

VILNIAUS GEDIMINO TECHNIKOS UNIVERSITETAS

Tadas ŽVIRBLIS

PROGNOSTINIŲ IR MAŠININIO MOKYMOSI
MODELIŲ TAIKYMAS MECHATRONINIŲ
SISTEMŲ PARAMETRAMS PROGNOZUOTI
IR GEDIMAMS KLASIFIKUOTI

DAKTARO DISERTACIJA

TECHNOLOGIJOS MOKSLAI,
MECHANIKOS INŽINERIJA (T 009)

Vilnius 2022

Disertacija rengta 2018–2022 metais Vilniaus Gedimino technikos universitete.

Vadovas

doc. dr. Artūras KILIKEVIČIUS (Vilniaus Gedimino technikos universitetas, mechanikos inžinerija – T 009).

Vilniaus Gedimino technikos universiteto Mechanikos inžinerijos mokslo krypties disertacijos gynimo taryba:

Pirmininkas

prof. habil. dr. Rimantas BELEVIČIUS (Vilniaus Gedimino technikos universitetas, mechanikos inžinerija – T 009).

Nariai:

prof. dr. Arnas KAČENIAUSKAS (Vilniaus Gedimino technikos universitetas, mechanikos inžinerija – T 009),

doc. dr. Olga KURASOVA (Vilniaus universitetas, informatikos inžinerija – T 007),

dr. Olga ORYNYCZ (Balstogės technologijos universitetas, Lenkija, mechanikos inžinerija – T 009),

prof. dr. Artūras SERACKIS (Vilniaus Gedimino technikos universitetas, elektros ir elektronikos inžinerija – T 001).

Disertacija bus ginama viešame Mechanikos inžinerijos mokslo krypties disertacijos gynimo tarybos posėdyje **2022 m. birželio 13 d. 9 val.** Vilniaus Gedimino technikos universiteto senato posėdžių salėje.

Adresas: Saulėtekio al. 11, LT-10223 Vilnius, Lietuva. Tel.: (8 5) 274 4956; faksas (8 5) 270 0112; el. paštas: doktor@vilniustech.lt

Pranešimai apie numatomą ginti disertaciją išsiusti 2022 m. gegužės 12 d.

Disertaciją galima peržiūrėti Vilniaus Gedimino technikos universiteto talpykloje <http://dspace.vgtu.lt> ir Vilniaus Gedimino technikos universiteto bibliotekoje (Saulėtekio al. 14, LT-10223 Vilnius, Lietuva).

Vilniaus Gedimino technikos universiteto 2022-022-M mokslo literatūros knyga doi:10.20334/2022-022-M

Parengta L^AT_EX₂_ε sistema

© Vilniaus Gedimino technikos universitetas, 2022

© Tadas Žvirblis, 2022

tadas.zvirblis@vilniustech.lt

VILNIUS GEDIMINAS TECHNICAL UNIVERSITY

Tadas ŽVIRBLIS

APPLICATION OF PREDICTIVE AND MACHINE
LEARNING MODELS FOR MECHATRONIC
SYSTEMS PARAMETERS PREDICTION
AND FAULT CLASSIFICATION

DOCTORAL DISSERTATION

TECHNOLOGICAL SCIENCES,
MECHANICAL ENGINEERING (T 009)

Vilnius 2022

Doctoral dissertation was prepared at Vilnius Gediminas Technical University in 2018–2022.

Scientific supervisor

Assoc. Prof. Dr Artūras KILIKEVIČIUS (Vilnius Gediminas Technical University, Mechanical Engineering – T 009).

The Dissertation Defense Council of Scientific Field of Mechanical Engineering of Vilnius Gediminas Technical University:

Chairman

Prof. Dr Habil. Rimantas BELEVIČIUS (Vilnius Gediminas Technical University, Mechanical Engineering – T 009).

Members:

Prof. Dr Arnas KAČENIAUSKAS (Vilnius Gediminas Technical University, Mechanical Engineering – T 009),

Assoc. Prof. Dr Olga KURASOVA (Vilnius University, Informatics Engineering – T 007),

Dr Olga ORYNYCZ (Bialystok University of Technology, Poland, Mechanical Engineering – T 009),

Prof. Dr Artūras SERACKIS (Vilnius Gediminas Technical University, Electrical and Electronic Engineering – T 001).

The dissertation will be defended at the public meeting of the Dissertation Defense Council of Mechanical Engineering in the Senate Hall of Vilnius Gediminas Technical University at **9 a. m. on 13 June 2022.**

Address: Saulėtekio al. 11, LT-10223 Vilnius, Lithuania. Tel. +370 5 274 4956; fax +370 5 270 0112; e-mail: doktor@vilniustech.lt

A notification on the intend defending of the dissertation was send on 12 May 2022. A copy of the doctoral dissertation is available for review at Vilnius Gediminas Technical University repository <http://dspace.vgtu.lt> and at the Library of Vilnius Gediminas Technical University (Saulėtekio al. 14, LT-10223 Vilnius, Lithuania).

Reziumė

Pastaruoju metu kuriant vis sudėtingesnes mechatronines sistemas susiduriama su įvairiomis šių sistemų eksploatavimo problemomis: priežiūra, palaikymu, gedimų identifikavimu bei šalinimu. Sudėtingų sistemų eksploatavimas reikalauja ieškoti naujų šiuolaikiškų šių problemų sprendimo būdų. Mokslinėje literatūroje ir praktikoje jau kuris laikas yra vystomi netiesioginiai mechatroninių sistemų priežiūros metodai tokie kaip virpesių analizė.

Iš surinktų virpesių duomenų reikalingai informacijai išgauti taikomi dviejų tipų metodai: signalo apdorojimo ir duomenų struktūros požymių atpažinimo. Šie metodai remiasi automatizuotais duomenų apdorojimo algoritmais. Duomenų struktūros požymių atpažinimo metodai apima tris pagrindines dalis: duomenų rinkimą, požymių išskyrimą ir požymių atpažinimą. Šį darbą dabar jau gali atlikti dirbtinio intelekto sistemos su integruotais mašininio mokymosi modeliais gebančiais apdoroti itin kompleksiškus ir didelės dimensijos duomenų masyvus.

Disertacijoje pateikiami vidaus degimo variklių ekologinių ir energinių parametrų statistiniai prognozavimo modeliai bei mašininio mokymosi modeliai skirti mechatroninių sistemų gedimams identifikuoti. Pateikti modeliai remiasi mechatroninių sistemų skleidžiamų virpesių bei garso slėgio signalų reikšmių analize. Mašininio mokymosi modeliai taikomi hipoidinės pavaros gedimams bei juostinio konvejerio apkrovos būsenoms identifikuoti.

Disertacijos tema publikuoti 3 moksliniai darbai. Du darbai buvo publikuoti *Clarivate Analytics Web of Science* duomenų bazės leidiniuose, turinčiuose citavimo rodiklį, vienas – kituose leidiniuose. Disertacijoje atliktų tyrimų rezultatai buvo pristatyti 4 mokslinėse konferencijose Lietuvoje ir užsienyje: tarptautinėse konferencijose „Fizyka Uszkodzeń Eksploatacyjnych“, Demblinas (2022); „IEEE 8th Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE’20)“, Vilnius (2021); „ESMO 21st World Congress on Gastrointestinal Cancer, Barselona (2019) bei Lietuvoje vykusioje konferencijoje „10-asis Lietuvos jaunųjų matematikų susitikimas (LJMS’10)“, Vilnius (2021).

Disertaciją sudaro įvadas, trys skyriai, bendrosios išvados ir literatūros šaltinių sąrašas.

Abstract

In recent years, the developers of complex mechatronic systems have faced various of operational problems related to maintenance, support, fault identification, and troubleshooting of the systems. The smooth operation of complex systems requires conducting new research to find novel modern solutions to these problems. As a response to this need, indirect methods for the maintenance of mechatronic systems, e.g., vibration analysis, have been under development around the globe.

Two types of methods are used to extract the required information from the collected vibration data: signal processing methods and data structure pattern recognition methods. The latter methods are based on automated data processing algorithms. Methods for recognizing a pattern in a data structure consist of three main parts: data collection, feature extraction, and feature recognition. These procedures can now be performed by artificial intelligence systems with integrated machine learning models capable of processing highly complex and high-dimensional data arrays.

This dissertation presents statistical models for predicting ecological and energetic parameters of internal combustion engine and machine learning models for identifying failures of a mechatronic system. The presented models are based on vibration and sound pressure signals emitted by mechatronic systems. Machine learning models are applied to identify hypoid gear faults and conveyor belt load states, but the same algorithms can be applied to other rotating mechanisms.

Three scientific works were published on the topic of the dissertation. Two papers were issued in indexed publications of the Clarivate Analytics Web of Science database; one in publications of other international databases. The research results were presented at four scientific conferences in Lithuania and other countries: international conferences “Fizyka Uszkodzeń Eksploatacyjnych”, Deblin (2022); “IEEE 8th Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE’20)”, Vilnius (2021); “ESMO 21st World Congress on Gastrointestinal Cancer”, Barcelona (2019) and Lithuanian conference “10th Lithuanian Young Mathematicians Meeting (LYMM’10)”, Vilnius (2021).

The following main parts comprise this dissertation: introduction, three chapters, general conclusions, and a list of references.

Žymėjimai

Santrumpos

1M-SNT – vienmatis sąsūkos neuroninis tinklas (angl. *One-Dimensional Convolutional Neural Network (1D-CNN)*);

2M-SNT – dvimatis sąsūkos neuroninis tinklas (angl. *Two-Dimensional Convolutional Neural Network (2D-CNN)*);

AIEEE – informacijos, elektronikos ir elektros inžinerijos pažanga. Trumpinys kilęs nuo angliško termino *Advances in Information, Electronic and Electrical Engineering*;

ANCOVA – kovariacinės analizės modelis. Trumpinys kilęs nuo angliško termino *ANalysis Of COVariance*;

ANOVA – dispersinės analizės modelis. Trumpinys kilęs nuo angliško termino *ANalysis Of VAriance*;

AM – atsitiktiniai miškai (angl. *Random Forest (RF)*);

AVM – atraminių vektorių modelis (angl. *Support Vector Machine (SVM)*);

BK – biodujų kompozicija;

DĮS – diržo įtempio signalas;

DNT – dirbtinių neuroninių tinklai (angl. *Artificial Neural Network (ANN)*);

EGR – išmetamųjų dujų recirkuliacija (angl. *Exhaust Gas Recirculation*);

GNT – gilieji neuroniniai tinklai (angl. *Deep Neural Network (DNN)*);

HP – hipoidinė pavara;

HVO – hidrintas augalinis aliejus;
 IEEE – Elektros ir elektronikos inžinierių institutas. Trumpinys kilęs nuo angliško termino *Institute of Electrical and Electronics Engineers*;
 ITAM – ilgos trumpalaikės atminties modelis (angl. *Long Short-Term Memory (LSTM)*);
 JK – juostinis konvejeris;
 JKD – juostinio konvejerio diržas;
 kAK – k artimiausi kaimynai (angl. *k-Nearest Neighbors (kNN)*);
 LARS – mažiausio kampo regresija (angl. *Least-Angle Regression*);
 LASSO – mažiausio absoliutaus susitraukimo ir atrankos operatoriaus metodas (angl. *Least Absolute Shrinkage and Selection Operator*);
 LJMS – Lietuvos jaunųjų matematikų susitikimas;
 LR – logistinė regresija (angl. *Logistic Regression (LR)*);
 RMS – vidutinis kvadratinis nuokrypis. Trumpinys kilęs nuo angliško termino *Root Mean Square*;
 SND – suskystintos natūralios dujos;
 SNT – sąsūkos neuroninis tinklas (angl. *Convolutional Neural Network (CNN)*);
 TNT – transformerio neuroninis tinklas (angl. *Transformer Neural Network (TNN)*);
 TRM – tiesinis regresijos modelis (angl. *Linear Regression Model (LRM)*);
 VAPP – vidutinė absoliuti procentinė paklaida (angl. *Mean Absolute Percentage Error (MAPE)*);
 VDV EEP – vidaus degimo variklių ekologiniai ir energiniai parametrai;
 VS – virpesių signalas.

Turinys

IVADAS.....	1
Problemos formulavimas.....	1
Darbo aktualumas	2
Tyrimų objektas	2
Darbo tikslas	2
Darbo uždaviniai	3
Tyrimų metodika	3
Darbo mokslinis naujumas	3
Darbo rezultatų praktinė reikšmė	4
Ginamieji teiginiai	4
Darbo rezultatų aprobavimas	5
Disertacijos struktūra	5
Padėka	6
 1. PROGNOTINIŲ IR MAŠININIO MOKYMOSI MODELIŲ TAIKymo MECHATRONINĖSE SISTEMOSE MOKSLINĖS LITERATŪROS AP- ŽVALGA	 7
1.1. Prognotiniai modeliai	8
1.2. Klasifikavimo modeliai	21
1.3. Klasifikavimo modelių įgyvendinimo mechatroninėse sistemose ty- rimų apžvalga	28

1.4. Pirmojo skyriaus išvados ir disertacijos uždavinių formulavimas	34
2. PROGNOTINIŲ BEI MAŠININIO MOKYMOSI MODELIŲ SUDARYMAS MECHATRONINIŲ SISTEMŲ PARAMETRAMS PROGNOZUOTI IR BŪKLĖMS KLASIFIKUOTI	37
2.1. Vidaus degimo variklių ekologinių ir energinių parametų prognotinių modelių sudarymas	37
2.2. Mašininio mokymosi klasifikavimo modelių sudarymas	45
2.3. Antrojo skyriaus išvados	57
3. SUDARYTŲ PROGNOTINIŲ BEI MAŠININIO MOKYMOSI MODELIŲ ĮGYVENDINIMAS MECHATRONINĖSE SISTEMOSE	59
3.1. Vidaus degimo variklių ekologinių ir energinių parametų prognozavimas	59
3.2. Hipoidinės pavaros gedimų identifikavimas	81
3.3. Juostinio konvejerio diržo apkrovos identifikavimas	85
3.4. Trečiojo skyriaus išvados	92
BENDROSIOS IŠVADOS	93
LITERATŪRA IR ŠALTINIAI	95
AUTORIAUS MOKSLINIŲ PUBLIKACIJŲ DISERTACIJOS TEMA SĄRAŠAS	105
SUMMARY IN ENGLISH	107

Contents

INTRODUCTION	1
Problem formulation	1
Relevance of the Thesis	2
Research Object	2
Aim of the Thesis	2
Tasks of the Thesis	3
Research Methodology	3
Scientific Novelty of the Thesis	3
Practical Value of the Research Findings	4
Defended Statements	4
Approval of the Research Findings	5
The Structure of the Dissertation	5
Acknowledgement	6
1. REVIEW OF PROGNOSTIC AND MACHINE LEARNING MODELS IN MECHATRONIC SYSTEMS	7
1.1. Prognostic Models	8
1.2. Classification Models	21
1.3. Review of Research on the Implementation of Classification models in Mechatronic Systems	28
1.4. The Conclusions of the First Chapter and the Formulation of the Objectives of the Thesis	34

2. DEVELOPMENT OF PROGNOSTIC AND MACHINE LEARNING MODELS FOR THE PREDICTION OF MECHATRONIC SYSTEM PARAMETERS AND CONDITION CLASSIFICATION	37
2.1. Development of Prognostic Models for Mechatronic System Parameter Prediction	37
2.2. Development of Machine Learning Classification Models	45
2.3. Conclusions of the Second Chapter	57
3. RESULTS OF PROGNOSTIC AND MACHINE LEARNING MODELS FOR THE PREDICTION OF MECHATRONIC SYSTEM PARAMETERS AND CONDITION CLASSIFICATION	59
3.1. Prognostic Models for Mechatronic System Parameter Prediction	59
3.2. Machine Learning Models for Hypoid Gear Fault Classification	81
3.3. Machine Learning Models for the Classification of Conveyor Belt Load Condition	85
3.4. Conclusions of the Third Chapter	92
GENERAL CONCLUSIONS	93
REFERENCES	95
LIST OF SCIENTIFIC PUBLICATIONS BY THE AUTHOR ON THE TOPIC OF THE DISSERTATION	105
SUMMARY IN ENGLISH	107

Išvadas

Problemos formulavimas

Mechatroninės sistemos ir jų komponentai tokie kaip įvairūs varikliai, pavarų dėžės, guoliai, rotoriai, yra lengvai pažeidžiami, o dėl visos sistemos stabdymo, siekiant pašalinti defektą, išauga ekonominiai nuostoliai. Dėl šių priežasčių jau kuris laikas vystomos išmaniosios mechatroninių sistemų būklės stebėjimo ir gedimų identifikavimo technologijos.

Dėl nesudėtingo informacijos surinkimo virpesių analizė yra viena dažniausiai naudojamų diagnostikos priemonių (Yunusa-Kaltungo et al. 2015). Norint iš surinktų virpesių duomenų išgauti informaciją, taikomi dviejų tipų metodai: signalo apdorojimo ir duomenų struktūros požymių atpažinimo (Guo et al. 2016).

Signalų apdorojimo metodai remiasi virpesių formų analizės modeliais. Šie metodai apima gedimo dažnio charakteristikų analizę, kuri naudoja pažangius signalų apdorojimo metodus, tokius kaip vilnelių transformaciją, empirinę modų dekompoziciją ar spektrinę ekscesą (Han et al. 2016; Sun et al. 2017; Tang et al. 2016; Yaqub and Loparo 2016). Visgi šie metodai reikalauja itin aukštos operatoriaus kvalifikacijos, kuris gerai suvoktų mechatroniniuose mechanizmuose vykstančius procesus bei turėtų daug patirties.

Duomenų struktūros požymių atpažinimo metodai pagrįsti automatizuotais duomenų apdorojimo algoritmais, kurie pastaraisiais metais yra sparčiai vystomi (Bogoevska et al. 2017; Cheng et al. 2016; Han et al. 2017; Liu et al. 2014).

Šie metodai apima tris pagrindines dalis: duomenų rinkimą, požymių išskyrimą ir požymių atpažinimą. Neseniai virpesių signalams apdoroti buvo pasiūlyti nauji duomenų struktūros požymių atpažinimo metodai, skirti gedimų diagnostikos algoritmams (Jia et al. 2016; Li et al. 2019b; Shao et al. 2017; Xu et al. 2019). Šie metodai naudoja įvairius mašininio mokymosi algoritmus, tokius kaip dirbtinių neuroninių tinklai, sąsūkos bei rekurentiniai neuroniniai tinklai ar klasikiniai mašininio mokymosi modeliai.

Disertacijoje pateikiami vidaus degimo variklių ekologinių ir energinių parametrų statistiniai prognozavimo modeliai bei mašininio mokymosi modeliai, skirti mechatroninių sistemų gedimams identifikuoti. Pateikti modeliai remiasi mechatroninių sistemų skleidžiamais virpesių ir garso slėgio signalais. Mašininio mokymosi modeliai taikomi hipoidinės pavaros gedimams bei juostinio konvejerio apkrovos būsenoms identifikuoti.

Darbo aktualumas

Mechatroninių sistemų (variklių, konvejerių, pavarų) statistiniai prognostiniai bei mašininio mokymosi modeliai, naudojantys virpesių signalus, atveria galimybes sudėtingus mechanizmus tyrinėti neatliekant didelių (ar visai neatliekant) intervencijų ir nestabdant veikimo proceso. Šių modelių taikymas realiomis sąlygomis gali pagreitinti ir atpiginti sudėtingų mechanizmų priežiūrą.

Naujų prognozavimo ir klasifikavimo modelių kūrimas yra aktualus uždavinys, nes skirtingoms sistemoms turi būti naudojami skirtingi modeliai dėl sistemos savitumo.

Tyrimų objektas

Tyrimų objektas – prognostiniai bei mašininio mokymosi modeliai, skirti mechatroninių sistemų parametrų prognozei bei gedimų klasifikavimui.

Darbo tikslas

Darbo tikslas – sudaryti prognostinius ir mašininio mokymosi modelius, skirtus mechatroninių sistemų parametrų reikšmėms prognozuoti bei gedimams identifikuoti ir klasifikuoti.

Darbo uždaviniai

Darbo tikslui pasiekti reikia išspręsti šiuos uždavinius:

1. Atlikti prognostinių ir mašininio mokymosi modelių, taikomų mechatroninių sistemų parametrų prognozuoti bei gedimams klasifikuoti apžvalgą.
2. Sudaryti darbe tiriamų mechatroninių sistemų prognostinius bei mašininio mokymosi modelius:
 - 2.1. vidaus degimo variklių ekologiniams ir energiniams parametrų prognozuoti;
 - 2.2. hipoidinės pavaros pažaidoms klasifikuoti;
 - 2.3. juostinio konvejerio diržo apkrovos būsenoms klasifikuoti.
3. Įgyvendinti sudarytus modelius, juos taikant realiose mechatroninėse sistemose:
 - 3.1. prognostinių modelių įgyvendinimas prognozuojant vidaus degimo variklių ekologinius ir energinius parametrus;
 - 3.2. mašininio mokymosi modelių įgyvendinimas klasifikuojant hipoidinės pavaros pažaidas;
 - 3.3. mašininio mokymosi modelių įgyvendinimas identifikuojant juostinio konvejerio diržo apkrovos būsenas.

Tyrimų metodika

Darbe taikomos duomenų apdorojimo, mašininio mokymosi ir statistinės analizės metodikos. Prognozavimo uždaviniams spręsti panaudoti įvairūs tiesinės regresijos modeliai: vienmatė ir daugiamatė tiesinė regresija, dispersinė analizė, kovariacinė analizė. Mechatroninių sistemų gedimams ir būklėms klasifikuoti panaudoti giliojo mašininio mokymosi modeliai (ilgos trumpalaikės atminties, transformerių, sąsūkos neuroniniai tinklai) bei kiti klasifikavimo modeliai (atsitiktiniai miškai, atraminių vektorių modeliai, logistinė regresija). Modelių tikslumui įvertinti buvo naudojamos klasifikavimo lentelės ir paklaidų skaičiavimo metodai.

Darbo mokslinis naujumas

1. Sukurtas naujas statistinės analizės algoritmas, leidžiantis sudaryti efektyvius vidaus degimo variklių ekologinių ir energinių parametrų prognostinius modelius.

2. Sudarytas tikslus vidaus degimo variklių ekologinių ir energinių parametų prognostinis modelis iš virpesių bei garso slėgio signalų, apdorotų laiko ir dažnio srities statistiniais parametrais.
3. Lyginant prognostinių modelių tikslumą įrodyta, kad virpesių ir garso slėgio signalų naudojimas prognostiniuose vidaus degimo variklių ekologinių ir energinių parametų modeliuose padidina jų tikslumą.
4. Sudaryti daugelio klasių mašininio mokymosi klasifikavimo modeliai, kurie geba identifikuoti hipoidinės pavaros gedimų tipus naudodami tik virpesių signalus.
5. Sudaryti dviejų klasių mašininio mokymosi klasifikavimo modeliai gebantys identifikuoti juostinio konvejerio diržo aprovimo būseną, naudojant tik diržo įtempio signalą.

Darbo rezultatų praktinė reikšmė

Sukurtas naujas statistinės analizės algoritmas leidžia efektyviai tirti naujus eksperimentinius vidaus degimo variklius, sudaryti jų ekologinių ir energinių parametų prognostinius modelius. Pasiūlytas tikslus prognostinis modelis leidžia įvertinti tiriamų parametų vertes nekartojant eksperimento.

Sudaryti mašininio mokymosi klasifikavimo modeliai naudojantys tik virpesių duomenis įgalina inžinierius atlikti mechatroninių sistemų priežiūros darbus neatliekant intervencinių darbų. Modelius patobulinus ir apmokius su platesnio spektro virpesių duomenimis galima būtų pasiekti labai jautrius klasifikavimo modelius, kurie identifikuotų gedimus dar labai ankstu etapu.

Juostinio konvejerio būsenų identifikavimo modelis leidžia realiuoju laiku įvertinti konvejerio būklę. Modeliai sudaryti naudojant nesubalansuotus duomenis, kas yra labiau susiję su realiomis sąlygomis. Modeliai gali būti praplėsti įtraukiant ne tik pastovias konvejerio apkrovas, bet ir galimas pažaidas, kas leistų visiškai nusakyti konvejerio būklę realiuoju laiku.

Darbe aprašyti modeliai ir surinkti duomenys bus naudojami tolesniems moksliniams tyrimams kaip kontroliniai lyginamieji modeliai ar naujų mokslinių projektų duomenų papildymai.

Ginamieji teiginiai

1. Taikant matematinės statistikos prognozavimo modelius galima sudaryti prognostinius vidaus degimo variklių ekologinių ir energinių parametų modelius, kurių vidutinės absoliučiosios procentinės paklaidos vidurkis neviršija 10 %.

2. Virpesių bei garso slėgio signalų įtraukimas į vidaus degimo variklių ekologinių ir energinių parametrų prognostinius modelius padidina modelių tikslumą.
3. Sąsukos, transformerio neuroninių tinklų bei ilgos trumpalaikės atminties modeliai gali klasifikuoti hipoidinės pavaros pažaidas su nemažesniu nei 80 % tikslumu, klasifikuoti naudojant tik virpesių signalus.
4. Hipoidinės pavaros pažaidų klasifikavimo tikslumas priklauso pavaros sukčių ir sukimo momento.
5. Sąsukos, transformerio neuroninių tinklų ir ilgos trumpalaikės atminties modeliai tiksliau klasifikuoja juostinio konvejerio diržo apkrovos būseną naudojant diržo įtempio signalą negu klasikiniai mašininio mokymosi modeliai.
6. Juostinio konvejerio diržo įtempio signalu atsirandantys atsitiktiniai ir dreifuojantys signalo triukšmai turi reikšmingą įtaką diržo apkrovos būsenų klasifikavimui.

Darbo rezultatų aprobavimas

Disertacijos tema publikuoti 3 moksliniai straipsniai: 2 – *Clarivate Analytics Web of Science* duomenų bazės leidiniuose, turinčiuose citavimo rodiklį (Žvirblis ir kt. 2021a; Kriaučiūnas ir kt. 2021); 1 – kituose leidiniuose (Žvirblis ir kt. 2021b).

Disertacijoje atliktų tyrimų rezultatai buvo pristatyti 4 mokslinėse konferencijose Lietuvoje ir užsienyje:

- Tarptautinėje konferencijoje „Fizyka Uszkodzeń Eksploatacyjnych“, Demblinas (2022).
- Konferencijoje „10-asis Lietuvos jaunųjų matematikų susitikimas (LJMS'10)“, Vilnius (2021).
- Tarptautinėje konferencijoje „IEEE 8th Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE'20)“, Vilnius (2021).
- Tarptautinėje konferencijoje „ESMO 21st World Congress on Gastrointestinal Cancer“, Barselona (2019).

Disertacijos struktūra

Disertaciją sudaro įvadas, trys skyriai: mokslinės literatūros apžvalga, prognostinių ir klasifikavimo modelių sudarymas, prognostinių ir klasifikavimo modelių

įgyvendinimas realiose mechatroninėse sistemose. Pateiktos darbo išvados, literatūros sąrašas.

Darbo apimtis – 106 puslapiai, tekste yra 27 paveikslai, 26 lentelės ir 64 numeruotos formulės. Literatūros sąrašą sudaro 127 šaltiniai.

Padėka

Kelias iki disertacijos rašymo užtruko nemažai laiko, baigus magistrantūros studijas ir toliau pasirinkus įgytų žinių taikymo kryptį, doktorantūros studijos nutolo. Tačiau laimingo atsitiktinumo dėka susipažinau su puikiu žmogumi, mokslininku ir vadovu doc. dr. Artūru Kilikevičiumi, kuris mano sukaupą statistikos mokslo taikymų patirtį nukreipė disertacijos rašymo link. Išskirtinę padėką reiškiu dr. Linui Petkevičiui už nenuilstamą konsultavimą, už šviesos paieškas, kai, regis, sprendimų nebėra. Negaliu nepaminti magistrantūros darbo vadovo dr. Prano Vaitkaus, kuris net po studijų neleido man atitolti nuo mokslinių naujienų bei padėjo žengti pirmuosius mokslinių tyrinėjimų žingsnius. Esu labai dėkingas darbo recenzentams prof. dr. Artūrai Serackiui, prof. dr. Arnui Kačeniauskui, prof. dr. Olgai Kurasovai, doc. dr. Regimantui Bareikiui už kruopštų darbą peržiūrint disertaciją – Jūsų išsakytos pastabos darbą padarė aiškesnį ir nuoseklesnį. Labai dėkoju savo šeimai už supratingumą bei palaikymą, ir atleiskite man už pavogtą iš Jūsų laiką.

Prognostinių ir mašininio mokymosi modelių taikymo mechatroninėse sistemose mokslinės literatūros apžvalga

Šiame skyriuje apžvelgiamas matematinės statistikos metodų taikymas mechatroninių sistemų tyrimuose. Išskiriamos dvi pagrindinės matematinės statistikos taikymo mechatroninėse sistemose kryptys – prognostiniai bei klasifikavimo modeliai.

Skyriuje apibendrinami statistinės analizės metodai skirti prognostinių modelių sudarymui, apžvelgiami tyrimai skirti šių modelių įgyvendinimui įvairiems vidaus degimo variklių parametrams prognozuoti, mechatroninių sistemų tokių kaip guoliai, pavaros, konvejeriai gedimams klasifikuoti. Apžvalgoje minimi metodai skelbti mokslinėse publikacijose (Žvirblis et al. 2021a; Kriaučiūnas et al. 2021) ir mokslinėse konferencijose (Žvirblis et al. 2021, 2021b).

1.1. Prognotiniai modeliai

Matematinė statistika yra bene labiausiai paplitusi tarpdalykinio mokslo šaka, gebanti identifikuoti ir skaitiškai įvertinti plataus spektro objektų sąryšius. Palyginti jaunas statistikos mokslas kaip atskira mokslo šaka prasidėjęs tik XVIII a., dabar yra išsitvirtinęs kone visose mokslo kryptyse (Walker 1975). Mechanikos inžinerijoje pirmosios publikacijos, kuriose taikyti statistiniai metodais pasirodė, pasirodė dar XX a. pradžioje (Shewhart 1924, 1931). Šiose publikacijose autorius siekė statistiškai ir tikimybių teorijos metodais įvertinti inžinerinėse sistemose atsirandančias paklaidas tarp teorinių ir realių duomenų. Buvo nustatyta, kad paklaidas galima aprašyti normaliuoju skirstiniu, tačiau tai yra tik atskiras paklaidų pasiskirstymo atvejis, t. y. paklaidos gali būti įvairių formų.

Analizuojant įvairių mechatroninių sistemų parametrus svarbu žinoti jų teorines pasiskirstymo funkcijas. Turima informacija leidžia tiksliau įvertinti atliekamų eksperimentų baigtis, todėl atliekant teorinius ar standinius eksperimentus yra labai svarbu įvertinti kuo daugiau stebimų parametrų statistikų, tokių kaip vidurkis, dispersija, įvairių eilių momentai ar kvantiliai. Šios statistikos leidžia tiksliau nusakyti stebimo proceso pasiskirstymą (Bury 1999).

Mechatroninių sistemų standiniai simuliaciniai modeliai yra labai naudingi įvertinant tos sistemos veikimą ir patikimumą prieš pradedant sistemą naudoti realiomis sąlygomis. Kartu su sistemų simuliaciniais modeliais sukuriama ir teoriniai matematiniai sistemos parametrų modeliai, kuriuos naudojant teoriškai įvertinami parametrai, jų kitimas keičiantis sistemos būsenoms. Deja, gautos teorinės parametrų reikšmės dažnu atveju yra netapačios eksperimentiniu būdu ar realiomis sistemos eksploatavimo sąlygomis gautoms reikšmėms. Šie parametrų skirtumai vadinami modelių nepastovumu (Hills and Trucano 1999). Kadangi parametrų gavimas eksperimentiniu būdu reikalauja daugiau laiko ir finansinių išteklių, tai dažnai atliekant sistemos testavimą ir kalibravimą yra naudojami statistiniai prognotiniai modeliai.

Taigi, analizuojant mechatroninę sistemą, dažniausiai naudojami dviejų tipų ją apibūdinantys modeliai. Pirmasis modelis ar modelių aibė, vadinama inžineriniais modeliais, grindžiama mechaninio proceso veikimo dėsniais, juos apibrėžiančiais analitiniais baigtinių elementų modeliais. Antrasis modelių tipas yra statistiniai modeliai, sudaromi naudojant eksperimentinius mechatroninės sistemos duomenis (Joseph and Melkote 2009). Kitame to paties autoriaus, darbe (Joseph and Yan 2015), pažymima, kad, kuriant inžinerinius modelius, naudojamos supaprastintos matematinės prielaidos, kurios neatspindi sistemos veikimo realiomis sąlygomis. Šis modelių trūkumas generuoja paklaidas tarp inžinerinio modelio ir eksperimentinių ar realiomis sąlygomis gautų parametrų įverčių. Kaip sprendimą inžinerinio sistemos modelio validacijai siūloma naudoti statistinius prognozavimo modelius (Hills and Trucano 1999; Joseph and Melkote 2009; Joseph and Yan 2015).

Kuriant vis sudėtingesnes mechatronines sistemas, nepakanka sukurti vieno prognostinio modelio arba tiesiog naudojant pradinis duomenis modelis negali prognozuoti sudėtingo proceso, kurį veikia daug vidinių sistemos elementų. Todėl tokioms sudėtingoms sistemoms kuriami daugiapakopiai statistinės analizės ir prognozavimo algoritmai (Eker 2015; Xiang and Tsung 2008).

1.1.1. Matematinės statistikos prognostiniai modeliai

Dažniausiai prognostiniai modeliai yra tiesinės arba netiesinės regresijos empirinės realizacijos, turinčios pavidalą (Davim 2014):

$$Y(\mathbf{x}) = \Phi(\mathbf{x}) + \epsilon, \quad (1.1)$$

čia $\Phi(\mathbf{x})$ – parametrizuojama funkcija

$$\Phi(\mathbf{x}) \in \{f(\mathbf{x}, \beta), \mathbf{x} \in \mathbb{R}^n, \beta \in \mathbb{R}^q\}; \quad (1.2)$$

ir ϵ – atsitiktinis dydis, kitaip dar vadinamas modelio paklaida, kurio vidurkis yra 0.

Prognostinio modelio β parametrų reikšmės yra įvertinamos iš turimos imties duomenų $\{x(k), y(k)\}$, čia $y(k)$ – atsitiktinio dydžio $Y(k)$ realizacija, $k = 1, \dots, N$; N – imties dydis.

Dauguma inžinerinių modelių naudoja tiesinius modelius, tačiau realybėje kai kurie mechatroninių sistemų procesai nėra tiesiški ir jiems prognozuoti yra būtina naudoti netiesinius modelius. Šių modelių parametrus vertinti naudojami tokie skaitiniai metodai kaip Gauso-Niutono (Gauss-Newton), gradientinis ir Levenbergo-Markvardo (Levenberg-Marquardt) algoritmai (Davim 2014).

Tiesinė regresija yra vienas iš bendros tiesinių modelių teorijos taikymo metodų, kai bandoma modeliuoti sąryšį tarp kintamųjų pritaikant tiesinę lygtį prie stebimų duomenų. Vieni kintamieji vadinami nepriklausomaisiais kintamaisiais (dar vadinami faktoriais arba paaiškinamaisiais kintamaisiais), kitas (tik vienas) priklausomuoju kintamuoju. Bendra matematinė tiesinės regresijos išraiška yra tokia:

$$Y = \alpha + \beta \mathbf{x} + \epsilon, \quad (1.3)$$

čia Y – priklausomas kintamasis; $\mathbf{x} = (x_1, x_2, \dots, x_n)$ – nepriklausomųjų kintamųjų vektorius; α – laisvasis regresijos parametras; β – regresijos parametrų vektorius prie nepriklausomojo kintamojo; ϵ – normaliai pasiskirsčiusi regresijos modelio paklaida su nuliniu vidurkiu ir pastovia dispersija σ^2 .

Vienmatės tiesinės regresijos modelis yra atskiras (1.3) modelio atvejis, kai modelį sudaro priklausomasis kintamasis ir tik vienas nepriklausomasis kintamasis:

$$Y = \beta_0 + \beta_1 x_1 + \epsilon, \quad (1.4)$$

čia Y – priklausomasis kintamasis; x_1 – nepriklausomas kintamasis; β_0 – laisvasis regresijos parametras; β_1 – regresijos parametras prie nepriklausomo kintamojo; ϵ – normaliai pasiskirsčiusi regresijos modelio paklaida su nuliniu vidurkiu ir pastovia dispersija σ^2 .

Daugiamatė tiesinė regresija yra tiesinės regresijos atvejis, kai nepriklausomųjų kintamųjų yra daugiau nei vienas. Naudojant daugiamatės tiesinės regresijos modelį galima tirti daugelio faktorių daromą bendrą įtaką priklausomajam kintamajam, kurią sudaro visų faktorių įtakos suma. Tam tikro atskiro faktoriaus įtaka vadinama daline ir nustatoma, darant prielaidą, kad kitų faktorių reikšmės nekinta. Matematinė daugiamatės teisinės regresijos išraiška yra:

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \epsilon, \quad (1.5)$$

čia Y – priklausomasis kintamasis; $x_1, x_2, \dots, x_n$ – nepriklausomieji kintamieji; β_0 – laisvasis regresijos parametras; $\beta_1, \beta_2, \dots, \beta_n$ – regresijos parametrai prie nepriklausomųjų kintamųjų; ϵ – normaliai pasiskirsčiusi regresijos modelio paklaida su nuliniu vidurkiu ir pastovia dispersija σ^2 .

Vienas pagrindinių uždavinių, sudarant tiesinės regresijos lygtis, yra įvertinti nežinomus regresijos parametrus (koeficientus). Mokslinėje literatūroje aprašyti keli metodai kaip būtų galima įvertinti šiuos koeficientus.

Mažiausiųjų kvadratų metodas yra populiariausias metodas, taikomas regresijos parametrų įvertinti. Šiuo metodu apskaičiuojama geriausiai stebimiems duomenims tinkama tiesinė linija, minimizuojanti vertikaliųjų nuokrypių nuo kiekvieno duomenų taško iki linijos kvadratų sumą. Kadangi visi nuokrypiai pirmiausia pakeliami kvadratu, o tik paskui sumuojami, tokiu būdu neigiami nuokrypiai paverčiami teigiamais. Tarkime, turime atsitiktinio dydžio Y stebėjimus Y_i , kuriuos galime užrašyti:

$$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_n x_{in} + \epsilon. \quad (1.6)$$

Tada, vertikaliųjų nuokrypių kvadratų sumą galima užrašyti taip:

$$E(\beta) = \sum_i (y_i - f(x_i, \beta_0, \beta_1, \beta_2, \dots, \beta_n))^2, \quad (1.7)$$

čia $\beta = (\beta_0, \beta_1, \beta_2, \dots, \beta_n)$. $E(\beta)$ pasieks minimumą, kai

$$\frac{\partial E(\beta)}{\partial \beta} = 0. \quad (1.8)$$

Skaičiuojant dalines išvestines, gaunama:

$$\frac{\partial E(\beta)}{\partial \beta_0} = -2 \sum_i^n (y_i - (\beta_0 + \beta_i x_i)), \quad (1.9)$$

$$\frac{\partial E(\beta)}{\partial \beta_i} = -2 \sum_i^n (y_i - (\beta_0 + \beta_i x_i)) x_i, \quad (1.10)$$

kai $i = 1, 2, \dots, m$.

Pažymėję

$$Y = \begin{pmatrix} Y_1 \\ Y_2 \\ \dots \\ Y_m \end{pmatrix}, \quad A = \begin{pmatrix} 1 & x_{11} & x_{12} & \dots & x_{1n} \\ 1 & x_{21} & x_{22} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & x_{m1} & x_{m2} & \dots & x_{mn} \end{pmatrix}, \quad (1.11)$$

gauname parametro β mažiausių kvadratų įvertinį:

$$\hat{\beta} = (A^T A)^{-1} A^T Y. \quad (1.12)$$

Mažiausio absoliutaus nuokrypio ir atrankos operatoriaus metodas sutrumpintai vadinamas LASSO (angliško pavadinimo *Least Absolute Shrinkage and Selection Operator* santumpa). Tarkime, turime duomenų aibę $(Y, \mathbf{x}) = (Y_i, x_i)$, $i = 1, 2, \dots, N$, čia $x_i = (x_{i1}, x_{i2}, \dots, x_{in})^T$ ir Y_i atitinkamai yra nepriklausomieji kintamieji ir atsako kintamieji. Tada tiesinės regresijos LASSO įvertiniai $(\hat{\alpha}, \hat{\beta})$ yra apibrėžti (Tibshirani 1996):

$$(\hat{\alpha}, \hat{\beta}) = \arg \min \left\{ \sum_{i=1}^N \left(y_i - \alpha - \sum_j \beta_j x_{ij} \right)^2 \right\} \text{ esant ribojimams } \sum_j |\beta_j| \leq t, \quad (1.13)$$

čia α, β – regresijos parametrai; t – reguliarizacijos laipsnis.

Elastinio tinklo (Elastic Net) parametrų vertinimo metode yra įvedami papildomi baudos daugikliai λ_2, λ_1 . Tarkime, turime duomenų aibę $(Y, \mathbf{x}) = (Y_i, x_i)$, $i = 1, 2, \dots, N$, čia $x_i = (x_{i1}, x_{i2}, \dots, x_{in})^T$ ir Y_i atitinkamai yra nepriklausomieji kintamieji ir atsako kintamieji. Tam, kad apibrėžtume regresijos parametrus, gautus naudojant elastinio tinklo algoritmą $\hat{\beta}$ (ElasticNet), pirmiausia apsibrėžkime paprastąjį elastinio tinklo kriterijų (Zou and Hastie 2005):

$$L(\lambda_1, \lambda_2, \beta) = |Y - \beta \mathbf{x}|^2 + \lambda_2 |\beta|^2 + \lambda_1 |\beta|_1, \quad (1.14)$$

čia λ_2, λ_1 – baudos daugikliai, o

$$|\beta|^2 = \sum_{i=1}^n \beta_i^2, \quad |\beta|_1 = \sum_{i=1}^n |\beta_i|. \quad (1.15)$$

Tada paprastojo elastinio tinklo įvertis $\hat{\beta}$ minimizuoja (1.14):

$$\hat{\beta} = \arg \min_{\beta} \{L(\lambda_1, \lambda_2, \beta)\}. \quad (1.16)$$

Lema (Tibshirani 1996):

Tarkime turime $(Y, \mathbf{x})$, (λ_1, λ_2) ir išplėstų duomenų aibę $(Y^*, \mathbf{x}^*)$, čia

$$\mathbf{x}_{(n+p) \times p}^* = (1 + \lambda_2)^{-1/2} \begin{pmatrix} \mathbf{x} \\ \mathbf{I}\sqrt{\lambda_2} \end{pmatrix}, \quad Y_{(n+p)}^* = \begin{pmatrix} Y \\ \mathbf{0} \end{pmatrix}. \quad (1.17)$$

Tada, jeigu $\hat{\beta}^*$ yra išplėstų duomenų aibės paprastojo elastinio tinklo parametro įvertis, tai:


$$\hat{\beta} = \frac{1}{\sqrt{1 + \lambda_2}} \hat{\beta}^* \quad (1.18)$$

yra duomenų aibės $(Y, \mathbf{x})$ paprastojo elastinio tinklo parametro įvertis.

Mažiausio kampo regresija (angl. *Least-Angle Regression*, LARS) yra pažingsninės regresijos tipas, kai kiekvieno žingsnio metu pridamas vienas parametras. Algoritmo seka yra:

1. Algoritmas pradedamas su $\beta_j = 0, j = 1, 2, \dots, p$.
2. Randamas prediktorius x_j , kuris labiausiai koreliuoja su y .
3. β_j padidinamas kryptimi, kuri labiausiai koreliuoja su y , ir sustojama, kai randamas kitas x_k , kurio koreliacija yra lygi arba didesnė už x_j .
4. Padidinamas (β_j, β_k) kryptimi, kuri yra lygiakampė tiek x_j , tiek x_k .
5. Algoritmas tol, kol modelyje atsiranda visi prognostiniai parametrai.

Dispersine analize paremti modeliai yra tiesinės regresijos atvejai, kai modelio priklausomasis kintamasis užrašomas naudojant kokybinius nepriklausomuosius kintamuosius vadinamas dispersine analize. Dispersinės analizės tikslas – palyginti priklausomojo kintamojo vidurkių tarp kokybinio nepriklausomojo kintamojo (faktoriaus) lygių. Pagrindiniai dispersinės analizės modeliai yra ANOVA (angl. *Analysis of variance*) ir ANCOVA (angl. *Analysis of covariance*). ANCOVA modelio atveju statistinė analizė dažnai vadinama *kovariacine analize*.



1.1 pav. Eksperimento schema, kai duomenų analizei taikomas ANOVA modelis

Fig. 1.1. Experimental scheme when ANOVA model is used for data analysis

ANOVA modelis skirstomas į tris tipus (1.1 pav.):

1. Vienfaktorė ANOVA, kai modelyje yra 1 nepriklausomasis kategorinis kintamasis, pvz., variklio galia.
2. Dvifaktorė ANOVA, ai modelyje yra 2 nepriklausomieji kategoriniai kintamieji, pvz., variklio galia ir sūkliai.
3. Daugiafaktorė ANOVA, kai modelyje yra daugiau nei 2 nepriklausomieji kategoriniai kintamieji, pvz., variklio galia, sūkliai, sukimo momentas ir kt.

Bendra matematinė vienfaktorio ANOVA modelio išraiška yra tokia:

$$Y_{ij} = \mu_i + \epsilon_{ij} = \mu + \alpha_i + \epsilon_{ij}, \quad (1.19)$$

čia Y_{ij} – i -tojo faktoriaus lygio priklausomoko kintamojo stebėjimai; μ_i – i -tojo faktoriaus lygio vidurkis; μ – bendras imties vidurkis; $\alpha_i = \mu_i - \mu$ – i -tojo faktoriaus lygio efektas; ϵ_{ij} – nepriklausomai pasiskirstę normalieji atsitiktiniai dydžiai su nuliniu vidurkiu ir dispersija σ^2 .

ANCOVA taip pat yra vienas iš TRM taikymo atvejų. ANCOVA modelis yra labai panašus į ANOVA modelį, t. y. analizės metu tikrinama vidurkių lygybė tarp faktoriaus lygių, tik čia atsižvelgiama į papildomų kintamųjų (kovariančių) įtaką priklausomajam kintamajam.

Tarkime, eksperimento metu fiksuojame kintamojo Y reikšmės Y_{ij} , $j = 1, 2, \dots, J_i$, $i = 1, 2, \dots, I$. Be to, papildomai buvo fiksuotos tiesiškai susijusios kovariantės X reikšmės X_{ij} . Tada, eksperimento stebėjimai aprašomi ANCOVA modeliu:

$$Y_{ij} = \mu_i + \epsilon_{ij} = \mu + \alpha_i + \beta X_{ij} + \gamma_i X_{ij} \times \mathbb{I}_i + \epsilon_{ij}, \quad (1.20)$$

čia Y_{ij} – i -tojo faktoriaus lygio priklausomojo kintamojo stebėjimai; μ_i – i -tojo faktoriaus lygio vidurkis; μ – bendras imties vidurkis; $\alpha_i = \mu_i - \mu$ – i -tojo fak-

toriaus lygio efektas; β – regresijos koeficientas prie kovariantės X_{ij} ; X_{ij} – kovariantė (kiekybinis kintamasis); γ_i – faktoriaus lygio $\mathbb{I}_i$ ir kovariantės sąveikos efektas; ϵ_{ij} – nepriklausomai pasiskirstę normalieji atsitiktiniai dydžiai su nuliniu vidurkiu ir dispersija σ^2 .

1.1.2. Vidaus degimo variklių ekologinių ir energinių parametrų tyrimų apžvalga

Reikalavimai transporto priemonių išmetamųjų teršalų rodikliams tampa vis griežtesni siekiant aplinkosauginės naudos (Śladkowski 2020). Šiuo tikslu transporto priemonėse buvo panaudotos dekarbonizacijos programos, skirtos švarių, mažai anglies dioksido į aplinką išskiriančių degalų naudojimui. Ambicingi tikslai sumažinti pavojingųjų junginių koncentracijas išmetamosiose dujose buvo papildyti griežtais kietųjų dalelių koncentracijos ir tūrio mažinimo reikalavimais (Haasz et al. 2018), kurie jau perkelti į teisinę bazę (Euro standarto 6 reikalavimai) (Fuc et al. 2017).

Išmetamųjų dujų kenksmingumas yra ribojamas naudojant alternatyvius degalus (Murugesan Arthanarisamy 2016). Padidinus etanolio priedo koncentraciją degalų mišiniuose, variklis veikia garsiai ir pablogėja jo veikimo kokybė. Šiai problemai išspręsti buvo naudojami įvairūs išmetamųjų dujų reguliavimo (toliau – EGR) scenarijai, kai padidinus EGR greitį sumažėjo šiluminis efektyvumas (Saranvanan et al. 2020). Kitas būdas – vandenilio tiekimas, tačiau kartu tiekiant jį etanolio ir vandenilio, padidėjo suodžių koncentracija (EL-Seesy et al. 2020; Zöldy 2011). Deguonies ir dyzelino mišinių naudojimas yra efektyvus būdas sumažinti suodžių koncentracijas, nes tai leidžia sumažinti išmetamųjų dujų komponentų kenksmingumą (Jamrozik et al. 2018) (išskyrus NO_x , kurio koncentracija didėja esant aukštesnei temperatūrai (Mirhashemi and Sadri 2020)). Tai gali būti įvairūs dibutilo maleato ir dyzelino (Sevinc and Hazar 2020) bei biodyzelino mišiniai (pradedant palmių aliejaus (Raghuvaran et al. 2021), riebalų (Banković-Ilić et al. 2014), rapsų aliejaus (Rimkus et al. 2020) ir baigiant dyzelino esteriais).

Kitas variantas – naudoti hidrintųjų augalinių aliejų (HVO) mišinius su dyzelinu ir sojų pupelių aliejaus metilo esterio su dyzelinu. HVO mišinių su dyzelinu savybės ne tik pagerina variklio aplinkosaugos rodiklius, bet ir leidžia pasiekti geresnes jų eksploatacines charakteristikas (Aatola et al. 2008; Zöldy 2020), ypač optimizuojant pagrindinį degalų įpurškimo laiką (Dimitriadis et al. 2020). Į dyzelino ir HVO mišinius pridėjus feroceno nanodalelių (7 % HVO) NO_x koncentracija gali sumažėti 30 % (Dobrzyńska et al. 2020), o naudojant įvairias EGR strategijas padidėja THC ir CO koncentracija esant aukštam EGR režimui (Hunicz et al. 2020).

Kalbant apie sojų aliejaus metilo esterio mišinius su dyzelinu, taip pat buvo pastebėtas jų naudojimo poveikis aplinkai, kartu pabrėžiantis tokių mišinių stabi-

lumą ir taravimą (Romig and Spataru 1996). Sojų pupelių aliejaus metilo esterio klampumas, kuris yra 10 kartų didesnis nei dyzelino, yra dar viena reikšminga problema, todėl jo naudojimas yra labai ribotas, ypač esant žemesnei nei nulinei aplinkos temperatūrai (San José Alonso et al. 2008).

Literatūros apžvalgoje siūlomi variklių aplinkosaugos problemų sprendimai, naudojant įvairiuose šaltiniuose minimus biodyzelinus. Kita vertus, naudojant tokius degalus, variklio virpesiai sumažėja, ypač kai kalbama apie dviejų degalų variklį (Omar et al. 2017). Įvairių priedų (tokių kaip DTiCuN100 (dyzelinas + 50 ppm TiO_2 (titano (IV) dioksidas (TiO_2)) + 50 ppm $\text{Cu}(\text{NO}_3)_2$ (vario (II) nitratas ($\text{Cu}(\text{NO}_3)_2$) ir DTiCeA100 (dyzelinas) naudojimas + 50 ppm TiO_2 + 50 ppm $\text{Ce}(\text{CH}_3\text{CO}_2)_3 \cdot \text{H}_2\text{O}$ (cerio(III) acetato hidratas)) leido sumažinti variklio virpesius ir garso lygį visais variklio darbo režimais (Yaşar et al. 2019). Tai leidžia daryti išvadą, kad lygis garso slėgis ir virpesiai gali būti mažesni naudojant įvairius degalų priedus, lyginant su standartiniu EN590 dyzelinu. Tai pažymėta naudojant atliekos kepimo alyvos mišinius su dyzelinu, o virpesiai dar labiau sumažėjo pridėjus vandenilio (Çalik 2018). Tyrimai su vandeniliu ir dyzeliniais mišiniais taip pat patvirtina šią tendenciją, tačiau galima pabrėžti, kad virpesiai proporcingai didėja didinant variklio apkrovą (Nag et al. 2019). Tačiau tokie virpesių tyrimai labiau skirti nustatyti virpesių lygiams, pasireiškiantiems naudojant skirtingus biodegalus – Calophyllum inophyllum biodegalų mišinius su dyzelinu (Ong et al. 2017), trijų komponentų dyzelino – saulėgrąžų aliejaus – HHO, dyzelino – rapsų aliejaus – HHO ir dyzelino – kukurūzų aliejaus – HHO mišinius (Uludamar et al. 2017).

1.1.3. Vidaus degimo variklių ekologinių ir energinių parametru prognostinių modelių apžvalga

Per pastaruosius dešimtmečius tyrėjai pristatė nemažai transporto priemonių emisijų prognostinių modelių, viena iš pirmųjų platesnės apimties modelių apžvalga buvo išleista knygoje (Coburn 2001). Dažniausiai naudojami tiesiniai ANOVA modeliai, nes daugeliu atvejų tiriama, kaip variklio emisijų kiekiai priklauso nuo fiksuotų variklio parametru, tokių kaip degalų tipas, apkrova, sūkliai ir pan. Nemažėjantis publikacijų šia tema skaičius rodo, kad uždavinys nėra išspręstas, į analizę įtraukiami novatoriški mašininio mokymosi modeliai.

Keletas skirtingų statistinių metodų buvo aprašyti ir realizuoti Monyem ir Van Gerpen (2001). Šio tyrimo tikslas – ištirti, ar degalų cheminės sudėties pokyčiai, kuriuos sukelia oksidacija, sukelia reikšmingus variklio darbo ir emisijų pokyčius. Pirmiausia buvo sudaryta faktorinės analizės schema, kurioje priklausomasis kintamasis (emisijos, degalų sąnaudos ir kt.) buvo stebimas visose nepriklausomų kintamųjų lygių kombinacijose. Tačiau autoriai pažymi, kad visos apimties eks-

perimento faktorinės analizės schema negalėjo būti atlikta, nes dėl eksperimento apimties nebuvo galima atlikti per vieną dieną, todėl bandymai turėjo būti išskaidyti per kelias dienas. Tokiu būdu atliktas eksperimentas galimai gali turėti papildomą neapibrėžtą eksperimento duomenų sklaidą atsirandančią dėl eksperimento sustabdymo ir jo tęsimo jau kitą dieną. Dėl šios priežasties faktorinės analizės schemą autoriai pakeitė išskaidyto eksperimento schema, kuri buvo sudaryta iš dviejų dalių. Pirmoji dalis buvo sudaryta iš 3×3 lotynų kvadrato, ji atspindėjo dienos eksperimento planą, o antroji dalis buvo sudaryta iš 2×5 faktorinio eksperimento plano ir atspindėjo paties eksperimento planą. Galiausiai statistinė analizė ir parametrų įverčiai buvo apskaičiuoti naudojant ANOVA statistinį modelį. Sudarytame ANOVA modelyje variklio darbas ir emisijų kiekiai buvo vertinami atsižvelgiant į degalų oksidacijos lygį, degalų partijos numerį ir amžių, degalų tipą, apkrovą, įpurškimo laiką bei visas galimas sąveikas tarp degalų tipo, apkrovos ir įpurškimo laiko. Atlikta statistinė analizė parodė, kad degalų oksidacijos lygis bei įvairūs mišiniai neturėjo įtakos variklio darbui, lyginant grynus komercinius degalus, tačiau degalų mišinių sąnaudos buvo didesnės. Oksiduotas biodyzelinas 28 % sumažino CO emisijas lyginant su grynu dyzelinu, ir 15 %, lyginant su neoksiduotu biodyzelinu. Grynasis biodyzelinas ir jo mišiniai generavo mažesnes nesudegusių angliavandenilių emisijas, kurios buvo net 51 % mažesnės nei gryno dyzelino. Taip pat verta paminėti, kad NO_x emisijos buvo apie 14 % didesnės naudojant gryną biodyzeliną nei paprastą dyzeliną.

ANOVA modelis yra paprastas ir patogus statistinis metodas, kai reikia įvertinti įvairius pavienius kokybinius parametrus bei jų sąveikas variklių emisijų kiekiams prognozuoti. Sivaramakrishnan ir Ravikumar (2014) tyrime buvo sudaryti stabdžių šiluminio efektyvumo, specifinių stabdžių degalų sąnaudų, angliavandenilių, anglies monoksido ir azoto oksidų ANOVA modeliai. Nepriklausomaisiais kintamaisiais buvo pasirinkti suspaudimo santykis, degalų mišiniai ir variklio galia. Realizuotų modelių adaptuotasis R^2 buvo itin aukštas ir siekė >90 %, o stabdžių šiluminio efektyvumo, specifinių stabdžių degalų sąnaudų ir azoto oksidų adaptuotasis R^2 buvo lygus 100 %. Išvados autoriai papildomai pažymi, kad eksperimento planas įtraukiantis statistinę analizę pagreitino duomenų analizę ir leido sumažinti eksperimentų kieki.

Didelės apimties tyrimas, nagrinėjantis skirtingų tipų variklių degalų sunaudojimo kieki ir anglies dioksido emisijas, pristatomas Hien ir Kor (2022) publikacijoje. Autoriai analizuoja skirtingų gamintojų automobilių parametrus, taikydami vienmatės tiesinės bei polinominės regresijos modelius, giliojo mokymosi modelius. Įdomu tai, kad geriausių rezultatų pasiekama naudojant paprasčiausią tiesinės regresijos modelį (TRM). Sąsūkos neuroninis tinklas (SNT) buvo prasčiausias, tačiau autoriai pažymėjo, kad SNT pademonstravo gerą teigiamos reikšmės prognozavimo įvertį, todėl šį modelį verta tobulinti ir naudoti panašioms ateities tyrimams.

Ramachander et al. (2021) publikacijoje yra sudaryti prognostiniai modeliai paremti ANOVA metodologija. Daugiau nei dešimčiai įvairių variklio parametru buvo sudaryti prognostiniai modeliai su variklio apkrovos, degalų įpurškimo slėgio ir laiko įeities parametrais. Sudarytas ANOVA modelis parodė, kad variklio apkrova buvo statistiškai reikšminga beveik visiems prognozuojamiems parametrams (nereikšminga buvo tik NO_x). Degalų įpurškimo slėgis ir laikas kaip prognostinių faktoriai buvo reikšmingi mažesniai prognozuojamų parametru skaičiui. Sudarydami prognostinių modelių autoriai papildomai įtraukė visų įeities parametru porines sąveikas, bet pačių įeities parametru kvadratinės išraiškas. Modelio parametru įverčių reikšmės parodė, kad nevisos sąveikos veikia modelio išeitis. Tokiu atveju rekomenduojama, kad iš modelio reiktų pašalinti nereikšmingus sąveikos faktorius, tačiau publikacijoje nėra aišku ar tai autorių buvo padaryta.

Kelionės laiko, emisijų ir degalų sunaudojimo prognostiniai modeliai buvo sudaryti Capiello et al. (2002). Pateikti modeliai gali būti integruoti su įvairiais eismo modeliais tam, kad būtų galima numatyti erdvinį ir momentinį eismo pasiskirstymą bei įvertinti eismo valdymo strategijas. Prognostiniai modeliai buvo sudaryti taikant regresijų modelių metodologiją bei apkrova pagrįstą išmetamųjų teršalų modeliavimo metodą. Modelis buvo apibrėžtas:

$$E_i = \begin{cases} \alpha_i + \beta_i \nu + \gamma_i \nu^2 + \delta_i \nu^3 + \zeta_i a \nu, & \text{kai } P_{tract} > 0, \\ \alpha'_i, & \text{kai } P_{tract} = 0, \end{cases} \quad (1.21)$$

čia E_i – variklio i -tasis ekologinis ar energinis parametras; P_{tract} – apskaičiuojama pagal formulę:

$$P_{tract} = A\nu + B\nu^2 + C\nu^3 + Ma\nu + Mg \sin \theta \nu, \quad (1.22)$$

čia ν – automobilio greitis (m/s); a – automobilio pagreitis (m/s^2); A – riedėjimo pasipriešinimo koeficientas (kW/m/s); B – riedėjimo pasipriešinimo greičio korekcijos koeficientas ($\text{kW}/(\text{m/s})^2$); C – oro pasipriešinimo koeficientas ($\text{kW}/(\text{m/s})^3$); M – automobilio masė (kg); g – laisvo kritimo pagreitis ($9,81 \text{ m/s}^2$); θ – kelio posvyris (laipsniai).

Tyrimo rezultatai parodė, kad modeliai duoda patikimus rezultatus lyginant su faktiniais matavimais, taip pat su rezultatais, gautais naudojant išsamų modalinės emisijos modelį (angl. *Comprehensive Modal Emission Model*, *CMEM*). Degalų sąnaudų ir anglies dioksido prognostinių modelių tikslumas buvo labai aukštas ($R^2 > 97 \%$), tačiau anglies monoksido ir azoto oksidų tikslumas buvo mažesnis ($84 \% \leq R^2 \leq 80 \%$), bet pakankamas, o angliavandenilių modelio tikslumas buvo mažai tikslus ($53 \% \leq R^2 \leq 63 \%$).

Kolumbijos mokslininkai taip pat sudarė vidaus degimo variklių ekologinių ir energinių parametų prognostinius modelius taikydami ANOVA metodą (Mejia et al. 2020). Tačiau šiame tyrime autoriai rėmėsi prognostinio modelio mokymosi ir testavimo planu, atitinkamai naudojant 80 % ir 20 % eksperimento duomenų. Naudodami apmokytus modelius tyrėjai sudarė CO, O₂, CO₂, NO, NO₂ ir NO_x emisijų žemėlapius, kurie gali būti naudingi rutiniškai kalibruojant variklius ar po remonto. Išvadose tyrėjai tvirtina, kad buvo sukurta sėkminga statistinių modelių sudarymo metodologija, tačiau CO mokymosi ir testavimo modelių R^2 buvo tik 85,5 %, o tai nėra aukštas rezultatas, siekiant ateityje modelį naudoti variklių kalibravimo procese.

Viena iš pirmųjų publikacijų aprašanti vidaus degimo variklių ekologinių ir energinių parametų kiekių prognozavimo galimybę, naudojant dirbtinių neuronų tinklus (DNT) yra Çay et al. (2013). Autoriai sudarė trijų sluoksnių DNT modelį gebantį prognozuoti lyginamąsias degalų sąnaudas, CO, nesudegusį angliavandenilį ir oro bei degalų mišinio santykį. Modelio įeities parametrai buvo degalų tipas, variklio sūkliai, sukimo momentas ir degalų srautas. DNT mokymuisi buvo panaudoti keturi skirtingi metodai: atgalinio sklidimo kvazi-Niutono, Levenbergo-Markvardo, elastingas atgalinio sklidimo bei mastelio konjungato gradientinis atgalinio sklidimo algoritmai. Tyrimo metu nustatyta, kad lyginamųjų degalų sąnaudų, CO, nesudegusio angliavandenilio ir oro bei degalų mišinio santykio DNT prognostiniai modeliai prognozavo neviršydami priimtinos paklaidos (± 5 %). Šie rezultatai rodo, kad DNT mokymosi pajėgumas yra galingas prognozuojant BSFC, CO, HC ir AFR. Autoriai daro išvadą, kad DNT yra gera alternatyva kitiems įprastiems prognostiniams metodams lyginamųjų degalų sąnaudų ir išmetamųjų teršalų kiekio modeliams.

Dar vienas išsamus tyrimas atliktas siekiant įvertinti, ar statistinio modeliavimo metodas gali prognozuoti variklio efektyvumą ir išmetamųjų teršalų kiekį bet kokiomis sąlygomis ir jau kalibruotam kibirkštinio uždegimo varikliui (Fu et al. 2022). Šiame tyrime naudojamas DNT algoritmas, kurio modelio įeities parametrai yra variklio sūkliai ir apkrovos, o modelio išeities parametrai yra degalų sąnaudos ir teršalų emisijos. Autoriai sudarė du tos pačios architektūros DNT, kurie vienas nuo kito skyrėsi paslėptų sluoksnių skaičiumi. Pirmasis modelis, sudarytas iš vieno paslėpto sluoksnio su 9 parametrais, buvo mažiau tikslus prognozuojant degalų sąnaudas, angliavandenilių, anglies monoksido ir azoto oksidų emisijas, atitinkamai R^2 buvo 89 %, 62 %, 88 % ir 90 %. Neuroninis tinklas su dviem paslėptais sluoksniais (kiekvienas jų turi 9 parametrus) buvo tikslesnis ir R^2 atitinkamai buvo 95 %, 94 %, 96 % ir 96 %. Būtina pažymėti, kad įeities parametrai (variklio sūkliai ir apkrovos) buvo tolydūs, t. y. kintantys laike, o tai maksimaliai priartina sudarytų modelių naudojimą realiomis sąlygomis. Autoriai daro išvadą, kad DNT yra tinkamas juodosios dėžės modeliavimo metodas, kuris gali veiksmingai prognozuoti variklio teršalų parametrus. Todėl mašininio mokymosi technika

gali padėti atlikti dinamometrinius bandymus ir skaičiuojamosios skysčių dinamikos modeliavimą optimizuojant variklio darbą, o tai gali padėti sumažinti tyrimų išlaidas.

1.1.4. Virpesių signalo vaidmuo prognostiniuose modeliuose

Toliau apžvalgoje nagrinėjami tyrimai, kuriuose pristatomi prognostiniai modeliai, kurių įėjties arba išėjties parametrai yra variklių skleidžiami virpesių ir garso slėgio signalai.

Tiesinės ir netiesinės regresijos modeliai, skirti variklių skleidžiamiems virpesiams ir garso slėgiui prognozuoti, buvo pristatyti Uludamar et al. (2016) atliktame tyrime. Eksperimento metu buvo naudojami trijų tipų degalų mišiniai (mažai sieros turintis dyzelinas sumaišytas su saulėgrąžų, rapsų ir kukurūzų aliejais), taip pat buvo keičiami variklio sūkliai (1200, 1500, 1800, 2100 ir 2400 aps./min.). Autorių nuomone, vidutinis kvadratinis nuokrypis yra svarbiausias virpesių ir garso slėgio vertės matas, todėl jis buvo naudojamas kaip modelio išėjties parametras. Prognostinių modelių įėjties parametrai buvo degalų tankis, ketonų skaičius, klampumas ir mažiausia įkaitinimo vertė. Atlikus skaičiavimus ir parametrų vertinimą buvo gauti tokie prognostiniai modeliai:

– tiesinis modelis:

$$VS_{RMS} = 71,126 - 19,43 \times T - 0,123 \times KS - 1,042 \times K + 0,000121 \times MIV, \quad (1.23)$$

$$GS_{RMS} = 85,097 + 10,596 \times T + 0,041 \times KS - 0,336 \times K - 3,266 \times 10^{-5} \times MIV; \quad (1.24)$$

– netiesinis modelis:

$$VS_{RMS} = 35,318 \times T^{0,003} \times KS^{-0,101} \times K^{-0,109} \times MIV^{0,082}, \quad (1.25)$$

$$GS_{RMS} = 103,276 \times T^{0,127} \times KS^{0,017} \times K^{-0,02} \times MIV^{-0,011}, \quad (1.26)$$

čia VS_{RMS} – virpesių signalo RMS; GS_{RMS} – garso slėgio RMS; T – degalų tankis; KS – ketonų skaičius; K – degalų klampumas; MIV – mažiausia degalų įkaitinimo vertė.

Sudarytų modelių tinkamumas buvo įvertintas naudojant vidutinę absoliučiąją procentinę paklaidą (VAPP). Gauta, kad virpesių signalo RMS reikšmės buvo šiek tiek prasčiau prognozuojamos negu garso slėgio RMS, tačiau apskritai modeliai buvo tikslūs, o VAPP visais atvejais nesiekė 1 %.

Panašus tyrimas buvo atliktas siekiant įvertinti biodyzelino mišinius, kurie generuotų mažiausius virpesius (Taghizadeh-Alisaraei et al. 2012). Tuo tikslu buvo panaudotas dvifaktoris ANOVA modelis. Modelio išeities parametras buvo virpesių signalio RMS, o įeities parametrai (arba faktoriai) buvo du: degalų tipas (9 biodyzelino mišinio variantai) ir variklio apskukų greitis (7 variantai). Virpesių duomenys buvo gauti esant dviem variklio sąlygoms – prieš techninę apžiūrą ir po jos. ANOVA modelis parodė, kad, nepaisant to, ar variklis buvo prieš ar po techninės apžiūros, degalų tipas, apskukų greitis ir abiejų šių faktorių sąveika yra statistiškai reikšmingi, prognozuojant virpesių RMS vertes ($p < 0,001$). Tyrimas papildomai atskleidė, kad didžiausios virpesių RMS vertės yra pasiekiamos esant 1800 ir 2000 aps./min. variklio apskukų greičiui. Taip pat svarbu pažymėti, kad, atlikus variklio techninę apžiūrą, virpesių signalo RMS sumažėjo 12 %.

Pažangus DNT modelis buvo sudarytas variklio triukšmo ir virpesių lygiui prognozuoti, atsižvelgiant į naudojamus skirtingus degalus ir esant skirtingiems variklio sūkiams (Çelebi et al. 2017). DNT įeities parametrai buvo variklio sūkių, SND srauto greitis, ketonų skaičius ir degalų tankis. Tyrimo metu buvo naudojamas visiškai sujungtas DNT su vienu paslėptu sluoksniu, o rezultatams palyginti papildomai buvo atlikta daugiamatė tiesinė regresija. Tyrimo rezultatai parodė, kad DNT kur kas tiksliau prognozavo virpesių RMS testinėje aibėje, atitinkamai vidutinė absoliuti procentinė paklaida (VAPP) buvo 2,57 % ir 4,14 % naudojant DNT ir daugiamatį TRM. Garso slėgis buvo gerai prognozuojamas abiejų modelių ir VAPP atitinkamai buvo 0,42 % ir 0,59 %. Taip pat tyrime autoriai pristatė plačią, tačiau tik eksperimentinę variklio emisijų analizę, ir prognostiniai modeliai, atsižvelgiant į skleidžiamus virpesius, sudaryti nebuvo.

Dvisluksnio perceptrono neuroninį tinklą prognozuoti net 12 išeities parametrų sudarė ir aprašė Hosseini et al. (2020). Įeities parametrai buvo degalų mišinys, variklio sūkių, aplinkos oro slėgis, santykinis drėgnumas, alyvos temperatūra, deguonies kiekis išmetamosiose dujose, degalų sąnaudos, slėgis įsiurbimo kolektoriuje, mažesnioji šildymo vertė, išmetamųjų dujų temperatūra, degalų tankis ir degalų klampumas. Išeities (prognozuojamieji) parametrai buvo tokie: variklio darbas (galia ir sukimo momentas), emisijų kiekis (CO , CO_2 , UHC ir NO) ir virpesiai (RMS_x , RMS_y , RMS_z , ekscesas_x , ekscesas_y ir ekscesas_z). Sudaryto modelio mokymosi, validavimo ir testavimo R^2 atitinkamai siekė net 99,99 %, 99,94 % ir 99,95 %. Papildomai buvo atlikta regresinė analizė tarp neuroninio tinklo išeities parametrų ir atitinkamų eksperimento parametro reikšmių, kad būtų galima tiksliau įvertinti neuroninio tinklo tikslumą. Rezultatai parodė, kad sukonstruotas neuroninio tinklo modelis pakankamai gerai prognozuoja variklio darbą, emisijų kiekius ir virpesius keičiant įvairius modelio įeities parametrus. TRM R^2 siekė 89–99 % virpesių RMS ir eksceso reikšmėms. Autoriai daro išvadą, kad sudarytas dvisluksnis perceptronas yra galingas įrankis prognozuojant variklio darbo, emisijų kiekio bei virpesių charakteristikas.

1.2. Klasifikavimo modeliai

Nuolat tobulėjant mechanikos mokslui ir taikomoms technologijoms, mechatroninės sistemos tampa vis sudėtingesnės ir tradicinių mechanikos metodų šių sistemų eksploatacijai ir priežiūrai pakanka. Dėl šios priežasties dirbtinio intelekto sistemų, tokių kaip mašininis mokymasis, taikymas sparčiai veržiasi į tokias mechanikos inžinerijos sritis, kaip termodinamika, perkrovų analizė, skysčių mechanika, dinaminė analizė ir kontrolė, parametrų optimizavimas, kokybės kontrolė, procesų planavimas, diagnostika (Patel et al. 2021). Kaip pažymi Patel et al. (2021), dirbtinio intelekto algoritmai, tokie kaip DNT, SNT, neapibrėžtos logikos ir kiti modeliai leidžia geriau valdyti proceso parametrus, jo planavimą, kokybės kontrolę ir optimizavimą. Šiuos modelius įdiegus mechanikos inžinerijos programose galima sumažinti klaidų, gedimų dažnį. Mašininio mokymosi modeliai mechanikos inžinerijos problemoms spręsti skverbėsi kartu su jų atsiradimu (1.1 lentelė, Manikandan & Duraivelu 2021).

Jau paskutiniame XX a. dešimtmetyje buvo atlikti didelės apimties besisukančių mašinų gedimų klasifikavimo tyrimai naudojant DNT (Lee 1996; Paya et al. 1997). Pirmajame tyrime pristatomas DNT konceptas, skirtas mašinos gedimui analizuoti ir stebėti. Siūlomai koncepcijai pademonstruoti buvo sukurta integruota mokymosi, stebėjimo ir požymių atpažinimo metodika pavadinta duomenų po-

1.1 lentelė. Mašininio mokymosi modelių evoliucija

Table 1.1. Evolution of machine learning models

Eil. Nr.	Modelis	Metai
1	Negilūs neuroniniai tinklai	1940
2	Daugiasluoksnis perceptronas ir atgalinis sklaidimas	1960
3	K-vidurkių metodas	1960
4	Bejeso tinklai	1980
5	Sprendimų medžiai	1980
6	Atraminų vektorių modeliai	1990
7	Gilieji rekurentiniai neuroniniai tinklai	1993
8	Sąsūkos neuroninis tinklas (Lenet)	1998
9	Gilaus įsitikinimo (sąryšių) tinklai	2006
10	Sąsūkos neuroninis tinklas (Alexnet)	2012
11	Sąsūkos neuroninis tinklas (VGG net)	2014
12	Sąsūkos neuroninis tinklas (Resnet)	2015
13	Sąsūkos neuroninis tinklas (DenseNet)	2017
14	Sąsūkos neuroninis tinklas (NASNet)	2018
15	Sąsūkos neuroninis tinklas (SENet)	2018
16	Sąsūkos neuroninis tinklas (EfficientNet)	2019
17	Sąsūkos neuroninis tinklas (NFNet-F4)	2021

žymių diskriminacijos modeliu, kuris buvo pagrįstas smegenėlių modelio artikuliacijos valdikliu. Paya et al. (1997) pristatomo tyrimą, kuriame sudaromas DNT identifikuoti guolių ir krumpliaračių gedimus, naudojant virpesių signalų transformacijas. Autoriai sudarė prižiūravimo mokymosi daugiasluoksnį neuroninį tinklą su atgalinio sklaidimo algoritmu, kurio testavimo aibės bendrasis tikslumas siekė net 96 %.

Dėl palyginti lengvo DNT naudojimo (paprasti DNT modeliai yra realizuoti duomenų kompiuterinėse apdorojimo programose) buvo atlikti gedimų identifikavimo tyrimai tokiose mechatroninėse sistemose kaip vandens siurbiai (Cao et al. 2021; Chen et al. 2021; Tiwari et al. 2021), guoliai (Waziralilah et al. 2019), rotorai (Yousefian and Kamalasadan 2017), pavarų dėžės (Jiao et al. 2018; Wang et al. 2018), juostiniai konvejeriai (Zhang et al. 2021).

1.2.1. Klasifikavimo modelių matematinės išraiškos

Šiame skyrelyje aprašomi mašininio mokymosi modeliai skirti klasifikavimo uždaviniams spręsti.

Signalų klasifikavimas laikomas prižiūrimo (anlg. *supervised*) mašininio mokymosi klasifikavimo uždaviniu. Šiuo atveju, signalai negali vienu metu būti priskirti kelioms klasėms, todėl tai daugelio klasių vieno žymens uždavinys, kai modelis f_θ , kuriamas naudojant $\mathcal{D} = \{(x^{(i)}, y^{(i)}) | 1 \leq i \leq N\}$, klasifikuoja stebėjimus į vieną iš apibrėžtų klasių $f_\theta : X \subset \mathbb{R}^{d_x} \rightarrow Y \subset \mathbb{R}^{d_y}$, čia d_x – įeities dimensija, d_y – išeities dimensija / klasių skaičius. Šiuo atveju X žymi įeities signalo, o Y – išeities klasę. Čia $x^{(i)} = (x_1, x_2, \dots, x_{d_x}) \in X$ yra i -toji įeities sekos imtis ir $y^{(i)} \in Y$ yra i -toji imties žymė.

Visų modelių $\mathcal{P}$ išeitis yra transformuojama atliekant eksponentinę normalizaciją taikant softmax transformaciją. Ši transformacija įgalina gauti tikimybinių pasiskirstymą tarp nagrinėjamų klasių, o vieno žymens atveju suteikia galimybę pasirinkti klasę su didžiausia tikimybe:

$$\mathcal{P}(y) = \left(\frac{e^{y_1}}{\sum_{j=1}^{d_y} e^{y_j}}, \dots, \frac{e^{y_{d_y}}}{\sum_{j=1}^{d_y} e^{y_j}} \right). \quad (1.27)$$

Logistinės regresijos (LR) modelis yra plačiai taikomas dviejų klasių klasifikavimo uždaviniams spręsti. Dviejų klasių atsako modeliuose priklausomasis kintamasis Y gali įgyti vieną iš dviejų galimų eksperimento reikšmių $Y \in \{0, 1\}$. Tarkime, kad $\mathbf{X} \subset \mathbb{R}^n$ yra vektorius, sudarytas iš nepriklausomųjų paaiškinamųjų kintamųjų, $\mathbf{x}$ yra vektoriaus $\mathbf{X}$ realizacija (eksperimento metu gautos reikšmės)

ir $P(Y = 1|\mathbf{X} = \mathbf{x})$ yra modeliuojama atsako tikimybė, kai $Y = 1$. Tada LR modelis yra užrašomas taip (Kleinbaum et al. 2002):

$$\pi(\mathbf{x}) = P(Y = 1|\mathbf{X} = \mathbf{x}) = \frac{\exp(\alpha + \beta_1 x_1 + \dots + \beta_n x_n)}{1 + \exp(\alpha + \beta_1 x_1 + \dots + \beta_n x_n)}, \quad (1.28)$$

čia α – laisvasis parametras ir $\beta = (\beta_1, \dots, \beta_n)^T$ LR parametrai esant nepriklausomųjų kintamųjų vektoriui.

Atraminų vektorių modelis (AVM) yra prižiūrimo mokymosi modelis (Vapnik 1998), daugiausia naudojamas klasifikavimui ir yra kilęs iš statistinio mokymosi teorijos (Marwala 2010). AVM taikomas daugelyje tyrimų sričių, tokių kaip teksto ir vaizdų klasifikavimas, bioinformatika, pažaidų identifikavimas, ir daugelyje kitų (Cervantes et al. 2020).

Tarkime, kad duomenų aibė sudaryta iš stebėjimų porų:

$$(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_n, y_n), \quad (1.29)$$

čia $\mathbf{x}_i \in \mathbb{R}^d$ ir $y_i \in (+1, -1)$, $i = 1, 2, \dots, n$. Tokiu atveju yra begalinis skaičius hiperplokštumų $\mathbf{w}^T \mathbf{x}_i + b = 0$, kurios gali duomenis klasifikuoti į dvi klases ir egzistuoja tik viena hiperplokštuma, kuri duomenis atskiria su maksimaliu skirtumu. Tokia hiperplokštuma vadinama *optimalaus atskyrimo hiperplokštuma*.

Lagranžo formulė naudojama modelio parametrams vertinti:

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2} \langle \mathbf{w} \cdot \mathbf{w} \rangle - \sum_{i=1}^l \alpha_i [y_i (\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b) - 1], \quad (1.30)$$

čia α_i – Lagranžo daugikliai; o $\langle \cdot \rangle$ – skaliarinė sandauga.

Atsitiktinių miškų klasifikavimo modelis yra klasifikavimo algoritmas, grindžiamas tipiškų ansamblių mokymosi algoritmu, kai mokymosi metu dalyvauja daug mažų sprendimų medžių (Breiman 2001). Pirmiausia k mažų klasifikavimo sprendimų medžių $g_j(x^{*,j}|\phi_j)$, $j = 1, \dots, k$ su fiksuotu medžių gyliu w ir kintamųjų skaičiumi l yra sukonstruojami imant atsitiktinę kintamųjų $x^{*,j} \subset \mathbb{R}^l \subset \mathbb{R}^d$ imtį. Po to, mažų klasifikatorių derinys sudaromas galutiniam modeliui konstruoti.

Sąsukos neuroninis tinklas (SNT) yra giliųjų neuroninių tinklų (GNT) architektūra, plačiai naudojama kompleksiniams didelės dimensijos duomenims, tokiems kaip nuotraukos, garso ir vaizdo įrašai, analizuoti (Goodfellow et al. 2016). Priešingai nei visiškai sujungto perceptrono neuroninio tinklo, kur visi sluoksnio neuronai yra iki galo sujungti, SNT modelio jungtys yra retesnės dėl pasirinktos

erdvinės duomenų struktūros. SNT architektūra yra sudaryta naudojant tris pagrindines struktūras: sąsūkos sluoksniai, sutelkimo sluoksniai ir aktyvacijos funkcijos. Atskiru atveju esant vienmačiam signalui, sąsūkos naudojimas pakeičia visiškai sujungtus sluoksnius:

$$Y_i = (K * S)_i = \sum_{m=1}^M K_m S_{i-m+a+1}, \quad (1.31)$$

čia K – sąsūkos filtro branduolys; S – vienmatis signalas, $i = 1, \dots, A$; A – signalo Y ilgis; $a = \lfloor M/2 \rfloor$, M – filtro branduolio dydis.

Dvimačių sąsūkų atveju turime:

$$Y_{i,j} = (K * I)_{i,j} = \sum_{m=1}^M \sum_{n=1}^N K_{m,n} I_{i-m+a+1, j-n+b+1}, \quad (1.32)$$

čia I – vaizdas; $i, j = 1, \dots, A$ – vaizdo I aukštis ir plotis; $a = \lfloor M/2 \rfloor$; $b = \lfloor N/2 \rfloor$; M, N – filtro branduolio dydis.

Nagrinėtos transformacijos yra parametrinės: branduolio filtrai yra nežinomi modelio parametrai. Visgi neretai, norint sumažinti duomenų dimensiją, prisireikia ir skirtingų kitų transformacijų. Viena jų yra sutelkimas su duota funkcija. Sutelkimo operacija vykdoma analogiškai, kaip sąsūkos operacija, tik neturi nežinomų parametru ir duota funkcija taikoma lokaliai matymo sričiai (Goodfellow et al. 2016).

Giliojo mokymosi metu nuoseklių ir laiko eilučių duomenų $\mathbf{X} = (x_1, x_2, \dots, x_T)$ problemos labai dažnai aproksimuojamos rekurentiniais neuroniniais tinklais (Goodfellow et al. 2016). Ilgos trumpalaikės atminties modelis (ITAM) (Hochreiter and Schmidhuber 1997) yra vienas iš vyraujančių modelių laiko eilučių srityje, kuris remiasi vartų mechanizmo ir būsenos atnaujinimų deriniu. ITAM būsenos sudaro paslėptų būsenų vektorių porą (c_t, h_t) .

Kai yra gaunami nauji duomenys $x_t, t = 0, \dots, T$, ITAM atnauja paslėptas vektorių būsenas h_{t-1} į naujas langelių būsenas $\tilde{c}_t$ ir naujiems kintamiesiems apskaičiuoti taikomos vartų transformacijos i_t, f_t ir o_t , kurios atitinkamai yra žinomos kaip įėjimo, užmiršimo ir išėjimo sklendės. Įėjimo sklendė i_t turi langelio vektoriaus $\tilde{c}_t$ integravimo į c_t interpretaciją. Funkcija f_t yra interpretuojama kaip užmiršimo sklendė, t. y. kiek sumažinti signalo stiprumą, atsižvelgiant į duomenų x ir praėjusios būsenos c_{t-1} situaciją, o galutinis rezultatas skaičiuojamas kombinuojant šio laiko momento sklendės ir praeities būsenos c_t reikšmes:

$$i_t = \sigma(\mathbf{w}_{1,i}x_t + \mathbf{w}_{2,i}h_{t-1} + b_i), \quad (1.33)$$

$$f_t = \sigma(\mathbf{w}_{1,f}x_t + \mathbf{w}_{2,f}h_{t-1} + b_f), \quad (1.34)$$

$$o_t = \sigma(\mathbf{w}_{1,o}x_t + \mathbf{w}_{2,o}h_{t-1} + b_o), \quad (1.35)$$

$$\tilde{c}_t = \tanh(\mathbf{w}_{1,c}x_t + \mathbf{w}_{2,c}h_{t-1} + b_c), \quad (1.36)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t, \quad (1.37)$$

$$h_t = o_t \odot \tanh(c_t), \quad (1.38)$$

čia $\odot$ – daugyba pakoordinačiui; σ – sigmoidinė funkcija; $\tanh$ – hiperbolinio tangento aktyvacijos funkcija; $\mathbf{w}$ – nežinomi svoriai apskaičiuoti iš eksperimento duomenų. Visiškai sujungtas sluoksnius $y = \text{softmax}(\mathbf{w}h_t + b)$ pasirinktas kaip „daug su vienu“ išeities klasifikavimo modeliu.

Transformerio neuroninis tinklas (Vaswani et al. 2017) tapo pažangiausia ir standartine rašytinės natūralios kalbos apdorojimo (Radford et al. 2019), kalbos atpažinimo technika (Dong et al. 2018), laiko eilučių analizės (Li et al. 2019a) bei daugelio kitų su sekomis susijusių uždavinių sprendimo technika.

Transformerio matematinis modelis susideda iš kelių transformacijų: dėmesio sutelkimo blokų, kelių galvų dėmesio sutelkimo blokų ir visiškai sujungtų sluoksnių (Vaswani et al. 2017). Dėmesio sutelkimo transformacija $\text{Attention}(X) : \mathbb{R}^{d_x} \rightarrow \mathbb{R}^{d_v}$ naudojama sekos $\mathbf{x} = (x_1, x_2, \dots, x_{d_x})$ transformacijai į mažesnės dimensijos seką. Pirmiausia įėjimo signalas dekomponuojamas į tris matricas $Q = \mathbf{w}^Q \mathbf{x}$, $K = \mathbf{w}^K \mathbf{x}$, ir $V = \mathbf{w}^V \mathbf{x}$, tada dėmesio sutelkimas apskaičiuojamas taip:

$$\text{Attention}(Q, K, V) = \text{softmax}(cQK^T)V, \quad (1.39)$$

čia $c = 1/\sqrt{d_k}$ – normalizavimo konstanta; d_k – K dimensija; Q – nežinomų parametrų matrica.

Lygiai taip kaip ir kelių sluoksnių perceptronui (MLP), dėmesio sutelkimas gali būti derinamas naudojant kelių galvų dėmesio sutelkimo transformaciją MHA, kuri sujungia informaciją iš skirtingų įėjimo dėmesio sutelkimo atvaizdavimų skirtingose pozicijose:

$$\text{MHA}(Q, K, V) = (\text{Attention}_1, \dots, \text{Attention}_h)\mathbf{w}^Y, \quad (1.40)$$

čia $\text{Attention}_i = \text{Attention}(Q\mathbf{w}_i^Q, K\mathbf{w}_i^K, V\mathbf{w}_i^V)$. Čia projekcijos yra parametrų matricos $\mathbf{w}_i^Q \in \mathbb{R}^{d_x \times d_k}$, $\mathbf{w}_i^K \in \mathbb{R}^{d_x \times d_k}$, $\mathbf{w}_i^V \in \mathbb{R}^{d_x \times d_v}$, ir $\mathbf{w}^Y \in \mathbb{R}^{d_y \times d_x}$.

Galiausiai, daugelio galvų dėmesio sutelkimas yra susiejamas su pilnai sujungtomis transformacijomis:

$$Y = \text{relu}(\mathbf{w} \cdot \text{MHA}(Q, K, V)), \quad \mathbf{w} \in \mathbb{R}^{d_y \times (d_h + 1)}, \quad (1.41)$$

čia relu – aktyvacijos funkcija apibrėžiama, kaip teigiama argumento funkcija $\text{relu}(f(x)) = x^+ = \max(0, x)$. Galutinis rezultatas apskaičiuojamas taikant sigmoidinę funkciją.

1.2.2. Virpesių signalo vaidmuo klasifikavimo modeliuose

Šiuo metu yra atlikta daug virpesių analize grįstų gedimų identifikavimo tyrimų, nes virpesių analizė tapo gyvybiškai svarbiu modernios mechatroninių sistemų gedimų diagnostikos įrankiu (Gangsar and Tiwari 2020; Gupta and Pradhan 2017; Kumar et al. 2018). Yra keletas metodų, leidžiančių virpesių duomenis apdoroti sistemos diagnostikos ar palaikymo tikslu. Pagrindiniai du metodai yra signalo apdorojimas (Riaz et al. 2017; Shunming et al. 2013) ir požymių atpažinimo metodai (Kim and Katipamula 2018; Nasiri et al. 2017).

Signalų apdorojimo techniką sudaro empirinės modos išskaidymo (Lei et al. 2013) ir vilnelių transformacijos (Chen et al. 2016) metodai, galintys išgauti virpesių formų defektus. Empirinės modos išskaidymas yra vienas iš galingiausių signalų apdorojimo metodų ir buvo plačiai ištirtas ir plačiai taikomas besisukančių mašinų gedimų diagnostikai (Lei et al. 2013). Vilnelių transformacija taip pat buvo plačiai ištirta ir taikoma besisukančių mašinų gedimų diagnostikai, kaip vienas galingiausių nestacionarių signalų apdorojimo metodų (Chen et al. 2016). Visgi šio tipo signalų apdorojimo metodai reikalauja aukštos personalo kvalifikacijos, gilių žinių apie specifinius analizės metodus, tokius kaip signalų filtravimas, Furjė transformacija, Vignerio paskirstymo ar spektrogramos metodų taikomas (Riaz et al. 2017). Dėl šių priežasčių gedimų identifikavimo algoritmai neproporcingai išaugina mechatroninių sistemų palaikymo išlaidas, nes šiam darbui reikalingas aukštos kvalifikacijos personalas, įranga, taip pat didėja laiko sąnaudos.

Požymių atpažinimo metodai grindžiami mašininio mokymusi grįstais metodais, o tai leidžia, tinkamai apmokius modelį, kartą ir visiems laikams sukurti gedimų klasifikavimo modelius skirtus konkrečiai mechatroninei sistemai. Tokiu būdu labai palengvinama sistemų priežiūra realiuoju laiku. Dėl giliojo mokymosi modelių proveržio suklestėjo automatiniai požymių atpažinimo metodai, skirti tolesniam gedimų įvertinimui ir klasifikavimui. Neseniai buvo pasiūlyti keli nauji požymių atpažinimo metodai, skirti gedimų diagnostikos algoritmams, skirtiems virpesiams apdoroti (Jia et al. 2016; Li et al. 2019b; Shao et al. 2017; Xu et al. 2019). Visų pirma toks požymių atpažinimo metodų taikymas yra pagrįstas virpesių klasifikacija, todėl šiems uždaviniams spręsti galima naudoti daugybę mašininio mokymosi algoritmų, tokių kaip SNT, AVM, vienas po kito einančių autoenkoderių ar rekurentinių neuroninių tinklų (Han et al. 2018; Hoang and Kang 2019). Pagrindinis sunkumas yra pasirinkti tinkamiausią mašininio mokymosi modelį konkrečiai problemai spręsti.

1.2.3. Pavarų gedimų klasifikavimas naudojant mašininio mokymosi modelius

Įvairių mašininio mokymosi algoritmų naudojimas sprendžiant pavarų gedimų diagnostikos problemą taip pat yra populiari tema tarp tyrėjų. Pagrindiniai pavarų gedimai yra šie (Kumar et al. 2020):

1. Nuovargis. Tai lėtas ir progresuojantis gedimas, atsirandantis dėl ciklinės apkrovos. Šio tipo gedimai dažniausiai įvyksta trimis etapais: 1) plyšio atsiradimu; 2) plyšio plitimu; 3) lūžiu. Svarbu, žinoti, kad plyšiams plisti reikia trumpesnio laiko lyginant su jo plyšimo inicijavimu.
2. Kontaktinis nuovargis. Dažnas ciklinis įtempimas atsiranda ties paviršiaus įtrūkiais, o metalo likučiai išsiskiria iš besijungiančio danties paviršiaus. Makro ir mikro įdubimai dažniausiai atsiranda dėl kontaktnio nuovargio.
3. Susidėvėjimas. Nuo krumpliaračio dantų paviršių pašalinta medžiaga dėl daugelio priežasčių, įskaitant elektrinius, cheminius ar mechaninius veiksmus. Krumpliaračio dantų susidėvėjimas gali būti lipnus, erozinis (abrazyvinis) arba poliruotas.
4. Dilimas. Atsiranda, kai sutepti paviršiai ima slysti. Dėl slydimo susidaro aukšta temperatūra, kuri suardo paviršiaus plėvelę ir minkštesnę medžiagą deformuojasi.

Pavarų dėžės gedimams identifikuoti Li et al. (2016) palygino negiliuosius (AVM, kAK, AM) ir giliuosius (gilusis AM sujungimas, giliosios Boltzmano mašinos) mokymosi modelius ir išsiaiškino, kad giliojo mokymosi modeliai veikia geriau nei kiti. Autoriai daro išvadą, kad nors akustinės emisijos jutiklis ir virpesių akcelerometras gali aptikti pavarų dėžės defektus, jų negiliojo mokymosi modeliai yra nejautrūs ir negeba atskirti skirtingų duomenų modelių. Dėl šio priežasties autoriai sukūrė dvi giliausias Boltzmano mašinas, skirtas vilnelių transformacijos statistiniams parametrams atvaizduoti. Galiausiai buvo pasiūlytas gilusis AM sujungimas, kuris sujungtų dviejų giliųjų Boltzmano mašinų išėjimus kaip integruotą AM modelį. Pasiūlytas naujas AM modelis pasiekė 97,68 % tikslumą klasifikuojant 11 skirtingų greičių dėžės gedimų. Tyrimo rezultatai parodė, kad gilusis akustinių ir virpesių signalų sujungimas gali pagerinti pavarų dėžių gedimų diagnostikos galimybes.

Pasak kelių autorių, algoritmai pasiekė didesnę tikslumą, jei duomenys buvo sudėtingesni laiko ar erdvinio duomenų atžvilgiu, palyginti su kitais mašininio mokymosi algoritmais, tokiais kaip AVM, daugiasluoksnis perceptronas, kAK, sprendimų medžio algoritmai (Azamfar et al. 2020; Geggel et al. 2019; Grezmak et al. 2019; Jing et al. 2017; Qiu et al. 2019). Be to, Qiu ir kt. (Qiu et al. 2019) pažymėjo, kad, nepaisant didesnio tikslumo, SNT pasiekė žemą skaičiavimo sąnaudų lygį tiesiogiai naudodama neapdorotus signalus.

Tačiau pastaraisiais metais populiariausi gilaus mokymosi algoritmai buvo SNT (Hoang and Kang 2019; Jiao et al. 2020; Kumar et al. 2020). SNT gali tiesiogiai išgauti jautrius duomenų požymius iš didelės apimties duomenų, pvz., vaizdų ir vaizdo įrašų. Vienmačiai virpesių signalai laiko srityje gali būti pateikti dvimačiu formatu, tarkime, matricos forma arba dažnio spektro vaizdu, todėl atsirado tyrinėtojų, kurie bandė paversti virpesių signalą į dvimatę formą, kad išnaudotų kuo platesnes SNT galimybes (Hoang and Kang 2019). Plati virpesių signalo analizės, naudojant SNT, apžvalga atlikta Hoang ir Kang (2019). Kumar et al. (2020) apžvelgia naujus SNT modelių ir kitų modelių derinius tokius kaip prisitaikančio sutapimo SNT ar integruotas SNT su sklendžių rekurentinių vienetų modeliu. Prisitaikančio sutapimo SNT modelį pirmasis aprašė Li et al. (2020), siekdamas tiesiogiai išgauti maksimalų požymių išskyrimą iš neapdoroto virpesių signalo. Yao et al. (2018) pasiūlė integruotų SNT sklendžių rekurentinių vienetų modelių metodą spręsti krumpliaračio duobių gedimų diagnostikos problemai. Iš integruoto SNT ir sklendžių rekurentinių vienetų modelio gautos gedimų savybės buvo sujungtos į giliojo mokymosi struktūrą. Siūlomas metodas pademonstravo tikslių pavarų dėžės gedimų klasifikavimą naudojant mažiau eksperimentinių duomenų per trumpesnę laiką. Verta paminėti, kad Jiao et al. (2020) pažymi, kad sąsūka yra esminis požymių išskyrimo žingsnis naudojant SNT, kuris suteikia du išskirtinius pranašumus:

1. Reti sąryšiai. Generuoja naujus požymius, kai branduolio filtras atlieka transformaciją slinkdamas, per nagrinėjamų duomenų poaibius transformuoja regos lauke esančius senus požymius ir gali efektyviai sumažinti parametų skaičių ir pagreitinti mokymąsi.
2. Sviurių pasidalijimas. Kiekvieno branduolio sviuris išlieka nepakitęs, kai jis slenka požymių žemėlapiuose, o tai dar labiau sumažina parametų skaičių.

Sąsūkos transformacija, bendru atveju sudaryta iš kelių branduolio filtrų su palyginti nedaug nežinomų modelių parametų, įgalina sukurti naujus informatyvius požymius.

1.3. Klasifikavimo modelių įgyvendinimo mechatroninėse sistemose tyrimų apžvalga

Klasifikavimo modelių, paremtų GNT modeliais, taikymas yra plačiai paplitęs visose inžinerinės mechanikos srityse. Didžiausias GNT taikymų proveržis stebimas klasifikuojant įvairių pavarų dėžių, guolių ir kitų besisukančių mechatroninių sistemų būsenas. Šiame poskyryje yra pristatomi tyrimai, kuriuose sudaryti įvairūs klasifikavimo modeliai, paremti tiek GNT, tiek klasikinio mašininio mokymosi metodais.

1.3.1. Pavarų gedimų klasifikavimas

Jing et al. (2017) darbe buvo sudarytas SNT modelis, kur pavarų dėžės gedimai klasifikuoti naudojant neapdorotus virpesių signalus ir virpesių signalus, apdorotus laiko, dažnių ir laiko-dažnių srities statistiniais parametrais. Palyginimui požymiai buvo išskirti apdorojant virpesių signalą bei naudojant tris įprastus negiliojo mokymosi modelius (visiškai sujungtas neuroninis tinklas, AVM ir AM). Visi modeliai buvo apmokyti ir testuoti naudojant tiek neapdorotus laiko, dažnių ir vilnelių srities signalus, tiek apdorotus signalus pagal laiko, dažnių ir vilnelių srities statistinius parametrus. Apdorotą požymių išskyrimą sudarė 8 laiko, 32 dažnių ir 5 vilnelių srities statistiniai parametrai. Septynių klasių SNT modelio architektūrą sudarė vienas sąsūkos sluoksnis, vienas sutelkimo sluoksnis ir vienas iki galo sujungtas sluoksnis su normalizuota eksponentine (softmax) aktyvacijos funkcija. Tik 50 % duomenų buvo dedikuota modeliui mokytis, o likę 50 % buvo skirti modeliui testuoti. Tyrimo rezultatai parodė, kad sudarytas SNT modelis pasiekė net 99,33 % tikslumą klasifikuojant visas 7 pavarų dėžės būsenas. Lyginant neapdoroto ir apdoroto signalo požymių išskyrimo metodus gauta, kad, naudojant neapdorotą signalą pasiekiami kur kas geresni rezultatai nei su apdorotais signalais ir tikslumas padidėja apie 10 %. Šis rezultatas reikšmingai koreliuoja su unikalio SNT architektūra, kuri gali automatiškai išgauti reprezentatyvius neapdorotų duomenų požymius sluoksnis po sluoksnio ir suformuoti naudingas savybes aukštesniuose klasifikavimo sluoksnuose. Šis SNT pranašumas ne tik sumažina tyrėjo darbo apimtį ir išankstinių žinių apie signalų apdorojimą ir diagnostikos metodus, reikalingus požymiams išgauti, bet ir adaptyviai pritaiko išmokus požymius, kad išspręstų įvairias gedimų diagnostikos problemas.

Norėdami suprasti skirtingų eksploataavimo sąlygų poveikį ir bendrą pavarų dėžės veikimo proceso pablogėjimą, Qiu et al. (2019) surinko penkių skirtingų gedimo būsenų vertikalius ir horizontalius virpesių signalus trimis skirtingomis darbo sąlygomis. Naudojant požymių išskyrimo metodus, tokius kaip laiko, dažnių ir vilnelių srities statistiniai parametrai, buvo sukonstruota požymių aibė su 52 skirtingais apdorotų signalų požymiais. Penkių klasių SNT modelio architektūrą sudarė vienas įėjties sluoksnis, trys sąsūkos sluoksniai, du sutelkimo sluoksniai ir vienas sluoksnis, sujungtas su normalizuota eksponentine (*softmax*) aktyvacijos funkcija. SNT rezultatams palyginti papildomai klasifikavimo uždavinys buvo sprendžiamas naudojant AVM. Rezultatai parodė, kad vertikalūs virpesių signalai labiau koreliuoja su pavaros degradacija, o klasifikavimo tikslumas padidėja veikiant didesnei apkrovai. Tyrimo metu taip pat įrodyta, kad SNT pasiekia didesnę tikslumą nei AVM. Prie išvadų autoriai pažymi, kad didžiųjų duomenų eroje SNT pranašumai apdorojant duomenis gali būti dar labiau išryškinti, kai eksperimento duomenų mastas sparčiai didėja, o tikslumo ir skaičiavimų sudėtingumo kompleksą galima adaptuoti lanksčiai naudojant SNT algoritmus, todėl SNT modeliai

gali būti plačiai naudojami ir taikomi gedimų diagnostikos srityje. Visgi, darydami tokias išvadas, autoriai nedetalizuoja, kodėl tyrimo metu, jie stengėsi kuo labiau sumažinti duomenų dimensiją pirmu etapu apdorodami duomenis, o antru etapu principinių komponentų metodu išskirdami tik dominuojančius parametrus.

Azamfar et al. (2020) pasiūlė duomenų lygio kelių jutiklių sintezės metodą, pagrįstą dvimačiu SNT modeliu, skirtą automatiniam požymių išskyrimui ir mokymuisi iš neapdorotų virpesių dažnių spektro, gauto iš variklio įtampos signalo jutiklių. Siūlomas metodas nereikalauja išskirti požymius apdorojant duomenis, o eksperimentiniai rezultatai rodo šio metodo pranašumą, palyginti su kai kuriais gerai žinomais klasifikavimo algoritmais. Duomenų ir požymių suliejimas: duomenys iš kelių jutiklių sukraunami eilutė po eilutės, kad būtų sudaryta dvimatė įeities matrica. Sąsūkos filtrams judant per įeities matricą, informacija iš kelių jutiklių susilieja, todėl informacijos praradimas suliejimo procese buvo sumažintas taikant sąsūkos filtrą. Be to, apmokant SNT požymiai, išgauti iš kelių jutiklių, nuolat sujungiami skirtinguose tinklo sluoksniuose, kad būtų sukurtas aukštesnio lygio požymių vaizdas, kuris vėliau naudojamas normalizuotoje eksponentinėje (*softmax*) aktyvacijos funkcijoje. Dvimačio SNT modelio architektūrą sudarė keli sąsūkos sluoksniai ir sutelkimo sluoksniai bei keli visiškai sujungti sluoksniai su normalizuota eksponentine (*softmax*) aktyvacijos 7 klasių funkcija. Modelio mokymuisi buvo skirtas skirtingas duomenų kiekis (16,66 %, 33,33 %, 50,00 %, 66,66 % ir 83,33 %), atitinkamai likę duomenys buvo skirti modeliui testuoti. Dvimačio SNT rezultatams palyginti papildomai klasifikavimo uždavinys buvo sprendžiamas naudojant KAK, Naive Bayes, sprendimų medžių, AVM, diskriminantinės analizės ir klasikinius SNT modelius. Rezultatai parodė, kad SNT grįsti gedimų diagnostikos metodai pranoksta visus klasikinius mašininio mokymosi modelius, kai neapdoroti dažnio srities duomenys naudojami kaip modelio įeities parametrai. Rezultatai taip pat aiškiai parodo siūlomo dvimačio SNT modelio pranašumą klasifikavimo tikslumui ir nustatant optimalų mokymosi aibės dydį. Gauti rezultatai taip pat rodo, kad, naudojant kiekvieno jutiklio duomenis atskirai tipinėje SNT struktūroje, taip pat pasiekiamas didesnis našumas nei visi kiti klasikiniai mašininio mokymosi modeliai. Tarp skirtingų klasikinių modelių AVM pasižymi didžiausiu klasifikavimo tikslumu.

Grezmak et al. (2019) iškėlė naują giliųjų neuroninių tinklų (GNT) taikymo problemą. Autoriai teigia, kad pagrindinis GNT apribojimas yra tas, kad jie veikia kaip juodosios dėžės, kurios nesuteikia informacijos apie tai, kaip priimami gedimų klasifikavimo sprendimai. Tai ne tik kelia klausimų dėl pačių sprendimų patikimumo, bet ir riboja tolesnį GNT tobulinimą, kad jie būtų naudojami įvairiesiems uždaviniams spręsti. Tyrime pateikiamas paaiškinamas SNT, kuris buvo sukurtas remiantis sluoksnio lygio informacijos sklaida ir skirtas pavarų dėžių gedimų diagnostikai. Virpesių signalai, kaip laiko eilučių duomenys, pirmiausia buvo konvertuojami į laiko ir dažnio spektro vaizdus naudojant vilnelių transformaciją,

kuriuos vėliau klasifikuojama SNT. Norėdami paaiškinti sprendimo dėl klasifikavimo pagrindimą, sluoksnio lygio informacija išskaido spektro vaizdų vietinių regionų indėlį į klasifikavimo rezultatus ir nustato, kurie spektro vaizdo laiko ir dažnio taškai labiausiai prisideda prie gedimo tipo nustatymo. Tada analizės rezultatai sutikrinami su laiko ir dažnio analize. Sukurto paaiškinamo SNT efektyvumas buvo vertinamas atliekant pavarų dėžės eksperimentus bandymų stende, kur buvo įvertinamos pavaros su įvairaus tipo ir laipsnio gedimais. Sluoksnio lygio informacijos analizės rezultatai parodė, kad SNT gali aiškiai matyti dažnio atsako skirtumą, kurį sukelia pavaroje atsiradę įtrūkiai. Išvada atitinka turimas žinias apie šoninės juostos reiškinius dėl krumpliaračio danties pažeidimo. Išvadose autoriai konstatuoja, kad sluoksnio lygio informacijos įgalintas SNT sprendimų skaidrumas atveria galimybes plačiau pritaikyti GNT klasifikatorius mašinų gedimų diagnostikai.

1.3.2. Juostinio konvejerio būklių klasifikavimas

Kaip ir pavarų dėžės atveju, taip ir juostinio konvejerio būklių klasifikavimo uždavinio sprendimas apima daugybę statistinių ir mašininio mokymosi metodų. Wo-decki et al. (2017) apibendrina, kad, stebint juostinį konvejerį, į diagnostikos sistemą galima įtraukti juostinio konvejerio variklį, pavaras, volelius, įvairias jungtis ir diržą.

Paprasti statistiniai klasifikavimo modeliai buvo pateikti keliuose Andrejiova ir Grincova (2018, 2019, 2021) tyrimuose. Visuose šiuose tyrimuose buvo naudojami tie patys nepriklausomieji veiksniai, tokie kaip JKD tipas, apkrovos tipas ir apkrovos kritimo aukštis. Pirmajame tyrime (Andrejiova and Grincova 2018) autoriai pateikė 4 klasių klasifikavimo modelį, naivų Bayes klasifikatorių, kuris parodė 78,8 % klasifikavimo tikslumą. Vėliau autoriai išplėtė savo tyrimą naudodami papildomus modelius (Andrejiova et al. 2019). Išplėstame tyrime sprendimų medžio ir TRM parodė identišką 81,5 % tikslumą. Paskutiniame tyrime (Andrejiova et al. 2021) autoriai aprašė dar 4 klasifikavimo modelius: LR, TRM, sprendimų medį ir naivų Bayes klasifikatorių. Visi modeliai parodė identišką 85,0 % tikslumą, tačiau reikėtų pažymėti, kad paskutiniame moksliniame darbe autoriai sukūrė dviejų klasių klasifikavimo modelius.

Kai kurie autoriai pasiūlė JKD stebėjimo sistemą, pagrįstą garso ir šiluminio infraraudonųjų spindulių vaizdo deriniu, kuri gali atlikti gedimų analizę esant tuščiosios eigos JKD (Liu et al. 2021). Šiame tyrime buvo sudarytas gradiento padidininimo sprendimų medis, skirtas JKD tuščiosios eigos volelių gedimams klasifikuoti, naudojant Mel dažnio kepstro akustinio signalo koeficientus. Siūlomas metodas pasiekė vidutinį 94,5 % tikslumą.

Che et al. (2021) pasiūlė naują metodą, pavadintą garso ir vaizdo suliejimu, skirtą išilginiam JKD plyšimui aptikti. Tam, kad būtų stebimos JKD skirtingos

veikimo būsenos, autoriai naudojo ir matomą šviesą, ir mikrofonu gautus duomenis. Garso požymiams išgauti buvo naudojami Mel-dažnio kepstro koeficientai, spektrinis centroidas, trumpalaikė energija, nulinis kirtimo santykis ir spektrinis nukrypimas, o vaizdinei funkcijai išgauti buvo panaudota orientuoto gradiento histograma. Naudodami kAK, AVM ir AM modelius, autoriai pasiekė puikų 93–97 % tikslumą. Visgi autoriai nenurodė mokymosi ir testavimo rinkinių pasirinkimo, todėl nėra aišku, ar tas tikslumo lygis buvo pasiektas naudojant modelio nematytus duomenis.

Santos et al. (2020) pasiūlė automatinį vizualinį SNT paremtą detektorių, kuris atpažįsta nešvarumus ant JK volelių konstrukcijų. Tyrimo metu buvo sudaryti vizualinės geometrijos grupės tinklo, liekanų neuroninis tinklas (*ResNet*) ir tankiai sujungtu SNT (*Densenet*). Modelių įeities duomenys buvo JK volelių nuotraukos, kuriose modeliai turėjo rasti ar ant volelių yra prisikaupusių nešvarumų. Geriausią rezultatą parodė Densenet modelis, kurio dviejų klasių vidutinis klasifikavimo tikslumas buvo 89,75 %, o F-1 įvertis – 87,73 %.

Išsamų mašininio mokymosi modelių tyrimą atliko Zhang et al. (2021). Autoriai išskyrė tris mašininio mokymosi grįstų JK pažeidimų identifikavimo metodų tipus:

1. Vaizdo apdorojimo metodas. Vaizdo fiksavimo kamera gaunamas JK paviršiaus vaizdas, o atitinkamas vaizdo apdorojimo algoritmas naudojamas duomenų triukšmui pašalinti ir lengviau išskirti gedimo požymius. Tokiu atveju dažniausiai atliekama binarinė klasifikacija, t. y. identifikuojama, yra ar nėra JK pažeidimo.
2. JKD pažeidų nustatymo naudojant lazerio spindulį metodas. Lazerio spinduliu galima lengvai aptikti JKD pažeidimų požymius. Lazerio technologija leidžia veiksmingai sumažinti trukdžius, atsirandančius dėl dulkių.
3. Infraraudonųjų spindulių kameromis arba termovizoriais gaunamų duomenų apdorojimo metodas. Metodu visapusiškai atsižvelgiama į JKD pažeidimo priežastis ir atsižvelgiama į JKD lokaliojo šildymo problemą, kurią sukelia transportuojami objektai ir JKD trintis. Infraraudonųjų spindulių kamera naudojama šilumos šaltinio pasiskirstymui fiksuoti ir analizuoti ant JKD paviršiaus, o tada nustatyti, ar konvejerio juostos nebraižo transportuojami objektai.

Tyrimo metu buvo palyginti sudėtingi mašininio mokymosi modeliai, tokie kaip greitis regionais grįstas SNT (angl. *Fast Region-based Convolutional Network*, Fast R-CNN), vienos iteracijos objektų aptikimo modelis (angl. *Single Shot MultiBox Detector*, SSD), *RFBnet*, *M2det*, *Yolov3* (angl. *You Look at Once*) ir *Yolov4*. Autoriai daro prielaidą, kad gilesnis tinklas padeda išgauti gilesnius požymius taip pagerindamas modelio tikslumą, todėl buvo nuspręsta patobulinti *Yolov3* modelį. *Yolov3* modelis remiasi požymių piramidės tinklo idėja, kai daugia-

1.2 lentelė. Klasifikavimo lentelė**Table 1.2.** Classification table

		Prognozuojama būseną	
		Teigiama	Neigiama
Realioji būseną	Teigiama	Teisingai teigiama (TT)	Klaidingai neigiama (KN)
	Neigiama	Klaidingai teigiama (KT)	Teisingai neigiama (TN)

lypis požymių aptikimo mechanizmas integruoja tris skirtingų mastelių požymių sluoksnius, skirtus ieškomam objektui aptikti. Palyginti su *Yolov2*, *Yolov3* modelis pagrindinių požymių išgavimo tinklas atnaujintas iš *Darknet19* į *Darknet53*. Padidinus tinklo gylį, tikslumas padidėjo 9,8 %. Tačiau ribotame skaičiavimo bloke labai tikėtina, kad dėl padidėjusio tinklo gylio padidės skaičiavimo apimtis ir taip pailgės klasifikavimo laikas. Tačiau patobulintas *Yolov3* modelis vietoj *Darknet53* naudojo *EfficientNet-B0* tinklą. Rezultatai parodė, kad patobulintas *Yolov3* modelis dvigubai pagerina aptikimo tikslumą ir greitį. Buvo pasiektas 97 % testavimo aibės tikslumas, o didžiausias bandymo greitis siekė 42 paveikslėlius per sekundę. Tuo pačiu metu iš bandymo platformos matyti, kad mūsų pasiūlytas modelis pasižymi dideliu apibendrinimo gebėjimu. Be to, lyginant su originaliu *Yolov3* modeliu, tikslumas padidėjo 10,4 %, greitis 45,9 %.

Siekiant įvertinti klasifikavimo modelių tinkamumą, naudojami įvairūs modelių tikslumo matai. Klasifikavimo modelių tinkamumui vertinti dažniausiai naudojami tikslumo matai apskaičiuojami iš klasifikavimo lentelės (1.2 lentelė). Šiame darbe naudojami keturi tikslumo matai:

- bendras tikslumas;
- preciziškumas;
- jautrumas;
- F1-įvertis.

Bendras klasifikavimo tikslumas parodo, kaip tiksliai modelis identifikuoja nagrinėjamo objekto būsenas, t. y. įvertina visas teisingas prognozes (tiek teigiamų, tiek neigiamų objekto būsenų). Matematinė modelio bendro tikslumo išraiška yra tokia:

$$\begin{aligned}
 \text{Bendras tikslumas} &= \frac{\text{Teisingų prognozių skaičius}}{\text{Visų prognozių skaičius}} \\
 &= \frac{TT + TN}{TT + KN + KT + TN}.
 \end{aligned}
 \tag{1.42}$$

Bendras tikslumas yra geriausias modelio tikslumą apibendrinantis matas, kai eksperimento duomenys yra subalansuoti.

Modelio preciziškumas ir jautrumas taip pat yra gerai žinomi ir dažnai naudojami klasifikavimo tikslumo matai. Preciziškumas (dar vadinamas teigiamai prognozuota reikšmė) parodo santykį tarp TT ir visų teigiamai prognozuotų reikšmių, kitaip tariant preciziškumas parodo modelio teigiamos prognozės svorį, t. y. kuo jis artimesnis vienetui, tuo teisingiau modelis prognozuoja objekto teigiamą būseną, nepaisant realios objekto būsenos. Jautrumas parodo santykį tarp TT ir visų realių teigiamų objekto būsenų, kitaip tariant, jautrumas parodo modelio gebėjimą teisingai atskirti realias objekto būsenas, t. y. kuo jis artimesnis vienetui, tuo geriau modelis atskiria objekto teigiamą ir neigiamą būsenas.

Remiantis klasifikavimo lentele, preciziškumas ir jautrumas yra užrašomas taip:

$$\text{Preciziškumas} = \frac{TT}{TT + KT}, \quad (1.43)$$

$$\text{Jautrumas} = \frac{TT}{TT + KN}. \quad (1.44)$$

Dar vienas kiek rečiau naudojamas, tačiau labai svarbus modelio tikslumo matas yra F1-įvertis. F1-įvertis vadinamas pasvertu preciziškumo ir jautrumo vidurkiu, taip šis įvertis gali būti laikomas kaip preciziškumo ir jautrumo harmoniniu vidurkiu. Pagal klasifikavimo lentelę F1-įvertis užrašomas taip:

$$\text{F1-įvertis} = \frac{2TT}{2TT + KT + KN}. \quad (1.45)$$

Kai duomenys yra nesubalansuoti (teigiamų ir neigiamų objekto būsenų santykis nėra artimas 1), tada F1-įvertis yra geriausiai modelio tikslumą apibendrinantis įvertis, t. y. esant nesubalansuotiems duomenims korektiškiau taikyti F1-įvertį nei bendrą tikslumą.

Disertacijoje aprašyti klasifikavimo modeliai buvo vertinami šiais keturiais klasifikavimo modelių tikslumo matais.

1.4. Pirmojo skyriaus išvados ir disertacijos uždavinių formulavimas

1. Mechatroninėse sistemose tarp teorinių ir eksperimentinių duomenų atsirandančias paklaidas galima įvertinti taikant matematinės statistikos bei tikimybių teorijos metodus. Dauguma inžinerinių modelių naudoja tiesinius modelius, tačiau eksperimentiniai duomenys rodo, kad kai kurie mechat-

roninių sistemų procesai nėra tiesiški ir jiems prognozuoti būtina naudoti netiesinius modelius. Be to, dažnai nepakanka vienam procesui aprašyti naudoti vieno regresijos modelio, o reikia sukurti kelių žingsnių schemas.

2. Vidaus degimo variklių darbo bei ekologiniams ir energiniams parametrams prognozuoti dažniausiai pasirenkamas ANOVA modelis, nes į modelį, kaip įėjties parametrai, įtraukiami tik kokybiniai variklių parametrai. Paskutiniu metu pasirodo vis daugiau publikacijų, kuriose, vietoj ANOVA modelio, autoriai aprašo DNT, naudojamus variklių darbo bei ekologiniams ir energiniams parametrams prognozuoti, tačiau šių tyrimų yra labai mažai.
3. Virpesių signalai variklių tyrimuose analizuojami kaip išeities parametrai. Nėra atlikta tyrimų, kuriuose virpesių ar garso slėgio signalai būtų naudojami kaip prognostinių variklių darbo bei ekologinių ir energinių paramet-rų modelių įėjties faktoriai.
4. Yra atliktas didžiulis kiekis tyrimų, skirtų mechatroninių sistemų gedimų klasifikavimo uždaviniais spręsti. Tiek klasikiniai, tiek gilieji mašininio mokymosi metodai taikomi daugelyje mechanikos sričių.
5. Didžiausią proveržį klasifikuojant pavarų dėžės gedimus padarė SNT modeliai, kurie gali tiesiogiai išgauti jautrius duomenų požymius iš didelės apimties duomenų, pvz., vaizdų ir vaizdo įrašų. Tačiau yra pasigendama pačių naujausių DNT modelių pritaikymų pažaidų klasifikavimo uždavi-niams spręsti.
6. JKD būsenų klasifikavimo uždaviniai yra sudėtingesni, tyrimai remiasi su-dėtingais giliojo mokymosi modeliais. Daugeliu atvejų modeliai požymius išskiria iš vaizdinių, garsinių duomenų, prieš tai atliekant sudėtingas duo-menų transformacijas. Nėra atlikto JKD būklių prognozavimo, naudojant tik diržo įtempio duomenis.

Remiantis atlikta literatūros apžvalga ir pateiktomis išvadomis, iškelta hipotezė, kad galima sudaryti vidaus degimo variklių prognostinius paramet-rų modelius bei naudojant mašininio mokymosi metodus sudaryti mechatroninių sistemų pa-žaidų ir būklių klasifikavimo modelius.

Siekiant patikrinti pateiktą hipotezę, iškelti šie uždaviniai:

1. Atlikti prognostinių ir mašininio mokymosi modelių, taikomų mechatro-ninių sistemų parametrams prognozuoti bei gedimams klasifikuoti apžval-gą.
2. Sudaryti darbe tiriamų mechatroninių sistemų prognostinius bei mašininio mokymosi modelius:
 - 2.1. vidaus degimo variklių ekologiniams ir energiniams parametrams prognozuoti;

- 2.2. hipoidinės pavaros pažaidoms klasifikuoti;
- 2.3. juostinio konvejerio diržo apkrovos būsenoms klasifikuoti.
- 3. Įgyvendinti sudarytus modelius, juos taikant realiose mechatroninėse sistemose:
 - 3.1. prognostinių modelių įgyvendinimas prognozuojant vidaus degimo variklių ekologinius ir energinius parametrus;
 - 3.2. mašininio mokymosi modelių įgyvendinimas klasifikuojant hipoidinės pavaros pažaidas;
 - 3.3. mašininio mokymosi modelių įgyvendinimas identifikuojant juostinio konvejerio diržo apkrovos būsenas.


Prognostinių bei mašininio mokymosi modelių sudarymas mechatroninių sistemų parametrams prognozuoti ir būklėms klasifikuoti

Šiame skyriuje pristatomi sudaryti prognostiniai modeliai, skirti vidaus degimo variklių ekologiniams ir energiniams parametrams (VDV EEP) prognozuoti bei mašininio mokymosi modeliai, skirti mechatroninių sistemų, tokių kaip hipoidinė pavara ir juostinis konvejeris, gedimams bei apkrovos būklėms klasifikuoti. Visi pristatomi modeliai remiasi virpesių ir/ar garso slėgio signalų kaip modelio įeities parametrų idėja.

Skyriuje pateikti modelių sudarymo rezultatai aprašyti mokslo publikacijose (Žvirblis et al. 2021a; Kriaučiūnas et al. 2021) ir pristatyti mokslinėse konferencijose (Žvirblis et al. 2021, 2021b).

2.1. Vidaus degimo variklių ekologinių ir energinių parametrų prognostinių modelių sudarymas

Variklio sukuriama virpesiai priklauso nuo nesuderinto grįžtamojo judėjimo ir besisukančių dalių, ciklinio dujų slėgio kitimo, dinaminių sužadinimo jėgų iš besisukančių variklio dalių ir variklio tvirtinimo mechanizmo konstrukcinių savybių. Variklio tvirtinimo konstrukcijos standumas ir slopinimas turi būti didelis žemųjų dažnių diapazone, o mažas – aukštųjų dažnių diapazone. Norint sumažinti varik-



2.1 pav. Virpesių ir garso slėgio matavimo taškai: a) bendras analizuojamo variklio vaizdas ir virpesių (1 ir 2 taškai) bei garso slėgio (3 taškas) matavimo taškai; b) mikrofonas garso slėgiui matuoti (3 taškas); c) akcelerometrai, skirti virpesiams matuoti (2 taškas) X ir Y kryptimis

Fig. 2.1. Points of measurement of vibrations and sound pressure: a) general view of the analyzed engine and points of measurement of vibrations (points 1 and 2) and sound pressure (point 3); b) microphone to measure sound pressure (point 3); c) accelerometers to measure vibrations (point 2) in X and Y directions

lio virpesius, reikia tinkamai pritvirtinti variklį. Kartais variklio ir rėmo sąlyčio taške reikia naudoti atitinkamų charakteristikų tvirtinimo elementus. Įvairių tipų vibraciją izoliuojančios medžiagos dažnai naudojamos siekiant sumažinti jėgas, perduodamas iš variklio į tvirtinimo konstrukciją.

Atliekant eksperimentinius variklio bandymus, aplinkos garsas ir virpesiai matavimams patalpoje įtakos neturėjo. Bandymų patalpos sienose buvo akustinis pamušalas iš garsą izoliuojančios medžiagos, akustinės durys ir garsui nepralaidus dvigubo stiklo langas, skirtas apžiūrėti variklio bandymo kameros vidui iš operato-

riaus kambario. Garso slėgiui matuoti buvo naudojamas GRAS 46AE mikrofonas (dažnių diapazonas nuo 3,15 Hz iki 20 kHz; dinaminis diapazonas nuo 17 dB (A) iki 138 dB; jautrumas 50 mV/Pa) (2.1a pav. (3 taškas) ir 2.1b pav.). Variklio virpesiai buvo išmatuoti dviejuose taškuose (2.1a pav. (1 ir 2 taškai) ir 2.1c pav.) išilgine (Y) ir skersine (X) kryptimis, naudojant keturis Bruel&Kjear 8341 CCLD akcelerometrus (dažnių diapazonas 0,3–10000 Hz; jautrumas 10 mV/ms⁻²). Virpesių ir garso slėgio signalų duomenys buvo gauti naudojant Bruel&Kjear mašinos diagnostikos įrangos paketą. Įrenginio diagnostikos įrankių rinkinį sudaro 9727 tipo mašinų diagnostikos įrankių rinkinys ir universalus mašinos diagnostikos įrankių rinkinio programinės įrangos paketas, tipas 7910. 9727 tipą sudaro daugiakanalis 3560-B tipo PULSE duomenų gavimo įrenginys (5 kanalai).

2.1.1. Laiko ir dažnių srities statistiniai parametrai

Virpesių ir garso slėgio signalai pasižymi itin didele dimensija, kuri priklauso nuo signalo dažnio ir jo fiksavimo laiko. Sudarant prognostinius modelius, grįstus regresiniais modeliais, neapdoroti signalai, kurių dimensija siekia kelis ar keliasdešimt tūkstančių nuoseklių stebėjimų, yra netinkami. Didelės dimensijos neapdorotų signalų naudojimas tiesinės regresijos modeliuose mažina modelio stabilumą ir interpretuojamumą (Brimacombe 2014). Virpesių ir garso slėgio signalų dimensijai mažinti sudarant prognostinius modelius galima taikyti įvairius signalų apdorojimo metodus. Neapdorotų virpesių ir garso slėgio signalų duomenų apdorojimo būdus galima suskirstyti į tris pagrindines sritis (Staszewski and Worden 1997):

- laiko sritis;
- dažnio sritis;
- laiko ir dažnio sritis.

Paprastiausias laiko srities signalo atvaizdavimas yra grafinis, t. y. matuojamo signalo amplitudės priklausomybė nuo laiko. Grafinių duomenų analizė reikalauja aukštos personalo kvalifikacijos, daug laiko, priimant sprendimus išauga tikimybė priimti klaidingą sprendimą. Signalams apdoroti naudojamos diagnostinės statistikos, pateiktos 2.1 lentelėje.

Signalų analizei dažnių srityje naudojamas spektras, bispektras ir keprstras. Bispektras leidžia stebėti tuos pačius parametrus kaip ir naudojant spektrą, dar stebimas fazės pokytis. 2.2 lentelėje pateiktos diagnostinės statistikos, naudotinos dažnio srityje (Skrickij 2014).

2.1.2. Vidaus degimo variklių ekologinių ir energinių parametų prognostinio modelio sudarymo algoritmas

Eksperimento metu buvo surinkti dviejų tipų duomenys: 1) fiksuoti variklio parametrai (variklio galia, degalų tipas ir įpurškimo kampas); 2) virpesių ir garso slėgio

2.1 lentelė. Laiko srities statistiniai parametrai**Table 2.1.** Time domain statistics

$T_1 = \frac{1}{N} \sum_{n=1}^N x_n$	$T_2 = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2}$	$T_3 = \left(\frac{1}{N} \sum_{n=1}^N \sqrt{ x_n } \right)^2$
$T_4 = \frac{1}{N} \sum_{n=1}^N x_n $	$T_5 = \frac{1}{N} \sum_{n=1}^N (x_n - T_1)^3$	$T_6 = \frac{1}{N} \sum_{n=1}^N (x_n - T_1)^4$
$T_7 = \max_n x_n$	$T_8 = \min_n x_n$	$T_9 = T_7 - T_8$
$T_{10} = \frac{1}{N-1} \sum_{n=1}^N (x_n - T_1)^2$	$T_{11} = \frac{T_2}{T_4}$	$T_{12} = \frac{T_7}{T_2}$
$T_{13} = \frac{T_7}{T_4}$	$T_{14} = \frac{T_7}{T_3}$	$T_{15} = \frac{T_5}{T_2^3}$
$T_{16} = \frac{T_6}{T_2^4}$		

x_n – signalo n -ojo laiko momento reikšmė; N – signalo ilgis.

signalai. Tam, kad galutinis prognostinis modelis būtų sudarytas iš didžiausią įtaką turinčių prognostinių faktorių, pirmiausia buvo sudaryti vienmačiai prognostiniai modeliai, o tik paskui sudaromi daugiamačiai ANCOVA modeliai. Dėl šios priežasties trijų žingsnių statistinės analizės algoritmas buvo sukurtas siekiant sudaryti efektyvų VDV EEP prognostinį modelį. Tačiau prieš sudarant prognostinius modelius virpesių ir garso slėgio signalai buvo apdoroti naudojant laiko ir dažnių srities statistinius parametrus (2.1 ir 2.2 lentelės).

Pirmas žingsnis: pirminė signalų analizė. Pirmajame statistinės analizės žingsnyje buvo sudaryti vienmatės TRM siekiant nustatyti reikšmingiausius virpesių ir garso slėgio signalo laiko ir dažnių srities statistinius parametrus. Buvo sudarytas bendras TRM modelis:

$$Y^E = \alpha + \beta T_i^k + \epsilon, \quad (2.1)$$

čia Y^E – VDV EEP reikšmės (priklausomasis kintamasis); E – konkretus VDV EEP; T_i^k – i -tasis laiko / dažnių srities statistinis parametras (nepriklausomasis kintamasis); k – virpesių ar garso slėgio signalo matavimo taškas; α – laisvasis regresijos parametras; β – regresijos parametras prie nepriklausomo kintamojo; ϵ – atsitiktinė paklaida, pasiskirsčiusi pagal normalųjį skirstinį su nuliniu vidurkiu ir dispersija σ^2 .

2.2 lentelė. Dažnių srities statistiniai parametrai

Table 2.2. Frequency domain statistics

$$\begin{aligned}
 F_1 &= \frac{1}{K} \sum_{k=1}^K y_k & F_2 &= \frac{1}{K-1} \sum_{k=1}^K (y_k - F_1)^2 \\
 F_3 &= \frac{1}{K(\sqrt{F_2})^3} \sum_{k=1}^K (y_k - F_1)^3 & F_4 &= \frac{1}{K(F_2)^2} \sum_{k=1}^K (y_k - F_1)^4 \\
 F_5 &= \frac{\sum_{k=1}^K f_k y_k}{\sum_{k=1}^K y_k} & F_6 &= \sqrt{\frac{1}{K} \sum_{k=1}^K (f_k - F_5)^2 y_k} \\
 F_7 &= \sqrt{\frac{\sum_{k=1}^K f_k^2 y_k}{\sum_{k=1}^K y_k}} & F_8 &= \sqrt{\frac{\sum_{k=1}^K f_k^4 y_k}{\sum_{k=1}^K f_k^2 y_k}} \\
 F_9 &= \frac{\sum_{k=1}^K f_k^2 y_k}{\sqrt{\sum_{k=1}^K y_k \sum_{k=1}^K f_k^4 y_k}} & F_{10} &= \frac{F_5}{F_6} \\
 F_{11} &= \frac{1}{K(F_5)^3} \sum_{k=1}^K (f_k - F_6)^3 y_k & F_{12} &= \frac{1}{K(F_5)^4} \sum_{k=1}^K (f_k - F_6)^4 y_k \\
 F_{13} &= \frac{1}{K\sqrt{F_5}} \sum_{k=1}^K y_k \sqrt{(f_k - F_6)}
 \end{aligned}$$

y_k – dažnio spektras; k – spektro linijos eilės numeris; f_k – dažnis.

Antras žingsnis: prognostinio modelio sudarymas. Antras algoritmo žingsnis susideda iš dviejų dalių. Pirmoje dalyje buvo sudaromas ANOVA modelis, siekiant įvertinti fiksuotų variklio parametrų įtaką VDV EEP. Fiksuotais variklio parametrais buvo pasirinkti degalų tipas, variklio galia ir degalų įpurškimo kampas. Taigi sudarytas ANOVA modelis turėjo tokį pavidalą:

$$Y^E = \alpha + \gamma Z_j + \epsilon, \quad (2.2)$$

čia Y^E – VDV EEP reikšmės (priklausomasis kintamasis); E – konkretus VDV EEP; Z_j – nepriklausomasis kategorinis kintamasis (fiksuotas variklio parametras) su turintis j lygių; α – laisvasis regresijos parametras; γ – regresijos parametras prie nepriklausomo kategorinio kintamojo; ϵ – atsitiktinė paklaida, pasiskirsčiusi pagal normalųjį skirstinį su nuliniu vidurkiu ir dispersija σ^2 .

Antroje dalyje buvo apibendrinti TRM ir ANOVA modeliai, t. y. iš TRM ir ANOVA modelių atrinkus reikšmingiausius nepriklausomusius kintamuosius, turinčius didžiausią VDV EEP prognostinę vertę, buvo sudaryti ANCOVA modeliai kiekvienam VDV EEP. Tokiu būdu buvo sudaryti galutiniai prognostiniai ANCOVA modeliai:

$$Y^E = \alpha + \beta T_i^k + \gamma Z_j + \mu(T_i^k \times Z_j) + \epsilon, \quad (2.3)$$

čia Y^E – VDV EEP reikšmės (priklausomasis kintamasis); E – konkretus VDV EEP; T_i^k – i -asis laiko/dažnių srities statistinis parametras (nepriklausomasis kintamasis, kovariantė); k – virpesių ar garso slėgio signalo matavimo taškas; Z_j – nepriklausomasis kategorinis kintamasis (fiksotas variklio parametras) su turintis j lygių; α – laisvasis regresijos parametras; β – regresijos parametras prie nepriklausomo kintamojo; γ – regresijos parametras prie nepriklausomo kategorinio kintamojo; μ – regresijos parametras prie kategorinio kintamojo ir kovariantės sąveikos; ϵ – atsitiktinė paklaida, pasiskirsčiusi pagal normalųjį skirstinį su nuliniu vidurkiu ir dispersija σ^2 .

Trečias žingsnis: modelių tikslumo nustatymas. Trečiajame ir paskutiniame VDV EEP prognostinio modelio sudarymo algoritmo žingsnyje buvo vertinamas TRM, ANOVA ir ANCOVA modelių tikslumas. Šių modelių tikslumui įvertinti buvo pasirinkta vidutinė absoliuti procentinė paklaida (angl. *Mean Absolute Percentage Error*, MAPE) (VAPP). VAPP yra neneigiama procentinė vidutinės absoliučiosios paklaidos išraiška ir dėl savo santykinio dydžio išraiškos, neretai naudojama ir kaip modelio nuostolių funkcija, ir kaip modelio tikslumo matas. VAPP yra apskaičiuojama taip:

$$\text{VAPP} = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_i^E - \hat{Y}_i^E}{Y_i^E} \right|, \quad (2.4)$$

čia N – stebėjimų skaičius; Y^E – VDV EEP reikšmė gauta eksperimento metu; $\hat{Y}_i^E$ – VDV EEP prognozuojama reikšmė.

Yra įrodyta, kad modelio efektyvumą galima identifikuoti naudojant VAPP (De Myttenaere et al. 2016), todėl modelis, turintis mažiausią VAPP reikšmę, gali būti vadinamas efektyviu (geriausiu) VDV EEP prognostiniu modeliu.

2.1.3. Vidaus degimo variklių ekologinių ir energinių parametru prognostinio modelio sudarymo algoritmo įgyvendinimas

Virpesių ir garso slėgio reikšmės apdorojus tik laiko srities statistiniais parametrais sudaryti VDV EEP prognostiniai ANCOVA modeliai gali būti pateikiami naudojant šias išraiškas:

- degalų masės srautui, CO, CO₂, NO_X, THC, CO_{sick}, O₂, oro masės srautui ir t_{exhaust} :

$$Y^E = \alpha + \beta T_{11}^{H1} + \gamma \times VG + \mu(T_{11}^{H1} \times VG) + \epsilon \quad (2.5)$$

- t_{air} ir t_{fuel} :

$$Y^E = \alpha + \beta T_{11}^{H1} + \gamma \times DT + \mu(T_{11}^{H1} \times DT) + \epsilon, \quad (2.6)$$

čia VG – variklio galia; DT – degalų tipas.

Realizavus sudarytus modelius buvo pastebėta, kad modeliai gali prognozuoti VDV EEP esant dideliai variklio galiai arba naudojant degalų mišinius, tačiau varikliui veikiant mažesnės galios režimu ar naudojant gryną dyzeliną, papildoma kovariantė (virpesiai apdoroti laiko srities statistiniais parametrais) modelio nepatiksina ir modelis ANCOVA modelio prognostinė kreivė sutampa su vienfaktorio ANOVA modelio kreive (2.2 pav.).


Modelio patikslinimui buvo įtraukti papildomi laiko srities statistiniai parametrai bei nauji dažnių srities statistiniai parametrai, kurios turėjo reikšmingą įtaką VDV EEP TRM modelyje. Tokiu būdu išplėtus prognostinį modelį, buvo gauti nauji ANCOVA modeliai, kuriuose jau buvo įtrauktos virpesių ir garso slėgio reikšmės apdorotos dažnių srities statistiniais parametrais:

- degalų masės srautui, CO, CO₂, NO_X, THC, CO_{sick}, O₂, oro masės srautui ir t_{exhaust} :

$$\begin{aligned} Y^E = & \alpha + \beta_1 T_{11}^{H1} + \beta_2 T_5^{V1} + \beta_3 T_5^{GS} + \beta_4 F_4^{GS} + \beta_5 F_{12}^{GS} \\ & + \gamma \times VG \\ & + \mu_1(T_{11}^{H1} \times VG) + \mu_2(T_5^{V1} \times VG) \\ & + \mu_3(T_5^{GS} \times VG) + \mu_4(F_4^{GS} \times VG) \\ & + \mu_5(F_{12}^{GS} \times VG) + \epsilon, \end{aligned} \quad (2.7)$$

- t_{air} ir t_{fuel} :

$$\begin{aligned} Y^E = & \alpha + \beta_1 T_{11}^{H1} + \beta_2 T_5^{V1} + \beta_3 T_5^{GS} + \beta_4 F_4^{GS} + \beta_5 F_{12}^{GS} \\ & + \gamma \times DT \\ & + \mu_1(T_{11}^{H1} \times DT) + \mu_2(T_5^{V1} \times DT) \\ & + \mu_3(T_5^{GS} \times DT) + \mu_4(F_4^{GS} \times DT) \\ & + \mu_5(F_{12}^{GS} \times DT) + \epsilon, \end{aligned} \quad (2.8)$$




2.2 pav. Vidaus degimo variklių ekologinių ir energinių parametų realios ir prognostinės reikšmės, kai naudojami tik laiko srities statistiniai parametrai: a) oro masės srautas; b) t_{air}

Fig. 2.2. Real and prognostic values of ecological and energetic parameters of the engine when time domain statistics are used: a) air mass flow; b) t_{air}

čia Y^E – VDV EEP reikšmės (priklausomasis kintamasis); E – konkretus VDV EEP, T žymi laiko srities statistinius parametrus; F žymi dažnių srities statistinius parametrus; $H1$ – horizontalūs virpesiai; $V1$ – vertikalūs virpesiai; GS – garso slėgis; indeksas prie T ir F žymi statistikos numerį iš 2.1 ir 2.2 lentelių; $\alpha, \beta_i, \gamma, \mu_i$ – ANCOVA modelio parametrai; ϵ – atsitiktinė paklaida, pasiskirsčiusi pagal normalųjį skirstinį su nuliniu vidurkiu ir dispersija σ^2 ; VG – variklio galia; DT – degalų tipas.

Kadangi naują išplėstą modelį sudarė nebe 3 prognostiniai faktoriai, o 11, tai papildomai buvo atlikta parametų optimizacija pagal 1.1.1 skyrelyje aprašytą metodiką.



2.3 pav. Vidaus degimo variklių ekologinių ir energinių parametų realios ir prognostinės reikšmės, kai naudojami laiko ir dažnių srities statistiniai parametrai: a) oro masės srautas; b) t_{air}

Fig. 2.3. Real and prognostic values of ecological and energetic parameters of the engine when time and frequency domain statistics are used: a) air mass flow; b) t_{air}

Išplėstas modelis pagerino prognostines vertes esant mažai variklio galiai ar naudojant gryną dyzeliną (2.3 pav.). Įdomu pastebėti, kad modelis geriausiai prognozavo VDV EEP netaikant jokios regresijos parametų optimizacijos.

Detalus prognostinių modelių įgyvendinimas aprašytas 3 skyriuje.

2.2. Mašininio mokymosi klasifikavimo modelių sudarymas

Šiame poskyryje pristatomi modeliai sudaryti hipoidinės pavaros (HP) gedimams klasifikuoti ir juostinio konvejerio diržo (JKD) apkrovos būklėms klasifikuoti. Su-

daryti HP modeliai kaip įeities parametrus naudojo tik HP skleidžiamus virpesius, o sudaryti JKD modeliai naudojo diržo įtempio signalą.

2.2.1. Hipoidinės pavaros gedimų klasifikavimo modeliai


Šiame skyrelyje aprašomas tyrimas, kuriame buvo sudaryti HP gedimų diagnostikos klasifikavimo modeliai, paremti virpesių duomenų analize. Buvo iškelti šie tyrimo tikslai: 1) sudaryti giliojo mokymosi modelius skirtus, HP gedimams klasifikuoti; 2) nustatyti geriausiai ir blogiausiai klasifikuojamus HP gedimus; 3) ištirti skirtingo sukimo momento ir sukimosi greičio įtaką klasifikavimo tikslumui. Tikslams pasiekti buvo sudaryti giliojo mokymosi algoritmai, tokie kaip SNT, ITAM ir TNT.

Eksperimento aprašymas. HP tyrimai buvo atlikti Ilmenau technologijos universitete (Skrickij 2014). HP virpesių signalo duomenys buvo surinkti eksperimentiniu būdu, tiriant virpesių signalo pokyčius skirtingomis eksperimento sąlygomis. Eksperimento metu buvo keičiamas sukimosi greitis, sukimo momentas ir pažaidos tipas. Buvo pasirinkti penki sukimosi greičiai (1000, 2000, 3000, 4000 ir 5000 aps./min.) bei penki sukimo momentai (25, 50, 75, 100 ir 125 Nm) (Skrickij et al. 2016). Taip pat buvo pasirinktos septyni skirtingi pavaros pažaidų tipai. Pavara be pažaidų buvo pažymėta kaip 0 tipas, toliau pavaros pažaidos 1 tipas buvo vieno danties pažaida (2.4a pav.), 2–4 pažaidų tipai atitiko vieno danties didėjančią pažaidą (2.4a–d pav.), 5 tipas buvo, kai pažeisti 2 dantys (2.4e pav.), 6 tipas, kai pažeisti 3 dantys (2.4f pav.).

Virpesių signalas buvo matuojamas 5 s kiekvienam eksperimentui ir buvo filtruojamas 0,003–10 kHz diapazone. Virpesių signalui matuoti buvo naudojamas *Sinus Harmonie* duomenų kaupiklis, duomenų fiksavimo dažnis 51200 S/s, jutikliai 353B16 10 mV/g, dažnio intervalas 0,35–30 000 Hz (± 5 dB); AS-065 100 mV/g, dažnio intervalas 1–15 000 Hz (± 3 dB). Jutikliai sumontuoti ant HP korpuso.

Daugelio klasių klasifikavimo modelių sudarymas. Atliekant HP tyrimą, buvo atlikti du nepriklausomi eksperimentai, kur kiekviename eksperimente buvo atliekami virpesių matavimai visiems sukimo momento ir apskukų deriniams. Pirmojo eksperimento duomenys buvo skirti modeliams mokytis ir validuoti, o antrojo – modeliams testuoti.

Prieš atliekant modelių mokymąsi, validavimą ir testavimą, buvo atliktas duomenų išplėtimas. Kadangi eksperimento metu, kai 5 s buvo fiksuojamos virpesių signalo reikšmės, jokie parametrai nebuvo keičiami, laikoma, kad visas 5 s ilgio virpesių signalas yra homogeniškas. Todėl virpesių signalas buvo padalintas į 50 trumpų 0,1 s ilgio signalų. Papildomai mokymosi aibė buvo padidinta keturis kartus. Tai buvo atliekama imant fiksuotą 0,1 s ilgio virpesių signalo langą ir jį slenkant per visą 5 s ilgio virpesių signalą bei pridedant Laplaso tipo atsitiktinį triukš-



2.4 pav. Hipoidinės pavaros pažaidos (Skrickij et al. 2016): a) 1 tipas; b) 2 tipas; c) 3 tipas; d) 4 tipas; e) 5 tipas; f) 6 tipas


Fig. 2.4. Faults of hypoid gear (Skrickij et al. 2016): a) condition 1; b) condition 2; c) condition 3; d) condition 4; e) condition 5; f) condition 6

mą $\mathcal{L}(0, s)$, čia s – standartinis virpesių signalo nuokrypis. Iliustraciniai virpesių signalo formų pavyzdžiai parodyti 2.5 paveiksle. Taip pat 2M-SNT modeliui kiekvienas virpesių signalas buvo transformuojamas į Mel spektrogramą (Hoshen et al. 2015). Virpesių signalo Mel spektrogramos pavaizduotos 2.6–2.9 paveiksluose.

HP klasifikuoti buvo sukurti keturi GNT modeliai: 1M-SNT, 2M-SNT, ITAM ir TNT. Neapdorotas virpesių signalas buvo naudojamas 1M-SNT, ITAM ir TNT modeliams, o virpesių signalo Mel spektrogramos buvo naudojamos 2M-SNT. Tam, kad būtų klasifikuojamos visos septynios (0–6 tipai) pavaros būklės, buvo sprendžiamas daugelio klasių klasifikavimo uždavinys ir sukurti atitinkami modeliai. Galiausiai pavaros būklės buvo suskirstytos į dvi grupes: sveika pavarą ir pavarą su bet kokia pažaida.

Modeliams mokytis ir validuoti buvo naudojami tik pirmojo tyrimo etapo eksperimentiniai duomenys: 80 % duomenų buvo skirti modeliams mokytis, 20 % – validuoti. Modeliams testuoti buvo naudojami tik antrojo tyrimo etapo eksperimentiniai duomenys. Eksperimentų metu keičiami pavaros apskukų bei sukimo momento parametrai į klasifikavimo modelius įtraukti nebuvo, t. y. modeliams buvo žinomi tik virpesių signalai.

Tyrimo metu modeliai buvo nuolat konfigūruojami ir buvo ieškoma modelio parametrų rinkinio, kuris gebėtų tiksliausiai klasifikuoti pažaidas per priimtą




2.5 pav. Virpesių signalo formų iliustracija su 125 Nm sukimo momentu ir 5000 aps./min. apskukų:
a) 0 tipas; b) 1, 2 ir 3 tipai; c) 4, 5 ir 6 tipai

Fig. 2.5. Illustration of raw vibration waveforms with 125 Nm torque at 5000 RPM: a) condition 0;
b) conditions 1, 2, and 3; c) conditions 4, 5, and 6

laiko tarpą. Geriausios modelių architektūros (pasiektas didžiausias klasifikavimo tikslumas) parodytos 2.3 lentelėje. Visų modelių mokymosi ir validacijos metu buvo atliekama 30 epochų su 32 duomenų rinkinio dydžiu bei židinio tikslo funkcija (angl. *Focal Loss*) (Lin et al. 2017).


2.2.2. Juostinio konvejerio diržo apkrovos būsenų klasifikavimo modeliai

Šiame skyrelyje aprašomas tyrimas, kuriame buvo sudaryti JKD būklių klasifikavimo modeliai paremti diržo įtempio duomenų analize. Buvo iškelti šie tyrimo tikslai: 1) sudaryti mašininio mokymosi modelius, skirtus apkrautam ir neapkrautam JKD klasifikuoti; 2) nustatyti trumpiausią įtempio signalo ilgį, kuris leistų pasiekti maksimalų klasifikavimo tikslumą; 3) įvertinti geriausio modelio jautrumą,




2.6 pav. Virpesių signalo Mel spectrogramos iliustracija su 125 Nm sukimo momentu ir 5000 aps./min. apsukų: 0 tipas

Fig. 2.6. Illustration of vibration signal Mel spectrogram with 125 Nm torque at 5000 RPM: condition 0




2.7 pav. Virpesių signalo Mel spectrogramos iliustracija su 125 Nm sukimo momentu ir 5000 aps./min. apsukų: a) 1 tipas; b) 2 tipas

Fig. 2.7. Illustration of vibration signal Mel spectrogram with 125 Nm torque at 5000 RPM: a) condition 1; b) condition 2



2.8 pav. Virpesių signalo Mel spectrogramos iliustracija su 125 Nm sukimo momentu ir 5000 aps./min. apskūkų: a) 3 tipas; b) 4 tipas

Fig. 2.8. Illustration of vibration signal Mel spectrogram with 125 Nm torque at 5000 RPM: a) condition 3; b) condition 4



2.9 pav. Virpesių signalo Mel spectrogramos iliustracija su 125 Nm sukimo momentu ir 5000 aps./min. apskūkų: a) 5 tipas; b) 6 tipas

Fig. 2.9. Illustration of vibration signal Mel spectrogram with 125 Nm torque at 5000 RPM: a) condition 5; b) condition 6

kai įtempio signalė atsiranda papildomas triukšmas. Tikslams pasiekti buvo sudaryti giliojo mokymosi algoritmai, tokie kaip ITAM ir TNT. Modeliams palyginti buvo sudaryti ir klasikiniai mašininio mokymosi modeliai.

Tyrimo pradžioje buvo sukurta JKD stebėjimo sistema, pagrįsta deformacijų matuokliais (2.10 pav.), kad būtų galima imituoti JKD darbą. Jį sudarė du reguliuojamo sukimosi greičio voleliai ir guminis diržas tarp jų. Naudotas EDV08PB-AS 2.0 tipo, 2 mm storio diržas, pritaikytas darbui su minimalaus skersmens 30 mm voleliais. Jis turėjo du vidinius sluoksnius ir PVC išorinę dangą vienoje pusėje, kuri užtikrino vidinę darbo jėgą $F_{1\%} = 8 \text{ N/mm}$.

Eksperimentinis įrenginys leido iš pradžių reguliuoti įtempimą, kad ant vo-
lo abiejose diržo pločio pusėse būtų pasiekta panaši spaudimo jėga. Diržo pločio viduryje spaudimo jėga visada yra šiek tiek didesnė. Tokiu būdu sistema su de-
formacijos matuokliais išsprendė keletą problemų, kurias nurodė kiti tyrėjai, tyrę

2.3 lentelė. Klasifikavimo modelių architektūra**Table 2.3.** Architecture of classification models


Modelis	Architektūra
1M-SNT Nežinomų parametrų skaičius: 17199	Conv1D(64(3)) → BN-AP(3)-Conv1D(32(3)) → BN-AP(3)-Conv1D(16(3)) → BN-AP(3)-Conv1D(8(3)) → BN-AP(3)-Flatten-Dense(16)-DO(0.2)-Dense(16) → softmax
2M-SNT Nežinomų parametrų skaičius: 35103	Conv2D(64(3,3)), relu → BN-MP(2,2)-Conv2D(32(2,2)) → BN-MP(2,2)-Flatten-Dense(16) → BN-DO(0.2)-Dense(7) → softmax
ITAM Nežinomų parametrų skaičius: 233279	TD(Conv1D(512(3)), relu → BN-TD(AP(2))-TD(Conv1D(128(3))), relu → BN-TD(DO(0.5))-TD(AP(2))-TD(Conv1D(32(3))), relu → BN-TD(DO(0.5))-TD(AP(2))-TD(Conv1D(8(3))), relu → BN-TD(DO(0.5))-TD(AP(2))-TD(Flatten) → LSTM(16)-DO(0.5)-LSTM(16) → softmax
TNT Nežinomų parametrų skaičius: 44887	Patch(10) → PatchEnc(16) → N → MHA(8) → N → Dense(64) → DO(0.1) → Dense(64) → DO(0.1) → MHA(8) → N → Dense(64) → DO(0.1) → Dense(64) → DO(0.1) → N → Flat → Dense(64) → Dense(64) → Softmax

AP(x) – sutelkimo vidurkinant sluoksnis su x sluoksnio dydžiu; N – normalizacija; BN – duomenų rinkinio normalizacija; Conv1D($x(y)$) – vienmatė sąsūka su x filtrų ir y branduolių dyžiu; Conv2D($x(y, z)$) – dvimatė sąsūka su x filtrų ir y, z branduolių dyžiu; relu – aktyvacijos funkcija; Flatten – ištiesinimo sluoksnis; DO(x) – išmetimo santykis; MP(x, y) – sutelkimo imant maksimalią reikšmę sluoksnis su x ir y sluoksnio dydžiu; TD – pasiskirstęs laike; Patch – signalo taisymas; PatchEnc – pozicinis kodavimas.

diržo įtempimą (Zhao 2011) ir netinkamą juostos sekimą veikiant konvejeriui (Kobayashi and Toya 2007).


Bandymų sesija apėmė statinės įtampos matavimą esant 2 kg apkrovai skirtinguose JKD taškuose ir matavimus dinaminėmis sąlygomis. Šios sąlygos darė prielaidą, kad linijinio diržo greičių diapazonas yra tarp $\nu_1 = 0,5$ m/s ir $\nu_{\max} = 1,7$ m/s, kuris atitiko tipines pramoninių smulkių komponentų transportavimo sąlygas. Judančio diržo įtempimas buvo matuojamas tiek esant apkrovai, tiek be apkrovos.

Pagrindinė naujosios JKD koncepcijos idėja buvo įdėti įtempimo matuoklius tiesiai ant volelio paviršiaus, kad jie taptų nuo įtempimo priklausomos diržo slėgio



2.10 pav. Konvejerio juostos įtempimo eksperimentinio įrenginio a) schema ir b) nuotrauka:
 1) matavimo sistema, įmontuota į volelį; 2) reduktoriaus tvirtinimo plokštelė; 3) varančiojo volelio sandariklis; 4) įtempimo reguliavimas; 5) vedantis siūlas; 6) reguliavimo veržlė; 7) tuščiaaviduris velenas; 8) guminis diržas; 9) įtempio matuoklis ant volelio paviršiaus; 10) guolis; 11) variklio reduktorius

Fig. 2.10. Conveyor belt tension experimental rig a) scheme and b) photo: 1) measurement system imbedded in the roller; 2) reducer fixing plate; 3) seal of the driving roller; 4) tension regulation; 5) leading thread; 6) regulating nut; 7) precise hollow shaft; 8) rubber belt; 9) strain gauge on the roller surface; 10) bearing; 11) motor reducer



2.11 pav. Teorinis ir realus juostinio konvejerio įtempio signalas: T1 – diržo įtempio matuoklis nutolęs nuo apkrovos; T2 – diržo įtempio matuoklis pritvirtintas apkrovos pusėje


Fig. 2.11. Theoretical and actual conveyor belt tension signals: T1 when belt tension gauge is set away from the load; T2 when belt tension gauge is mounted on the load side

jėgos objektu. Įrenginį sudarė du įtempimo matuokliai, vienas ritinio ilgio viduryje, o kitas jo gale, signalų priėmimo ir perdavimo sistema bei speciali programinė įranga duomenims apdoroti ir pateikti. Po pirminių bandymų nustatyta, kad deformacijų matuokliai CP 152 NS yra optimalūs (Ryba 2021). Jų nominalus jautrumas buvo 0,5–0,8 mV/V, duomenų rašymo dažnis iki – 20 000 Hz, o atsako laikas – 5 μ s, todėl matuokliai buvo kvalifikuoti atlikti dinامينius matavimus.

Įtempimo matuokliai, veikiami JKD spaudimo jėgos, buvo sujungti su elektrosine sistema, įtaisyta tuščiaviduriame volelyje. Sukurta matavimo sistema galėjo nuolat matuoti diržo spaudimo jėgą F , taip pat rinkti ir perduoti duomenis per Bluetooth prievadą. Tada kompiuterio gauti duomenys buvo apdorojami realiuoju laiku, naudojant LabView programinę įrangą (Bzinkowski et al. 2022).

Apkrovų matuokliai (veikimo skersmuo – 16 mm) buvo pritvirtinti vienoje volo pusėje taip, kad jie būtų veikiami apkrovos jėgos tik tada, kai ši konkreti pusė buvo po konvejerio diržu. Tokiu būdu matuokliai apkrovos jėgos signalus skleisdavo tik per pusę volo apsisukimo laiko. Teoriškai, darant prielaidą, kad diržo vidinė įtampa pasiskirstys tolygiai, apkrovos signalai turėtų atitikti tam tikrą iš anksto apibrėžtą pasiskirstymą pavaizduotą 2.11 pav., kur kiekvienas sukimas atitinka ciklinį signalą, rodantį atitinkamą diržo įtempimo matuoklio slėgio impulsą. Tačiau realiomis sąlygomis labai sudėtingas dinaminis vidinių įtampų pasiskirstymas lėmė tam tikrus skirtumus tarp impulsų formos ir pačių impulsų formų (2.11 pav.). Realiose įtampų signaluose kiekviename jų pulse yra stebimi du maksimumai: pirmasis maksimumas, primenantis spyglio formą, stebimas pulso pradžioje, o antrasis kalvelės formos maksimumas atsiranda pulso vidurinėje dalyje.

Detalesnei diržo įtempio signalo (DĮS) analizei visi signalo pikai buvo išskirti iš vientiso signalo ir išcentruoti pagal jų pradžios tašką. Šie vieno piko signalai pavaizduoti 2.12 paveiksle, čia taip pat pavaizduoti vidutiniai su apkrova ir be apkrovos pikų signalai. Taigi vidutiniškai DĮS gauti iš apkrauto JKD yra didesni (žr. 2.12 pav., raudona kreivė). Vis gi nepaisant to, kad vidurkių kreivės išsiskyrė,



2.12 pav. Juostinio konvejerio diržo įtempio signalo pikas

Fig. 2.12. Conveyor belt tension peak

bet kuriuo laiko momentu apkrauto ir ne apkrauto JK DĮS pasiskirstymai stipriai persidengia ir pikų kreivės tampa sunkiai atskiriamos. Verta pažymėti, kad JKD tuščiosios eigos metu pikų kreivių pasiskirstymas turėjo didesnius nuokrypius nei esant apkrovai. Tai taip pat leidžia daryti išvadą, kad kreivės, išskyrus jų formą, bet kuriuo metu buvo neatskiriamos.

Eksperimento metu buvo pasirinktas 400 Hz diskretizavimo dažnis. Tai atitiko 140 įtempio matavimų per apsisukimą esant minimaliam 159 aps/min sukimosi greičiui (tiesinis JKD greitis buvo $v_{\min} = 0,5$ m/s) arba 45 įtempio matavimus per apsisukimą esant maksimaliam 540 aps./min. sukimosi greičiui (tiesinis JKD greitis buvo $v_{\max} = 1,7$ m/s).

Eksperimento metu buvo fiksuojami nuoseklūs apkrauto ir neapkrauto JK DĮS duomenys (2.11 pav.). Kadangi buvo atlikta tik 20 kartotinių eksperimentų, surinktų duomenų kiekis buvo nepakankamas mašininio mokymosi modeliams vystyti, t. y. modeliams mokytis, validuoti ir testuoti. Tariant, kad gauti DĮS yra homogeniški, buvo atlikta dviejų žingsnių DĮS kiekio padidinimo procedūra siekiant gerokai padidinti eksperimentinių duomenų kiekį. Pirmajame DĮS kiekio padidinimo žingsnyje buvo naudojamas slenkančio iškirpto fragmento metodas:

$$S_m^i = [1 + i; m + i], \quad i = 0, 1, \dots, 2000 - m, \quad (2.9)$$

čia S_m^i – m ilgio i -tasis DĮS; m – DĮS ilgis; i – DĮS padalijimo žingsnis. Po pirmojo DĮS padidinimo žingsnio trumpiausių signalų aibė turėjo daugiausia sugeneruotų DĮS ($N = 384\,200$) (2.4 lentelė).

Antrasis DĮS padidinimo žingsnis rėmėsi duomenų išplėtimo metodu, t. y. prie eksperimento metu surinktų DĮS buvo pridedamas papildomas triukšmas. Jis buvo sudarytas kaip dviejų tipų triukšmų suma. Pirmasis triukšmo signalas buvo kumuliatyvinė atsitiktinių dydžių, pasiskirsčiusių pagal normalų skirstinį $\mathcal{N}_i(x|\mu, \sigma^2)$ su vidurkiu $\mu = 0$ ir dispersija σ^2 reikšmė. Šis triukšmas leido pasiekti nedidelį signalo nukrypimą, kuriuos galima traktuoti kaip sistemos gedimą. Antrasis triukš-

2.4 lentelė. Įtempio signalų skaičius po pirmojo ir antrojo diržo įtempio signalo padidinimo žingsnių

Table 2.4. Data augmentation: number of signals after the first augmentation step and number of signals required to be generate in the second augmentation step

Signalų ilgis, s	Matavimo taškai	DĮS padidinimas	
		1 žingsnis	2 žingsnis
0,2	80	384 200	0
0,4	160	368 200	16 000
0,8	320	336 200	48 000
1,6	640	272 200	112 000
3,2	1280	144 200	240 000
5,0	2000	200	384 000

Bendras DĮS skaičius kiekvienam signalo ilgiui buvo 384 200.

mo tipas yra atsitiktinis dydis, pasiskirstęs pagal Laplaso skirstinį. Šis triukšmas į signalą įveda didelius nuokrypius, tačiau tokių stebėjimų yra mažai. Šie triukšmai gali būti apibrėžti taip:

$$U_i = \mathcal{U}^{-1}(0, 1), \quad i = 1, 2, \dots, m, \quad (2.10)$$

$$F_1(x) = \mathcal{N}_i(x|0, \sigma^2) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}(x/\sigma)^2}, \quad (2.11)$$

$$F_2(x) = \frac{1}{2\sigma} e^{-|x|/2\sigma}, \quad (2.12)$$

$$\begin{aligned} N_i &= N_i^{\text{CNorm}} + N_i^{\text{Lap}} \\ &= \left(\sum_{j=1}^i F_1^{-1}(U_j) \right) + F_2^{-1}(U_i), \end{aligned} \quad (2.13)$$

čia U_i – atsitiktinis stebėjimai generuoti tolygiojo skirstinio; σ – standartinis skirstinio nuokrypis.

Šie atsitiktiniai triukšmai buvo susumuoti su DĮS, kurie buvo gauti iš pirmojo DĮS padidinimo žingsnio. Antrojo DĮS padidinimo žingsnio rezultatai parodyti 2.4 lentelėje.

Tyrimo metu buvo sudaryti penki dviejų klasių klasifikavimo mašininio mokymosi modeliai, skirti apkrautai ir neapkrautai JKD būklei identifikuoti: LR, AVM, AM, ITAM ir TNT. LR, AVM ir AM modelių mokymosi ir testavimo aibės atitinkamai sudarė 80 % (307 360 DĮS) ir 20 % (76 840 DĮS) visų eksperimento duomenų. ITAM ir TNT modeliams buvo priskirta papildoma validavimo aibė. Taigi šių modelių mokymosi, validavimo ir testavimo aibės sudarė 70 % (268 940 DĮS), 10 % (38 420 DĮS) ir 20 % (76 840 DĮS) visų eksperimento duomenų.

2.5 lentelė. Klasifikavimo modelių architektūra

Table 2.5. Architecture of classification models

Modelis	Architektūra / hiperparametras
LR	nėra hiperparametrų
AVM	C=1.0, kernel='rbf', degree=3,
AM	n_estimators=100, criterion='gini', max_depth=8, min_samples_split=2, bootstrap=True
ITAM*	LSTM(128, input.shape(signal_length,1)) → Dropout(0.2) → LSTM(8) → dense(1, sigmoid)
TNT*	input.shape(signal_length,1)) Nuosekliams blokams: Normalization(epsilon=1e-6)(input) → MultiHeadAttention(key_dim=64, num_heads=8, dropout=0.25) → d := Dropout(0.25) Normalization(d, epsilon=1e-6) Conv1D(filters=4, kernel_size=1, relu) → Dropout(0.25) → c := Conv1D(kernel_size=1) → input := c + d + input MLP part: GlobalAveragePooling1D(input) → Dense(128, relu) → Dropout(0.4) → outputs = dense(1, sigmoid)

*ITAM modelio hiperparametrų skaičius buvo 70 953. TNT modelio hiperparametrų skaičius variavo nuo 17 033 iki 78 473 ilgėjant signalui.

Tyrimo metu modeliai buvo nuolat konfigūruojami, buvo ieškoma modelio parametrų rinkinio, kuris gebėtų tiksliausiai identifikuoti JKD būklę. Geriausios modelių architektūros parodytos 2.5 lentelėje. ITAM ir TNT modelių mokymosi ir validacijos metu buvo atliekama 20 epochų su 8 duomenų rinkinio dydžiu bei dvinarės kryžminės entropijos (angl. *Cross Entropy*) tikslo funkcija.

LR, AVM ir AM modeliams vietoj neapdorotų DĮS buvo naudojama 16 laiko srities statistinių parametrų, apskaičiuotų iš neapdorotų DĮS (2.1 lentelė). Tokiu būdu visi 0,2 s (80 taškų), 0,4 s (160 taškų), 0,8 s (320 taškų), 1,6 s (640 taškų), 3,2 s (1280 taškų) ir 5,0 s (2000 taškų) ilgio DĮS buvo apdoroti į vienodos ir daug kartų sumažintos dimensijos signalus. Ši DĮS transformacija leidžia tiksliau interpretuoti LR, AVM ir AM modelių rezultatus. Visgi taikant sudarytus ITAM ir TNT modelius, kurie naudoja neapdorotus duomenis, galima gauti kur kas geresnius klasifikavimo rezultatus.

Sudarytų JKD apkrovos būsenų klasifikavimo modelių testavimas parodė, kad modelių tikslumas monotoniškai auga kartu su augančiu klasifikuoti naudojamo signalo ilgiu. Klasikinių mašininio mokymosi modelių tikslumas buvo mažesnis nei ITAM bei TNT modelių. Be to, šie modeliai gebėjo tiksliau mokytis ir klasifikuoti naudodami gerokai trumpesnio ilgio DĮS. Klasikinių mašininio mokymosi modelių tikslumas nepasiekė 80 % bendro tikslumo naudojant bet kokio ilgio DĮS,

o TNT 100 % tikslumą pasiekė naudodamas 5 s ilgio DĮS, o ITAM 100 % pasiekė naudodamas tik 3,2 s ilgio DĮS. Apibendrinus modelių tikslumą, buvo sudaryta nelygybė:

$$\begin{aligned} \text{bendras tikslumas}_{LR} &\leq \text{bendras tikslumas}_{AVM} \leq \text{bendras tikslumas}_{AM} \\ &\leq \text{bendras tikslumas}_{TNT} \leq \text{bendras tikslumas}_{ITAM}. \end{aligned} \quad (2.14)$$

2.3. Antrojo skyriaus išvados

1. Taikant sudarytą ANCOVA modelį, galima prognozuoti vidaus degimo variklio ekologinius ir energinius parametrus. Sudarytų prognostinių ANCOVA modelių kreivės geriau atspindi eksperimentinius duomenis, kai yra virpesių signalas apdorojamas ir laiko ir dažnių srities statistiniais parametrais.
2. Hipoidinės pavaros gedimams klasifikuoti sudaryti daugelio klasių gilieji neuroniniai tinklai (sąsūkos ir transformerio neuroninių tinklų bei ilgos trumpalaikės atminties modeliai) didžiausią tikslumą pasiekė mokymo metu atliekant 30 epochų su 32 duomenų rinkinio dydžiu bei naudojant židinio (angl. *Focal Loss*) tikslo funkciją.
3. Juostinio konvejerio diržo apkrovos būklei klasifikuoti sudaryti dviejų klasių klasikiniai (logistinės regresijos, atraminių vektorių ir atsitiktinių miškų modeliai) ir gilieji neuroniniai tinklai (transformerio neuroniniai tinklai bei ilgos trumpalaikės atminties modeliai) geriausią tikslumą pasiekė mokymo metu atliekant 20 epochų su 8 duomenų rinkinio dydžiu bei naudojant kryžminės entropijos (angl. *Cross Entropy*) tikslo funkciją.
4. Transformerio neuroninių tinklų ir ilgos trumpalaikės atminties modeliai yra tikslesni nei klasikiniai mašininio mokymosi modeliai.

Sudarytų prognostinių bei mašininio mokymosi modelių įgyvendinimas mechatroninėse sistemose

Šiame skyriuje aprašyti sudarytų prognostinių ir klasifikavimo modelių taikymo rezultatai. Prognostiniai modeliai buvo pritaikyti vidaus degimo variklių ekologiniams ir energiniams parametrų (VDV EEP) prognozuoti. Mašininio mokymosi daugelio klasių klasifikavimo modeliai buvo pritaikyti sprendžiant hipoidinės pavaros gedimų klasifikavimo uždavinį, o dviejų klasių mašininio mokymosi modeliai, skirti įtempio signalams klasifikuoti, pritaikyti klasifikuojant juostinio konvejerio diržo apkrovimo būsenas.

Pirmiausia VDV EEP bei variklio skleidžiamų virpesių ir garso slėgio signalų sąryšiai buvo nustatyti mažos apimties bandomajame tyrime ir aprobuoti mokslinėje publikacijoje (Kriauciūnas et al. 2021). VDV EEP prognostinių modelių pritaikymo rezultatai aprobuoti mokslinėje publikacijoje (Žvirblis et al. 2021a) ir mokslinėje konferencijoje (Žvirblis 2021). Klasifikavimo modeliai skirti hipoidinės pavaros gedimams ir juostinio konvejerio diržo apkrovos būklėms klasifikuoti yra aprobuoti mokslinėje publikacijoje (Žvirblis et al. 2021b) ir mokslinėje konferencijoje (Žvirblis et al. 2022).

3.1. Vidaus degimo variklių ekologinių ir energinių parametrų prognozavimas

Prieš sudarant VDV EEP prognostinius modelius yra labai svarbu įvertinti galimus sąryšius tarp priklausomojo parametro (emisijos) ir nepriklausomųjų prognostinių

faktorių, todėl šiame poskyryje pirmiausia yra aprašomi bandomojo tyrimo, skirto VDV EEP ir virpesių bei garso slėgio signalų sąryšiams įvertinti, rezultatai. Antroje poskyrio dalyje aprašomi konkrečių VDV EEP prognostinių modelių rezultatai.

3.1.1. Vidaus degimo variklių ekologinių ir energinių parametrų ir virpesių sąryšių tyrimas

Šiame skyrelyje aprašomas tyrimas, taikant statistinės analizės metodus, analizuojami VDV EEP. Atlikta išsami koreliacinė analizė, siekiant įvertinti VDV EEP ryšį su virpesių ir garso slėgio duomenimis.


Eksperimentiniai bandymai buvo atlikti naudojant keturių cilindrų, kibirkštinio uždegimo „Nissan“ kompanijos variklį HR16DE (3.1 lentelė). Degalų masės srauto matuokliai, išmetamųjų dujų analizatoriai ir variklis buvo pritaikyti biodujoms. Modifikuotas variklio įsiurbimo kolektorius ir pridėtas CH₄ purkštukas. Variklio elektroninio valdymo prietaisas pakeistas perprogramuotu „MoTeC M800“ elektroninio valdymo prietaisu. Naujas elektroninio valdymo prietaisas leido reguliuoti kibirkšties laiką ir įpurškiamų biodujų kiekį. Tiesioginiam oro ir degalų santykio stebėjimui buvo pridėtas plačiajuostis deguonies jutiklis „Bosch LSU 4.9“. Siekiant išlaikyti stabilią variklio darbinę temperatūrą visų eksperimentų metu, į variklį aušinimo sistemą buvo pridėtas plokštelinis šilumokaitis.

Variklio apkrova ir alkūninio veleno greitis reguliuojamas variklio apkrovos stovu AMX200/100 su 0,9 Nm tikslumu. Įsiurbiamo oro masė išmatuota „BOSCH HFM 5“ matuokliu 2 % tikslumu. Biodujų sudėtis atkurta naudojant du atskirus CH₄ ir CO₂ rezervuarus. Dujų masės srautas matuotas dviem atskirais „Coriolis“

3.1 lentelė. Kibirkštinio įpurškimo variklio HR16DE techninės charakteristikos

Table 3.1. Technical characteristics of spark injection engine HR16DE

Parametras	Reikšmė
Cilindrų skaičius	4
Ištūmimas, dm ³	1,598
Cilindro anga, mm	78,0
Stūmoklio eiga, mm	86,6
Variklio galia, kW (aps./min.)	84 (6000)
Variklio sukimo momentas, Nm (aps./min.)	156 (4400)
Suspaudimo santykis	10,7
Atidaryti įsiurbimo vožtuvai, CAD BTDC1	24
Uždaryti įsiurbimo vožtuvai, CAD BTDC1	72
Atidaryti išmetimo vožtuvai, CAD BTDC1	24
Uždaryti išmetimo vožtuvai, CAD BTDC1	10



3.1 pav. Eksperimento schema: 1) HR16DE kibirkštinio uždegimo variklis; 2) jungiamasis velenas; 3) variklio apkrovos stovas; 4) apkrovos stovo elektroninio valdymo prietaisas ir ekranas; 5) alkūninio veleno padėties jutiklis; 6) uždegimo žvakė su slėgio jutikliu; 7) cilindro slėgio registravimo įranga; 8) išmetamųjų dujų temperatūros jutiklis; 9) išmetamųjų dujų temperatūros ekranas; 10) plačiajuostis deguonies jutiklis; 11) perprogramuotas variklio elektroninio valdymo prietaisas; 12) išmetamųjų dujų analizatorius; 13) oro masės srauto matuoklis; 14) droselinės sklendės valdymo servo variklis; 15) CH₄ purkštukas; 16) mažo slėgio reguliatorius; 17) didelio slėgio reguliatorius; 18) CH₄ masės srauto matuoklis; 19) CH₄ cilindras; 20) didelio slėgio reguliatorius; 21) CO₂ masės srauto matuoklis; 22) CO₂ balionas; 23) išilginės krypties akcelerometras; 24) skersinės krypties akcelerometras; 25) mikrofonas; 26) Bruel&Kjear mašinų diagnostikos įrankių rinkinys

Fig. 3.1. Experimental setup: 1) HR16DE SI engine; 2) connecting shaft; 3) engine load stand; 4) load stand ECU and display; 5) crankshaft position sensor; 6) spark plug with a pressure sensor; 7) in-cylinder pressure recording equipment; 8) exhaust gas temperature sensor; 9) exhaust gas temperature display; 10) wideband oxygen sensor; 11) reprogrammable engine ECU; 12) exhaust gas analyzer; 13) air mass flow meter; 14) throttle control servo motor; 15) CH₄ injector; 16) low pressure regulator; 17) high-pressure regulator; 18) fuel mass flow meter for CH₄; 19) CH₄ cylinder; 20) high-pressure regulator; 21) fuel mass flow meter for CO₂; 22) CO₂ cylinder; 23) accelerometer for longitudinal direction; 24) accelerometer for transverse direction; 25) microphone; 26) Bruel&Kjear Machine Diagnostics Toolbox

tipo RHEONIK masės srauto matuokliais RHM 015, kurių matavimo diapazonas yra 0,004–0,6 kg/min., tikslumas $\pm 0,10$ %. Variklio bandymų stendo ir matavimo įrangos schema pateikta 3.1 paveiksle.

Slėgis cilindre buvo matuojamas naudojant AVL ZI31/Y7S slėgio jutiklį (jautrumas 12 pC/bar, matavimo diapazonas 0–200 barų), kuris buvo integruotas į uždegimo žvakę. Slėgio jutiklio duomenys apdoroti naudojant AVL DiTEST DPM 800 signalo stiprintuvą ir įrašyta naudojant „LabView Real Time“ modulį. Kiekvieno eksperimento metu buvo atlikta 200 degimo ciklų. Išmetamųjų dujų sudėtis, išmatuota tiesiai iš variklio, naudojant išmetamųjų dujų analizatorių „AVL DiCom 4000“.

Eksperimento metu buvo vertinamas vidaus degimo variklio, varomo natūraliomis suskystintomis dujomis ir biodujų (CH₄ ir CO₂) kompozicija, ekologinių ir

3.2 lentelė. Vidaus degimo variklių ekologinių ir energinių parametų bei virpesių ir garso slėgio signalų reikšmių palyginimas tarp skirtingų biodujų grupių

Table 3.2. Comparison of ecological and energetic engine parameters, vibration, and sound pressure between different biogas groups

Parametras	Suskystintos natūralios dujos	Kompozitinės dujos	<i>p</i> reikšmė
Metanas, vol. %	66,7 (8,37)	69,8 (4,52)	0,665
BTE, %	33,0 (0,03)	35,0 (0,01)	0,561
Maksimalus vidinis cilindro slėgis, bar	3,1 (0,72)	3,7 (0,26)	0,245
Maksimalus ROHR, J/deg	23,0 (6,28)	25,2 (3,72)	0,665
Maksimalaus slėgio padidėjimas, bar/deg	0,9 (0,52)	1,3 (0,19)	0,384
CD	66,2 (13,90)	59,9 (6,12)	0,885
CO, g/kWh	22,0 (6,01)	19,0 (1,27)	1,000
CO ₂ , g/kWh	1052,0 (410,2)	969,0 (300,40)	1,000
HC, g/kWh	0,01 (0,001)	0,01 (0,002)	0,081
NO _x , g/kWh	0,7 (0,64)	0,9 (0,51)	0,561
T _{ex} , °C	663,7 (10,75)	647,5 (6,54)	0,061
Vertikalūs virpesiai	22,5 (0,72)	23,0 (0,51)	0,312
Horizontalūs virpesiai	4,9 (0,55)	5,3 (0,25)	0,470
Garso slėgis, Pa	0,7 (0,09)	0,8 (0,03)	0,312

3.3 lentelė. Vidaus degimo variklių ekologinių ir energinių parametų bei virpesių ir garso slėgio signalų koreliacija: bendra BK ir SND grupė

Table 3.3. Correlation of ecological and energetic engine parameters, vibration, and sound pressure: BK and LPG groups

Parametras	Vertikalios krypties virpesiai <i>ρ, p</i> reikšmė	Horizontalios krypties virpesiai <i>ρ, p</i> reikšmė	Garso slėgis (Pa) <i>ρ, p</i> reikšmė
Metanas, vol. %	0,732, <i>p</i> = 0, 039	0,830, <i>p</i> = 0, 011	−0,049, <i>p</i> = 0, 909
BTE, %	0,755, <i>p</i> = 0, 031	0,922, <i>p</i> = 0, 001	0,216, <i>p</i> = 0, 608
Maksimalus vidinis cilindro slėgis, bar	0,850, <i>p</i> = 0, 007	0,970, <i>p</i> < 0, 001	0,240, <i>p</i> = 0, 568
Maksimalus ROHR, J/deg	0,714, <i>p</i> = 0, 047	0,929, <i>p</i> = 0, 001	0,238, <i>p</i> = 0, 570
Maksimalaus slėgio padidėjimas, bar/deg	0,671, <i>p</i> = 0, 069	0,934, <i>p</i> = 0, 001	0,311, <i>p</i> = 0, 453
CD	−0,595, <i>p</i> = 0, 120	−0,833, <i>p</i> = 0, 010	−0,310, <i>p</i> = 0, 456
CO, g/kWh	−0,659, <i>p</i> = 0, 076	−0,395, <i>p</i> = 0, 333	−0,335, <i>p</i> = 0, 417
CO ₂ , g/kWh	0,731, <i>p</i> = 0, 040	−0,826, <i>p</i> = 0, 011	−0,120, <i>p</i> = 0, 778
HC, g/kWh	0,108, <i>p</i> = 0, 799	0,012, <i>p</i> = 0, 978	0,527, <i>p</i> = 0, 180
NO _x , g/kWh	0,755, <i>p</i> = 0, 031	0,922, <i>p</i> = 0, 001	0,216, <i>p</i> = 0, 608
T _{ex} , °C	0,238, <i>p</i> = 0, 570	−0,405, <i>p</i> = 0, 320	−0,833, <i>p</i> = 0, 010

3.4 lentelė. Vidaus degimo variklių ekologinių ir energinių parametrų bei virpesių ir garso slėgio signalų koreliacija: tik SND grupė

Table 3.4. Correlation of ecological and energetic engine parameters, vibration, and sound pressure: only LPG group

Parametras	Vertikalios krypties virpesiai ρ, p reikšmė	Horizontalios krypties virpesiai ρ, p reikšmė	Garso slėgis (Pa) ρ, p reikšmė
Metanas, vol. %	0,800, $p = 0,200$	1,000, $p < 0,001$	0,800, $p = 0,200$
BTE, %	0,800, $p = 0,200$	1,000, $p < 0,001$	0,800, $p = 0,200$
Maksimalus vidinis cilindro slėgis, bar	0,800, $p = 0,200$	1,000, $p < 0,001$	0,800, $p = 0,200$
Maksimalus ROHR, J/deg	0,800, $p = 0,200$	1,000, $p < 0,001$	0,800, $p = 0,200$
Maksimalaus slėgio padidėjimas, bar/deg	0,800, $p = 0,200$	1,000, $p < 0,001$	0,800, $p = 0,200$
CD	-0,800, $p = 0,200$	-1,000, $p < 0,001$	-0,800, $p = 0,200$
CO, g/kWh	-0,800, $p = 0,200$	-0,400, $p = 0,600$	-0,800, $p = 0,200$
CO ₂ , g/kWh	-0,800, $p = 0,200$	-1,000, $p < 0,001$	-0,800, $p = 0,200$
HC, g/kWh	-0,400, $p = 0,600$	-0,200, $p = 0,800$	-0,400, $p = 0,600$
NO _x , g/kWh	0,800, $p = 0,200$	1,000, $p < 0,001$	0,800, $p = 0,200$
T _{ex} , °C	-0,800, $p = 0,200$	-1,000, $p < 0,001$	-0,800, $p = 0,200$

energinų parametrų sąryšis su variklio skleidžiamomis virpesių ir garso slėgio signalais. Tyrimo matavimai buvo atlikti tiek naudojant suskystintas natūralias dujas (SND), tiek biodujų kompoziciją (BK).

Pirmiausia VDV EEP bei virpesių ir garso slėgio signalų reikšmės buvo įvertintos tarp skirtingų biodujų. Gauta, kad kai kurie energiniai variklio parametrai buvo linkę turėti skirtingą pasiskirstymą biodujų grupėse, tačiau statistinio reikšmingumo lygio pasiekta nebuvo. Didesnis maksimalaus cilindro vidinio slėgio vidurkis ir mažesnis standartinis nuokrypis buvo rastas kompozicinių biodujų grupėje. Apskritai, beveik visų VDV EEP virpesių ir garso slėgio signalų standartinis nuokrypis naudojant kompozicines bioudijas buvo mažesnis, o tai reiškia, kad variklis dirba stabiliau, jo išeities parametrai yra stabilesni (3.2 lentelė). Stabilūs išeities parametrai mažina prognostinių modelių paklaidas. Tai reiškia, kad prognostinių modelių tikslumas išauga.

HC ir T_{ex} teršalų lygis buvo labiausiai linkęs skirtis biodujų grupėse nei kitų parametrų. Didesnės HC reikšmės buvo stebimos kompozicinių biodujų grupėje, atitinkamai vidurkis (standartinis nuokrypis) kompozicinių biodujų ir SND buvo 0,01 (0,001) ir 0,01 (0,002) g/kWh ($p = 0,081$). Didesnės T_{ex} reikšmės buvo SND grupėje, tačiau statistinio reikšmingumo pasiekta nebuvo ($p = 0,061$) (3.2 lentelė).

3.5 lentelė. Vidaus degimo variklių ekologinių ir energinių parametrų bei virpesių ir garso slėgio signalų koreliacija: tik BK grupė


Table 3.5. Correlation of ecological and energetic engine parameters, vibration, and sound pressure: only BK group

Parametras	Vertikalios krypties virpesiai ρ, p reikšmė	Horizontalios krypties virpesiai ρ, p reikšmė	Garso slėgis (Pa) ρ, p reikšmė
Metanas, vol. %	0,800, $p = 0, 200$	0,800, $p = 0, 200$	-1,000, $p < 0, 001$
BTE, %	0,800, $p = 0, 200$	0,800, $p = 0, 200$	-1,000, $p < 0, 001$
Maksimalus vidinis cilindro slėgis, bar	1,000, $p < 0, 001$	1,000, $p < 0, 001$	-0,800, $p = 0, 200$
Maksimalus ROHR, J/deg	0,800, $p = 0, 200$	0,800, $p = 0, 200$	-1,000, $p < 0, 001$
Maksimalaus slėgio padidėjimas, bar/deg	1,000, $p < 0, 001$	1,000, $p < 0, 001$	-0,800, $p = 0, 200$
CD	-0,600, $p = 0, 400$	-0,600, $p = 0, 400$	0,800, $p = 0, 200$
CO, g/kWh	-0,400, $p = 0, 600$	-0,400, $p = 0, 600$	0,200, $p = 0, 800$
CO ₂ , g/kWh	-0,800, $p = 0, 200$	-0,800, $p = 0, 200$	1,000, $p < 0, 001$
HC, g/kWh	-0,800, $p = 0, 200$	-0,800, $p = 0, 200$	1,000, $p < 0, 001$
NO _x , g/kWh	0,800, $p = 0, 200$	0,800, $p = 0, 200$	-1,000, $p < 0, 001$
T _{ex} , °C	0,800, $p = 0, 200$	0,800, $p = 0, 200$	-1,000, $p < 0, 001$


Aukštesnės virpesių ir garso slėgio signalų reikšmės buvo BK grupėje. Atitinkamai, vidutinės vertikalios, horizontalios pozicijos virpesių bei garso slėgio RMS reikšmės buvo 2,3 %, 8,0 % ir 11,0 % didesnės BK grupėje nei SND.

Nagrinėjant visą imtį (BK kartu su SND) virpesiai ir garso slėgis turėjo aiškią koreliaciją su VDV EEP. CO ir HC buvo vieninteliai parametrai, turėję silpnas koreliacijas su virpesiais ar garso slėgiu, o visi kiti parametrai turėjo stiprias arba labai stiprias koreliacijas. Verta pažymėti, kad garso slėgis silpniausiai koreliavo su VDV EEP, t. y. tik vienas parametras T_{ex} turėjo stiprią koreliaciją ($\rho = -0,833, p = 0,010$) (3.3 lentelė, 3.2, 3.3 pav.).

SND grupėje atlikta koreliacinė analizė parodė, kad vyrauja labai stipri koreliacija tarp nagrinėjamų VDV EEP ir horizontalios krypties virpesių. CO ir HC buvo silpnai koreliuoti su horizontalios krypties virpesiais, tačiau visi kiti parametrai turėjo absoliučias koreliacijas ($\rho = \pm 1,000, p < 0,001$) (3.4 lentelė, 3.2, 3.3 pav.). BK grupėje didesnės koreliacijos vertės buvo rastos su garso slėgiu. Energiniai parametrai metanas, BTE ir maksimalus ROHR turėjo neigiamą koreliaciją su garso slėgiu ($\rho = -1,000, p < 0,001$), o ekologiniai parametrai CO₂, HC, NO_x ir T_{ex} su garso slėgiu koreliavo absoliučiai ($\rho = \pm 1,000, p < 0,001$) (3.5 lentelės, 3.2, 3.3 pav.).



a) Suskystintos natūralios dujos



b) Suskystintos natūralios dujos


3.2 pav. Vidaus degimo variklių ekologinių ir energinių parametų bei virpesių ir garso slėgio signalų koreliacija: a) SND grupės ekologiniai variklio parametrai; b) SND grupės energiniai variklio parametrai

Fig. 3.2. Correlation among ecological and energetic engine parameters and vibration and sound pressure signals: a) ecological parameters when CNG is optimal for sparking time; b) energetic parameter when CNH is optimal for sparking time


3.1.2. Vidaus degimo variklių ekologinių ir energinių parametų prognostiniai modeliai

Šiame skyrelyje aprašomi tyrimo, kurio metu buvo sudaryti efektyvūs VDV EEP prognostiniai modeliai, rezultatai. Tyrimo metu buvo sudarytas trijų žingsnių algoritmas, kuriuo remiantis buvo sudaryti efektyvūs VDV EEP ANCOVA modeliai, suformuoti iš fiksuotų modelio įeities parametų (variklio galia, degalų tipas) ir virpesių bei garso slėgio signalų apdorotų laiko bei dažnių srities statistiniai parametrai.

Eksperimentiniai bandymai atlikti IVECO AIFO 8031 i06.05 tipo dyzeliniame variklyje su tiesioginio įpurškimo sistema. Pagrindinės variklio techninės charakteristikos pateiktos 3.6 lentelėje. Bandymų serijos metu variklio modifikacijos nebuvo keistos.



a) Biodujų kompozicija




b) Biodujų kompozicija

3.3 pav. Vidaus degimo variklių ekologinių ir energinių parametų bei virpesių ir garso slėgio signalų koreliacija: a) BK grupės ekologiniai variklio parametrai; b) BK grupės energiniai variklio parametrai

Fig. 3.3. Correlation among ecological and energetic engine parameters and vibration and sound pressure signals: a) ecological parameters when sparking time is optimal for the mixture; b) energetic parameter when sparking time is optimal for the mixture

Bandymų stendo schema pateikta 3.4 pav. Variklyje sumontuoti indikacijos sistemos jutikliai: vienas skirtas duomenų rinkimo moduliui suaktyvinti su 1024 signalais / raundui ir sinchronizuoti su vienu signalu / raundui. Kitas greičio jutiklis priklauso bandymų stendui. Antrasis jutiklis, kuris yra keitiklis, skirtas slėgiui cilindre matuoti, o trečiasis – bėgelio slėgiui matuoti, kad būtų įrašytas įpurškimo profilis. Pjezo signalai po stiprintuvo siunčiami į duomenų rinktuvą, iš kurio perduodami į kompiuterį, kuris turi atitinkamą programą signalams įvertinti. Greičio signalai optine mova perduodami į duomenų rinktuvą. Slėgio keitiklis ir įkrovimo stiprintuvai yra Kistler gaminiai. Buvo atliktas sistemos (slėgio keitiklio, kabelių, įkrovimo stiprintuvo ir duomenų rinkimo sistemos) kalibravimas prieš ir po bandymų (diapazonas 100 bar) ir apskaičiuotas tikslumas. Tyrimo metu buvo nustatytas skirtingas degalų įpurškimo laikas, kuris buvo įvertintas kaip švaistiklio kampo laipsniai (CAD) prieš viršutinį mirties tašką (BTDC).



3.4 pav. Variklio testavimo schema


Fig. 3.4. Engine test scheme

VDV EEP prognostinio modeliui įgyvendinti buvo atliktas tyrimas, kuriame buvo matuojama 11 VDV EEP. Matavimai buvo atliekami skirtingomis eksperimento sąlygomis, t. y. identiški matavimai buvo replikuojami keičiant variklio galią, degalų tipą ir degalų įpurškimo kampą:

- variklio galia: 4 kW, 8 kW, 12 kW, 20 kW;
- degalų tipas: D100, HVO30, HVO50, SME30, SME50;
- degalų įpurškimo kampas: 5 CAD BTDC, 7,5 CAD BTDC, 10 CAD BTDC, 12,5 CAD BTDC, 15 CAD BTDC, 17,5 CAD BTDC.

Tokiu būdu išviso buvo atlikta 120 matavimų skirtingomis eksperimento sąlygomis.

Kiekvieno eksperimento metu 2 s buvo renkami virpesių (po du vertikalios (V1 ir V2) ir horizontalios (H1 ir H2) krypties, žr. 3.5 pav.) ir garso slėgio duomenys su 3,2 kHz dažniu, todėl kiekvienas virpesių ir garso slėgio signalas sudarė 16384 laiko momentus. Dėl šios priežasties signalo dimensija buvo sumažinta. Visi gauti signalai buvo apdoroti laiko ir dažnių srities statistiniais parametrais (žr. 2.1 ir 2.2 lenteles).



3.5 pav. Virpesių ir garso slėgio matavimo taškai: a) bendras variklio ir virpesių (1 ir 2 taškai) bei garso slėgio (3 taškas) matavimo taškų vaizdas; b) garso slėgio matavimo mikrofonas (3 taškas); c) vertikalios ir horizontalios krypties virpesių matavimo akcelerometras (2 taškas)

Fig. 3.5. Points of measurement of vibrations and sound pressure: a) general view of the engine and points of measurement of vibrations (points 1 and 2) and sound pressure (point 3); b) microphone to measure sound pressure (point 3); c) accelerometers to measure vibrations (point 2) in X and Y directions

3.6 lentelė. Kibirkštinio įpurškimo variklio IVECO AIFO 8031 i06.05 techninės charakteristikos

Table 3.6. Technical characteristics of spark ignition engine IVECO AIFO 8031 i06.05

Parametras	Reikšmė
Cilindrų skaičius	3
Išstūmimas, dm ³	2,9
Cilindro anga, mm	104
Stūmoklio eiga, mm	115
Suspaudimo santykis	17:1
Variklio galia, kW	24
Variklio sūkliai, aps/min	150

3.7 lentelė. Vidaus degimo variklių ekologinių ir energinių parametų vidurkis (standartinis nuokrypis) tarp variklio galios grupių

Table 3.7. Mean (SD) of ecological and energetic engine parameters in different engine power groups

Parametras	Variklio galia			
	4 kW	8 kW	12 kW	20 kW
Degalų masės srautas, kg/h	1,9 (0,07)	2,5 (0,09)	3,3 (0,43)	5,0 (0,21)
CO, ppm	297 (55,5)	296 (43,7)	260 (50,7)	955 (98,3)
CO ₂ , V%	2,4 (0,10)	3,4 (0,09)	4,6 (0,51)	7,2 (0,15)
NO _x , ppm	285 (106,8)	422 (155,1)	678 (279,5)	1110 (369,9)
THC, ppm	103 (19,0)	105 (19,0)	107 (27,2)	158 (26,6)
CO _{sick} , V%	0,05 (0,011)	0,05 (0,012)	0,05 (0,012)	0,09 (0,021)
O ₂ , V%	17,4 (0,17)	16,0 (0,14)	14,2 (0,76)	10,1 (0,26)
t _{air} , °C	20,8 (1,83)	20,9 (2,02)	21,8 (2,04)	22,6 (2,49)
Oro masės srautas, kg/h	134,4 (0,94)	134,5 (1,03)	133,7 (1,18)	132,1 (1,21)
t _{fuel} , °C	27,6 (2,66)	27,5 (2,19)	28,2 (2,52)	28,6 (3,27)
t _{exhaust} , °C	198 (8,3)	247 (9,6)	311 (32,7)	464 (10,1)

Aprašomoji statistinė analizė atskleidė, kad variklio galia stipriai veikia beveik visus nagrinėjamus variklio parametrus. O₂ ir oro masės srautas buvo atvirkščiai proporcingas augančiai variklio galiai. Vidutinė O₂ reikšmė sumažėjo apie 42,0 % nuo 17,4 V% esant 4 kW variklio galiai iki 10,1 V% esant 20 kW variklio galiai. Nors oro masės srautas taip pat mažėjo didėjant variklio galiai, tačiau tai vyko kur kas lėčiau. Vyko NO_x (289,5 %), CO (221,5 %) ir CO₂ (200,0 %) dideli reikšmių šuoliai didėjant galiai (3.7 lentelė).

Degalų tipas turėjo didelę reikšmę CO ir THC parametrams: vidutinė (standartinis nuokrypis) CO reikšmė varijavo nuo 361 (233,4) ppm iki 514 (292,7) ppm, o

3.8 lentelė. Vidaus degimo variklių ekologinių ir energinių parametų aprašomoji statistika (vidurkis (standartinis nuokrypis)) tarp degalų tipų

Table 3.8. Descriptive statistics of ecological and energetic engine parameters in different fuel type groups

Parametras	Degalų tipas				
	D100	HVO30	HVO50	SME30	SME50
Degalų masės srautas, kg/h	3,1 (1,19)	3,0 (1,14)	3,1 (1,18)	3,5 (1,30)	3,3 (1,28)
CO, ppm	361 (233,4)	413 (295,3)	421 (316,3)	487 (313,2)	514 (292,7)
CO ₂ , V%	4,5 (1,94)	4,3 (1,86)	4,3 (1,85)	4,6 (1,88)	4,4 (1,83)
NO _x , ppm	606 (419,6)	605 (386,6)	578 (377,1)	711 (434,7)	645 (412,0)
THC, ppm	102 (29,3)	118 (20,1)	105 (32,4)	128 (35,5)	139 (30,9)
CO _{sick} , V%	0,07 (0,020)	0,08 (0,020)	0,07 (0,021)	0,05 (0,014)	0,05 (0,013)
O ₂ , V%	14,2 (2,92)	14,5 (2,82)	14,5 (2,85)	14,1 (2,83)	14,6 (2,70)
t_{air} , °C	23,6 (1,27)	20,1 (1,99)	19,0 (0,79)	22,7 (1,54)	22,5 (0,97)
Oro masės srautas, kg/h	132,9 (1,01)	134,6 (1,53)	134,7 (0,63)	132,6 (1,34)	133,3 (1,17)
t_{fuel} , °C	31,7 (0,56)	25,4 (1,57)	25,3 (1,55)	29,1 (1,19)	28,6 (0,85)
$t_{exhaust}$, °C	306 (103,3)	297 (100,8)	300 (100,7)	328 (108,3)	301 (104,5)

THC variavo nuo 102 (29,3) ppm iki 139 (30,9) ppm. Degalai, sukurti SME pagrindu, lėmė didesnes degalų masės srauto, CO, CO₂, NO_x, THC, oro (t_{air}), degalų (t_{fuel}) ir išmetamųjų dujų (t_{ex} temperatūros reikšmes. Šiek tiek didesnės CO_{sick} ir oro masės srauto reikšmės buvo gautos naudojant HVO pagrindu sukurtus degalus. O₂ reikšmė liko nepriklausoma nuo degalų mišinio (3.8 lentelė).

Didėjantis įpurškimo kampas turėjo itin didelę įtaką NO_x reikšmėms. NO_x vidurkis (standartinis nuokrypis) išaugo nuo 352 (194,5) ppm esant 5 CAD BTDC iki 1000 (495,0) ppm esant 17,5 CAD BTDC. Įdomu tai, kad THC pasiekė minimalią reikšmę esant 10 CAD BTDC su vidurkiu (standartinis nuokrypis) 111 (28,4) ppm, o nuo šio taško didėjant ir mažėjant kampui THC pradėjo didėti. Panaši tendencija stebėta ir CO reikšmėms, kai minimali vidutinė reikšmė buvo pasiekta esant 12,5 CAD BTDC įpurškimo kampui. Kiti VDV EEP buvo nepriklausomi nuo įpurškimo kampo (3.9 lentelė).

Toliau buvo atliekamas trijų žingsnių statistinės analizės algoritmas.

Pirmas žingsnis: pirminė signalų analizė. Pirmame žingsnyje buvo įvertinta tiksliausiai VDV EEP prognozuojantys laiko srities statistiniai parametrai. Visiems signalams (V1, V2, H1, H2 ir garso slėgiui) buvo apskaičiuoti 16 laiko srities statistinių parametų. Šie nauji kintamieji buvo įtraukti į TRM. TRM atskleidė, kad net 8–11 VDV EEP gali būti prognozuojami naudojant T_2 – T_{11} statistikas apskaičiuotas iš visų penkių signalų. Taip pat 10 VDV EEP gali būti prognozuojami naudojant T_{15} statistiką apskaičiuotą iš V1 ir V2 signalų, bei T_{16} statistiką apskai-

3.9 lentelė. Vidaus degimo variklių ekologinių ir energinių parametų aprašomoji statistika (vidurkis (standartinis nuokrypis)) tarp įpurškimo kampo grupių

Table 3.9. Descriptive statistics of ecological and energetic engine parameters in different fuel injection angle groups

Parametras	Įpurškimo kampas		
	5 CAD BTDC	7,5 CAD BTDC	10 CAD BTDC
Degalų masės srautas, kg/h	3,2 (1,24)	3,2 (1,22)	3,2 (1,22)
CO, ppm	440 (250,0)	439 (285,6)	429 (313,0)
CO ₂ , V%	4,4 (1,87)	4,4 (1,86)	4,4 (1,86)
NO _x , ppm	352 (194,5)	436 (247,4)	545 (290,2)
THC, ppm	128 (27,9)	124 (26,4)	111 (28,4)
CO _{sick} , V%	0,06 (0,017)	0,06 (0,019)	0,06 (0,022)
O ₂ , V%	14,4 (2,81)	14,4 (2,79)	14,4 (2,80)
t_{air} , °C	21,5 (2,58)	21,7 (2,35)	21,5 (2,43)
Oro masės srautas, kg/h	134,2 (1,41)	133,8 (1,57)	133,7 (1,55)
t_{fuel} , °C	28,1 (3,19)	28,0 (2,87)	27,9 (2,83)
$t_{exhaust}$, °C	320 (104,1)	310 (103,9)	309 (103,5)

Parametras	Įpurškimo kampas		
	12,5 CAD BTDC	15 CAD BTDC	17,5 CAD BTDC
Degalų masės srautas, kg/h	3,2 (1,23)	3,2 (1,25)	3,2 (1,29)
CO, ppm	423 (311,3)	431 (308,7)	488 (324,1)
CO ₂ , V%	4,4 (1,88)	4,4 (1,89)	4,5 (1,95)
NO _x , ppm	645 (341,7)	806 (411,2)	1000 (495,0)
THC, ppm	112 (34,7)	116 (39,2)	120 (37,6)
CO _{sick} , V%	0,06 (0,023)	0,06 (0,025)	0,07 (0,027)
O ₂ , V%	14,5 (2,85)	14,4 (2,85)	14,3 (2,95)
t_{air} , °C	21,3 (2,05)	21,6 (2,11)	21,6 (1,94)
Oro masės srautas, kg/h	133,6 (1,25)	133,3 (1,27)	133,1 (1,53)
t_{fuel} , °C	27,9 (2,63)	27,9 (2,47)	27,9 (2,43)
$t_{exhaust}$, °C	300 (103,5)	298 (104,0)	301 (107,0)

čiuotą iš H1 ir H2 signalų. Visgi T_{15} apskaičiuotas iš V2 ir H1 signalų buvo silpnas prognostinis faktorius.

Tik vienas laiko srities statistinis parametras T_{11} , apskaičiuotas naudojant H1 (toliau T_{11}^{H1}) signalą turėjo statistiškai reikšmingą įtaką visiems 11 VDV EEP ir buvo apibrėžta kaip geriausias prognostinis faktorius vienmačiame TRM (3.10 lentelė). Todėl tik T_{11}^{H1} statistika buvo įtraukta į tolesnį efektyviausio prognostinio modelio sudarymo algoritmą.

Aprašomoji statistika parodė, kad variklio galia buvo stipriai susijusi su T_{11}^{H1} : T_{11}^{H1} mediana (Q1–Q3) esant 4 kW, 8 kW, 12 kW ir 20 kW variklio galiai atitinkamai buvo 1,41 (1,38–1,43), 1,42 (1,39–1,46), 1,46 (1,45–1,48) ir 1,51 (1,47–1,53)

3.10 lentelė. Suminis statistiškai reikšmingų laiko srities statistinių parametrų skaičius prognozuojant vidaus degimo variklių ekologinius ir energinius parametrus

Table 3.10. Cumulative counts of statistically significant time domain statistics in predicting ecological and energetic engine parameters

Laiko srities statistiniai parametrai	V1	V2	H1	H2	GSS
T_1	0	1	0	1	0
T_2	10	10	10	8	9
T_3	10	10	10	8	9
T_4	10	10	10	8	9
T_5	10	8	9	10	10
T_6	10	10	10	8	9
T_7	10	9	10	8	10
T_8	9	9	10	8	9
T_9	10	9	10	8	9
T_{10}	10	10	10	8	9
T_{11}	10	9	11	9	9
T_{12}	0	0	3	4	6
T_{13}	7	1	8	7	7
T_{14}	8	1	9	8	7
T_{15}	10	0	5	10	8
T_{16}	8	5	10	10	9

V1 ir V2 – vertikalios krypties virpesių signalai; H1 ir H2 – horizontalios krypties virpesių signalai; GSS – garso slėgio signalas.


(3.6a pav.). Verta paminėti, kad skirtingos variklio galios grupėse T_{11}^{H1} variacija išliko nedidelė.

Statistikos T_{11}^{H1} pasiskirstymas nepriklausė nuo degalų tipo. Tačiau priešingai nei variklio galios grupėse, variacija degalų tipo grupėse buvo didesnė (3.6b pav.).

Įvairiose įpurškimo kampo grupėse T_{11}^{H1} pasiskirstymas varijavo labai netolygiai, t. y. T_{11}^{H1} pasiskirstymas keitėsi netiesiškai didėjant įpurškimo kampui. Mažiausios statistikos T_{11}^{H1} reikšmės buvo fiksuotos esant 7,5 CAD BTDC įpurškimo kampui: mediana (Q1–Q3) buvo 1,38 (1,37–1,43), o didžiausios reikšmės fiksuotos esant 12,5 CAD BTDC įpurškimo kampui: mediana (Q1–Q3) buvo 1,48 (1,45–1,50) (3.6c pav.).

Antras žingsnis: prognostinio modelio sudarymas. Antrame modelio sudarymo algoritmo žingsnyje buvo atlikta ANOVA analizė siekiant įvertinti nepriklausomų faktorių, t. y. variklio galios, degalų tipo ir įpurškimo kampo prognostinę vertę VDV EEP. Faktoriai, turintys didžiausią R^2 reikšmę, buvo vertinami kaip turintys didžiausią prognostinę vertę ir buvo įtraukti į tolimesnę ANCOVA analizę.

ANOVA analizė atskleidė (žr. 3.11 lentelė), kad variklio galia turėjo didžiausią R^2 įvertį (kartu turėjo didžiausią prognostinę įtaką) degalų masės srautui, CO,



3.6 pav. Laiko srities statistinio parametro T_{11}^{H1} pasiskirstymas tarp fiksuotų eksperimento parametrų: a) variklio galia; b) degalų tipas; c) įpurškimo kampas

Fig. 3.6. Distribution of time domain statistic T_{11}^{H1} among fixed experimental parameters: a) engine power; b) type of fuel; c) injection timing

3.11 lentelė. Vidaus degimo variklių ekologinių ir energinių parametrų prognostinių modelių R^2 įverčiai

Table 3.11. R^2 estimates in prognostic models of ecological and energetic engine parameters

Parametras	T_{11}^{H1a}	Degalų tipas ^b	Variklio galia ^b	Įpurškimo kampas ^b
Degalų masės srautas, kg/h	51,3*	2,5	96,0*	<0,1
CO, ppm	33,2*	3,4	95,3*	0,5
CO ₂ , V%	48,6*	0,6	97,8*	<0,1
NO _x , ppm	52,6*	1,3	61,8*	29,9*
THC, ppm	29,6*	18,3*	50,2*	3,6
CO _{sick} , V%	13,8*	35,3*	57,6*	9,8
O ₂ , V%	47,9*	4,9	97,8*	0,1
t_{air} , °C	7,9*	62,5*	11,3*	0,4
Oro masės srautas, kg/h	30,9*	37,3*	44,0*	6,1
t_{fuel} , °C	3,7*	80,4*	2,6	0,1
$t_{exhaust}$, °C	47,3*	1,2	96,9*	0,6

^a R^2 apskaičiuotas naudojant vienmatę TRM iš 1 žingsnio.

^b R^2 apskaičiuotas panaudojant ANOVA analizę iš 2 žingsnio.

* Žymi statistiškai reikšmingus VDV EEP.

3.12 lentelė. Vidaus degimo variklių ekologinių ir energinių parametų prognostinių modelių parametų įverčiai

Table 3.12. Estimates of ecological and energetic engine parameters

Parametras	LP (α)	T_{11}^{H1} (β)	VG (γ) 8 kW; 12 kW; 20 kW	$T_{11}^{H1} \times VG$ (μ) 8 kW; 12 kW; 20 kW	R^2
Degalų masės srautas, kg/h	1,486	0,277	0,697; -4,470; -0,318	-0,022; 4,050; 2,309	96,6
CO, ppm	291,7	3,8	-87,7; -396,9; -1125,7	60,5; 246,6; 1190,6	96,0
CO ₂ , V%	2,626	-0,166	0,279; -5,281; 4,726	0,484; 5,108; 0,085	98,0
NO _x , ppm	1059,3	-550,3	-1496,5; -4982,7; -9382,1	1154,6; 3704,7; 6842,1	74,2
THC, ppm	141,1	-27,3	-119,4; -90,4; -556,3	86,0; 65,9; 409,5	56,2
CO _{sick} , V%	0,131	-0,055	-0,057; 0,089; 0,025	0,041; -0,060; 0,012	58,8
O ₂ , V%	16,59	0,59	-0,06; 7,90; -7,63	-0,98; -7,61; 0,19	98,0
Oro masės srautas, kg/h	138,35	-2,83	0,02; 12,37; 4,77	0,09; -8,82; -4,53	47,6
t_{exhaust} , °C	143,8	38,5	109,2; -222,3; 415,3	-42,9; 228,9; -102,8	97,1
Parametras	LP (α)	T_{11}^{H1} (β)	DT (γ) HVO30; HVO50; SME30; SME50	$T_{11}^{H1} \times DT$ (μ) HVO30; HVO50; SME30; SME50	R^2
t_{air} , °C	22,08	1,04	-33,13; 11,19; -27,10; -9,54	20,70; -10,96; 17,91; 5,82	72,4
t_{fuel} , °C	24,14	5,21	-22,59; 27,62; -10,48; -7,69	11,43; -23,55; 5,54; 3,13	85,8

4 kW variklio galia ir D100 degalų tipas yra referentinės kategorijos su nustatytu nuliniu parametru įverčiu. LP – laisvasis parametras; VG – variklio galia; DT – degalų tipas.

CO₂, NO_x, THC, CO_{sick}, O₂, oro masės srautui ir t_{exhaust} . Degalų tipas turėjo didžiausią R^2 įvertį tik t_{air} ir t_{fuel} . Ipurškimo kampas visiems VDV EEP turėjo labai mažus R^2 įverčius ir į tolesnį prognostinio modelio sudarymo algoritmą įtrauktas nebuvo (3.11 lentelė). Galiausiai remiantis 3.11 lentele buvo sudaryti ANCOVA modeliai:


- degalų masės srautui, CO, CO₂, NO_x, THC, CO_{sick}, O₂, oro masės srautui ir t_{exhaust} :

$$Y = \alpha + \beta T_{11}^{H1} + \gamma \times VG + \mu(T_{11}^{H1} \times VG) + \epsilon, \quad (3.1)$$

- t_{air} ir t_{fuel} :

$$Y = \alpha + \beta T_{11}^{H1} + \gamma \times DT + \mu(T_{11}^{H1} \times DT) + \epsilon, \quad (3.2)$$

čia VG – variklio galia; DT – degalų tipas.



3.7 pav. Prognotinių modelių vidutinės absoliučios procentinės paklaidos


Fig. 3.7. Mean absolute percentage error for prognostic models

ANCOVA modelio parametų bei R^2 įverčiai apskaičiuoti pagal (3.1) ir (3.2) pateikti 3.12 lentelėje. ANCOVA modelio visos R^2 reikšmės buvo didesnės nei R^2 reikšmės gautos ANOVA modelyje ir dar labiau didesnės nei vienmačiame TRM. Didžiausias R^2 padidėjimas ANCOVA modelyje buvo pasiektas NO_x ir t_{air} parametruose, kai jų prognostinio modelio R^2 reikšmės atitinkamai padidėjo 12,4 ir 9,9 %.

Trečias žingsnis: modelių tikslumo nustatymas. Trečiame žingsnyje trijų prognotinių modelių (vienmačio TRM, ANOVA ir ANCOVA) tikslumas buvo įvertintas taikant VAPP matą.

Vienmatis TRM su vienu nepriklausomu faktoriumi T_{11}^{H1} buvo netiksliausias ir turėjo santykinai dideles VAPP reikšmes visiems 11 VDV EEP. Vidutiniškai ANOVA ir ANCOVA modeliai buvo 3,3 kartus tikslesni nei vienmatis TRM. Itin didelis tikslumo pagerėjimo šuolis pereinant nuo vienmačio TRM prie ANOVA ar ANCOVA modelių, buvo fiksuotas degalų masės srauto, CO, CO₂, O₂ ir t_{exhaust} parametrams. Visgi THC, t_{air} ir t_{fuel} parametų modelių tikslumas pagerėjo mažiau, tačiau vis tiek ANOVA ir ANCOVA modeliai gerokai pagerino jų tikslumą. Tik oro masės srauto prognotinių modelių tikslumas išliko stabilus (3.7 pav.).

ANCOVA modelis, kuriame yra du nepriklausomi prognostiniai faktoriai (T_{11}^{H1} ir variklio galia arba degalų tipas), turėjo mažiausias VAPP reikšmes, todėl yra geriausias, t. y. efektyvus prognostinis modelis visiems 11 VDV EEP (3.7 pav.). Didžiausias VAPP sumažėjimas, pereinant nuo ANOVA prie ANCO-




3.8 pav. NO_x prognostinių modelių įgyvendinimas: a) modeliai tik su laiko srities statistiniais parametrais apdorotais virpesių signalais; b) modeliai su laiko ir dažnių srities statistiniais parametrais apdorotais virpesių signalais

Fig. 3.8. Implementations of NO_x prognostic models: a) models with vibration signals processed only by time domain statistics; b) models with vibration signals processed by time and frequency domain statistics

VA modelio, buvo fiksuotas NO_x , t_{air} ir t_{fuel} parametrų – atitinkamai buvo 4,5 %, 2,2 % ir 2,6 %.

Iš 3.8a ir 3.9a paveikslų galime matyti, kad prognozavimo tikslumas gerokai pagerėja, kai variklis veikia didesnės galios režimu, o esant mažai variklio galiai ANCOVA prognostinis modelis nėra patikimas. Analogiškai galime daryti išvadą, kad ANCOVA prognostinis modelis yra patikimas varikliui veikiant su dyzelino mišiniais, naudojant dyzeliną modelis tampa nebepatikimas (3.10a ir 3.11a pav.). Dėl šių priežasčių modeliui patikslinti buvo įtraukti papildomi laiko srities statistiniai parametrai ir nauji dažnių srities statistiniai parametrai, kurie turėjo reikšmingą įtaką VDV EEP TRM modelyje. Tokiu būdu išplėtus prognostinį modelį, buvo




3.9 pav. Oro masės srauto prognostinių modelių įgyvendinimas: a) modeliai tik su laiko srities statistiniais parametrais apdorotais virpesių signalais; b) modeliai su laiko ir dažnių srities statistiniais parametrais apdorotais virpesių signalais

Fig. 3.9. Implementations of air mass flow prognostic models: a) models with vibration signals processed only by time domain statistics; b) models with vibration signals processed by time and frequency domain statistics

gauti nauji ANCOVA modeliai, pavadinti *išplėstais prognostiniais modeliais*, kuriuose jau buvo įtrauktos virpesių ir garso slėgio reikšmės apdorotos dažnių srities statistiniais parametrais:

- degalų masės srautui, CO , CO_2 , NO_x , THC , CO_{sick} , O_2 , oro masės srautui ir t_{exhaust} :

$$\begin{aligned}
 Y^E = & \alpha + \beta_1 T_{11}^{H1} + \beta_2 T_5^{V1} + \beta_3 T_5^{GS} + \beta_4 F_4^{GS} + \beta_5 F_{12}^{GS} \\
 & + \gamma \times VG \\
 & + \mu_1 (T_{11}^{H1} \times VG) + \mu_2 (T_5^{V1} \times VG) \\
 & + \mu_3 (T_5^{GS} \times VG) + \mu_4 (F_4^{GS} \times VG) \\
 & + \mu_5 (F_{12}^{GS} \times VG) + \epsilon,
 \end{aligned} \tag{3.3}$$




3.10 pav. t_{air} prognostinių modelių įgyvendinimas: a) modeliai tik su laiko srities statistiniais parametrais apdorotais virpesių signalais; b) modeliai su laiko ir dažnių srities statistiniais parametrais apdorotais virpesių signalais

Fig. 3.10. Implementations of t_{air} prognostic models: a) models with vibration signals processed only by time domain statistics; b) models with vibration signals processed by time and frequency domain statistics

• t_{air} ir t_{fuel} :

$$\begin{aligned}
 Y^E = & \alpha + \beta_1 T_{11}^{H1} + \beta_2 T_5^{V1} + \beta_3 T_5^{GS} + \beta_4 F_4^{GS} + \beta_5 F_{12}^{GS} \\
 & + \gamma \times DT \\
 & + \mu_1 (T_{11}^{H1} \times DT) + \mu_2 (T_5^{V1} \times DT) \\
 & + \mu_3 (T_5^{GS} \times DT) + \mu_4 (F_4^{GS} \times DT) \\
 & + \mu_5 (F_{12}^{GS} \times DT) + \epsilon,
 \end{aligned} \tag{3.4}$$

čia Y^E – VDV EEP reikšmės (priklausomasis kintamasis); E – konkretus VDV EEP;



3.11

pav. t_{fuel} prognostinių modelių įgyvendinimas: a) modeliai tik su laiko srities statistiniais parametrais apdorotais virpesių signalais; b) modeliai su laiko ir dažnių srities statistiniais parametrais apdorotais virpesių signalais

Fig. 3.11. Implementations of t_{fuel} prognostic models: a) models with vibration signals processed only by time domain statistics; b) models with vibration signals processed by time and frequency domain statistics

T žymi laiko srities statistinius parametrus; F žymi dažnių srities statistinius parametrus; $H1$ – horizontalūs virpesiai; $V1$ – vertikalūs virpesiai; GS – garso slėgis; indeksas prie T ir F žymi statistikos numerį iš 2.1 ir 2.2 lentelių; $\alpha, \beta_i, \gamma, \mu_i$ – ANCOVA modelio parametrai; ϵ – atsitiktinė paklaida, pasiskirsčiusi pagal normalųjį skirstinį su nuliniu vidurkiu ir dispersija σ^2 ; VG – variklio galia; DT – degalų tipas.

Kadangi naują išplėstą modelių sudarė nebe 3 prognostiniai faktoriai, o 11, tai papildomai buvo atlikta parametru optimizacija pagal 1.1.1 skyrelyje aprašytą metodiką. Išplėstas modelis pagerino prognostines vertes, esant mažai variklio galiai ar naudojant gryną dyzeliną (3.8b, 3.9b, 3.10b ir 3.11b pav.). Įdomu pastebėti, kad modelis geriausiai prognozavo VDV EEP netaikant jokios regresijos parametru optimizacijos.

3.1.3. Vidaus degimo variklių ekologinių ir energinių parametru prognotinių modelių taikymo apibendrinimas

Variklių varomų BK ir SND statistinė virpesių signalų ir garso slėgio analizė neidentifikavo didelio skirtumo tarp BK ir SND, tačiau kai kurių VDV EEP vidurkių reikšmės buvo linkusios skirtis. VDV EEP standartinis nuokrypis buvo kur kas didesnis SND varomų variklių. Vidurkio ir standartinio nuokrypio santykis buvo 11,7 ir 22,3 atitinkamai SND ir BK varomų variklių, o tai reiškia, kad SND varomo variklio standartinis nuokrypis buvo dvigubai didesnis nei BK. Tai įrodo kibirkšties laiko reguliavimo svarbą ir variklio parametru stabilumą, pakeičiant standartines SND į BK.

VDV EEP ir virpesių bei garso slėgio signalų koreliacinė analizė parodė, kad vyrauja stiprios ($\rho \geq 0,7$) ir vidutinio stiprumo ($0,3 < \rho < 0,7$) koreliacijos. Taip pat rasta, kad tarp virpesių signalų ir variklio energinių parametru vyravo teigiamos koreliacijos, t. y. didėjant virpesių signalo RMS didėdavo ir energinių parametru vertės. Atvirkštinė tendencija (išimtis NO_x) buvo identifikuota tarp virpesių signalo RMS ir ekologinių parametru, t. y. esant didelėms virpesių signalo RMS reikšmėms vyravo mažos ekologinių parametru vertės.

Visgi reikia paminėti, kad šis tyrimas yra bandomasis, tirta statistiškai mažai imtis ir griežtų išvadų apie tyrimo rezultatus daryti nevertėtų.

VDV EEP prognotinio modelio sudarymo tyrime eksperimentinių duomenų statistinė analizė parodė, kad variklio galia turėjo didžiausią įtaką generuojamiems virpesių ir garso slėgio signalams. RMS reikšmės padidėjo 20–30 %, kai variklio galia padidėjo nuo 4 kW iki 20 kW. Degalų tipas ir įpurškimo kampas nebuvo susijęs su RMS pokyčiais.

Virpesių ir garso slėgio signalai pademonstravo gana didelį prognotinį potencialą taikant vienmatę TRM. Visi neneigiami laiko srities statistiniai parametrai buvo linkę geriau prognozuoti VDV EEP, o geriausias laiko srities statistinis parametras buvo susijęs su RMS įverčiu (T_{11}). Statistinis parametras T_{11} , gautas naudojant H1 signalą, buvo statistiškai reikšmingas prognotinis faktorius visiems VDV EEP.

Taip pat ANOVA analizė atskleidė, kad variklio galia bei degalų tipas yra stiprūs VDV EEP prognotiniai faktoriai ir turi būti įtraukiami sudarant tolesnius prognotinius modelius. Šiame tyrime variklio galia buvo stiprus degalų masės srauto, CO , CO_2 , NO_x , THC , CO_{sick} , O_2 , oro masės srauto ir t_{exhaust} prognotinis faktorius, o parametrams t_{air} ir t_{fuel} prognozuoti geriau rinktis degalų tipą.

Kadangi tiek virpesių signalo (T_{11}^{H1}), tiek variklio galia ar degalų tipas buvo stiprūs prognotiniai faktoriai, šiuos faktorius buvo būtina kartu įdėti į prognotinį modelį. Tokiu būdu sudarytas ANCOVA modelis parodė dar geresnius visų 11 VDV EEP prognozavimo rezultatus. VAPP apytiksliai yra tris kartus mažesnė ANCOVA modeliui nei vienmačiam TRM, kur modelyje yra tik vienas prog-

nostinis faktorius (T_{11}^{H1}). Modelio tikslumas išauga, kai variklis veikia aukštesnės galios diapazone, o esant 4 kW ir 8 kW galiai modeliu pasitikėti nebegalima. Įvertinus tai, kad išaugusi galia taip pat didina virpesių signalo vertes, darytina išvada, kad virpesių signalo VDV EEP prognostinius modelius pagerina tik esant didelės amplitudės virpesiams. Mažos virpesių signalo vertės laiko srityje nesukuria papildomos informacijos. Panaši išvada daroma prognostiniams modeliams, kuriuose vietoje variklio galios yra degalų tipas. Varikliui veikiant su D100 degalais, laiko srities virpesių signalas nesukuria papildomos informacijos ir prognostinis modelis nepagerėja, o varikliui veikiant su HVO30, HVO50, SME30 ir SME50 mišiniais prognostinio modelio rezultatas smarkiai pagerėja dėl padidėjusių virpesių signalo verčių.

Šios tyrimo išvados leidžia teigti, kad virpesių signalas, apdorotas laiko srities statistiniu parametru T_{11}^{H1} , pagerina VDV EEP prognostinius modelius padidindamas jų tikslumą. Dyzelinių variklių, naudojančių alternatyvius degalus, triukšmo ir virpesių charakteristikos rodo patikimus ryšius su variklio eksploatacinėmis savybėmis ir išmetamųjų teršalų charakteristikomis. Taigi gauti rezultatai leidžia sukurti patikimą ir nebrangų metodą, leidžiantį įvertinti įvairių alternatyvių degalų mišinių įtaką svarbiems VDV EEP.

3.2. Hipoidinės pavaros gedimų identifikavimas

Šiame poskyryje aprašomi hipoidinės pavaros (HP) gedimų diagnostikos mašininio mokymosi modelių taikymo rezultatai, kurie gedimams identifikuoti naudoja tik pavaros skleidžiamus virpesių signalus. Šio tyrimo metu buvo sudaryti giliojo mokymosi modeliai, gebantys spręsti daugelio klasių uždavinius, identifikuotos lengviausiai ir sunkiausiai klasifikuojamos HP pažaidos, taip pat buvo įvertinta skirtingų sukimo momentų ir apsukų greičio įtaka klasifikavimo tikslumui. Giliojo mokymosi modeliai, tokie kaip SNT, ITAM ir TNT, buvo apmokyti virpesių signalo duomenimis, paskui testuoti su nepriklausomo nuo mokymosi aibės eksperimento duomenimis. Modeliams mokytis ir validuoti buvo naudojami tik pirmojo tyrimo etapo eksperimentiniai duomenys: 80 % duomenų buvo skirti modeliams mokytis, 20 % – validuoti. Modeliams testuoti buvo naudojami tik antrojo tyrimo etapo eksperimentiniai duomenys. Eksperimentų metu keičiami pavaros apsukų bei sukimo momento parametrai į klasifikavimo modelius įtraukti nebuvo, t. y. modeliams buvo žinomi tik virpesių signalai. Tyrimo metu modeliai buvo nuolat konfigūruojami ir buvo ieškoma modelio parametrų rinkinio, kuris gebėtų tiksliausiai klasifikuoti pažaidas per priimtina laiko tarpą. Geriausios modelių architektūros yra parodytos 2.3 lentelėje. Visų modelių mokymosi ir validacijos metu buvo atliekama 30 epochų su 32 duomenų rinkinio dydžiu bei židinio tikslo (angl. *focal*

3.13 lentelė. Geriausio daugelio klasių modelio (2M-SNT) normalizuota klasifikavimo lentelė testavimo duomenims

Table 3.13. Normalized confusion matrix of the best-performing multi-class classification model (CNN-2D) for test data

		Prognozuojama klasė						
Pažaidos tipas		0	1	2	3	4	5	6
Tikroji klasė	0	100,0	0,0	0,0	0,0	0,0	0,0	0,0
	1	0,0	99,4	0,1	0,1	0,2	0,1	0,2
	2	0,0	0,2	83,5	8,3	1,3	2,4	4,3
	3	0,0	0,3	17,2	57,6	1,5	10,4	13,0
	4	0,0	0,2	0,9	4,0	58,9	26,6	9,5
	5	0,0	0,0	1,5	1,7	2,2	77,5	17,1
	6	0,0	0,0	1,1	1,3	1,8	5,7	90,1

3.14 lentelė. Daugelio klasių klasifikavimo modelių tikslumo įverčiai testavimo duomenims: preciziškumas, jautrumas ir F1-įvertis

Table 3.14. Precision, recall, and F1-score for the multi-class model for test data

Modelis	Įvertis	0	1	2	3	4	5	6
1M-SNT	Preciziškumas	16,6	15,4	14,5	15,3	11,6	12,8	15,2
	Jautrumas	41,4	8,4	5,7	14,9	5,8	17,3	11,1
	F1-įvertis	23,7	10,9	8,2	15,1	7,8	14,7	12,8
2M-SNT	Preciziškumas	100	99,4	80,7	78,3	89,6	63,4	67,4
	Jautrumas	100	99,4	83,5	57,6	58,9	77,5	90,1
	F1-įvertis	100	99,4	82,1	66,3	71,1	69,8	77,1
ITAM	Preciziškumas	83,3	47,8	42,4	32,8	38,1	41,9	38,7
	Jautrumas	99,4	67,2	31,2	32,9	53,7	15,6	34,2
	F1-įvertis	90,7	55,8	35,9	32,9	44,6	22,7	36,3
TNT	Preciziškumas	93,2	67,4	27,8	21,6	22,5	25,9	42,4
	Jautrumas	95,1	59,0	13,9	34,3	19,3	28,5	46,0
	F1-įvertis	94,1	62,9	18,5	26,6	20,8	27,2	44,1

loss) funkcija (Lin et al. 2017). Platesnė modelių sudarymo metodologija aprašyta 2.2 poskyryje.

Daugelio klasių klasifikavimo modelių atveju, testuojant modelių jų klasifikavimo tikslumas buvo labai nevienodas. Didžiausias tikslumas buvo pasiektas naudojant 2M-SNT modelį (81,1 %). Šis modelis HP be pažaidos gebėjo identifikuoti be klaidų (100,0 %), o 1 tipo pažaidos klasifikavo tikslumas taip pat buvo itin didelis (99,4 %). 2–5 tipo pažaidų klasifikavimo tikslumas nebuvo geras ir siekė tik 57,6 %–83,5 % (3.13 lentelė). Sunkiausiai klasifikuojamos buvo 3 ir 4 tipo pažaidos, atitinkamai klasifikavimo jautrumas siekė tik 57,6 % ir 58,9 % (3.14 lentelė).

ITAM, TNT ir 1M-SNT modeliai reikšmingai prasčiau klasifikavo HP pažaidas negu 2M-SNT, atitinkamai bendras modelių tikslumas siekė tik 47,8 %, 42,4 %

3.15 lentelė. Bendras daugelio klasių klasifikavimo modelio 2M-SNT tikslumas, kai atliekamas skirtingų sūkių ir sukimo momentų eksperimentas

Table 3.15. Multi-class CNN-2D model classification accuracy of 7 gear conditions with different rotation speed, torque load, and a combination of both


		Sūkių greitis, aps/min					
		1000	2000	3000	4000	5000	Bendras
Sukimo momentas, Nm	25	86,7	78,9	84,4	79,2	82,1	82,3
	50	88,7	83,9	87,6	88,2	84,4	86,5
	75	87,0	87,6	86,7	88,4	80,7	86,1
	100	77,7	80,1	77,5	78,9	68,6	76,5
	125	76,9	79,8	81,5	68,9	63,6	74,1
	Bendras	83,4	82,1	83,6	80,7	75,9	81,1

ir 15,0 % Nepaisant to, kad ITAM ir TNT bendrasis tikslumas buvo ypač mažas, šių modelių jautrumas, preciziškumas ir F1-įvertis, klasifikuoti HP be pažaidos buvo gan aukšti ir siekė >80 % (3.14 lentelė).

2M-SNT modelio jautrumas klasifikuojant 3 ir 4 tipo HP pažaidas buvo labai mažas, tačiau atitinkamų pažaidų preciziškumas buvo reikšmingai didesnis ir siekė 78,3 % ir 89,6 %. Priešinga tendencija buvo stebėta klasifikuojant 5 ir 6 HP pažaidos tipus: atitinkamai modelio preciziškumas nukrito iki 63,4 % ir 67,4 %, o jautrumas išaugo iki 77,5 % ir 90,1 % (3.14 lentelė).

Kadangi 2M-SNT parodė geriausius klasifikavimo rezultatus, tai modelis buvo išsamiau ištirtas siekiant įvertinti HP sūkių ir sukimo momento parametrų įtaką klasifikavimo tikslumui. Analizė parodė, kad didžiausias tikslumas pasiekiamas kai yra mažesnis sukimo momentas (25, 50 ir 75 Nm) ir mažesnis apsukų greitis (1000, 2000 ir 3000 aps./min.) (3.15 lentelė). HP apsukų greitis turėjo šiek tiek mažesnę įtaką klasifikavimo modelio tikslumui negu sukimo momentas. Skirtumas tarp tiksliausiai (3000 aps/min) ir prasčiausiai (5000 aps/min) klasifikuojamų HP pažaidų yra 7,7 %, o sukimo momento grupių analogiškas skirtumas siekia 12,4 % (3.15 lentelė). Vertinant sūkių ir sukimo momento poras, gauta, kad tiksliausiai 2M-SNT modelis klasifikuoja esant 1000 aps/min sūkiams ir 50 Nm sukimo momentui (88,7 %). Modelis prasčiausiai klasifikuoja, kai sūkių ir sukimo momentas atitinkamai yra 5000 aps./min. ir 125 Nm (63,6 %). Sūkių ir sukimo momento poros, kurioms esant modelis pasiekia tiksliausią ir prasčiausią bendrą tikslumą, atitinkamai bendrą tikslumą, kai neatsižvelgiama į sūkių ir sukimo momentą, pagerina 7,6 % ir pablogina 17,5 % (3.15 lentelė).

Iš 3.12 paveikslo matoma, kad bendras modelio tikslumas beveik monotoniskai didėja pradedant nuo mažiausio modelio tikslumo taško (5000 aps./min. ir 125 Nm) ir pasiekiant 75 ir 50 Nm sukimo momentus neatsižvelgiant į HP sūkių.



3.12 pav. Bendras daugelio klasių klasifikavimo modelio 2M-SNT tikslumas, kai eksperimentas atliekamas esant skirtingiems sūkiams ir sukimo momentams

Fig. 3.12. Multi-class CNN-2D model classification accuracy regarding rotation speed and torque loads

Tačiau pasiekus mažiausią sukimo momentą (25 Nm), bendras modelio tikslumas staigiai sumažėja.

Papildomai buvo patikrinta, kaip sudaryti modeliai geba klasifikuoti nepažeistą HP ir turinčią bent kokią pažeidą. Dviejų klasių (kaip ir daugelio klasių atveju) geriausią klasifikavimo tikslumą pasiekė 2M-SNT modelis. Modelis HP su pažeidomis ir be jų klasifikavo be klaidų (visi modelio tikslumo įverčiai siekė 100,0 %). Nedaug nuo geriausio modelio atsiliko ITAM modelis, kurio bendras tikslumas siekė 99,6 %. ITAM preciziškumas, jautrumas ir F1-įvertis klasifikuojant HP be pažeidų atitinkamai buvo 97,9 %, 99,5 % ir 98,7 %, HP su pažeidomis siekė >99 %. TNT modelis taip pat parodė gerus klasifikavimo rezultatus, beveik visi (išskyrus jautrumą klasifikuojant HP be pažeidos) tikslumo įverčiai siekė >90 % (3.16 lentelė).

Prasčiausi rezultatai klasifikuojant HP su ir be pažeidos buvo pasiekti naudojant 1M-SNT. Modelis visiškai negebėjo klasifikuoti HP be pažeidų, o pažeidas identifiko gana gerai, tačiau šiuo atveju geresni tikslumo įverčius lemia kur kas didesnė HP su pažeidomis imtis (3.16 lentelė).

3.16 lentelė. Dviejų klasių klasifikavimo modelių tikslumo įverčiai: preciziškumas, jautrumas ir F1-įvertis

Table 3.16. Precision, recall, and F1-score for two-class classification models

Modelis	Įvertis	Be pažaidų	Su pažaidomis
1M-SNT	Preciziškumas	7,1	85,6
	Jautrumas	0,1	99,8
	F1-įvertis	0,1	92,2
2M-SNT	Preciziškumas	100,0	100,0
	Jautrumas	100,0	100,0
	F1-įvertis	100,0	100,0
ITAM	Preciziškumas	97,9	99,9
	Jautrumas	99,5	99,6
	F1-įvertis	98,7	99,8
TNT	Preciziškumas	96,0	97,5
	Jautrumas	85,0	99,4
	F1-įvertis	90,1	98,5

3.3. Juostinio konvejerio diržo apkrovos identifikavimas

Šiame poskyryje aprašomi dviejų klasių klasifikavimo mašininio mokymosi modelių, skirtų juostinio konvejerio diržo (JKD) apkrovos būklėms klasifikuoti, rezultatai. Modeliai naudoja tik JKD įtempio signalą.

Buvo sudaryti penki mašininio mokymosi modeliai, skirti apkrautai ir neapkrautai JKD būklei identifikuoti: LR, AVM, AM, ITAM ir TNT. LR, AVM ir AM modelių mokymosi ir testavimo aibės atitinkamai sudarė 80 % (307 360 DĮS) ir 20 % (76 840 DĮS) visų eksperimento duomenų. ITAM ir TNT modeliams buvo priskirta papildoma validavimo aibė. Taigi šių modelių mokymosi, validavimo ir testavimo aibės sudarė 70 % (268 940 DĮS), 10 % (38 420 DĮS) ir 20 % (76 840 DĮS) visų eksperimento duomenų. Tyrimo metu modeliai buvo nuolat konfigūruojami, buvo ieškoma modelio parametrų rinkinio, kuris gebėtų tiksliausiai identifikuoti JKD būklę. Geriausios modelių architektūros parodytos 2.5 lentelėje. ITAM ir TNT modelių mokymosi ir validacijos metu buvo atliekama 20 epochų su 8 duomenų rinkinio dydžiu bei dvinarės kryžminės entropijos (*binary cross-entropy*) tikslo funkcija. Platesnė modelių sudarymo metodologija aprašyta 2.2 poskyryje.

Modelių LR, AVM ir AM mokymosi laikas nepriklausė nuo DĮS ilgio, kadangi įėjimo signalo dimensija buvo lygi 16, nepriklausomai nuo DĮS ilgio. LR modelių pavyko apmokyti per ~ 4 s ir tai buvo trumpiausias laikas iš visų modelių. AM ir AVM modelių mokymasis vyko kur kas lėčiau ir užtruko atitinkamai ~ 86 s ir net $\sim 10\,000$ s.

Modelių testavimas parodė, kad modelių tikslumas monotoniškai auga kartu su augančiu klasifikuoti naudojamo signalo ilgiu (3.17 ir 3.18 lentelės). Vidutiniš-

3.17 lentelė. Juostinio konvejerio diržo būsenos klasifikavimo tikslumo įverčiai: bendrasis tikslumas
Table 3.17. Accuracy metrics for the classification of the conveyor belt load: general accuracy

Modelis	Signalų ilgis, s					
	0,2	0,4	0,8	1,6	3,2	5,0
LR	57	61	65	69	72	76
AVM	58	62	66	71	74	76
AM	60	62	67	74	79	78
TNT	60	63	69	81	92	100
ITAM	72	77	98	100	100	100

kai bendrasis modelių tikslumas augo po 4 % kiekvieną kartą dvigubai pailginus DĮS. AM buvo tiksliausias modelis, lyginant jį su LR ir AVM. Naudojant 3,2 s ir 5,0 s ilgio apdorotus DĮS, AM atitinkamai pasiekė 79 % ir 78 % bendrą tikslumą ir tai buvo vidutiniškai 3 % daugiau nei LR ir AVM. Verta atkreipti dėmesį, kad AM buvo tiksliausias klasifikuojant beveik visų ilgių signalus, tik 0,4 s ilgio DĮS klasifikavimo tikslumas buvo toks pat kaip AVM. Apibendrinus, modelių bendrasis tikslumas visų ilgių DĮS tenkino nelygę:

$$\text{bendras tikslumas}_{LR} \leq \text{bendras tikslumas}_{AVM} \leq \text{bendras tikslumas}_{AM}. \quad (3.5)$$

Modelių preciziškumas klasifikuojant JKD be apkrovos augo žymiai greičiau ilgėjant DĮS: LR preciziškumas atitinkamai išaugo 23 % ir 13 % klasifikuojant JKD be apkrovos ir su apkrova, AVM – 21 % ir 12 %, o AM – 28 % ir 7 %. Šie rezultatai parodo, kad ilgėjant signalui modeliai geba tiksliau identifikuoti signalus be apkrovos. Tai patvirtina prielaidą, kad trumpi signalai yra labai panašūs ir tik pavieniai signalų pikai išsiskiria savo skaitinėmis charakteristikomis, tačiau ir sujungus pikus į ilgesnes pikų grandines šie modeliai geba preciziškiau klasifikuoti signalus su mažiau svyruojančiomis skaitinėmis charakteristikomis.

Visi trys modeliai, naudojantys apdorotus signalus, jautriausiai klasifikavo JKD su apkrova. JKD su apkrova klasifikavimo jautrumas mažai kito ilgėjant DĮS: LR, AVM ir AM jautrumas, klasifikuojant JKD su apkrova, atitinkamai padidėjo 11 %, 14 % ir net 32 %. JKD be apkrovos klasifikavimo jautrumas išaugo tik 8 %, 8 % ir 6 % atitinkamai LR, AVM ir AM modeliams. Jautrumo rezultatai rodo, kad ilginant DĮS vis didesnis signalų su apkrova skaičius yra teisingai klasifikuojamas. Tokiu būdu patvirtinama prielaida, kad DĮS pikai, gauti iš apkrauto JKD, turi charakteringesnius požymius nei DĮS, generuoti iš JKD be apkrovos. JKD be apkrovos generuoti DĮS pikai dažniau priskiriami apkrovos klasei, todėl būtina ilginti gaunamus signalus, kad tai būtų minimizuojama.

F1-įvertis apibendrina gautus preciziškumo ir jautrumo rezultatus. Kadangi F1-įvertis geriau atspindi modelių su nesubalansuotais duomenimis klasifikavimo

3.18 lentelė. Juostinio konvejerio diržo būsenos klasifikavimo tikslumo įverčiai: preciziškumas, jautrumas ir F1-įvertis

Table 3.18. Accuracy metrics for the classification of the conveyor belt load: precision, sensitivity, and F1-score

Modelis		Signalų ilgis, s					
		0,2	0,4	0,8	1,6	3,2	5,0
Preciziškumas, %							
LR	be apkrovos	47	51	56	60	64	70
	su apkrova	68	71	73	76	78	81
AVM	be apkrovos	48	52	56	64	67	69
	su apkrova	69	70	73	76	79	81
AM	be apkrovos	50	51	57	66	75	78
	su apkrova	71	72	78	79	82	78
TNT	be apkrovos	50	54	60	73	88	100
	su apkrova	68	70	76	87	96	100
ITAM	be apkrovos	60	65	97	100	100	100
	su apkrova	88	92	98	100	100	100
Jautrumas, %							
LR	be apkrovos	64	63	63	66	69	72
	su apkrova	68	60	67	71	75	79
AVM	be apkrovos	64	59	63	64	69	72
	su apkrova	65	64	68	77	78	79
AM	be apkrovos	66	67	74	70	72	63
	su apkrova	56	58	52	76	84	88
TNT	be apkrovos	55	58	67	81	94	100
	su apkrova	63	67	70	80	92	100
ITAM	be apkrovos	87	92	98	100	100	100
	su apkrova	62	68	98	100	100	100
F1-įvertis, %							
LR	be apkrovos	54	56	59	63	67	71
	su apkrova	59	65	70	73	76	80
AVM	be apkrovos	55	56	59	64	68	71
	su apkrova	61	67	70	76	78	80
AM	be apkrovos	57	58	64	68	73	70
	su apkrova	63	64	69	77	83	83
TNT	be apkrovos	53	56	63	77	91	100
	su apkrova	65	69	73	83	94	100
ITAM	be apkrovos	71	76	98	100	100	100
	su apkrova	72	78	98	100	100	100

3.19 lentelė. Ilgos trumpalaikės atminties ir transformerio neuroninio tinklo modelių laiko sąnaudos reikalingos 1 epochos mokymuisi

Table 3.19. Time required to train one epoch for LSTM and Transformer models

Signalų ilgis, s	Matavimo taškai	1 epochos mokymosi laikas, s	
		ITAM	TNT
0,2	80	343	410
0,4	160	510	450
0,8	320	830	750
1,6	640	1550	1950
3,2	1280	2850	6460
5,0	2000	4600	14800

tikslumą nei bendras tikslumas, galime tvirtinti, kad modeliai LR, AVM ir AM beveik identišškai klasifikuoja JKD būsenas.

Gauti rezultatai leidžia daryti išvadą, kad naudojant modelius su apdorotais DĮS, gaunami panašūs rezultatai. Deja, AVM modelio mokymuisi reikia nepriimtinau daug laiko, todėl šis modelis nėra tinkamas šio tipo klasifikavimo uždaviniams spręsti. Nors klasifikavimo tikslumo įverčiai buvo beveik identiški tarp LR ir AM, tačiau RF pademonstravo šiek tiek didesnę bendrą tikslumą ir F1-įvertį. Visgi AM mokymosi laikas buvo 21,5 karto ilgesnis nei LR (atitinkamai 86 s ir 4 s).

Neapdorotiems DĮS klasifikuoti buvo sudaryti ITAM ir TNT modeliai. Kiekvienas modelis buvo apmokytas su visais skirtingų ilgių DĮS (0,2 s, 0,4 s, 0,8 s, 1,6 s, 3,2 s ir 5,0 s).

ITAM ir TNT modelių mokymosi laikas buvo stipriai priklausomas nuo signalo ilgio. Greičiausiai modeliai buvo apmokomi su trumpiausiais 0,2 s signalais, vienos jų epochos mokymasis ITAM ir TNT modeliams atitinkamai trukdavo 343 s ir 410 s naudojant GPU atmintį. Ilgiausiai modeliai buvo mokomi su ilgiausiais 5,0 s DĮS, kur vienos jų epochos mokymasis ITAM ir TNT modeliams atitinkamai trukdavo 4600 s ir 14 800 s, naudojant GPU atmintį, tai yra atitinkamai 13,4 ir 36,1 karto ilgiau nei 0,2 s signalui (3.19 lentelė).

Modelių klasifikavimo tikslumo įverčiai pateikti 3.17 ir 3.18 lentelėse. ITAM ir TNT modelių tikslumas ilgėjant signalui augo labai greitai ir abiem modelių atvejais buvo pasiektas 100 % bendras tikslumas. TNT bendras tikslumas vidutiniškai padidėdavo 8 % padvigubinus DĮS ilgį, o apmokius ilgiausiu 5 s ilgio DĮS bendras tikslumas pasiekė 100 %. ITAM modelio bendras tikslumas augo dar greičiau ir jau apmokius su 1,6 s ilgio DĮS modelio bendras tikslumas pasiekė 100 %. TNT modelio atveju ilgėjant DĮS buvo stebimas pastovus tikslumo prieaugis, o ITAM atveju pirmą kartą dvigubai pailginus DĮS, modelio tikslumas paaugo 5 %, dar kartą padvigubinus DĮS iki 0,8 s, bendras tikslumas paaugo jau 21 % ir pasiekė 98 %.

Lyginant modelių preciziškumą, ITAM net 20 % preciziškiau klasifikavo apkrauto JKD būseną ir siekė 88 % apmokius trumpiausiu (0,2 s) DĮS nei TNT, kurio preciziškumas analogiško ilgio DĮS siekė tik 63 %. Visgi kaip ir klasifikuojant apdorotus DĮS, taip ir šiuo atveju abu modeliai kur kas preciziškiau klasifikuoja apkrautą nei be apkrovos JKD, kai naudojami trumpi DĮS. Nepaisant to, kad modeliai turi skirtingus preciziškumo atskirų DĮS ilgių įverčius, abu modeliai pasiekia 100 % preciziškumą klasifikuojant abi JKD būsenas: TNT 100 % preciziškumą pasiekė su 5,0 s ilgio DĮS, ITAM pakako 1,6 s ilgio DĮS.

Yra gauti įdomūs modelių jautrumo rezultatai. TNT kaip ir kiti (LR, AVM ir AM) modeliai jautriau klasifikuoja apkrautą JKD naudojant trumpus signalus, tačiau nuo 1,6 s ilgio DĮS jautrumas klasifikuojant JKD be apkrovos išauga per 23 % ir pasiekia 85 %, o apkrauto JKD klasifikavimo jautrumas padidėja tik 5 % ir siekia 79 %, t. y. modelis pradėjo jautriau klasifikuoti JKD be apkrovos. ITAM modelio atveju jautrumas klasifikuojant JKD be apkrovos yra gerokai didesnis, jau naudojant trumpiausią DĮS, yra smarkiai didesnis nei apkrauto JKD (87 % ir 62 %), tačiau jau nuo 0,8 s ilgio DĮS jautrumas tampa vienodas ir nuo 1,6 s ilgio signalo jautrumas pasiekia 100 %.


Nesubalansuotų duomenų klasifikavimo tikslumui labiau tinkantis F1-įvertis parodė, kad ITAM modelis yra efektyvus ir geba vienodu tikslumu klasifikuoti abi JKD būsenas naudojant visų ilgių DĮS. TNT elgiasi lygiai taip pat kaip ir LR, AVM ar AM, t. y. apkrauto JKD būseną klasifikuoja tiksliau nei JKD be apkrovos nepriklausomai nuo DĮS ilgio.

Apibendrinant neapdoroto DĮS klasifikavimo modelius matomas aiškus ITAM modelio pranašumas tiek mokymosi laiko atžvilgiu tiek gerokai geresniais klasifikavimo tikslumo įverčiais.

Klasifikavimo modelio jautrumui įvertinti buvo pasirinktas ITAM modelis su 1,6 s ilgio DĮS, nes šis modelis buvo efektyviausias JKD būsenoms klasifikuoti. Tam, kad būtų įvertintas modelio tvirtumas, buvo siekiama nustatyti, kaip stipriai DĮS turi būti paveikti atsitiktinių triukšmų, kad modelis pradėtų neteisingai klasifikuoti JKD būsenas. Tuo tikslu trys atsitiktinio triukšmo tipai buvo pridėti prie neapdorotų 1,6 s ilgio DĮS:


1. Atsitiktinis Laplaso triukšmas N^{Lap} . Tokio tipo paklaidas sukelia nenuspėjami signalo skaitymo svyravimai ir jos yra nepriklausomos nuo JKD susidėvėjimo ar eksperimentuotojo kvalifikacijos.
2. Triukšmas su dreifu N^{CNorm} . Tai sukaupioji paklaida, kuri gali atsirasti dėl matavimo sistemos trūkumų, JKD susidėvėjimo ar prastos eksperimentuotojo kvalifikacijos. Triukšmas su dreifu yra atsitiktinio dydžio, pasiskirsčiusio pagal normalųjį skitinį, sukaupioji reikšmė.
3. Triukšmas N . Tai yra atsitiktinio ir triukšmo su dreifu suma.

Modelio jautrumui įvertinti buvo pasirinkta vienuolika skirtingų triukšmo ly-



3.13 pav. Įtempio signalai su pridėtiniais triukšmais: a) atsitiktinis Laplaso triukšmas N^{Lap} ; b) triukšmas su dreifu N^{CNorm} ; c) triukšmas $N = N^{Lap} + N^{CNorm}$

Fig. 3.13. Tension signals with noise: a) random Laplace noise N^{Lap} ; b) drifted noise N^{CNorm} ; c) noise $N = N^{Lap} + N^{CNorm}$



3.14 pav. ITAM modelio klasifikavimo tikslumas, kai klasifikuojami skirtingo tipo ir lygio triukšmo signalai

Fig. 3.14. LSTM model classification accuracy when the signals of different noise type and level are classified

gių. Signalas su didžiausiu triukšmu buvo sukurtas prie neapdoroto DĮS pridendant triukšmą, priklausomą nuo neapdoroto DĮS standartinės nuokrypio. Toliau DĮS triukšmas buvo mažinamas mažinant triukšmo standartinį nuokrypį 10, 20, ..., 100 kartų (žr. 3.13a, 3.13b ir 3.13c pav.).

Skirtingų tipų ir lygių triukšmo signalų klasifikavimas parodė, kad modelis buvo mažiausiai jautrus atsitiktiniam Laplaso triukšmui. Atsitiktinis triukšmas beveik neturėjo įtakos modelio tikslumui, kol triukšmas nepasiekė 20 kartų mažesnės standartinio nuokrypio vertės, t. y. tik esant itin dideliems (didesniems nei 10^{-1} standartinio nuokrypio) atsitiktiniams triukšmams (3.14 pav.). Tačiau triukšmas su dreifu turėjo daug didesnę poveikį modelio tikslumui, nors esant santykinai dideliame standartiniam nuokrypiui, modelis galėjo klasifikuoti $>90\%$ tikslumu. 3.14 paveikslas rodo, kad triukšmas su dreifu buvo daug reikšmingesnis nei atsitiktinis triukšmas ir turėjo didesnę poveikį visais triukšmo lygiais.

3.4. Trečiojo skyriaus išvados

1. Tarp vidaus degimo variklių ekologinių ir energinių parametų bei skleidžiamų virpesių ir garso slėgio signalo vyravo vidutinio stiprumo ($0,3 < \rho < 0,7$) ir stipri ($\rho \geq 0,7$) koreliacija.
2. Vidaus degimo variklių ekologinių ir energinių parametų prognostinio modelio vidutinė absoliuti procentinė paklaida sumažėjo 1,54 karto ir vidutiniškai siekė 6,0 %, į prognostinį modelį įtraukus laiko ir dažnių srities statistiniai parametrais apdorotus virpesių ir garso slėgio signalus.
3. Sudarytas hipoidinės pavaros pažaidų klasifikavimo daugelio klasių dvimatis sąsūkos neuroninių tinklų modelis pasiekė didžiausią tikslumą (81,1 %). Pasiektas tikslumas buvo 1,7, 1,9 ir 5,4 karto didesnis nei atitinkamai ilgos trumpalaikės atminties, transformerio neuroninių tinklų ir vienmačio sąsūkos neuroninių tinklų modelių.
4. Sudaryti daugelio klasių modeliai tiksliausiai klasifikavo hipoidinės pavaros būklę, kai nėra pažaidų: dvimatis sąsūkos neuroninių tinklų, ilgos trumpalaikės atminties, transformerio neuroninių tinklų ir vienmačio sąsūkos neuroninių tinklų modeliai atitinkamai pasiekė 99,4 %, 99,4 %, 95,1 % ir 41,4 % tikslumą.
5. Didžiausias dvimačio sąsūkos neuroninio tinklo modelio tikslumas buvo pasiektas esant 1000 aps/min sūkiams ir 50 Nm sukimo momentui (88,7 %). Hipoidinės pavaros pažaidas modelis prasčiausiai klasifikuoja, kai sūčiai ir sukimo momentas atitinkamai yra 5000 aps./min. ir 125 Nm (63,6 %).
6. Sudaryti juostinio konvejerio diržo apkrovos būklių klasifikavimo dviejų klasių modeliai parodė, kad giliaisiais neuroniniais tinklais grįsti modeliai yra tikslesni nei klasikiniai mašininio mokymosi modeliai: didžiausias atsitiktinių miškų modelio tikslumas buvo 79 %, o tiek ilgos trumpalaikės atminties, tiek transformerio neuroninių tinklų modeliai pasiekė 100 % tikslumą.
7. Ilgos trumpalaikės atminties modeliui pasiekti 100 % tikslumą užteko 1,6 s ilgio diržo įtempio signalo, kai transformerio neuroninių tinklų modeliui 100 % tikslumui pasiekti prirėikė 5 s ilgio diržo įtempio signalo.
8. Geriausias klasifikavimo modelis (ilgos trumpalaikės atminties modelis) yra neįautrus atsitiktiniam triukšmui. Triukšmo su dreifu atveju modelis buvo jautresnis, tačiau, esant santykinai dideliu standartiniam nuokrypiui, modelis galėjo klasifikuoti >90 % tikslumu.

Bendrosios išvados

1. Vidaus degimo variklių ekologinių ir energinių parametų prognostinių ANCOVA modelių vidutinės absoliučios procentinės paklaidos vidurkis yra 9,3 %, kai į modelį yra įtraukti virpesių signalai apdoroti laiko srities statistiniais parametrais. Papildomai į modelį įtraukus dažnių srities statistiniais parametrais apdorotus virpesių ir garso slėgio signalus, ANCOVA modelio tikslumas vidutiniškai pagerėjo 1,54 karto ir vidutinės absoliučios procentinės paklaidos vidurkis siekė 6,0 %.
2. Sudarytų daugelio klasių hipoidinės pavaros pažaidų klasifikavimo modelių palyginimas parodė, kad didžiausią tikslumą (81,1 %) pasiekė dvimatis sąsūkos neuroninių tinklų modelis. Atitinkamai šio modelio bendrasis tikslumas buvo 1,7, 1,9 ir 5,4 karto didesnis nei ilgos trumpalaikės atminties, transformerio ir vienmačio sąsūkos neuroninių tinklų modelių. Visiems (išskyrus vienmatį sąsūkos neuroninį tinklą) modeliams lengviausia klasifikuoti nepažeistos hipoidinės pavaros būseną (bendras tikslumas >95 %).
3. Sūčiai ir sukimo momentas turi reikšmingą įtaką hipoidinės pavaros pažaidų klasifikavimo tikslumui, tačiau klasifikavimo tikslumo funkcija nuo pavaros sūčių ir sukimo momento nėra monotoniška. Didžiausias dvimačio sąsūkos neuroninių tinklų modelio tikslumas (88,7 %) buvo pasiektas esant 1000 aps./min. sūčiams ir 50 Nm sukimo momentui. Modelis prasčiausiai klasifikuoja (63,6 %), kai sūčiai ir sukimo momentas atitinkamai yra 5000 aps./min. ir 125 Nm.

4. Sudarytų dviejų klasių juostinio konvejerio diržo apkrovos būklių klasifikavimo modelių palyginimas parodė, kad giliaisiais neuroniniais tinklais grįsti modeliai yra tikslesni nei klasikiniai mašininio mokymosi modeliai: didžiausias atsitiktinių miškų modelio tikslumas buvo 79 %, kai tiek ilgos trumpalaikės atminties, tiek transformerio neuroninių tinklų modeliai pasiekė 100 % tikslumą. Ilgos trumpalaikės atminties modelis 100 % tikslumą pasiekė naudodamas 1,6 s ilgio diržo įtempio signalą, transformerio neuroninių tinklų modelis 100 % tikslumą pasiekė naudodamas 5 s ilgio diržo įtempio signalą.
5. Ilgos trumpalaikės atminties neuroninis tinklas modelis yra nejautrus papildomam atsitiktiniam diržo įtempio signalo triukšmui. Triukšmo su dreifu atveju modelis buvo jautresnis, tačiau esant santykinai dideliame standartiniam nuokrypiui, modelis galėjo klasifikuoti >90 % tikslumu.

Literatūra ir šaltiniai

Aatola, H., Larmi, M., Sarjovaara, T., and Mikkonen, S. (2008). Hydrotreated vegetable oil (hvo) as a renewable diesel fuel: Trade-off between nox, particulate emission, and fuel consumption of a heavy duty engine. [see 14 p.]

Andrejiova, M. and Grincova, A. (2018). Classification of impact damage on a rubber-textile conveyor belt using naïve-bayes methodology. *Wear*, 414–415:59–67. [see 31, 112 p.]

Andrejiova, M., Grincova, A., and Marasova, D. (2019). Failure analysis of the rubber-textile conveyor belts using classification models. *Engineering Failure Analysis*, 101:407–417. [see 31, 112 p.]

Andrejiova, M., Grincova, A., and Marasova, D. (2021). Identification with machine learning techniques of a classification model for the degree of damage to rubber-textile conveyor belts with the aim to achieve sustainability. *Engineering Failure Analysis*, 127:105564. [see 31, 112 p.]

Azamfar, M., Singh, J., Bravo-Imaz, I., and Lee, J. (2020). Multisensor data fusion for gearbox fault diagnosis using 2-d convolutional neural network and motor current signature analysis. *Mechanical Systems and Signal Processing*, 144:106861. [see 27, 30, 112 p.]

Banković-Ilić, I. B., Stojković, I. J., Stamenković, O. S., Veljkovic, V. B., and Hung, Y.-T. (2014). Waste animal fats as feedstocks for biodiesel production. *Renewable and sustainable energy reviews*, 32:238–254. [see 14 p.]

Bogoevska, S., Spiridonakos, M., Chatzi, E., Dumova-Jovanoska, E., and Höffer, R. (2017). A data-driven diagnostic framework for wind turbine structures: A holistic approach. *Sensors*, 17(4):720. [see 1, 108 p.]

- Breiman, L. (2001). Random forests. *Machine learning*, 45(1):5–32. [see 23 p.]
- Brimacombe, M. (2014). High-dimensional data and linear models: a review. *Open Access Medical Statistics*, 4:17–27. [see 39 p.]
- Bury, K. (1999). *Statistical Distributions in Engineering*. Cambridge University Press. [see 8 p.]
- Bzinkowski, D., Ryba, T., Siemiatkowski, Z., and Rucki, M. (2022). Real-time monitoring of the rubber belt tension in an industrial conveyor. *Reports in Mechanical Engineering*, 3(1):1–10. [see 53 p.]
- Çalik, A. (2018). Determination of vibration characteristics of a compression ignition engine operated by hydrogen enriched diesel and biodiesel fuels. *Fuel*, 230:355–358. [see 15 p.]
- Cao, S., Hu, Z., Luo, X., and Wang, H. (2021). Research on fault diagnosis technology of centrifugal pump blade crack based on pca and gmm. *Measurement*, 173:108558. [see 22 p.]
- Cappiello, A., Chabini, I., Nam, E. K., Lue, A., and Abou Zeid, M. (2002). A statistical model of vehicle emissions and fuel consumption. In *Proceedings. The IEEE 5th international conference on intelligent transportation systems*, page 801–809. IEEE. [see 17 p.]
- Çay, Y., Korkmaz, I., Çiçek, A., and Kara, F. (2013). Prediction of engine performance and exhaust emissions for gasoline and methanol using artificial neural network. *Energy*, 50:177–186. [see 18, 112 p.]
- Çelebi, K., Uludamar, E., Tosun, E., Yıldızhan, Ş., Aydın, K., and Özcanlı, M. (2017). Experimental and artificial neural network approach of noise and vibration characteristic of an unmodified diesel engine fuelled with conventional diesel, and biodiesel blends with natural gas addition. *Fuel*, 197:159–173. [see 20, 111 p.]
- Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L., and Lopez, A. (2020). A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 408:189–215. [see 23 p.]
- Che, J., Qiao, T., Yang, Y., Zhang, H., and Pang, Y. (2021). Longitudinal tear detection method of conveyor belt based on audio-visual fusion. *Measurement*, 176:109152. [see 31, 112 p.]
- Chen, J., Li, Z., Pan, J., Chen, G., Zi, Y., Yuan, J., Chen, B., and He, Z. (2016). Wavelet transform based on inner product in fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, 70–71:1–35. [see 26 p.]
- Chen, Y., Yuan, J., Luo, Y., and Zhang, W. (2021). Fault prediction of centrifugal pump based on improved knn. *Shock and Vibration*, 2021. [see 22 p.]
- Cheng, G., Chen, X.-h., Shan, X.-l., Liu, H.-g., and Zhou, C.-f. (2016). A new method of gear fault diagnosis in strong noise based on multi-sensor information fusion. *Journal of Vibration and Control*, 22(6):1504–1515. [see 1, 108 p.]

Coburn, T. C. (2001). *Statistical Analysis and Modeling of Automotive Emissions*. Diane Publishing. [see 15 p.]

Davim, J. P. (2014). *Modern mechanical engineering*. Springer. [see 9, 111 p.]

De Myttenaere, A., Golden, B., Le Grand, B., and Rossi, F. (2016). Mean absolute percentage error for regression models. *Neurocomputing*, 192:38–48. [see 42 p.]

Dimitriadis, A., Seljak, T., Vihar, R., Žvar Baškovič, U., Dimaratos, A., Bezergianni, S., Samaras, Z., and Kutrašnik, T. (2020). Improving pm-nox trade-off with paraffinic fuels: A study towards diesel engine optimization with hvo. *Fuel*, 265:116921. [see 14 p.]

Dobrzyńska, E., Szewczyńska, M., Pośniak, M., Szczotka, A., Puchałka, B., and Woodburn, J. (2020). Exhaust emissions from diesel engines fueled by different blends with the addition of nanomodifiers and hydrotreated vegetable oil hvo. *Environmental Pollution*, 259:113772. [see 14 p.]

Dong, L., Xu, S., and Xu, B. (2018). Speech-transformer: a no-recurrence sequence-to-sequence model for speech recognition. In *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, page 5884–5888. IEEE. [see 25 p.]

Eker, Ö. F. (2015). *A hybrid prognostic methodology and its application to well-controlled engineering systems*. Cranfield University. [see 9 p.]

EL-Seesy, A. I., Kayatas, Z., Takayama, R., He, Z., Kandasamy, S., and Kosaka, H. (2020). Combustion and emission characteristics of rcem and common rail diesel engine working with diesel fuel and ethanol/hydrous ethanol injected in the intake and exhaust port: Assessment and comparison. *Energy Conversion and Management*, 205:112453. [see 14 p.]

Fu, J., Yang, R., Li, X., Sun, X., Li, Y., Liu, Z., Zhang, Y., and Sunden, B. (2022). Application of artificial neural network to forecast engine performance and emissions of a spark ignition engine. *Applied Thermal Engineering*, 201:117749. [see 18 p.]

Fuc, P., Lijewski, P., Kurczewski, P., Ziolkowski, A., and Dobrzynski, M. (2017). The analysis of fuel consumption and exhaust emissions from forklifts fueled by diesel fuel and liquefied petroleum gas (lpg) obtained under real driving conditions. In *ASME International Mechanical Engineering Congress and Exposition*, volume 58417, page V006T08A060. American Society of Mechanical Engineers. [see 14 p.]

Gangsar, P. and Tiwari, R. (2020). Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review. *Mechanical Systems and Signal Processing*, 144:106908. [see 26 p.]

Gecgel, O., Ekwaro-Osire, S., Dias, J. P., Serwadda, A., Alemayehu, F. M., and Nispel, A. (2019). Gearbox fault diagnostics using deep learning with simulated data. In *2019 IEEE International Conference on Prognostics and Health Management (ICPHM)*, page 1–8. [see 27, 112 p.]

Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. MIT Press. [see 23, 24 p.]

Grezmak, J., Wang, P., Sun, C., and Gao, R. X. (2019). Explainable convolutional neural network for gearbox fault diagnosis. *Procedia CIRP*, 80:476–481. 26th CIRP Conference on Life Cycle Engineering (LCE) Purdue University, West Lafayette, IN, USA May 7–9, 2019. [see 27, 30, 112 p.]

Guo, L., Gao, H., Huang, H., He, X., and Li, S. (2016). Multifeatures fusion and nonlinear dimension reduction for intelligent bearing condition monitoring. *Shock and Vibration*, 2016. [see 1, 107 p.]

Gupta, P. and Pradhan, M. (2017). Fault detection analysis in rolling element bearing: A review. *Materials Today: Proceedings*, 4(2, Part A):2085–2094. 5th International Conference of Materials Processing and Characterization (ICMPC 2016). [see 26 p.]

Haasz, T., Vilchez, J. J. G., Kunze, R., Deane, P., Fraboulet, D., Fahl, U., and Mulholland, E. (2018). Perspectives on decarbonizing the transport sector in the eu-28. *Energy strategy reviews*, 20:124–132. [see 14 p.]

Han, T., Jiang, D., and Wang, N. (2016). The fault feature extraction of rolling bearing based on emd and difference spectrum of singular value. *Shock and vibration*, 2016. [see 1, 107 p.]

Han, T., Jiang, D., Zhang, X., and Sun, Y. (2017). Intelligent diagnosis method for rotating machinery using dictionary learning and singular value decomposition. *Sensors*, 17(4):689. [see 1, 108 p.]

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):2681–2693. [see 26, 112 p.]

Hien, N. L. H. and Kor, A.-L. (2022). Analysis and prediction model of fuel consumption and carbon dioxide emissions of light-duty vehicles. *Applied Sciences*, 12(2):803. [see 16 p.]

Hills, R. G. and Trucano, T. G. (1999). Statistical validation of engineering and scientific models: Background. *Sandia National Laboratories, SAND99-1256*, 36. [see 8 p.]

Hoang, D.-T. and Kang, H.-J. (2019). A survey on deep learning based bearing fault diagnosis. *Neurocomputing*, 335:327–335. [see 26, 28, 112 p.]

Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8):1735–1780. [see 24 p.]

Hoshen, Y., Weiss, R. J., and Wilson, K. W. (2015). Speech acoustic modeling from raw multichannel waveforms. In *2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, page 4624–4628. IEEE. [see 47 p.]

Hosseini, S. H., Taghizadeh-Alisaraei, A., Ghobadian, B., and Abbaszadeh-Mayvan, A. (2020). Artificial neural network modeling of performance, emission, and vibration of a ci engine using alumina nano-catalyst added to diesel-biodiesel blends. *Renewable Energy*, 149:951–961. [see 20, 112 p.]

Hunicz, J., Matijošius, J., Rimkus, A., Kilikevičius, A., Kordos, P., and Mikulski, M. (2020). Efficient hydrotreated vegetable oil combustion under partially premixed conditions with heavy exhaust gas recirculation. *Fuel*, 268:117350. [see 14 p.]

Jamrozik, A., Tutak, W., Pyrc, M., Gruca, M., and Kočiško, M. (2018). Study on co-combustion of diesel fuel with oxygenated alcohols in a compression ignition dual-fuel engine. *Fuel*, 221:329–345. [see 14 p.]

Jia, F., Lei, Y., Lin, J., Zhou, X., and Lu, N. (2016). Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. *Mechanical Systems and Signal Processing*, 72:303–315. [see 2, 26, 108, 112 p.]

Jiao, J., Zhao, M., Lin, J., and Liang, K. (2020). A comprehensive review on convolutional neural network in machine fault diagnosis. *Neurocomputing*, 417:36–63. [see 28, 112 p.]

Jiao, J., Zhao, M., Lin, J., and Zhao, J. (2018). A multivariate encoder information based convolutional neural network for intelligent fault diagnosis of planetary gearboxes. *Knowledge-Based Systems*, 160:237–250. [see 22 p.]

Jing, L., Zhao, M., Li, P., and Xu, X. (2017). A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox. *Measurement*, 111:1–10. [see 27, 29, 112 p.]

Joseph, V. R. and Melkote, S. N. (2009). Statistical adjustments to engineering models. *Journal of Quality Technology*, 41(4):362–375. [see 8 p.]

Joseph, V. R. and Yan, H. (2015). Engineering-driven statistical adjustment and calibration. *Technometrics*, 57(2):257–267. [see 8 p.]

Kim, W. and Katipamula, S. (2018). A review of fault detection and diagnostics methods for building systems. *Science and Technology for the Built Environment*, 24(1):3–21. [see 26 p.]

Kleinbaum, D. G., Klein, M., and Pryor, E. R. (2002). *Logistic regression: a self-learning text*. Springer. [see 23 p.]

Kobayashi, Y. and Toya, K. (2007). Effect of belt transport speed and other factors on belt mistracking. *Microsystem technologies*, 13(8–10):1325–1330. [see 51 p.]

Kumar, A., Gandhi, C., Zhou, Y., Kumar, R., and Xiang, J. (2020). Latest developments in gear defect diagnosis and prognosis: A review. *Measurement*, 158:107735. [see 27, 28, 112 p.]

Kumar, S., Goyal, D., Dang, R. K., Dhimi, S. S., and Pabla, B. (2018). Condition based maintenance of bearings and gears for fault detection – a review. *Materials Today: Proceedings*, 5(2, Part 1):6128–6137. 7th International Conference of Materials Processing and Characterization, March 17–19, 2017. [see 26 p.]

Lee, J. (1996). Measurement of machine performance degradation using a neural network model. *Computers in Industry*, 30(3):193–209. Computer Integrated Manufacturing. [see 21 p.]

- Lei, Y., Lin, J., He, Z., and Zuo, M. J. (2013). A review on empirical mode decomposition in fault diagnosis of rotating machinery. *Mechanical Systems and Signal Processing*, 35(1):108–126. [see 26 p.]
- Li, C., Sanchez, R.-V., Zurita, G., Cerrada, M., Cabrera, D., and Vásquez, R. E. (2016). Gearbox fault diagnosis based on deep random forest fusion of acoustic and vibratory signals. *Mechanical Systems and Signal Processing*, 76:283–293. [see 27, 112 p.]
- Li, S., Jin, X., Xuan, Y., Zhou, X., Chen, W., Wang, Y., and Yan, X. (2019a). Enhancing the locality and breaking the memory bottleneck of transformer on time series forecasting. *Advances in Neural Information Processing Systems*, 32:5243–5253. [see 25 p.]
- Li, X., Li, J., Zhao, C., Qu, Y., and He, D. (2020). Gear pitting fault diagnosis with mixed operating conditions based on adaptive 1d separable convolution with residual connection. *Mechanical Systems and Signal Processing*, 142:106740. [see 28 p.]
- Li, X., Yang, Y., Pan, H., Cheng, J., and Cheng, J. (2019b). A novel deep stacking least squares support vector machine for rolling bearing fault diagnosis. *Computers in Industry*, 110:36–47. [see 2, 26, 108, 112 p.]
- Lin, T.-Y., Goyal, P., Girshick, R., He, K., and Dollár, P. (2017). Focal loss for dense object detection. In *Proceedings of the IEEE international conference on computer vision*, page 2980–2988. [see 48, 82, 115 p.]
- Liu, C., Jiang, D., and Yang, W. (2014). Global geometric similarity scheme for feature selection in fault diagnosis. *Expert Systems with Applications*, 41(8):3585–3595. [see 1, 108 p.]
- Liu, Y., Miao, C., Li, X., Ji, J., and Meng, D. (2021). Research on the fault analysis method of belt conveyor idlers based on sound and thermal infrared image features. *Measurement*, 186:110177. [see 31, 112 p.]
- Manikandan, S. and Duraivelu, K. (2021). Fault diagnosis of various rotating equipment using machine learning approaches—a review. *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*, 235(2):629–642. [see 21 p.]
- Marwala, T. (2010). Finite-element-model updating applied in damage detection. *Finite-element-model updating using computational intelligence techniques: Applications to structural dynamics*, page 203–223. [see 23 p.]
- Mejía, A., Leiva, M., Rincón-Montenegro, A., Gonzalez-Quiroga, A., and Duarte-Forero, J. (2020). Experimental assessment of emissions maps of a single-cylinder compression ignition engine powered by diesel and palm oil biodiesel-diesel fuel blends. *Case Studies in Thermal Engineering*, 19:100613. [see 18 p.]
- Mirhashemi, F. S. and Sadriani, H. (2020). Nox emissions of compression ignition engines fueled with various biodiesel blends: A review. *Journal of the Energy Institute*, 93(1):129–151. [see 14 p.]
- Monyem, A. and H. Van Gerpen, J. (2001). The effect of biodiesel oxidation on engine

performance and emissions. *Biomass and Bioenergy*, 20(4):317–325. [see 15 p.]

Murugesan Arthanarisamy, N. N. (2016). *Biodiesel as an Alternative Transportation Fuel in Diesel Engines an In-Depth Study on Biodiesel Performance*, volume 124 of *Lecture Notes in Networks and Systems*. LAMBERT Academic Publishing, Riga. [see 14 p.]

Nag, S., Sharma, P., Gupta, A., and Dhar, A. (2019). Combustion, vibration and noise analysis of hydrogen-diesel dual fuelled engine. *Fuel*, 241:488–494. [see 15 p.]

Nasiri, S., Khosravani, M. R., and Weinberg, K. (2017). Fracture mechanics and mechanical fault detection by artificial intelligence methods: A review. *Engineering Failure Analysis*, 81:270–293. [see 26 p.]

Omar, F. K., Selim, M. Y., and Emam, S. A. (2017). Time and frequency analyses of dual-fuel engine block vibration. *Fuel*, 203:884–893. [see 15 p.]

Ong, Z. C., Mohd Mishani, M. B., Chong, W. T., Soon, R. S., Ong, H. C., and Ismail, Z. (2017). Identification of optimum calophyllum inophyllum bio-fuel blend in diesel engine using advanced vibration analysis technique. *Renewable Energy*, 109:295–304. [see 15 p.]

Patel, A. R., Ramaiya, K. K., Bhatia, C. V., Shah, H. N., and Bhavsar, S. N. (2021). Artificial intelligence: Prospect in mechanical engineering field—a review. *Data Science and Intelligent Applications*, page 267–282. [see 21 p.]

Paya, B., Esat, I., and Badi, M. (1997). Artificial neural network based fault diagnostics of rotating machinery using wavelet transforms as a preprocessor. *Mechanical Systems and Signal Processing*, 11(5):751–765. [see 21, 22 p.]

Qiu, G., Gu, Y., and Cai, Q. (2019). A deep convolutional neural networks model for intelligent fault diagnosis of a gearbox under different operational conditions. *Measurement*, 145:94–107. [see 27, 29, 112 p.]

Radford, A., Wu, J., Child, R., Luan, D., Amodei, D., Sutskever, I., et al. (2019). Language models are unsupervised multitask learners. *OpenAI blog*, 1(8):9. [see 25 p.]

Raghuvaran, S., Ashok, B., Veluchamy, B., and Ganesh, N. (2021). Evaluation of performance and exhaust emission of c.i diesel engine fuel with palm oil biodiesel using an artificial neural network. *Materials Today: Proceedings*, 37:1107–1111. International Conference on Newer Trends and Innovation in Mechanical Engineering: Materials Science. [see 14 p.]

Ramachander, J., Gugulothu, S., Sastry, G. R., and Surya, M. S. (2021). Statistical and experimental investigation of the influence of fuel injection strategies on crdi engine assisted cng dual fuel diesel engine. *International Journal of Hydrogen Energy*. [see 17 p.]

Riaz, S., Elahi, H., Javaid, K., and Shahzad, T. (2017). Vibration feature extraction and analysis for fault diagnosis of rotating machinery-a literature survey. *Asia Pacific Journal of Multidisciplinary Research*, 5(1):103–110. [see 26 p.]

Rimkus, A., Matijošius, J., and Manoj Rayapureddy, S. (2020). Research of energy and ecological indicators of a compression ignition engine fuelled with diesel, biodiesel (rme-based) and isopropanol fuel blends. *Energies*, 13(9). [see 14 p.]

Romig, C. and Spataru, A. (1996). Emissions and engine performance from blends of soya and canola methyl esters with arb #2 diesel in a ddc 6v92ta mui engine. *Bioresource Technology*, 56(1):25–34. A Collection of Papers Presented at An Alternative Energy Conference - Liquid Fuels, Lubricants and Additives from Biomass. [see 15 p.]

Ryba, T. (2021). Initial tests of the rubber belts tension of conveyors with a prototype measuring system. *Mechanik*. [see 53 p.]

San José Alonso, J., López Sastre, J., Romero-Ávila, C., and López, E. (2008). A note on the combustion of blends of diesel and soya, sunflower and rapeseed vegetable oils in a light boiler. *Biomass and Bioenergy*, 32(9):880–886. [see 15 p.]

Santos, A. A., Rocha, F. A. S., Reis, A. J. d. R., and Guimarães, F. G. (2020). Automatic system for visual detection of dirt buildup on conveyor belts using convolutional neural networks. *Sensors*, 20(20). [see 32, 112 p.]

Saravanan, P., Kumar, N. M., Ettappan, M., Dhanagopal, R., and Vishnupriyan, J. (2020). Effect of exhaust gas re-circulation on performance, emission and combustion characteristics of ethanol-fueled diesel engine. *Case Studies in Thermal Engineering*, 20:100643. [see 14 p.]

Sevinc, H. and Hazar, H. (2020). Investigation of performance and exhaust emissions of a chromium oxide coated diesel engine fueled with dibutyl maleate mixtures by experimental and ann technique. *Fuel*, 278:118338. [see 14 p.]

Shao, H., Jiang, H., Zhao, H., and Wang, F. (2017). A novel deep autoencoder feature learning method for rotating machinery fault diagnosis. *Mechanical Systems and Signal Processing*, 95:187–204. [see 2, 26, 108, 112 p.]

Shewhart, W. A. (1924). Some applications of statistical methods to the analysis of physical and engineering data. *Bell System Technical Journal*, 3(1):43–87. [see 8 p.]

Shewhart, W. A. (1931). Statistical method from an engineering viewpoint. *Journal of the American Statistical Association*, 26(175):262–269. [see 8 p.]

Shunming, L., Haidong, G., and Dianrong, L. (2013). Review of vibration signal processing methods. *Chinese Journal of Scientific Instrument*, 34(8):1907–1915. [see 26 p.]

Sivaramakrishnan, K. and Ravikumar, P. (2014). Optimization of operational parameters on performance and emissions of a diesel engine using biodiesel. *International Journal of Environmental Science and Technology*, 11(4):949–958. [see 16 p.]

Skrickij, V. (2014). *Transporto mašinų transmisijos elementų dinaminių procesų tyrimas*. PhD thesis, Vilniaus Gedimino technikos universitetas. [see 39, 46 p.]

Skrickij, V., Bogdevičius, M., and Junevičius, R. (2016). Diagnostic features for the condition monitoring of hypoid gear utilizing the wavelet transform. *Applied Acoustics*, 106:51–62. [see 46, 47 p.]

Śladowski, A. (2020). *Ecology in transport: problems and solutions*, volume 124. Springer Nature. [see 14 p.]

- Staszewski, W. J. and Worden, K. (1997). Classification of faults in gearboxes—pre-processing algorithms and neural networks. *Neural Computing & Applications*, 5(3):160–183. [see 39 p.]
- Sun, P., Liao, Y., and Lin, J. (2017). The shock pulse index and its application in the fault diagnosis of rolling element bearings. *Sensors*, 17(3):535. [see 1, 107 p.]
- Taghizadeh-Alisaraei, A., Ghobadian, B., Tavakoli-Hashjin, T., and Mohtasebi, S. S. (2012). Vibration analysis of a diesel engine using biodiesel and petrodiesel fuel blends. *fuel*, 102:414–422. [see 20, 111 p.]
- Tang, G., Luo, G., Zhang, W., Yang, C., and Wang, H. (2016). Underdetermined blind source separation with variational mode decomposition for compound roller bearing fault signals. *Sensors*, 16(6):897. [see 1, 107 p.]
- Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1):267–288. [see 11, 12 p.]
- Tiwari, R., Bordoloi, D., and Dewangan, A. (2021). Blockage and cavitation detection in centrifugal pumps from dynamic pressure signal using deep learning algorithm. *Measurement*, 173:108676. [see 22 p.]
- Uludamar, E., Tosun, E., and Aydın, K. (2016). Experimental and regression analysis of noise and vibration of a compression ignition engine fuelled with various biodiesels. *Fuel*, 177:326–333. [see 19, 111 p.]
- Uludamar, E., Tosun, E., Tüccar, G., Şafak Yıldızhan, Çalık, A., Yıldırım, S., Serin, H., and Özcanlı, M. (2017). Evaluation of vibration characteristics of a hydroxyl (hho) gas generator installed diesel engine fuelled with different diesel–biodiesel blends. *International Journal of Hydrogen Energy*, 42(36):23352–23360. [see 15 p.]
- Vapnik, V. (1998). *Statistical learning theory*. John Wiley & Sons. [see 23 p.]
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., and Polosukhin, I. (2017). Attention is all you need. In *NIPS*. [see 25 p.]
- Walker, H. M. (1975). *Studies in the history of statistical method*. Arno Press. [see 8 p.]
- Wang, Z., Wang, J., and Wang, Y. (2018). An intelligent diagnosis scheme based on generative adversarial learning deep neural networks and its application to planetary gearbox fault pattern recognition. *Neurocomputing*, 310:213–222. [see 22 p.]
- Waziralilah, N. F., Abu, A., Lim, M., Quen, L. K., and Elfakharany, A. (2019). A review on convolutional neural network in bearing fault diagnosis. In *MATEC Web of Conferences*, volume 255, page 06002. EDP Sciences. [see 22 p.]
- Wodecki, J., Zdunek, R., Wyłomańska, A., and Zimroz, R. (2017). Nonnegative factorization of spectrogram for local damage detection of belt conveyor gearboxes. *IFAC-PapersOnLine*, 50(1):4714–4718. 20th IFAC World Congress. [see 31 p.]
- Xiang, L. and Tsung, F. (2008). Statistical monitoring of multi-stage processes based on engineering models. *IIE transactions*, 40(10):957–970. [see 9 p.]

Xu, G., Liu, M., Jiang, Z., Söffker, D., and Shen, W. (2019). Bearing fault diagnosis method based on deep convolutional neural network and random forest ensemble learning. *Sensors*, 19(5):1088. [see 2, 26, 108, 112 p.]

Yaşar, A., Keskin, A., Şafak Yıldızhan, and Uludamar, E. (2019). Emission and vibration analysis of diesel engine fuelled diesel fuel containing metallic based nanoparticles. *Fuel*, 239:1224–1230. [see 15 p.]

Yao, Y., Wang, H., Li, S., Liu, Z., Gui, G., Dan, Y., and Hu, J. (2018). End-to-end convolutional neural network model for gear fault diagnosis based on sound signals. *Applied Sciences*, 8(9):1584. [see 28 p.]

Yaqub, M. and Loparo, K. A. (2016). An automated approach for bearing damage detection. *Journal of Vibration and Control*, 22(14):3253–3266. [see 1, 107 p.]

Yousefian, R. and Kamalasadan, S. (2017). A review of neural network based machine learning approaches for rotor angle stability control. *arXiv preprint arXiv:1701.01214*. [see 22 p.]

Yunusa-Kaltungo, A., Sinha, J. K., and Nembhard, A. D. (2015). A novel fault diagnosis technique for enhancing maintenance and reliability of rotating machines. *Structural Health Monitoring*, 14(6):604–621. [see 1, 107 p.]

Zhang, M., Shi, H., Zhang, Y., Yu, Y., and Zhou, M. (2021). Deep learning-based damage detection of mining conveyor belt. *Measurement*, 175:109130. [see 22, 32, 113 p.]

Zhao, L. (2011). Typical failure analysis and processing of belt conveyor. *Procedia Engineering*, 26:942–946. ISMSSE2011. [see 51 p.]

Zöldy, M. (2011). Ethanol–biodiesel–diesel blends as a diesel extender option on compression ignition engines. *Transport*, 26(3):303–309. [see 14 p.]

Zöldy, M. (2020). Fuel properties of butanol–hydrogenated vegetable oil blends as a diesel extender option for internal combustion engines. *Periodica Polytechnica Chemical Engineering*, 64(2):205–212. [see 14 p.]

Zou, H. and Hastie, T. (2005). Regularization and variable selection via the elastic net. *Journal of the royal statistical society: series B (statistical methodology)*, 67(2):301–320. [see 11 p.]

Autoriaus mokslinių publikacijų disertacijos tema sąrašas

Straipsniai recenzuojamuose mokslo žurnaluose

Žvirblis, T., Vainorius, D., Matijošius, J., Kilikevičienė, K., Rimkus, A., Bereczky, Á., Lukács, K., and Kilikevičius, A. 2021. Engine vibration data increases prognosis accuracy on emission loads: A novel statistical regressions algorithm approach for vibration analysis in time domain. *Symmetry*, 13(7), 1234. ISSN 2073-8994. DOI: 10.3390/sym13071234.

Kriaučiūnas, D., Žvirblis, T., Kilikevičienė, K., Kilikevičius, A., Matijošius, J., Rimkus, A., and Vainorius, D. 2021. Impact of simulated biogas compositions (CH₄ and CO₂) on vibration, sound pressure and performance of a spark ignition engine. *Energies*, 14(21), 7037. ISSN 1996-1073. DOI: 10.3390/en14217037.

Straipsniai kituose mokslo leidiniuose

Žvirblis, T., Petkevičius, L., Vaitkus, P., Šabanovič, E., Skrickij, V., and Kilikevičius, A. 2021. Investigation of deep neural networks for hypoid gear signal classification to identify anomalies. In *2020 IEEE 8th Workshop on Advances in Information, Electronic and Electrical Engineering, AIEEE 2020 – Proceedings* (pp. 1–6). Vilnius, IEEE. DOI: 10.1109/AIEEE51419.2021.9435792.

Summary in English

Introduction

Problem Formulation

In recent years, the developers of increasingly complex mechatronic systems have faced a variety of operational problems related to maintenance, support, fault identification, and troubleshooting of these systems. The smooth operation of complex systems requires searching for new modern solutions to the above-mentioned problems. Indirect methods, where the condition of the system is assessed by processing large amounts of data received from the system, have been under development for some time around the globe. Indirect methods of data management are most commonly used for the analysis of mechatronic systems, prediction of various outputs, or fault diagnosis.

Mechatronic systems and their components, such as various motors, gearboxes, bearings, and rotors, are easily damageable, resulting in increased economic loss due to a shutdown of the entire system to eliminate the defect or simply to perform a routine inspection. For this reason, intelligent technologies for condition monitoring and fault identification of mechatronic systems have been developing in recent years.

Vibration analysis is one of the most commonly used diagnostic tools (Yunusa-Kaltungo et al. 2015) due to the convenient and straightforward collection of information. Two types of methods are used to extract the required information from collected vibration data: signal processing and data structure pattern recognition (Guo et al. 2016).

Signal processing methods are based on vibration waveform detection models. These methods also include the analysis of fault frequency characteristics that use advanced signal processing techniques such as waveform transformation, empirical mode decomposition, or spectral expression (Han et al. 2016; Sun et al. 2017; Tang et al. 2016; Yaqub and Loparo, 2016). However, these methods require an extremely high level of operator qualification with a good understanding of the

processes in mechatronic mechanisms and large experience, which can aggravate the identification of faults in real-time.

Meanwhile, data structure template recognition methods are based on automated data processing algorithms, which have been rapidly developing in recent years (Bogoevska et al. 2017; Cheng et al. 2016; Han et al. 2017; Liu et al. 2014). Data structure template recognition methods consist of three main parts: data collection, feature extraction, and template recognition. Recently, new data structure pattern recognition methods for fault diagnosis algorithms have been proposed for processing vibration signals (Shao et al. 2017; Jai et al. 2016; Xu et al. 2019; Li et al. 2019b). These algorithms use a variety of machine learning algorithms, such as artificial neural networks, support vector machines, convolutional neural networks, autoencoders, or recurrent neural networks. The main difficulty is choosing the most appropriate method to solve a particular problem.

This dissertation presents statistical models for predicting ecological and energetic engine parameters and machine learning models for identifying mechatronic system failures. The presented models are based on vibration and sound pressure signals emitted by mechatronic systems. Machine learning models are applied to identify hypoid drive failures and belt conveyor load states, but the same algorithms can be applied to other rotating mechanisms.

Relevance of the Thesis

Statistical prognostic and machine learning models of mechatronic systems (motors, conveyors, and drives) that use vibration signals open up the possibility to study complex mechanisms without major interventions or none at all and without stopping the operation process. Applying these models in real conditions can speed up the maintenance of complex mechanisms and reduce its costs.

The development of new forecasting and classification models is a highly relevant task, as different models may be used for different systems due to the specificity of the system.

Research Object

The object of research is prognostic and machine learning models developed to predict mechatronic system parameters and fault classification.

Aim of the Thesis

This dissertation aims to develop prognostic and machine learning models capable of predicting the values of mechatronic system parameters and identifying and classifying faults.

Tasks of the Thesis

To achieve the aim of the dissertation, the following tasks need to be attained:

1. To perform an overview of prognostic and machine learning models for the prediction of mechatronic system parameters and fault classification.
2. To develop prognostic and machine learning models for:
 - 2.1. forecasting ecological and energetic parameters of the engine;
 - 2.2. classifying hypoid gear faults;
 - 2.3. identifying conveyor belt load states.

3. To implement the developed models by applying them in real mechatronic systems:
 - 3.1. implementing prognostic models for forecasting ecological and energetic parameters of the engine;
 - 3.2. implementing machine learning models for classifying hypoid gear faults;
 - 3.3. implementing machine learning models for identifying conveyor belt load states.

Research Methodology

This dissertation applied theories of data processing, machine learning and statistical analysis. Various linear regression models were used to solve forecasting problems: one-dimensional and multidimensional linear regression, ANOVA, and ANCOVA. Various models were used to classify faults and states of mechatronic systems, including deep learning models such as long short-term memory, Transformer or convolutional neural networks, and classical classification models such as random forests, support vector machines, and logistic regression. Classification tables and error calculation methods were used to assess the accuracy of the models.

Scientific Novelty of the Thesis

1. A new algorithm for statistical analysis has been developed, which allows the development of efficient prognostic models for ecological and energetic parameters of an engine.
2. An accurate prognostic model of ecological and energetic parameters of an engine was developed, consisting of vibration and sound pressure signals aggregated with time and frequency domain statistics.
3. The comparison of different prognostic models demonstrated that model accuracy increased using vibration and sound pressure signals in the prognostic models of ecological and energetic parameters of an engine.
4. Multi-class machine learning classification models were developed capable of identifying hypoid drive failure types by using only vibration signals.
5. Two-class machine learning classification models were developed capable of identifying the conveyor belt load state by using only the belt tension signal.

Practical Value of the Research Findings

The developed new algorithm of statistical analysis allows studying effectively new experimental engines and creating prognostic models for their ecological and energetic parameters.

The proposed accurate prognostic model allows estimating the values of ecological and energetic parameters of an engine without repeating the experiment. The developed model can also be used as a training model to solve further prediction tasks.

Developed machine learning classification models that only use vibration data enable engineers to perform maintenance of mechatronic systems without intervention. Improving and training the models with a wider range of vibration data could lead to highly sensitive classification models that would identify faults at a very early stage.

The conveyor belt load status identification model allows real-time assessment of the conveyor's condition. The models are created using unbalanced data, which is more relevant to real-world conditions. The models can be expanded to include constant conveyor loads and its possible damage, which would allow fully determining condition of the conveyor in real-time.

The models specified in this dissertation and collected data will be used for further research as control comparative models or additions to the data of new research projects.

Defended Statements

1. Accurate prognostic models of ecological and energetic parameters of an engine can be developed using mathematical statistics prediction models.
2. The inclusion of vibration and sound pressure signals in the prediction models of the ecological and energetic parameters of an engine increases the accuracy of these models.
3. Deep learning-based multi-class classification models can classify hypoid gear faults with at least 80% accuracy by using only vibration signals.
4. The accuracy of the fault classification of a hypoid gear depends on the gear speed and torque.
5. Classification models based on deep learning can classify the conveyor belt load condition by using belt tension signal more accurately than classical machine training models.
6. Random and drifting signal noises in the conveyor belt tension signal have a significant effect on the classification of belt load states.

Approval of the Research Findings

Three scientific works were published on the topic of the dissertation. Two papers were issued in indexed publications of the Clarivate Analytics Web of Science database (Žvirblis et al. 2021a; Kriaučiūnas et al. 2021); one in publications of other international databases (Žvirblis et al. 2021b). The results of the research conducted in the dissertation were presented in 4 scientific conferences in Lithuania and other countries:

- International conference “Fizyka Uszkodzeń Eksploatacyjnych”, Deblin (2022).
- International conference “IEEE 8th Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE’20)”, Vilnius (2021).
- Conference “10-asis Lietuvos jaunųjų matematikų susitikimas (LJMS’10)”, Vilnius (2021).
- International conference “ESMO 21st World Congress on Gastrointestinal Cancer”, Barcelona (2019).

The Structure of the Dissertation

The dissertation consists of an introduction and three chapters: a review of scientific literature, the development of prognostic and classification models, and the application of prognostic and classification models in real mechatronic systems. The conclusions and a list of literature sources are also provided.

The volume of this dissertation is 106 pages; the dissertation contains 27 figures, 26 tables, and 64 numbered formulas. The bibliography consists of 127 sources.

Acknowledgement

I am grateful to supervisor Assoc. Prof., PhD Artūras Kilikevičius for motivation and professional leadership and PhD Linas Petkevičius for tireless counseling throughout all studies. Special thanks

go to my master's thesis supervisor PhD Pranas Vaitkus who introduced me to the doctoral supervisor and helped me take the first steps in scientific research. I sincerely appreciate the help of reviewers and editor for their comments and recommendations that have improved the quality of the dissertation. Many thanks go to my family, relatives, friends, and colleagues for their encouragement, support, and understanding.

1. Review of prognostic and machine learning models in mechatronic systems

The most common prognostic models are based on linear or nonlinear regression models (Davim, 2014):

$$Y(\mathbf{x}) = \Phi(\mathbf{x}) + \epsilon, \quad (\text{S.1.1})$$

where $\Phi(\mathbf{x})$ is a parameterized function:

$$\Phi(\mathbf{x}) \in \{f(\mathbf{x}, \beta), \mathbf{x} \in \mathcal{R}^n, \beta \in \mathcal{R}^q\}; \quad (\text{S.1.2})$$

and ϵ is a random variable with zero expectation.

Linear regression is one of the methods of applying the general theory of linear models for modeling the relationship between certain variables by applying a linear equation to the observed data. In a regression, some variables are called independent (also known as factors or explanatory variables), and one variable is referred to as dependent. The general mathematical expression for linear regression is:

$$Y = \alpha + \beta X + \epsilon, \quad (\text{S.1.3})$$

where Y is a dependent variable, $X = (X_1, X_2, \dots, X_n)$ is a vector of independent variables, α is regression intercept, β is a vector of regression parameters, ϵ is a random variable with zero expectation.

The main task in constructing linear regression equations is to estimate the unknown regression parameters (coefficients). There are several methods for estimating these coefficients:

- Least Squares Method;
- Least Absolute Shrinkage and Selection Operator (LASSO);
- Elastic Net regularization (ElasticNet);
- Least-Angle Regression (LARS).

The linear regression is called analysis of variance (ANOVA) when its independent variable is qualitative. The goal of ANOVA is to compare the mean of a dependent variable among different levels of a qualitative independent variable (factor). Covariance analysis (ANCOVA) is one more application of the linear regression model. ANCOVA model is very similar to the ANOVA model, i.e., the ANCOVA analysis checks the equality of the mean among different factor levels with additional variables (covariates).

In previous literature, favorable prediction results were shown using linear and non-linear statistical models for predicting the noise and vibration characteristics using different fuel blends (low sulfur diesel, sunflower, canola, corn biodiesels) at different engine speeds (Uludamar et al. 2016). Another statistical approach was used to evaluate the effect of various biodiesel blends at different engine speeds seeking to identify the fuel blends with minimal vibration (Taghizadeh-Alisaraei et al. 2012). Using the two-way ANOVA statistical model, a conclusion was drawn that vibration values significantly depend on biodiesel blends and engine speed. Moreover, advanced artificial neural network (ANN) modeling was used to predict the noise and vibration levels of the engine using various fuel blends at different engine speeds (Çelebi et al. 2017). The authors additionally presented a wide

analysis of engine exhausted emissions but they did not apply ANN modeling for it. Papers that use ANN for predictions of engine exhaust emissions are very sparse. Cay et al. (2013) showed that ANN with input data such as fuel type, engine speed, torque, fuel flow, carbon monoxide, unburned hydrocarbon, brake-specific fuel consumption, and air-fuel ratio can be very useful and accurate in predicting CO, THC, BSFC, and AFR values. Unfortunately, engine vibration was not included as input data in this model. One more comprehensive study for modeling of performance, emission, and vibration of a compressed ignition engine using the ANN technique was performed by Hosseini et al. (2020). Twelve parameters were used in the input layer in the ANN model for predicting and another 12 parameters in the output layer. However, as in a previous study, the engine vibration data was not included in the input layer.

With a breakthrough in deep learning methods, automated feature extraction techniques for further fault evaluation and classification have flourished. Multiple novel pattern recognition approaches for fault diagnostic algorithms were proposed recently for signal processing (Shao et al. 2017; Jia et al. 2016; Xu et al. 2019; Li et al. 2019b). Primarily, the use of pattern recognition methods is based on VS classification. In such a case, it can be solved by using a lot of machine learning (ML) algorithms such as ANN, support vector machines (SVM), convolutional neural networks (CNN), stacked auto-encoders or recurrent NNs (Han et al. 2018; Hoang and Kang, 2019). The main difficulty is choosing the most appropriate method for a given problem. The application of various machine learning algorithms for solving gear fault diagnostic problems is also a trending topic among researchers (Kumar et al. 2020). Li et al. (2016) compared shallow (SVM, k-nearest neighbourhood (kNN), random forest (RF)) and deep (deep RF fusion, deep Boltzmann machines) learning algorithms and found that large models performed better than the shallow ones. However, in recent years, the most popular deep learning algorithms have been the CNNs (Hoang and Kang, 2019; Kumar et al. 2020; Jiao et al. 2020). According to several authors, algorithms reached superior accuracy if the data had temporal or spatial data complexity as compared with other machine learning algorithms such as SVM, multi-layer perceptron (MLP), kNN, decision tree algorithms (Li et al. 2016; Grezmaek et al. 2019; Qiu et al. 2019; Jing et al. 2017; Gecgel et al. 2019; Azamfar et al. 2020). Furthermore, Qiu et al. (2019) noted that despite increased accuracy, CNN achieved a low computational cost level by using the raw signals directly.

Simple statistical classification models were presented in several research works by Andrejiova et al. (2018; 2019; 2021). The same independent factors such as conveyor belt (CB) type, impactor type, and the drop height were used in all these studies. In the first article (Andrejiova and Grincova, 2018), the authors presented the classification analysis of 4-conditions CB damage using a naïve Bayes classifier which showed 78.8% classification accuracy. Later, the authors expanded their investigation by using additional models (Andrejiova et al. 2019). A decision tree and linear regression models showed identical accuracy of 81.5%. In a later research paper, Andrejiova et al. (2021), presented four classification models: logistic regression, linear regression, decision tree, and a naïve Bayes classifier. Some authors proposed a CB monitoring system based on the combination of sound and a thermal infrared image which can perform a fault analysis of CB idlers (Liu et al. 2021). This study developed a gradient boost decision tree for the classification of CB idler rolls' faults which used Mel-frequency cepstral coefficients of an acoustic signal. The proposed method achieved an accuracy of 94.5% on average. Che et al. (2021) proposed a new method, named audio-visual fusion (AVF), for detecting a longitudinal tear of CB. The authors used both visible light and microphone array to monitor CB in different running states. Mel-frequency cepstral coefficients, spectral centroid, short-time energy, zero-crossing rate, and spectral roll-off were used for extraction of the audio feature, and a histogram of the oriented gradient was used for extraction of the visual feature. Using K-nearest neighbors, a support vector machine, and random forest algorithms the authors reached an excellent accuracy of 93%–97%. However, the authors did not specify the selection of their training and testing sets; therefore, it is not clear if that accuracy level was reached by using unseen data. Santos et al. (2020) presented binary classification models which used CB

images. This classification was performed using CNNs such as visual geometry group (VGG) network, residual network (ResNet), and densely connected convolutional network (DenseNet). The best average accuracy (89.8%) was reached by using the DenseNet model. Comprehensive research on machine learning algorithms was performed by Zhang et al. (2021). The authors compared a wide range of sophisticated machine learning algorithms such as Faster R-CNN, SSD, RFBnet, M2det, Yolov3, and Yolov4. The Yolov3 algorithm was improved by the authors and reached a 97.3% precision on average for four classes.

2. Development of prognostic and machine learning models for the prediction of mechatronic system parameters and condition classification

A three-step statistical analysis algorithm was developed to identify the optimal prognostic model for ecological and energetic engine parameters (EEEP). Vibration and sound pressure signals were aggregated using time and frequency domain statistics prior to including them in prediction models (Tables 2.1 and 2.2). In the first step of statistical analysis, univariate linear regression models (S.1.3) were developed to determine the most significant statistics in the time and frequency domains of the vibration and sound pressure signals. The second step of the algorithm consisted of two parts. In the first part, an ANOVA model was developed to evaluate the effect of fixed engine

Table S.2.1. Architecture of hypoid gear fault classification models

Model	Architecture
1D-CNN	Conv1D(64(3)) → BN-AP(3)-Conv1D(32(3)) →
Number of parameters: 17199	BN-AP(3)-Conv1D(16(3)) → BN-AP(3)-Conv1D(8(3)) → BN-AP(3)-Flatten-Dense(16)-DO(0.2)-Dense(16) → softmax
2D-CNN	Conv2D(64(3,3)), relu → BN-MP(2,2)-Conv2D(32(2,2)) →
Number of parameters: 35103	BN-MP(2,2)-Flatten-Dense(16) → BN-DO(0.2)-Dense(7) → softmax
LSMT	TD(Conv1D(512(3))), relu →
Number of parameters: 233279	BN-TD(AP(2))-TD(Conv1D(128(3))), relu → BN-TD(DO(0.5))-TD(AP(2))-TD(Conv1D(32(3))), relu → BN-TD(DO(0.5))-TD(AP(2))-TD(Conv1D(8(3))), relu → BN-TD(DO(0.5))-TD(AP(2))-TD(Flatten) → LSTM(16)-DO(0.5)-LSTM(16) → softmax
TNN	Patch(10) → PatchEnc(16) → N → MHA(8) → N →
Number of parameters: 44887	Dense(64) → DO(0.1) → Dense(64) → DO(0.1) → MHA(8) → N → Dense(64) → DO(0.1) → Dense(64) → DO(0.1) → N → Flat → Dense(64) → Dense(64) → Softmax

AP(x): Average Pooling with x pool size. N: Normalization, BN: Batch Normalization. Conv1D($x(y)$): one dimensional convolution with x filters and y kernel size. DO(x): Dropout rate of x . MP(x,y): Max Pooling with x and y pool size. TD: Time Distributed. Patch: signal patching, PatchEnc: positional encoding.

Table S.2.2. Configuration of classification models

Model	Architecture/hyper-parameters
LR	no hyper-parameters
SVM	$C=1.0$, kernel='rbf', degree=3,
RF	n_estimators=100, criterion='gini', max_depth=8, min_samples_split=2, bootstrap=True
LSTM*	LSTM(128, input.shape(signal_length,1)) → Dropout(0.2) → LSTM(8) → dense(1, sigmoid)
Transformer*	input.shape(signal_length,1)) Four sequential blocks: Normalization(epsilon=1e-6)(input) → MultiHeadAttention(key_dim=64, num_heads=8, dropout=0.25) → d := Dropout(0.25) Normalization(d, epsilon=1e-6) Conv1D(filters=4, kernel_size=1, relu) → Dropout(0.25) → c := Conv1D(kernel_size=1) → input := c + d + input MLP part: GlobalAveragePooling1D(input) → Dense(128, relu) → Dropout(0.4) → outputs = dense(1, sigmoid)

*The number of LSTM model hyper-parameters was 70953. The number of Transformer model hyper-parameters varied from 17033 to 78473 for 0.2 s and 5.0 s-length signal models, respectively.

parameters on EEEP. The fuel type, engine power, and fuel injection timing were selected as fixed engine parameters. In the second part of the second step of the algorithm, the linear regression and ANOVA models were consolidated. ANCOVA models were constructed for each EEEP after selecting the most significant independent variables with the highest predictive value of the EEEP from the linear regression and ANOVA models.

After processing the values of vibration and sound pressure signals only with time domain statistics, the predictive ANCOVA models of EEEP had the form:

- fuel mass flow, CO, CO₂, NO_x, THC, CO_{sick}, O₂, air mass flow, and t_{exhaust} :

$$Y = \alpha + \beta T_{11}^{H1} + \gamma \times EP + \mu(T_{11}^{H1} \times EP); \quad (\text{S.2.1})$$

- t_{air} and t_{fuel} :

$$Y = \alpha + \beta T_{11}^{H1} + \gamma \times FT + \mu(T_{11}^{H1} \times FT), \quad (\text{S.2.2})$$

where EP is engine power, FT is fuel type.

Additional time domain statistics and new frequency domain statistics were added to refine the model, which significantly impacted the EEEP in the first step. Extending the prognostic model in this way resulted in new ANCOVAs that already included vibration and sound pressure values in the frequency domain statistics:

- fuel mass flow, CO, CO₂, NO_x, THC, CO_{sick}, O₂, air mass flow, and t_{exhaust} :

$$\begin{aligned}
 Y^E &= \alpha + \beta_1 T_{11}^{H1} + \beta_2 T_5^{V1} + \beta_3 T_5^{GS} + \beta_4 F_4^{GS} + \beta_5 F_{12}^{GS} \\
 &\quad + \gamma \times EP \\
 &\quad + \mu_1 (T_{11}^{H1} \times EP) + \mu_2 (T_5^{V1} \times EP) \\
 &\quad + \mu_3 (T_5^{GS} \times EP) + \mu_4 (F_4^{GS} \times EP) \\
 &\quad + \mu_5 (F_{12}^{GS} \times EP) + \epsilon;
 \end{aligned} \tag{S.2.3}$$

- t_{air} and t_{fuel} :

$$\begin{aligned}
 Y^E &= \alpha + \beta_1 T_{11}^{H1} + \beta_2 T_5^{V1} + \beta_3 T_5^{GS} + \beta_4 F_4^{GS} + \beta_5 F_{12}^{GS} \\
 &\quad + \gamma \times FT \\
 &\quad + \mu_1 (T_{11}^{H1} \times FT) + \mu_2 (T_5^{V1} \times FT) \\
 &\quad + \mu_3 (T_5^{GS} \times FT) + \mu_4 (F_4^{GS} \times FT) \\
 &\quad + \mu_5 (F_{12}^{GS} \times FT) + \epsilon,
 \end{aligned} \tag{S.2.4}$$

where EP is engine power, FT is fuel type.

Four DNN models have been developed for hypoid gear (HG) classification: 1D-CNN, 2D-CNN, LSTM, and TNN. The raw vibration signal was used for the 1D-CNN, LSTM, and TNN models, while the Mel spectrograms of the vibration signal were used for 2D-CNN. To classify all seven (0–6) drive states, the classification problem of many classes was solved, and corresponding models were developed.

During the study, the models were continuously configured and a set of model parameters was sought that could classify the lesions most accurately over a reasonable period. The best model architectures are shown in Table S.2.1. Thirty epochs with 32 batch size and a focal loss function (Lin et al. 2017) were performed during the training and validation of all models.

Five models were developed for distinguishing CB-loaded and unloaded conditions: LR, SVM, RF, LSTM, and TNN. Training and test data sets contained 80% and 20% of total separate experiment sessions to have a realistic testing, respectively, for LR, SVM, and RF. For LSTM and Transformer, an additional validation data set was assigned from the training set so that training, validation, and test data sets contained 70% (268 940), 10% (38 420), and 20% (76 840) of records, with the same test set as for LR, SVM, and RF.

This research investigated, multiple configurations of all the considered models. Experimentally, the best-fitted models for the research objectives were identified. The architecture of those models is presented in Table S.2.2. For all models, training and validation were carried out for 20 epochs with a batch size of 8. The binary cross-entropy loss function was used for LSTM and Transformer.

Sixteen time domain parameters were estimated instead of raw signals to reduce the dimension of classification model input for LR, SVM, and RF models (Table 2.1). Thus, all signals of 0.2 s (80 points), 0.4 s (160 points), 0.8 s (320 points), 1.6 s (640 points), 3.2 s (1280 points), and 5.0 s (2000 points) lengths were transformed to estimates of 16 parameters. Such a signal transformation allowed highlighting predominant features of the classes and allowed the interpretation of results of LR, SVM, and RF models more accurately. Since a deep neural network model can obtain better generalization from raw data, raw signal data was used for both LSTM and Transformer neural networks.

3. Results of prognostic and machine learning models for the prediction of mechatronic system parameters and condition classification

One-way ANOVA analysis revealed that engine power had the highest R^2 values for fuel mass flow, CO, CO₂, NO_x, THC, CO_{sick}, O₂Sick, air mass flow, and t_{exhaust} . The fuel type had the highest R^2 value for t_{air} and t_{fuel} , while fuel injection timing had very low R^2 values and was not included in the further analysis (Table S.3.1). R^2 for T_{11}^{H1} was somewhat lower than engine power or type of fuel but still remained statistically significant for all exhaust emission parameters.

Finally, based on the analysis results provided in Table S.3.1, the best predictive models for exhaust emission were developed of T_{11}^{H1} , engine power, and fuel type. Further predictive ANCOVA models with the interaction of a categorical variable and a covariate were constructed:

- Fuel mass flow, CO, CO₂, NO_x, THC, CO_{sick}, O₂, air mass flow, and t_{exhaust} :

$$Y = \alpha + \beta \times [T_{11}^{H1}] + \gamma \times EP + \mu([T_{11}^{H1}] \times EP) + \epsilon; \quad (\text{S.3.1})$$

- t_{air} and t_{fuel} :

$$Y = \alpha + \beta \times [T_{11}^{H1}] + \gamma \times FT + \mu([T_{11}^{H1}] \times FT) + \epsilon, \quad (\text{S.3.2})$$

where EP is engine power, FT is fuel type.

Table S.3.2 shows regression parameter estimates and R^2 values calculated from the ANCOVA model. All R^2 values were higher in the ANCOVA model than in the ANOVA model and much higher than in the univariate linear regression model. The major R^2 improvement in the ANCOVA model as compared to ANOVA was reached in NO_x and t_{air} with an increment of 12.4% and 9.9%, respectively. Exhaust parameters with $R^2 > 90\%$ in the ANOVA model had a very low (<1%) R^2 increment in the ANCOVA model.

Unfortunately, it was observed that the models predicted EEEP rather accurately only at high engine power or using fuel mixtures, but when the engine was running in a lower-power mode or

Table S.3.1. R^2 estimates of prognostic models of ecological and energetic parameters of an engine

	T_{11}^{H1}	Fuel type ^b	Engine power ^b	Injection angle ^b
Fuel mass flow, kg/h	51.3*	2.5	96.0*	<0.1
CO, ppm	33.2*	3.4	95.3*	0.5
CO ₂ , V%	48.6*	0.6	97.8*	<0.1
NO _x , ppm	52.6*	1.3	61.8*	29.9*
THC, ppm	29.6*	18.3*	50.2*	3.6
CO _{sick} , V%	13.8*	35.3*	57.6*	9.8
O ₂ , V%	47.9*	4.9	97.8*	0.1
t_{air} , °C	7.9**	62.5*	11.3*	0.4
Air mass flow, kg/h	30.9*	37.3*	44.0*	6.1
t_{fuel} , °C	3.7*	80.4*	2.6	0.1
t_{exhaust} , °C	47.3*	1.2	96.9*	0.6

^a R^2 estimated using a univariate linear regression model from the first analysis step.

^b R^2 estimated using the ANOVA model from the second analysis step.

* Statistically significant parameters in the models of respective prognostic parameters of the engine.

Table S.3.2. ANCOVA model parameter estimates of ecological and energetic parameters of an engine

	Interc. (α)	T_{11}^{H1} (β)	EP (γ) 8 kW; 12 kW; 20 kW	$[T_{11}^{H1}] \times \text{EP}$ (μ) 8 kW; 12 kW; 20 kW	R^2
Fuel mass flow, kg/h	1,486	0,277	0,697; -4,470; -0,318	-0,022; 4,050; 2,309	96,6
CO, ppm	291,7	3,8	-87,7; -396,9; -1125,7	60,5; 246,6; 1190,6	96,0
CO ₂ , V%	2,626	-0,166	0,279; -5,281; 4,726	0,484; 5,108; 0,085	98,0
NO _x , ppm	1059,3	-550,3	-1496,5; -4982,7; -9382,1	1154,6; 3704,7; 6842,1	74,2
THC, ppm	141,1	-27,3	-119,4; -90,4; -556,3	86,0; 65,9; 409,5	56,2
CO _{sick} , V%	0,131	-0,055	-0,057; 0,089; 0,025	0,041; -0,060; 0,012	58,8
O ₂ , V%	16,59	0,59	-0,06; 7,90; -7,63	-0,98; -7,61; 0,19	98,0
Air mass flow, kg/h	138,35	-2,83	0,02; 12,37; 4,77	0,09; -8,82; -4,53	47,6
t_{exhaust} , °C	143,8	38,5	109,2; -222,3; 415,3	-42,9; 228,9; -102,8	97,1
	Interc. (α)	T_{11}^{H1} (β)	FT (γ) HVO30; HVO50; SME30; SME50	$T_{11}^{H1} \times \text{FT}$ (μ) HVO30; HVO50; SME30; SME50	R^2
t_{air} , °C	22,08	1,04	-33,13; 11,19; -27,10; -9,54	20,70; -10,96; 17,91; 5,82	72,4
t_{fuel} , °C	24,14	5,21	-22,59; 27,62; -10,48; -7,69	11,43; -23,55; 5,54; 3,13	85,8

Interc.: intercept; EP: engine power; FT: fuel type. Engine power of 4 kW and D100 were set as reference categories.

using pure diesel, the additional covariate (vibration processed time domain statistics) did not help improve the results and the ANCOVA model prediction curve overlapped with a one-way ANOVA model curve (Fig. S.3.1).

The extended model improved the prognostic values at low engine power or using pure diesel (Fig. S.3.2). It is interesting to note that the model predicted EEP the best without any regression parameter optimization.

Classification accuracy in the test set was dispersed in a wide range over all models. The best accuracy score was reached by the CNN-2D model (81.1%). The model recognized condition 0 without mistakes (100%) and the classification accuracy of condition 1 was also extremely high (99.4%). However, the model showed unstable accuracy results for defects of one gear tooth (conditions 1–4) (Table S.3.3).

Conditions 3 and 4 were the most difficult to be assigned correctly as their recall reached only 57.6% and 58.9%, respectively. LSTM, Transformer, and CNN-1D models performed significantly worse than CNN-2D and demonstrated only 47.8%, 42.4%, and 15.0% accuracy, respectively. Al-




Fig. S.3.1. NO_x observed and prognostic values when time domain statistics are used




Fig. S.3.2. NO_x observed and prognostic values when time and frequency domain statistics are used

though LSTM and Transformer had extremely low accuracy, they were able to assign gear condition 0 with very high estimates of precision, recall, and F1-score (>80%) (Table S.3.4).

As shown in Table S.3.4, CNN-2D demonstrated a low level of recall for conditions 3 and 4, but the precision rate was significantly higher and reached 78.3% and 89.6%, respectively. The opposite was true for conditions 5 and 6, where the precision rate stood at 63.4%, and 67.4%, respectively and was lower than the rate of recall which climbed as high as 77.5% and 90.1%, respectively.

As the CNN-2D model showed the best performance results in fault signal identification, it was investigated in more detail. A deeper analysis revealed that the highest model accuracy was reached with lower torque loads (25, 50, and 75 Nm) and lower rotation speed (1000, 2000, and 3000 RPM). As Table S.3.5 shows, classification accuracy was more dependent on torque loads than the rotation speed. The rotation speed of 5000 RPM demonstrated the lowest accuracy (75.9%), while a lower speed provided more accurate results. Torque loads of 100 and 125 Nm produced a significantly lower (9.6%) accuracy than 25, 50, and 75 Nm loads.

In LR, SVM, and RF models the accuracy of the model increased by 4% on average each time

Table S.3.3. Normalized confusion matrix of the best-performing classification model (CNN-2D) for a multi-class case

		Predicted Classes						
Condition		0	1	2	3	4	5	6
Actual Classes	0	100.0	0.0	0.0	0.0	0.0	0.0	0.0
	1	0.0	99.4	0.1	0.1	0.2	0.1	0.2
	2	0.0	0.2	83.5	8.3	1.3	2.4	4.3
	3	0.0	0.3	17.2	57.6	1.5	10.4	13.0
	4	0.0	0.2	0.9	4.0	58.9	26.6	9.5
	5	0.0	0.0	1.5	1.7	2.2	77.5	17.1
	6	0.0	0.0	1.1	1.3	1.8	5.7	90.1

Table S.3.4. Precision, recall, and F1-score for multi-class case

Model	Statistic	0	1	2	3	4	5	6
CNN-1D	Precision	16.6	15.4	14.5	15.3	11.6	12.8	15.2
	Recall	41.4	8.4	5.7	14.9	5.8	17.3	11.1
	F1-score	23.7	10.9	8.2	15.1	7.8	14.7	12.8
CNN-2D	Precision	100	99.4	80.7	78.3	89.6	63.4	67.4
	Recall	100	99.4	83.5	57.6	58.9	77.5	90.1
	F1-score	100	99.4	82.1	66.3	71.1	69.8	77.1
LSTM	Precision	83.3	47.8	42.4	32.8	38.1	41.9	38.7
	Recall	99.4	67.2	31.2	32.9	53.7	15.6	34.2
	F1-score	90.7	55.8	35.9	32.9	44.6	22.7	36.3
Transformer	Precision	93.2	67.4	27.8	21.6	22.5	25.9	42.4
	Recall	95.1	59.0	13.9	34.3	19.3	28.5	46.0
	F1-score	94.1	62.9	18.5	26.6	20.8	27.2	44.1

when the signal length was doubled. RF was the most accurate among the three models and was able to classify 3.2 s and 5.0 s-length signals with an accuracy of 79% and 78%, which was 3% higher than that of LR or SVM. It is worth paying attention that RF was the most accurate in classifying the signals of all lengths. Only 0.4 s-length signal classification accuracy was the same in RF as in SVM.

The precision of the models in classifying CB without load increased significantly faster with increasing signal length: the precision of LR, SVM, and RF increased from the shortest to the longest signal by 23% and 13%, by 21% and 12%, by 28% and 7% for unloaded and loaded CB condition, respectively. Since 0.2 s was equivalent to the length of one peak cycle, this fact showed that the models were able to identify more accurately the unloaded signals as they lengthened, which confirmed the assumption that numerical characteristics of short signals of loaded and unloaded CB were very similar and only individual signal peaks stood out for their numerical characteristics.

In all three models using aggregated signals, the highest recall was observed for the classification of a loaded condition. The recall of the loaded condition classification increased considerably with the signal elongation: LR, SVM, and RF models' recall of the loaded CB classification increased by 11%, 14%, and even 32%, respectively, while the unloaded classification recall increased by 8%, 8%, and 6% for LR, SVM, and RF, respectively.

The F1-score summarizes the results of precision and recall tests. The F1-score reflects the accuracy of the model classification with imbalanced data better than the accuracy measure; therefore, it can be argued that the models LR, SVM, and RF classified different CB conditions almost identically.

Table S.3.5. CNN-2D model classification accuracy of 7 gear conditions with different rotation speed, torque load, and a combination of both

		Rotation speed, RPM					
		1000	2000	3000	4000	5000	Per group
Torque load, Nm	25	86.7	78.9	84.4	79.2	82.1	82.3
	50	88.7	83.9	87.6	88.2	84.4	86.5
	75	87.0	87.6	86.7	88.4	80.7	86.1
	100	77.7	80.1	77.5	78.9	68.6	76.5
	125	76.9	79.8	81.5	68.9	63.6	74.1
	Per group	83.4	82.1	83.6	80.7	75.9	81.1

Table S.3.6. Classification metrics for all models

Model	Signal length, s					
	0.2	0.4	0.8	1.6	3.2	5.0
Accuracy, %						
LR	57	61	65	69	72	76
SVM	58	62	66	71	74	76
RF	60	62	67	74	79	78
Transformer	60	63	69	81	92	100
LSTM	72	77	98	100	100	100

Raw signal classification models LSTM and Transformer were developed to classify raw CB signals. Each model was trained with signals of different lengths (0.2 s, 0.4 s, 0.8 s, 1.6 s, 3.2 s, and 5.0 s) by repeating the training for 20 epochs.

Classification metrics of the models are shown in Table S.3.6. The accuracy of the LSTM and Transformer models increased very rapidly with increasing signal length and an accuracy of 100% was achieved when using both models with the longest signals. The accuracy of the Transformer increased on average by 8% when doubling the signal length and after training with the longest signal of 5.0 s, its accuracy reached 100%. The accuracy of the LSTM model grew even faster, and after training with the 1.6 s signal, the accuracy reached 100%. In the case of Transformer, a monotonically constant increase in accuracy was observed with the elongation of the signal, but in the case of LSTM the accuracy of the model increased by 5%, and doubling the signal length up to 0.8 s led to an increase in accuracy by 21 percentage points up to 98%.

A comparative analysis of the precision of the models showed that LSTM classified the loaded CB even by 20 percentage points more precisely than the Transformer and reached 88% with the shortest (0.2 s) signal. the Transformer's precision with the same-length signal reached only 63%. However, as in the case of the classification of aggregated signals, both models classified the loaded CB much more precisely than the idle CB when using short signals. Nevertheless, both models achieved a precision of 100% when classifying both CB states: the Transformer achieved this level of accuracy with a 5.0 s-length signal and LSTM with a 1.6 s-length signal.

The sensitivity of the models demonstrated some noteworthy aspects. The Transformer, like other models (LR, SVM, and RF), classified loaded CBs more sensitively when using short signals than when using the longer ones. However, starting from a 1.6 s-length signal, the Transformer's sensitivity of classifying the unloaded CB condition jumped significantly by 23 percentage points and reached 85%, while the sensitivity of the loaded CB classification increased by only 5% and reached 79% for this length of the signal, i.e., the model started to classify the idle CB state more sensitively. In the case of the LSTM model, the sensitivity to classify the unloaded CB condition using the shortest signal was significantly higher than that of the loaded CB (87% vs. 62%, respec-

tively), but starting from a 0.8 s-length signal, the sensitivity started to be the same for both CB conditions, and starting from a 1.6 s-length signal, the sensitivity reached 100%.

The F1-score, which is more suitable to measure the accuracy of classification of imbalanced data, showed that the LSTM model was the optimal one and was able to classify both CB states with equal accuracy for all signal lengths. Meanwhile, the Transformer performed in exactly the same way as LR, SVM, or RF, i.e., it classified the loaded CB state more accurately than that of a idle CB regardless of the signal length.

Summarizing the analysis of raw signal classification models, the LSTM model demonstrated clear advantages in terms of a shorter training time and significantly better classification accuracy measurements.

General Conclusions

1. Prognostic models of ecological and energetic parameters of an engine were developed, including vibration signal as an additional covariant of the model. The accuracy of the ANCOVA model slightly improved after processing the vibration signals with time domain statistics (MAPE was 9.3% on average). Furthermore, with the addition of vibration signal processed in the frequency domain, MAPE of the ANCOVA model improved by 1.54 times on average.
2. The development of deep neural networks in many classes showed that such modeling could be applied to classify hypoid gear faults using the vibration signal only. 2D-CNN model's overall accuracy was 1.7, 1.9, and 5.4 times higher than long short-term memory, the Transformer, and 1D-CNN models neural networks, respectively.
3. Engine speed and torque had a significant effect on the accuracy of the hypoid gear fault classification. The highest accuracy of 2D-CNN (88.7%) was achieved at 1000 RPM and 50 Nm of torque. Meanwhile, the worst classification was achieved (63.6%) at 5000 RPM and 125 Nm torque.
4. Five binary classification models of conveyor belt load states using a belt tension signal were developed. Deep learning models achieved significantly higher classification accuracy than classical machine learning models. The long short-term memory and Transformer models reached 100% accuracy.
5. The long short-term memory model was insensitive to additional random signal noise. In the case of drift noise, the model was more sensitive, but with a relatively large standard deviation, the model was able to classify with a >90% accuracy.

Tadas ŽVIRBLIS

PROGNOSTINIŲ IR MAŠININIO MOKYMOSI MODELIŲ
TAIKYMAS MECHATRONINIŲ SISTEMŲ PARAMETRAMS
PROGNOZUOTI IR GEDIMAMS KLASIFIKUOTI

Daktaro disertacija

Technologijos mokslai,
mechanikos inžinerija (T 009)

APPLICATION OF PREDICTIVE AND MACHINE LEARNING
MODELS FOR MECHATRONIC SYSTEMS PARAMETERS
PREDICTION AND FAULT CLASSIFICATION

Doctoral Dissertation

Technological Sciences,
Mechanical Engineering (T 009)

2022 05 12. 10,0 sp. l. Tiražas 20 egz.

Leidinio el. versija <https://doi.org/10.20334/2022-022-M>

Vilniaus Gedimino technikos universitetas

Saulėtekio al. 11, 10223 Vilnius

Spausdino UAB „Ciklonas“,

Žirmūnų g. 68, LT-09124 Vilnius