


ŽILINSKÁ UNIVERZITA V ŽILINE
Strojnícka
fakulta

**AUTOREFERÁT
DIZERTAČNEJ PRÁCE**

Žilina, 2025

Ing. Daria Fedorova



ŽILINSKÁ UNIVERZITA V ŽILINE

Strojnícka
fakulta

Ing. Daria Fedorova

AUTOREFERÁT DIZERTAČNEJ PRÁCE

Implementácia analytických metód pre interpretáciu prevádzkových dát

Na získanie akademického titulu **doktor**
(„**philosophiae doctor**“, v skratke „**PhD.**“)

v študijnom odbore Strojárstvo
v študijnom programe Automatizované výrobné systémy

Žilina 2025

Dizertačná práca bola vypracovaná v dennej forme doktorandského štúdia na Žilinskej univerzite v Žiline, Strojníckej fakulte, Katedre automatizácie a výrobných systémov.

Predkladateľ: **Ing. Daria Fedorova**
Žilinská univerzita v Žiline
Strojnícka fakulta
Katedra automatizácie a výrobných systémov

Školiteľ: **prof. Dr. Ing. Ivan Kuric**
Žilinská univerzita v Žiline
Strojnícka fakulta
Katedra automatizácie a výrobných systémov

Oponenti:

1. **prof. Ing. Michal Frivaldský, PhD.**
Žilinská univerzita v Žiline, Fakulta elektrotechniky a informačných technológií, Katedra mechatroniky a elektroniky, Univerzitná 8215/1, 010 26, Žilina
2. **prof. Ing. Peter Frankovský, PhD.**
Technická univerzita v Košiciach, Strojnícka fakulta, Katedra aplikovanej mechaniky a strojného inžinierstva, Letná 1/9, 042 00, Košice-Sever.
3. **doc. Ing. Peter Pokorný, PhD.**
Trenčianska univerzita Alexandra Dubčeka v Trenčíne, Fakulta špeciálnej techniky, Katedra strojného inžinierstva, Ku kyselke 469, 911 06, Trenčín

Autoreferát bol rozoslaný dňa:

Obhajoba dizertačnej práce sa koná dňa 14.08.2025 o 10:00 hod. v miestnosti PP135 na SjF, Univerzitná 8215/1, 010 26, Žilina, pred komisiou pre obhajobu dizertačnej práce schválenou odborovou komisiou v študijnom odbore Strojárstvo, v študijnom programe Automatizované výrobné systémy, vymenovanou dekanom Strojníckej fakulty, Žilinskej univerzity v Žiline.

S dizertačnou prácou je možné sa oboznámiť na referáte pre vedu a výskum dekanátu SjF, UNIZA, Univerzitná 8215/1, 010 26 Žilina.

prof. Ing. Andrej Czán, PhD.
predseda komisie pre obhajobu dizertačnej práce

ABSTRAKT

Predkladaná dizertačná práca sa zaoberá aplikáciou metód dátovej analytiky a umelých neurónových sietí v oblasti technickej diagnostiky v strojárскеj výrobe. Práca poskytuje prehľad o súčasnom stave skúmanej problematiky so zameraním na efektívne uplatnenie dátovej analytiky a neurónových pri riešení praktických úloh v priemysle. Experimentálna časť práce je zameraná na implementáciu a testovanie vybraných prístupov dátovej analytiky a architektúr umelých neurónových sietí pri riešení vybraných priemyselných úloh. Získané poznatky v oblasti aplikácie dátovej analytiky a neurónových sietí sú následne využité pri výbere optimálnych charakteristík vibračného signálu s cieľom zabezpečiť efektívnu detekciu porúch priemyselných robotov.

Kľúčové slová: dátová analytika, neurónové siete, vibrodiagnostika, inžinierstvo funkcií

ABSTRACT

The presented dissertation focuses on the application of data analytics methods and artificial neural networks in the context of technical diagnostics in production engineering. The thesis presents a comprehensive review of the current state of the field, with a focus on the effective use of data-driven approaches and neural network architectures for solving practical challenges. The experimental part of the dissertation is dedicated to the implementation and evaluation of selected data analytics techniques and neural network models in addressing specific use cases within industrial environments. The knowledge acquired is subsequently applied to identify the most informative characteristics of vibration signals to enhance the accuracy and efficiency of fault detection of industrial robots.

Keywords: data analytics, neural networks, vibrodiagnostics, feature engineering

Úvod

S rozvojom techniky a priemyslu rastie aj komplexnosť a dokonalosť používaných pracovných prostriedkov, ako aj ich výkonnosť. Úlohou človeka, ako riadiacej zložky je zabezpečenie opatrení pre zachovanie prevádzkovej spoľahlivosti systému. Pre splnenie tejto podmienky je nevyhnutne mať predstavu o možných aktuálnych a budúcich stavoch výrobných strojov a zariadení – diagnostikovať, tzn. rozpoznávať a určovať prípadné problémy a ohrozenia.^[8]

V tomto kontexte je integrácia prediktívnej údržby a technickej diagnostiky rozhodujúcim princípom, ktorý zásadne mení prevádzkovú efektívnosť a spoľahlivosť. S prechodom na Priemysel 4.0, ktorý je charakterizovaný implementáciou technológií ako internet vecí, analýza veľkých dát a umelá inteligencia, sa význam technickej diagnostiky a prediktívnej údržby ešte viac prehĺbuje. Tieto technológie umožňujú nielen zber a prenos veľkých objemov prevádzkových údajov, ale aj ich pokročilé spracovanie a interpretáciu, čím vytvárajú priestor pre nové úrovne autonómie a automatizácie nielen výrobných, ale aj rozhodovacích činností v rámci výrobného prostredia.^[7]

Svoje uplatnenie v uvedených odvetviach nachádzajú moderné prístupy v oblasti dátovej analytiky a prostriedky umelej inteligencie, vrátane algoritmov strojového učenia a umelých neurónových sietí. Tieto prístupy ponúkajú výrazný potenciál pre analýzu a interpretáciu komplexných dát z technických systémov, kde tradičné analytické metódy často narážajú na limity v presnosti alebo použiteľnosti.

Technická diagnostika úzko súvisí so spoľahlivosťou technických systémov. Zároveň rastie záujem o využitie dátovej analytiky a umelej inteligencie v rôznych oblastiach priemyslu. Vzhľadom na uvedené skutočnosti, sa dizertačná práca zameriava na analýzu existujúcich prístupov v kontexte technickej diagnostiky a prediktívnej údržby, dátovej analytiky a umelých neurónových sietí v strojárskom priemysle.

Základnou časťou práce je spracovanie a interpretácia dát, získaných pomocou stavového monitoringu priemyselných zariadení. Získané poznatky slúžia ako základ pre návrh a realizáciu experimentu, cieľom ktorého je overenie efektívnosti využitia uvedených prístupov pre zvýšenie spoľahlivosti technických systémov v priemyselnom prostredí.

Hlavným cieľom dizertačnej práce je experimentálne overenie vybraných prístupov dátovej analytiky a navrhutej architektúry umelej neurónovej siete pre detekciu porúch priemyselného robota Fanuc LR Mate 200iC, ktorým disponuje Katedra automatizácie a výrobných systémov Žilinskej univerzity v Žiline. V rámci experimentu sa overuje hypotéza dizertačnej práce, ktorá v prípade potvrdenia napomáha k rozšíreniu poznatkov v oblasti technickej diagnostiky strojov so sekvenčným pohybom. Potvrdením hypotézy by boli vytvorené predpoklady ako pre efektívnu integráciu diagnostických prístupov, založených na dátach do výrobného prostredia, tak aj pre prehĺbenie výskumu v príslušnej oblasti.

1 Analýza súčasného stavu skúmanej problematiky

Analýza prevádzkových dát je základom modernej technickej diagnostiky a prediktívnej údržby. Dátová analytika umožňuje interpretovať komplexné súbory údajov, na základe ktorých je možné identifikovať potenciálne problémy, čo v konečnom dôsledku znižuje prestoje a náklady na údržbu. Problematike uplatnenia prediktívnych a diagnostických modelov, založených na dátach sa začína venovať väčšie množstvo výskumných prác približne od rokov 2017-2018 spolu s rozvojom strojového učenia a umelých neurónových sietí. ^[3,10] Zároveň je možné pozorovať, že problematike implementácie umelých neurónových sietí, algoritmov strojového učenia a analýzy prevádzkových dát je venovaná veľká pozornosť na Slovensku a v zahraničí, a to nielen v rámci výskumných inštitúcií, ale aj v komerčných spoločnostiach.

1.1 Stav skúmanej problematiky – Slovenská republika

Na území Slovenskej republiky sa výskum zameraný na využitie dátovej analytiky a algoritmov umelej inteligencie v priemysle realizuje na viacerých univerzitách a výskumných inštitúciách. Okrem samotného výskumu narastá aj záujem o praktické uplatnenie získaných poznatkov. Tento trend potvrdzujú viaceré projekty v spolupráci s priemyslom, ako aj vedecké publikácie. Nižšie sú uvedené niektoré z oblastí, ktorým je venovaný výskum na území Slovenska:

- Slovenská technická univerzita v Bratislave, Materiálovotechnologická fakulta STU so sídlom v Trnave, v spolupráci s PredictiveDataScience, s.r.o.: Vývoj komplexného softvérového riešenia pre kontrolu kvality automobilov s implementáciou dátovej analýzy a modelov umelej inteligencie.
- Slovenská technická univerzita v Bratislave, Materiálovotechnologická fakulta STU so sídlom v Trnave: Návrh systému monitorovania stavu strojov v reálnom výrobnom prostredí, s dôrazom na využitie technológií *edge computing*, expertného systému a umelých neurónových sietí pre identifikáciu kritických stavov stroja.
- Žilinská univerzita v Žiline, Katedra automatizácie a výrobných systémov: Problematika využitia prediktívnych modelov neurónových sietí NAR na predpovedanie priebehu určitých veličín, ktoré môžu indikovať problém s priemyselnými strojmi alebo ich závažné poruchy.
- Technická univerzita v Košiciach, Strojnícka fakulta: Aplikácia prístupov, založených na adaptívnych neuro-fuzzy regulátoroch pre riadenie nekonvenčných robotických prvkov.
- Technická univerzita v Košiciach, Fakulta výrobných technológií: Vibrodiagnostika ako nástroj prediktívnej údržby pri prevádzke turbogenerátorov malej vodnej elektrárne.

1.2 Stav skúmanej problematiky – Európa

Na území Európskej Únie viacero výskumných akademických a priemyselných inštitúcií významne prispieva k rozvoju diagnostických technológií, založených na implementácii rozličných prostriedkov umelej inteligencie. Dôraz je kladený na zvýšenie spoľahlivosti strojov, minimalizáciu neplánovaných prestojov a umožnenie rozhodovania na základe prevádzkových dát v rôznych výrobných odvetviach. Medzi niektoré z kľúčových výskumov, ktoré sa realizujú na území Európskej Únie patria:

- Politecnico di Torino, Department of Aerospace and Mechanical Engineering, Turin (Taliansko): Prognózovanie aktuálneho stavu elektromechanického pohonu pre letecký priemysel pomocou umelých neurónových sietí (odhadovanie tretieho momentu).

- Zurich University of Applied Sciences, Institute of Mechatronic Systems, Zürich (Švajčiarsko): Indikácia stavu ložísk pomocou použitia konvolučného autoenkódera, prediktívna údržba pre 3DOF delta-robota na základe autoenkódera.
- Lublin University of Technology, Faculty of Mechanical Engineering, Department of Production Engineering Fundamentals, Lublin (Poľsko): Použitie neurónových sietí pre predikciu zložiek reznej sily a kvality obrobeného povrchu. Skúmanie vplyvu technologických parametrov na zrýchlenie vibrácií pri frézovaní a predikcia vibrácií pomocou umelých neurónových sietí.
- Fraunhofer Institute for Integrated Circuits IIS, Division Engineering of Adaptive Systems, Drážďany (Nemecko): Aplikácia algoritmov vysvetliteľnej umelej inteligencie na konvolučné neurónové siete pre detekciu porúch ložísk na základe vibračných dát.

1.3 Stav skúmanej problematiky – ďalšie krajiny

Celosvetovo zaznamenala implementácia neurónových sietí a iných algoritmov strojového učenia v prediktívnej údržbe a technickej diagnostike rýchly rast. Súčasný výskumný priestor reflektuje geograficky diverzifikovaný záujem. Inštitúcie na všetkých kontinentoch sa zaoberajú teoretickými aj aplikovanými štúdiami v príslušnej oblasti. Tým sa naznačuje globálny trend vedúci k sofistikovanejším, škálovateľnejším a kontextovo orientovaným riešeniam, založeným na analýze a interpretácii prevádzkových dát. Príkladmi sú nasledujúce výskumy:

- Chongqing Technology and Business University, Research Center of System Health Maintenance, Čchung-čching (Čína): Multimodálne spracovanie vibračného signálu pomocou hlbokého učenia pre úlohy diagnostiky porúch prevodových mechanizmov.
- Big Data Research and Development Group, STM Defense Technologies Engineering and Trade Inc. Ankara (Turecko): Použitie sietí LSTM na predpovedanie stavu motora v rámci spracovania údajov veľkého rozsahu.
- Kumamoto University, Department of Computer Science and Electrical Engineering Kumamoto (Japonsko): Predikcia zostávajúcej životnosti ložísk pomocou dopredných neurónových sietí.
- University of Waterloo, Department of Mechanical and Mechatronics Engineering Waterloo (Kanada): Viackrokový predikčný systém na báze umelej neurónovej siete a fuzzy logiky pre predikciu a odhad porúch ozubených kolies v prevodových mechanizmoch.
- Kalashnikov Izhevsk State Technical University, Votkinsk Branch, Votkinsk (Rusko): Implementácia prediktívnych modelov neurónových sietí NAR v radiacích systémoch a úlohách prediktívnej údržby.

2 Cieľ dizertačnej práce

Súčasný výrobný proces generujú rozsiahle množstvo prevádzkových dát, ktoré menia priemyselné odvetvia. Aby si firmy zachovali konkurencieschopnosť a zefektívnil výrobu, musia vyvinúť stratégie na využitie týchto dát. Prevádzkové dáta zahŕňajú všetky informácie získané z monitorovaných zariadení alebo systémov počas ich činnosti, ako sú indikátory stavu stroja, environmentálne podmienky a prevádzkové parametre. Nepretržité zhromažďovanie týchto dát si vyžaduje ich efektívne spracovanie a analýzu.

2.1 Čiastkové ciele dizertačnej práce

Medzi ciele dizertačnej práce patrí preukázanie efektívnosti prístupov, založených na dátovej analýze a umelých neurónových sieťach pre riešenie rozmanitých komplexných úloh v kontexte

moderného priemyslu. Čiastkové ciele práce sú zamerané na kľúčové etapy realizovaného výskumu a spracovanie teoretických a praktických poznatkov v oblasti využitia metód dátovej analytiky a umelých neurónových sietí v priemysle. Medzi stanovené čiastkové úlohy dizertačnej práce patria:

- Analýza súčasného stavu skúmanej problematiky a spracovanie aktuálnych poznatkov v oblasti prediktívnej údržby a technickej diagnostiky strojov a zariadení.
- Spracovanie poznatkov o architektúrach neurónových sietí a prístupoch dátovej analytiky používaných v priemyselných aplikáciách s cieľom následnej implementácie v rámci riešenia experimentov dizertačnej práce.
- Voľba vhodných prístupov dátovej analytiky a architektúr neurónových sietí pre riešenie vybraných experimentov.
- Implementácia zvolených prístupov a metód v rámci realizovaných experimentov s cieľom overenia možností ich použitia pre úlohy predikcie prevádzkových parametrov a identifikácie anomálií počas prevádzky vybraných zariadení.

2.2 Hlavný cieľ dizertačnej práce

Monitorovanie stavu je kľúčové v súčasnej výrobe, pretože umožňuje včasné odhalenie problémov, čím predchádza rozsiahlym škodám a neplánovaným odstávkam. Vibrodiagnostika zohráva v tomto procese významnú úlohu, pretože vibrácie sú ľahko merateľné a poskytujú aktuálne informácie o stave strojov bez narušenia výroby, čo umožňuje identifikovať anomálie ako mechanické poškodenia ešte pred ich eskaláciou.

Priemyselné roboty sú neoddeliteľnou súčasťou modernej výroby, obzvlášť v aplikáciách vyžadujúcich vysokú presnosť. V týchto prípadoch je udržiavanie stabilných výkonnostných parametrov kritické na predchádzanie kolíziám alebo výrobe nekvalitných produktov. Hlavným cieľom práce je teda preukázať efektívnosť využitia neurónových sietí a dátovej analytiky pre technickú diagnostiku robota Fanuc LR Mate 200iC na základe vibračného signálu. Pomocou experimentu bude overená pravdivosť stanovenej hypotézy dizertačnej práce:

Na základe vybraných parametrov vibračného signálu je možné pomocou navrhnutého modelu neurónovej siete zistiť uvoľnenie priemyselného robota na jeho základni s presnosťou minimálne 95 %.

3 Uplatnenie neurónových sietí a dátovej analytiky pre riešenie úloh v priemysle


Nasledujúca kapitola je venovaná zhrnutiu experimentov, realizovaných pre splnenie čiastkových úloh práce. Cieľom bolo overiť efektívnosť navrhnutých prístupov a získať zmysluplné poznatky z komplexných súborov údajov pomocou štatistických techník, umelých neurónových sietí a metód výberu príznakov. Jedna skupina dát, použitých v rámci experimentov pochádza z testovacích a priemyselných zariadení, ktorými disponuje Katedra automatizácie a výrobných systémov, Žilinskej univerzity v Žiline. Okrem toho boli použité aj dáta poskytnuté priemyselným partnerom, v rámci spolupráce pri riešení projektov zameraných na výskum a technický rozvoj v oblasti digitalizácie a modernizácie priemyselného odvetvia.

Úlohy súvisiace s programovaním boli realizované v prostredí MATLAB, nakoľko uvedený softvér poskytuje široké spektrum pokročilých možností pre programovanie, numerické výpočty, analýzu dát, vývoj algoritmov a tvorbu výpočtových modelov.

3.1 Aplikácia umelých neurónových sietí pre odhad prevádzkových parametrov a prediktívnu údržbu hydraulického obvodu

Experiment je zameraný na tréning a validáciu navrhutej doprednej neurónovej siete s cieľom vizualizovať vzťahy medzi skúmaným parametrom a vybranými vstupnými premennými. V rámci experimentu boli použité dva súbory údajov, získané z testovacieho zariadenia (Obr. 1b). Testovacie zariadenie predstavuje uzavretý hydraulický okruh s možnosťou ohrievania a prečerpania pracovnej kvapaliny. Konštrukcia simulačného zariadenia bola navrhnutá tak, aby zodpovedala požiadavkám na jednoduchosť, ľahkú opraviteľnosť a možnosť jednoduchšej modifikácie.

Zariadenie umožňuje súčasný monitoring ôsmich prevádzkových parametrov a dvoch parametrov okolitého prostredia. Použitá konfigurácia zariadenia obsahuje niekoľko snímačov znázornených na principiálnej schéme (Obr. 1a). Riadenie je realizované prostredníctvom mikrokontroléru Arduino Uno. Pre zber dát zo snímačov teploty je použitý mikrokontrolér Arduino MEGA.



Obr. 1 Experimentálne zariadenie a) principiálna schéma; b) praktické prevedenie

Po natrénovaní a overení neurónovej siete sa získané výsledky použijú na výpočet a znázornenie závislostí skúmaného parametra t_{tank} od zvolených vstupných premenných (1). Cieľom tejto vizualizácie je objasniť vplyv každej vstupnej premennej na sledovaný parameter a ďalej overiť schopnosť navrhovaného modelu neurónovej siete aproximovať zadanú funkciu.

$$t_{tank} = f(t_{inp}, t_{out}, t_{HCH}, t_{amb}, RH, U, I, p_{sys}, Q, T) \quad (1)$$

Kde t_{tank} je teplota kvapaliny v nádrži, [°C]; t_{inp} je teplota kvapaliny na vstupe do výmenníka tepla, [°C]; t_{out} je teplota na výstupe z výmenníka tepla, [°C]; t_{HCH} je teplota výmenníka tepla, [°C]; t_{amb} je teplota okolitého prostredia, [°C]; RH je relatívna vlhkosť vzduchu, [%]; U je elektrické napätie, [V]; I je elektrický prúd, [A]; p_{sys} je tlak kvapaliny v systéme, [kPa]; Q je prietok kvapaliny, [L.hod⁻¹]; T je prevádzkový čas, [min].

3.1.1 Metodológia experimentu


Podrobný popis experimentu, architektúry navrhnutého modelu, jeho tréningu a validácie boli publikované v rámci samostatného vedeckého článku.^[5] Preto v danej kapitole bude uvedený len súhrn postupnosti realizácie daného výskumu:

- 1 Pomocou testovacieho zariadenia boli zozbierané dva datasety pre tréning a testovanie doprednej neurónovej siete (FFNN). Datasety boli predspracované za účelom filtrácie chybných hodnôt a do datasetu boli pridané časové značky.
- 2 Model FFNN bol navrhnutý, natrénovaný a otestovaný pomocou nazbieraných dát. Okrem dosiahnutia vyhovujúcich výsledkov po tréningu, model preukázal aj priaznivú schopnosť predpovedať sledovanú hodnotu t_{tank} .
- 3 Na identifikáciu vzorov a vzťahov medzi vstupnými a výstupnými premennými bola použitá metóda korelačných povrchov.
- 4 Pre vybrané závislosti boli vytvorené a nasledovné vyhodnotené grafy korelačných povrchov. Sledovaný parameter t_{tank} predstavuje os Z, osi X a Y predstavujú parametre, ktoré sa v jednotlivých prípadoch menia.


3.1.2 Výsledky experimentu

Presnosť modelu bola overená pomocou testovacej sady údajov a numerických metrík. Koeficient korelácie dosahuje pre trenovací súbor údajov hodnotu $R = 0,9998$ a pre testovací súbor údajov hodnotu $R = 0,9987$. Stredná kvadratická chyba má pre trenovaciu sadu údajov hodnotu $RMSE = 0,0276$ a pre testovaciu sadu údajov $RMSE = 0,2448$.

Následne pomocou navrhnutej neurónovej siete bola vykonaná simulácia prevádzkového procesu ohrevu a chladenia pracovnej kvapaliny v testovacom zariadení. Na základe dosiahnutých výsledkov boli zostavené grafy závislosti pre vybrané skúmané závislosti (Obr. 2 a Obr. 3). Vizualizácia jednotlivých závislostí slúži na pochopenie vplyvu vstupných premenných na skúmaný parameter a na dodatočné overenie schopnosti navrhnutého modelu neurónovej siete aproximovať zadanú funkciu. Opodstatnenie voľby konkrétnych závislostí je súčasťou predchádzajúceho výskumu.



Obr. 2 Príklady závislosti a) medzi teplotou kvapaliny v nádrži, prevádzkovým časom a prietokom kvapaliny; b) medzi teplotou kvapaliny v nádrži vstupnou a výstupnou teplotou



Obr. 3 Príklady závislosti a) medzi teplotou kvapaliny v nádrži, teplotou okolitého prostredia a teplotou výmenníka tepla; b) medzi teplotou kvapaliny v nádrži, teplotou okolitého prostredia a elektrickým prúdom (2D pohľad)

Navrhnutý model dokáže spoľahlivo predpovedať teplotu pracovnej kvapaliny v nádrži na základe zohľadnenia faktorov, ako je prevádzkový čas, teplota kvapaliny v hydraulickom okruhu (na vstupe

aj výstupe z výmenníka tepla), teplota výmenníka tepla, prietok kvapaliny v potrubí, tlak v systéme a elektrický prúd a napätie v okruhu. Presnosť modelu bola overená pomocou testovacieho súboru údajov.

Analýza korelačných povrchov medzi prevádzkovými parametrami zariadenia prispela ku lepšiemu pochopeniu vzájomných vzťahov medzi parametrami. Na základe analýzy uvedených grafov bolo zistené, že najväčší vplyv na skúmaný parameter majú teploty kvapaliny v hydraulickom okruhu, teplota výmenníka tepla a prevádzkový čas testovacieho zariadenia. Okrem toho, bolo zistené, že pomocou aktuálnej konfigurácie zariadenia nie je možné skúmať vplyv okolitej teploty, nakoľko snímač DTH11 neposkytuje dostatočnú spoľahlivosť snímaných údajov pre stanovené experimentálne podmienky. Poznatky získané v rámci experimentu majú prínos pre oblasť deskriptívnej analýzy a prispievajú ku vývoju komplexných systémov prediktívnej údržby založených na modeloch umelých neurónových sietí.

3.2 Prediktívne riadenie a simulácia procesu pogumovania drôtu vo výrobe pätkových lán

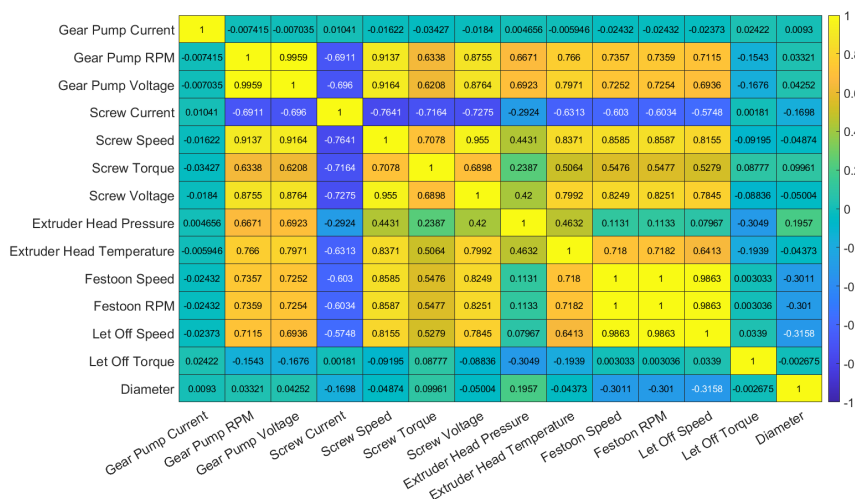
Súčasťou riešenia projektu v spolupráci s priemyselným partnerom, bolo použitie metód dátovej analytiky a umelých neurónových sietí pre simuláciu procesu pogumovania drôtu pätkových lán. Výsledkom je návrh modelu prediktívneho riadenia daného procesu a jeho následné experimentálne overenie v praxi.

3.2.1 Výber relevantných vlastností pre modely neurónových sietí

Pri vývoji neurónových sietí zohráva výber relevantných vstupných vlastností kľúčovú úlohu pre zabezpečovanie účinnosti navrhnutého modelu. Proces výberu zahŕňa štatistické aj algoritmické prístupy, vrátane metód redukcie dimenzionality, korelačnej analýzy a techník výberu relevantných prvkov. Vybrané techniky inžinierstva funkcií sa následne aplikovali na súbor údajov. Cieľom je identifikovať najviac relevantné príznaky pre následný návrh neurónovej siete pre proces prediktívneho riadenia.

3.2.1.1 Analýza korelačnej matice

Matica Pearsonových korelačných koeficientov pre monitorované parametre výrobného procesu pogumovania drôtu je uvedená na obr. 4. Hodnota blízka +1 alebo -1 naznačuje silnú koreláciu, zatiaľ čo hodnota blízka 0 naznačuje žiadnu koreláciu.



Obr. 4 Matica korelačných koeficientov medzi parametrami


Pri analýze korelačnej matice je vhodné pre následnú predikčnú úlohu voliť premenné s vysokými hodnotami absolútnej korelácie. Pretože tieto parametre majú silnejší lineárny vzťah so skúmaným parametrom Diameter, ktorý predstavuje priemer pogumovaného drôtu. Analýzou korelačnej matice boli zistené nasledujúce kľúčové závislosti:

- **Silná pozitívna korelácia:** otáčky zubového čerpadla a napätie zubového čerpadla (*Gear Pump RPM* a *Gear Pump Voltage*, $\rho=0,9959$), otáčky závitovky a napätie závitovky (*Screw Speed* a *Screw Voltage*, $\rho=0,955$), rýchlosť odvíjania drôtu a rýchlosť otáčania závitovky (*Let Off Speed* a *Screw Speed*, $\rho=0,8155$), rýchlosť závitovky a teplota v hlave vytlačacieho stroja (*Screw Speed* a *Extruder Head Temperature*, $\rho=0,8371$).
- **Silná negatívna korelácia:** elektrický prúd a rýchlosť závitovky (*Screw Current* a *Screw Speed*, $\rho=-0,7641$), elektrický prúd a krútiaci moment závitovky (*Screw Current* a *Screw Torque*, $\rho=-0,7164$).
- **Slabá korelácia:** elektrické napätie zubového čerpadla a ostatné parametre súboru dát (*Gear Pump Current*, $|\rho|_{\max}=0,0327$), krútiaci moment odvíjania drôtu a tlak v hlave vytlačacieho stroja (*Let Off Torque* a *Extruder Head Pressure*, $\rho=-0,3049$), priemer pogumovaného drôtu a rýchlosť odvíjania drôtu (*Diameter* a *Let Off Speed*, $\rho=-0,3158$).

Z hľadiska prvotného pohľadu na dáta je možné tvrdiť, že analýza korelačnej matice bola užitočná pre pochopenie všeobecnej štruktúry dát a identifikáciu potenciálne redundantných parametrov. Avšak vysoká miera lineárnej závislosti medzi dvomi parametrami neznamená vysokú mieru ich príčinnej závislosti, nakoľko môžu existovať ďalšie premenné, ktoré ovplyvňujú variabilitu skúmanej premennej vo väčšej miere. Okrem toho, z pohľadu samotného riešeného problému - predikcie priemeru pogumovaného drôtu, je možné vidieť, že miera jeho lineárnej závislosti s ostatnými parametrami dátového súboru je relatívne nízka, čo indikuje že nie je možné na základe vykonanej analýzy jednoznačne určiť parametre s najsilnejším vplyvom na sledovaný parameter - *Diameter*. Preto pre následné použitie v rámci návrhu algoritmu prediktívneho riadenia je potrebné použiť aj iné prístupy pre voľbu relevantných parametrov procesu.

3.2.1.2 Uplatnenie algoritmov mRMR a RReliefF

Ako ďalšia metóda pre výber optimálnych vstupných parametrov na základe ktorých by bolo možné spoľahlivo predpovedať výstupný priemer pogumovaného drôtu, bol zvolený algoritmus minimálnej redundancie a maximálnej relevantnosti (*mRMR*). Na obr. 5a sú uvedené vypočítané hodnoty kritéria *mRMR* v podobe stĺpcového grafu.




Obr. 5 Hodnoty kritéria dôležitosti: a) mRMR; b) RReliefF

Ďalšia z použitých metód je algoritmus *RReliefF*, ktorého výsledky sú znázornené na obr. 5b. Tento stĺpcový graf znázorňuje hodnotu dôležitosti každej vlastností datasetu vypočítanú pomocou algoritmu *RReliefF*. Os Y označuje mieru dôležitosti, kým na osi X sú uvedené jednotlivé vlastnosti, zoradené podľa klesajúcej hodnoty dôležitosti. Z analýzy grafov na Obr. 5a Obr. 5b je možné konštatovať:

- *LetOffSpeed* (rýchlosť odvíjania drôtu) má najvyššie hodnoty kritérií dôležitosti *mRMR* a *RReliefF*, čo z neho robí najrelevantnejší parameter v súbore údajov.
- Potenciálne relevantnými parametrami sú aj *ExtruderHeadPressure*, *FestoonRPM*, *ScrewVoltage* a *LetOffTorque*, hoci je vidieť výrazný pokles ich hodnôt kritérií *mRMR* a *RReliefF* v porovnaní s parametrom *LetOffSpeed*.
- Parametre *ExtruderHeadTemperature*, *FestoonSpeed*, *GearPumpRPM*, *ScrewCurrent*, *ScrewSpeed* a *ScrewTorque* pravdepodobne nemajú veľký význam pre riešenie stanovenej úlohy, nakoľko ich hodnoty kritérií dôležitosti sú výrazne nižšie.
- Parametre *GearPumpCurrent* a *GearPumpVoltage* majú nulové hodnoty kritéria *mRMR* a najnižšie hodnoty *RReliefF* zo všetkých parametrov. Dané parametre neprispievajú k významným informáciám a sú pre analýzu nadbytočné alebo irelevantné.

3.2.1.3 Uplatnenie analýzy hlavných komponentov

Analýza hlavných komponentov je metóda redukcie dimenzionality, ktorá sa často používa na zníženie počtu premenných veľkých súborov údajov so zachovaním dôležitých informácií z pôvodných. Na obr. 6a je uvedený Pareto diagram, ktorý znázorňuje prvých 7 vypočítaných hlavných komponentov, ktoré vysvetľujú približne 95 % variability pôvodného dátového súboru. Okrem toho, pri premietaní všetkých premenných pôvodného datasetu do súradnicového priestoru, vytvoreného na základe prvých dvoch komponentov PC1 a PC2 (Obr. 6b), je možné pozorovať aj vzájomnú koreláciu medzi parametrami.



Obr. 6 Výsledky uplatnenia analýzy hlavných komponentov: a) Pareto diagram hlavných komponentov; b) Reprezentácia parametrov procesu pogumovania drôtu v priestore PC1 a PC2

Jednotlivé parametre datasetu sú na grafe (Obr. 6b) reprezentované vo forme vektorov, pričom ich smer a dĺžka vyjadruje mieru korelácie s prvým a druhým hlavným komponentom (PC1 a PC2). Červené body na grafe predstavujú jednotlivé hodnoty datasetu, premietnuté do priestoru

definovaného hlavnými komponentami PC1 a PC2. Pri analýze uvedeného grafu a grafickej reprezentácii je možné vidieť nasledujúce:


- Prvý hlavný komponent (PC1) zachytáva najväčší rozptyl a je ovplyvnený viacerými parametrami výrobného procesu.
- Druhý hlavný komponent (PC2) zachytáva primárne variabilitu priemeru pogumovaného drôtu (parameter *Diameter*) a tlaku v hlave vytlačacieho stroja (parameter *Extruder Head Pressure*).
- Medzi niektorými skupinami parametrov (ako napríklad *Festoon Speed* a *Festoon RPM*, *Gear Pump Voltage* a *Gear Pump RPM*, *Screw Voltage*, *Screw Speed* a *Screw Torque*) je možné pozorovať vysokú pozitívnu koreláciu. To naznačuje, že použitie každého parametra z každej skupiny pre návrh a tréning modelu neurónovej siete pre prediktívne riadenie je nadbytočné.

3.2.2 Návrh neurónovej siete pre prediktívne riadenie procesu pogumovania drôtu

Z hľadiska prediktívneho riadenia procesu pogumovania drôtu je dôležité správne zadať parametre, ktoré budú kľúčové pre tréning modelu neurónovej siete. Úlohou neurónovej siete je na základe požadovaného priemeru drôtu po pogumovaní, nastaviť optimálne parametre technologického procesu pre dosiahnutie požadovaného výsledku.

Na základe výsledkov, ktoré boli dosiahnuté pomocou použitia uvedených prístupov dátovej analytiky, ako aj s ohľadom na možnosť riadenia určitých parametrov na reálnom výrobnom zariadení, bolo rozhodnuté o použití parametrov *Let Off Speed*, *Extruder Head Pressure* a *Diameter* ako vstupných premenných pre návrh a tréning neurónovej siete (Obr. 7). Za cieľový parameter, teda parameter, ktorý bude riadený pomocou neurónovej siete bola zvolená rýchlosť zubového čerpadla *Gear Pump RPM*.

Pomocou nástroja *Regression Learner App* bolo navrhnutých niekoľko modelov dopredných neurónových sietí rozličných architektúr. Navrhnuté modely sa líšili počtom a veľkosťou skrytých vrstiev. Následné všetky modely boli natrénované a vyhodnotené s cieľom určiť najefektívnejší model. Výsledky vyhodnotenia presnosti modelov sú uvedené nižšie.




Obr. 7 Všeobecná štruktúra modelu prediktívneho riadenia

Vyhodnotenie presnosti modelov


P.č.	Validácia			Test		
	RMSE	MSE	R ²	RMSE	MSE	R ²
1	0,1644	0,0270	0,9523	0,1569	0,0246	0,9564
2	0,1581	0,0250	0,9560	0,1721	0,0296	0,9475
3	0,1670	0,0279	0,9508	0,1541	0,0238	0,9579
4	0,1760	0,0310	0,9454	0,2403	0,0577	0,8977
5	0,1729	0,0299	0,9473	0,1662	0,0276	0,9511

Model č. 3 preukázal najväčšiu robustnosť na základe analýzy všetkých troch vypočítaných metrík, preto bolo rozhodnuté o jeho použití pre simuláciu procesu pogumovania drôtu. Na základe simulácie boli získané trojrozmerné grafy povrchov, ktoré poskytujú prehľad o vzájomnej interakcii najdôležitejších parametrov procesu pogumovania drôtu pre zadanú receptúru gumovej zmesi.

Z analýzy grafov na obr. 8 je možné zistiť, že pre udržiavanie priemeru pogumovaného drôtu na hodnote 1,83 mm, pri zmene hodnoty tlaku v hlave vytlačacieho stroja v rozsahu od 83 do 251 bar, by mala byť rýchlosť zubového čerpadla udržiavaná v rozsahu od 2,64 do 4,46 ot.min⁻¹. Zároveň je vidieť trend zvyšovania rýchlosti zubového čerpadla pri zvyšovaní tlaku v hlave vytlačacieho stroja.



Obr. 8 Závislosť rýchlosti zubového čerpadla od priemeru pogumovaného drôtu a tlaku v hlave vytlačacieho stroja a) trojrozmerná reprezentácia; b) dvojrozmerná reprezentácia



Obr. 9 Závislosť rýchlosti zubového čerpadla od priemeru pogumovaného drôtu a rýchlosti odvíjania drôtu a) trojrozmerná reprezentácia; b) dvojrozmerná reprezentácia

Analýza závislostí rýchlosti zubového čerpadla od rýchlosti odvíjania drôtu (Obr. 9) poukazuje, že pre udržiavanie priemeru pogumovaného drôtu na hodnote 1,83 mm, hodnoty rýchlosti odvíjania drôtu by sa mali meniť v rozsahu od 20 do 155 m.min⁻¹. Pritom by mala hodnota rýchlostí zubového čerpadla meniť v rozsahu od 1,83 ot.min⁻¹ do 4,18 ot.min⁻¹.


Výsledky daného experimentu je možné použiť pri návrhu optimálnych technologických parametrov procesu pogumovania drôtu. Avšak je dôležité získané hodnoty riadiacich parametrov výrobného zariadenia overiť v reálnych podmienkach. Zároveň je dôležité v rámci reálneho výrobného procesu preveriť potenciálnu existenciu aj iných parametrov, ktoré môžu mať vplyv na výsledný priemer pogumovaného drôtu, ale neboli súčasťou poskytnutého súboru dát.

3.3 Klasifikácia pohybov priemyselných robotov na základe monitoringu vibrácií

Cieľom daného experimentu je overenie schopnosti LSTM-neurónovej siete identifikovať a klasifikovať zmenu pohybových parametrov (rýchlostí) koncového efektora priemyselného robota Fanuc LR Mate 200iC, ktorý je k dispozícii v laboratóriu Katedry automatizácie a výrobných systémov.


3.3.1 Zber a spracovanie experimentálnych dát

Snímanie vibrácií bolo vykonané pomocou 3-osového akcelerometra ADXL345, ktorý bol upevnený na koncovom efektore robota (Obr. 10a). Zber dát prebiehal počas lineárneho pohybu efektora medzi bodmi A a B (Obr. 10b) pri štyroch hodnotách rýchlosti: 100 %, 75 %, 50 % a 25 % z maximálnej lineárnej rýchlosti 4000 mm.s⁻¹ a bolo vykonaných 60 opakovaní.



Obr. 10 a) Umiestnenie akcelerometra ADXL345; b) Umiestnenie meracej dráhy v pracovnom priestore robota

Nazbierané dáta v rámci experimentu boli vo forme časových radov (z angl. *time-series data*). Pred použitím dát na tréning a testovanie neurónovej siete, bolo potrebné dáta spracovať s cieľom zlepšenia ich kvality a prevedenia do formátu, vhodného pre spracovanie navrhnutou neurónovou sieťou.



Obr. 11 Ukážka dát z akcelerometra: a) pred predspracovaním; b) po predspracovaní


V rámci predspracovania bol z dát (Obr. 11a) odstránený šum a odchýlky. Na obr. 11b je ukážka spracovaných dát. Zároveň boli údaje rozdelené na sekvencie, pričom každá sekvencia zodpovedá jednému pracovnému cyklu robota, teda pohybu efektora z bodu A do bodu B a späť. Každá zo sekvencií bola priradená do jednej zo štyroch tried na základe rýchlosti pohybu. Teda boli vytvorené štyri triedy pre štyri rýchlosti pohybu (100 %, 75 %, 50 % a 25 %).

3.3.2 Návrh, tréning a testovanie neurónovej siete

Úlohou neurónovej siete je priradiť sekvenciu dát získanú pri jednom pracovnom cykle robota, k jednej zo štyroch tried. Každá trieda predstavuje jednu zo štyroch možných rýchlostí pohybu efektora robota. Pre splnenie tejto úlohy bolo rozhodnuté o použití LSTM neurónovej siete.

Navrhnutý model neurónovej siete (Obr. 12a) pozostáva zo sekvenčnej vstupnej vrstvy vo veľkosti $3 \times N$. Kde 3 je počet osí, v ktorých bol vykonaný záznam vibračného signálu a N je počet záznamov v rámci jedného pracovného cyklu robota. Za vstupnou vrstvou nasleduje skrytá vrstva *BiLSTM*, ktorá obsahuje 400 pamäťových buniek.

Pre overenie schopnosti navrhnutého modelu generalizovať poznatky o vstupných údajoch a klasifikovať namerané vibračné signatúry, bol model otestovaný na nových údajoch, ktoré neboli súčasťou tréningového súboru. Pre vyhodnotenie presnosti klasifikátora bola zostavená chybová matica (z angl. *confusion matrix*), zobrazená na obr. 12b.



Obr. 12 a) Architektúra navrhnuitej LSTM neurónovej siete; b) Chybová matica

Výsledná presnosť použitého modelu je 98,61 %, čo naznačuje, že s pravdepodobnosťou takmer 99 % bude vstupná vibračná sekvencia zaradená do správnej triedy. Výsledok naznačuje perspektívu využitia tohto modelu na úlohy technickej diagnostiky a prediktívnej údržby, ako pre detekciu a klasifikáciu anomálnych stavov skúmaného zariadenia. Vzhľadom na úspešnosť neurónovej siete LSTM pri spracovaní a klasifikácii vibračných signálov, je plánovaný nasledujúci výskum zamerať na ďalšiu optimalizáciu modelu a jeho aplikáciu v reálnom priemyselnom prostredí.

4 Využitie metód dátovej analytiky a neurónových sietí pre detekciu porúch priemyselných robotov

Jednou z kľúčových úloh, ktoré je potrebné vyriešiť pred nasadením umelých neurónových sietí pre riešenie zadaného problému v reálnych priemyselných podmienkach je predspracovanie a voľba správnych charakteristík vibračného signálu. Ide o úlohy, ktoré sú nevyhnutné pre zaručenie spoľahlivosti a robustnosti navrhnutého modelu. Zároveň voľba optimálnych sledovaných metrík znižuje výpočtovú náročnosť, čo je obzvlášť dôležité pri prirodzene komplexnej povahe operácií, vykonávaných v nestabilných podmienkach, ako sú zmeny zaťaženia, zmeny prevádzkových otáčok a rýchlostí. Zároveň je evidentné, že počet štúdií zameraných na vibrodiagnostiku strojov so sekvenčným pohybom, vrátane priemyselných robotov, je podstatne menej ako tých, ktoré sa zaoberajú vibrodiagnostikou točivých strojov.

Cieľom experimentu je overenie možnosti detekcie uvoľnenia upnutia základne robota počas realizácii pracovného cyklu na základe vybraných metrík vibračného signálu a neurónových sietí so zadanou presnosťou. Pod uvoľnením základne robota je chápané náhle oslabenie jeho uchytenia počas prevádzky v dôsledku pôsobenia síl a zaťažení. Experiment bol navrhnutý pre overenie primárnej hypotézy dizertačnej práce. V rámci overenia hypotézy bude riešená úloha klasifikácie jednotlivých sekvencií dát, z ktorých každá predstavuje jeden pracovný cyklus robota.

4.1 Metodológia a postup experimentu

Pre plnenie hlavného cieľa dizertačnej práce, bolo rozhodnuté o rozšírení experimentu, ktorý bol navrhnutý a realizovaný v rámci predchádzajúceho výskumu [4]. Boli doplnené ďalšie vlastností vibračného signálu s cieľom rozšíriť možnosti implementácie získaných poznatkov pri detekcii porúch priemyselných robotov na základe vibračného signálu. Vo všeobecnosti je postup experimentu nasledovný:


- **Zber experimentálnych dát** - dáta predstavujú *peak-to-peak* hodnoty rýchlostí vibrácií, zaznamenané v troch osiach pomocou troch snímačov Baluff BCM0002, ktoré boli umiestnené na upínacej platni robota. Nazbierané dáta obsahujú hodnoty, ktoré sú charakterné

pre bezporuchový pracovný cyklus robota a hodnoty, zodpovedajúce anomálnemu stavu. Anomálny stav bol simulovaný pomocou manuálneho uvoľnenia skrutiek M8×20, ktoré slúžia na upevnenie robota a upínacej platne k doske stola.

- **Predspracovanie dát** - dáta boli rozdelené na údaje o normálnej prevádzke a údaje zodpovedajúce anomálnemu stavu. Tieto údaje boli následne spracované do sekvencií, z ktorých každá zodpovedá jednému pracovnému cyklu robota. Jeden pracovný cyklus robota a teda aj jedna sekvencia trvá 17,93s a je reprezentovaná 52 záznamami zo snímača BCM0002.
- **Označovanie dát** - jednotlivé sekvencie boli priradené do tried s názvom „Normal“ a „Anomaly“, pre normálnu prevádzku robota a stav kedy boli uvoľnené skrutky.
- **Extrakcia vlastností signálu** - cieľom tohto kroku je izolácia kľúčových vzorcov signálu, pre získanie relevantných a zmysluplných atribútov, ktoré by následne umožnili jednoznačnú identifikáciu anomálnych sekvencií. Okrem štatistických vlastností signálu, ktoré boli použité v rámci publikovaného článku ^[4], bol experiment doplnený aj o vlastností signálu z frekvenčnej oblasti.
- **Inžinierstvo funkcií** - tento krok zahŕňa aplikáciu vybraných metód dátovej analytiky s cieľom redukcie dimenzionality dátového súboru a identifikáciu najrelevantnejších príznakov signálu, ktoré majú potenciál zabezpečiť vysokú presnosť klasifikačného modelu. Na základe predchádzajúcich výsledkov a empirických poznatkov bola pre uvedený účel zvolená kombinácia metódy T-testu a korelačnej analýzy.
- **Návrh, tréning a testovanie modelu neurónovej siete** pre riešenie zadanej klasifikačnej úlohy.
- **Zhodnotenie výsledkov experimentu** - potvrdenie alebo vyvrátenia stanovenej hypotézy.

4.2 Zber experimentálnych dát

Zber experimentálnych dát bol vykonaný na pracovisku automatizovanej montáže, ktoré sa nachádza na Katedre automatizácie a výrobných systémov. Počas pracovného cyklu, robot odoberá vopred zmontovaný výrobok z montážnej stanice (Obr. 13, body P2 a P3), premiestňuje ich do skrutkovacieho prípravku, kde sa vykonáva jeho skrutkovanie (Obr. 13, body P4, P5) a nakoniec ukladá výrobok do skladovacieho regálu (Obr. 13, body P6, P7, P8). Manipulačné operácie sú na danom pracovisku vykonávané priemyselným robotom Fanuc LR Mate 200iC.



Obr. 13 Trajektória pohybu koncového efektora robota počas pracovného cyklu

Súbor dát obsahuje 1500 vzoriek sekvencií, sumárne pre 9 osí v ktorých sa vykonával zber dát (tri osi pre jeden snímač). Pričom 990 vzoriek zodpovedá normálnemu stavu skúmaného zariadenia (trieda *Normal*) a 510 vzoriek reprezentuje prevádzku robota pri uvoľnených skrutkách jeho upnutia (trieda *Anomaly*). V rámci predchádzajúceho výskumu^[4] bolo zistené, že z hľadiska zníženia výpočtovej

a analytickej náročnosti je možné pre analýzu dát a tiež návrh modelu umelej neurónovej siete použiť iba údaje z jedného zo snímačov, umiestneného v zadnej časti upínacej platne robota.

4.3 Extrakcia vlastností vibračného signálu

Na extrakciu vlastností signálu bol použitý nástroj *Diagnostic Feature Designer* v programovacom prostredí MATLAB. Pomocou tohto nástroja je možné z extrahovaných vlastností signálu separovať najrelevantnejšie príznaky na určenie, ktoré vlastnosti signálu sú najúčinnnejšie.

Okrem štatistických vlastností vibračného signálu boli v rámci experimentu preskúmané aj jeho charakteristiky vo frekvenčnej oblasti. Tento prístup bol motivovaný predpokladom, že prítomnosť anomálie sa prejaví zmenami v jeho spektrálnych vlastnostiach. Medzi získané vlastnosti vibračného signálu patria:


- Amplitúda signálu (*Peak Amplitude*);
- Frekvencia signálu (*Peak Ferequency*);
- Výkon pásma signálu (*Band Power*);
- Priemerná hodnota (*Mean*);
- Stredná kvadratická hodnota (*RMS*);
- Smerodajná odchýlka (*Std*);
- Špičková hodnota (*Peak Value*);
- Faktor vôle (*Clearance factor*);
- Impulzný faktor (*Impulse factor*).

4.4 Voľba relevantných vlastností signálu pomocou metód inžinierstva funkcií

Podstatou inžinierstva funkcii je vyber len tých vlastností, ktoré majú významný vplyv na výstup modelu. Okrem zvýšenia výpočtovej náročnosti, môže prípadné použitie všetkých dostupných vlastností viesť k nadmernému prispôsobeniu modelu (z angl. *overfitting*). Komplexné posúdenie a výber relevantných parametrov bol zrealizovaný na základe aplikácii štatistických metód T-Test a analýzy korelácii.

4.4.1 Aplikácia metódy T-Test pre výber relevantných vlastností signálu

T-Test je metóda, ktorá sa vo všeobecnosti používa pre vyhodnotenie rozdielu v priemeroch dvoch skúmaných skupín. Pritom sa predpokladá, že rozdelenie skúmaného parametra je normálne. Pri aplikácii tejto metódy sa pre každý pár – hodnoty konkrétneho parametra pre každú príslušnú triedu, vypočíta hodnota T_{score} . Vysoká hodnota T_{score} pre daný parameter naznačuje jeho potenciál pre využitie pri trénovaní neurónovej siete.



Obr. 14 Hodnoty T_{score} pre skúmané vlastnosti signálu v jednotlivých osiach

Na obr. 14 sú zobrazené všetky vypočítané hodnoty T_{score} pre každú vlastnosť signálu v jednotlivých osiach, pričom vlastností sú zoradené podľa klesajúcej dôležitosti. Následné kľúčovú úlohu pri použití T-testu zohrávajú nulová a alternatívna hypotézy, ktoré slúžia na posúdenie štatistickej

významnosti vzťahu medzi jednotlivými parametrami a cieľovou premennou. Nulová hypotéza predpokladá, že neexistuje významný rozdiel v priemerných hodnotách skúmanej vlastnosti medzi triedami cieľovej premennej. V tomto prípade znie nulová hypotéza (**H0**) následne:

H0: v prípade hodnôt analyzovanej vlastnosti nebol medzi anomálnymi a normálnymi údajmi identifikovaný štatisticky významný rozdiel.

Alternatívna hypotéza predpokladá, že štatisticky významný rozdiel v priemerných hodnotách skúmanej vlastnosti signálu existuje. Tým daná vlastnosť predstavuje potenciálne použitie pre tréning neurónovej siete. Alternatívna hypotéza (**H1**) je stanovená nasledovne:

H1: pre skúmanú vlastnosť existuje štatisticky významný rozdiel medzi anomálnymi a normálnymi údajmi.

Hodnota p-value je štatistickým ukazovateľom, ktorý určuje šancu pravdepodobnosťou sa pozorovaný výsledok vyskytol náhodne. Nižšia hodnota p-value znamená vyššiu pravdepodobnosť zamietnutia nulovej hypotézy **H0** a tým podporovania alternatívnej hypotézy **H1**.

Proces postupného posudzovania nulovej a alternatívnej hypotéz pre každú z vlastností signálu umožňuje vybrať tie vlastnosti, ktoré majú štatisticky významný vzťah s cieľovou premennou. V tab. 1 sú uvedené jednotlivé vlastnosti signálu spolu s informáciou o prijatí nulovej alebo alternatívnej hypotézy za predpokladu, že počet stupňov voľnosti zodpovedá hodnote $d_f=1498$ a hodnota hladiny významnosti testu $\alpha=0,05$.

Tab. 1 Prijatie alternatívnej alebo nulovej hypotézy pre špecifikované parametre signálu na základe T-testu

Parameter	Os X	Os Y	Os Z
Mean	H1	H1	H1
RMS	H1	H1	H1
Std	H1	H1	H1
Peak Value	H1	H1	H1
Clearance Factor	H1	H1	H0
Impulse Factor	H1	H1	H0
Peak Amplitude	H1	H1	H1
Peak Frequency	H0	H1	H1
Band Power	H1	H1	H1

Parametre, pre ktoré bola prijatá alternatívna hypotéza (H1), sú označené zelenou farbou. Parametre, pre ktoré bola prijatá nulová hypotéza (H0), sú označené červenou farbou.


Na základe analýzy stĺpcových grafov (Obr. 14) a výsledkov štatistického testu (Tab. 1) je možné konštatovať, že frekvencia signálu (*Peak Frequency*), impulzný faktor (*Impulse Factor*) a faktor vôle (*Clearance Factor*) sú vlastnosťami signálu, ktoré pravdepodobne nemajú významnú rozlišovaciu schopnosť pre stanovený klasifikačný problém:

- Frekvencia signálu (*Peak Frequency*) vykazuje najnižšie hodnoty T_{score} v osiach X a Y, ktoré zároveň vykazovali najvýraznejšie prejavy anomálneho správania robota. Okrem toho, na základe posudzovania hodnoty p-value bola pre tento parameter akceptovaná nulová hypotéza, čo potvrdzuje jeho štatistickú bezvýznamnosť v rozlišovaní medzi anomálnou a normálnou triedou.
- Impulzný faktor (*Impulse Factor*) dosahuje najnižšie hodnoty T_{score} v osi Z a v osi X vykazuje vyššiu rozlišovaciu schopnosť len v porovnaní s frekvenciou signálu (*Peak Frequency*). Hoci v osi Y tento príznak dosahuje relatívne lepšie výsledky, na základe hodnoty p-value bola aj v tomto prípade akceptovaná nulová hypotéza, čo poukazuje na štatistickú bezvýznamnosť daného parametra.

- Faktor vôle (*Clearance Factor*) vykazuje v osi X lepšie výsledky v porovnaní s impulzným faktorom (*Impulse Factor*) a frekvenciou signálu (*Peak Frequency*). Na základe komplexného vyhodnotenia tejto metriky naprieč všetkými osami a s ohľadom na akceptovanie nulovej hypotézy je možné konštatovať, že prínos uvedenej vlastnosti pre klasifikačnú úlohu z hľadiska rozlišovacej schopnosti je obmedzený.

4.4.2 Výber relevantných vlastností signálu na základe korelačnej analýzy

V prípade diskretnej cieľovej premennej je možné vypočítať Pearsonov korelačný koeficient medzi jednotlivými vlastnosťami a binárne zakódovanou cieľovou premennou (v prípade riešeného problému 0 – *Normal*, 1 – *Anomaly*). Účelom analýzy je identifikácia sily lineárnych vzťahov medzi charakteristikami signálu a triednou príslušnosťou skúmanej vzorky.



Obr. 15 Hodnoty korelačného koeficientu medzi vlastnosťami signálu a triedou cieľovej premennej

Na obr. 15 je uvedená grafická reprezentácia hodnôt Pearsonového korelačného koeficientu pre jednotlivé vlastností signálu v podobe stĺpcových grafov pre každú os, v ktorej bol vykonaný zber dát. Vo všeobecnosti možno konštatovať, že väčšina analyzovaných parametrov vykazuje stredne silnú až silnú mieru korelácie s diskretnou cieľovou premennou v osiach X a Y, pričom absolútne hodnoty Pearsonovho korelačného koeficienta sa pohybujú v intervale od 0,5 do 0,79.

Na základe komplexnej analýzy dostupného dátového súboru a odvodených signálnych parametrov možno konštatovať, že len tri vlastnosti vykazujú dostatočne vysokú mieru korelácie s cieľovou premennou vo všetkých troch osiach. Konkrétne ide o strednú hodnotu (*Mean*), amplitúdu (*Peak Amplitude*) a výkon pásma (*Band Power*). Okrem toho boli identifikované ďalšie tri príznaky – maximálna hodnota (*Peak Value*), stredná kvadratická hodnota (*RMS*) a smerodajná odchýlka (*Std*) – ktoré spĺňajú kritérium v osiach X a Y, teda v tých, kde sa prejavy anomálií vyskytovali najintenzívnejšie. Tieto parametre preto predstavujú relevantných kandidátov pre následné využitie v klasifikačných modeloch.

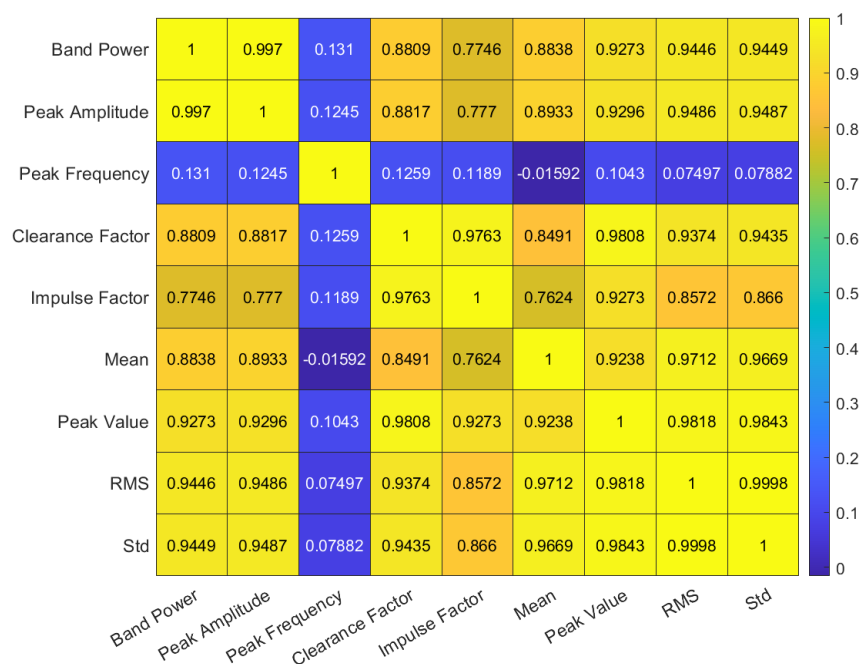
4.4.3 Konečný výber vlastností signálu na základe analytických výsledkov

Z hľadiska štatistickej významnosti, boli do ďalšej analýzy zahrnuté parametre s piatimi najvyššími hodnotami T_{score} v každej z analyzovaných osí. Týmito parametrami sú priemerná hodnota (*Mean*), stredná kvadratická hodnota (*RMS*), smerodajná odchýlka (*Std*), amplitúda signálu (*Peak Amplitude*) a špičková hodnota (*Peak Value*).

Z hľadiska analýzy lineárnej korelácie vlastnosti signálu s diskretnou cieľovou premennou, je možné parametre *Mean*, *Peak Amplitude* a *Band Power* identifikovať ako najkonzistentnejšie a najrelevantnejšie. Parametre *RMS*, *Std* a *Peak Value* taktiež vykazujú vysoký stupeň korelácie,

predovšetkým v osiach X a Y, kde sú anomálne prejavy najvýraznejšie, a preto môžu byť považované za perspektívne prediktory v kontexte daného klasifikačného problému.

Pre zabezpečenie efektívneho učenia modelu neurónovej siete nie je postačujúci len výber najinformatívnejších príznakov vzhľadom na cieľovú premennú. Rovnako dôležité je zohľadniť aj ich vzájomný vzťah. Za účelom vyhodnotenia vzájomných vzťahov medzi potenciálnymi prediktormi bola použitá korelačná matica (Obr. 16). Tá kvantifikuje výlučne lineárne závislosti medzi jednotlivými vlastnosťami monitorovaného vibračného signálu, nezávisle od cieľovej premennej.



Obr. 16 Matica korelačných koeficientov medzi prediktormi

Cieľom tohto kroku je identifikovať príznaky s vysokou mierou informatívnosti a zároveň eliminovať redundantné premenné. Výsledkom by mal byť predpoklad pre efektívnu redukciu dimenzionality a optimalizácia priestoru vstupných premenných pre následný návrh modelu neurónovej siete.

Vo všeobecnosti sa väčšina analyzovaných vlastností signálu vyznačuje vysokým stupňom vzájomnej lineárnej korelácie, s výnimkou parametra *Peak Frequency*, ktorý nevykazuje výraznejšie korelačné väzby s ostatnými premennými. Na základe predchádzajúcich analytických postupov boli ako najrelevantnejšie potenciálne prediktory identifikované parametre *Mean*, *RMS*, *Std*, *Band Power*, *Peak Amplitude* a *Peak Value*. Avšak matica korelačných koeficientov (Obr. 16) poukazuje na existenciu takmer perfektnej korelácie medzi niektorými z nich, ako napríklad *Band Power* a *Peak Amplitude* ($\rho=0,9970$), *Std* a *Peak Value* ($\rho=0,9843$), *RMS* a *Std* ($\rho=0,9998$).

Z tohto dôvodu je z pohľadu optimalizácie výberu príznakov pre následný tréning neurónovej siete vhodné preferovať také vlastnosti, ktoré sa medzi sebou vyznačujú čo najnižšou mierou korelácií. Preto na základe výsledkov štatistickej analýzy a vyhodnotenia vzájomných korelácií medzi jednotlivými vlastnosťami signálu boli za finálne prediktory zvolené parametre *Peak Value*, *Band Power* a *Mean*.

Výber týchto príznakov je odôvodnený ich vysokou informatívnou hodnotou z hľadiska korelácie s cieľovou premennou, ako aj ich štatistickou významnosťou vo vzťahu k diskriminačnej schopnosti. Zároveň sa tieto parametre vyznačujú najnižšou mierou vzájomnej lineárnej závislosti, čím


sa minimalizuje riziko redundancie v tréningových dátach a podporuje sa efektívnosť učenia klasifikačného modelu.

4.5 Implementácia umelej neurónovej siete pre detekciu porúch priemyselných robotov

Na dosiahnutie stanoveného cieľa experimentu je potrebné navrhnuť, natréňovať a otestovať model neurónovej siete, ktorý by bol schopný klasifikovať analyzovanú vzorku vibračného signálu do príslušnej triedy. Správna klasifikácia vzorky umožní identifikovať, či počas sledovaného pracovného cyklu došlo k uvoľneniu robota, a to na základe analýzy vibračného signálu, reflektujúceho vplyv pôsobiacich síl a zaťaženia na jeho konštrukciu.

4.5.1 Návrh a tréningu neurónovej siete

Navrhnutý model neurónovej siete predstavuje doprednú neurónovú sieť (*feed-forward network*). Vstupná vrstva obsahuje deväť neurónov, z ktorých každý zodpovedá hodnote jednotlivého parametra signálu v osi X, Y a Z. Štruktúra navrhnutého modelu je uvedená na obr. 17.



Obr. 17 Štruktúra navrhnutého klasifikačného modelu

Pre tréning navrhnutého modelu sa použila metóda učenia s učiteľom (*supervised learning*), ktorá vyžaduje použitie označeného súboru údajov pre účely tréningu a validácie modelu. Počas tréningového procesu sa každý z navrhnutých modelov snažil na základe vstupných príznakov a známej hodnoty cieľovej premennej (trieda *Normal* alebo *Anomaly*) identifikovať vnútorné vzory typické pre konkrétnu triedu.

4.5.2 Testovanie modelu a vyhodnotenie presnosti

Výsledky testovania poskytujú relevantné informácie o generalizačnej schopnosti neurónovej siete - o jej schopnosti správne klasifikovať nové vzorky, a tým spoľahlivo riešiť zadanú klasifikačnú úlohu. Pre detailnejšie vyhodnotenie presností bola použitá chybová matica. Pre komplexné zhodnotenie výkonnosti modelu sa okrem presnosti (*Accuracy*) bežne používajú aj ďalšie metriky, ako sú presnosť (*Precision*), úplnosť (*Recall*), špecifickosť (*Specificity*) a F1 skóre (*F1 score*). Tieto metriky sú obzvlášť dôležité v prípadoch, kde je potrebné zohľadniť rozdielnú závažnosť falošne pozitívnych a falošne negatívnych predikcií, ktoré môžu mať v praktickej aplikácii rozdielny dopad. Chybová matica a vypočítané metriky presnosti sú uvedené v tab. 2.

Tab. 2 Tabuľka vypočítaných výkonnostných metrík

Počet vzoriek v chybovú maticu				Metrika výkonnosti				
TP	TN	FP	FN	Accuracy	Precision	Recall	Specificity	F1 score
290	148	2	4	98,65%	99,32%	98,64%	98,67%	99,98%

- **Presnosť modelu** (*Accuracy*) vyjadruje celkový pomer správne predpovedaných prípadov k celkovému počtu prípadov. Táto metrika sa často používa ako prvý pohľad na výkonnosť modelu, avšak nemusí byť univerzálna, obzvlášť pri nevyvážených dátových súboroch.
- **Presnosť pozitívnych predikcií modelu**, nazývaná precíznosť (*Precision*) poskytuje informáciu o miere chybovosti pri predikcii pozitívnej triedy a je obzvlášť dôležitá v aplikáciách, kde sú falošne pozitívne výsledky nežiadúce. Vysoká hodnota presnosti svedčí o schopnosti modelu minimalizovať počet nesprávne klasifikovaných negatívnych prípadov ako pozitívnych. Uvedená metrika sa používa na overenie hypotézy dizertačnej práce.
- **Úplnosť** (*Recall*) vyjadruje podiel správne identifikovaných vzoriek, ktoré patria do triedy *Normal* (290 vzoriek) k celkovému počtu predpovede danej triedy (294 vzorky). Daná metrika poskytuje informáciu o výkonnosti modelu pri detekcii relevantných pozitívnych výsledkov.
- **Špecifickosť** (*Specificity*) vyjadruje podiel správne klasifikovaných anomálií (148 vzoriek) zo všetkých prípadov, ktoré skutočne patria do triedy *Anomaly* (150 vzoriek).
- **F1 skóre** (*F1 score*) je harmonickým priemerom presností pozitívnych predikcií modelu a jeho úplnosti. F1 skóre je dôležitý pri vyhodnotení nevyvážených súborov dát.

V rámci navrhnutého experimentu bol vyvinutý model umelej neurónovej siete určený na riešenie klasifikačnej úlohy spočívajúcej v zaradovaní vzoriek vibračného signálu do dvoch tried, reprezentujúcich normálny a anomálny stav prevádzky robota počas pracovnej operácie. Klasifikácia bola realizovaná na základe vopred zvolených metód dátovej analytiky charakteristík vibračného signálu. Na základe vyhodnotených metrík výkonnosti modelu je možné konštatovať, že navrhnutý klasifikačný model neurónovej siete dosahuje presnosť klasifikácii 99,32 %, a tým umožňuje efektívnu detekciu anomálií počas prevádzky sledovaného zariadenia.

Na základe dosiahnutých výsledkov uvedených v experimentálnej časti dizertačnej práce je stanovená hypotéza potvrdená.

5 Prínosy dizertačnej práce

Dizertačná práca je venovaná využitiu metód dátovej analytiky a umelých neurónových sietí v priemyselných aplikáciách. Na overenie stanovenej hypotézy boli využité poznatky, získané pri riešení čiastkových úloh. Tieto poznatky boli využité pre získanie relevantných vlastností vibračného signálu. Získané vlastnosti by mali umožňovať jednoznačné určenie poruchového stavu priemyselného robota počas vykonávania pracovnej operácie.

V rámci dizertačnej práce sú prezentované poznatky v súvislosti s dátovou analytikou, inžinierstvom funkcií a umelými neurónovými sieťami. Tieto poznatky boli nadobudnuté počas riešenia úloh na Katedre automatizácie a výrobných systémov v rámci doktorandského štúdia, výskumnými pobytnými, školeniami a v neposlednom rade riešením vedecko-výskumných projektov pre priemysel.

5.1 Prínosy pre vedu

Experiment navrhnutý v rámci dizertačnej práce rozširuje doterajšie poznatky v oblasti technickej diagnostiky strojov so sekvenčným pohybom, medzi ktoré patria aj priemyselné roboty. Získané výsledky môžu poslúžiť ako východisko pre ďalší výskum implementácie umelých neurónových sietí a dátovej analytiky v oblasti prediktívnej údržby a technickej diagnostiky. Konkrétne môže ísť o predikciu zostávajúcej životnosti zariadení, detekciu porúch v reálnom čase či plánovanie úkonov údržby s ohľadom na aktuálny technický stav analyzovaného zariadenia alebo jeho častí.

Dizertačná práca zároveň poskytuje prehľad o aplikácii prístupov umelej inteligencie v kontexte prediktívnej údržby a technickej diagnostiky, ako aj o konkrétnych modeloch neurónových sietí a typoch úloh, ktoré sú tieto modely schopné efektívne riešiť. Okrem toho, princípy dátovej analytiky, ako aj analýza trojrozmerných reprezentácií technologických procesov prispievajú k zvýšeniu interpretovateľnosti modelov umelých neurónových sietí. Súčasťou práce je aj analýza faktorov ovplyvňujúcich úspešnosť implementácie prístupov založených na strojovom učení a umelých neurónových sieťach v reálnom výrobnom prostredí.

5.2 Prínosy pre prax

V dizertačnej práci boli opísané a implementované rôzne princípy spracovania prevádzkových dát a prístupy dátovej analytiky určené na analýzu údajov získaných z reálnych priemyselných strojov. Tieto spracované dáta následne slúžili ako vstupy pri návrhu a testovaní rôznych architektúr umelých neurónových sietí, ktoré preukázali schopnosť efektívne riešiť definované aplikačné úlohy. Zároveň praktické ukážky aplikácie princípov založených na dátovej analýze a umelých neurónových sieťach na reálnych dátach, prispievajú k zvyšovaniu povedomia o možnostiach implementácie umelých neurónových sietí a algoritmov strojového učenia pri riešení úloh v priemyselnej praxi.

V rámci navrhnutého experimentu bola preukázaná efektívnosť vybraných metrík vibračného signálu pri detekcii uvoľnenia priemyselného robota na jeho základni. Navrhnutá metodika predstavuje významný prínos nielen z hľadiska zvyšovania bezpečnosti na robotizovanom pracovisku, ale aj v kontexte technickej diagnostiky priemyselných robotov. Včasná detekcia uvoľnenia robota, prípadne iných porúch, umožňuje efektívnu prevenciu výrobných strát a dodatočných nákladov, čím sa výrazne zvyšuje spoľahlivosť a efektivita výrobného procesu.

5.3 Prínosy pre pedagogiku

Z pedagogického hľadiska poskytuje dizertačná práca teoretický prehľad stratégií údržby vo výrobnom procese, so zameraním na prepojenie prediktívnej údržby, technickej diagnostiky a implementácie moderných prístupov založených na analýze prevádzkových dát. Súčasťou práce je aj prehľad vybraných modelov umelých neurónových sietí vrátane podrobného opisu princípov ich fungovania, čo tvorí teoretický základ pre pochopenie mechanizmov ich činnosti. Práca zároveň obsahuje popis úlohy dátovej analytiky v kontexte monitorovania technického stavu zariadení, postupy spracovania získaných údajov, ako aj výber a charakteristiku vybraných metód dátovej analýzy. V kombinácii s množstvom vytvorených skriptov v prostredí MATLAB môže byť táto práca využitá ako podporný výučbový materiál pre predmety zamerané na technickú diagnostiku, programovanie a dátovú analytiku.

Záver

Dizertačná práca sa zameriava na technickú diagnostiku a prediktívnu údržbu v súčasnom priemysle, pričom skúma, ako môžu byť metódy umelej inteligencie a strojového učenia použité na sledovanie stavu zariadení a predpovedanie porúch. Pozornosť je tiež venovaná faktorom ovplyvňujúcim integráciu prostriedkov umelej inteligencie do reálnych výrobných prostredí. Práca podrobne popisuje fungovanie umelých neurónových sietí, ktoré sú často využívané v praxi pre tieto úlohy, a venuje sa aj metódam dátovej analytiky pre priemysel. Poznatky získané z teoretickej časti slúži ako základ pre vzdelávanie a bolo aplikované na riešenie praktických úloh s cieľom overiť efektivitu vybraných metód spracovania dát a modelov neurónových sietí v priemyselnom kontexte. V rámci riešenia čiastkových úloh práce, akými sú overenie efektívnosti vybraných metód spracovania a analýzy dát a modelov umelých neurónových sietí pre riešenie úloh v priemysle, bolo vykonané niekoľko experimentov.

Cieľom prvého experimentu bolo využitie doprednej neurónovej siete na aproximáciu zložitej funkcie súvisiacej s teplotou kvapaliny a prevádzkovými parametrami testovacieho zariadenia. Táto sieť dokázala s vysokou presnosťou (99,87 %) modelovať nelineárne vzťahy, čo následne umožnilo vizualizovať procesy ohrevu a chladenia pomocou grafov korelačných povrchov. Analýza týchto vizualizácií viedla k lepšiemu pochopeniu vzájomných závislostí medzi parametrami procesu. Výsledky prispievajú k rozvoju prediktívnej údržby a deskriptívnej analýzy pomocou neurónových sietí.

V rámci ďalšieho experimentu bol riešený vývoj algoritmu na prediktívne riadenie procesu pogumovania drôtu, kľúčového pre výrobu pätkového lana. Základom je simulácia procesu pomocou umelej neurónovej siete, ktorá umožňuje optimalizovať technologické parametre. Pred tréningom siete bolo nevyhnutné znížiť redundanciu dát použitím techník ako analýza korelácií, algoritmov *mRMR*, *RReliefF* a analýzy hlavných komponent, čo viedlo k výberu optimálnych vstupných parametrov pre model neurónovej siete. Výsledný model dokáže na základe stanoveného priemeru pogumovaného drôtu a monitorovaných procesných veličín (rýchlosť odvíjania drôtu a tlak v hlave vytlačacieho stroja) regulovať otáčky zubového čerpadla pre udržanie požadovaného priemeru drôtu. Navrhnutá neurónová sieť bola tiež využitá na simuláciu pre stanovenie optimálnych rozsahov zmien parametrov.

Tretí experiment sa zameriaval na využitie LSTM neurónovej siete na detekciu a klasifikáciu zmien rýchlosti pohybu efektora priemyselného robota Fanuc LR Mate 200iC. Kľúčovou metódou bolo snímanie vibrácií pomocou akcelerometra ADXL345, ktoré slúžili ako vstupné dáta pre sieť. Výsledná presnosť klasifikácie je 98,61 %. Výsledky predstavujú významný prínos pre praktické aplikácie v oblasti technickej diagnostiky a prediktívnej údržby, obzvlášť pri včasnej identifikácii anomálnych stavov zariadení.

Na základe získaných poznatkov a praktických skúseností bol navrhnutý a realizovaný ďalší z experimentov. Jeho hlavným cieľom bolo experimentálne overenie vybraných prístupov dátovej analytiky a navrhnuitej architektúry umelej neurónovej siete pre detekciu porúch priemyselného robota Fanuc LR Mate 200iC. Experimentálne bolo overené, že sieť dokáže s vysokou presnosťou (99,32%) rozlíšiť normálny a anomálny stav robota Fanuc LR Mate 200iC na základe vybraných parametrov vibračného signálu, ako sú *Peak Value*, *Band Power* a *Mean*. Tieto zistenia potvrdzujú hypotézu o možnosti detekcie uvoľnenia základne robota pomocou neurónových sietí, čo vytvára priestor pre ďalší výskum v oblasti prediktívnej údržby a technickej diagnostiky. Napríklad pre diagnostiku iných typov porúch, akými sú kolízie alebo opotrebovanie pohonných jednotiek.

Táto práca rozširuje vedomosti v oblasti technickej diagnostiky strojov so sekvenčným pohybom, konkrétne o aplikácii metód a algoritmov, ktoré využívajú prevádzkové dáta pre diagnostiku a údržbu. Navrhnuté postupy sa ukázali ako účinné, čo umožňuje ich integráciu do reálnych výrobných prostredí. Tým sa posilňuje využitie dátovo orientovaných prístupov v rámci konceptu prediktívnej údržby a technickej diagnostiky. Získané poznatky nielen prispievajú k výskumu, ale aj zvyšujú spoľahlivosť a prevádzkovú efektívnosť priemyselných systémov.

Výsledky práce prispievajú k rozšíreniu vedomostí v oblasti technickej diagnostiky strojov s sekvenčným pohybom, konkrétne o aplikácie metód a algoritmov, ktoré využívajú prevádzkové dáta pre diagnostiku a údržbu. Navrhnuté postupy sa ukázali ako účinné v praktických aplikáciách, čo umožňuje ich integráciu do reálneho výrobného prostredia.

Najdôležitejšie literárne zdroje

- [1] ČERVEŇAN, A. *Systém údržby* [online]. Bratislava: CKV Consult, s r.o., 2015. 68 s. ISBN 978-80-971986-0-2.
- [2] DONG, G. et al. *Feature Engineering for Machine Learning and Data Analytics* [online]. 1. vyd. Ed. Guozhu. Dong a Huan. Liu. Boca Raton: CRC Press, 2018. ISBN 9781315181080.
- [3] FAKHAR MANESH, M. et al. Knowledge Management in the Fourth Industrial Revolution: Mapping the Literature and Scoping Future Avenues. In *IEEE Transactions on Engineering Management* [online]. 2021. Vol. 68, no. 1, s. 289–300. [cit. 2024-09-10]. Dostupné na internete: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8964410>>.
- [4] FEDOROVA, D. et al. Technical Diagnostics of Industrial Robots Using Vibration Signals: Case Study on Detecting Base Unfastening. In *Applied Sciences 2025, Vol. 15, Page 270* [online]. 2024. Vol. 15, no. 1, s. 270. [cit. 2025-04-11]. Dostupné na internete: <<https://www.mdpi.com/2076-3417/15/1/270/htm>>.
- [5] KURIC, I. et al. Artificial Neural Network Approach for Estimating Operating Parameters for Predictive Maintenance of Hydraulic Circuit. In *Qshine 2023* [online]. [s.l.]: Springer Nature Switzerland AG 2024, 2024. s. 391–406. ISBN 978-3-031-65122-9. Dostupné na internete: <https://link.springer.com/10.1007/978-3-031-65123-6_29>.
- [6] LORENZ, A. et al. Vibration Data Analysis for Fault Detection in Manufacturing Systems - A Systematic Literature Review. In *2022 IEEE 17th Conference on Industrial Electronics and Applications (ICIEA)* [online]. [s.l.]: IEEE, 2022. s. 851–857. [cit. 2024-09-17]. Dostupné na internete: <<https://ieeexplore.ieee.org/document/10006127/>>.
- [7] PECH, M. et al. Predictive Maintenance and Intelligent Sensors in Smart Factory: Review. In *Sensors 2021, Vol. 21, Page 1470* [online]. 2021. Vol. 21, no. 4, s. 1470. [cit. 2025-01-20]. Dostupné na internete: <<https://www.mdpi.com/1424-8220/21/4/1470/htm>>.
- [8] PEŤKOVÁ, V. *Teória a aplikácia vybraných metód technickej diagnostiky*. Ed. Anna Knapíková. Nitra: Technická univerzita v Košiciach, 2010. 234 s. ISBN 978-80-553-0483-0.
- [9] RIEČANOVÁ, Z. et al. *Numerické metódy a matematická štatistika* [online]. Bratislava: Alfa, 1987. 1–490 s.
- [10] ZEBA, G. et al. Technology mining: Artificial intelligence in manufacturing. In *Technological Forecasting and Social Change* [online]. 2021. Vol. 171, s. 120971. [cit. 2023-05-16]. Dostupné na internete: <<https://www.sciencedirect.com/science/article/pii/S0040162521004030>>.

Zoznam publikovaných prác doktoranda

1. **Fedorova, D.**, Ivolska, D., Alexeev, V., & Balyakin, A. (2016). Research of the Milling Properties of 316L Billet Made by SLM. *Izvestia of Samara Scientific Center of the Russian Academy of Sciences*, 4(6), 1186–1190.
2. Kuric, I., Bohušík, M., Stenclák, V., Bartoš, M., **Fedorova, D.**, & Sága, M. Jr. (2022). Trends and Applications of Artificial Intelligence Methods in Industry. *International Scientific Journal INDUSTRY 4.0*, 7(2), 42 – 45. Dostupné na internete: <<https://stumejournals.com/journals/i4/2022/2/42>>
3. Kuric, I., **Fedorova, D.**, Stenclák, V., Bohušík, M., Bartoš, M., & Sága, M. Jr. (2022). Development of predictive maintenance based on artificial intelligence methods. *International Scientific Journal INNOVATIONS*, 10(2), 57 – 60. Dostupné na internete: <<https://stumejournals.com/journals/innovations/2022/2>>
4. **Fedorova, D.**, Stenclák, V. (2022). Possibilities of Using Deep Neural Networks in Predictive Maintenance. *Technologie, Procesy i Systemy Produkcyjne*, 75–82. Dostupné na internete: <<https://doi.org/10.53052/9788366249981.09>>
5. Kuric, I., **Fedorova, D.**, Stenclák, V., Bartoš, M., Bohušík, M., & Bencel, A. (2023). Possibilities of Using an Autoencoder Network in the Failure State Recognition. *International Journal for Science, Technics and Innovations for the Industry MACHINES. TECHNOLOGIES. MATERIALS.*, 144(4), 141–144. Dostupné na internete: <<https://stumejournals.com/journals/mtm/2023/4/141>>
6. **Fedorova, D.**, Stenclák, V., Tlach, V., Kuric, I., & Wiecek, D. (2023). Prediction of Temperature Behavior in Hydraulic Circuits. *Transportation Research Procedia*, 74, 500–507. Dostupné na internete: <<https://doi.org/10.1016/J.TRPRO.2023.11.174>>. **(Q3 - SCOPUS)**
7. **Fedorova, D.**, Tlach, V., & Kuric, I. (2023). Classification of Industrial Robot Movements Based on Vibration Monitoring Data Using Lstm Neural Network. In J. Rysiński (Ed.), *Projektowanie, badania i eksploatacja* (pp. 169–178). Wydawnictwo Naukowe Uniwersytetu Bielsko-Bialskiego. Dostupné na internete: <<https://doi.org/doi.org/10.53052/9788367652148>>.
8. Kuric, I., **Fedorova, D.**, Zajačko, I., Tlach, V., Stenclák, V., & Bencel, A. (2024). Artificial Neural Network Approach for Estimating Operating Parameters for Predictive Maintenance of Hydraulic Circuit. In *Qshine 2023* (pp. 391–406). Springer Nature Switzerland AG 2024. Dostupné na internete: <https://doi.org/10.1007/978-3-031-65123-6_29>. **(Q4 – SCOPUS)**
9. Zajačko, I., **Fedorova, D.**, Tlach, V., Kuric, I., & Forgáč, P. (2024). Possibilities of Using Deep Convolutional Neural Network and Autoencoder Neural Network for Predictive Maintenance Tasks. *16th International Conference on Computer and Automation Engineering (ICCAE)*, 130–136. Dostupné na internete: <<https://doi.org/10.1109/ICCAE59995.2024.10569846>>.
10. **Fedorova, D.**, Tlach, V., Kuric, I., Dodok, T., Zajačko, I., & Tucki, K. (2024). Technical Diagnostics of Industrial Robots Using Vibration Signals: Case Study on Detecting Base Unfastening. *Applied Sciences* 2025, Vol. 15, Page 270, 15(1), 270. Dostupné na internete: <<https://doi.org/10.3390/APP15010270>>. **(Q1 - WoS, SCOPUS, CCC)**

