

Како што беше претходно изнесено, анализата на нискофреквентниот спектар има за цел да ја издвои енергетската содржина на сигналот во опсегот каде што се појавуваат првите неколку хармоници на ротационата фреквенција на вратилото. Во искористената база на податоци, максималната ротациона фреквенција при која се снимени сигналите изнесува приближно 60 Hz, па хармониците поврзани со дебаланс и нецентричност се очекуваат при $1\times$, $2\times$, $3\times$, а во некои случаи и $4\times$ (односно 60, 120, 180 и ≈ 240 Hz). Затоа, во ова истражување се применува нископропусен Батервортов филтер од четврт ред со гранична фреквенција од 250 Hz, кој ги пропушта сите компоненти до четвртиот хармоник на ротационата фреквенција, а значително ги намалува амплитудите при повисоките фреквенции од 250 Hz. На тој начин, во сигналот се задржува релевантната нискофреквентна содржина поврзана со дефектите на дебаланс и нецентричност, додека високофреквентниот шум и карактеристичните фреквенции за присутни дефекти во тркалачки лежишта се отстрануваат. Истите ќе се анализираат одделно со примена на друг соодветен метод за обработка на сигнали.

- **Дизајн и примена на филтер против протекување на сигналот (Anti-Leakage Filter)**

На слика 44 е прикажан принципот на протекување на сигналот и примената на соодветен прозорец за негово спречување. Доколку сигналот што влегува во Фуриевата трансформација е идеално периодичен (периодичен во времето на мерење T , слика 44 лево), не постои дисконтинуитет на краевите на сигналот и резултатот во фреквентниот домен е единствена спектрална линија која точно ја одговара реалната фреквенција на сигналот, па затоа нема потреба од примена на филтер против протекување. Проблемот се појавува во случај кога сигналот што влегува во Фуриевата трансформација не е периодичен (слика 44 десно). Иако сигналот по својата природа е идентичен како во случајот на слика 44 лево, времето на мерење е различно и предизвикува непериодичност.

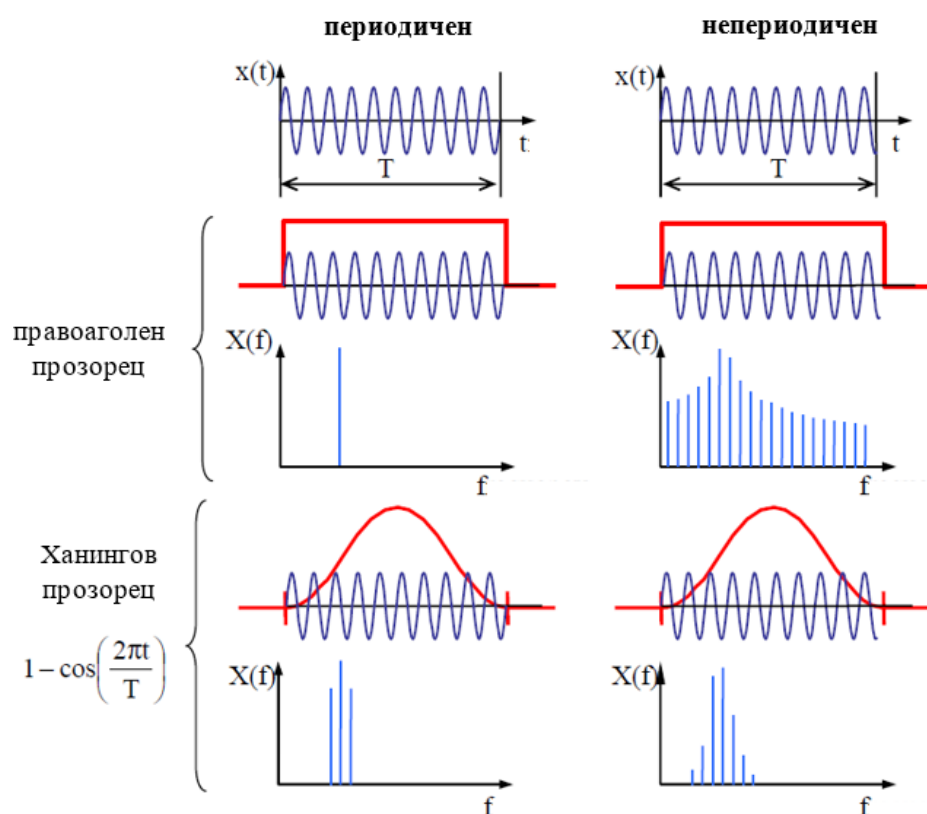
Во овој случај, алгоритмот за трансформација се обидува да моделира добиениот дисконтинуитет и единствениот начин на кој може да го направи тоа е со (бесконечно) многу други синусни компоненти. Во овој случај резултатот од трансформацијата не е единствена линија во фреквентниот спектар која се појавува на соодветната фреквенција, туку енергијата „протекува“ во многу други спектрални линии. Како резултат на тоа, таквиот спектар не е реална слика на оригиналниот сигнал. За да се спречи протекување на сигналот, се применува тежински прозорец, при што во ова истражување е избран Ханингов прозорец кој ја анулира амплитудата на сигналот на краевите со цел отстранување на дисконтинуитетите и создавање сигнал кој е поблизок до реалниот периодичен сигнал. Резултатот од користење на Ханингов прозорец е прикажан на долниот дел од слика 44. Во случај кога сигналот е периодичен, примената на Ханингов прозорец го влошува резултатот (наместо една спектрална линија има три линии), но во случај на непериодични резултатот е значително подобрен - има само неколку спектрални линии.

Во ова истражување, Ханингов прозорец се применува пред трансформацијата на сигналот во фреквентен домен со примена на брза Фуриева трансформација.

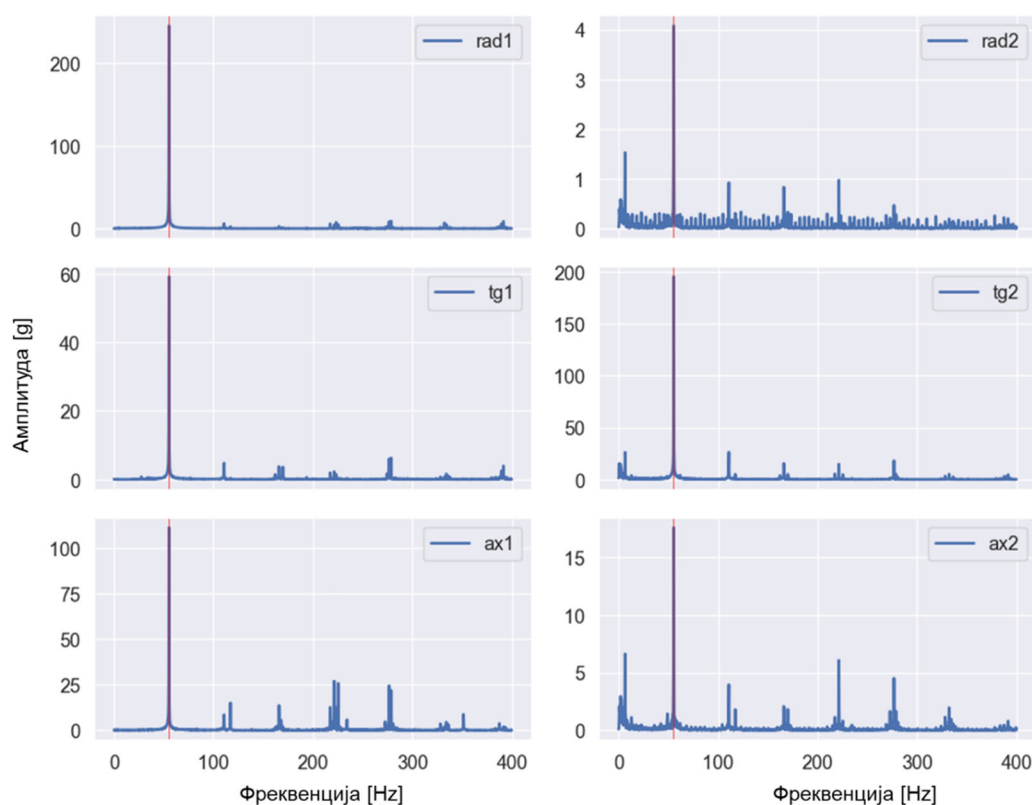
- Трансформација и анализа на фреквентниот спектар на сигналот

По примената на нископропусниот Батервортот филтер и Ханингов прозорец, обработениот сигнал се трансформира во фреквентен домен со примена на брза Фуриева трансформација (FFT).


На слика 45 прикажан е фреквентниот спектар при присутен дебаланс со ниво на изразеност од 35 g при зададена ротациона брзина на вратилото од 56,7296 Hz, добиен со помош на алгоритмот на брза Фуриева трансформација. Анализирани се сигналите по радијалната, тангенцијалната и аксијалната оска, снимени на куќиштата на двете лежишта. Согласно теоретските основи, во фреквентниот спектар на сигнали снимени во присуство на дебаланс, врвна вредност се очекува при фреквенција еднаква на ротационата фреквенција на вратилото, слика 15. Ротационата фреквенција се пресметува користејќи го методот објаснет во 2.3, слика 10. Може да се забележи дека врвни вредности во амплитудата се појавуваат при фреквенција еднаква на ротационата фреквенција, која во овој случај изнесува 55,40 Hz. На слика 45 може да се забележи врвна вредност во фреквентниот спектар која е еднаква на ротационата фреквенција на вратилото, односно при вредност 55,40 Hz (црвена вертикална линија).



Слика 44. Манифестација на протекување на сигнал, лево – периодичен сигнал, десно – непериодичен сигнал (Anti-Leakage)



Слика 45. Фреквентен спектар на сигнал снимен при присутен дебаланс во машината со ниво на изразеност од 35 g при ротациона фреквенција од 55,40 Hz (црвена линија)



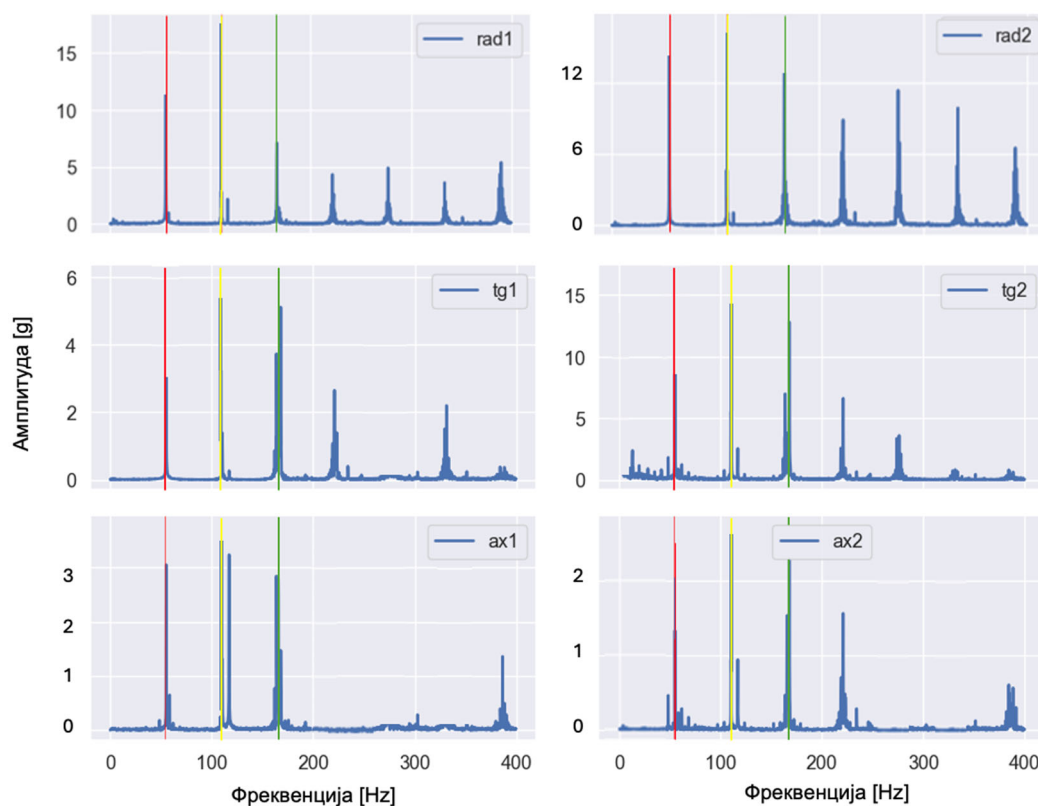
Слика 46. Фреквентен спектар на сигналот снимен со тахометарот при брзина на ротација на вратилото од 56,7296 Hz

На слика 47, даден е фреквентниот спектар на сигнал снимен при присутна паралелна нецентричност по вертикален правец со ниво на изразеност од 1.90 mm при ротациона брзина на вратилото од 56,7296 Hz. При дијагностика на конкретната машина, навраќајќи се на теоретските основи, потребни се вредностите за првите три хармоници на ротационата фреквенција, табела 12.

Добиениот фреквентен спектар има врвна вредност при вториот хармоник на ротационата фреквенција во сите оски, при што амплитудите по радијалната оска се значително поголеми од оние по аксијалната. Ваквиот фреквентен спектар е карактеристичен за паралелна нецентричност, слика 16.

Карактеристиките на генерираните спектри се поклопуваат со теоретските основи со што може да се заклучи дека подготовката и обработката на сигналите е правилно извршена. Од вака обработените сигнали може да се екстрахираат карактеристиките засновани на физиката на

ротирачката машина кои се однесуваат на содржаната енергија при хармониците во фреквентниот спектар, односно Содржаната енергија при првиот хармоник E_{1X} од спектарот и Индексот на нецентричност MIS_{index} .



Слика 47. Фреквентен спектар на сигнал снимен при присутна нецентричност во машината со ниво на изразеност од 1.90 mm

*прв хармоник 55,40 Hz (црвена линија), В=втор хармоник 110,80 Hz (жолта линија), трет хармоник 166,20 Hz (зелена линија)

Табела 12. Вредности на првите пет хармоници при ротациона фреквенција од 55,40 Hz

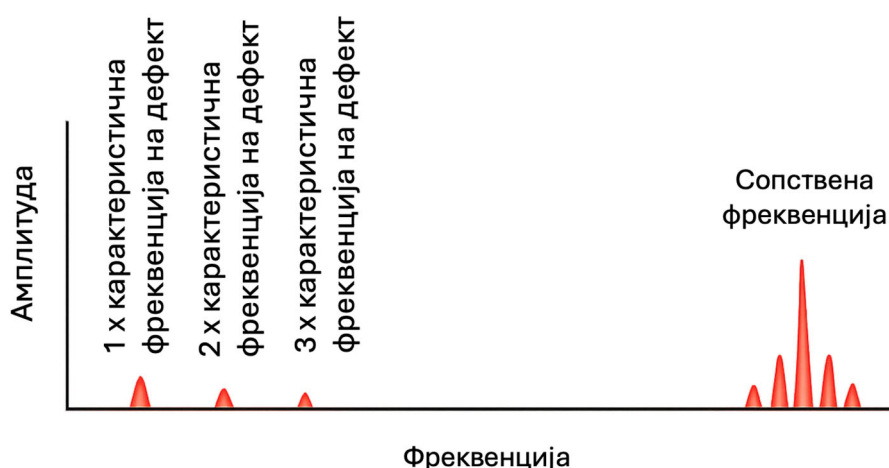
Хармоник	I	II	III	IV	V
Фреквенција [Hz]	55,40	110,80	166,20	221,60	277,00

3.2.2 Анализа на енvelope (Envelope Analysis)

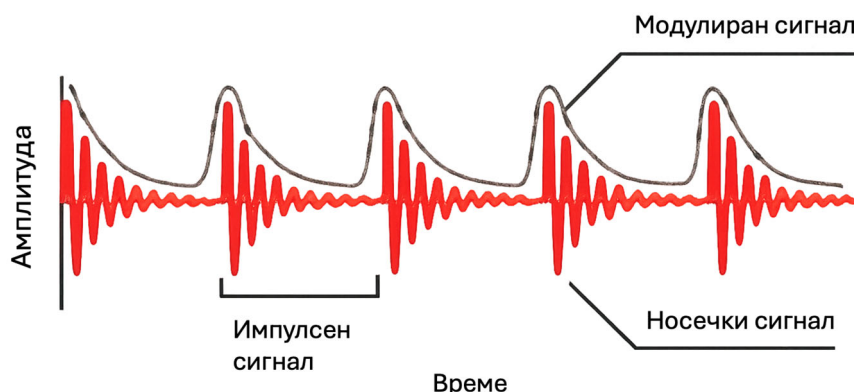
Доколку во измерените вибрациони сигнали се присутни значителни шумови, обработката на сигналите преку нивно филтрирање и директна примена на брза Фуриева трансформација (FFT) не резултира со фреквентни спектри кои се поклопуваат со очекуваните карактеристики за секој тип на дефект согласно теоретските основи. Оваа појава е типична при дијагностика на тркалачки лежишта, бидејќи локалните дефекти генерираат краткотраен импулсен сигнал при секој контакт на топчињата со дефектната површина. Иако карактеристичните фреквенции на овие дефекти (BPFO, BRFI, BSF) се наоѓаат во нискофреквентниот опсег, самите удари претставуваат импулси во временскиот домен кои покриваат широк фреквентен спектар. Поради тоа, овие импулси може да ги возбудат сопствените фреквенции на системот лежиште–кукиште–акцелерометар, кои најчесто се наоѓаат во високофреквентниот опсег (1-20 kHz), слика 48. Како резултат на оваа појава, значајната информација во однос на присутни дефекти во лежиштата не се појавува директно како изразен

врв при карактеристичните фреквенции во амплитудно-фреквентниот спектар, туку се манифестира како амплитудна модулација, на високофреквентниот резонантен одговор на системот (и е содржана во високофреквентната резонанца). Во дијагностиката на тркалачки лежишта, високофреквентниот резонантен одговор на механичкиот систем претставува носечки сигнал, додека карактеристичната фреквенција на дефектот дејствува како модулирачки сигнал, слика 49. Ударите кои настануваат при контакт на топчињата со дефектната површина периодично ја возбуждуваат сопствената фреквенција на системот, при што амплитудата на резонантната вибрација е модулирана со фреквенцијата на дефектот. Како последица на тоа, информацијата за дефектот е содржана во енвелопата на сигналот, а не директно во неговиот амплитудно-фреквентен спектар.

За издвојување на оваа значајна информација и за појасна идентификација на дефектите кај тркалачките лежишта, се применува дополнителен метод за обработка на сигналите познат како анализа на енvelope (Envelope Analysis) [15]. Во рамки на ова истражување, анализата на енvelope се користи за издвојување на нискофреквентната информација поврзана со карактеристичните дефектни фреквенции од високофреквентниот резонантен одговор, со што се овозможува појасна и посигурна дијагностика на дефектите кај тркалачките лежишта. Потоа, од така обработените сигнали се екстрахираат физичките карактеристики кои се поврзани со присуство на дефекти во тркалачки лежишта.



Слика 48. Концептуален приказ на амплитудно-фреквентен спектар на вибрационен сигнал при присутен дефект во тркалачко лежиште, со појава на резонантен високофреквентен одговор



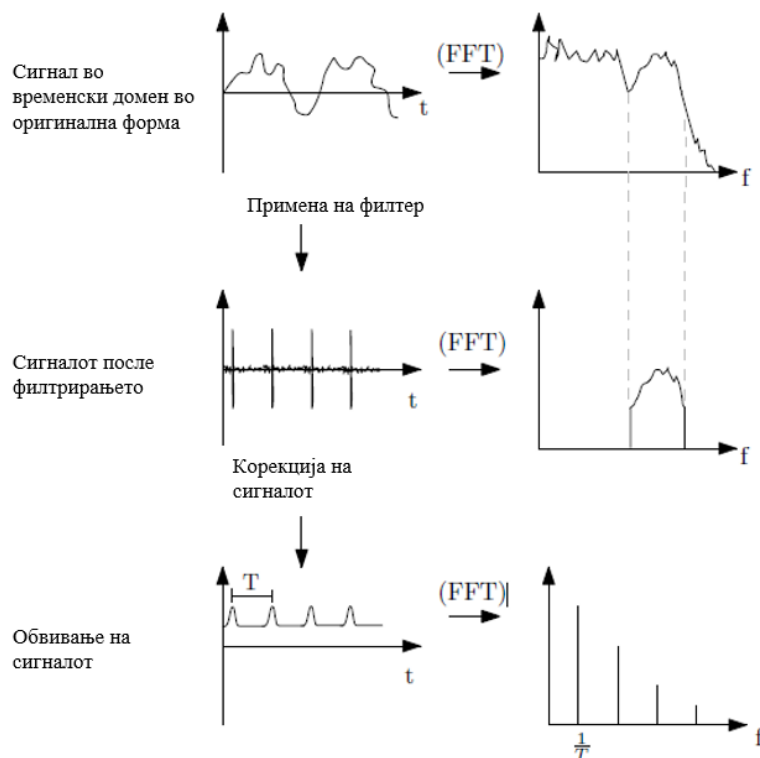
Слика 49. Концептуален приказ на модулиран сигнал во временски домен снимен при присутен дефект во лежишта

Методот за обработка на сигналите анализа на енvelopa врши демодулација на сигналот на неговите составни сигнали кои потекнуваат од различни извори на машината и отстранување на пропратните шумови во сигналот. Генерално, се состои од следните три чекори, слика 50:

а) снимениот вибрационен сигнал во својата оригинална форма во временски домен, поминува низ соодветен филтер кој дозволува премин на определен опсег на фреквенции (band-pass filter), а амплитудата на останатите значително ја намалува. Потребата од примена на ваков филтер се должи на тоа што снимениот вибрационен сигнал во својата оригинална форма најчесто содржи значајни нискофреквентни компоненти поврзани со ротационата динамика на системот (дебаланс, нецентричност), како и високофреквентни компоненти поврзани со импулсните возбуди од дефектите во лежиштата. Поради тоа, неопходно е најпрво да се издвои фреквентниот опсег во кој е содржана информацијата која е поврзана со дефектите во лежиштата. Во овој дел дизајниран е и применет Батервортов филтер од четврт ред, со долна гранична фреквенција од 300 Hz и горна гранична фреквенција од 2000 Hz. Како што беше и претходно објаснето, во искористената база на податоци, максималната ротациона фреквенција при која се снимени сигналите изнесува приближно 60 Hz, па хармониците поврзани со дебаланс и нецентричност се очекуваат до вредности од околу 240 Hz. За да се отстранат хармониците кои ги опишуваат дебалансот и нецентричната, избрана е вредност од 300 Hz како долна гранична фреквенција. Исто така, согласно постоечката литература [16,20,32], горната вредност за граничната фреквенција (2 kHz) целосно ги опфаќа карактеристичните фреквенции од интерес, па нема ризик од губење релевантни дијагностички информации.

Согласно горенаведеното, избраниот опсег овозможува отстранување на нискофреквентните компоненти поврзани со дебаланс и нецентричност и задржување на високофреквентната резонантна содржина која е возбудена од импулсите при дефекти во лежиштата.

Примената на Батервортов филтер овозможува рамномерна амплитудна карактеристика во пропусниот опсег без извитоперување на сигналот, што го прави погоден за понатамошна демодулација.



Слика 50. Шематски приказ на основните чекори во состав на методот анализа на енvelopa

Така филтрираниот сигнал е потоа коригиран, односно се задржуваат само позитивните вредности.

б) Следно така обработениот сигнал се обвива користејќи ја Хилбертовата трансформација (Hilbert Transformation). Со оваа постапка се добива временски сигнал чија амплитуда ја следи модулацијата предизвикана од дефектните фреквенции, односно во понатамошните анализи се влегува со множеството точки формирано од обвивката/енвелопата на обработениот сигнал во временски домен.

Енвелопата сè уште може да содржи високофреквентни компоненти и шум, поради што се применува дополнително нископропусно филтрирање. Во овој дел дизајниран е и применет нископропусен Батервортов филтер од четврти ред. Со овој чекор се задржуваат карактеристичните дефектни фреквенции и нивните хармоници, како и можните странични појаси, додека преостанатите високофреквентни компоненти се отстрануваат.

Меѓутоа, при избирање на вредноста на граничната фреквенција неопходно е да се утврди дали највисоките значајни фреквенции поврзани со анализираните дефекти се пониски од оваа граница. Од анализираните дефекти, највисоките карактеристични фреквенции се очекуваат при присутен дефект во надворешниот прстен на лежиштето (BPFO). Имајќи ја во предвид највисоката вредност за ротационата фреквенција при која се снимени сигналите, која изнесува 60 Hz, вредноста за карактеристичната фреквенција при присутен дефект во надворешен прстен на лежиштата според табела 4 и израз (2.7) изнесува 179.88 Hz. Согласно слика 19, за прецизна дијагностика на овој дефект неопходен е четвртиот хармоник на BPFO кој изнесува 719.52 Hz. Според тоа, избрана вредност за граничната фреквенција на нископропусниот Батервортов филтер од четврти ред е 800 Hz која е вредност доволно повисока од максималната очекувана 719.52 Hz.

Вредностите за карактеристичните фреквенции при секој дефект во тркалачко лежиште се пресметани согласно геометријата на лежиштето (табела 4) и изразите (2.7) - (2.9):

$$BPFO = \frac{8}{2} \cdot \left(1 - \frac{7,145}{21,374} \cdot \cos 41,5^\circ\right) \cdot f_r = 8 \cdot FTF = 2,9980 \cdot f_r$$

$$BSF = \frac{21,374}{2 \cdot 7,145} \cdot \left(1 - \left(\frac{7,145}{21,374} \cdot \cos 41,5^\circ\right)^2\right) \cdot f_r = 1,402 \cdot f_r$$

$$FTF = \frac{1}{2} \cdot \left(1 - \frac{7,145}{21,374} \cdot \cos 41,5^\circ\right) \cdot f_r = 0,3750 \cdot f_r$$

и се дадени во табела 13, во функција од ротационата фреквенција.

Табела 13. Карактеристични фреквенции за дефекти во тркалачки лежишта од MaFaulda база на податоци – изразени во функција од ротационата фреквенција

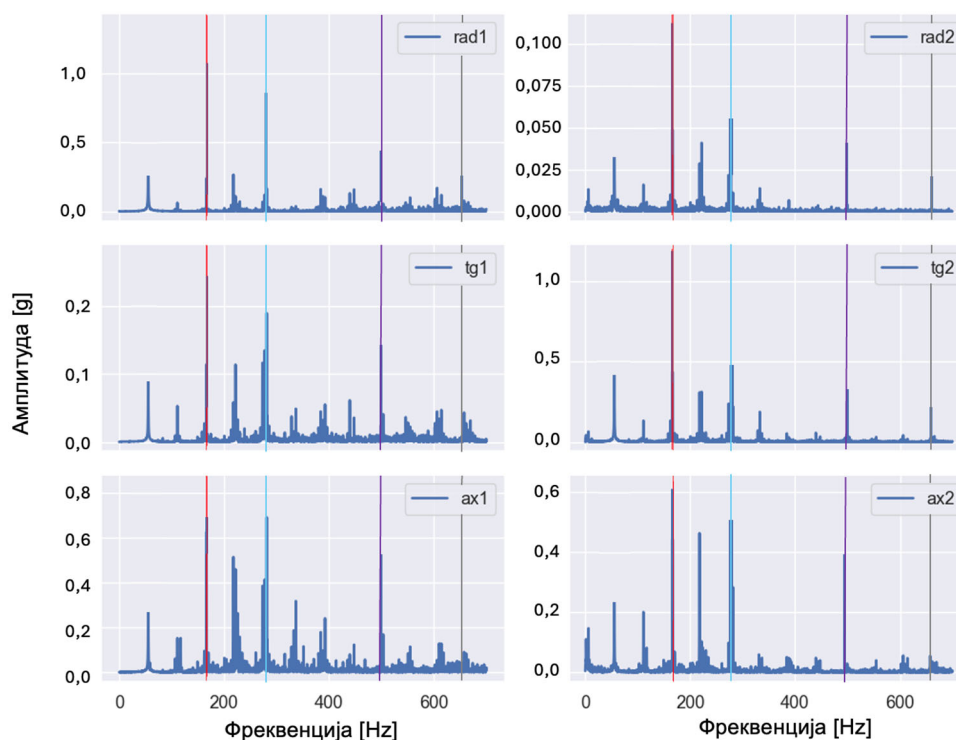
Тип на дефект	Карактеристична фреквенција
FTF	$0.3750 \cdot f_r$
BPFO	$2.9980 \cdot f_r$
BSF	$1.402 \cdot f_r$

Пред трансформацијата во фреквентен домен, на енvelopираниот сигнал во временски домен се применува и филтер против протекување на сигналот - Ханингов прозорец (Hanning Window).

в) излезниот сигнал се пренесува во фреквентен домен користејќи брза Фуриева трансформација (FFT). На овој начин се добива спектарот на енвелопата, во кој јасно се појавуваат врвни вредности при карактеристичните фреквенции на дефектите кај лежиштата и нивните хармоници.


Како пример, на слики 51 и 52 дадени се фреквентните спектри на сигналите снимени при присутни дефекти во тркалачките лежишта и тоа во надворешниот прстен и топчињата и присутен дебаланс од 20 g, соодветно. Мора да се нагласи дека на сликите се прикажани одредени интервали на фреквенции во кои забележани пикови, а не е прикажан целиот фреквентен спектар (до 2,5 kHz) затоа што во останатиот дел не се забележани значителни врвни вредности по примена на методот за обработка анализа на енVELOПА. Причината за ваквиот приказ е добивање на јасни фреквентни спектри и избегнување на фреквентни интервали кои не даваат значајни дијагностички информации.

Согласно добиените фреквентни спектри по филтрирањето на сигналите во состав на базата на податоци MaFaulda и примената на FFT, може да се заклучи дека искористената методологија за нивна обработка и трансформација е задоволителна односно добиените фреквентни спектри се поклопуваат со очекуваните фреквентни спектри за секој тип на дефект согласно претходно објаснетите теоретски основи. Од вака обработените сигнали може да се екстрахираат физичките карактеристики кои се поврзани со дефекти во тркалачки лежишта.



Слика 51. Фреквентен спектар на сигнал снимен при присутен дефект на надворешен прстен и дебаланс од 20 g, $f_r = 55,40$ Hz

*BPFO $2,9980 \cdot 55.4 = 166.0892$ Hz (црвена линија), $2 \cdot \text{BPFO} = 332.1784$ Hz (сина линија),
 $3 \cdot \text{BPFO} = 498.2676$ Hz (виолетова линија), $4 \cdot \text{BPFO} = 664.3568$ Hz (сива линија)



Слика 52. Фреквентен спектар на сигнал снимен при присутен дефект во топчиња и дебаланс од 20 g, $f_r = 54,80$ Hz

*BPF $1,402 \cdot 54.8 = 76.8296$ Hz (црвена линија), $2 \cdot \text{BPF} = 153.6592$ Hz (сина линија)

3.3 Нормализација на екстрахираните карактеристики

Во ова истражување, целта од примената на база на снимени вибрациони сигнали при присутни дефекти во експериментални или реални услови е креирање на систем за одржување, поконкретно систем за прогностика и управување со состојбата на ротационите машини кој би можел да се имплементира во реални паметни фабрики. Затоа, со цел отстранување на зависноста на резултатите и точноста на системот за одржување од конфигурацијата на експерименталниот стол или реалниот систем, од работните услови, од фреквенцијата на семплирање или од времетраењето на снимените сигнали при креирање на базата на податоци за тренинг, тестирање и валидација на алгоритмите, извршена е нормализација на амплитудата на екстрахираните карактеристики.

Притоа е применета Min–Max нормализација, со која амплитудата на секоја карактеристика се нормализира и има вредност во интервалот $[0,1]$, според изразот:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2.10)$$

x_{norm} – нормализирана вредност на амплитудата на екстрахираните карактеристики

x – оригинална вредност на амплитудата на екстрахираните карактеристики

x_{max} – максимална вредност на амплитудата на екстрахираните карактеристики

x_{min} – минимална вредност на амплитудата на екстрахираните карактеристики

Кодот за нормализација на екстрахираните карактеристики е даден во Прилог А-6. По примената на соодветни методи за обработка, екстрахираните се различни типови на карактеристики согласно табела 8. По нивната нормализација истите се подготвени за примена за тренинг и тестирање на алгоритми за надгледувано машинско учење кои ќе служат за дијагностика на ротирачки машини.

4. ПРИМЕНА НА АЛГОРИТМИ НА НАДГЛЕДУВАНО МАШИНСКО УЧЕЊЕ ЗА ДИЈАГНОСТИКА НА ДЕФЕКТИ КАЈ РОТИРАЧКИ МАШИНИ

Претходните поглавје ги опфатија фазите на избор на соодветна база на податоци за тренирање на модели за дијагностика на дефекти, нивната подготовка и обработка, како и екстракцијата на релевантни карактеристики од вибрационите сигнали. Моделите за дијагностика на дефекти генерално решаваат проблеми на класификација на податоците, односно се фокусираат на одредување на моменталната состојба на машината преку класификација на моменталната состојба на системот согласно влезните податоци во дискретни состојби.

Во зависност од поставениот дијагностички проблем, класификацијата може да биде бинарна, односно да овозможи разграничување помеѓу нормална состојба и состојба со присутен дефект, или пак мултикласна, при што се врши идентификација на конкретниот тип на дефект, како што се дебаланс, нецентричност и различни типови дефекти кај лежиштата. Алгоритмите на машинско учење кои се применуваат за овие цели најчесто се делат во две основни групи: алгоритми базирани на техники на надгледувано учење и алгоритми базирани на техники на ненадгледувано учење. Кај алгоритмите со надгледувано учење, влезните податоци се организирани во однапред дефинирани класи, додека кај алгоритмите со ненадгледувано учење, природата и бројот на присутните класи не се познати. Во тој случај, покрај класификацијата, дополнителен предизвик претставува и идентификацијата и дефинирањето на самите класи.

Согласно избраната база на податоци, опишана во второто поглавје, во ова истражување се применуваат алгоритми базирани на техники на надгледувано учење за дијагностика на дефекти кај ротирачки машини. Како што беше наведено и во воведното поглавје на оваа дисертација, табела 3, врз основа на анализираната релевантна литература, алгоритмите кои покажуваат највисока точност при дијагностика на дефекти се алгоритмот на машини со поддржувачки вектори, алгоритмот на случајни шуми и алгоритмот на градиентно зголемување. Покрај нивната индивидуална примена, реализирана е и комбинација на овие алгоритми во форма на комбинирани модели при што на секој алгоритам му се доделува соодветен тежински фактор, во зависност од неговата постигната точност во фазата на тестирање. Ваквиот тежински систем овозможува оптимизирано донесување одлуки во фазата на валидација, со цел искористување на предностите на секој поединечен модел и подобрување на вкупните дијагностички перформанси. Примената на повеќе алгоритми на машинско учење, како и нивна комбинација, овозможува споредливост на добиените резултати, како и избор на модели кои обезбедуваат висока точност и робусност при различни работни услови.

Во рамки на ова поглавје ќе биде направена детална споредба на перформансите на применетите алгоритми на надгледувано машинско учење, при што ќе се анализира разликата помеѓу модели базирани исклучиво на екстрахирани карактеристики од базата на податоци и модели кои комбинираат екстрахирани карактеристики од базата на податоци како и карактеристики кои произлегуваат од динамиката на анализираната машина.

Класификациските модели ќе бидат дизајнирани така што ќе вршат двослојна класификација. Во првиот слој ќе се изврши мултикласна класификација со цел идентификација

на доминантната состојба на машината, односно определување на тип на дефект кој има највисоко ниво на веројатност да биде присутен. Во вториот слој ќе се примени бинарна класификација, чија цел е испитување на присуството на дебаланс како дополнителен дефект, имајќи предвид дека дебалансот претставува дефект кој многу често коегзистира со дефекти кај тркалачките лежишта и може значително да влијае врз вибрационата состојба на системот.

Алгоритмот кој ќе покаже највисоки перформанси ќе биде дополнително искористен за тренирање на модели со влезни карактеристики поединечно по секоја мерна оска, со цел креирање дијагностички модели кои може да се применат за различни бази на податоци снимени по различни оски на мерење.

Класификацискиот модел кој ќе покаже највисоки перформанси во фазите на тренинг и тестирање, во следното поглавје ќе биде валидиран со примена на за него непознати бази на податоци, односно база на податоци снимена во лабораториски услови и база на податоци снимена во реални работни услови.

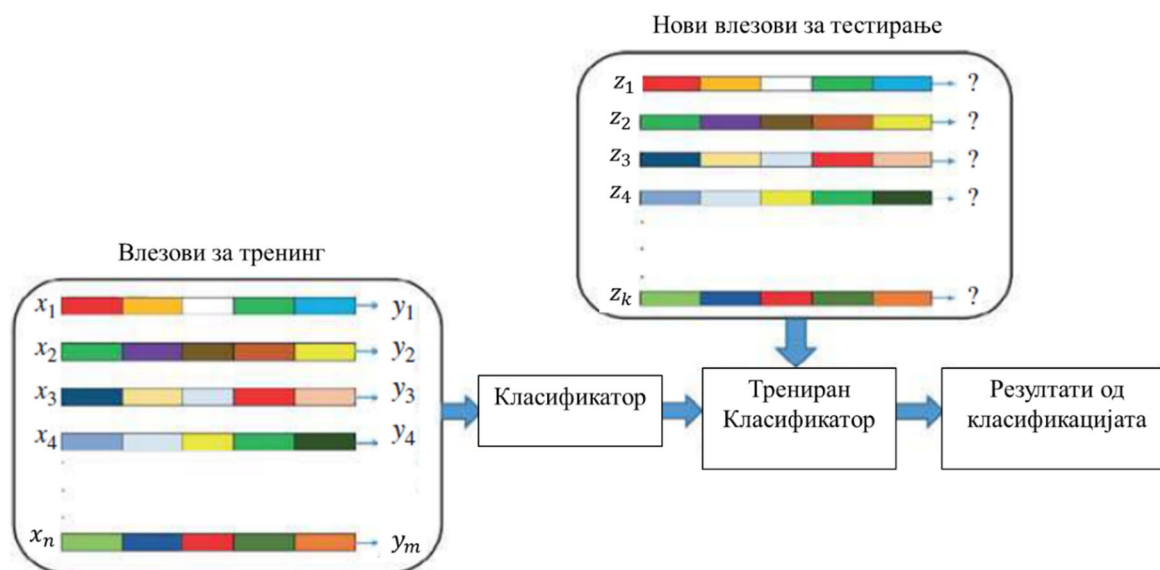
4.1 Алгоритми на надгледувано машинско учење

Алгоритмите на надгледувано машинско учење може да се поделат во две големи групи според типот на учење и тоа: алгоритми за класификација и алгоритми за регресија, кои се применуваат зависно од типот на влезни податоци и целта на нивната примена. Како влез при примена на алгоритмите на надгледувано машинско учење се користи множество од претходно екстрахирани податоци од снимените и обработени сигнали, како што беше објаснето во претходното поглавје. Потоа алгоритмите учат од тие влезови во фазата на тренинг, со цел носење одлуки во фазата на тестирање. При класификацијата, излезот е дискретен одговор и покажува на која класа припаѓа одреден влез. Класификацијата може да биде бинарна или мултикласна во зависност од тоа дали влезните податоци се класифицираат во две или во повеќе од две класи. При регресијата излезот е континуирана променлива.

Автоматизацијата на процесот на дијагностика во рамки на ова истражување е реализиран со примена на алгоритми на надгледувано машинско учење, при што секое множество екстрахирани карактеристики кое се користи при нивниот тренинг е означено согласно класата на која припаѓа. Притоа, неопходно е креирање на модел или класификатор кој ќе може да ја предвидува ознаката односно класата на нови влезови кои не се содржани во множеството влезови за тренинг, односно се сосема непознати за него. Генерираниот модел се однесува како функција f која врши најпрво учи како да ги поврзе влезовите x со означените излези y во делот на негов тренинг, а потоа во делот на тестирање за дадените влезови x предвидува соодветни излези y , слика 53. Меѓутоа, генерираното предвидување од моделот секогаш е подложно на определени грешки.

Целта при тренинг на моделот е намалување на функцијата на грешки, која се пресметува користејќи ги ознаките на влезовите. Сè додека не се достигне минимум на оваа функција (локален или апсолутен) параметрите на моделот се коригираат. Евалуацијата на грешките при класификација се врши после фазата на тренинг на моделот, и има специфична форма која детално е објаснета во следните поглавја и овозможува споредливост на перформансите на различни модели. Значајно е да се истакне дека голема предност на генерираните модели е нивната способност за анализа на податоци, односно откако еднаш ќе ги комплетираат фазите на тренинг и валидација, моделот може да евалуира големи бази на податоци и тоа со висока ефикасност и за краток временски интервал. Друга предност е димензионалноста на анализата, односно способностите за човечка визуелизација генерално ни овозможуваат следење до три димензии истовремено (нумерички или графички индикатори), додека кај моделите на машинско

учење не постои ограничување на бројот на димензии што може да ги анализира и кон кои може да се приспособи користејќи техники на машинско учење.



Слика 53. Шематски приказ на тренирање и тестирање на класификатор базиран на надгледувано машинско учење

При тестирање на класификаторот, односно при проценка на неговите перформанси, користејќи за него претходно непознати влезни податоци, неопходно е однапред да се дефинираат параметрите за евалуација и критериумот за евалуација.

За евалуација на перформансите на алгоритмите за класификација постојат повеќе различни параметри, при што изборот на соодветен параметар зависи од природата на проблемот и целите на анализата.

- **Точност (Overall Accuracy)** претставува најчесто употребуван параметар за евалуација и се пресметува како процент од сите примероци кои се правилно класифицирани, без разлика на класата на која припаѓаат. Со други зборови, го претставува соодносот меѓу бројот на точни одговори и вкупниот број на тестирани примероци.

При бинарна класификација:

$$\text{Точност} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.1)$$

TP (True Positive) - број на примероци кои припаѓаат на позитивната класа и се точно класифицирани како позитивни,

TN (True Negative) – број на примероци кои припаѓаат на негативната класа и се точно класифицирани како негативни,

FP (False Positive) - негативни примероци погрешно класифицирани како позитивни,

FN (False Negative) - позитивни примероци погрешно класифицирани како негативни.

При мултикласна класификација:

$$\text{Точност} = \frac{\sum_{i=1}^C TP_i}{N} \quad (4.2)$$

TP_i – точно класифицирани примероци од i – тата класа

C – број на класи,

N – вкупен број на примероци.

Иако параметарот точност дава општ приказ за перформансите на моделот, тој не обезбедува еднаков придонес на сите класи во конечната оценка. Чувствителен е на апсолутниот број на примероци по класа и дури и кај приближно балансиран бази може да даде предност на класите со поголема застапеност, што ја ограничува нејзината применливост во мултикласни дијагностички проблеми.

Во ова истражување се претпоставува дека сите класи имаат еднаква важност, односно дека секој тип на дефект има подеднакво значење од аспект на сигурноста, доверливоста и безбедното работење на машината. Поради тоа, не се фаворизира ниту една класа при евалуацијата на моделите, без разлика со колку примероци е претставена при фазата на тренинг. Затоа, покрај параметарот точност, при детална анализа на перформансите на моделите се користат и следните параметри:

- **Прецизност (Precision)** го претставува соодносот помеѓу бројот на точно детектирани примероци од одредена класа и вкупниот број примероци кои моделот ги има класифицирано во таа класа:

$$\text{Прецизност} = \frac{TP_i}{TP_i + FP_i} \quad (4.3)$$

TP_i (True Positives) – примероци од класата i кои се точно класифицирани,

FP_i (False Positives) – примероци од други класи кои погрешно се класифицирани како i -та класа.

Овој параметар е особено значаен при намалување на бројот на лажно позитивни резултати.

- **Одзив (Recall)** познат и како осетливост (Sensitivity) го претставува соодносот помеѓу бројот на точно детектирани примероци од одредена класа и вкупниот број реални примероци од таа класа:

$$\text{Одзив} = \frac{TP_i}{TP_i + FN_i} \quad (4.4)$$

Во контекст на дијагностика на дефекти, овој параметар има клучна улога бидејќи покажува колкав дел од реалните дефекти моделот успева да ги препознае, односно колку дефекти остануваат недетектирани.

- **F1-мерка (F1-score)** претставува хармониска средина помеѓу прецизноста и одзивот и овозможува балансирана проценка на моделот:

$$F1 = 2 \cdot \frac{\text{Прецизност} \cdot \text{Одзив}}{\text{Прецизност} + \text{Одзив}} \quad (4.5)$$

. Висока вредност на F1 укажува дека моделот истовремено има добра прецизност и висок одзив.

Поради еднаквата важност на сите класи, параметрите за евалуација: прецизност, одзив и F1-мерка се пресметуваат со примена на макро-усреднување (macro-averaging), при што метриците најпрво се пресметуваат поединечно за секоја класа, а потоа се зема нивната аритметичка средина:

$$\text{Параметар}_{macro} = \frac{1}{C} \sum_{i=1}^C \text{Параметар}_i \quad (4.6)$$

На тој начин се обезбедува еднаков придонес на секоја класа во конечната оценка на перформансите, независно од бројот на примероци по класа.

Дополнително, визуелна и информативна алатка за анализа на резултатите претставува матрицата на конфузија (confusion matrix), која овозможува детален увид во правилно и погрешно класифицираните примероци по класи. Елементи од матрицата во нејзината главна

дијагонала (составена од сите TP односно сите точно класифицирани примероци од сите класи) ја претставуваат точноста по класа (одзивот), додека елементите надвор од дијагоналата ги прикажуваат погрешно класифицираните примероци. Поради претпоставката дека сите класи имаат еднаква важност, конфузните матрици во овој труд се нормализирани по редови, при што секоја реална класа е претставена со 100%. На овој начин се обезбедува еднаков придонес на сите типови дефекти во евалуацијата, независно од нивната застапеност во базата на податоци. Ваквиот пристап овозможува јасна интерпретација на одзивот по класи и е соодветен за дијагностички системи каде што пропуштањето на било кој тип на дефект може да има сериозни последици. Важно е да се напомене дека параметарот точност не може директно да се прочита од нормализираната конфузна матрица по редови, бидејќи при нормализацијата се губи информацијата за апсолутниот број на примероци по класа. Нормализираната матрица првенствено служи за анализа на одзивот по класи, додека параметарот точност се пресметува од оригиналните, ненормализирани резултати.

Поради наведените причини, приказот на резултатите од тестирањето на тренираните модели во ова истражување, перформансите на класификаторите се прикажани преку параметарот точност, како и преку макро-усреднети вредности на параметрите прецизност, одзив и F1-мерката, додека конфузните матрици се користат за детална анализа на параметарот одзив по класи.

Мора да се потенцира дека евалуацијата на моделот не се врши со истото множество примероци кое е користено за негов тренинг, бидејќи целта на моделот е постигнување на што повисока точност при препознавање на нови, претходно непознати примероци со цел проверка на способноста на класификаторот за генерализација. Пред да се премине кон фазата на тестирање на алгоритмот неопходно е дефинирање на критериум за евалуација на перформансите на моделот.

Еден од критериумите за експериментална евалуација на перформансите на моделот со примена на една база на податоци е нејзина поделба во групи податоци за тренинг и за тестирање. Издвоената група на податоци за тренинг служи за градење и подесување на класификаторот, додека групата за тестирање служи само за негова евалуација. При примена на алгоритми на надгледувано машинско учење за дијагностика и прогностика на дефекти, вообичаено 80% од податоците се користат за негов тренинг додека 20% за тестирање и евалуација [147-149].

Еден од главните проблеми на кој треба да се внимава при креирање на нов модел за класификација е проблемот на преклопување (*overfitting*), односно проблем при кој моделот покажува висока точност во фазата на тренинг, но во фазата на валидација при која треба да ги класифицира за него непознатите влезни податоци, покажува ниска точност. Најдобар метод кој служи за проверка на моделот на овој проблем е често применуваната техника за евалуација на класификатори - техниката на крос-валидација. Влезните екстрахирани карактеристики кои се користат за тренинг се делат на K делови и се вршат K итерации на тренинг и тестирање така што K -тиот дел од екстрахираните карактеристики се користи за тестирање, а останатите делови за тренинг на класификаторот, слика 54. По извршување на секој тест во рамки на крос-валидацијата со K -превиткувања, се генерираат параметри за евалуација на перформансите на класификаторот и меѓусебно се споредуваат. Во рамки на ова истражување овој метод е искористен при евалуација на сите креирани класификатори.



Слика 54. Шематски приказ на поделба на податоци при крос-валидација со 5 превиткувања

Во продолжение ќе бидат изнесени теоретските основи на алгоритмите на надгледувано учење кои се користени во рамки на ова истражување.

4.1.1 Алгоритам на машини со поддржувачки вектори

Алгоритамот на машини со поддржувачки вектори е еден од најприменуваните алгоритми базирани на надгледувано машинско учење за класификација на дефекти кај ротирачки машини, а често наоѓа своја примена и при решавање на проблеми во полето на регресија. Целта на овој алгоритам е наоѓање на најдобрата хипер рамнина која би ги разделила примероците од различни класи на начин што растојанието меѓу одделните класи односно маргината би била максимална. Поддржувачки вектори се примероците кои се најблиски до креираната хипер рамнина, односно оние примероци кои лежат на краевите на маргината. Маргината уште може да се дефинира и како нормалното растојание меѓу линиите кои поминуваат низ поддржувачките вектори.


Нека е дадено множество влезни примероци со соодветно означени класи во облик на карактеристика-ознака на класа, односно во облик:

$$D = (x_1, y_1), (x_2, y_2), \dots, (x_L, y_L)$$

$$D = (x_i, y_i), \forall i = 1, 2, \dots, L \quad (4.7)$$

каде $x_i \in R^N$ е N димензионален вектор на влезни карактеристики, а y_i е вектор на ознаки на соодветните класи за секој $i = 1, 2, \dots, L$ и нека $y_i \in \{+1, -1\}$ за две потенцијални класи односно нормална состојба на машината (без присутен дефект) и состојба со присутен дефект, што всушност претставува бинарен проблем на класификација. Основниот проблем кој треба да го реши бинарната класификација е дефинирање на функција $f(x)$ која со висока точност ќе ја предвиди ознаката на класата y_i за непознат вектор на влезни карактеристики x_i . Во зависност од тоа дали влезните карактеристики може да се разделат линеарно или не, алгоритамот на машини со поддржувачки вектори врши линеарни, слика 55, и нелинеарни класификации, слика 56.

Наједноставен пример е бинарна линеарна класификација, слика 55, при која хипер рамнината е права која подеднакво ги одделува најблиските податоци од двете одделни класи, односно обезбедува максимална маргина. Класификаторот кај бинарната линеарна класификација уште се нарекува и линеарен класификатор на машини со поддржувачки вектори.



Слика 55. Бинарна линеарна класификација со линеарен класификатор за машини со поддржувачки вектори

Во општ случај функцијата $f(x)$ која ја дефинира хипер рамнината има облик:

$$f(x) = \text{sgn}(\mathbf{w}^T \mathbf{x} + b) \quad (4.8)$$

при што sgn е функција која го дефинира знакот на $(\mathbf{w}^T \mathbf{x} + b)$, \mathbf{w} е нормалниот вектор кој ја дефинира хипер рамнината, \mathbf{w}^T е транспониран вектор од нормалниот вектор \mathbf{w} , \mathbf{x} е вектор на влезни карактеристики, b е скалар кој го означува растојанието помеѓу хипер рамнината и координатниот почеток на хипер просторот.

За да се определи оптималната хипер рамнина, поставени се следните три хипотези:

$$H_0 = \mathbf{w}^T \mathbf{x} + b = 0$$

$$H_1 = \mathbf{w}^T \mathbf{x} + b = -1$$

$$H_2 = \mathbf{w}^T \mathbf{x} + b = +1$$

Графички прикажано на слика 48, растојанието помеѓу H_1 и H_2 е маргина M , односно нормалното растојание M од точка x_i до хипер рамнината $\mathbf{w}^T \mathbf{x} + b = 0$ може да се определи како:

$$M = \frac{|\mathbf{w}^T \mathbf{x}_i + b|}{\|\mathbf{w}\|} \quad (4.9)$$

$\|\mathbf{w}\|$ – големина на векторот \mathbf{w} .

Најдобар класификатор е оној со најголема маргина, односно што е поголема маргината, тоа е подобар класификаторот. Во овој случај маргината M може да се запише како: Без разлика за каков тип на класификација или регресија станува збор, целта на алгоритмот на машини со поддржувачки вектори при фазата на тренинг е да најде нормалниот вектор \mathbf{w} кој ја дава максималната маргина (M) при исполнување на следното ограничување:

$$y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq M, \forall i = 1, 2, \dots, L \quad (4.10)$$

за примероците во позитивната класа $y_i = +1, (\mathbf{w}^T \mathbf{x}_i + b) \geq M$

за примероците во негативната класа $y_i = -1, (\mathbf{w}^T \mathbf{x}_i + b) \leq -M$

односно сите примероци во рамки на x_i лежат најмалку на растојание M од хипер рамнината.

Согласно поставените хипотези H_1 и H_2 , за поддржувачките вектори ќе важи следното:

$$|\mathbf{w}^T \mathbf{x}_i + b| = 1 \quad (4.11)$$

Имајќи ги во предвид претходните два изрази (4.9) и (4.11) може да се изведе:

$$M = \frac{1}{\|\mathbf{w}\|} \quad (4.12)$$

Како што беше претходно нагласено, целта е да се добие максимална маргина M , што е еквивалентно на минимизирање на $\|\mathbf{w}\|$:

$$M_{max} = \min \|\mathbf{w}\| \quad (4.13)$$

така што

$$y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq M, \forall i = 1, 2, \dots, L \quad (4.14)$$

Важно е да се истакне дека сведувањето на минимум на $\|\mathbf{w}\|^2$ дава исто решение како и одредувањето на минимум на $\|\mathbf{w}\|$ со таа разлика што работењето со квадратната форма на големината на нормалниот вектор е поедноставно поради тоа што $\|\mathbf{w}\|^2$ е диференцијабилна за секоја вредност. Поради дополнително поедноставување на првиот извод при оптимизација, $\|\mathbf{w}\|^2$ се множи со коефициентот $\frac{1}{2}$, односно може да се запише:

$$M_{max} = \min \frac{1}{2} \|\mathbf{w}\|^2 \quad (4.15)$$

така што

$$y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq M, \forall i = 1, 2, \dots, L \quad (4.16)$$

Процесот на оптимизација всушност претставува наоѓање хипер рамнина која ќе резултира со висока ефективност и точноста при предвидување.

Со цел наоѓање на екстремот при истовремено исполнување на даденото ограничување, потребно е да воведување на Лагранжови множители α кои овозможуваат комбинација на изразот за наоѓање на екстрем и ограничувањето во еден единствен израз, односно:

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^L \alpha_i [y_i(\mathbf{w}^T \mathbf{x}_i + b) - 1] \quad (4.17)$$

$$\alpha_i \geq 0, \forall i = 1, 2, \dots, L$$

α_i – Лагранжови множителни кои се однесуваат на ограничувањата.

За да се реши претходниот израз, се користат условите на Каруш-Кун-Такер кои се неопходни и доволни за постигнување оптимална хипер рамнина и задоволување на ограничувањето. Еден од условите на Каруш-Кун-Такер кој тука ќе биде применет гласи:

$$\alpha_i [y_i(\mathbf{w}^T \mathbf{x}_i + b) - 1] = 0 \quad (4.18)$$

$$\forall i = 1, 2, \dots, L$$

Ако се пресметаат парцијалните изводи на (4.17) по w и b , се добиваат изразите:

$$\frac{\partial L(\mathbf{w}, b, \alpha)}{\partial b} = \sum_{i=1}^L \alpha_i y_i = 0 \quad (4.19)$$

$$\frac{\partial L(\mathbf{w}, b, \alpha)}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^L \alpha_i y_i \mathbf{x}_i = 0 \quad (4.20)$$

односно

$$\mathbf{w} = \sum_{i=1}^L \alpha_i y_i \mathbf{x}_i \quad (4.21)$$

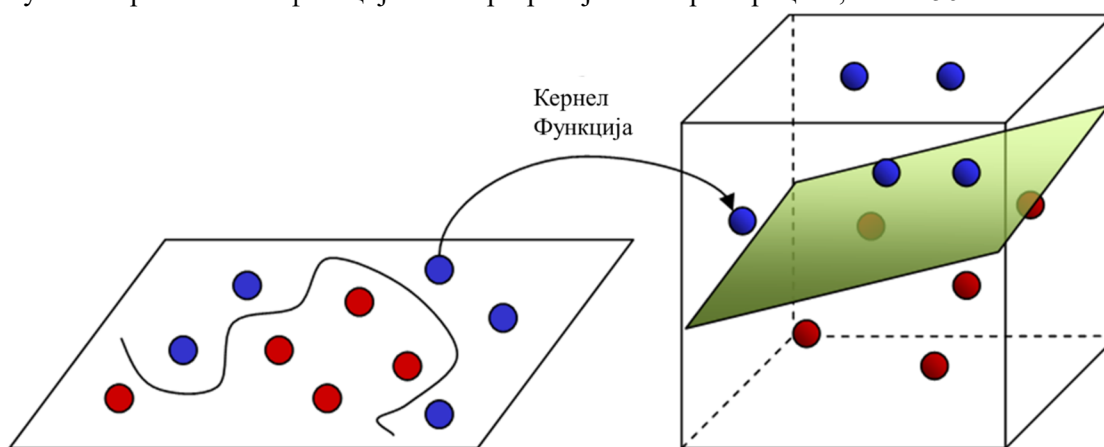
Со замена на изразите од парцијалните изводи во (4.17) се добива Лагранжовиот дуален проблем:

$$L_{dual} = \sum_{i=1}^L \alpha_i - \frac{1}{2} \sum_{i=1}^L \sum_{j=1}^L \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \quad (4.22)$$

Во зависност од екстрахираните карактеристики кои се користат како влез, алгоритмот на машини со поддржувачки вектори може да извршува линеарни и нелинеарни класификации. Доколку примероците се нелинеарни односно не може да се разделат на линеарен начин се применува нелинеарна класификација која користи Кернел класификатор на машини со поддржувачки вектори. Во општ случај, скаларниот производ $\mathbf{x}_i^T \mathbf{x}_j$ може да се замени со Кернел функција $K(\mathbf{x}_i, \mathbf{x}_j)$, при што функцијата на одлучување добива облик:

$$f(x) = \text{sgn} \left(\sum_{i=1}^L \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}_j) + b \right) \quad (4.23)$$

Кернел функцијата врши трансформација на димензионалноста на влезните примероци во повисок димензионален простор во кој би можела да се формира линеарна хипер рамнина и таму би се вршела класификацијата или регресијата на примероците, слика 56.



Слика 56. Нелинеарна класификација со Кернел функција за машини со поддржувачки вектори

Главната оптимизација се постигнува со промена на влезовите $(\mathbf{x}_i, \mathbf{x}_j)$ со различни типови на Кернел Функции $K(\mathbf{x}_i, \mathbf{x}_j)$, додека не се добие оптимално решение. Во продолжение се дадени различните типови на Кернел функции:

- Линеарна Кернел функција

$$K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \cdot \mathbf{x}_j \quad (4.24)$$

- Гаусова Радијална базна Кернел функција

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp \left(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2 \right) \quad (4.25)$$

γ – Гама функција која го определува степенот на влијание на секоја влезна карактеристика

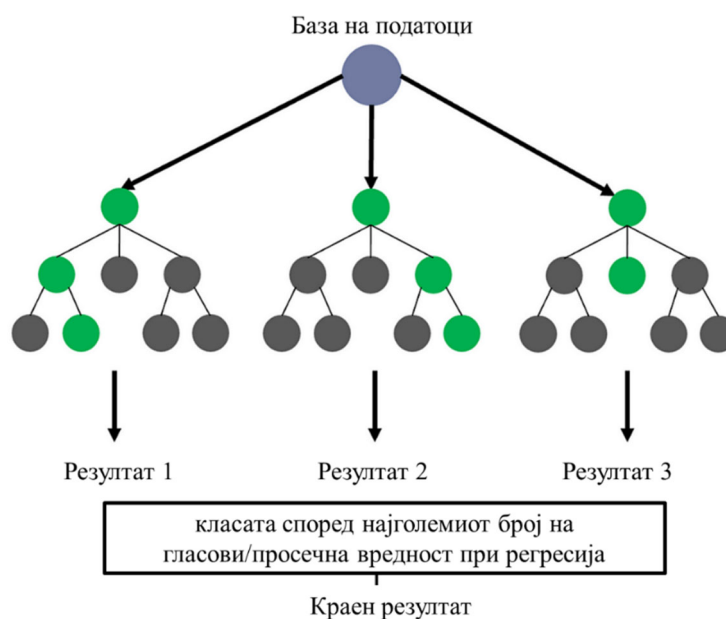
- Полиномна Кернел функција

$$K(x_i, x_j) = (x_i^T \cdot x_j + 1)^d \quad (4.26)$$

Покрај бинарна класификација помеѓу две класи на примероци, алгоритмот на машини со поддржувачки вектори ефикасно врши и мултикласна класификација, користејќи ја истата методологија како при бинарна класификација повеќе пати, односно онолку пати колку што е потребно за да се одделат сите класи на примероци.

4.1.2 Алгоритам на случајни шуми

Алгоритмот на случајни шуми претставува алгоритам на надгледувано машинско учење и може да се користи за решавање на проблеми од класификациона или регресиона природа. Самиот назив означува дека се состои од повеќе дрва на одлуки (Decision Trees). Дрва на одлуки е алгоритам кој врши поделба на влезните податоци во помали и помали групи, користејќи определени услови или карактеристики, сè додека не донесе одлука. Градењето на алгоритмот на дрва на одлуки започнува со внесување на сите влезни податоци во коренскиот јазол. Потоа, алгоритмот ја наоѓа најдобрата карактеристика или услов врз база на кои ги дели податоците во две или повеќе групи. Понатаму се гради следното ниво на дрвото односно секоја група продолжува да се дели врз основа на други карактеристики додека не се исполни претходно дефинираниот услов за запирање (на пр. групата е чиста, дрвото е премногу длабоко или нема доволно примероци за понатамошно разделување) и се стигнува до лисните јазли односно конечните одлуки. На секој лисен јазол, дрвото ја предвидува класата според најголемиот број на гласови (при класификација) или просечната вредност (при регресија). На тој начин се врши тренингот на алгоритмот на дрва на одлуки. Меѓутоа, резултатите од тестирањето на ваков алгоритам трениран на еден начин и со една група податоци нема да покажат висока точност доколку дрвото има мала длабочина, а доколку има голема длабочина, постои ризик од појава на преклопување. Со цел искористување на позитивните страни на алгоритмот на дрва на одлуки како што се релативно едноставната примена и интерпретација на резултатите, при истовремено минимизирање на претходно споменатите недостатоци, се јавува идејата за креирање на алгоритам на случајни шуми, слика 57, кој се состои од повеќе дрва на одлуки, кои се тренирани со помош на случајно избрани влезови, со цел постигнување разновидност и робустност на дрвата.



Слика 57. Шематски приказ на алгоритам на случајни шуми

Нека е дадено множество од n број на податоци:

$$D = \{(x_1, y_1), \dots, (x_i, y_i)\} \quad (4.27)$$

x_i – податок

y_i – класата на која припаѓа тој податок.

Секое дрво на одлука ги дели податоците во подгрупи при што целта е минимизирање на нечистоста во рамки на секоја подгрупа. За даден вектор на карактеристики x_j :

$$x_j = (x_{j1}, \dots, x_{jd}) \quad (4.28)$$

преку кој е претставен секој x_i податок, постои точка на поделба s која ги дели податоците од почетната група S во две подгрупи S_1 и S_2 :

$$S_1 = \{(x_i, y_i) | x_j \leq s\} \quad (4.29)$$

$$S_2 = \{(x_i, y_i) | x_j > s\} \quad (4.30)$$

Притоа, мора да се дефинираат и параметри кои служат за квантификација на нечистоста на подгрупите, односно прикажуваат колку успешно јазлите ги делат податоците по класи:

- Индекс на Гини - Gini Index (се применува за класификација):

$$G(S) = 1 - \sum_{k=1}^K p_k^2 \quad (4.31)$$

p_k – процент на примероци во класа k од група S

- Ентропија - Entropy (се применува за класификација):

$$H(S) = - \sum_{k=1}^K p_k \log(p_k) \quad (4.32)$$

- Средно квадратна грешка - Mean Squared Error (MSE) (се применува за регресија):

$$MSE(S) = \frac{1}{|S|} \sum_{i \in S} (y_i - \bar{y})^2 \quad (4.33)$$

$|S|$ – средна вредност на примероците од група S .

Најдобра поделба на почетната група S се постигнува со минимизирање на тежинскиот збир на нечистоста на секоја од формираните подгрупи (во овој случај двете подгрупи S_1 и S_2):

$$IR = I(S) - \left(\frac{|S_1|}{|S|} I(S_1) + \frac{|S_2|}{|S|} I(S_2) \right) \quad (4.34)$$

IR – намалување на нечистоста на групата/подгрупата

$I(S)$ – ниво на нечистост на група S

$I(S_1)$ – ниво на нечистост на подгрупа S_1

$I(S_2)$ – ниво на нечистост на подгрупа S_2

$|S_1|$ – средна вредност на примероците од подгрупа S_1

$|S_2|$ – средна вредност на примероците од подгрупа S_2 .

При секоја поделба во секој од јазлите, алгоритмот на случајни шуми врши случаен избор на k карактеристики од целосниот збир на карактеристики p , при што $k < p$, при што најчесто се користат релациите:

$$k = \sqrt{p} \text{ за класификација} \quad (4.35)$$

$$k = \frac{p}{3} \text{ за регресија} \quad (4.36)$$

Нека алгоритмот на случајни шуми е составен од m дрва на одлуки, а X е влез за тестирање на алгоритмот. Притоа, секое T_i дрво носи \hat{y}_i предвидување за влезот X , при што при решавање на проблеми на класификација ги комбинира предвидувањата и ја предвидува класата согласно најголем број на гласови од сите дрва на одлуки:

$$\hat{y} = \text{mode}(\hat{y}_1, \hat{y}_2, \dots, \hat{y}_m) \quad (4.37)$$

при што се бара модус на сите предвидувања, додека при решавање на проблеми на регресија ги комбинира предвидувањата на сите дрва на одлуки и бара нивни просек:

$$\hat{y} = \frac{1}{m} \sum_{i=1}^m \hat{y}_i \quad (4.38)$$

4.1.3 Алгоритам на градиентно зголемување

Алгоритмот на градиентно зголемување претставува алгоритам на надгледувано машинско учење кој најчесто се користи за решавање на проблеми од класификациона природа. Основната идеја на овој алгоритам се базира на градење на комбинирани модели, односно модел кој соединува повеќе поединечни слаби модели со цел креирање на еден силен модел со подобра предвидувачка точност и робустност, слика 58.

За разлика од алгоритмот на случајни шуми, кај кој дрвата се тренираат независно и паралелно, кај градиентното зголемување дрвата се тренираат секвенцијално, при што секое ново дрво има за цел да ги коригира грешките направени од претходните дрва. На тој начин, алгоритмот постепено го подобрува моделот преку минимизирање на дефинираната функција на загуба (Loss Function).

За да се опише овој процес на оптимизација, неопходно е најпрво да се дефинира множеството на n податоци:

$$D = \{(x_1, y_1), \dots, (x_n, y_n)\} \quad (4.39)$$

x_i – податок

y_i – класата на која припаѓа тој податок.

Целта на алгоритмот е да се изгради модел $F(x)$ кој ќе ја минимизира вкупната функција на загуба:

$$\mathcal{L} = \sum_{i=1}^n L(y_i, F(x_i)) \quad (4.40)$$

каде L претставува функција на загуба.

При решавање на проблеми од класификациона природа се користи следната функција на загуба:

$$L(y, \hat{p}) = -[y \log(\hat{p}) + (1 - y) \log(1 - \hat{p})] \quad (4.41)$$

каде \hat{p} е предвидена веројатност дека примерокот припаѓа на класата $y=1$.

Процесот на градење на моделот започнува со иницијално приближување кое ја минимизира функцијата на загуба со константна вредност:

$$F_0(x) = \arg \min_c \sum_{i=1}^n L(y_i, c) \quad (4.42)$$

каде c е константна вредност.

Овој чекор претставува почетна точка за понатамошната итеративна оптимизација. Понатаму моделот се подобрува итеративно во m чекори при што во секоја итерација се пресметува негативниот градиент на функцијата на загуба, односно резидуалната грешка:

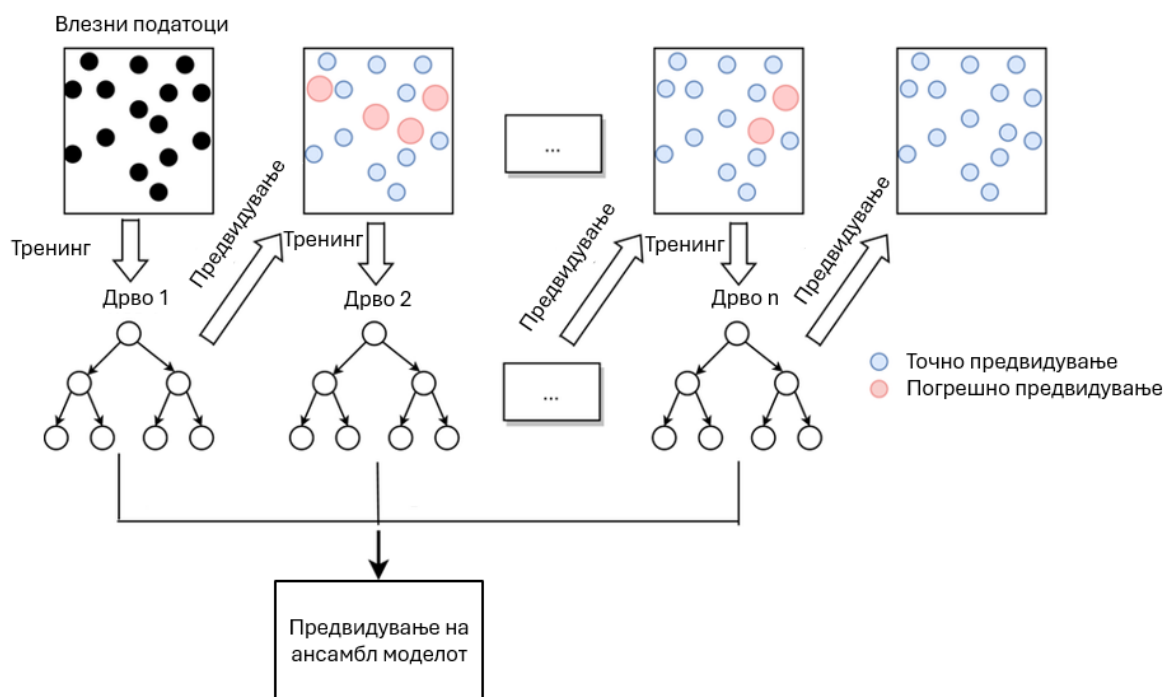
$$r_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x)=F_{m-1}(x)} \quad (4.43)$$

Овие резидуални вредности се користат како целни вредности за тренинг на ново дрво на одлука $h_m(x)$, чија задача е да ги апроксимира преостанатите грешки на моделот во претходната итерација. На слика 58 прикажан е шематски приказ на секвенцијалното градење на комбинирани модели кај алгоритмот на градиентно зголемување, каде што секое дрво на одлука се тренира со цел да ги коригира грешките на моделот од претходната итерација.

Потоа, моделот се обновува на овој начин:

$$F_m(x) = F_{m-1}(x) + \eta \cdot h_m(x) \quad (4.44)$$

η е стапка на учење (learning rate) која го контролира придонесот на секое ново дрво, $h_m(x)$ е новото дрво на одлука.



Слика 58. Шематски приказ на алгоритмот на градиентно зголемување

Овој процес се повторува сè додека не се достигне зададениот број на итерации или не се постигне задоволителна точност. По завршување на итеративниот процес, предвидувањето за нов влезен податок X се добива како збир на придонесите од сите индивидуални дрва:

$$\hat{y} = \sum_{m=1}^M \eta \cdot h_m(X) \quad (4.45)$$

4.1.4 Комбинирани модели

Комбинираните модели се тип на алгоритми на надгледувано машинско учење кои комбинираат повеќе поединечни модели (базични класификатори) со цел постигнување подобри перформанси во споредба со секој од нив поединечно. Основната идеја на пристапот на спојување на повеќе модели е дека различни модели прават различни грешки, па со нивна соодветна комбинација може да се намали вкупната грешка и да се зголеми робушноста и способноста за генерализација на конечниот модел.

Нека е дадено множество од M поединечни класификатори:

$$\mathcal{H} = \{h_1(x), h_2(x), \dots, h_M(x)\} \quad (4.46)$$

каде што $h_m(x)$ го претставува предвидувањето на m -тиот класификатор за влезниот вектор на карактеристики x .

Во литературата најчесто се користи стратегијата на гласање на комбинираните модели која подразбира комбинирање на резултатите од различни модели. При решавање на проблеми од мултикласна класификација, комбинираниот модел може да користи тврдо гласање (hard voting) или меко гласање (soft voting). Во овој труд е применето меко гласање, при што секој поединечен класификатор не дава директна класа, туку вектор на веројатности за припадност на секоја класа.

Нека $p_m(c | x)$ ја претставува веројатноста која m -тиот класификатор ја доделува на класата c за влезниот примерок x . Тогаш конечната одлука на комбинираниот модел се добива како:

$$\hat{y} = \arg \max_c \sum_{m=1}^M w_m \cdot p_m(c | x) \quad (4.47)$$

w_m е тежинскиот фактор на m -тиот класификатор,

M е бројот на класификатори во комбинираниот модел,

c е индекс на класата,

\hat{y} е предвидената класа.

4.2 Тренинг и тестирање на дијагностички модели

Во претходните точки прикажани се теоретските основи на алгоритмите на надгледувано машинско учење кои се искористени при креирање на модел за дијагностика на дефекти кај ротирачки машини: алгоритмот на машини со поддржувачки вектори, алгоритмот на случајни шуми и алгоритмот на градиентно зголемување. Покрај нивната индивидуална примена, реализирана е и комбинација на овие алгоритми во форма на комбинирани модели при што на секој алгоритам му се доделува соодветен тежински фактор, во зависност од неговата постигната точност при тестирањето. Овој тежински систем овозможува оптимизирано донесување одлуки во фазата на валидација, со цел искористување на предностите на секој поединечен модел. При дијагностика односно класификација на дефекти, искористени се карактеристики кои се екстрахирани од искористената база на податоци, но и карактеристики кои произлегуваат од физиката на анализираната ротирачка машина и од природата на присутните дефекти. На тој начин креиран е и хибриден модел за дијагностика трениран со примена на физички карактеристики и екстрахирани карактеристики од претходно обработената база на податоци.

Понатаму, резултатите од хибридните модели се споредени со резултатите од класичните, врз основа на точноста постигната при тестирањето.

Како техника за евалуација се користи техниката на крос-валидација, а бројот на превиткувања е избран согласно бројот на примероци од кои се состои базата, односно во овој случај 2147 примероци. За бази на податоци со 1000-10000 примероци препораките се избор на техника на крос-валидација со 10-превиткувања [150]. Влезните карактеристики се групираат по случаен избор во сетови за тренирање и тестирање. Со цел постигнување на повторливи анализи, односно добивање на исти резултати при секое извршување на анализите, неопходно е дефинирање на зачетокот на генераторот на случајни бројки (random seed value) со што се постигнува повторливост на случајните резултати. На тој начин се овозможува веродостојна споредливост на резултатите добиени со примена на различни класификатори со користење на истата случајна состојба за разделување на влезните податоци по сетови. Во ова истражување секаде е користена вредност 42.

Со цел подобрување на точноста на моделите, извршена е нивна хиперпараметарска оптимизација. Генерирани се конфузни матрици, кои ја прикажуваат точноста при класификација на податоците во секоја одделна класа, при што се прикажани 10 класи на дефекти како вистинска класа по вертикала и предвидена класа по хоризонтала.

Во продолжение ќе бидат прикажани методологиите за развој на класификациски модели кои вршат двослојна класификација. Во првиот слој ќе се изврши мултикласна класификација со цел идентификација на доминантната состојба на машината, додека во вториот слој ќе се примени бинарна класификација, чија цел е испитување на присуството на дебаланс како дополнителен дефект. Ќе биде ставен особен фокус на хиперпараметарската оптимизација на алгоритмите, како и на изборот на оптимален алгоритам врз основа на добиените вредности за избраните параметри за евалуација.

4.2.1 Прв слој на дијагностичкиот модел - Мултикласна класификација

Кај алгоритмот на машини со поддржувачки вектори искористена е радијална базна функција како кернел функција со цел решавање на проблемот на класификација во 10 класи бидејќи оваа функција овозможува ефективна нелинеарна сепарација на податоците. При оптимизацијата на моделот базиран на алгоритам на машини со поддржувачки вектори се разгледани два клучни хиперпараметри и тоа регулациониот параметар C и коефициентот γ . Вредноста на регулациониот параметар C треба да биде доволно висока со цел минимизирање на грешката на класификаторот при негово тренирање, а доволно ниска со цел минимизирање на сложеноста на моделот и намалување на веројатноста од појава на преклопување. Во ова истражување се разгледани вредности $C \in \{10, 20, 50, 100, 200\}$, кои претставуваат умерен до повисок опсег соодветен за стандардизирани, високодимензионални влезни карактеристики. Со оптимизација на параметарот C , се контролира осетливоста на алгоритмот на машини со поддржувачки вектори на влезните податоците за тренинг и се влијае врз способноста за генерализација при примена на претходно непознати податоци. γ коефициентот ја дефинира вредноста на Кернел коефициентот преку кој ја дефинира распределбата на Кернел функцијата, односно критериумот кој моделот го користи при препознавање на сличности и разлики помеѓу влезните податоци. Со цел балансирање помеѓу генерализација и прецизно разграничување на дефектите, разгледани се вредности $\gamma \in \{0,001; 0,005; 0,01; 0,05; 0,1; 0,5\}$, кои се во близина на препорачаните почетни вредности за нормализирани податоци.

Кај алгоритмот на случајни шуми извршена е оптимизација на два клучни хиперпараметри: бројот на естиматори ($n_estimators$), кој го означува бројот на дрва во шумата, и максималната длабочина (max_depth) на секое дрво. Бројот на естиматори директно влијае врз

стабилноста и робусноста на моделот, при што зголемувањето на бројот на дрва обично доведува до намалување на варијансата и подобра генерализација, меѓутоа е потребно подолго време за калкулација. Во ова истражување се разгледани вредности $n_estimators \in \{200, 400, 600\}$, со цел постигнување на што е можно повисока класификациска точност при прифатливо време на извршување. Параметарот max_depth ја контролира сложеноста на поединечните дрва и нивната способност да ги моделираат нелинеарните релации во податоците. Со цел испитување на влијанието на различни степени на сложеност врз перформансите на моделот, разгледани се вредности $max_depth \in \{None, 10, 20, 40\}$, при што вредноста $None$ овозможува растење на дрвото сè додека примероците во рамки на еден лист не станат хомогени, односно не припаѓаат на иста класа. Согледано е дека останатите параметри како пр., минимален број на примероци, минимален број на листови, не влијаат значително врз зголемувањето на точноста на класификаторот па затоа за нив е земена стандардна вредност во рамки на библиотеката `scikit-learn` во Python (минимален број на примероци=2, минимален број на листови=1).

Кај алгоритмот на градиентно зголемување извршена е оптимизација на три клучни хиперпараметри: бројот на естиматори ($n_estimators$), стапката на учење ($learning_rate$) и максималната длабочина (max_depth) на базното дрво. Бројот на естиматори го дефинира бројот на базни дрва кои се комбинираат во комбинирани модели и директно влијае врз способноста на моделот да ги апроксимира сложените нелинеарни релации во податоците. Во ова истражување се разгледани вредности $n_estimators \in \{50, 150, 250, 350, 450\}$, кои обезбедуваат доволна флексибилност на моделот без значително зголемување на ризикот од преклопување и пресметковната сложеност. Параметарот $learning_rate$ ја контролира стапката со која секој нов модел придонесува кон вкупниот комбиниран модел. Помали вредности на овој параметар овозможуваат попрецизно и постабилно учење, но бараат поголем број естиматори, додека поголемите вредности можат да доведат до побрзо учење по цена на зголемена веројатност за преклопување. Со цел да се постигне соодветен баланс помеѓу стабилноста и брзината на конвергенција, разгледани се вредности $learning_rate \in \{0,01; 0,05; 0,1; 0,5\}$. Максималната длабочина на базното дрво max_depth ја одредува сложеноста на поединечните слаби модели и нивната способност да ги моделираат локалните структури во податоците. Во ова истражување се користени плитки дрва со $max_depth \in \{2, 3, 4\}$, што е во согласност со принципите на алгоритмот на градиентно зголемување, каде што се претпочитаат едноставни базни модели со цел намалување на веројатноста од појава на преклопување и обезбедување на добра генерализациска способност.

Дополнително, во ова истражување е применет комбиниран модел со гласање, кој ги комбинира претходно оптимизираните алгоритми и тоа: алгоритмот на машини со поддржувачки вектори, алгоритмот на случајни шуми и алгоритмот на градиентно зголемување. Овој пристап овозможува искористување на различните предности на секој од применетите алгоритми: геометриската сепарабилност кај алгоритмот на машини со поддржувачки вектори, робусноста и случајноста кај алгоритмот на случајни шуми и способноста за fino моделирање на сложени нелинеарности кај алгоритмот на градиентно зголемување. Во рамки на комбинираниите модели со меко гласање, поединечните класификатори не се третираат како подеднакво влијателни. На алгоритмот кој ќе покаже највисока вредност за избраниот параметар за евалуација во фазата на тестирање, согласно избраниот критериум за евалуација, е доделен поголем тежински коефициент, со цел зголемување на неговото влијание при донесување на конечната одлука. Во конкретниот случај, за определување на тежинските коефициенти е користен параметарот точност, додека финалната евалуација на дијагностичките перформанси е базирана на параметрите одзив, прецизност и F1-мерка со макро-усреднување. Како критериум за евалуација е искористена техниката на крос-валидација со 10 преклопувања. Согласно резултатите, на класификаторот со највисока вредност за параметарот точност му е доделен тежински

коэффициент $w = 2$, додека на преостанатите два класификатори им е доделен тежински коэффициент $w = 1$. Ваквиот пристап овозможува балансирано комбинирање на моделите, при што се задржуваат придобивките од сите алгоритми, а воедно се нагласува придонесот на класификаторот со највисоки перформанси.

Во табела 14 прикажани се средните вредности на параметрите за евалуација (точност, прецизност, одзив и F1-мерка), како и нивната стандардна девијација, добиени со примена на техника на крос-валидација со 10 превиткувања, за чисто податочните и хибридните модели со примена на наведените алгоритми на надгледувано машинско учење и нивната комбинација во форма на комбинирани модели, по извршена хиперпараметарска оптимизација. Прикажувањето на стандардната девијација овозможува проценка на стабилноста и конзистентноста на моделите при различни поделби на податоците. На овој начин, покрај споредбата на просечните перформанси, се овозможува и анализа на нивната робусност и сигурност при генерализација на претходно непознати податоци. Помала вредност на стандардната девијација укажува на покonzistentни перформанси на класификаторот, независно од начинот на поделба на податоците во подмножества за тренинг и тестирање, додека поголема вредност индицира поголема чувствителност на моделот на конкретната поделба на податоците и на изборот на тренинг и тест подмножества.

Табела 14. Перформанси на чисто податочни и хибридни модели за мултикласна класификација по хиперпараметарска оптимизација со примена на крос-валидација со 10-преклопувања

Тип на карактеристики	Алгоритам	Точност \pm std [%]	Прецизност \pm std [%]	Одзив \pm std [%]	F1-Мерка \pm std [%]	Оптимални хиперпараметри
Чисто податочни	SVM	89,851 \pm 1,133	88,129 \pm 1,051	87,755 \pm 1,157	87,937 \pm 1,112	C=50; γ =0,05
	RF	89,363 \pm 1,103	88,015 \pm 1,153	87,592 \pm 1,189	87,002 \pm 1,164	n_estimators=400; max_depth=None
	GB	89,036 \pm 1,258	87,328 \pm 1,205	86,503 \pm 1,333	86,914 \pm 1,283	n_estimators=250; lr=0,05; depth=3
	Ensemble	91,594 \pm 0,954	89,981 \pm 1,001	89,491 \pm 1,034	89,558 \pm 0,991	weights=[2,1,1]
Хибридни – податочни и физички	SVM	94,618 \pm 0,852	94,350 \pm 0,814	94,127 \pm 0,894	94,247 \pm 0,859	C=10; γ =0,01
	RF	97,539 \pm 0,588	97,021 \pm 0,605	96,751 \pm 0,644	96,881 \pm 0,626	n_estimators=200; max_depth=20
	GB	96,770 \pm 0,665	95,469 \pm 0,732	95,460 \pm 0,718	95,657 \pm 0,713	n_estimators=250; lr=0,1; depth=3
	Ensemble	98,308 \pm 0,236	97,853 \pm 0,198	97,499 \pm 0,266	97,679 \pm 0,219	weights=[1,2,1]

Од прикажаните резултати може јасно да се забележи дека хибридните модели, кои ги комбинираат податочните и физичките карактеристики, остваруваат значително подобри перформанси во однос на чисто податочните модели кај сите применети алгоритми. Најдобри перформанси се постигнати со комбинираниот модел, кој при примена на хибридни карактеристики достигнува точност од 98,308 % \pm 0,236, како и високи вредности на прецизност, одзив и F1-мерка, при најмала забележана стандардна девијација меѓу сите разгледани модели. Овие резултати потврдуваат дека комбинирањето на различни алгоритми, заедно со вклучување на физички информативни карактеристики, овозможува значително подобрување на дијагностичките перформанси и нивна висока конзистентност.

Врз основа на овие резултати, како најсоодветен пристап за понатамошна анализа и практична примена е избран хибридниот комбиниран модел, кој обезбедува оптимален баланс помеѓу висока дијагностичка точност, робусност и способност за генерализација при претходно непознати податоци.

Понатамошната анализа е фокусирана на испитување на перформансите на избраниот хибриден комбиниран модел при различни мерни конфигурации. Со цел поголема применливост на предложениот пристап во реални индустриски услови, каде мерењата често се вршат со различни типови сензори и не секогаш се достапни сите оски на мерење, дополнително се развиени и анализирани модели базирани на поединечни оски и нивни комбинации, чии резултати се прикажани во табела 15. Ваквиот пристап овозможува флексибилна примена на методологијата во различни мерни конфигурации и системи за мониторинг.

Табела 15. Перформанси на комбинираните модели за мултикласна класификација за различни оски и нивни комбинации со примена на хибридни карактеристики

* Надворешно лежиште = Overhang bearing – 1, Внатрешно лежиште = Underhang bearing - 2

Оска	Точност [%]	Прецизност	Одзив	F1-Мерка	Ensemble тежини
Аксијална на Надворешно лежиште (ax1)	86,982 ± 1,652	82,624 ± 2,086	80,696 ± 2,017	80,863 ± 2,446	[1,2,1]
Тангенцијална на Надворешно лежиште (tg1)	94,514 ± 1,828	95,143 ± 2,190	92,157 ± 2,319	93,222 ± 2,061	[1,2,1]
Радијална на Надворешно лежиште (rad1)	93,796 ± 1,596	94,319 ± 2,136	91,652 ± 2,530	92,619 ± 2,334	[1,2,1]
Аксијална на Внатрешно лежиште (ax2)	84,265 ± 2,581	81,853 ± 2,128	79,686 ± 2,089	80,226 ± 2,505	[1,2,1]
Тангенцијална на Внатрешно лежиште (tg2)	93,491 ± 1,976	94,085 ± 1,772	91,539 ± 2,070	92,226 ± 2,584	[1,2,1]
Радијална на Внатрешно лежиште (rad2)	92,055 ± 1,877	92,518 ± 2,669	91,953 ± 2,716	91,955 ± 2,682	[1,2,1]
Аксијална на Надворешно и Внатрешно лежиште (ax1+ax2)	89,133 ± 1,948	89,755 ± 2,385	88,356 ± 2,942	88,529 ± 2,757	[1,2,1]
Тангенцијална на Надворешно и Внатрешно лежиште (tg1+tg2)	94,110 ± 1,001	94,208 ± 1,457	93,832 ± 1,903	94,013 ± 1,604	[1,2,1]
Радијална на Надворешно и Внатрешно лежиште (rad1+rad2)	95,843 ± 1,026	94,912 ± 1,347	93,667 ± 1,875	94,283 ± 1,483	[1,2,1]
Тангенцијална и радијална на надворешно лежиште (tg1+rad1)	96,353 ± 0,951	95,955 ± 1,209	95,698 ± 1,462	95,823 ± 1,303	[1,2,1]
Тангенцијална и радијална на внатрешно лежиште (tg2+rad2)	96,036 ± 1,023	95,035 ± 1,303	94,605 ± 1,574	94,997 ± 1,458	[1,2,1]

Сите оски на Надворешно лежиште ($ax1+tg1+rad1$)	$96,874 \pm 0,326$	$96,961 \pm 0,344$	$96,582 \pm 0,355$	$96,615 \pm 0,379$	[1,2,1]
Сите оски на Внатрешно лежиште ($ax2+tg2+rad2$)	$96,668 \pm 0,355$	$96,848 \pm 0,346$	$95,774 \pm 0,381$	$96,084 \pm 0,387$	[1,2,1]
Сите оски на двете лежишта	$98,308 \pm 0,236$	$97,853 \pm 0,198$	$97,499 \pm 0,266$	$97,679 \pm 0,219$	[1,2,1]

Како што беше и претходно нагласено, целта е дизајнирање на класификациски модели кои ќе вршат двослојна класификација. Во овој дел детално беше опишана методологијата за моделирање на првиот слој кој врши мултикласна класификација со цел идентификација на доминантната состојба на машината детално беше опишана во овој дел. Во следната точка детално е прикажана методологијата за моделирање на вториот слој кој ќе врши бинарна класификација, со цел испитување на присуството на дебаланс како дополнителен дефект. Воведувањето на овој слој е мотивирано од фактот што дебалансот претставува дефект кој многу често коегзистира со дефекти кај тркалчките лежишта и може значително да влијае врз вибрационата состојба на системот, како и врз точноста на дијагностичката одлука.

4.2.2 Втор слој на дијагностичкиот модел - Бинарна класификација

За разлика од првиот слој, кој врши мултикласна класификација со цел идентификација на доминантната состојба на машината, вториот слој има бинарен карактер, при што излезот од класификаторот прикажува дали дебалансот е присутен (класа 1) или не е присутен (класа 0).

За потребите на бинарната класификација е искористена Mafaulda базата на податоци во нејзиниот оригинален облик, со тоа што сите податоци се групирани во две класи (0 – нема дебаланс и 1- присутен дебаланс). Притоа, во класата 0 вклучени се сите податоци снимени при следните состојби, табела 6: нормална состојба (49 примероци), хоризонтална (197 примероци) и вертикална нецентричност (301 примерок) и дефекти во надворешно ($3 \times 49 = 147$ примероци) и внатрешно лежиште без присутен дебаланс ($2 \times 49 + 50 = 148$ примероци). Во класата 1 вклучени се сите преостанати податоци, односно при состојбите дебаланс (333) и дефекти во надворешно ($49 + 49 + 41 + 49 + 49 + 41 + 43 + 25 + 20 = 366$ примероци) и внатрешно лежиште со различни нивоа на присутен дебаланс ($48 + 49 + 42 + 49 + 49 + 37 + 49 + 49 + 38 = 410$). На овој начин, класата со присутен дебаланс (класа 1) се состои од вкупно 842 примероци, додека класата без присутен дебаланс (класа 0) се состои од 1109 примероци. Со оглед на тоа што класите се приближно балансирани, не е применета дополнителната методологија за балансирање на базата на податоци, која е опишана во точка 2.6.1.

Вака организираната база на податоци е подготвена и обработена со примена на методологијата објаснета во Поглавјата 2 и 3, при што се екстрахирани истите карактеристики прикажани во табела 8. За бинарната класификација искористен е алгоритмот кој покажа највисоки перформанси во фазата на мултикласна класификација, односно комбинираниот модел со примена на хибридни карактеристики. Како критериум за евалуација е применета техниката на крос-валидација со 10 преклопувања. Како параметар за евалуација е искористен параметарот точност, бидејќи класите се приближно балансирани, а двете состојби (присутен и неприсутен дебаланс) имаат еднаква важност од дијагностички аспект. Во ваков бинарен дијагностички проблем, параметарот точност обезбедува јасна и директна проценка на успешноста на моделот при детекција на дебаланс.

Во табела 16 дадени се вредностите за параметарот точност добиени како излез од комбинираниите модели за сите оски и за различни оски и нивни комбинации со примена на хибридни карактеристики.

Табела 16. Перформанси на комбинираниите модели за бинарна класификација за различни оски и нивни комбинации со примена на хибридни карактеристики

Оска	Точност [%]	Ensemble тежини
Аксијална на Надворешно лежиште (ax1)	87,453 ± 1,153	[1,2,1]
Тангенцијална на Надворешно лежиште (tg1)	94,541 ± 1,056	[1,2,1]
Радијална на Надворешно лежиште (rad1)	94,601 ± 0,981	[1,2,1]
Аксијална на Внатрешно лежиште (ax2)	91,671 ± 1,203	[1,2,1]
Тангенцијална на Внатрешно лежиште (tg2)	94,349 ± 1,003	[1,2,1]
Радијална на Внатрешно лежиште (rad2)	93,057 ± 1,008	[1,2,1]
Аксијална на Надворешно и Внатрешно лежиште (ax1+ax2)	91,889 ± 0,954	[1,2,1]
Тангенцијална на Надворешно и Внатрешно лежиште (tg1+ tg2)	95,874 ± 0,883	[1,2,1]
Радијална на Надворешно и Внатрешно лежиште (rad1+ rad2)	96,425 ± 0,852	[1,2,1]
Тангенцијална и радијална на надворешно лежиште (tg1+rad1)	96,348 ± 0,831	[1,2,1]
Тангенцијална и радијална на внатрешно лежиште (tg2+rad2)	96,326 ± 0,829	[1,2,1]
Сите оски на Надворешно лежиште (ax1+tg1+rad1)	97,424 ± 0,486	[1,2,1]
Сите оски на Внатрешно лежиште (ax2+tg2+rad2)	97,333 ± 0,471	[1,2,1]
Сите оски на двете лежишта	98,777 ± 0,309	[1,2,1]

Излезот од ова поглавје претставува трениран модел на надгледувано машинско учење кој врши мултикласна класификација во првиот слој, со цел препознавање на доминантната состојба на машината, како и бинарна класификација во вториот слој, при што моделот детектира дали, покрај доминантниот дефект, е присутен и дебаланс. Со цел потврдување на генерализациската способност и практичната применливост на предложената методологија, дел од хибридниите комбинирани модели, во зависност од оските по кои се снимени сигналите, ќе бидат валидирани со претходно непознати бази на податоци во следното поглавје. Оваа валидација ќе биде извршена со примена на податоци снимени во различни експериментални и реални работни услови, што ќе овозможи објективна проценка на робусноста на моделите и нивната способност за преносливост помеѓу различни мерни системи и конфигурации.


Програмскиот код во Python за тренинг на двослоен модел за дијагностички цели, со примена на алгоритмот на машини со поддржувачки вектори, алгоритмот на случајни шуми, алгоритмот на градиентно зголемување и комбинирани модели чии резултати се дадени во табели 14, 15 и 16 даден е во Прилог Б-1.

Со цел целосна транспарентност и детална анализа на резултатите од класификацијата, во Прилог В на оваа дисертација се прикажани сите конфузни матрици, добиени за разгледаните модели и мерни конфигурации. Конфузните матрици се нормализирани по редови, при што секоја реална класа е претставена со 100%, што овозможува јасна интерпретација на одзивот по класи. Ваквиот приказ овозможува јасно идентификување на класите кај кои моделите најчесто прават погрешни класификации, како и анализа на природата на овие грешки. Поради тоа, конфузните матрици се дадени како дополнителен материјал, со цел да се обезбеди подлабок увид во дијагностичките слабости и ограничувања на моделите, како дополнување на параметрите за евалуација прикажани во табеларна форма.

4.3 Анализа на нивото на значајност на карактеристиките

Со цел утврдување на карактеристиките кои најмногу придонесуваат за подобрување на перформансите на дијагностичките модели, извршена е анализа чија цел е добивање на квантитативна проценка на нивото на значајност во насока на дијагностика на присутните дефекти. Применет е методот на пермутација на карактеристиките (Permutation-Based Method) кој врши проценка на нивото на значајност на секоја карактеристика врз основа на просечното намалување на точноста на моделот откако е извршена случајна пермутација на вредностите на карактеристиката. Притоа е применет хибридниот комбиниран модел со измерени сигнали по три оски на две лежишта, при што е применета техника на крос-валидација со 10 преклопувања за евалуација на перформансите на моделот.

На слика 59 прикажани се дваесетте најзначајни карактеристики (од вкупно 192 карактеристики) рангирани според просечното намалување на точноста при пермутација на вредностите на карактеристиката. Добиените резултати покажуваат дека значаен придонес во перформансите на моделот имаат карактеристики и од фреквентниот и од временскиот домен, но меѓу највлијателните карактеристики се издвојуваат и карактеристиките кои произлегуваат од физичките својства на анализираниот машински систем, како што се енергијата содржана во првиот хармоник, BSF_ratio, BPFO_ratio и индексот на нецентричност (MIS_index).



Слика 59. Дваесет карактеристики со највисоко ниво на значајност по примена на методот на пермутација на вредностите на карактеристиките за хибридниот комбиниран модел со примена на сите шест мерни оски

Со цел дополнителна проценка на релативниот придонес на различните групи карактеристики, извршена е агрегација на кумулативната значајност според типот на карактеристиките (карактеристики од фреквентен домен, временски домен и карактеристики засновани на физички информации). Добиените резултати се прикажани во табела 17. Карактеристиките од фреквентниот домен учествуваат со 42,46 % од вкупната пермутациона

значајност на карактеристиките во моделот, оние од временскиот домен со 33,15 %, додека карактеристиките засновани на физички информации придонесуваат со 24,39 %.

Табела 17. Кумулативна и релативна пермутациска значајност на различни групи карактеристики

Типови на карактеристики	Кумулативна значајност	Придонес [%]
Карактеристики во фреквенцен-домен	1,2409	42,46
Карактеристики во временски-домен	0,9688	33,15
Карактеристики засновани на физиката на машината	0,7127	24,39

Распределбата на значајноста не укажува на доминација на една поединечна карактеристика, туку на балансиран придонес на повеќе комплементарни дескриптори. Посебно е значајно што карактеристиките засновани на физички информации учествуваат со приближно една четвртина од вкупната значајност на моделот, обезбедувајќи дополнителни дијагностички информации кои ја подобруваат робушноста на класификацијата при различни работни услови. Овие резултати потврдуваат дека подобрувањето на перформансите кое се забележува при примена на хибридни карактеристики се должи на интеграцијата на физички интерпретабилни индикатори на присутните дефекти во процесот на машинско учење.

Програмскиот код во Python за анализа на нивото на значајност на екстрахираните карактеристики чии резултати се дадени на слика 59 и табела 17, даден е во Прилог Б-2.

4.4 Компјутерска ефикасност и индустриска применливост на предложената дијагностичка методологија

Предложената методологија за дијагностика е наменета за примена во индустриски системи за надзор на состојбата на машинските системи, каде компјутерската ефикасност претставува значаен практичен фактор. Покрај анализа на постигнатата точност при класификација, беше извршена и систематска анализа на пресметковното време потребно за екстракција на карактеристики, тренинг и тестирање на применетите алгоритми.

За комплетна анализа, потребно е да се наведе конфигурацијата на работната станица на која се извршени сите експерименти. Применетата работна станица е опремена со процесор Intel® Core™ i7-10750H (6 јадра, 12 нишки, основна фреквенција 2,60 GHz) и 16 GB DDR4 RAM меморија (2933 MHz), со оперативен систем Windows 10 (64-битен). Имплементацијата на алгоритмите е реализирана во програмскиот јазик Python 3.11.1, со користење на библиотеките scikit-learn 1.3.0 и NumPy 1.25.2. Оваа конфигурација претставува стандардна работна станица од средна класа и овозможува репродукцибилност на прикажаните резултати.

Најпрво е извршена анализа на чувствителноста на предложениот метод за намалување на фреквенцијата на семплирање, при што се прикажани компјутерското време потребно за екстракција на карактеристики и постигнатата точност на хибридниот комбиниран модел при различни вредности на фреквенцијата на семплирање. Од резултатите прикажани во табела 18 може да се забележи дека со намалување на фреквенцијата на семплирање значително се намалува времето потребно за екстракција на карактеристиките, додека точноста на моделот останува на високо ниво. Овој резултат укажува дека соодветниот избор на фреквенција на семплирање може значително да ја подобри компјутерската ефикасност на системот без

значително намалување на точноста при класификација. Од резултатите може да се заклучи дека избраната фреквенција на семплирање од 5 kHz резултира со значително намалување на компјутерското време при екстракција на карактеристики, додека придонесува за 0,259 % намалување на точноста при класификација.

Табела 18. Анализа на чувствителност на фреквенцијата на семплирање: потребно компјутерско време за екстракција на карактеристики и точност на хибридниот комбиниран модел

Сооднос	Фреквенција на семплирање F_s [kHz]	Компјутерско време за екстракција на карактеристики	Точност на хибриден комбиниран модел (со сигнали по сите оски) [%]
5	10,00	72 min 58,92 s	98,567 ± 0,231
6	8,33	34 min 5,32 s	98,560 ± 0,242
7	7,14	21 min 35,82 s	98,355 ± 0,227
8	6,25	20 min 31,02 s	98,359 ± 0,170
9	5,56	19 min 19,48 s	98,329 ± 0,226
10	5,00	17 min 24,72 s	98,308 ± 0,236
11	4,55	16 min 55,22 s	98,004 ± 0,281
12	4,17	16 min 49,49 s	97,765 ± 0,280
13	3,85	16 min 46,44 s	97,622 ± 0,321
14	3,57	16 min 38,50 s	97,491 ± 0,366
15	3,33	16 min 30,62 s	97,358 ± 0,365
20	2,50	15 min 59,92 s	96,912 ± 0,371
30	1,67	15 min 49,54 s	96,337 ± 0,383
40	1,25	15 min 40,05 s	96,981 ± 0,454
50	1,00	15 min 33,82 s	95,641 ± 0,464

Компјутерското време потребно за екстракција на целосниот сет од 192 карактеристики од тренинг базата на податоци изнесува 17 min 24,72 s за 2147 сигнали (по извршено балансирање на базата MaFaulda). Ова одговара на просечно време на обработка од 486.595 ms за екстракција на 192 карактеристики од еден сигнал.

Дополнително, извршена е анализа на времето потребно за тренинг и тестирање на алгоритмите кои го сочинуваат комбинираниот модел, при што е користен целосниот сет од 192 карактеристики. Добиените резултати се прикажани во табела 19. Бидејќи комбинираниот модел е реализиран комбинирајќи претходно тренирани базични модели, неговата имплементација не воведува дополнително време за тренинг надвор од времето потребно за тренинг на поединечните алгоритми.

Табела 19. Потребно компјутерско време за тренинг и тестирање на алгоритмите кои го сочинуваат комбинираниот модел (со 192 екстрахирани карактеристики)

Тип на алгоритам	Компјутерско време за тренинг и тестирање на алгоритмите [s]
Алгоритам на машини со поддржувачки вектори	102,01
Алгоритам на случајни шуми	94,87
Алгоритам на градиентно зголемување	3354,19

Програмскиот код во Python за анализа на компјутерска ефикасност чии резултати се дадени во табели 18 и 19, даден е во Прилог Б-3.

Најдолгото време за тренинг е забележано кај алгоритмот на градиентно зголемување, додека алгоритмот на случајни шуми и алгоритмот на машини со поддржувачки вектори покажуваат значително пократко време за тренинг и тестирање. Меѓутоа, тренингот на моделите не се извршува во реално време, односно по тренингот модели се зачувуваат и се користат директно во процесот на класификација. Поради тоа, времето потребно за тренинг не претставува ограничувачки фактор за нивна примена во реално време.

Времето за донесување одлука на тренираните модели е определено преку мерење на просечното време потребно за предвидување на еден сигнал по извршената екстракција на карактеристики. За избраниот хибриден комбиниран модел кој користи сигнали измерени по сите шест оски (192 карактеристики), просечното време за донесување одлука изнесува 18,456 ms по сигнал.

Кога се зема предвид вкупното време потребно за екстракција на карактеристики и инференција, вкупното време на обработка изнесува приближно:

$$486,595 \text{ ms} + 18,456 \text{ ms} \approx 505 \text{ ms} \text{ по сигнал}$$

Ова одговара на теоретска пропусност од приближно два обработени сигнални прозорци во секунда при дадената хардверска конфигурација.

Треба да се напомене дека можноста за обработка во реално време зависи од односот меѓу времето на обработка и времетраењето на измерениот сигнал. Во типични индустриски системи за вибрациски надзор сигналите најчесто се сегментираат во прозорци со времетраење од 1 до 2 секунди. Бидејќи вкупното време на обработка (≈ 0.505 s) е помало од времето потребно за снимање на сигнал од една секунда, предложената методологија ги задоволува барањата за обработка во реално време во стандардни системи за мониторинг.

Дополнително, треба да се има предвид дека процесите на појава и развој на дефекти кај ротирачките машини се одвиваат постепено и не се менуваат нагло во временски интервали од неколку десетини од секунда. Ова дополнително ја потврдува индустриската применливост на предложената дијагностичка методологија.

Иако современите методи базирани на длабоко учење често постигнуваат висока точност при дијагностика на дефекти, тие обично бараат значително поголеми пресметковни ресурси, како и употреба на графички процесор (GPU), особено при тренинг и имплементација на комплексни архитектури. Наспроти тоа, предложената методологија функционира со користење исклучиво на централниот процесор (CPU) и обезбедува време на обработка помало од една секунда по сигнален прозорец, што ја прави погодна за имплементација во индустриски системи со ограничени пресметковни ресурси.

5. ВАЛИДАЦИЈА НА ДИЈАГНОСТИЧКИТЕ МОДЕЛИ

Следната фаза опфаќа валидација на предложената методологија, како и на дел од креираните хибридни комбинирани модели, кои како тип на алгоритам покажаа највисоки перформанси во фазата на тестирање (Поглавје 4), во зависност од оските по кои се снимени сигналите. Во рамки на ова поглавје ќе се провери нивната точност при класификација на претходно непознати податоци кои не биле искористени во фазата на тренинг. За таа цел ќе бидат искористени бази на податоци од различна природа, односно вибрациони сигнали снимени во експериментални услови и вибрациони сигнали снимени во реални услови. Најпрво детално ќе бидат опишани мерните системи и начинот на организација на базите на податоци односно вибрациони сигнали. Потоа, согласно предложената методологија, вибрационите сигнали ќе бидат обработени и од нив ќе се екстрахираат соодветни карактеристики, по што ќе биде извршена валидација на дијагностичките модели.

5.1 Валидација со примена на база на податоци снимена во експериментални услови

За потребите на ова истражување креиран е целосен експериментален систем со цел формирање на мала база на податоци од вибрациони сигнали за валидација на предложената методологија и тренираните хибридни комбинирани модели. Експерименталниот систем се состои од симулатор, односно ротациона машина на која може да се симулираат дебаланс и дефекти на тркалачки лежишта и мерен систем за мерење на вибрациони сигнали.

5.1.1 Опис и обработка на база на податоци измерена во експериментални услови

Како што беше и претходно нагласено, за потребите на ова истражување е изработен целосен експериментален систем за мерење на вибрациони сигнали во присуство на најчестите дефекти кај ротирачките машини. Експериментот беше изведен во лабораторијата за Вибрации и бучава при Машинскиот факултет во Скопје.

Дизајниран е симулатор на ротирачка машина на кој може да се симулираат дебаланс и дефекти на тркалачки лежишта при контролирани работни услови. При дизајнот на симулаторот главни цели беа постигнување на едноставна заменливост на тркалачките лежишта и променлива ротациона брзина на вратилото која може да се подесува согласно потребите на експериментот. Согласно приложената документација, компанијата БРАКО од Велес комплетно го изработи симулаторот и го донираше на лабораторијата за Вибрации и бучава при Машинскиот Факултет во Скопје со цел поддршка на научните достигнувања на факултетот во овие области. Во состав на дизајнираниот симулатор искористени се електромотор АК80-2 и фреквентен регулатор Delta-VFD-EL-W A1.


Во состав на симулаторот искористени се тркалачки лежишта од тип 6205 2RS, а во табела 20 се дадени спецификациите за тој тип на лежишта. При креирањето на базата на податоци искористени се тркалачки лежишта без присуство на дефект, со присуство на локален дефект на надворешен прстен, слика 60, со присуство на питинг на надворешен прстен, слика 61 и со присуство на два локални дефекти - во кафез и во топче, слика 62. Симулираните

оштетувања на лежиштата се изработени од компанијата ЛТХ Леарница во Охрид со примена на обработка со електроерозија со електрода.


Вибрационите сигнали се снимени при две ротациони фреквенции на вратилото односно при 25 Hz и 50 Hz. Овие вредности се избрани бидејќи претставуваат типични и најчесто применувани работни брзини кај индустриски ротациони машини, особено кај електромотори напојувани од мрежна фреквенција од 50 Hz, каде што номиналната брзина на вртење често е приближно 1500 rpm (25 Hz) или 3000 rpm (50 Hz), во зависност од бројот на полови. Анализата при две различни брзини овозможува испитување на стабилноста и робусноста на дијагностичкиот модел при различни работни режими и проверка на неговата способност за генерализација.

Табела 20. Параметри на тркалачки лежишта од тип 6205 2RS искористени при снимање на базата на податоци во експериментални услови

Спецификации на лежишта	
Број на топчиња	9
Дијаметар на топчиња D_B	7,94 мм
Дијаметар на кафез D_C	46,44 мм
Pitch Diameter ($D_P = D_C - D_B$)	38,5 мм
Контактен агол φ	0 °



Слика 60. Оштетено тркалачко лежиште со локален дефект на надворешен прстен



Слика 61. Оштетено тркалачко лежиште со питинг на надворешен прстен



Слика 62. Оштетено тркалачко лежиште со локални дефекти на кафез и топче

Користејќи ги податоците за димензиите на овој тип на тркалачки лежишта од табела 20, пресметани се вредностите на карактеристичните фреквенции при присутни дефекти во лежиштата, табела 21. Следствено, пресметани се и првите четири хармоници на карактеристичните фреквенции за овие типови на дефекти на тркалачки лежишта, табели 22 и 23, при $f_r = 25 \text{ Hz}$ и $f_r = 50 \text{ Hz}$.

$$BPFO = \frac{9}{2} \cdot \left(1 - \frac{7,94}{38,5} \cdot \cos 0^\circ\right) \cdot f_r = 9 \cdot FTF = 3,573 \cdot f_r$$

$$BSF = \frac{38,5}{2 \cdot 7,94} \cdot \left(1 - \left(\frac{7,94}{38,5} \cdot \cos 0^\circ\right)^2\right) \cdot f_r = 2,321 \cdot f_r$$

$$FTF = \frac{1}{2} \cdot \left(1 - \frac{7,94}{38,5} \cdot \cos 0^\circ\right) \cdot f_r = 0,397 \cdot f_r$$

Табела 21. Пресметани коефициенти за карактеристичните фреквенции при присутни дефекти во тркалачки лежишта тип 6205 2RS искористени при снимање на базата на податоци во експериментални услови

Дефект	$f(f_r)$	$f_r = 25 \text{ Hz}$	$f_r = 50 \text{ Hz}$
BPFO	$3,573 \cdot f_r$	89,325 Hz	178,650 Hz
BSF	$2,321 \cdot f_r$	58,025 Hz	116,050 Hz
FTF	$0,397 \cdot f_r$	9,925 Hz	19,850 Hz


Табела 22. Вредности за првите четири хармоници на карактеристичните фреквенции за најчестите типови на дефекти на тркалачки лежишта тип 6205 2RS при $f_r = 25 \text{ Hz}$

Дефект	f [Hz]	2X	3X	4X
FTF	9,925	19,85	29,775	39,70
BPFO	89,325	178,65	267,975	357,30
BSF	58,028	116,056	174,084	232,112


На слики 63-65 даден е целосен приказ на искористениот експериментален систем, со тоа што на слика 63 е прикажан подетално симулаторот, на слика 64 детално се прикажани елементите од кои се состои мерниот систем, додека на слика 65 е прикажан начинот на поставеност на акцелерометарот при мерење на сигналите.

Табела 23. Вредности за првите четири хармоници на карактеристичните фреквенции за најчестите типови на дефекти на тркалачки лежишта тип 6205 2RS при $f_r = 50 \text{ Hz}$


Дефект	f [Hz]	2X	3X	4X
FTF	19,85	39,70	59,55	79,40
BPFO	178,65	357,30	535,95	714,60
BSF	116,056	232,112	348,168	464,224



Слика 63. Приказ на симулаторот и поставеноста на едноосниот акцелерометар на куќиштето на надворешното лежиште



Слика 64. Приказ на елементите од кои се состои мерниот систем во состав на експерименталниот систем



Слика 65. Поставеност на едноосниот акцелерометар тип 4526 од В&К при мерење на забрзувањето на вибрациите по вертикална и по хоризонтална оска

За мерниот систем е искористена следната опрема, слика 56:

- акцелерометар тип 4526 од производителот Brüel & Kjær Данска,
- анализер на динамички сигнал тип 3560-B-040 од производителот Brüel & Kjær Данска,
- кабел BNC-BNC тип АО-0087-D од производителот Brüel & Kjær Данска,
- адаптер BNC to 10-32 UNF тип JP-0145 од производителот Brüel & Kjær Данска.

За мерење на вибрационите сигнали кои ги јавува симулаторот искористен е едноосен акцелерометар тип 4526 од Brüel&Kjær. Акцелерометарот е поставен на куќиштето на надворешното лежиште, со помош на магнетна врска. Како анализер на динамичкиот сигнал е искористена аквизициона единица од Brüel&Kjær, тип 3560-B-040 Fast Fourier Transform (FFT). Аквизиционата единица се карактеризира со максимална фреквенција на семплирање од 25,6 kHz. Врската помеѓу акцелерометарот и аквизиционата единица е остварена со кабел BNC-BNC тип АО-0087-D и адаптер BNC to 10-32 UNF тип JP-0145 од производителот Brüel&Kjær. За визуелизација и зачувување на сигналите искористен е софтверот PULSE 5.0 од Brüel&Kjær кој претставува лиценциран софтвер за анализа на вибрации и бучава. Пред да се започне со мерењето, подготвен е темплејт во софтверот PULSE 5.0 во кој се прилагодени мерните параметри, калибрацијата на акцелерометарот и начинот на визуелизација на измерените сигнали во текот на мерењето.

Согласно препораките за вибрациона дијагностика на дефекти кај тркалачки лежишта, фреквенцијата на семплирање при креирањето на базата на податоци е поставена на 10 kHz. Максималното времетраење на снимањето на сигналите што може да се постигне со користената аквизициона единица при оваа фреквенција на семплирање изнесува 1,28 s. Согласно постоечката литература, овој временски период на снимање на сигналите е доволен сè додека е задржана соодветно висока вредност за фреквенцијата на семплирање. Понатаму, снимените сигнали во временски домен се експортирани во извештај во Universal ASCII формат во 12800 точки, односно зачувани се 12800 вредности за забрзувањето на вибрациите изразени во m/s^2 измерени во времетраење од 1,28 s. Потоа податоците се конвертирани во .csv формат и организирани во соодветни директориуми според типот на присутен дефект, при што именувањето е извршено согласно работните услови при кои сигналите се снимени.

Терминологијата за означување на лежиштата е усвоена во согласност со MaFaulDa базата на податоци (внатрешно и надворешно лежиште).


Сигналите се снимени по две радијални оски, вертикална и хоризонтална оска, слика 65, при вредности од 1500 грм и 3000 грм, односно 25 Hz и 50 Hz, за ротационата брзина на вратилото и при следните работни состојби:

- при нормална состојба или при состојба во која не се присутни дефекти (4 датотеки),
- при присутен дебаланс од 5g и од 10g (4+4 датотеки),
- при присутен локален дефект во надворешен прстен на надворешното тркалачко лежиште (4 датотеки),
- при присутен локален дефект во надворешен прстен на надворешното тркалачко лежиште и дебаланс од 10g (4 датотеки),
- при присутен питинг во надворешен прстен на надворешното тркалачко лежиште (4 датотеки),
- при присутен питинг во надворешен прстен на надворешното тркалачко лежиште и при присутен дебаланс од 10g (4 датотеки),
- при присутни два локални дефекти: во кафез и во топче на надворешното тркалачко лежиште (4 датотеки),
- при присутни два локални дефекти: во кафез и во топче на надворешното тркалачко лежиште при присутен дебаланс од 10g (4 датотеки).


Во табела 24 даден е детален приказ на начинот на организација на снимените сигнали во рамки на креираната база на податоци во лабораториски услови. Од секој сигнал се екстрахирани истите карактеристики кои беа користени при тренинг на моделот (прикажани во Табела 8), со цел обезбедување методолошка конзистентност и директна споредливост на резултатите. Обработката на сигналите е извршена согласно методологијата која е детално опишана во Поглавје 3, при што се применети повеќе паралелни методи за обработка. Карактеристиките се екстрахирани од сигналите обработени со различни методи за обработка, при што секоја група карактеристики е добиена од соодветно обработениот сигнал кој најдобро ги истакнува информациите релевантни за детекција на присутниот дефект. Во анализата се користени сигналот во временски домен, сигналот трансформиран во фреквентен домен, сигналот добиен по примена на анализа на нискофреквентниот спектар, како и сигналот добиен по примена на анализата на енvelope во фреквентен домен. Обработката на сигналите е извршена при самото снимање на сигналите во софтверот Pulse, применувајќи ја истата методологија која беше опишана во Поглавје 3 и со подесување на соодветните параметри и методи за обработка во рамки на самиот софтвер. На слики 66-69 даден е пример на сигнал пред и по примена на анализа на нискофреквентниот спектар при присутен дебаланс, а на слики 70-77 пред и по примена на анализа на енvelope во фреквентен домен при присутни дефекти во надворешниот прстен на надворешното тркалачко лежиште. При присутен дебаланс може да се забележи врвна вредност при фреквенција блиска до ротационата фреквенција. При присутен дефект во надворешен прстен на тркалачкото лежиште може да се забележат врвни вредности при карактеристичните фреквенции за конкретните ротациони фреквенции на вратилото за искористениот тип на тркалачко лежиште, табели 22 и 23. Поклопувањето на теоретски пресметаните карактеристични фреквенции и врвните вредности во обработените фреквентни спектри потврдува дека експерименталниот стол, мерниот систем и применетата методологија за обработка на сигналите се соодветно дизајнирани и валидирани.

Табела 24. Организација на лабораториски снимените сигнали според ротациона брзина, мерна оска и состојба на системот


Назив на сигнал	Ротациона брзина при која е измерен сигналот [Hz]	Оска по која е измерен сигналот на надворешното лежиште	Состојба при која е измерен сигналот
Signal_01	25	вертикална (rad1)	нормална состојба
Signal_02	50	вертикална (rad1)	
Signal_03	25	хоризонтална (tg1)	
Signal_04	50	хоризонтална (tg1)	
Signal_05	25	вертикална (rad1)	дебаланс од 5 g
Signal_06	50	вертикална (rad1)	
Signal_07	25	хоризонтална (tg1)	
Signal_08	50	хоризонтална (tg1)	
Signal_09	25	вертикална (rad1)	дебаланс од 10 g
Signal_10	50	вертикална (rad1)	
Signal_11	25	хоризонтална (tg1)	
Signal_12	50	хоризонтална (tg1)	
Signal_13	25	вертикална (rad1)	присутен локален дефект во надворешен прстен на надворешното тркалачко лежиште
Signal_14	50	вертикална (rad1)	
Signal_15	25	хоризонтална (tg1)	
Signal_16	50	хоризонтална (tg1)	
Signal_17	25	вертикална (rad1)	присутен локален дефект во надворешен прстен на надворешното тркалачко лежиште и дебаланс од 10 g
Signal_18	50	вертикална (rad1)	
Signal_19	25	хоризонтална (tg1)	
Signal_20	50	хоризонтална (tg1)	
Signal_21	25	вертикална (rad1)	присутен питинг во надворешен прстен на надворешното тркалачко лежиште
Signal_22	50	вертикална (rad1)	
Signal_23	25	хоризонтална (tg1)	
Signal_24	50	хоризонтална (tg1)	
Signal_25	25	вертикална (rad1)	присутен питинг во надворешен прстен на надворешното тркалачко лежиште и дебаланс од 10 g
Signal_26	50	вертикална (rad1)	
Signal_27	25	хоризонтална (tg1)	
Signal_28	50	хоризонтална (tg1)	
Signal_29	25	вертикална (rad1)	присутни два локални дефекти: во кафез и во топче на надворешното тркалачко лежиште
Signal_30	50	вертикална (rad1)	
Signal_31	25	хоризонтална (tg1)	
Signal_32	50	хоризонтална (tg1)	
Signal_33	25	вертикална (rad1)	присутни два локални дефекти: во кафез и во топче на надворешното тркалачко лежиште и дебаланс од 10 g
Signal_34	50	вертикална (rad1)	
Signal_35	25	хоризонтална (tg1)	
Signal_36	50	хоризонтална (tg1)	




Слика 66. Фреквентен спектар на Signal_05 (дебаланс од 5 g, 25 Hz, вертикална оска) пред примена на анализа на нискофреквентен спектар




Слика 67. Фреквентен спектар на Signal_05 (дебаланс од 5 g, 25 Hz, вертикална оска) по примена на анализа на нискофреквентен спектар




Слика 68. Фреквентен спектар на Signal_12 (дебаланс од 10 g, 50 Hz, хоризонтална оска) пред примена на анализа на нискофреквентен спектар




Слика 69. Фреквентен спектар на Signal_12 (дебаланс од 10 g, 50 Hz, хоризонтална оска) по примена на анализа на нискофреквентен спектар




Слика 70. Фреквентен спектар на Signal_17 (локален дефект во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 25 Hz, вертикална оска) пред примена на анализа на енvelopa




Слика 71. Фреквентен спектар на Signal_17 (локален дефект во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 25 Hz, вертикална оска) по примена на анализа на енvelopa




Слика 72. Фреквентен спектар на Signal_18 (локален дефект во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 50 Hz, вертикална оска) пред примена на анализа на енvelopa




Слика 73. Фреквентен спектар на Signal_18 (локален дефект во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 50 Hz, вертикална оска) пред примена на анализа на енvelopa




Слика 74. Фреквентен спектар на Signal_27 (присутен питинг во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 25 Hz, хоризонтална оска) пред примена на анализа на енvelope



Слика 75. Фреквентен спектар на Signal_27 (присутен питинг во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 25 Hz, хоризонтална оска) по примена на анализа на енvelope



Слика 76. Фреквентен спектар на Signal_28 (присутен питинг во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 50 Hz, хоризонтална оска) пред примена на анализа на енvelopa



Слика 77. Фреквентен спектар на Signal_28 (присутен питинг во надворешен прстен на тркалачко лежиште и дебаланс од 10 g, 50 Hz, хоризонтална оска) по примена на анализа на енvelopa

5.1.2 Резултати од валидација на дијагностичките модели со примена на база на податоци снимена во лабораториски услови

Во табела 25 прикажани се резултатите од валидацијата на хибридниот комбиниран модел со измерени сигнали по тангенцијалната и по радијалната оска на надворешното лежиште (tg1 и rad1). Во фазата на тестирање моделот покажа точност од $94,514 \pm 1,828$ % при мултикласната класификација и точност од $93,796 \pm 1,596$ % при бинарната класификација, односно точност од

94,541 ± 1,056 % при мултикласната класификација и точност од 94,601 ± 0,981 % при бинарната класификација. Изборот на овој модел се должи на фактот што оваа комбинација на оски е често применувана во практиката при мерење вибрации за дијагностика на дефекти. Во табелата се прикажани трите состојби со највисоки нивоа на веројатност кои моделот ги предвидува при мултикласната класификација, заедно со соодветните вредности на веројатност. Дополнително, при бинарната класификација моделот ја пресметува веројатноста за присуство на дебаланс за секој анализиран сигнал. Добиената вредност претставува квантитативна мера за сигурноста на одлуката. За донесување конечна класификација се применува праг на одлучување од 0,5, при што сигналите со веројатност $p \geq 0,5$ се класифицираат како „присутен дебаланс“, додека сигналите со $p < 0,5$ се класифицираат како состојба во која „не е присутен дебаланс“. Прикажаните вредности на веројатност овозможуваат дополнителна интерпретација на сигурноста на дијагностичката одлука. Исто така, дадена е и вредноста на v_{RMS} во mm/s, со цел евалуација на нивото на вибрации, односно давање одговор на прашањето дали нивото на вибрации при дијагностицираната состојба на машината сè уште е во прифатлив опсег или не (согласно табела 7).

Табела 25. Резултати од валидација на хибриден комбиниран модел (tg1+rad1) за мултикласна и бинарна класификација – со примена на база на податоци снимена во лабораториски услови

Назив на сигнал	Реална состојба при која е измерен сигналот	Предвидена доминантна состојба	Предвидена состојба (Дебаланс: Присутен/Не е присутен)	Резултат	V_{RMS} [mm/s]
Signal_01	нормална состојба	нормална состојба (Top 3: normal=0,446, overhang_outer_race=0,170, underhang_ball_fault=0,158)	0,480022 Не е присутен дебаланс	Точен	0,152166
Signal_02		нормална состојба (Top 3: normal=0,391, overhang_outer_race=0,158, overhang_ball_fault=0,113)	0,484026 Не е присутен дебаланс	Точен	0,194870
Signal_03		нормална состојба (Top 3: normal=0,398, overhang_outer_race=0,196, overhang_ball_fault=0,160)	0,410977 Не е присутен дебаланс	Точен	0,106013
Signal_04		нормална состојба (Top 3: normal=0,409, overhang_outer_race=0,162, overhang_ball_fault=0,118)	0,402472 Не е присутен дебаланс	Точен	0,182827
Signal_05	дебаланс од 5 g	нормална состојба (Top 3: normal=0,198, imbalance=0,196, overhang_ball_fault=0,160)	0,498632 Не е присутен дебаланс	Погрешен	0,517963
Signal_06		нормална состојба (Top 3: normal=0,175, horizontal_misalignment=0,166, imbalance=0,162)	0,50505 Присутен дебаланс	Погрешен	0,418999
Signal_07		нормална состојба (Top 3: normal=0,217, overhang_outer_race=0,168, imbalance=0,122)	0,516243 Присутен дебаланс	Погрешен	0,426863

Signal_08		дебаланс (Top 3: imbalance=0,505, overhang_outer_race=0,163, normal=0,155)	0,562125 Присутен дебаланс	Точен	0,749961
Signal_09		дебаланс (Top 3: imbalance=0,310, normal=0,172, overhang_outer_race=0,127)	0,517581 Присутен дебаланс	Точен	4,449812
Signal_10	дебаланс од 10 g	дебаланс (Top 3: imbalance=0,451, overhang_outer_race=0,159, overhang_ball_fault=0,115)	0,568613 Присутен дебаланс	Точен	2,997105
Signal_11		дебаланс (Top 3: imbalance=0,367, horizontal_misalignment =0,206, overhang_ball_fault=0,159)	0,860962 Присутен дебаланс	Точен	4,973856
Signal_12		дебаланс (Top 3: imbalance=0,384, normal =0,197, vertical misalignment=0,139)	0,652431 Присутен дебаланс	Точен	3,374969
Signal_13		дефект во надворешен прстен на внатрешно лежиште (Top 3: underhang_outer_race=0,293, imbalance=0,171, overhang_outer_race=0,127)	0,45784 Не е присутен дебаланс	Погрешен	3,350964
Signal_14	присутен локален дефект во надворешен прстен на надворешното тркалачко лежиште	дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race=0,542, imbalance=0,135, overhang_outer_race=0,127)	0,44909 Не е присутен дебаланс	Точен	3,390173
Signal_15		дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race=0,459, underhang_outer_race=0,127, imbalance=0,113)	0,454356 Не е присутен дебаланс	Точен	3,280448
Signal_16		дефект во топче на надворешно лежиште (Top 3: overhang_ball_fault=0,370, overhang_outer_race=0,136, horizontal_misalignment=0,108)	0,462099 Не е присутен дебаланс	Погрешен	3,482674
Signal_17	присутен локален дефект во надворешен прстен на надворешното тркалачко лежиште и дебаланс од 10 g	дефект во топче на надворешно лежиште (Top 3: overhang_ball_fault=0,387, overhang_outer_race=0,136, horizontal_misalignment=0,107)	0,655037 Присутен дебаланс	Погрешен	4,312922
Signal_18		дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race=0,479, overhang_ball_fault=0,100, underhang_cage_fault=0,104)	0,539775 Присутен дебаланс	Точен	4,318369

Signal_19		дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race=0,460, overhang_ball_fault=0,153, underhang_cage_fault=0,101)	0,508557 Присутен дебаланс	Точен	4,537783
Signal_20		дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race=0,475, overhang_ball_fault=0,105, horizontal_misalignment=0,107)	0,559918 Присутен дебаланс	Точен	4,764609
Signal_21		дефект во топче на надворешно лежиште (Top 3: overhang_ball_fault=0,339, overhang_outer_race=0,151, horizontal_misalignment=0,121)	0,442239 Не е присутен дебаланс	Погрешен	3,296151
Signal_22	присутен питинг во надворешен прстен на надворешното тркалачко лежиште	дефект во топче на надворешно лежиште (Top 3: overhang_ball_fault=0,374, overhang_outer_race=0,135, horizontal_misalignment=0,107)	0,423231 Не е присутен дебаланс	Погрешен	3,41184
Signal_23		дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race=0,484, overhang_ball_fault=0,104, underhang_cage_fault=0,100)	0,437741 Не е присутен дебаланс	Точен	3,30395
Signal_24		дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race=0,475, overhang_ball_fault=0,126, underhang_cage_fault=0,096)	0,446659 Не е присутен дебаланс	Точен	3,340365
Signal_25		дефект во кафез на надворешно лежиште (Top 3: overhang_cage_fault=0,202, normal=0,169, overhang_outer_race=0,136)	0,731856 Присутен дебаланс	Погрешен	4,199542
Signal_26	присутен питинг во надворешен прстен на надворешното тркалачко лежиште и дебаланс од 10 g	дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race=0,476, overhang_ball_fault=0,107, underhang_cage_fault=0,104)	0,702305 Присутен дебаланс	Точен	4,233931
Signal_27		дефект во надворешен прстен на внатрешно лежиште (Top 3: underhang_outer_race=0,262, overhang_outer_race=0,127, vertical_misalignment=0,122)	0,695839 Присутен дебаланс	Погрешен	4,155174
Signal_28		дефект во надворешен прстен на внатрешно лежиште (Top 3: underhang_outer_race=0,246,	0,489063 Не е присутен дебаланс	Погрешен	4,210835

		overhang_outer_race=0,155, normal=0,114)			
Signal_29		дефект во кафез на надворешно лежиште (Top 3: overhang_cage_fault=0,225, overhang_outer_race=0,197, overhang_ball_fault=0,151)	0,413621 Не е присутен дебаланс	Точен	3,829533
Signal_30	присутни два локални дефекти: во кафез и во топче на надворешното тркалачко лежиште	дефект во топче на надворешно лежиште (Top 3: overhang_ball_fault=0,504, imbalance=0,144, underhang_outer_race=0,131)	0,413539 Не е присутен дебаланс	Точен	3,940322
Signal_31		дефект во топче на внатрешно лежиште (Top 3: underhang_ball_fault=0,360, overhang_outer_race=0,175, overhang_ball_fault=0,123)	0,417901 Не е присутен дебаланс	Погрешен	3,764906
Signal_32		дефект во топче на надворешно лежиште (Top 3: overhang_ball_fault=0,331, overhang_outer_race=0,176, horizontal_misalignment=0,119)	0,468478 Не е присутен дебаланс	Точен	3,777804
Signal_33		дефект во кафез на надворешно лежиште (Top 3: overhang_cage_fault=0,402, normal=0,169, overhang_outer_race=0,136)	0,513109 Присутен дебаланс	Точен	3,972191
Signal_34	присутни два локални дефекти: во кафез и во топче на надворешното тркалачко лежиште и дебаланс од 10 g	дефект во топче на надворешно лежиште (Top 3: overhang_ball_fault=0,439, overhang_outer_race=0,163, horizontal_misalignment=0,110)	0,522141 Присутен дебаланс	Точен	3,963005
Signal_35		дефект во топче на надворешно лежиште (Top 3: overhang_ball_fault=0,326, overhang_outer_race=0,177, horizontal_misalignment=0,129)	0,611149 Присутен дебаланс	Точен	4,324799
Signal_36		дефект во топче на надворешно лежиште (Top 3: overhang_ball_fault=0,523, overhang_outer_race=0,160, horizontal_misalignment=0,129)	0,580022 Присутен дебаланс	Точен	4,414399

Согласно резултатите прикажани во табела 25, може да се заклучи дека моделот успешно ја предвидува доминантната состојба на машината и воедно детектира дали е присутен дебаланс како дополнителен дефект во 66,67 % од анализираните случаи. Резултатите покажуваат дека моделот се карактеризира со робусност и способност за генерализација при валидација со

претходно непозната база на податоци, снимена во лабораториски услови, што потврдува дека предложената методологија за обработка на сигналите, екстракција на карактеристики и избор на алгоритам е соодветна и применлива и при различни работни услови. Сепак, може да се забележи дека моделот покажува ограничувања во случаи кога постојат слични вибрациони карактеристики помеѓу различни типови дефекти, особено кај дефекти на лежишта. Во такви ситуации моделот може да резултира со непрецизно идентификување на конкретниот тип или позиција на дефектот (на пример дали е присутен дефект во внатрешното или во надворешното лежиште), иако детектира дека е присутен дефект во лежиште. Од апликативен аспект, ваквиот тип на грешка не претставува критичен проблем, бидејќи доколку се утврди дека постои дефект во конкретното лежиште и нивото на вибрации го надминува дозволеният праг согласно стандардите, лежиштето би било предмет на замена без оглед на точната локација на оштетувањето. Дополнително, вредностите на v_{RMS} претставуваат значаен индикатор за следење на состојбата на машината. Тие овозможуваат проценка на интензитетот на вибрациите и во случаи кога нивото сè уште не е критично. На тој начин се создава можност за рано предупредување и планирање на превентивна интервенција, со што се подобрува сигурноста и економичноста на одржувањето. Програмскиот код во Python за валидација на дијагностичките модели со примена на база на податоци снимена во лабораториски услови чии резултати се прикажани во табела 25 е прикажан во Прилог Г-1.

5.1.3 Валидација на робустноста на моделите со примена на сигнали со шумови

Со цел проценка на робустноста на предложената методологија за дијагностика во услови кои се поблиски до реалните индустриски средини, извршена е дополнителна валидација со вештачко додавање на адитивен бел Гаусов шум (Additive White Gaussian Noise – AWGN) во сигналите од базата снимена во лабораториски услови (чија организација е прикажана во табела 24). Овој пристап е применет имајќи предвид дека лабораториските бази на податоци најчесто содржат значително почисти сигнали во споредба со сигналите измерени во реални индустриски услови, каде што често се присутни шум од околината, структурни вибрации и други извори на интерференција.

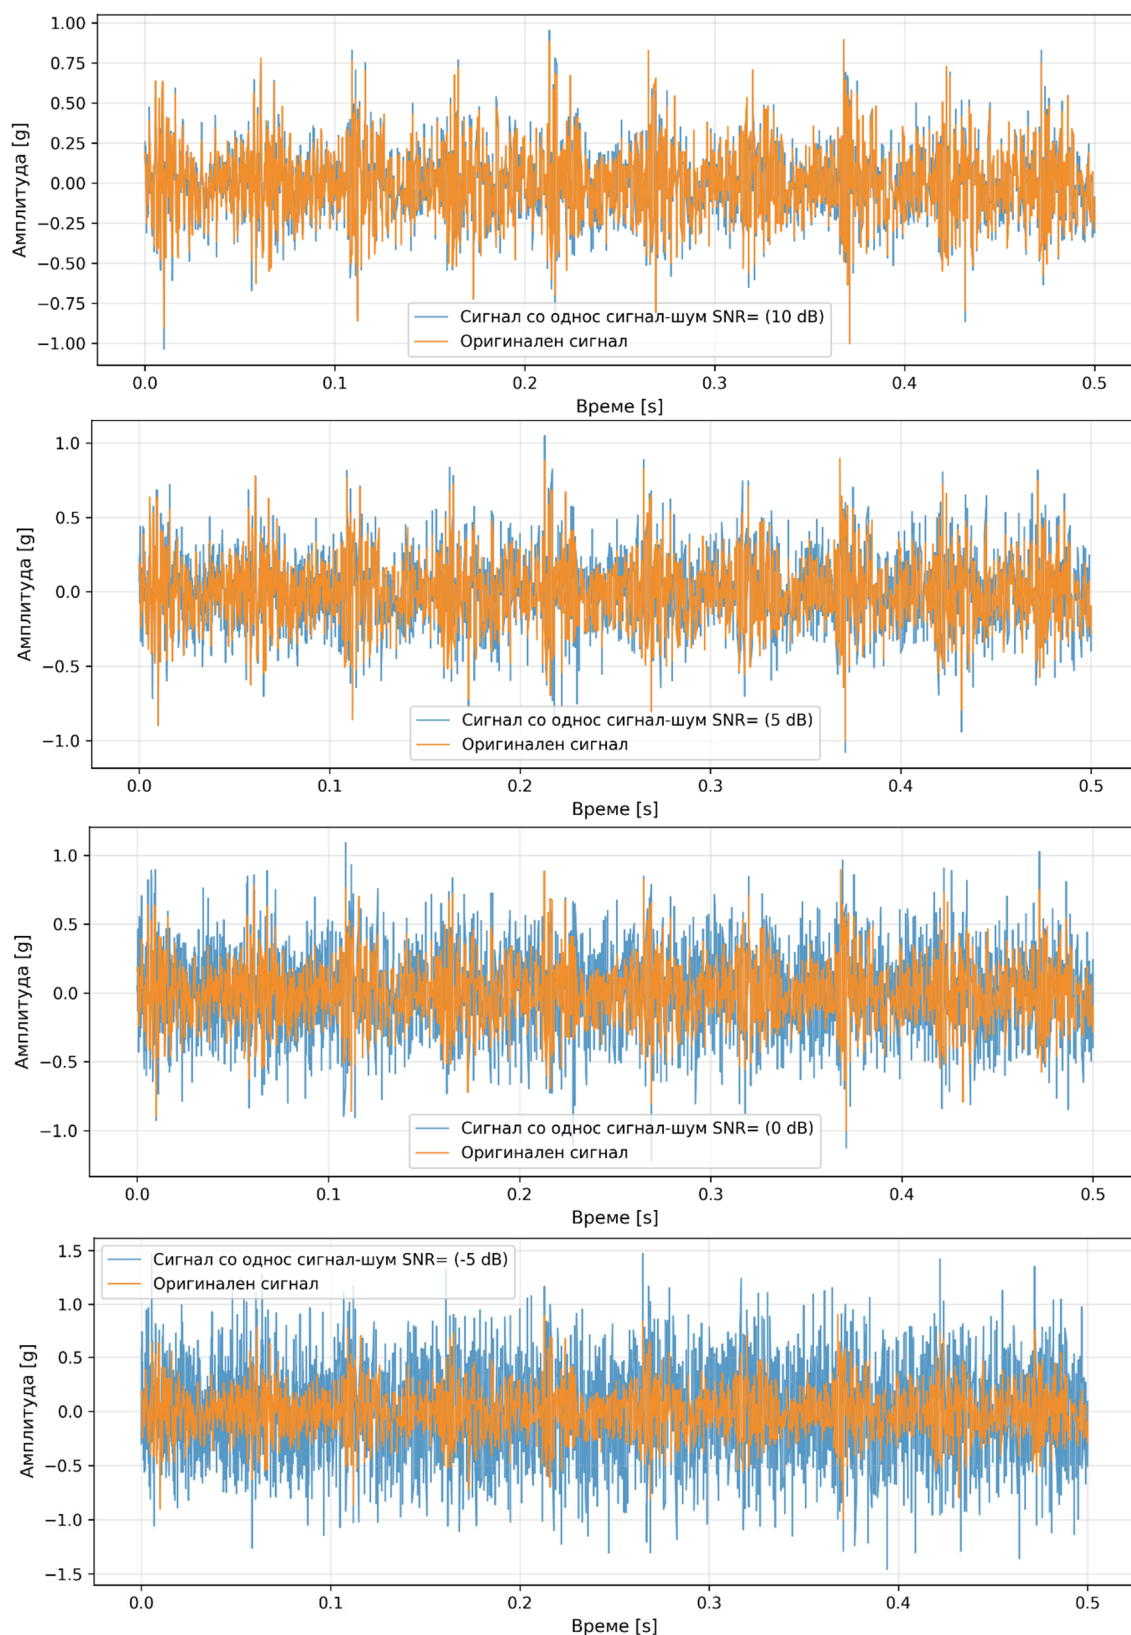
Шумот е додаден при повеќе вредности на сооднос сигнал-шум (Signal-to-Noise Ratio – SNR): 40, 30, 20, 15, 10, 5, 0 и -5 dB. За секое ниво на SNR е применета истата методологија за обработка на сигналите, екстракција на карактеристиките и класификација опишана во поглавјата 3 и 4, без повторно тренирање на моделите. Основните резултати прикажани во точка 5.1.2 се однесуваат на измерените сигнали без дополнително внесен шум.

На слика 78 прикажан е оригиналниот сигнал (Signal_07), како и неговите верзии со додаден шум при ниски вредности на односот сигнал-шум (10, 5, 0 и -5 dB).


На слика 79 прикажана е вкупната точност при класификација добиена при валидацијата со примена на сигналите со различни нивоа на адитивен бел Гаусов шум. Притоа, како точна класификација се смета случајот кога истовремено се правилно предвидени и доминантниот тип на дефект во рамки на мултикласната класификација (прв слој), како и присуството или отсуството на дебаланс (втор слој).

Добиените резултати покажуваат постепено и монотонно намалување на точноста на класификација како што се зголемува на интензитетот на шумот. Може да се забележи дека перформансите на моделот остануваат релативно стабилни до вредности од околу 10 dB, што укажува на добра отпорност на умерени нивоа на шум кои често се присутни во индустриските системи за вибрациски надзор. Значително намалување на точноста се забележува само при екстремно ниски вредности на SNR (≤ 0 dB), кои претставуваат многу неповолни услови и ретко се јавуваат кај правилно инсталирани системи за мерење вибрации.

Овие резултати потврдуваат дека предложената методологија како и креираниот дијагностички модел се карактеризира со робустност и во услови на присуство на шум, што ја потврдува применливоста на предложената методологија во реални индустриски апликации.




Слика 78. Временска репрезентација на оригиналниот сигнал и неговите верзии со додаден шум при ниски вредности на SNR




Слика 79. Точност при класификација со примена на различни нивоа на адитивен бел Гаусов шум

5.1.4 Резултати од валидација на дијагностичките модели со сигнал снимен во лабораториски услови со MEMS Акцелерометар

Со цел дополнителна проверка на способноста за генерализација на предложената методологија, извршена е валидација со сигнал снимен со автономен MEMS (Micro-Electro-Mechanical Systems MEMS) акцелерометар ADXL335 интегриран со WeMos D1 Mini микроконтролер. Сигналот е снимен по хоризонтална оска (tg1) при присутен локален дефект во надворешен прстен на надворешното лежиште, при ротациона фреквенција на вратилото од 51,5 Hz. Снимениот сигнал во временски домен е прикажан на слика 80. Согласно наведеното, применет е моделот tg1, кој при тестирање покажа точност од $94,514 \pm 1,828$ % при мултикласна класификација, табела 15, и точност од $94,541 \pm 1,056$ % при бинарна класификација, табела 16. За разлика од мерењата реализирани со специјализиран анализер на динамички сигнали (тип 3560-B-040 од производителот Brüel & Kjær Данска), обработката на сигналот во овој случај целосно е извршена во Python околина. Сигналот, зачуван во .txt формат и конвертиран во g, најпрво е обработен со отстранување на неговата средна вредност што се елиминира константната (DC) компонента и сигналот се центрира околу нулата. Потоа е извршено отстранување на линеарната компонента, односно евентуалниот тренд кој може да настане поради карактеристики на мерниот систем или бавни варијации во сигналот. Со ова се добива сигнал без константна и линеарна компонента, чија амплитуда осцилира околу нула, што претставува предуслов за правилна фреквентна анализа. Потоа е применета методологијата за обработка на сигналот и екстракција на карактеристики опишана во Поглавје 3. Фреквентниот спектар на сигналот во неговата оригинална форма, без претходна обработка, е прикажан на слика 81. Може да се забележи дека без претходна обработка на сигналот карактеристичните фреквенции на дефектот не се јасно изразени, што ја отежнува директната дијагностичка интерпретација.




Слика 80. Снимен сигнал со MEMC акцелерометар ADXL335 интегриран со WeMos D1 Mini микроконтролер во временски домен



Слика 81. Фреквентен спектар на оригиналниот сигнал снимен со MEMC акцелерометар ADXL335 интегриран со WeMos D1 Mini микроконтролер

По обработката на сигналот се добива фреквентен спектар на енvelopата на сигналот кој е прикажан на слики 82 и 83. Во спектарот се идентификуваат врвни вредности при околу 186 Hz, 376 Hz, 552 Hz и 736 Hz. Овие вредности се во согласност со теоретски пресметаната карактеристична фреквенција при присутен дефект во надворешен прстен на тркалачки лежишта тип 6205 2RS при ротациона фреквенција од 51,5 Hz, односно 184,01 Hz, како и нејзините хармоници (2X, 3X, 4X). Пресметаните вредности се дадени во табела 26.




Слика 82. Фреквентен спектар на енvelopата на обработениот сигнал снимен со MEMC акцелерометар ADXL335 интегриран со WeMos D1 Mini микроконтролер

Означените врвни вредности во фреквентниот спектар на енvelopата ја потврдуваат присутноста на дефект во надворешен прстен, што е во согласност со реалната состојба на машината.

Екстрахираните карактеристики потоа се внесени во претходно тренираниот хибриден комбиниран модел по хоризонтална оска (tg1). При мултикласната класификација, табела 27, моделот ја предвидува состојбата „overhang_outer_race“ (дефект во надворешен прстен на надворешно лежиште) со највисока веројатност од 0,429, што е во согласност со реално

присутниот дефект. При бинарната класификација, табела 27, добиената веројатности за присуство на дебаланс изнесува 0,703, што е над 0,5, па сигналот е класифициран како состојба со „присутен дебаланс“.



Слика 83. Фреквентен спектар на енвелопата на обработениот сигнал снимен со MEMS акцелерометар ADXL335 интегриран со WeMos D1 Mini микроконтролер – со означени врвни вредности

Резултатите покажуваат дека предложената методологија за обработка на сигналите и екстракција на карактеристики постигнува стабилна дијагностичка способност и при примена врз сигнал снимен со автономен MEMS систем. Со тоа се потврдува применливоста на моделот не само при примена на специјализиран анализер за снимање и обработка на вибрациони сигнали, туку и во реални IoT (Internet of Things) системи за мониторинг на вибрации.

Табела 26. Пресметани коефициенти за карактеристичните фреквенции при присутен дефект во надворешен прстен на тркалачки лежишта тип 6205 2RS искористени при снимање на базата на податоци во експериментални услови

Дефект	$f(f_r)$	$f_r = 51,5 \text{ Hz}$	2X	3X	4X
BPFO	$3,573 \cdot f_r$	184,010 Hz	368,020 Hz	552,030 Hz	736,040 Hz

Табела 27. Резултати од валидација на хибриден комбиниран модел (tg1+rad1) за мултикласна и бинарна класификација – со примена на сигнал снимен во лабораториски услови со MEMS акцелерометар ADXL335 интегриран со WeMos D1 Mini микроконтролер

Реална состојба при која е измерен сигналот	Предвидена доминантна состојба	Предвидена состојба (Дебаланс: Присутен/Не е присутен)	Резултат	V_{RMS} [mm/s]
присутен локален дефект во надворешен прстен на надворешното тркалачко лежиште и дебаланс од 10 g	дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race = 0,4292 overhang_ball_fault = 0,1941 horizontal-misalignment = 0,1067)	0,702910 Присутен дебаланс	Точен	4,798415

5.2 Валидација со примена на база на податоци измерена во реални услови

Националниот Технички Универзитет при Атина сподели база на податоци измерена во реални индустриски услови со Машинскиот Факултет во Скопје со цел поддршка на истражувачките достигнувања во овие области. Истата се состои од вибрациони сигнали измерени во неколку различни машински системи кај кои е присутен дефект во надворешниот прстен на едно тркалачко лежиште. Во продолжение е даден опис на снимената база на податоци и начинот на нивна обработка.

5.2.1 Опис и обработка на база на податоци снимена во реални услови

Во табела 28 е прикажан начинот на организација на базата на податоци снимена во реални услови според ротациона брзина, фреквенција на семплирање и тип и димензии на тркалачко лежиште. Сите сигнали се снимени по вертикалната оска на едно лежиште и при фреквенцијата на семплирање од 8,33 kHz во времетраење од 0,5 s. Согласно Никвистовата теорема, највисоката фреквенција која може да се детектира во овој случај е 4,165 kHz, што е доволно за дијагностика на дефекти во лежишта. При снимање на Сигнал 5 не е присутен дефект. При снимање на Сигнал 14 присутен е само дефект во надворешен прстен на тркалачко лежиште додека во сите други случаи присутна е комбинација на дефект во надворешен прстен на тркалачко лежиште и дебаланс.

Табела 28. Организација на базата на податоци снимена во реални услови според ротациона брзина, фреквенција на семплирање и тип и димензии на тркалачко лежиште

Назив на сигнал	Ротациона брзина f_r при која е снимен сигналот [Hz]	Податоци за лежиште (тип и димензии)	Карактеристична фреквенција при присутен дефект во надворешен прстен на тркалачко лежиште $BPF0 = f(f_r)$
Signal_01		тип 22228B	
Signal_02		(Број на топчиња 19)	
Signal_03	22,50	Дијаметар на топчиња $D_B = 1,141$ mm	$8,13 \times f_r$
Signal_04		Pitch Diameter $D_P = 7,807$ mm	
Signal_05		Контактен агол $\varphi = 10^\circ$	
Signal_06		тип SKF2312	
Signal_07		(Број на топчиња 12)	
Signal_08	20,00	Дијаметар на топчиња $D_B = 0,812$ mm	$4,72 \times f_r$
Signal_09		Pitch Diameter $D_P = 3,681$ mm	
Signal_10		Контактен агол $\varphi = 15^\circ$	
Signal_11	18,75	тип SKF1218	
		(Број на топчиња 10)	
		Дијаметар на топчиња $D_B = 0,625$ mm	$8,30 \times f_r$
		Pitch Diameter $D_P = 4,901$ mm	
		Контактен агол $\varphi = 6^\circ$	
Signal_12	17,50	тип 22220 ЕК	
		(Број на топчиња 18)	
		Дијаметар на топчиња $D_B = 0,807$ mm	$7,72 \times f_r$
		Pitch Diameter $D_P = 5,583$ mm	

Контактен агол $\varphi = 10^\circ$			
тип SKF2312			
(Број на топчиња 12)			
Signal_13	21,00	Дијаметар на топчиња $D_B = 0,812 \text{ mm}$	$4,72 \times f_r$
		Pitch Diameter $D_P = 3,681 \text{ mm}$	
Контактен агол $\varphi = 15^\circ$			
тип SKF23222			
(Број на топчиња 19)			
Signal_14	20,60	Дијаметар на топчиња $D_B = 0,866 \text{ mm}$	$8,20 \times f_r$
		Pitch Diameter $D_P = 6,186 \text{ mm}$	
Контактен агол $\varphi = 1^\circ$			

На слика 84 прикажани се снимените вибрациони сигнали (Сигнал 1- Сигнал 5) во временски домен на индустриски компресор во присуство на дефект во надворешниот прстен на неговото тркалачко лежиште. Ротационата брзина на вратилото при снимањето на овие сигнали е 1350 врт/мин, односно 22,5 Hz. Лежиштето со присутен дефект е тип 22228В. Согласно спецификацијата за овој тип на тркалачко лежиште, карактеристичната BPFO фреквенција е 8,13 пати поголема од ротационата брзина на вратилото односно изнесува 182,925 Hz. Временскиот интервал помеѓу две последователни мерења е една недела, а Сигнал 5 е снимен откако е заменето лежиштето со присутен дефект, односно присутниот дефект е отстранет и компресорот работи без присутен дефект во моментот на снимање на сигналот.


На слика 85 се прикажани фреквентните спектри по примена на брза Фуриева трансформација на оригиналните сигнали (Сигнал 1- Сигнал 5). Може да се забележат врвни вредности на амплитудата на фреквенции од околу 2000 Hz и 2200 Hz. Присуството на дефект во надворешниот прстен на лежиштето генерира импулсни сигнали кои предизвикуваат резонанца кога ќе се поклопат со природната фреквенција на лежиштето, куќиштето на лежиштето или сензорскиот систем. Природната фреквенција на тркалачките лежишта, куќиштата на лежиштата и акцелерометрите генерално се движи во опсег од 1-5 kHz [151]. Со други зборови, врвните вредности кои се забележуваат во фреквентниот спектар на оригиналниот сигнал не се при карактеристичните фреквенции туку се резултат на резонанцата која се јавува при преклопување на импулсниот сигнал кој е предизвикан од присуството на дефект во надворешниот прстен на тркалачкото лежиште и природната фреквенција на лежиштето, неговото куќиште или акцелерометрите. Вредноста на амплитудата, односно содржаната енергија при карактеристичната BPFO фреквенција од 182,925 Hz е значително пониска отколку онаа при резонанцата. Како резултат на ваквата резонанца како и присуството на шумови во снимениот сигнал, не се забележува врвна вредност при карактеристичната BPFO фреквенција.

За решавање на овој проблем, како што беше и претходно објаснето, применета е методологијата која е детално опишана во Поглавје 3. На слика 86 прикажан е фреквентниот спектар на енвелопата на сигналите од кои може да се забележи дека се појавуваат врвни вредности во опсег од 183 Hz до 189 Hz, додека врвните вредности при високи фреквенции (2000 Hz и 2200 Hz) повеќе не се присутни. Во овој случај, присуството на дефект во надворешниот прстен на лежиштето може да се отчита како присуство на врвни вредности во фреквентниот спектар на енвелопата во опсег од 183 Hz до 190 Hz. Согласно спецификацијата на тркалачкото лежиште неговата карактеристична фреквенција при присуство на дефект во надворешниот прстен изнесува 182,925 Hz. Се забележува одредено отстапување како резултат на промени во ротационата брзина на вратилото како резултат на триење и пролизгување или пак како резултат на резолуцијата на FFT (соодносот помеѓу фреквенцијата на семплирање и бројот на примероци или во овој случај 2,03 Hz). Бидејќи петтиот сигнал е снимен откако е заменето лежиштето со

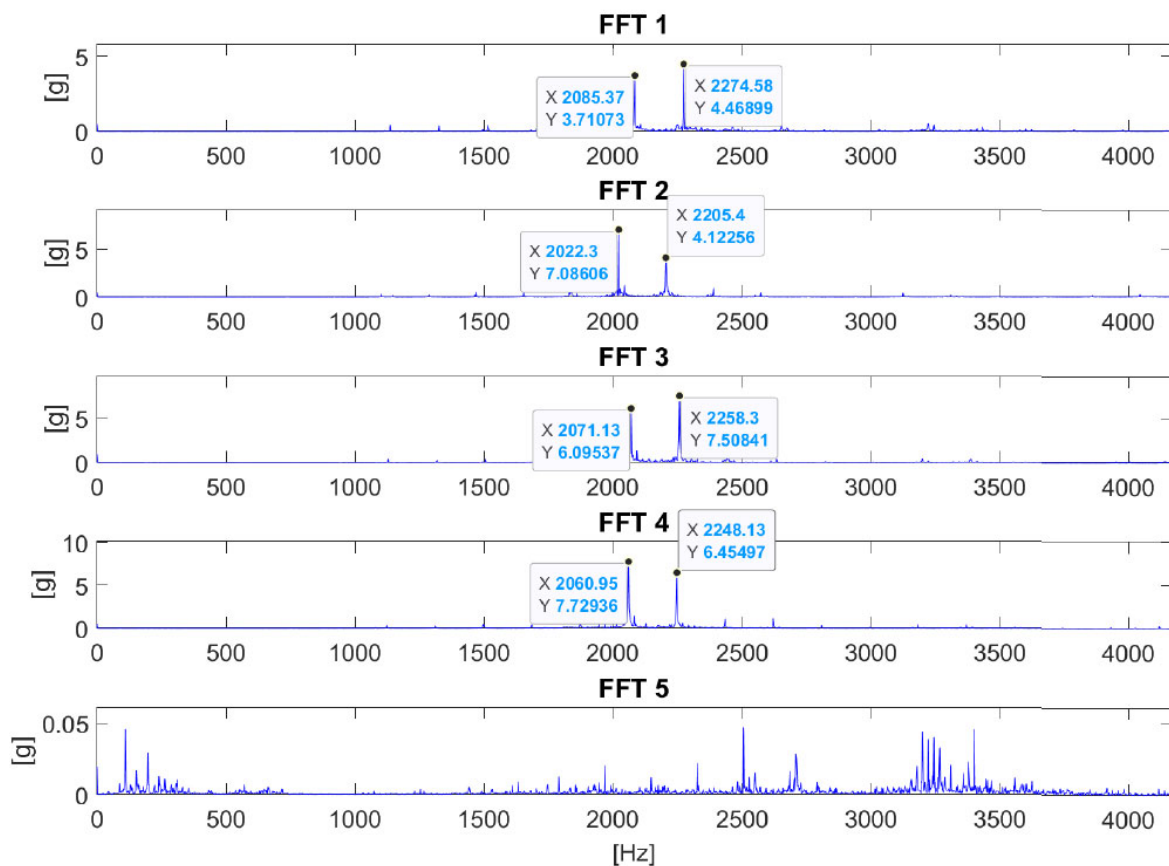
присутен дефект може да се забележи дека истиот има сосема поинаква природа, односно во него не се забележуваат карактеристичните фреквенции и врвните вредности на амплитудата на сигналот се многу пониски.

На слика 87 прикажани се вибрациони сигнали (Сигнал 6–10) во временски домен снимени на вентилатор во присуство на дефект во надворешниот прстен на неговото тркалачко лежиште. Ротационата брзина на вратилото при снимањето на овие сигнали е 1200 врт/мин, односно 20 Hz. Лежиштето со присутен дефект е од брендот SKF тип 2312. Согласно спецификацијата за овој тип на тркалачко лежиште, карактеристичната BPFO фреквенција е 4,72 пати поголема од ротационата брзина на вратилото односно изнесува 94,4 Hz. Притоа, сигналите прикажуваат различни нивоа на изразеност на дефектите бидејќи временскиот интервал помеѓу две последователни мерења е два месеци во текот на кои вентилаторот работел.


На слика 88 прикажани се фреквентните спектри по примена на брза Фуриева трансформација на оригиналните сигнали. Може да се забележат врвни вредности на амплитудата на фреквенции од околу 1300 Hz и 1400 Hz и тие се фреквенции-носители кои се јавуваат како резултат на резонанцата.



Слика 84. Снимени вибрациони сигнали 1-5 во временски домен




Слика 85. Фреквентен спектар по примена на FFT на оригиналните сигнали 1-5



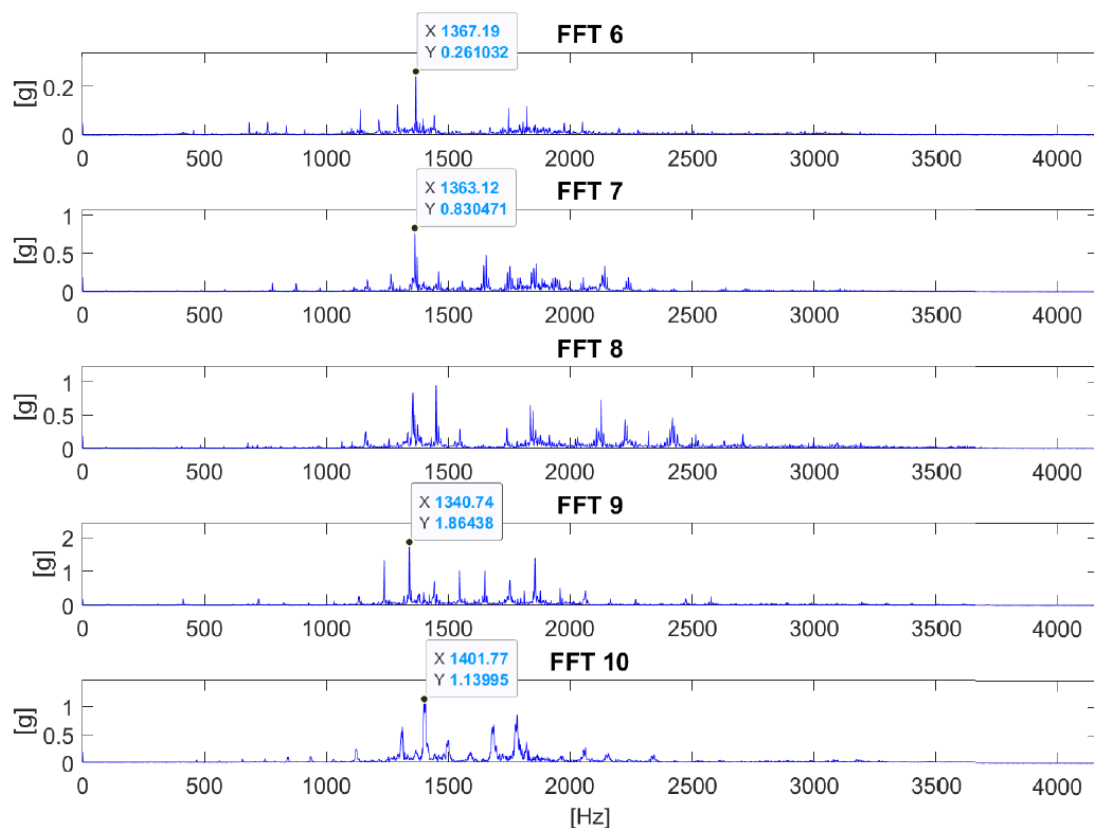
Слика 86. Фреквентен спектар на енвелопата на сигналите 1-5

На слика 89 даден е фреквентниот спектар на енvelopата на сигналот по примена на методологијата за обработка на сигналите опишана во Поглавје 3. Во овој случај, присуството на дефект во надворешниот прстен на лежиштето може да се отчита како присуство на врвни вредности во фреквентниот спектар на енvelopата во опсег од 75 Hz до 103 Hz. Согласно спецификацијата на тркалачкото лежиште неговата карактеристична фреквенција при присуство на дефект во надворешниот прстен изнесува 94,4 Hz. Отстапувањето кај сигнал 6, кое е и најмногу отстапува, се должи на тоа што вибрациониот сигнал е измерен во рана фаза на појава на дефектот во лежиштето. Секој фреквентен спектар на енvelopата на измерените сигнали содржи во себе информација за различно ниво на изразеност на дефектот во надворешниот прстен на лежиштето.


Сигнал 11 е снимен во присуство на дебаланс и дефект во надворешниот прстен на неговото тркалачко лежиште. Ротационата брзина на вратилото при снимањето на овој сигнал изнесува 18,75 Hz. Лежиштето со присутен дефект е од брендот SKF тип 1218. Согласно спецификацијата за овој тип на тркалачко лежиште, карактеристичната BPFO фреквенција е 8,3 пати поголема од ротационата брзина на вратилото односно изнесува 155,625 Hz. На слика 90 прикажан е фреквентниот спектар на Сигнал 11 по примена на брза Фуриева трансформација на оригиналниот сигнал. Може да се забележи врвна вредност на амплитудата на фреквенција од околу 1141 Hz и таа е фреквенција-носител која се јавува како резултат на резонанцата.



Слика 87. Снимени вибрациони сигнали 6-10 во временски домен



Слика 88. Фреквентен спектар по примена на FFT на оригиналните сигнали 6-10




Слика 89. Фреквентен спектар на енvelopата на сигналите 6-10


На слика 91 даден е фреквентниот спектар на енвелопата на сигналот по примена на методологијата за обработка на сигналите опишана во Поглавје 3. Во овој случај, присуството на дефект во надворешниот прстен на лежиштето може да се отчита како присуство на врвна вредност во фреквентниот спектар на енвелопата при вредност од 162,72 Hz. Согласно спецификацијата на тркачалкото лежиште неговата карактеристична фреквенција при присуство на дефект во надворешниот прстен изнесува 155,625 Hz. Се забележува одредено отстапување како резултат на промени во ротационата брзина на вратилото како резултат на триење и пролизгување или пак како резултат на резолуцијата на FFT (соодносот помеѓу фреквенцијата на семплирање и бројот на примероци или во овој случај 2,03 Hz).

Сигнал 12 снимен е во присуство на дебаланс и дефект во надворешниот прстен на неговото тркачалко лежиште. Ротационата брзина на вратилото при снимањето на овој сигнал изнесува 17,5 Hz. Лежиштето со присутен дефект е тип 22220 ЕК. Согласно спецификацијата за овој тип на тркачалко лежиште, карактеристичната BPFO фреквенција е 7,72 пати поголема од ротационата брзина на вратилото односно изнесува 135,1 Hz. На слика 92 прикажан е фреквентниот спектар на Сигнал 12 по примена на брза Фуриева трансформација на оригиналниот сигнал. Може да се забележи врвна вредност на амплитудата на фреквенција од околу 1350 Hz и таа е фреквенција-носител која се јавува како резултат на резонанцата.


На слика 93 даден е фреквентниот спектар на енвелопата на сигналот по примена на методологијата за обработка на сигналите опишана во Поглавје 3. Во овој случај присуството на дефект во надворешниот прстен на лежиштето може да се отчита како присуство на врвна вредност во фреквентниот спектар на енвелопата при вредност од 136,32 Hz. Согласно спецификацијата на тркачалкото лежиште неговата карактеристична фреквенција при присуство на дефект во надворешниот прстен изнесува 135,1 Hz. Се забележува релативно мало отстапување како резултат на промени во ротационата брзина на вратилото како резултат на триење и пролизгување или пак како резултат на резолуцијата на FFT (соодносот помеѓу фреквенцијата на семплирање и бројот на примероци или во овој случај 2,03 Hz).




Слика 90. Фреквентен спектар по примена на FFT на оригиналниот сигнал – Сигнал 11



Слика 91. Фреквентен спектар на енвелопата – Сигнал 11




Слика 92. Фреквентен спектар по примена на FFT на оригиналниот сигнал – Сигнал 12




Слика 93. Фреквентен спектар на енvelopата– Сигнал 12

Сигнал 13 снимен е во присуство на дебаланс и дефект во надворешниот прстен на неговото тркалачко лежиште. Ротационата брзина на вратилото при снимањето на овој сигнал изнесува 21 Hz. Лежиштето со присутен дефект е од брендот SKF тип 2312. Согласно спецификацијата за овој тип на тркалачко лежиште, карактеристичната BPFO фреквенција е 4,72 пати поголема од ротационата брзина на вратилото односно изнесува 99,12 Hz. На слика 94 е прикажан фреквентниот спектар на Сигнал 13 по примена на брза Фуриева трансформација на оригиналниот сигнал. Може да се забележи врвна вредност на амплитудата на фреквенција од околу 1420 Hz и таа е фреквенција-носител која се јавува како резултат на резонанцата. На слика 95 даден е фреквентниот спектар на енvelopата на сигналот по примена на методологијата за обработка на сигналите опишана во Поглавје 3. Во овој случај присуството на дефект во надворешниот прстен на лежиштето што може да се отчита како присуство на врвна вредност во фреквентниот спектар на енvelopата при вредност од 101,725 Hz. Согласно спецификацијата на тркалачкото лежиште неговата карактеристична фреквенција при присуство на дефект во надворешниот прстен изнесува 99,12 Hz. Се забележува релативно мало отстапување како резултат на промени во ротационата брзина на вратилото како резултат на триење и пролизгување или пак како резултат на резолуцијата на FFT (соодносот помеѓу фреквенцијата на семплирање и бројот на примероци или во овој случај 2,03 Hz).




Слика 94. Фреквентен спектар по примена на FFT на оригиналниот сигнал - Сигнал 13




Слика 95. Фреквентен спектар на енvelopата– Сигнал 13

Сигнал 14 сниман е во присуство на дефект во надворешниот прстен на неговото тркалачко лежиште. Ротационата брзина на вратилото при снимањето на овој сигнал изнесува 20,6 Hz. Лежиштето со присутен дефект е од брендот SKF тип 23222. Согласно спецификацијата за овој тип на тркалачко лежиште, карактеристичната BPFO фреквенција е 8,2 пати поголема од ротационата брзина на вратилото односно изнесува 168,92 Hz. На слика 96 прикажан е фреквентниот спектар на Сигнал 14 по примена на брза Фуриева трансформација на оригиналниот сигнал. Може да се забележи врвна вредност на амплитудата на фреквенција од околу 1717 Hz и таа е фреквенција-носител која се јавува како резултат на резонанцата. На слика 97 даден е фреквентниот спектар на енvelopата на сигналот по примена на методологијата за обработка на сигналите опишана во Поглавје 3. Во овој случај не може јасно да се забележи врвна

вредност во фреквентниот спектар на енvelopата. Ова се должи на тоа што снимањето на сигналот е извршено во почетна фаза на развој на дефектот во надворешниот прстен на тркалачкото лежиште при што импулсите се мали.



Слика 96. Фреквентен спектар по примена на FFT на оригиналниот сигнал – Сигнал 14



Слика 97. Фреквентен спектар на енvelopата– Сигнал 14

5.2.2 Резултати од валидација на дијагностичките модели со примена на база на податоци снимена во реални услови

Генерално, за целата база на податоци може да се заклучи дека по примената на методологијата за обработка на сигнали опишана во Поглавје 3, се добиваат фреквентни спектри кои соодветствуваат со теоретските основи за соодветните дефекти кај тркалачки лежишта, па оваа методологија за обработка е задоволителна во овој случај.

Потоа, од соодветно обработениот сигнал екстрахирани се истите карактеристики наведени во табела 8. Сите сигнали се снимени по вертикалната оска на едно лежиште па искористен е хибридниот комбиниран модел со снимени сигнали по радијална оска rad1. Валидацијата на креираниот двослоен модел е извршена на начин што се искористени екстрахирани статистички карактеристики од секој од 14те снимени сигнали како влез и испитана е точноста на класификаторот при нивно препознавање и класифицирање во соодветната класа. Резултатите од валидацијата се дадени во табела 29.

Табела 29. Резултати од валидација на хибриден комбиниран модел (rad1) за мултикласна и бинарна класификација со база на податоци снимена во реални услови

Назив на сигнал	Реална состојба при која е измерен сигналот	Предвидена доминантна состојба	Предвидена состојба (Дебаланс: Присутен/Не е присутен)	Резултат	V_{RMS} [mm/s]
Signal_01	дефект во надворешен прстен на надворешно лежиште и присутен дебаланс	дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race=0,394, overhang_ball_fault=0,206, horizontal-misalignment=0,124)	0,582092 Присутен дебаланс	Точен	1,411814
Signal_02		дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race=0,312, overhang_ball_fault=0,252 horizontal-misalignment=0,133)	0,592510 Присутен дебаланс	Точен	2,748654
Signal_03		дефект во надворешен прстен на надворешно лежиште (overhang_outer_race=0,419, overhang_ball_fault=0,188, horizontal-misalignment=0,129)	0,559833 Присутен дебаланс	Точен	3,335291
Signal_04		дефект во топче на надворешно лежиште (Top 3: overhang_ball_fault=0,331 overhang_outer_race=0,239, horizontal-misalignment=0,136)	0,505369 Присутен дебаланс	Погрешен	2,315809
Signal_05		нормална состојба	нормална состојба (Top 3: normal=0,529 imbalance=0,137)	0,318012	Точен

ПРИМЕНА НА АЛГОРИТМИ НА НАДГЛЕДУВАНО МАШИНСКО УЧЕЊЕ ЗА ПРОГНОСТИКА И УПРАВУВАЊЕ СО СОСТОЈБАТА НА РОТИРАЧКИ МАШИНИ

		3. horizontal-misalignment=0,131)	Не е присутен дебаланс		
Signal_06		нормална состојба (Top 3: normal=0,373, overhang_outer_race=0,204, imbalance=0,141)	0,573314 Не е присутен дебаланс	Погрешен	2,669570
Signal_07		дефект во топче на надворешно лежиште (Top 3: overhang_ball_fault=0,304, overhang_outer_race=0,249, underhang_ball_fault =0,168)	0,437783 Не е присутен дебаланс	Погрешен	1,876191
Signal_08		дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race=0,334, underhang_ball_fault=0,261, overhang_cage_fault=0,138)	0,546192 Присутен дебаланс	Точен	3,338313
Signal_09	дефект во надворешен прстен на надворешно лежиште и присутен дебаланс	дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race=0,335, overhang_ball_fault=0,239, imbalance=0,142)	0,532390 Присутен дебаланс	Точен	4,698269
Signal_10		дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race=0,444, horizontal-misalignment=0,143, overhang_ball_fault=0,131)	0,485327 Не е присутен дебаланс	Погрешен	4,598863
Signal_11		дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race=0,505, horizontal-misalignment=0,138, overhang_ball_fault=0,075)	0,556874 Присутен дебаланс	Точен	3,150121
Signal_12		дефект во топче на надворешно лежиште (Top 3: overhang_ball_fault=0,479, overhang_outer_race=0,172, vertical-misalignment=0,109)	0,570031 Присутен дебаланс	Погрешен	4,471823
Signal_13		дефект во надворешен прстен на надворешно лежиште (Top 3: overhang_outer_race=0,346, imbalance=0,213, overhang_ball_fault=0,158)	0,549014 Присутен дебаланс	Точен	4,706756

Signal_14	присутен локален дефект во надворешен прстен на надворешното тркалачко лежиште	дефект во топче на надворешно лежиште (Top 3: overhang_ball_fault=0,317, overhang_outer_race= 0,245, horizontal-misalignment=0,153)	0,470434 Не е присутен дебаланс	Погрешен	3,742404
-----------	--	---	------------------------------------	----------	----------

Програмскиот код во Python за валидација на дијагностичките модели со примена на база на податоци снимена во реални индустриски услови чии резултати се прикажани во табела 29, даден е во Прилог Г-2.

Од прикажаните резултати може да се констатира дека класификаторот точно класифицира 8 од 14 сигнали, односно точно ги класифицира влезните сигнали во 57,142 % од случаите. При валидацијата искористени се вибрациони сигнали измерени на едно лежиште и по една оска (радијална), при што влезниот вектор содржи 32 карактеристики. Класификаторот прави погрешна проценка кај сигналите 4, 6, 7, 10, 12 и 14. Кај Сигнал 6 може да се забележи релативно ниско ниво на изразеност на дефектот во надворешниот прстен, што најверојатно доведува до преклопување на карактеристиките со состојба без изразен дефект, поради што моделот го класифицира како нормална состојба. Во останатите случаи на погрешна класификација, моделот правилно идентификува дека станува збор за дефект во лежиште, но прави грешка во однос на типот на дефект (надворешен прстен или топче). Ова може да се објасни со сличноста во спектралните карактеристики и присуството на блиски или преклопени карактеристични фреквенции (BPFO и BSF), особено во услови на присутен дебаланс, што ја отежнува нивната јасна дистинкција.

Иако постигнатата точност од 57,142 % не претставува висока вредност во апсолутна смисла, истата може да се смета за прифатлива имајќи предвид условите под кои е извршено тестирањето. Имено, моделот е валидиран со примена на релативно мал број на влезни карактеристики (32), што е значително помалку во споредба со бројот на карактеристики користени во голем дел од релевантните истражувања во постоечката литература. Дополнително, анализата е базирана на мерење на вибрациони сигнали по една оска (радијална). Понатаму, тестирањето е извршено во реални услови на работа, на машински систем кој се разликува од системот употребен за тренинг, со поинаква механичка конфигурација, поинаква поставеност на мерниот систем и со неколку различни геометрии на лежишта и динамички услови. Овие фактори доведуваат до разлика во распределбата на податоците искористени за тренинг и за валидација (доменска варијација), со што значително се зголемува комплексноста на задачата за класификација.

Во таа смисла, способноста на моделот да препознае дефектни состојби и во услови на изразена структурна и динамичка варијабилност претставува важен индикатор за неговата генерализациска способност и робустност.

6. ПРОГНОСТИКА

Во ова поглавје детално е опишана искористената методологија за автоматизацијата на процесот на прогностика при имплементација на дисциплината прогностика и управување со состојбата како дел од системот за одржување на ротирачки машини. Поконкретно, извршено е предвидување на преостанатиот корисен век на машинските компоненти, користејќи измерени вибрациони сигнали од анализираниот машински систем. Целта е проценка на определена континуирана вредност која го претставува степенот на деградација или преостанатото време пред да се појави дефект.

Најпрво неопходно е обезбедување на соодветна база на податоци. За автоматизација на процесот на прогностика, базите на податоци треба да бидат снимени во определен временски период и да ја покажуваат постепената деградација на компонентите во текот на анализираниот период, обезбедувајќи доволно влезни податоци за моделот да научи како да го предвидува преостанатиот корисен век на компонентите врз основа на прогресијата на дефектите. Поради самата природа на овие бази на податоци, процесот на нивно креирање бара поголеми ресурси во споредба со базите кои се потребни за дијагностика (кои се снимаат откако ќе се појават одредени дефекти). Отворените бази на податоци кои се онлајн достапни содржат снимени вибрациони сигнали при деградација на тркалачки лежишта бидејќи го адресираат најчестиот проблем кој придонесува за намалување на достапноста, ефикасноста и квалитетот на машинските системи. И ова истражување се насочува кон прогностика на преостанат корисен работен век на тркалачки лежишта, како најкритични машински компоненти.

6.1 Избор на бази на податоци и опис на база на податоци – FEMTO

Искористената база на податоци е снимена од FEMTO-ST Institute [152] користејќи ја лабораториската експериментална платформа наречена PRONOSTIA која овозможува снимање на сигнали при забрзана деградација на тркалачко лежиште при константни или променливи работни услови. Притоа, снимени се 4 излези односно сигнали кои ја карактеризираат: ротационата брзина на вратилото, надворешното оптоварување (сила) кое симулира забрзана деградација на лежиштето, температурата и вибрациите кои се јавуваат. Симулираната забрзана деградација на нови, претходно неупотребени тркалачки лежишта се случува за неколку часа како резултат на дејствување на надворешна сила. PRONOSTIA платформата се состои од три потсистеми: ротирачки потсистем, потсистем кој предизвикува забрзана деградација на лежиштата и мерен потсистем и овозможува спроведување на тестови сè до целосна деградација на лежиштето. За да се спречи оштетување на опремата, тестовите се запрени во момент кога амплитудата на измерените вибрации достигнува интензитет од 20 g. Во табела 30 даден е начинот на организација на FEMTO базата на податоци.

Според табела 30, може да се воочи дека базата на податоци е снимена при три различни работни услови односно:

- аголна брзина на вратилото од 1800 врт/мин и интензитет на надворешна сила од 4000 N,
- аголна брзина на вратилото од 1650 врт/мин и интензитет на надворешна сила од 4200 N,
- аголна брзина на вратилото од 1500 врт/мин и интензитет на надворешна сила од 5000 N.

Табела 30. Начин на организација на FEMTO базата на податоци


	Работни услови I	Работни услови II	Работни услови III
Интензитет на надворешна сила [N]	4000	4200	5000
Аголна брзина на вратило [rpm]	1800	1650	1500
База за тренинг	2 датотеки: Bearing1_1 Bearing1_2	2 датотеки: Bearing2_1 Bearing2_2	2 датотеки: Bearing3_1 Bearing3_2
База за тестирање	5 датотеки: Bearing1_3 Bearing1_4 Bearing1_5 Bearing1_6 Bearing1_7	5 датотеки: Bearing2_3 Bearing2_4 Bearing2_5 Bearing2_6 Bearing2_7	1 датотека: Bearing3_3

Базата на податоци во состав на делот за тренинг е релативно мала меѓутоа се состои од широк дијапазон на временски интервали на работа на лежиштата пред да настане некаков дефект во нив, односно временските интервали се движат во интервал од 1 до 7 работни часа. Притоа, измерени се вибрациони сигнали по хоризонталната и по вертикалната оска со акцелерометар од типот DYTRAN 3035B. Вредноста на фреквенцијата на семплирање е избрана така што го опфаќа целиот фреквентен спектар на лежиштата низ сите фази на нивната деградација и изнесува 25,6 kHz. Дополнително, измерена е и развиената температура во лежиштата, меѓутоа тој тип на сигнали не се предмет на интерес во ова истражување. Во табела 31 дадено е објаснување на организацијата на секоја од датотеките во состав на FEMTO базата на податоци.


Табела 31. Начин на организација на датотеките во состав на FEMTO базата на податоци

Колони	I	II	III	IV	V	VI
Вибрациони сигнали	часови	минути	секунди	микросекунди	Амплитуда на вибрациони сигнали по хоризонтална оска	Амплитуда на вибрациони сигнали по вертикална оска


На слики 98-106 може да се видат снимените сигнали од базата на податоци во својата оригинална форма во временски домен, по хоризонтална (H) и по вертикална (V) оска. Според тоа може да се заклучи дека генерално, во почетокот на снимањето, амплитудата на измерените сигнали е релативно стабилна и ниска по интензитет. Како што деградацијата на лежиштата прогресира, некои од сигналите покажуваат значителен пораст во интензитетот на амплитудата. Исто така, може да се забележи дека значително се разликува времетраењето на сигналите и нивната природа кај сите 6 лежишта (по двете оски). Така на пример, кај сигналите Bearing1_1 (по двете оски), Bearing1_2 H (по хоризонтална оска), Bearing2_2 (по двете оски) и Bearing3_1 (по двете оски) може да се забележи ниска амплитуда на вибрациите сè до моментот во кој се појавува дефект на лежиштата, при што нагло се зголемува интензитетот на амплитудата. За разлика од овие сигнали, сигналот Bearing1_2 H (по хоризонтална оска) изобилува со нагли промени во амплитудата. Поради тоа очигледно е дека вибрациониот сигнал сам снимен во својот оригинален облик не е доволен за да се открие трендот на деградација, туку се неопходни дополнителни чекори на нивна подготовка и анализа.




Слика 98. Приказ на промена на амплитудата на сигналите (по двете оски) од базата за тренинг во текот на времето




Слика 99. Приказ на промена на амплитудата на сигналот Bearing1_1 (по двете оски) во текот на времето




Слика 100. Приказ на промена на амплитудата на сигналот Bearing1_2 (по двете оски) во текот на времето




Слика 101. Приказ на промена на амплитудата на сигналот Bearing1_5 (по двете оски) во текот на времето




Слика 102. Приказ на промена на амплитудата на сигналот Bearing1_7 (по двете оски) во текот на времето




Слика 103. Приказ на промена на амплитудата на сигналот Bearing2_1 (по двете оски) во текот на времето



Слика 104. Приказ на промена на амплитудата на сигналот Bearing2_2 (по двете оски) во текот на времето



Слика 105. Приказ на промена на амплитудата на сигналот Bearing3_1 (по двете оски) во текот на времето




Слика 106. Приказ на промена на амплитудата на сигналот Bearing3_2 (по двете оски) во текот на времето

6.2 Обработка на базата на податоци


Една од најважните фази што мора да се изведе пред примена на податоците во алгоритмите на машинско учење е нивната обработка со цел нагласување на оние карактеристики на сигналот кои се релевантни за откривање на дефекти. Како што беше и претходно изнесено, измерените вибрациони сигнали содржат и непосакувани шумови, кои најчесто се јавуваат на високи фреквенции. Во обработката на сигналите со цел дијагностика на дефекти во тркалачки лежишта беше искористена техниката анализа на енvelopa [122,115]. Како што беше и претходно објаснето, техниката анализа на енvelopa е специфичен тип на техника на демодулација кој користи Хилбертовата трансформација [120] и често се користи за препознавање на повторувачки импулси што се јавуваат како резултат на оштетувања на лежиштата. Сепак, примената на исклучиво оваа техника има свои ограничувања, особено кога преовладува шум во сигналите или кога оштетувањето е во почетна фаза и не покажува висока успешност при откривање на трендови во сигналот. Поради тоа, при обработка на сигналите искористена е комбинација на два методи за обработка, односно пред да се примени техниката анализа на енvelopa, применета е уште една често применувана техника за обработка на сигнали снимени во присуство на дефекти во лежишта, а тоа е вејвлет трансформацијата. Оваа техника овозможува отстранување на високите фреквенции од сигналот и пренесување на значајните карактеристики од сигналот во нискофреквентната зона со што значително го подобрува соодносот сигнал-шум. Меѓутоа, изборот на соодветната фреквентна зона за демодулација не е секогаш очигледен и во некои ситуации претставува особен предизвик [121,122]. Спаѓа во временско-фреквентните методи за обработка на сигнали и особено е погодна за проценка на преостанатиот работен век на машинските системи, бидејќи овозможува прецизно следење на постепени промени во

сигналот поврзани со влошување на состојбата. На тој начин значително ја зголемува ефикасноста на прогностичките модели базирани на вештачка интелигенција.


На слики 107-112 прикажана е споредба на оригиналниот сигнал и сигналот по примена на вејвлет трансформацијата. Со цел појасно согледување на резултатите од примената на овој метод на обработка на сигналите, прикажана е и вредноста на статистичкиот параметар куртоза пред примена на вејвлет трансформацијата и по неговата примена. Куртозата како параметар е особено чувствителен на присуство на импулсни компоненти, односно пикови во сигналот. Во контекст на вибрациона дијагностика, може да се заклучи дека по примената на вејвлет трансформацијата се постигнало истакнување на импулсивните елементи, односно се потенцирале компонентите на сигналите кои се значајни во препознавање на дефектите. Според тоа може да се заклучи дека искористената техника за обработка на сигналите значително го намалува шумот во сигналите при истовремено нагласување на значајните информации потребни за понатамошна анализа на состојба на машинските системи.




Слика 107. Сигнал Bearing1_1 во текот на времето пред и по примена на вејвлет трансформацијата




Слика 108. Сигнал Bearing1_2 во текот на времето пред и по примена на вејвлет трансформацијата




Слика 109. Сигнал Bearing2_1 во текот на времето пред и по примена на вејвлет трансформацијата



Слика 110. Сигнал Bearing2_2 во текот на времето пред и по примена на вејвлет трансформацијата



Слика 111. Сигнал Bearing3_1 во текот на времето пред и по примена на вејвлет трансформацијата



Слика 112. Сигнал Bearing3_2 во текот на времето пред и по примена на вејвлет трансформацијата

Следно, применета е анализа на енvelopa со цел воочување на пикови во фреквентниот спектар на карактеристичните фреквенции при присуство на најчесто појавуваните дефекти во лежиштата: дефект на внатрешен прстен - BPFI (Ball Pass Frequency Inner), дефект на надворешен прстен - BPFO (Ball Pass Frequency Outer), дефект на тркалочки елемент - BSF (Ball Spin Frequency), дефект на кафез - FTF (Fundamental Train Frequency).

Во табела 32 дадени се параметрите на лежиштата со помош на кои се пресметани вредностите на карактеристичните фреквенции при присутни дефекти во лежиштата искористени при снимање на FEMTO базата на податоци, а во табела 33 вредностите на карактеристичните фреквенции при присутни дефекти во лежишта.

Табела 32. Параметри на тркалочки лежишта искористени при снимање на FEMTO базата на податоци

Спецификации на лежишта	
Број на топчиња	13
Дијаметар на топчиња D_B	3,5 мм
Дијаметар на кафез D_C	29,1 мм
Pitch Diameter ($D_P = D_C - D_B$)	25,6 мм
Контактен агол φ	0°


Табела 33. Вредности на карактеристични фреквенции при присутни дефекти во лежишта за FEMTO базата на податоци

Работни услови	Аголна брзина на вратило [rpm]	BPFO [Hz]	BPFI [Hz]	BSF [Hz]	FTF [Hz]
I	1800	168,3	221,7	107,7	12,9
II	1650	154,3	203,2	98,7	11,9
III	1500	140,3	184,7	89,7	10,8


Мора да се потенцира дека за разлика од претходните бази на податоци кои се состоеја од сигнали снимени во присуство на само еден дефект, во FEMTO базата на податоци сигналите се снимени во поголем временски интервал, од вклучување во работа на новите лежишта сè до нивна деградација (или во овој случај до појава на амплитуди на вибрации поголеми од 20 g). Тоа значи дека во текот на работата на лежиштата може да дојде до појава на повеќе различни типови на дефекти во лежиштата истовремено. Затоа, не може да се пристапи кон дијагностика користејќи ја претходно предложената методологија. Во овој дел целта е определување на

преостанатиот работен век на машинските системи, поконкретно тркалачките лежишта. Поради тоа, во овој дел не е важно при која карактеристична фреквенција се појавува пик, туку дека има пик во амплитудата барем на една од нив што укажува дека почнува појавата на некој дефект во лежиштата, односно почнува фазата на нивна деградација или истрошување.

На слики 113 и 114 дадена е промената на параметарот куртоза во текот на времето при снимање на сигналот Bearing1_1 со цел определување на временските единици при кои се јавуваат различните фази на работа на лежиштата: фаза на загревање (0-950 временски единици), фаза на корисна работа (1000-3300 временски единици) и фаза на истрошување (над 3300 временски единици). Понатаму, овие временски единици се искористени за генерирање на фреквентниот спектар на енвелопата на сигналот при различните фази на работа на лежиштата. Може да се забележи дека во текот на фазата на загревање и фазата на корисна работа нема високи амплитуди, додека при фазата на истрошување се забележуваат пикови при карактеристичните фреквенции и при нивните хармоници.



Слика 113. Промена на вредноста параметарот куртоза во текот на времето при снимање на сигналот Bearing1_1



Слика 114. ЕнVELOпа на фреквентен спектар на сигналот Bearing1_1, во текот на трите различни фази на работа на лежиштето

Претходно опишаната методологија за обработка на сигналите која комбинира техника на трансформација на бранови облици и анализа на енVELOпа е искористена за обработка на сите

сигнали во состав на FEMTO базата на податоци и како такви понатаму се искористени за екстракција на значајни карактеристики. Во Прилог Д-1 даден е кодот за обработка на сигналите.

6.3 Екстракција на карактеристики

Извршена е екстракција на неколку групи карактеристики кои припаѓаат на различни домени, и тоа по двете оски, табела 34:

- статистички параметри во временски домен
- статистички параметри во фреквентен домен
- статистички параметри во временско-фреквентен домен
- индекс на состојба на машински системи.

Табела 34. Екстрахирани карактеристики од FEMTO база на податоци

Тип	Карактеристика	Број
Статистички параметри во временски домен	Средна квадратна вредност на амплитудата (RMS) Стандардна девијација (Std) Куртоза (Kurtosis) Фактор на искривување (Skewness) Врвна вредност на амплитудата (Peak Value) Крест Фактор (Crest) Импулсен Фактор (Impulse) Фактор на Маргина (Margin) Фактор на Форма (Shape) Ентропија (Entropy)	10 карактеристики x 2 оски 20
Статистички параметри во фреквентен домен	Средна квадратна вредност на фреквентниот спектар (RMSF) Фреквентен центар (FC) Средно квадратна варијанса на фреквентниот спектар (RVF)	3 карактеристики x 6 групи x 2 оски 36
Статистички параметри во временско-фреквентен домен	Средна вредност на енергија во спектрограм (SPEC) Средна вредност на енергија во вејвлет дијаграм (Wavelet_E)	1 карактеристика x 10 групи x 2 оски 20 1 карактеристика x 4 вејвлет компоненти x 2 оски 8
Индекс на состојба на машински системи		1 карактеристика x 2 оски 2
Вкупно		86

Како што беше и претходно нагласено, десет статистички параметри во временски и три статистички параметри во фреквентен домен имаат суштинско значење во полето на дијагностика и прогностика кај ротирачки машини. Затоа и тука се екстрахирани десетте најзначајни статистички параметри во временски домен и тоа [149]: средна квадратна вредност на амплитудата (RMS), стандардна девијација (std), куртоза (kurtosis), фактор на искривување (skewness), врвна вредност на амплитудата (peak value), крест фактор (crest), импулсен фактор (impulse), фактор на маргина (margin), фактор на форма (shape), ентропија (entropy) и трите најзначајни статистички параметри и тоа: средна квадратна вредност на фреквентниот спектар (средна квадратна вредност на фреквентниот спектар - RMSF), фреквентен центар (фреквентен центар - FC), средно квадратна варијанса на фреквентниот спектар (средно квадратна варијанса

на фреквентниот спектар - RVF). При прогностика, статистичките параметри во временски домен ќе се пресметаат од снимениот сигнал во временски домен, а статистичките параметри во фреквентен домен од трансформираниот сигнал во фреквентен домен [152].


Во делот на дијагностика неопходен е целиот опсег на фреквенции затоа што значајно е воочување и на хармониците на карактеристичните фреквенции на дефектите со цел прецизна дијагностика и идентификација на присутниот дефект. При прогностика на дефекти на тркалачки лежишта може да се анализира само одреден значаен опсег на фреквенции во кој се очекува појава на пресметаните карактеристични фреквенции на лежиштата, но не и нивните хармоници, затоа што целта не е прецизна идентификација на типот на дефект во лежиштето, туку само дека одреден дефект се појавува [121,122]. Доколку се екстрахираат карактеристики во рамки на целиот фреквентен спектар, би се добиле голем број на статистички параметри при што најголем дел од нив не би имале големо значење при прогностика на идни дефекти во лежишта. Значаен опсег на фреквенции за прогностика на дефектите согласно типот на тркалачки лежишта кои се искористени при снимање на FEMTO базата на податоци и бројот на вртежи на роторот (од 600 до 3600 rpm) е од 0 до 300 Hz. При повисоки фреквенции обично доминира шум во енвелопата на фреквентниот спектар.

Со цел детално отсликување на распределбата на енергија на сигналот при различни фреквенции, применета е методологија со која анализираниот фреквентен опсег од интерес се дели на помали групи (фреквентни интервали). На тој начин се задржува информацијата за тоа во кои делови од спектарот се јавуваат значајни промени или пораст на амплитудата, што е корисно за препознавање на појава и развој на дефекти. Овој пристап овозможува моделирање на деградацијата со поголема прецизност, бидејќи ја задржува локалната фреквентна чувствителност која би се изгубила со анализа на целиот опсег како една целина [121]. Затоа, при екстракција на карактеристики од фреквентниот спектар, опсегот од 0 до 300 Hz се дели на 6 еднакви групи и за секоја засебна група се екстрахирани претходно споменатите три статистички параметри во фреквентен домен.

FEMTO базата на податоци се состои од измерени сигнали по две оски, односно снимени се по два сигнали при секое мерење. Според претходно објаснетото, ќе се екстрахираат вкупно 20 карактеристики во временски и 36 карактеристики во фреквентен домен.

Временско-фреквентниот домен ја прикажува промената на содржаната енергија на фреквентниот спектар во текот на времето. Како алатка за приказ на промените се користат спектрограми кои всушност претставуваат матрици чии колони ја претставуваат димензијата време, а редовите димензијата фреквенција. Користејќи ја аналогијата од претходно објаснетиот метод со цел отсликување на распределбата на енергија на сигналот во различни временски интервали, целиот временски интервал ќе се подели на вкупно 10 групи од кои ќе се екстрахира средна вредност на содржана енергија на сигналот (RMS). Согласно ова, ќе се екстрахираат вкупно 20 карактеристики од спектрограмот. Во спектрограмите на слика 115 е прикажана промената на енергетската содржина на сигналот Bearing1_1 во различни временски моменти и при различни фреквенции. На слика 115 лево е прикажан спектрограмот во почетен момент на снимање на сигналот (припаѓа на почетната фаза на загревање на лежиштето) енергијата е распределена и присутна во различни фреквентни опсези со поумерени амплитуди, односно лежиштето не покажува сериозни знаци на дефект. На слика 115 десно е прикажан спектрограм после поминати 3500 временски единици (во фаза на истрошување) покажува појасна концентрација на енергија во одредени фреквентни опсези, особено при повисоки фреквенции. Оваа зголемена и концентрирана енергетска содржина се должи на присуството на карактеристични фреквенции на дефекти, односно претставува јасен индикатор дека започнала фазата на истрошување на лежиштето. Ваквата визуелна анализа со примена на спектрограм

овозможува детекција на промени во енергијата на вибрациите кои се јавуваат со текот на времето и е особено корисна за рана прогностика на дефекти кај ротирачки машини.



Слика 115. Спектрограм при временска единица 0 и при временска единица 3500

*у-оската (фреквентната оска) е поделена на 66 групи и на спектрограмот се дадени средните вредности за енергијата содржана во секоја од тие групи од фреквентниот спектар

Последниот тип на карактеристики се екстрахирани по примена на методот Вејвлет декомпозиција (Wavelet Decomposition) на сигналите. Овој метод овозможува анализа на сигналот и во временски и во фреквентен домен и е особено применлив при детекција на нагли промени во сигналот кои се јавуваат во кратки временски интервали. Притоа, сигналот се разложува на неколку компоненти кои ја опишуваат содржаната енергија на сигналот на различни фреквентни нивоа. Во овој случај, сигналот е разделен на две длабочини, што значи дека се добиваат 4 компоненти кои ја претставуваат енергијата на сигналот во различни фреквентни опсези. За секоја од овие компоненти се пресметува вкупната енергија, со што се добиваат 4 нумерички вредности што всушност претставуваат и екстрахирани карактеристики. Овие вредности даваат информација за тоа колку е интензитетот на сигналот во секој од фреквентните опсези.

Последна екстрахирана карактеристика е Индексот на состојба на машинските системи (Health Index HI) кој претставува нумеричка вредност која се користи за следење на деградацијата на даден систем во текот на времето. Овој параметар е клучен за предвидување на преостанатиот работен век (RUL). Главната цел е да се трансформираат измерените вибрациони сигнали во нумерички вредности кои ја претставуваат моменталната состојба на компонентата, при што се очекува тренд сличен на теоретските криви на животен век на машинските системи, односно стабилен во почетната фаза, а потоа постепено се влошува и прогресира кон деградација. HI најчесто се пресметува преку споредба на вредностите на значајните параметри при моменталната состојба на машината со нивната вредност при почетната нормална состојба на машината. Меѓутоа, фазата на загревање на машинските системи често не се карактеризира со најниски амплитуди на вибрациите, па затоа е препорачливо почетната нормална состојба да се дефинира по оваа фаза.

Програмскиот код во Python за екстракција на карактеристики за модел за прогностика согласно табела 34 даден е во Прилог Д-2.

6.4 Примена на алгоритми на надгледувано машинско учење и хиперпараметарска оптимизација

Во рамки на ова истражување применети се алгоритми на машинско учење со цел предвидување на преостанатиот работен век (RUL) на лежиштата, врз основа на претходно екстрахираните карактеристики од обработените вибрациони сигнали. Алгоритми на надгледувано машинско учење кои покажале највисока точност при прогностика на состојбата на системите се алгоритмот на случајни шуми [153-155] и алгоритмот на машини со поддржувачки вектори [156-158] кои ќе бидат применети и во ова истражување. За разлика од задачата која е предмет на интерес при дијагностика на дефекти (класификација на податоците по класи на присутни дефекти), при решавање на задачи во областа на прогностика алгоритмите имаат за цел да предвидат континуирани вредности односно трендови и на тој начин да го определат преостанатиот работен век на лежиштата.

Важно е да се потенцира дека за тренинг на алгоритмите е искористен делот од базата на податоци за тренинг, додека за тестирање и валидација на алгоритмите е искористен сосема друг дел од базата на податоци кој е претходно непознат за алгоритмите и спаѓа во делот за тестирање на базата на податоци.

Главен предизвик при предвидување на преостанатиот работен век на лежишта е високата варијабилност на преостанатиот работен век на различни лежишта кои може да пројават дефект во потполно различни моменти иако работеле при идентични работни услови. Два вибрациони сигнали кои се навидум слични во даден момент (и во однос на присутни хармоници и во однос на вредности на амплитуда) може да бидат измерени на лежишта кои имаат сосема различен преостанат работен век доколку нивниот вкупен работен век се разликува. Тоа може да биде збунувачко за моделот бидејќи тоа значи дека моделот треба да предвиди вредност за преостанатиот работен век на лежиштето кој притоа можеби и не е директно поврзан со вредностите на екстрахираните карактеристики. За да се избегне грешка која е поврзана со различниот вкупен работен век на различните лежишта, применет е пристапот на нормализација на преостанатиот работен век или се пресметува релативен RUL.

Притоа, при примена на делот од FEMTO базата на податоци кој служи за тренинг на алгоритмите се претпоставува дека работниот век на лежиштата завршува при последната временска единица на снимање на сигналите (односно при достигнување на 20g). Затоа, при тренинг, релативниот преостанат работен век се изразува користејќи го следниот израз:

$$RUL_{\text{релативно}} = \frac{l - t}{l} \quad (6.1)$$

l – број на временски единици на целосниот работен век на лежиштето (од почеток на работа до појава на дефект или во случајот на тренинг број на временски единици при кои се снимал вибрациониот сигнал)

t – разгледувана (моментална) временска единица.

Во табела 35 дадени се вкупните временски интервали на снимање на сигналите во состав на базата на податоци за тренинг.

Табела 35. Вкупни временски интервали на снимање на сигналите во состав на FEMTO базата на податоци – дел за тренинг

Сигнал	Временски интервал на снимање на сигналот
Bearing1_1	7 h 47min 00s
Bearing1_2	2h 25min 00s
Bearing2_1	2h 31min 40s
Bearing2_2	2h 12min 40s
Bearing3_1	1h 25min 40s
Bearing3_2	4h 32min 40s

Од друга страна, снимените сигнали од делот од базата на податоци кој служи за тестирање на алгоритмите не се снимени до појава на дефект во лежиштата, туку снимањето е прекинато во определен момент. Со други зборови, при снимањето на сите сигнали во состав на базата на податоци за тестирање не се појавува дефект на лежиште. Со цел проверка на добиените резултати при тестирање на моделот во состав на самата база на податоци е дадена табела со преостанат работен век на секое лежиште, односно бројот на секунди од снимањето на последната временска единица во состав на сигналот до моментот во кој се појавува дефект на лежиштето. Затоа, при тестирање, релативниот преостанат работен век се пресметува користејќи го следниот израз:

$$RUL_{\text{релативно}} = \frac{RUL}{RUL + l_t} \quad (6.2)$$

RUL – вистински преостанат работен век (податоци од табела)

l_t – број на временски единици на снимање на сигналот (податоци од табела).

Во табела 36 се дадени вкупните временски интервали на снимање на сигналите во состав на базата на податоци за тестирање, а во табела 37 се дадени реалните временски интервали за преостанатиот работен век на секое лежиште.

Табела 36. Вкупни временски интервали на снимање на сигналите во состав на FEMTO базата на податоци – дел за тестирање

Сигнал	Временски интервал на снимање на сигналот
Bearing1_3	5 h 00min 10s
Bearing1_4	3h 09min 40s
Bearing1_5	6h 23min 30s
Bearing1_6	6h 23min 29s
Bearing1_7	4h 10min 11s
Bearing2_3	3h 20min 10s
Bearing2_4	1h 41min 50s
Bearing2_5	5h 33min 30s
Bearing2_6	1h 35min 10s
Bearing2_7	0h 28min 30s
Bearing3_3	0h 58min 30s

Табела 37. Реални временски интервали за преостанатиот работен век на секое лежиште во состав на FEMTO базата на податоци – дел за тестирање

Сигнал	Преостанат работен век (Реален)
Bearing1_3	5730 s
Bearing1_4	339 s
Bearing1_5	1610 s
Bearing1_6	1460 s
Bearing1_7	7570 s
Bearing2_3	7530 s
Bearing2_4	1390 s
Bearing2_5	3090 s
Bearing2_6	1290 s
Bearing2_7	580 s
Bearing3_3	820 s

Овој пристап овозможува унифицирано моделирање кое не зависи од бројот на временски единици при кои е снимен секој сигнал, со што се подобрува робустноста на системот за прогностика и овозможува споредливост на резултатите за различни лежишта.

Дополнително, точноста на овие модели и нивната способност за генерализација значително зависат и од процесот на хиперпараметарска оптимизација односно од соодветниот избор на вредности на хиперпараметрите на соодветните алгоритми. Како параметар за евалуација на перформансите на моделите после хиперпараметарската оптимизација е искористен параметарот средна апсолутна грешка (Mean Absolute Error MAE). MAE ја претставува средната вредност на апсолутните разлики помеѓу вистинските вредности за преостанатиот работен век и предвидените вредности за преостанатиот работен век:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6.3)$$

y_i - вистинска вредност за преостанатиот работен век

\hat{y}_i - предвидена вредност за преостанатиот работен век


n - број на единици (временски единици x број на анализирани лежишта).

Пониска вредност на MAE означува повисока точност на алгоритмот. Овој параметар е едноставен за интерпретација и се карактеризира со робустност при екстремни вредности, со што претставува соодветен параметар за евалуација при решавање на регресиони задачи за предвидување на преостанат работен век.

За хиперпараметарска оптимизација на алгоритмот за регресија со вектор на поддршка (Support Vector Regression - SVR) искористени се три хиперпараметри и тоа Кернел функцијата, регулациониот параметар C и дозволената грешка епсилон ϵ . Значењето на Кернел функцијата и регулациониот параметар C детално беше објаснето во поглавје 4.2.1. За разлика од стандардните регресиони модели кои вршат класично минимизирање на сите грешки, при примена на алгоритмот за регресија со вектор на поддршка се дефинира дозволена грешка епсилон ϵ . Алгоритмот се обидува да пронајде функција која ќе предвидува континуирани вредности доволно блиску до вистинската вредност и доколку грешката е во рамки на ϵ , тогаш алгоритмот ја смета таа грешка за незначајна. Податоците кои се надвор од ϵ се нарекуваат поддржувачки вектори. Поддржувачките вектори се значајни при оптимизација и тие директно го дефинираат

моделот, односно позицијата и обликот на Кернел функцијата. На овој начин се добива модел со висока робустност и во случаи на присуство на шум во податоците и овозможува подобра генерализација, бидејќи мали отстапувања не влијаат врз точноста на регресијата, што е особено чест случај при прогностика на работен век на компоненти во реални услови.

На слика 116 дадени се резултатите од хиперпараметарската оптимизација на алгоритмот за регресија со вектор на поддршка. Со цел моделирање на нелинеарни односи помеѓу екстрахираните карактеристики и преостанатиот работен век (RUL) во ова истражување како Кернел функции се применети радијалната базна функција (RBF) и полиномната Кернел функција (poly). Согласно добиените резултати, вредноста на MAE при примена на полиномната Кернел функција (poly) е значително повисока во однос на добиената вредност на MAE при примена на радијалната базна функција (RBF), што значи дека во овој случај радијалната базна функција (RBF) е усвоена како Кернел функција за алгоритмот. За регулациониот параметар C, кој претставува баланс помеѓу точноста и сложеноста на моделот, тестирани се вредностите 10 и 100. Повисоки вредности на C дозволуваат помалку грешки, додека пониските вредности толерираат повеќе отстапувања со цел намалување на веројатноста од појава на преклопување. Хиперпараметарот ϵ е клучен при регресија бидејќи дефинира толеранција при која грешката е незначајна. Тестирани се ϵ вредности од 0,1, 0,001 и 0,00001. Најдобри резултати се добиени со RBF Кернел функцијата, C=100 и $\epsilon=0,00001$, при што средната вредност на MAE изнесува 0,14427, и претставува најниска вредност меѓу сите тестирани комбинации.

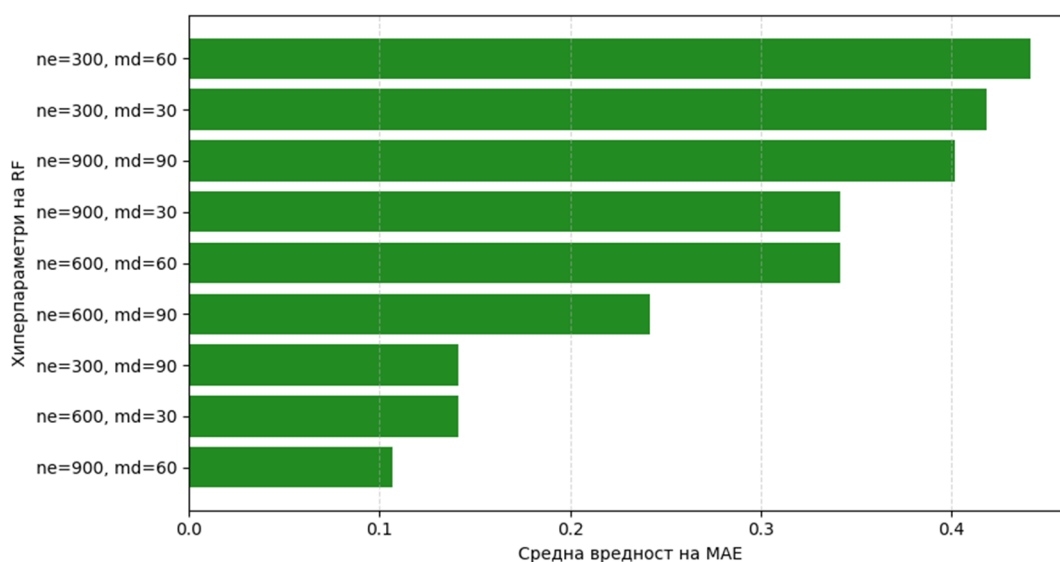


Слика 116. Резултати од хиперпараметарска оптимизација на алгоритмот за регресија со вектор на поддршка - вредности на MAE при различни комбинации на вредности на хиперпараметрите

За оптимизација на алгоритмот за регресија - случајни шуми искористени се два клучни хиперпараметри: бројот на естиматори (ne) односно бројот на дрва во шумата и максималната длабочина на дрвата (md). Резултатите се прикажани на слика 117 и покажуваат дека најдобри перформанси се постигнати при примена на 900 естиматори и максимална длабочина на дрвата 60, при што е добиена најниска средна вредност за MAE од 0,10678. Според тоа може да се заклучи дека со зголемување на бројот на дрва и оптимално ограничување на длабочината може значително да се подобри точноста на моделот. За другите хиперпараметри како минимален број на примероци по лист и максимален број на карактеристики, е задржана стандардната вредност (`min_samples_leaf=1`, `max_features='sqrt'`) предложена од библиотеката Scikit-learn, бидејќи нивното менување не доведе до значајни подобрувања во точноста.

Кодот за тренинг и хиперпараметарска оптимизација на моделите е даден во Прилог Д-3.

Во следното поглавје се искористени добиените вредности за хиперпараметрите за алгоритмот за регресија со вектор на поддршка и алгоритмот за регресија - случајни шуми.



Слика 117. Резултати од хиперпараметарска оптимизација на алгоритмот за регресија - случајни шуми - вредности на MAE при различни комбинации на вредности на хиперпараметрите

6.5 Преглед на резултати од тестирањето на моделот за прогностика

Во овој дел ќе бидат прикажани добиените резултати од примената на двата алгоритми на надгледувано машинско учење по нивната хиперпараметарска оптимизација. Притоа, за евалуација на резултатите користени се неколку параметри:

- Средна апсолутна грешка (Mean Absolute Error MAE) кој претходно беше детално дефиниран,
- Средна квадратна грешка - Root Mean Squared Error (RMSE) е параметар која ја евалуира просечната големина на грешките, односно разликата помеѓу вистинските вредности и предвидените вредности. Се пресметува како квадратен корен од просекот на квадратите на грешките. Колку е пониска вредноста на RMSE, толку е повисока точноста на моделот.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6.4)$$

y_i - вистинска вредност за преостанатиот работен век

\hat{y}_i - предвидена вредност за преостанатиот работен век

n - број на единици (временски единици x број на анализирани лежишта).

- Коefициент на детерминација R^2 покажува колкав дел од варијацијата на зависната променлива (во овој случај RUL) може да се објасни преку независните променливи (во овој случај векторот на екстрахирани карактеристики) во моделот. Вредноста на R^2 е во интервал од 0 до 1, со тоа што вредности на R^2 поблиски до 1 укажуваат на модел со подобри перформанси.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (6.5)$$

y_i - вистинска вредност за преостанатиот работен век

\hat{y}_i - предвидена вредност за преостанатиот работен век

\bar{y} - средна вредност за преостанатиот работен век

n - број на единици (временски единици \times број на анализирани лежишта).

Во табела 38 се дадени добиените вредности на параметрите за евалуација на перформансите на двата алгоритми на надгледувано машинско учење по хиперпараметарската оптимизација.

Табела 38. Вредности на параметрите за евалуација на перформансите на двата алгоритми на надгледувано машинско учење по хиперпараметарската оптимизација

Сигнал	SVR			RF		
	MAE	RMSE	R ²	MAE	RMSE	R ²
Bearing1_3	0,05446	2,77594	0,97832	0,04912	0,96909	0,99889
Bearing1_4	0,11950	3,43953	0,95943	0,09238	1,79517	0,99614
Bearing1_5	0,20432	6,74563	0,92564	0,16329	3,56309	0,98528
Bearing1_6	0,23553	7,11054	0,91485	0,17346	3,68734	0,98378
Bearing1_7	0,11482	3,11723	0,96832	0,07128	1,81703	0,99616
Bearing2_3	0,03111	1,36297	0,99025	0,03821	0,80380	0,99925
Bearing2_4	0,26388	7,52814	0,90148	0,19674	4,47738	0,97593
Bearing2_5	0,09977	3,18728	0,97635	0,07092	1,75310	0,99642
Bearing2_6	0,25084	6,86321	0,91357	0,18456	4,05000	0,98031
Bearing2_7	0,05622	1,98733	0,98614	0,04297	1,00376	0,99882
Bearing3_3	0,15656	4,28102	0,96018	0,09164	2,41181	0,99324

Според прикажаните резултати, алгоритмот на случајни шуми покажува подобри перформанси при предвидување на преостанатиот работен век (RUL) на лежиштата. Притоа се добиваат ниски вредности за MAE и RMSE што укажува на висока точност за предвидување, а високи вредности за коефициентот на детерминација R² за повеќето лежишта, што значи дека моделот задоволително ја прикажува варијацијата на податоците. На пример, за сигналот Bearing1_3 добиените се следните вредности:

- MAE = 0,04912, RMSE = 0,96909, R² = 0,9988

Вака добиените вредности на параметрите за евалуација покажуваат дека моделот многу прецизно ја предвидува вистинската RUL вредност и објаснува повеќе од 99% од варијацијата во податоците.

Согласно резултатите од табела 38, може да се заклучи дека алгоритмот на машини со поддржувачки вектори применет за регресија покажа послаби перформанси при предвидување на преостанатиот работен век (RUL) на лежиштата, споредено со алгоритмот на случајни шуми. Иако алгоритмот за регресија со вектор на поддршка за некои сигнали покажува високи вредности за коефициентот на детерминација (R²), вредностите за средна апсолутна грешка (MAE) и средна квадратна грешка (RMSE) се значително повисоки во споредба со оние добиени при примена на алгоритмот за регресија - случајни шуми. Може да се заклучи дека алгоритмот за регресија со вектор на поддршка не е доволно прецизен во следење на реалната деградација на лежиштата додека алгоритмот за регресија - случајни шуми покажува подобра робустност и стабилност, дури и при примена на помал број на влезни карактеристики. Кодот за валидација на моделот за прогностика е даден во Прилог Д-4. Во Прилог Г дадени се реалните криви на преостанатиот корисен работен век (RUL) и предвидените криви при примена на моделот кој покажа подобри перформанси согласно добиените резултати за сите сигнали од делот на базата на податоци за тестирање. Со зелена боја е прикажана реалната крива зададена во состав на FEMTO, додека со сина боја е прикажана предвидената крива на RUL со примена на моделот базиран на алгоритмот за регресија - случајни шуми, по неговата хипероптимизација. За сите слики важи дека една временска единица по x-оска означува 10 секунди од снимениот сигнал или предвидениот работен век.

7. ЗАКЛУЧОЦИ И ПРЕПОРАКИ ЗА ИДНА РАБОТА

Во рамки на оваа докторска дисертација беше спроведено систематско и структурирано истражување во областа на прогностиката и управувањето со состојбата на ротирачки машини, со фокус на развој на методологија за автоматизирана дијагностика на присутни дефекти и предвидување на преостанатиот корисен век на машинските компоненти. Истражувањето беше мотивирано од потребата за зголемување на сигурноста, намалување на трошоците за одржување и спречување на ненадејни дефекти во индустриските системи. Примената на анализа на вибрациони сигнали во комбинација со алгоритми на надгледувано машинско учење овозможи развој на конзистентен пристап кој ги поврзува обработката на сигналите, екстракцијата и селекцијата на релевантни карактеристики, како и изборот и оптимизацијата на модели за решавање на задачи од дијагностика и прогностика. Во текот на истражувањето беа анализирани различни пристапи, беа споредени повеќе алгоритми и беа испитани нивните перформанси во контролирани и во реални услови, со цел да се оцени точноста, робустноста и практичната применливост на предложената методологија.

Врз основа на резултатите добиени во претходните поглавја може да се изврши синтеза на главните научни сознанија кои произлегуваат од спроведеното истражување. Во ова поглавје се сумираат најзначајните резултати од истражувањето и се анализира нивната поврзаност со поставените научни хипотези. На тој начин се овозможува систематска евалуација на степенот на нивна потврда, како и оценка на научниот придонес на предложената методологија.

Поглавјето е организирано на следниот начин: најпрво се презентираат главните заклучоци кои произлегуваат од спроведеното истражување, по што се разгледува степенот на потврда на поставените хипотези. Во продолжение се дадени препораки за идни истражувања и можни насоки за понатамошен развој и практична примена на предложената методологија.

7.1 Главни заклучоци од истражувањето

Главните резултати од истражувањето можат да се сумираат преку неколку клучни заклучоци.

Резултатите од дијагностичкиот дел од истражувањето покажаа дека изборот на карактеристики и тип на алгоритам имаат суштинско влијание врз точноста на моделите. Примената на хибриден сет од карактеристики, составен од статистички параметри во временски и фреквентен домен, спектрални индикатори, како и карактеристики засновани на физиката на машинските системи, резултира со значително подобрување на перформансите во однос на моделите тренирани исклучиво со сет од податочно-базирани карактеристики. Ова ја потврдува оправданоста на комбинирањето на статистички и физички-информирани индикатори и укажува дека внимателната селекција на карактеристики претставува клучен фактор во развојот на робустни дијагностички модели.

Во рамки на предложената методологија беа дефинирани 32 карактеристики по мерна оска, односно вкупно 192 карактеристики при користење на сите шест мерни оски. Со користење на овој проширен хибриден сет беше развиен комбиниран модел базиран на алгоритми на

надгледувано машинско учење. Дополнително беше имплементирана двослојна дијагностичка стратегија, при што во првиот слој се врши идентификација на доминантниот дефект, а во вториот слој се анализира присуството на дебаланс како дополнителна состојба која може да коегзистира со други дефекти. Ова претставува практично значајна надградба, бидејќи во реални индустриски услови често се јавува истовремено присуство на повеќе извори на вибрации.

При тестирање на предложената методологија со користење на претходно балансираната MaFaulDa база на податоци и примена на методот на крос-валидација со 10 преклопувања, хибридниот комбиниран модел со примена на сите шест мерни оски постигна точност од 98,308%, што ја потврдува неговата способност за прецизна автоматизирана дијагностика на дефекти кај ротирачките машини. Споредбата со постоечките истражувања покажува дека во литературата најчесто се разгледуваат задачи со помал број класи, при што се постигнува точност во опсег од 94 % до 100 % за три или шест класи. Во ова истражување е постигната точност од $98,308 \pm 0,236$ % при класификација во десет класи, што укажува дека предложениот модел успешно се справува со покомплексна класификациска задача, базирана на поширока и физички поинформативна репрезентација на сигналите. Значајно е да се нагласи дека разгледуваните класи на дефекти се од различна физичка природа и се карактеризираат со различна фреквентна распределба на енергијата во вибрационите сигнали. Одредени состојби, како што се дебалансот и нецентричноста, се манифестираат претежно преку нискофреквентни компоненти поврзани со ротационата фреквенција и нејзините хармоници. Наспроти тоа, дефектите во тркалачките лежишта се карактеризираат со појава на високофреквентни вибрациони компоненти поврзани со карактеристичните фреквенции на дефектите и нивните хармоници.

Поради оваа разлика во спектралната природа на сигналите, во рамки на дисертацијата беше развиена методологија за обработка на вибрационите сигнали која овозможува издвојување на значајните дијагностички информации од различни фреквентни опсези. Со примена на карактеристики во временски и фреквентен домен, како и на карактеристики засновани на физиката на системот, беше формиран информативен хибриден сет погоден за тренинг на алгоритмите на машинско учење.

Беше извршена и анализа на компјутерската ефикасност на предложената методологија. Резултатите покажаа дека компјутерското време потребно за екстракција на карактеристиките и извршување на класификацијата е помало од времетраењето на анализираниот сигнален прозорец. Ова значи дека обработката на податоците може да се извршува побрзо од времето потребно за аквизиција на нов сигнален сегмент, што претставува основен предуслов за примена на предложениот пристап во системи за мониторинг на состојбата во реално време. Имајќи предвид дека процесите на појава и развој на дефекти кај ротирачките машини се одвиваат постепено, а не во многу кратки временски интервали, вкупното време на обработка може да се смета за сосема доволно за практична примена во системи за вибрациски надзор во реално време.

Валидацијата на дијагностичките модели во лабораториски услови потврди стабилност и конзистентност на перформансите, додека примената во реални услови покажа дека моделите во најголем дел ги задржуваат своите дијагностички способности, иако се јавуваат поединечни отстапувања. Овој резултат укажува дека методологијата е применлива и надвор од иницијалната тренинг средина, но истовремено укажува и на потреба од дополнително подобрување на робушноста при варијации на работните услови и шум во сигналите. Резултатите од валидацијата покажаа дека предложениот пристап во најголем дел ги задржува своите дијагностички способности и при промена на типот на лежишта, мерната опрема и работните режими, што укажува на добра способност за генерализација. Сепак, со оглед на ограничениот број на достапни валидациски сигнали, овие резултати треба да се разгледуваат како иницијална потврда на применливоста на методологијата, додека понатамошни истражувања со поголем број

експериментални податоци би овозможиле подетална статистичка евалуација на нејзината генерализациска способност.

Способноста за препознавање на присутниот дефект беше тестирана и во случај кога во сигналите вештачки беше додаден адитивен бел Гаусов шум. Моделите покажаа робустност и при примена на сигнали со високо ниво на шум, при што перформансите остануваат релативно стабилни до вредности од околу 10 dB. Овој резултат укажува на добра отпорност на умерени нивоа на шум кои често се присутни во индустриските системи за вибрациски надзор и дополнително ја потврдува применливоста на предложената методологија во реални работни услови.

Значајно е и тоа што во рамки на истражувањето беше потврдена применливоста на предложената методологија и врз сигнал измерен со автономен MEMS сензор. Резултатите од анализата на сигналот обработен со истиот дијагностички пристап покажаа дека методологијата може успешно да се примени и на сигнали добиени од поедноставен и енергетски поефикасен мерен систем, што претставува важен показател за нејзината потенцијална примена во идни интегрирани системи за мониторинг на состојбата.

Во прогностичкиот дел од истражувањето беше развиен модел за предвидување на преостанатиот корисен век на тркалачки лежишта со користење на FEMTO базата на податоци. По обработка на сигналите и екстракција на деградациски индикатори беа применети алгоритми на надгледувано машинско учење за регресија, при што добиените резултати покажаа ниски вредности на грешка и високи вредности на коефициентот на детерминација. За одредени лежишта беа добиени вредности на R^2 поголеми од 0,99, што укажува на висока точност при моделирање на процесот на деградација и предвидување на преостанатиот корисен век. Овие резултати потврдуваат дека избраните карактеристики и применетите алгоритми се соодветни за моделирање на постепеното оштетување и имаат практична вредност при планирање на одржување.

Врз основа на спроведеното истражување и добиените резултати може да се заклучи дека примената на алгоритми на надгледувано машинско учење овозможува автоматизација на активностите на вибрациско-дијагностички надзор и класификација на дефекти со висок степен на точност, со што се потврдува првата поставена хипотеза. Истовремено, резултатите од прогностичката анализа покажуваат дека алгоритмите на машинско учење овозможуваат прецизно предвидување на преостанатиот корисен век на машинските компоненти, што ја потврдува втората поставена хипотеза. Покрај тоа, добиените резултати јасно укажуваат дека методологијата за обработка на вибрационите сигнали и изборот на карактеристики имаат значително влијание врз точноста и робустноста на развиените модели, со што се потврдува и третата поставена хипотеза. Согласно потврдата на сите три поставени хипотези, може да се заклучи дека предложената методологија претставува валиден научен придонес во областа на автоматизирана дијагностика и прогностика на ротирачки машини.

Дополнително, добиените резултати покажаа дека точноста на алгоритмите на машинско учење може значително да зависи од поставеноста на сензорите, бидејќи различните позиции и правци на мерење овозможуваат различна чувствителност кон одредени типови дефекти. На пример, дефекти како дебаланс и нецентричност често се поизразени во радијален и тангенцијален правец, додека дефектите во тркалачките лежишта може подобро да се детектираат на позиции поблиску до лежиштето и во правец во кој се пренесуваат ударните компоненти. Дополнително, начинот на монтирање на сензорите, односно дали се монтирани со навој или магнет, исто така влијае врз фреквентниот опсег и квалитетот на измерениот сигнал. Поради тоа, не постои универзално оптимална поставеност на сензорите за сите дефекти и сите машински системи. Оптималната конфигурација зависи од типот на машината, работните услови и дефектите кои се анализираат. Во рамки на ова истражување, најдобри резултати се постигнати

со примена на повеќе мерни оски и комбинирање на информации од различни позиции на мерење.

7.2 Препораки за идна работа

Иако резултатите од ова истражување покажуваат висока точност и потенцијал за практична примена на предложената методологија, постојат повеќе насоки за понатамошен развој и унапредување на системите за автоматизирана дијагностика и прогностика на состојбата на ротирачките машини.

7.2.1 Насоки за понатамошно унапредување на предложената методологија

Во идни истражувања потребно е да се прошири експерименталната база на податоци со дополнителни типови на дефекти, различни работни режими и различни типови на машински системи. Со ваквиот пристап може дополнително да се подобри способноста на моделите за генерализација и нивната примена во различни индустриски услови. Особено значајно е да се зголеми бројот на независни валидациски сигнали, како и да се вклучат дополнителни брзини на ротација, различни нивоа на дебаланс и повторени мерења по состојба, со цел да се намали варијабилноста на резултатите и да се зајакне нивната статистичка доверливост.

Дополнително, може да се анализира влијанието на различни методи за обработка на сигналите, различни временски прозорци и различни домени на анализа врз перформансите на алгоритмите на машинско учење. Особен интерес претставува интеграцијата на методи за анализа на значајноста на карактеристиките, техники за селекција на карактеристики и методи за намалување на димензионалноста во единствена методолошка рамка, со цел оптимизација на векторот на влезни карактеристики и подобрување на перформансите и интерпретабилноста на моделите.

Иако во ова истражување беше избран пристап базиран на надгледувано машинско учење поради неговата интерпретабилност, стабилност и релативно мали пресметковни барања, идните истражувања би можеле да вклучат и споредбена анализа со модели базирани на длабоко учење. Особено интересна би била споредба помеѓу предложениот хибриден пристап и архитектури базирани на невронски мрежи, кои овозможуваат директно учење на репрезентации од суровите вибрациони сигнали. На тој начин би можело да се оцени дали зголемената комплексност на моделите на длабоко учење води до значајно подобрување на дијагностичките перформанси, особено во услови на ограничен обем на достапни податоци и присуство на шум во сигналите. Дополнително, ваквата анализа би овозможила проценка на компромисот помеѓу интерпретабилноста на класичните модели базирани на карактеристики и репрезентациската моќ на невронските мрежи.

Во делот на прогностиката, идните истражувања може да бидат насочени кон проширување на анализата со дополнителни деградациски индикатори, како и модели кои поексплицитно ја земаат во предвид нестационарноста на сигналите и временскиот контекст на деградацијата. Исто така, значајна насока за понатамошна работа претставува и вклучување на пристапи за рано предвидување на дефекти и поврзување на резултатите од прогностиката со критериуми за одлучување при планирање на одржувањето. Дополнително, значајно би било да се изврши валидација на предложената методологија со нови експериментални бази на податоци, добиени преку долгорочно следење на работата на машинските системи. Ваквите податоци би овозможиле анализа на реални процеси на деградација во подолг временски период и би придонеле за дополнителна проверка на способноста на моделите за предвидување на преостанатиот корисен век во реални индустриски услови.

7.2.2 Концепт за примена во интегриран систем со автономен сензор

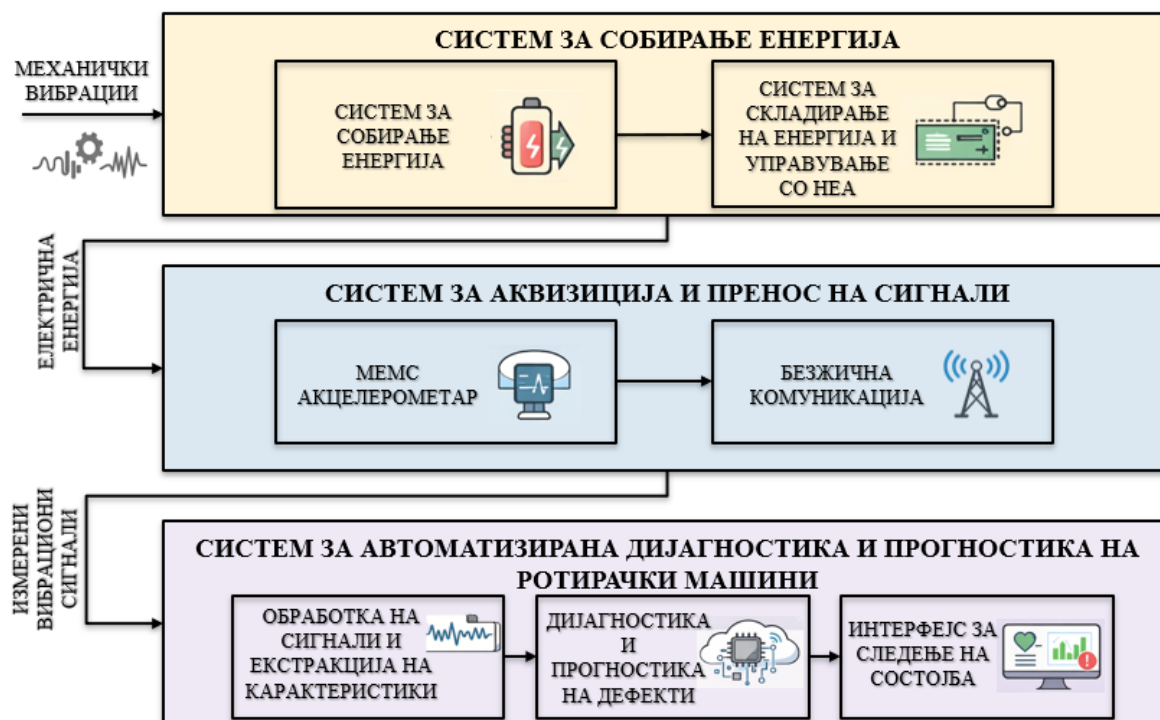
Една од можните насоки за понатамошен развој на предложената методологија е нејзината примена во интегриран систем за мониторинг на состојбата базиран на автономен сензор. Во ваков систем, вибрационите сигнали би се собирале со помош на компактна и енергетски ефикасна сензорска единица, способна да работи со сопствено напојување и без потреба од сложена мерна инфраструктура. Ваквиот концепт е во согласност со современите насоки за развој на интелигентни и дистрибуирани системи за следење на состојбата на машините.

Концептот на идната примена може да се организира во три основни нивоа: потсистем за собирање на енергија од индустриските вибрации, потсистем за аквизиција и пренос на сигналите и платформа за анализа и дијагностика. Дополнително, концептуалната архитектура на ваквиот систем е прикажана на слика 118. Прикажаниот шематски приказ го илустрира начинот на интеграција на автономниот сензорски систем со платформата за интелигентна анализа на податоците со цел практична имплементација во реални индустриски системи за континуиран мониторинг на состојбата на машините. Архитектурата е организирана во три функционални нивоа кои го опфаќаат целиот тек на информацијата. Во првиот дел, индустриските вибрации би се искористиле како извор на енергија за автономно напојување на сензорската единица. Во рамки на овој потсистем механичката енергија од вибрациите на машината би се конвертирала во електрична енергија со примена на соодветни енергетски конвертори. Добиената енергија би се складираше и управувала преку модул за управување со енергија и складирање, со што би се овозможило автономно напојување на сензорската единица без потреба од надворешен извор на енергија. Во вториот дел, измерените вибрациони сигнали би се собирале и безжично би се пренесувале до локална (edge) или централизирана cloud платформа за обработка на податоците. Во овој дел би се искористил компактен MEMS акселерометар кој би ги мерел вибрациите на машината и би генерирал временски сигнали кои ја опишуваат нејзината механичка состојба. Измерените сигнали потоа би се дигитализирале и преку безжична комуникација би се пренесувале кон платформа за понатамошна анализа. Во третиот дел, сигналите би биле предмет на претпроцесирање, екстракција на карактеристики и автоматизирана дијагностика со примена на предложената методологија и моделите развиени во рамки на ова истражување, по што добиените резултати би се прикажувале преку интерфејс за следење на состојбата. Со тоа би се овозможил континуиран мониторинг и навремено донесување одлуки во процесите на одржување.

Резултатите од делот 5.1.4 покажаа дека предложената методологија е применлива и врз сигнал измерен со автономен MEMS сензор, што претставува важен чекор кон практична реализација на ваков систем. Со тоа е потврдено дека методологијата не е ограничена само на сигнали добиени со стандардна лабораториска мерна опрема, туку има потенцијал да се примени и во пофлексибилни, компактни и енергетски ефикасни решенија за индустриски мониторинг.

На овој начин би се овозможило континуирано и автоматизирано следење на состојбата на машините, навремено откривање на дефекти и оптимизација на процесите на одржување. Интеграцијата на вакви системи е во согласност со современите концепти на дигитализација на индустриските процеси и развој на интелигентни системи за одржување во рамки на концептот Индустрија 4.0, при што се создаваат услови за зголемување на сигурноста, ефикасноста и економичноста на индустриските системи. Ваквиот концепт, иако претставува насока за идна работа, логично произлегува од добиените резултати и од можноста предложената дијагностичка методологија да се вгради во поширока архитектура на паметен индустриски мониторинг. Дополнително, имплементацијата на вакви системи би овозможила постепено формирање на нови бази на податоци за анализа на деградацијата и прогностика на машинските компоненти.

Со оглед на тоа што базите на вибрациони сигнали кои опфаќаат реални процеси на деградација се релативно ограничено достапни и бараат долгорочни експериментални мерења, ваквите системи би можеле да обезбедат релевантни бази на податоци за идни научни истражувања, дополнителна валидација на моделите и нивна понатамошна оптимизација.



Слика 118. Концептуална шема на архитектура на интегриран автономен систем за вибрациско-дијагностички мониторинг на ротирачки машини

Во целина, резултатите добиени во рамки на оваа докторска дисертација покажуваат дека предложената методологија, која комбинира соодветна обработка на вибрационите сигнали, и креира модели базирани на алгоритмите на надгледувано машинско учење, претставува ефективен пристап за автоматизирана дијагностика и прогностика на состојбата на ротирачките машини. Со оглед на постигнатите резултати и потенцијалот за практична примена, предложениот пристап може да претставува значаен чекор кон развој на интелигентни системи за следење на состојбата на машините во современите индустриски системи, особено во контекст на дигитализацијата на индустријата и концептите на паметни фабрики и Индустрија 4.0.

КОРИСТЕНА ЛИТЕРАТУРА

- [1] Fetić N. Maintenance of tools, 2019. 12th International Scientific Conference on Production Engineering, Development and modernization of production.
- [2] Duboka C.V., Autoservisi, 1999. Masinski fakultet - Beograd.
- [3] Wonk V., Machinery Vibration - Measurement and Analysis.
- [4] McKinsey & Company, *Manufacturing analytics unleashes productivity and profitability*, 2015. [Online]. Available: <https://www.mckinsey.com/capabilities/operations/our-insights/manufacturing-analytics-unleashes-productivity-and-profitability>.
- [5] A. Heng, A. C. C. Tan, J. Mathew, N. Montgomery, D. Banjevic, and A. K. S. Jardine, "Intelligent condition-based prediction of machinery reliability," *Mech. Syst. Signal Process.*, vol. 23, no. 5, pp. 1600_1614, 2009.
- [6] R. X. Gao and R. Yan, *Wavelets: Theory and Applications for Manufacturing*. Cham, Switzerland: Springer, 2010.
- [7] Zurita, G., Sánchez, V. and Cabrera, D., 2016. A review of vibration machine diagnostics by using artificial intelligence methods. *Investigación & Desarrollo*, 1(16), pp.102-114.
- [8] Lupea, I. and Lupea, M., 2022. Machine learning techniques for multi-fault analysis and detection on a rotating test rig using vibration signal. *Symmetry*, 15(1), p.86.
- [9] Vyas, N.S. and Satishkumar, D., 2001. Artificial neural network design for fault identification in a rotor-bearing system. *Mechanism and machine theory*, 36(2), pp.157-175.
- [10] Hoffman, A.J. and Van Der Merwe, N.T., 2002. The application of neural networks to vibrational diagnostics for multiple fault conditions. *Computer Standards & Interfaces*, 24(2), pp.139-149.
- [11] Wu, T.Y., Chen, J.C. and Wang, C.C., 2012. Characterization of gear faults in variable rotating speed using Hilbert-Huang Transform and instantaneous dimensionless frequency normalization. *Mechanical Systems and Signal Processing*, 30, pp.103-122.
- [12] Han, T., Jiang, D., Zhao, Q., Wang, L. and Yin, K., 2018. Comparison of random forest, artificial neural networks and support vector machine for intelligent diagnosis of rotating machinery. *Transactions of the Institute of Measurement and Control*, 40(8), pp.2681-2693.
- [13] Al-Badour, F., Sunar, M. and Cheded, L., 2011. Vibration analysis of rotating machinery using time-frequency analysis and wavelet techniques. *Mechanical Systems and Signal Processing*, 25(6), pp.2083-2101.

- [14] Mohd Ghazali, M.H. and Rahiman, W., 2021. Vibration analysis for machine monitoring and diagnosis: a systematic review. *Shock and Vibration*, 2021(1), p.9469318.
- [15] Kumar, S.S. and Kumar, M.S., 2014. Condition monitoring of rotating machinery through vibration analysis.
- [16] Mohd Ghazali, M.H. and Rahiman, W., 2021. Vibration analysis for machine monitoring and diagnosis: a systematic review. *Shock and Vibration*, 2021(1), p.9469318.
- [17] Teng, W., Zhang, X., Liu, Y., Kusiak, A. and Ma, Z., 2016. Prognosis of the remaining useful life of bearings in a wind turbine gearbox. *Energies*, 10(1), p.32.
- [18] Thoppil, N.M., Vasu, V. and Rao, C.S.P., 2021. Deep learning algorithms for machinery health prognostics using time-series data: A review. *Journal of Vibration Engineering & Technologies*, pp.1-23.
- [19] Rustighi, E., 2004. Dynamics of rotating machinery: analysis, identification and control. Università di Pisa, DIMNP.
- [20] Walker, R., Perinpanayagam, S. and Jennions, I.K., 2013. Rotordynamic faults: recent advances in diagnosis and prognosis. *International Journal of Rotating Machinery*, 2013.
- [21] Heng, A., Zhang, S., Tan, A.C. and Mathew, J., 2009. Rotating machinery prognostics: State of the art, challenges and opportunities. *Mechanical systems and signal processing*, 23(3), pp.724-739.
- [22] Вибрации на машини, Анание Илиевски, Златко Петрески, Машински Факултет Скопје 2013.
- [23] ISO 17359 - Condition monitoring and diagnostics of machines - General guidelines.
- [24] ISO 13373-1:2002, *Condition monitoring and diagnostics of machines — Vibration condition monitoring — Part 1: General procedures*. Geneva: International Organization for Standardization, 2002.
- [25] ISO 10816-3, ISO 20816-1: "Mechanical vibration — Measurement and evaluation of machine vibration.
- [26] Scheffer, C. and Girdhar, P., 2004. *Practical machinery vibration analysis and predictive maintenance*. Elsevier.
- [27] Aherwar, A., 2012. An investigation on gearbox fault detection using vibration analysis techniques: A review. *Australian Journal of Mechanical Engineering*, 10(2), pp.169-183.
- [28] Peng, Z. and Kessissoglou, N., 2003. An integrated approach to fault diagnosis of machinery using wear debris and vibration analysis. *Wear*, 255(7-12), pp.1221-1232.
- [29] Betta, G., Liguori, C., Paolillo, A. and Pietrosanto, A., 2002. A DSP-based FFT-analyzer for the fault diagnosis of rotating machine based on vibration analysis. *IEEE Transactions on Instrumentation and Measurement*, 51(6), pp.1316-1322.

- [30] Dybała, J. and Zimroz, R., 2014. Rolling bearing diagnosing method based on empirical mode decomposition of machine vibration signal. *Applied Acoustics*, 77, pp.195-203.
- [31] Roemer, M.J., Byington, C.S. and Sheldon, J., 2008. Advanced vibration analysis to support prognosis of rotating machinery components. *International journal of COMADEM*, 11(2), p.2.
- [32] Janjarasjitt, S., Ocaik, H.A.S.A.N. and Loparo, K.A., 2008. Bearing condition diagnosis and prognosis using applied nonlinear dynamical analysis of machine vibration signal. *Journal of Sound and Vibration*, 317(1-2), pp.112-126.
- [33] Wang, D., Tsui, K.L. and Miao, Q., 2017. Prognostics and health management: A review of vibration based bearing and gear health indicators. *Ieee Access*, 6, pp.665-676.
- [34] Javed, K., Gouriveau, R., Zerhouni, N. and Nectoux, P., 2014. Enabling health monitoring approach based on vibration data for accurate prognostics. *IEEE Transactions on industrial electronics*, 62(1), pp.647-656.
- [35] Mansouri, M., Harkat, M.F., Nounou, H. and Nounou, M.N., 2020. Data-driven and model-based methods for fault detection and diagnosis. Elsevier.
- [36] Luo, J., Namburu, M., Pattipati, K., Qiao, L., Kawamoto, M. and Chigusa, S.A.C.S., 2003, September. Model-based prognostic techniques [maintenance applications]. In Proceedings AUTOTESTCON 2003. IEEE Systems Readiness Technology Conference. (pp. 330-340).
- [37] Eker, O.F., Camci, F. and Jennions, I.K., 2012. Major challenges in prognostics: Study on benchmarking prognostics datasets. In PHM Society European Conference (Vol. 1, No. 1).
- [38] An, D., Choi, J.H. and Kim, N.H., 2013. Options for Prognostics Methods: A review of data-driven and physics-based prognostics. In 54th AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference (p. 1940).
- [39] Oppenheimer, C.H. and Loparo, K.A., 2002, July. Physically based diagnosis and prognosis of cracked rotor shafts. In Component and systems diagnostics, prognostics, and health management II (Vol. 4733, pp. 122-132). SPIE.
- [40] Bahaloo, H., Ebrahimi, A. and Samadi, M., 2009, January. Misalignment modeling in rotating systems. In Turbo Expo: Power for Land, Sea, and Air (Vol. 48876, pp. 973-979).
- [41] Chen, G., 2009. A new rotor-ball bearing-stator coupling dynamics model for whole aero-engine vibration. *Journal of Vibration and Acoustics*, 131(6).
- [42] Luo, Y., Zhang, S., Ren, Z. and Wen, B., 2009, January. Dynamic Characteristics of Nonlinear Elastics Rotor-Bearing System With Coupling Faults of Pedestal Looseness and Rub-Impact. In International Design Engineering Technical Conferences and Computers and Information in Engineering Conference (Vol. 48982, pp. 1123-1127).

- [43] Liu, Y., Xue, Z., Jia, L., Shi, T. and Ma, H., 2017. Response characteristics of looseness-rubbing coupling fault in rotor-sliding bearing system. *Mathematical Problems in Engineering*, 2017.
- [44] McFadden, P.D. and Smith, J.D., 1984. Model for the vibration produced by a single point defect in a rolling element bearing. *Journal of sound and vibration*, 96(1), pp.69-82.
- [45] Patel, V.N., Tandon, N. and Pandey, R.K., 2014. Vibrations generated by rolling element bearings having multiple local defects on races. *Procedia Technology*, 14, pp.312-319.
- [46] Luo, J., Bixby, A., Pattipati, K., Qiao, L., Kawamoto, M. and Chigusa, S., 2003, October. An interacting multiple model approach to model-based prognostics. In *SMC'03 Conference Proceedings. 2003 IEEE International Conference on Systems, Man and Cybernetics. Conference Theme-System Security and Assurance (Cat. No. 03CH37483) (Vol. 1, pp. 189-194)*. IEEE.
- [47] Bankert, R.J., Singh, V.K. and Rajiyah, H., 1995, June. Model based diagnostics and prognosis system for rotating machinery. In *Turbo Expo: Power for Land, Sea, and Air (Vol. 78828, p. V005T14A022)*. American Society of Mechanical Engineers.
- [48] Marble, S. and Morton, B.P., 2006, March. Predicting the remaining life of propulsion system bearings. In *2006 IEEE Aerospace Conference (pp. 8-pp)*. IEEE.
- [49] Li, Y.S.C.T.S., Billington, S., Zhang, C., Kurfess, T., Danyluk, S. and Liang, S., 1999. Adaptive prognostics for rolling element bearing condition. *Mechanical systems and signal processing*, 13(1), pp.103-113.
- [50] Qiu, J., Seth, B.B., Liang, S.Y. and Zhang, C., 2002. Damage mechanics approach for bearing lifetime prognostics. *Mechanical systems and signal processing*, 16(5), pp.817-829.
- [51] Yu, W.K. and Harris, T.A., 2001. A new stress-based fatigue life model for ball bearings. *Tribology transactions*, 44(1), pp.11-18.
- [52] Kotzalas, M., and Harris, T. (n.d). Fatigue failure progression in ball bearings. *Journal of Tribology-Transactions of The Asme*, 123(2), 238-242.
- [53] Paris, P.C., 1961. A rational analytic theory of fatigue. *Trends Engin*, 13, pp.9-14.
- [54] Kacprzyński, G.J., Roemer, M.J., Byington, C.S., Modgil, G.A., Palladino, A. and Maynard, K.P., 2002, April. Enhancing gear physics of failure models with system level vibration features. In *Proc. 56th Meeting of the Society for MFPT (pp. 263-277)*.

- [55] Li, C.J. and Lee, H., 2005. Gear fatigue crack prognosis using embedded model, gear dynamic model and fracture mechanics. *Mechanical systems and signal processing*, 19(4), pp.836-846.
- [56] Bechhoefer, E., Bernhard, A. and He, D., 2008, March. Use of Paris law for prediction of component remaining life. In 2008 IEEE Aerospace Conference (pp. 1-9). IEEE.
- [57] He, D., Bechhoefer, E., Dempsey, P. and Ma, J., 2012, May. An integrated approach for gear health prognostics. In AHS International 68th Annual Forum and Technology Display (No. E-18242).
- [58] Zio, E. and Peloni, G., 2011. Particle filtering prognostic estimation of the remaining useful life of nonlinear components. *Reliability Engineering & System Safety*, 96(3), pp.403-409.
- [59] Aslantaş, K. and Taşgetiren, S., 2004. A study of spur gear pitting formation and life prediction. *Wear*, 257(11), pp.1167-1175.
- [60] Blake, J.W. and Cheng, H.S., 1991. A surface pitting life model for spur gears: Part I—Life prediction.
- [61] Kundu, P., Darpe, A.K. and Kulkarni, M.S., 2019. A correlation coefficient based vibration indicator for detecting natural pitting progression in spur gears. *Mechanical Systems and Signal Processing*.
- [62] Ahmed, H. and Nandi, A.K., 2020. Condition monitoring with vibration signals: Compressive sampling and learning algorithms for rotating machines. John Wiley & Sons.
- [63] Saufi, S.R., Ahmad, Z.A.B., Leong, M.S. and Lim, M.H., 2019. Challenges and opportunities of deep learning models for machinery fault detection and diagnosis: A review. *Ieee Access*, 7, pp.122644-122662.
- [64] Hang, J., Zhang, J. and Cheng, M., 2016. Application of multi-class fuzzy support vector machine classifier for fault diagnosis of wind turbine. *Fuzzy Sets and Systems*, 297, pp.128-140.
- [65] Baccarini, L.M.R., e Silva, V.V.R., de Menezes, B.R. and Caminhas, W.M., 2011. SVM practical industrial application for mechanical faults diagnostic. *Expert Systems with Applications*, 38(6), pp.6980-6984.
- [66] Yuan, S.F. and Chu, F.L., 2006. Support vector machines-based fault diagnosis for turbo-pump rotor. *Mechanical Systems and Signal Processing*, 20(4), pp.939-952.
- [67] Kang, M., Kim, J., Kim, J.M., Tan, A.C., Kim, E.Y. and Choi, B.K., 2014. Reliable fault diagnosis for low-speed bearings using individually trained support vector machines with kernel discriminative feature analysis. *IEEE Transactions on Power Electronics*, 30(5), pp.2786-2797.

- [68] Liu, Z., Cao, H., Chen, X., He, Z. and Shen, Z., 2013. Multi-fault classification based on wavelet SVM with PSO algorithm to analyze vibration signals from rolling element bearings. *Neurocomputing*, 99, pp.399-410.
- [69] Shen, C., Wang, D., Liu, Y., Kong, F. and Tse, P.W., 2014. Recognition of rolling bearing fault patterns and sizes based on two-layer support vector regression machines. *Smart Structures and Systems*, 13(3), pp.453-471.
- [70] Wu, T.Y., Chen, J.C. and Wang, C.C., 2012. Characterization of gear faults in variable rotating speed using Hilbert-Huang Transform and instantaneous dimensionless frequency normalization. *Mechanical Systems and Signal Processing*, 30, pp.103-122.
- [71] Yang, D., Liu, Y., Li, S., Li, X. and Ma, L., 2015. Gear fault diagnosis based on support vector machine optimized by artificial bee colony algorithm. *Mechanism and Machine Theory*, 90, pp.219-229.
- [72] Hang, J., Zhang, J. and Cheng, M., 2016. Application of multi-class fuzzy support vector machine classifier for fault diagnosis of wind turbine. *Fuzzy Sets and Systems*, 297, pp.128-140.
- [73] Sanchez, R.V., Lucero, P., Vasquez, R.E., Cerrada, M., Macancela, J.C. and Cabrera, D., 2018. Feature ranking for multi-fault diagnosis of rotating machinery by using random forest and KNN. *Journal of Intelligent & Fuzzy Systems*, 34(6), pp.3463-3473.
- [74] Lu, Q., Shen, X., Wang, X., Li, M., Li, J. and Zhang, M., 2021. Fault diagnosis of rolling bearing based on improved VMD and KNN. *Mathematical Problems in Engineering*, 2021(1), p.2530315.
- [75] Lu, J., Qian, W., Li, S. and Cui, R., 2021. Enhanced K-nearest neighbor for intelligent fault diagnosis of rotating machinery. *Applied Sciences*, 11(3), p.919.
- [76] Wang, H., Yu, Z. and Guo, L., 2020, April. Real-time online fault diagnosis of rolling bearings based on KNN algorithm. In *Journal of Physics: Conference Series* (Vol. 1486, No. 3, p. 032019), IOP Publishing.
- [77] Zhang, N., Wu, L., Yang, J. and Guan, Y., 2018. Naive bayes bearing fault diagnosis based on enhanced independence of data. *Sensors*, 18(2), p.463.
- [78] Muralidharan, V. and Sugumaran, V., 2012. A comparative study of Naïve Bayes classifier and Bayes net classifier for fault diagnosis of monoblock centrifugal pump using wavelet analysis. *Applied Soft Computing*, 12(8), pp.2023-2029., da Silva, P.R.N.
- [79] Gabbar, H.A., Junior, P.V. and da Costa Junior, C.T., 2018. A new methodology for multiple incipient fault diagnosis in transmission lines using QTA and Naïve Bayes classifier. *International journal of electrical power & energy systems*, 103, pp.326-346.

- [80] Saini, M.K. and Aggarwal, A., 2018. Detection and diagnosis of induction motor bearing faults using multiwavelet transform and naive Bayes classifier. *International Transactions on Electrical Energy Systems*, 28(8), p.e2577.
- [81] Guo, Z., Zhang, Y., Li, X., & Zhou, C., 2020. Fault-Diagnosis of Bearings Based on 1D-CNN and XGBoost. In *SPIE Proceedings 13250: 13250-24-12-3038683* (Aug 23).
- [82] Farooq, U., Ademola, M., & Shaalan, A., 2024. Comparative Analysis of Machine-Learning Models for Predictive Maintenance of Ball Bearing Systems. *Electronics*, 13(2): 438.
- [83] Ayyappa, T., & Kurse, Shridhar, 2021, April. Fault Detection of Bearing using XGBoost Algorithm and Data Visualization using t-SNE Method. In *Proceedings of the International Conference on Innovative Computing & Communication (ICICC 2021)*. SSRN.
- [84] Das, O., 2024. Real-time intelligent fault diagnosis of rotating machines based on Archimedes-algorithm-optimised gradient boosting. In *Nondestructive Testing & Evaluation*, 39: 474-512.
- [85] Li, X., Shao, H., Lu, S., Xiang, J., & Cai, B., 2024. Enhanced Bearing Fault Diagnosis Through Tree Ensemble including Extreme Gradient Boosting (XGBoost). *Springer Journal: Measurement, Machines & Fault Detection*, 2024.
- [86] Widodo, A., Kim, E.Y., Son, J.D., Yang, B.S., Tan, A.C., Gu, D.S., Choi, B.K. and Mathew, J., 2009. Fault diagnosis of low-speed bearing based on relevance vector machine and support vector machine. *Expert systems with applications*, 36(3), pp.7252-7261.
- [87] Zhang, Y., Li, B., Wang, Z., Wang, W. and Wang, L., 2013. Fault diagnosis of rotating machine by isometric feature mapping. *Journal of Mechanical Science and Technology*, 27(11), pp.3215-3221.
- [88] Saravanan, N., Siddabattuni, V.K. and Ramachandran, K.I., 2010. Fault diagnosis of spur bevel gear box using artificial neural network (ANN), and proximal support vector machine (PSVM). *Applied soft computing*, 10(1), pp.344-360.
- [89] Vyas, N.S. and Satishkumar, D., 2001. Artificial neural network design for fault identification in a rotor-bearing system. *Mechanism and machine theory*, 36(2), pp.157-175.
- [90] Kaewkongka, T., Au, Y.J., Rakowski, R. and Jones, B.E., 2001, May. Continuous wavelet transform and neural network for condition monitoring of rotodynamic machinery. In *IMTC 2001. Proceedings of the 18th IEEE Instrumentation and Measurement Technology Conference. Rediscovering Measurement in the Age of Informatics (Cat. No. 01CH 37188) (Vol. 3, pp. 1962-1966)*. IEEE.
- [91] Ngolah, C.F., Morden, E. and Wang, Y., 2011. Intelligent fault recognition and diagnosis for rotating machines using neural networks. *International Journal of Software Science and Computational Intelligence (IJSSCI)*, 3(4), pp.67-83.
- [92] Lei, Y., He, Z. and Zi, Y., 2009. Application of the EEMD method to rotor fault diagnosis of rotating machinery. *Mechanical Systems and Signal Processing*, 23(4), pp.1327-1338.

- [93] Bin, G.F., Gao, J.J., Li, X.J. and Dhillon, B.S., 2012. Early fault diagnosis of rotating machinery based on wavelet packets—Empirical mode decomposition feature extraction and neural network. *Mechanical Systems and Signal Processing*, 27, pp.696-711.
- [94] Rajeswari, C., Sathiyabhama, B., Devendiran, S. and Manivannan, K., 2014. A gear fault identification using wavelet transform, rough set based GA, ANN and C4. 5 algorithm. *Procedia Engineering*, 97, pp.1831-1841.
- [95] Sohaib, M. and Kim, J.M., 2018. Reliable fault diagnosis of rotary machine bearings using a stacked sparse autoencoder-based deep neural network. *Shock and Vibration*, 2018.
- [96] Zhou, F., Gao, Y. and Wen, C., 2017. A novel multimode fault classification method based on deep learning. *Journal of Control Science and Engineering*, 2017.
- [97] Mao, W., He, J., Li, Y. and Yan, Y., 2017. Bearing fault diagnosis with auto-encoder extreme learning machine: A comparative study. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 231(8), pp.1560-1578.
- [98] Qi, Y., Shen, C., Wang, D., Shi, J., Jiang, X. and Zhu, Z., 2017. Stacked sparse autoencoder-based deep network for fault diagnosis of rotating machinery. *Ieee Access*, 5, pp.15066-15079.
- [99] Shao, H., Jiang, H., Wang, F. and Wang, Y., 2017. Rolling bearing fault diagnosis using adaptive deep belief network with dual-tree complex wavelet packet. *ISA transactions*, 69, pp.187-201.
- [100] Guo, S., Yang, T., Gao, W. and Zhang, C., 2018. A novel fault diagnosis method for rotating machinery based on a convolutional neural network. *Sensors*, 18(5), p.1429.
- [101] Karpatne, A., Atluri, G., Faghmous, J.H., Steinbach, M., Banerjee, A., Ganguly, A., Shekhar, S., Samatova, N. and Kumar, V., 2017. Theory-guided data science: A new paradigm for scientific discovery from data. *IEEE Transactions on knowledge and data engineering*, 29(10), pp.2318-2331.
- [102] Russell, M. and Wang, P., 2022. Physics-informed deep learning for signal compression and reconstruction of big data in industrial condition monitoring. *Mechanical Systems and Signal Processing*, 168, p.108709.
- [103] Shen, S., Lu, H., Sadoughi, M., Hu, C., Nemani, V., Thelen, A., Webster, K., Darr, M., Sidon, J. and Kenny, S., 2021. A physics-informed deep learning approach for bearing fault detection. *Engineering Applications of Artificial Intelligence*, 103, p.104295.
- [104] Sadoughi, M. and Hu, C., 2018, October. A physics-based deep learning approach for fault diagnosis of rotating machinery. In *IECON 2018-44th Annual Conference of the IEEE Industrial Electronics Society* (pp. 5919-5923). IEEE.
- [105] Sadoughi, M. and Hu, C., 2019. Physics-based convolutional neural network for fault diagnosis of rolling element bearings. *IEEE Sensors Journal*, 19(11), pp.4181-4192.
- [106] Lu, H., Sadoughi, M., Zimmerman, A.T. and Hu, C., 2019. Fault Diagnosis of Rolling Element Bearings on Low-Cost and Scalable IIoT Platform. *Structural Health Monitoring 2019*.

- [107] Shen, S., Lu, H., Sadoughi, M., Hu, C., Nemani, V., Thelen, A., Webster, K., Darr, M., Sidon, J. and Kenny, S., 2021. A physics-informed deep learning approach for bearing fault detection. *Engineering Applications of Artificial Intelligence*, 103, p.104295.
- [108] Zhang, Z., Wang, Y. and Wang, K., 2013. Fault diagnosis and prognosis using wavelet packet decomposition, Fourier transform and artificial neural network. *Journal of Intelligent Manufacturing*, 24(6), pp.1213-1227.
- [109] S. N. Ganeriwala, B. Schwarz, and M. H. Richardson, "Operating deflection shapes detect unbalance in rotating equipment," *Sound and Vibration*, vol. 43, no. 5, pp. 11–13, 2009.
- [110] T. Yang and M. W. Hsu, "An efficient diagnosis technique for variations of shaft-bow and unbalance," in *Proceedings of the ASME International Design Engineering Technical Conferences and Computers and Information in Engineering Conference (DETC '09)*, pp. 57–66, San Diego, Calif, USA, September 2009.
- [111] Villa, L.F., Reñones, A., Perán, J.R. and de Miguel, L.J., 2012. Statistical fault diagnosis based on vibration analysis for gear test-bench under non-stationary conditions of speed and load. *Mechanical Systems and Signal Processing*, 29, pp.436-446.
- [112] Hong, J., Miao, X., Han, L. and Ma, Y., 2009, January. Prognostics model for predicting aero-engine bearing grade-life. In *Turbo Expo: Power for Land, Sea, and Air (Vol. 48821, pp. 639-647)*
- [113] Xia, M., Li, T., Liu, L., Xu, L., Gao, S. and De Silva, C.W., 2017, October. Remaining useful life prediction of rotating machinery using hierarchical deep neural network. In *2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)* (pp. 2778-2783). IEEE.
- [114] P. Borghesani, P. Pennacchi, R. B. Randall, N. Sawalhi, and R. Ricci, "Application of cepstrum-pre-whitening for the diagnosis of bearing faults under variable speed conditions," *Mechanical Systems and Signal Processing*, 2012.
- [115] Zhao, F., Tian, Z., Liang, X. and Xie, M., 2018. An integrated prognostics method for failure time prediction of gears subject to the surface wear failure mode. *IEEE Transactions on Reliability*, 67(1), pp.316-327.
- [116] Teng, W., Zhang, X., Liu, Y., Kusiak, A. and Ma, Z., 2016. Prognosis of the remaining useful life of bearings in a wind turbine gearbox. *Energies*, 10(1), p.32.
- [117] J. Deutsch and D. He, "Using Deep Learning Based Approaches for Bearing Remaining Useful Life Prediction," *Annu. Conf. Progn. Heal. Manag. Soc.*, pp. 1–7, 2015.
- [118] Wang, Q., Zhao, B., Ma, H., Chang, J. and Mao, G., 2019. A method for rapidly evaluating reliability and predicting remaining useful life using two-dimensional convolutional neural network with signal conversion. *Journal of Mechanical Science and Technology*, 33(6), pp.2561-2571.
- [119] J. Zhu, N. Chen, and W. Peng, "Estimation of Bearing Remaining Useful Life Based on Multiscale Convolutional Neural Network," *IEEE Trans. Ind. Electron.*, vol. 66, no. 4, pp. 3208–3216, 2019.

- [120] Thoppil, N.M., Vasu, V. and Rao, C.S.P., 2021. Deep learning algorithms for machinery health prognostics using time-series data: A review. *Journal of Vibration Engineering & Technologies*, pp.1-23.
- [121] Rezaeianjouybari, B. and Shang, Y., 2020. Deep learning for prognostics and health management: State of the art, challenges, and opportunities. *Measurement*, 163, p.107929.
- [122] Yang, H., Zhao, F., Jiang, G., Sun, Z. and Mei, X., 2019. A novel deep learning approach for machinery prognostics based on time windows. *Applied Sciences*, 9(22), p.4813.
- [123] Hu, C.H., Pei, H., Si, X.S., Du, D.B., Pang, Z.N. and Wang, X., 2019. A prognostic model based on DBN and diffusion process for degrading bearing. *IEEE Transactions on Industrial Electronics*, 67(10), pp.8767-8777.
- [124] Deutsch, J. and He, D., 2017. Using deep learning-based approach to predict remaining useful life of rotating components. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 48(1), pp.11-20.
- [125] MaFaulda - Machinery Fault Database. [Online]. Available: http://www02.smt.ufrj.br/~offshore/mfs/page_01.html.
- [126] SpectraQuest, Inc. [Online]. Available: <http://www.spectraquest.com/>
- [127] A.M. Matheus, M.L.F. Ribeiro, L.N. Sergio, A.B.S. Eduardo, “Improved Similarity-Based Modeling for the Classification of Rotating-Machine Failures”, *Journal of the Franklin Institute*, 2017.
- [128] D.P. Viana, D.Z. Lopez, R.D., A.A. Lima, T.D.M. Prego, S.L. Netto, and E.A. Silva, “The influence of feature vector on the classification of mechanical faults using neural networks” *IEEE 7th Latin American Symposium on Circuits & Systems*, pp. 115-118, February, 2016.
- [129] A.A De Lima, T.D.M. Prego, S.L. Netto, E.A. Da Silva, R.H. Gutierrez, U.A. Monteiro, A.C. Troyman, F.J.D.C. Silveira, and L. Vaz, “On fault classification in rotating machines using fourier domain features and neural networks.” *4th LASCAS* (pp. 1-4). IEEE, February 2013.
- [130] A.M. Matheus, M.L.F. Ribeiro, L.N. Sergio, A.B.S. Eduardo, “Improved Similarity-Based Modeling for the Classification of Rotating-Machine Failures”, *Journal of the Franklin Institute*, 2017.
- [131] D.P. Viana, D.Z. Lopez, R.D., A.A. Lima, T.D.M. Prego, S.L. Netto, and E.A. Silva, “The influence of feature vector on the classification of mechanical faults using neural networks” *IEEE 7th Latin American Symposium on Circuits & Systems (LASCAS)* (pp. 115-118). February, 2016.
- [132] Goutam Senapaty and Sathish Rao U., *Vibration based condition monitoring of rotating machinery, Condition monitoring of rotating machinery. A statistical approach* TIM GISSEMAN, FABIAN HEDIN.
- [133] Гаврилоски В., Домазетовска С. Вибрации во машинството – Машински Факултет – Скопје, Вибрации на машини, Анание Илиевски, Златко Петрески, Машински Факултет Скопје 2013.

- [134] ISO 10816-1: Mechanical vibration - Evaluation of machine vibration by measurements on non-rotating parts - Part 1: General guidelines and Appendix ISO 10816-1/Amd.1.
- [135] ISO 20816-1:2016: Mechanical vibration — Measurement and evaluation of machine vibration - Part 1: General guidelines.
- [136] Chawla, N.V., 2010. Data mining for imbalanced datasets: An overview. *Data mining and knowledge discovery handbook*, pp.875-886.
- [137] ISO 5348:2021: Mechanical vibration and shock — Mechanical mounting of accelerometers.
- [138] Sinha, J.K., 2015. *Vibration analysis, instruments, and signal processing* (Vol. 1). Boca Raton: CRC press.
- [139] Rai, A. and Upadhyay, S.H., 2016. A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings. *Tribology International*, 96, pp.289-306.
- [140] Wang, B., 2023. Remaining Useful Life Predictions for Bearings Using Spectrogram and Scalogram-Based Convolutional Neural Networks (Doctoral dissertation, Université d'Ottawa/University of Ottawa).
- [141] Althubaiti, A., Elasha, F. and Teixeira, J.A., 2022. Fault diagnosis and health management of bearings in rotating equipment based on vibration analysis—a review. *Journal of Vibroengineering*, 24(1), pp.46-74.
- [142] M.D.Coats, S.Nader, and R. B. Randall, "Extraction of tacho information from a vibration signal for improved synchronous averaging." In Proceedings of acoustics, pp. 1-8. 2009.
- [143] P.D.McFadden, and M.M.Toozhy, "Application of synchronous averaging to vibration monitoring of rolling element bearings." *Mechanical Systems and Signal Processing* 14, no. 6, 891-906, 2000.
- [144] W.Wang, N.Sawalhi, and A.Becker, "Size estimation for naturally occurring bearing faults using synchronous averaging of vibration signals." *Journal of Vibration and Acoustics* 138, no. 5, 2016.
- [145] Yang, B.S.; Widodo, A. Introduction of Intelligent Machine Fault Diagnosis and Prognosis; Nova Science Publishers: New York, NY, USA, 2009.
- [146] Caesarendra, W. and Tjahjowidodo, T. A review of feature extraction methods in vibration-based condition monitoring and its application for degradation trend estimation of low-speed slew bearing. *Machines*, 5(4), p.21., 2017.
- [147] A., Gowen, E., Poliakoff, E. and Casson, A.J., 2019. Machine learning algorithm validation with a limited sample size. *PloS one*, 14(11), p.e0224365.
- [148] Acernese, A., Del Vecchio, C., Tipaldi, M., Battilani, N. and Glielmo, L., 2021. Condition-based maintenance: an industrial application on rotary machines. *Journal of Quality in Maintenance Engineering*, 27(4), pp.565-585.
- [149] Heng, A., Zhang, S., Tan, A.C. and Mathew, J., 2009. Rotating machinery prognostics: State of the art, challenges and opportunities. *Mechanical systems and signal processing*, 23(3), pp.724-739.

[150] Raschka, S., 2018. Model evaluation, model selection, and algorithm selection in machine learning. *arXiv preprint arXiv:1811.12808*.

[151] Turek, Paweł. 2021. "Determination of the Natural Frequency of the Model Spindle System with Active Regulation of the Initial Tension of the Bearings" *Lubricants* 9, no. 7: 68. <https://doi.org/10.3390/lubricants9070068>.

[152] Patrick Nectoux, Rafael Gouriveau, Kamal Medjaher, Emmanuel Ramasso, Brigitte Chebel-Morello, et al.. PRONOSTIA : An Experimental Platform for Bearings Accelerated Life Test. IEEE International Conference on Prognostics and Health Management, PHM'12., Jun 2012, Denver, Colorado, United States. pp.1-8. fihal-00719503f.

[153] Alfarizi, M.G., Tajiani, B., Vatn, J. and Yin, S., 2022. Optimized random forest model for remaining useful life prediction of experimental bearings. *IEEE Transactions on Industrial Informatics*, 19(6), pp.7771-7779.

[154] Bienefeld, C., Kirchner, E., Vogt, A. and Kacmar, M., 2022. On the importance of temporal information for remaining useful life prediction of rolling bearings using a random forest regressor. *Lubricants*, 10(4), p.67.

[155] Patil, S., Patil, A., Handikherkar, V., Desai, S., Phalle, V.M. and Kazi, F.S., 2018, November. Remaining useful life (RUL) prediction of rolling element bearing using random forest and gradient boosting technique. In ASME international mechanical engineering congress and exposition (Vol. 52187, p. V013T05A019). American Society of Mechanical Engineers.

[156] Huang, H.Z., Wang, H.K., Li, Y.F., Zhang, L. and Liu, Z., 2015. Support vector machine based estimation of remaining useful life: current research status and future trends. *Journal of Mechanical Science and Technology*, 29(1), pp.151-163.

[157] Zhang, L., Liu, Z., Luo, D., Li, J. and Huang, H.Z., 2013, July. Review of remaining useful life prediction using support vector machine for engineering assets. In *2013 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering (QR2MSE)* (pp. 1793-1799). IEEE.

[158] Louen, C., Ding, S.X. and Kandler, C., 2013, October. A new framework for remaining useful life estimation using support vector machine classifier. In *2013 Conference on Control and Fault-Tolerant Systems (SysTol)* (pp. 228-233). IEEE.

ПРИЛОЗИ

Прилог А - Програмски код во Python за подготовка на базата на податоци за тренинг на модел, како и за обработка на сигналите, екстракција на карактеристики и нивна нормализација за дијагностички цели за дијагностички цели

- Прилог А-1 - Програмски код во Python за вчитување на метаподатоците за сигналите и дефинирање на ознаките за припадност на класите согласно табела 6 од глава 2.1
- Прилог А-2 - Програмски код во Python за дефинирање и повикување на функција за определување на ротационата фреквенција со примена на сигналот снимен со тахометарот, согласно методологијата опишана во глава 2.3
- Прилог А-3 - Програмски код во Python за балансирање на базата на податоци согласно методологијата опишана во глава 2.6.1
- Прилог А-4 - Програмски код во Python за намалување на фреквенцијата на семплирање согласно методологијата опишана во глава 2.6.2
- Прилог А-5 - Програмски код во Python за обработка на сигнали, екстракција на карактеристики согласно табела 8 од глава 3.2
- Прилог А-6 - Програмски код во Python за нормализација на екстрахирани карактеристики согласно методологијата опишана во глава 3.3

Прилог Б - Програмски код во Python за тренинг на модел за дијагностички цели

- Прилог Б-1 - Програмски код во Python за тренинг на двослоен модел за дијагностички цели, со примена на алгоритмот на машини со поддржувачки вектори, алгоритмот на случајни шуми, алгоритмот на градиентно зголемување и комбинирани модели чии резултати се дадени во табели 14, 15 и 16, од глава 4.2
- Прилог Б-2 - Програмски код во Python за анализа на нивото на значајност на екстрахирани карактеристики чии резултати се дадени на слика 59 и табела 17 од глава 4.3
- Прилог Б-3 - Програмски код во Python за анализа на компјутерска ефикасност чии резултати се дадени во табели 18 и 19 од глава 4.4

Прилог В - Конфузни матрици од тестирања на алгоритмите чии резултати се прикажани во табели 15 и 16 од глава 4.2

Прилог Г - Програмски код во Python за валидација на дијагностичките модели

- Прилог Г-1 - Програмски код во Python за валидација на дијагностичките модели со примена на база на податоци снимена во лабораториски услови чии резултати се прикажани во табела 25 од глава 5.1
- Прилог Г-2 - Програмски код во Python за валидација на дијагностичките модели со примена на база на податоци снимена во реални индустриски услови чии резултати се прикажани во табела 29 од глава 5.2

Прилог Д - Програмски код во Python за модел за прогностика

- Прилог Д-1 - Програмски код во Python за обработка на база на податоци за модел за прогностика согласно методологија од глава 6.2
- Прилог Д-2 - Програмски код во Python за екстракција на карактеристики за модел за прогностика согласно табела 34 од глава 6.3
- Прилог Д-3 - Програмски код во Python за тренинг на модел за прогностика согласно методологија од глава 6.4
- Прилог Д-4 - Програмски код во Python за валидација на модел за прогностика чии резултати се прикажани во табела 38 од глава 6.5

Прилог Г - Криви на преостанат корисен век согласно резултатите од табела 38 глава 6.5