

**SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE
FAKULTA CHEMICKEJ A POTRAVINÁRSKEJ
TECHNOLÓGIE**

Evidenčné číslo: FCHPT-113709-91815

**PREDIKTÍVNA DÁTOVÁ ANALYTIKA S VYUŽITÍM
STROJOVÉHO UČENIA**

BAKALÁRSKA PRÁCA

2020

Marek Wadinger

**SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE
FAKULTA CHEMICKÉJ A POTRAVINÁRSKEJ
TECHNOLÓGIE**

**PREDIKTÍVNA DÁTOVÁ ANALYTIKA S VYUŽITÍM
STROJOVÉHO UČENIA**

BAKALÁRSKA PRÁCA

FCHPT-113709-91815

Študijný program: automatizácia, informatizácia a manažment v chémii a potravinárstve

Číslo študijného odboru: 2621R18

Názov študijného odboru: automatizácia, informatizácia a manažment v chémii a potravinárstve

Školiace pracovisko: Oddelenie informatizácie a riadenia procesov (ÚIAM FCHPT)

Vedúci záverečnej práce/školiťel: doc. Ing. Michal Kvasnica, PhD.

Konzultant: Ing. Martin Kalúz, PhD.

Bratislava 2020

Marek Wadinger



ZADANIE BAKALÁRSKEJ PRÁCE

Študent: **Marek Wadinger**
ID študenta: 91815
Študijný program: automatizácia, informatizácia a manažment v chémii a potravinárstve
Kombinácia študijných odborov: kybernetika, strojárstvo
Vedúci práce: doc. Ing. Michal Kvasnica, PhD.
Miesto vypracovania: Oddelenie informatizácie a riadenia procesov (ÚIAM FCHPT)

Názov práce: **Prediktívna dátová analytika s využitím strojového učenia**

Jazyk, v ktorom sa práca vypracuje: slovenský jazyk

Špecifikácia zadania:

Cieľom projektu je navrhnuť a implementovať automatizovaný systém, ktorý na základe strojového učenia spracuje a vyhodnotí procesné charakteristiky zariadení procesného priemyslu ako sú čerpadlá alebo ohrevné členy. Využijú sa pritom neinvazívne spôsoby získania dát, akými sú zvukové a vibračné odtlačky čerpadiel a výkonové profily ohrevných členov. Tieto dáta sa využijú na naučenie vhodne zvoleného mechanizmu strojového učenia, výsledkom ktorého bude digitálny model daného zariadenia. Tento model sa následne využije na predikciu nemerateľných veličín, ako i na predikciu potreby servisných zásahov.

Riešenie zadania práce od: 17. 02. 2020

Dátum odovzdania práce: 31. 05. 2020

Marek Wadinger
študent

doc. Ing. Michal Kvasnica, PhD.
vedúci pracoviska

prof. Ing. Miroslav Fikar, DrSc.
garant študijného programu

Čestné vyhlásenie

Vyhlasujem, že predloženú záverečnú prácu som vypracoval samostatne pod vedením vedúceho záverečnej práce, s použitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú citované v práci a uvedené v zozname použitej literatúry. Ako autor záverečnej práce ďalej prehlasujem, že som v súvislosti s jej vytvorením neporušil autorské práva tretích osôb.

Pod'akovanie

Ďakujem vedúcemu svojej práce doc. Ing. Michalovi Kvasnicovi, PhD. za odborné rady pri vypracovaní práce, konzultantovi práce Ing. Martinovi Kalúzovi, PhD. za podporu a technické zabezpečenie práce a doc. Ing. Jozefovi Dudášovi, PhD. za sprostredkovanie kontaktov na odborníkov v skúmanej oblasti. Vďaka venovanej pomoci sa mi podarilo prácu úspešne napísať a naučiť sa pri jej písaní veľa nových poznatkov aplikovateľných v budúcom štúdiu.

Abstrakt

Cieľom bakalárskej práce je návrh algoritmu na identifikáciu výkonového stupňa jednosmerného motora s komutátorom, spracovaním a vyhodnotením procesných charakteristík zariadenia. Využijú sa pritom vibračné odtlačky motora získané neinvazívnymi metódami. Algoritmus má slúžiť ako základ automatizovaného systému, ktorý získané dáta využije na naučenie vhodne zvoleného mechanizmu strojového učenia, výsledkom ktorého bude digitálny model daného zariadenia. Tento model sa následne využije na krátkodobú predikciu nemerateľných veličín, ako i na predikciu potreby servisných zásahov.

Kľúčové slová: jednosmerný motor; monitorovanie stavu; vibrácie; strojové učenie; prediktívna údržba

Abstract

Main aim of this bachelor's thesis is to design algorithm that identifies performance level of brushed DC electric motor, by processing and evaluating process characteristic of devices. Vibratory fingerprints of DC motor are used, obtained by non-invasive means. Algorithm will serve as a basis of automated system, that will use acquired data for training of respectably used machine learning mechanism, which outcome will be digital model of given device. Model will be used to predict immeasurable variables, as well as on short term prediction of service termination needs.

Key words: DC motor; condition monitoring; vibration; machine learning; predictive maintenance

Obsah

Zoznam ilustrácií.....	15
Zoznam tabuliek.....	17
Zoznam skratiek a značiek	18
Úvod.....	19
1 Súčasný stav riešenej problematiky	21
1.1 Stratégie plánovania údržby v priemysle	21
1.1.1 Reaktívna údržba.....	22
1.1.2 Preventívna údržba.....	22
1.1.3 Proaktívna údržba – stavovo založená údržba.....	22
1.1.4 Prediktívna údržba	23
2 Teoretická časť	25
2.1 Jednosmerné motory s komutátorom	25
2.1.1 Princíp prevádzky	25
2.1.2 Vibrácie elektrických motorov	27
2.2 Získavanie dát.....	27
2.2.1 Meranie vibrácií	28
2.2.2 MEMS Akcelerometer	28
2.3 Spracovanie dát.....	29
2.3.1 Techniky predspracovania dát.....	30
2.4 Identifikácia indikátorov stavu.....	31
2.4.1 Indikátory stavu v časovej oblasti	32
2.4.2 Indikátory stavu vo frekvenčnej oblasti	34
2.5 Kvalita indikátorov stavu.....	35
2.5.1 Vizualizácia dát.....	35
2.5.2 Analýza hlavných komponentov	38

2.6	Implementácia strojového učenia.....	39
2.6.1	Detekcia a diagnostika poruchy – klasifikačné metódy	39
2.6.2	Evaluácia klasifikačného modelu	41
2.6.3	Predikcia zostávajúcej životnosti – regresné metódy	43
3	Cieľ práce	44
4	Metodika práce a metódy skúmania	45
4.1	Objekt skúmania	45
4.2	Spôsob získavania údajov a ich zdroje.....	45
4.2.1	Hardvérové riešenia	45
4.2.2	Softvérové riešenia.....	46
4.3	Pracovný postup.....	47
4.3.1	Pripojenie zariadenia a príprava pracovného prostredia.....	47
4.3.2	Postup merania a získavania dát.....	48
4.3.3	Postup predspracovania dát.....	49
4.3.4	Identifikácia indikátorov stavu.....	50
4.3.5	Vyhodnocovanie kvality indikátorov stavu.....	51
4.3.6	Tvorba modelov strojového učenia	54
5	Výsledky práce	57
5.1	Klasifikácia výkonového stupňa	57
5.2	Klasifikácia uchytenia.....	60
5.3	Klasifikácia výkonového stupňa a uchytenia.....	62
6	Diskusia	66
7	Záver.....	68
	Zoznam použitej literatúry	70

Zoznam ilustrácií

Obr. 1 Názorná ilustrácia jednotlivých typov údržby	24
Obr. 2 Prierez jednosmerného motora s komutátorom.....	26
Obr. 3 Kapacitný akcelerometer s hrebeňovým usporiadaním.....	29
Obr. 4 Zobrazenie vibrácií stroja vo frekvenčnej oblasti a identifikácia anomálie	31
Obr. 5 Korelačný graf, vpravo silná korelačná závislosť vľavo slabá korelačná závislosť ...	36
Obr. 6 Histogram, vpravo dobre odlišiteľné jednotlivé triedy pre danú dĺžku intervalu, vľavo zle odlišiteľné dáta pre danú dĺžku intervalu	37
Obr. 7 Krabicový graf, vpravo kvalitný indikátor stavu dobre reprezentujúci jednotlivé výkonnostné stupne. Vľavo indikátor stavu, ktorý neseparuje hodnoty dostatočne.	37
Obr. 8 Graf rovnobežných súradníc	38
Obr. 9 Porovnanie korelačných grafov pred PCA vľavo a po PCA vpravo.....	38
Obr. 10 Ilustrácia klasifikácie súboru dát.....	39
Obr. 11 Vľavo: dataset s úplne separovateľnými triedami. Nekonečné množstvo priamok by mohlo dávať nulovú chybu. Vpravo: lineárna separácia tried na základe metódy podporných vektorov. Čiernou farbou vyznačené dáta predstavujú podporné vektory (Kuhn, 2013).....	41
Obr. 12 Ilustrácia lineárnej regresie a predikcie zostávajúcej životnosti	43
Obr. 13 Technický náčrt MEMS akcelerometrickej jednotky Accel Board - HW REV.2.02	45
Obr. 14 Technický náčrt jednodoskového mikropočítača Arduino 101	46
Obr. 15 Zobrazenie skutočného objektu skúmania a polohy akcelerometra	47
Obr. 16 Graf zobrazenia hlavných komponentov. Červenou farbou sú vyznačené hlavné komponenty objasňujúce 95% disperzie dát.	54
Obr. 17 Graf minimálnej chyby klasifikácie pre optimalizovaný model.	56
Obr. 18 CM 4. učenia univerzálneho modelu náhodného lesa pri klasifikácii 10 výkonových stupňov využitím všetkých indikátorov stavu.....	59
Obr. 19 CM 2. učenia univerzálneho modelu náhodného lesa pri klasifikácii 10 výkonových stupňov využitím 8 indikátorov zvolených vizualizáciou.....	59
Obr. 20 CM 2. učenia univerzálneho modelu náhodného lesa pri klasifikácii 10 výkonových stupňov využitím prvých 8 hlavných komponentov z PCA.....	59
Obr. 21 CM 4. učenia univerzálneho modelu náhodného lesa pri klasifikácii 5 typov uchytenia využitím všetkých indikátorov stavu.	61

Obr. 22 CM 3. učenia univerzálneho modelu náhodného lesa pri klasifikácii 5 typov uchytenia využitím 8 indikátorov zvolených vizualizáciou.	61
Obr. 23 CM 4. učenia univerzálneho modelu náhodného lesa pri klasifikácii 5 typov uchytenia využitím prvých 8 hlavných komponentov z PCA.	61
Obr. 24 CM 2. učenia univerzálneho modelu náhodného lesa pri klasifikácii výkonu a uchytenia využitím všetkých indikátorov.	63
Obr. 25 CM 1. učenia univerzálneho modelu náhodného lesa pri klasifikácii výkonu a uchytenia využitím 8 indikátorov zvolených vizualizáciou.	64
Obr. 26 CM 5. učenia univerzálneho modelu náhodného lesa pri klasifikácii výkonu a uchytenia využitím prvých 8 hlavných komponentov z PCA.	65

Zoznam tabuliek

Tab. 1 Matica zámeny (CM z angl. Confusion matrix).....	42
Tab. 2 Tabuľka špecifikácií akcelerometrického senzora ADXL330	46
Tab. 3 Ukážka zaznamenaných údajov pre meranie uskutočnené na motore s identifikačným číslom 2 pri výkone 100% a uchytení typu 1.....	48
Tab. 4 Tabuľka priradení typu uchytenia ku programovému označeniu.....	49
Tab. 5 Ukážka niektorých identifikovaných indikátorov stavu pre meranie uskutočnené na motore s identifikačným číslom 2 pri výkone 100% a uchytení typu 1.....	50
Tab. 6 Tabuľka subjektívneho prieskumu kvality indikátorov stavu pomocou krabicových grafov z hľadiska rozptylu hodnôt a rozlišovacej schopnosti. Na vytvorenie krabicového grafu bol použitý dátový súbor s 10000 meraniami pre motor s identifikačným označením 1 zahŕňajúcim merania pre všetky výkonové stupne a možnosti uchytenia na základe Tab. 4.....	52
Tab. 7 Parametre neoptimalizovaného modelu náhodného lesa.....	55
Tab. 8 Parametre optimalizovaných modelov náhodného lesa	55
Tab. 9 Výsledky predikčnej úspešnosti a časov tréningovania pri klasifikácii výkonového stupňa.	58
Tab. 10 Výsledky predikčnej úspešnosti a časov tréningovania pri klasifikácii uchytenia.	60
Tab. 11 Výsledky predikčnej úspešnosti a časov tréningovania pri klasifikácii výkonového stupňa a uchytenia.....	62

Zoznam skratiek a značiek

Std	Výberová smerodajná odchýlka dát (z angl. standard deviation)
Shapefactor	Tvarový faktor (z angl. shape factor)
Rms	Kvadratický priemer (z angl. root mean square)
Mean	Aritmetický priemer
Skewness	Výberový koeficient šikmosti
Kurtosis	Výberový koeficient špicatosti
Peak2peak	Vzdialenosť maxima a minima hodnôt
Peaktorms	Činiteľ výkyvu
Max	Maximálna hodnota

Úvod

Štvrtá priemyselná revolúcia, alebo Industry 4.0 ako sa vo svetovej literatúre uvádza od prvého verejného predstavenia tohto pomenovania v roku 2011 na svetovom veľtrhu priemyslu HANNOVER MESSE 2011, je prirodzeným následkom digitalizácie a vzniku nových technológií. Spája sa so snahou o efektívnejšie využívanie prírodných zdrojov a energie, udržateľný rast podnikov, zlepšenie pracovného prostredia, znižovanie nákladov na produkciu a maximalizáciu využitia výrobných kapacít. Zmeny, ktoré sa v znamení trendu revolúcie nesú však zasahujú do všetkých aspektov nášho každodenného života. Hlavnou myšlienkou je využitie plného potenciálu technológií akými sú internet vecí (z angl. Internet of Things), kyber-fyzické systémy, strojové učenie a cloudové riešenia. Industry 4.0 prináša nevidaný pokrok v oblasti automatizácie priemyslu, rozvoja robotiky a využitia umelej inteligencie, ktorých implementácia znamená podstatnú zmenu v kvalite produkcie, znížení rizika a zvýšení efektivity. Práve jedným z najhodnotnejších využití riešení, ktoré Industry 4.0 ponúka, je prediktívna údržba a analytika. Cieľom prediktívnej údržby je odhadnúť čas, ktorý dokáže zariadenie pracovať do zlyhania a na základe toho prispôbiť vykonávanie servisných úkonov na zariadení v prevádzke. Pomáha nám presne zistiť závady na stroji a identifikovať komponenty, ktoré musia byť opravené alebo vymenené. Digitálne modely zariadení prevádzky sú veľmi efektívnym prostriedkom pre dosahovanie týchto zámerov. Ich tvorba však vyžaduje veľmi dobrú znalosť zariadenia a jeho správania, ktoré zodpovedá jeho rôznym stavom. Tvorba účinných digitálnych modelov je spojená s využitím strojového učenia, ktoré je schopné spracovať veľké množstvo dát a nájsť v nich abstraktné súvislosti podobne ako to dokáže ľudský mozog. Tieto dáta môžu predstavovať rôzne indikátory stavu zariadenia, získané z monitorovaných charakteristík zariadenia zozbieraných v rôznych časoch.

Cieľom tejto záverečnej práce je priblížiť súčasný stav riešenej problematiky a súhrnne popísať pracovný postup pri vývoji algoritmov monitorovania stavu. S implementáciou teoretických poznatkov o logickej postupnosti vývoja algoritmu popísaných v práci navrhne algoritmus, schopný na základe vibračných charakteristík predpovedať stav jednosmerného motora za prevádzky v laboratórnych podmienkach, menovite jeho výkon a uchytenie. Následne ohodnotíme kvalitu zostrojeného algoritmu na základe jeho robustnosti, teda odolnosti voči chybám, a všeobecne možnosti implementácie v priemyselných podmienkach na motoroch rovnakého typu. Zhodnotíme možnosť ďalšieho rozvoja tematiky.

Tému som sa rozhodol spracovať na základe vnímaného potenciálu prediktívnej údržby v budúcnosti, ktorej základný stavebný pilier predstavuje monitorovanie stavu zariadenia v reálnom čase. To poskytuje možnosť krátkodobej predikcie jeho stavu.

1 Súčasný stav riešenej problematiky

Údržba sa vo všeobecnosti zaoberá rýchlou identifikáciou a opravou poruchy. Cieľom manažmentu údržby je zabezpečiť fungovanie zariadenia, podľa stanoveného plánu a potreby prevádzky. Vo všeobecnosti rieši dva optimalizačné problémy, prvým je maximalizácia dostupnosti vybavenia a systému a druhým minimalizácia nákladov spojených s údržbou. Manažment údržby plánuje jej stratégiu na základe špecifických potrieb podniku. Práve správne implementovaná stratégia údržby je kľúčová pre dosahovanie obchodných cieľov. Pri nasadení nesprávnej stratégie údržby sa stáva prevádzka reaktívna. Opakuje sa výskyt bežných porúch a väčší podiel zariadení je mimo prevádzky. Následkom je prerušenie výroby, vyššie náklady na údržbu a všeobecne neistota (Deighton, 2016).

Na základe štúdie z roku 2019 vykonanej portálom Plant Engineering v Severnej Amerike, ktorej cieľom bolo vyhodnotiť priemyselné praktiky a stratégie uplatňované v súčasnosti a ich efekty na produktivitu a profitabilitu, nadobúdame predstavu o aktuálnom stave. Z odpovedí 199 respondentov v období od 21. decembra 2018 do 9. januára 2019 vyplynulo, že až pri 78% výrobných zariadení volia stratégiu preventívnej údržby, pri 61% využíva počítačový systém riadenia údržby (skratka CMMS) a pri 56% volí reaktívnu údržbu. Najväčšia pozornosť je pritom venovaná rotačným zariadeniam, ako sú motory, prevodovky a pod. ďalej hydraulickým mechanizmom a automatizovaným systémom prevádzky. Ako hlavné dôsledky neplánovaného pozastavenia prevádzky uvádzali respondenti vek zariadenia, mechanické zlyhanie, či chybu na strane operátora. Ďalším dôležitým poznatkom vyplývajúcim z prieskumu je fakt, že priemerná prevádzka využíva externé zdroje pri 19% údržbových operácií v dôsledku nedostatku špecializácie v rámci personálneho osadenia (Pelliccione & Vavra, 2019).

Podľa prípadovej štúdie, ktorú publikovali Okoh a Haugen (2013) bola práve nesprávna údržba prekurzorom nehôd a zlyhaní prevádzok chemického a petrochemického priemyslu v 30 – 40% skúmaných prípadov. Príkladom takéhoto prípadu je výbuch rafinérie v meste Texas 23. marca 2005, pri ktorom zahynulo 15 ľudí a ďalších 180 bolo zranených. Mnoho ďalších podobných prípadov bolo zaznamenaných v spojitosti s nedostatočnou údržbou (Okoh & Haugen, 2013).

1.1 Stratégie plánovania údržby v priemysle

V závislosti od aktív, nákladov a technickej náročnosti je možné uplatniť široké spektrum stratégií plánovania údržby. Tieto stratégie siahajú od reakcií na vzniknuté poruchy po vysoko

automatizované systémy optimalizujúce plánovanie údržby pre maximalizáciu využitia strojového zariadenia v rámci odhadnutej zostávajúcej životnosti (Deloitte, 2017). V tejto práci sa pozrieme na základné štyri typy údržby, ktorými sú reaktívna, preventívna, proaktívna a prediktívna údržba.

1.1.1 Reaktívna údržba

Inak nazývaná aj korektívna je typ údržby, ktorý predstavuje reakciu na vzniknutý poruchový stav strojného zariadenia (pozri Obr. 1a). Využíva sa v prípade zariadení nízkej hodnoty, ktorých oprava je jednoduchá a nepredstavuje výraznú prekážku v procese výroby. Vždy, keď zariadenie alebo systém zlyhá, musí sa vykonať oprava alebo obnova, aby sa znova zaviedla jeho funkčnosť. Môže obsahovať jeden alebo všetky z nasledujúcich krokov: lokalizácia poruchy, izolácia poruchy, rozklad zariadenia, výmena poškodeného komponentu, opätovná montáž, nastavenie a testovanie. Problémom tejto údržby je prestoj strojného zariadenia pred opätovným uvedením do prevádzky (Xu, 2017; Mital, 2014). Preto sa v prípade reaktívnej stratégie údržby v priemysle využíva 100% záloha zariadenia alebo 2/3 záloha v prípade zaradenia viacerých zariadení rovnakého typu paralelne.

1.1.2 Preventívna údržba

Je využívaná najmä pri snahe minimalizovať pravdepodobnosť výskytu poruchy. Predstavuje plánovanú údržbu založenú na odhadnutej pravdepodobnosti poškodenia zariadenia v danom časovom intervale (pozri Obr. 1b). Úlohy preventívnej údržby zahŕňajú najmä mazanie zariadenia, výmenu dielcov, čistenie a nastavenie (napr. utiahnutie alebo uvoľnenie). Zariadenie sa môže počas preventívnej údržby kontrolovať aj na náznaky poškodenia. Týmto typom údržby dokážeme zabrániť neplánovanému pozastaveniu prevádzky zariadenia. Nadmerná údržba však predstavuje dva problémy. Jedným je nevyužitie plného potenciálu náhradných dielcov v rámci ich životného cyklu. Ďalší problém predstavujú častejšie prestoje zariadenia z dôvodu nadmernej údržby (Deloitte, 2017; Mital, 2014; Xu 2017).

1.1.3 Proaktívna údržba – stavovo založená údržba


Predstavuje stratégiu plánovania údržby založenú na monitorovaní stavových veličín zariadenia v čase. Vo všeobecnosti možno údržbu založenú na monitorovaní stavu považovať za metódu, znižujúcu neistotu pri vykonávaní servisných zásahov na základe uvedených požiadaviek na stav zariadenia (Peng et al., 2010). Preto nám táto údržba umožňuje identifikovať

a riešiť problémy skôr, ako dôjde k poškodeniu strojového zariadenia (pozri Obr. 1c). V priemyselných systémoch môže mať akékoľvek poškodenie vážne následky. Vzhľadom na to je táto stratégia údržby využívaná v priemysle na vysoko hodnotné zariadenia, ktorých zlyhanie môže predstavovať výraznú prekážku v procese výroby. Zameriava sa na predpoveď degradácie zariadenia, ktorá sa zakladá na predpoklade, že väčšina abnormalít sa nevyskytuje okamžite a zvyčajne existujú určité druhy procesu degradácie z normálnych stavov do abnormálnych (Jong-Ho et al., 2015).

Monitorovanie stavu je definované ako „činnosť vykonávaná buď manuálne alebo automaticky, určená na meranie charakteristík a parametrov skutočného stavu položky vo vopred určených intervaloch“ (SS-EN 13306, 2010, s. 14). Oprava a údržba zariadenia je iniciovaná vtedy, keď veličina charakterizujúca stav zariadenia prekročí určitú kritickú úroveň. Na základe meraných charakteristík sa vytvára model schopný získavať dáta a diagnostikovať ich s cieľom indikovať prekročenie tejto hranice. S týmito modelmi sa spájajú mnohé nevýhody, nakoľko sa kritická úroveň vyberá subjektívne a na základe odporúčaní výrobcov strojného zariadenia alebo dodávateľov monitorovacích zariadení (Mital, 2014).

1.1.4 Prediktívna údržba

Prediktívna údržba je typ údržby, ktorá zvyšuje efektívnosť podniku v oblasti časových a finančných investícií, nakoľko umožňuje odhad zostávajúcej životnosti strojového zariadenia. Tento prístup je založený na monitorovaní indikátorov stavu získaných senzormi umiestnenými na zariadení alebo v jeho okolí, ktoré umožňujú nepretržité sledovanie parametrov zariadenia, akými sú jeho vibrácie a teplota, zloženie maziva a hladina hluku (pozri Obr. 1d). Na základe historických dát zobrazujúcich vývoj poruchy a stavových modelov zariadení dokážeme účelne navrhnúť algoritmy schopné predikovať poruchový stav zo sledovaných stavových veličín meraných v reálnom čase. Samotné monitorovanie stavu nemôže byť považované za prediktívne, nakoľko umožňuje iba identifikáciu zmien parametrov z minulých záznamov alebo v reálnom čase, nie však predpovedať zmenu v budúcnosti. Tým pádom neumožňuje zodpovednej osobe naplánovať budúcu údržbu efektívnym spôsobom (Krupitzer, 2020). Systémy prediktívnej údržby využívajú metódy regresnej analýzy.



Obr. 1 Názorná ilustrácia jednotlivých typov údržby

2 Teoretická časť

Elektromotory sa v súčasnosti nachádzajú v každom priemyselnom podniku. Sú súčasťou mnohých akčných členov regulačných obvodov, kde je vyžadovaný spojený rotačný pohyb na ovládanie regulačného orgánu, hydrodynamických strojov, generátorov, termoregulačných zariadení a pod. V dôsledku rotačného pohybu produkujú zvyčajne výrazné merateľné vibrácie a akustický hluk, ktoré sa dajú identifikovať v súvislosti s ich zdrojom. So zmenou stavu sa zvyčajne tieto merateľné indikátory pravidelne a s predvídateľným charakterom menia. Široká aplikovateľnosť elektromotorov a možnosť získania relevantných dát z nich robí zaujímavý objekt skúmania a dobrú reprezentatívnu vzorku zariadení pre skúmanie.


2.1 Jednosmerné motory s komutátorom

Aj napriek klesajúcemu podielu jednosmerných motorov s komutátorom na trhu v 21. storočí zostáva stále ich veľké množstvo zaradené v prevádzke tam, kde sa vyžaduje regulácia otáčok alebo krútiaceho momentu. Jednosmerné motorové pohony zostávajú konkurencieschopné v niektorých väčších aplikáciách (niekoľko stoviek kW) najmä tam, kde sú prijateľné motory s konštrukciou otvoreného odkvapu. Tie umožňujú dobrý prietok vzduchu vďaka vetracím otvorom v plechovom kryte, avšak ich použitie je typicky obmedzené na suché a neprašné vnútorné prostredie. Jednosmerné motory sa vo veľkej miere používajú v pohonoch s premenlivými otáčkami a v systémoch riadenia polohy, kde sa vyžaduje dobrá dynamická odozva a stabilný výkon. Uplatnenie nachádzajú napríklad v robotických jednotkách, tlačiarňach, obrábacích strojoch, procesoch valcovania, mlynoch, v papierenskom a textilnom priemysle a podobne (Hughes et al., 2019; Rahman et al., 2018).

2.1.1 Princíp prevádzky

Vo všeobecnosti pracujú všetky elektrické motory na rovnakom princípe. Základom je interakcia dvoch magnetických polí. Jedno magnetické pole vzniká na pevne uchytenej časti, statore a druhé na pohyblivej časti, rotore. Tieto magnetické polia sú vytvárané buď tokom elektrického prúdu vinutím, použitím permanentných magnetov alebo indukovaným prúdom. Sila vyvolaná interakciou medzi týmito dvoma magnetickými poľami vytvára krútiaci moment na rotore a spôsobuje otáčanie hriadeľa (Kim, 2017).

Jednosmerný motor má dva oddelené elektrické obvody. Prvý sa nachádza na statore a vytvára indukčný magnetický tok. Nazýva sa aj budiace vinutie statora. Druhý pozostáva zo sady identických cievok navinutých na rotore známych ako kotva a predstavuje vinutie rotora. Krútiaci moment vyvolaný na hriadieli pohyblivého rotora spôsobuje jeho otáčavý pohyb. Malé jednosmerné motory majú zvyčajne namiesto budiaceho vinutia permanentný magnet, ktorý vytvára magnetický indukčný tok statora. Jednosmerný motor má mechanické komutačné zariadenie. Pozostáva z navzájom izolovaných kovových lamiel pevne uchytených na hriadieli rotora a zo zberačov - kefiiek alebo uhlíkov opierajúcich sa o lamely. Zberače prevádzajú jednosmerný prúd dodávaný zo zdroja jednosmerného prúdu na striedavý prúd vo vinutí rotora. Rovnako ako mnohé elektrické zariadenia aj jednosmerné motory môžu byť navrhnuté pre všetky požadované napájacie napätia. Z mnohých dôvodov je však veľmi neobvyklé nájsť jednosmerné motory s komutátorom s nižším menovitým napätím ako 6 V a omnoho vyšším ako 700 V. Dolná hranice vzniká z dôvodu nevyhnutného poklesu napätia, zhruba 0,5 – 1 V v dôsledku prítomnosti zberačov. Je zjavné, že nie je dobrým zvykom, aby sa veľká časť napájacieho napätia premenila na stratovú. Na druhej strane škály sa stretávame s problémom neúmerných nákladov, pri snahe izolovať jednotlivé lamelové segmenty, aby odolali vyššiemu napätiu. Komutačné zariadenie sa stáva problematickým pri veľmi vysokých rýchlostiach. Treba poznamenať, že zberače sú stacionárne mechanické súčasti opierajúce sa o pohybujúce sa lamely a teda sú mechanicky namáhané. Preto nie je prekvapivé, že pre zabezpečenie bezproblémovej prevádzky treba udržiavať kefy čisté a prítlačné pružiny pravidelne opravované (Hughes et al., 2019; Kim, 2017).



Obr. 2 Prierez jednosmerného motora s komutátorom

2.1.2 Vibrácie elektrických motorov

V každom motore sa okrem požadovaných síl, krútiacich momentov a pohybov nevyhnutne vytvárajú aj nežiadúce sily. Všetky tieto efekty vytvárajú hluk prenášaný štruktúrou a ako také sa prejavujú vo forme vibrácií. Tieto zdroje vibrácií vieme vo všeobecnosti rozdeliť do dvoch kategórií na základe príčiny ich vzniku a to elektricky a mechanicky indukované (Ágoston, 2015).

Elektricky indukované vibrácie vznikajú napríklad v dôsledku tangenciálnych síl pôsobiacich na stator, spôsobených zmenou hustoty magnetického indukčného toku v čase, ktorá je nevyhnutne potrebná na vytvorenie krútiaceho momentu. Ak je motor vhodne skonštruovaný, kolísanie tangenciálnych síl má veľmi malý účinok, pretože keď sa sčítajú po obvode statora, veľký počet miestnych tangenciálnych síl sa navzájom vyrovnáva. Inou príčinou môže byť skrat časti elektrického vinutia.

Mechanicky indukované vibrácie môžu byť zapríčinené nerovnováhou, nesprávnym uložením a uchytením, nedostatočným príkonom, neúmerným zaťažením či trecími silami, premenlivými v čase v ložiskách a na kontaktných plochách. Práve tieto trecie sily sú prítomné pri využití komutačných zariadení, kde dochádza ku kontaktu statických a rotujúcich častí. Rotor s lamelami v dôsledku veľkej relatívnej hmotnosti a tuhosti v porovnaní so zberačom nevytvára pozorovateľné vibrácie. To ako vibrujú kovové alebo uhlíkové zberače je závislé od ich pružnosti a hmotnosti, rovnako ako od systému uchytenia a kvality styčnej plochy. Výsledný hluk týchto zberačov je veľmi malý kvôli ich malým rozmerom. Dokážeme však vnímať vibrácie prenášané na štruktúru prostredníctvom systému uchytenia a blízkej oblasti, nakoľko tieto časti tvoria väčší povrch (Bertolini, 2011).

Nainštalované prevodovky spôsobujú taktiež nežiadajú rotačnú osciláciu v dôsledku pohybu ozubených kolies a zapríčiňujú vznik mechanických vibrácií. (Ágoston, 2015).

2.2 Získavanie dát

Je proces zaznamenávania meracích signálov pomocou rôznych druhov snímačov z monitorovaných zariadení a ukladania týchto dát v počítači. Tieto meracie signály by mali spravidla súvisieť so stavom monitorovaného zariadenia. Inak povedané mali by obsahovať niektoré užitočné informácie, ktoré priamo odpovedajú stavu. Existuje mnoho rôznych typov meracích signálov, ako sú vibračné, akustické, teplotné a elektrické. Rôzne senzory vrátane

akcelerometrov, akustických emisných senzorov, infračervených teplomerov, ultrazvukových senzorov a pod. boli navrhnuté na zber rôznych typov signálov (Lei, 2017a).

Analýza vibračných odtlačkov je hlavnou metódou sledovania stavu strojov. Väčšina vibrácií strojov je nútené periodické kmitanie spôsobené samotným zariadením alebo vonkajším prostredím. Množstvo vibrácií závisí od excitujúcej sily, od blízkosti frekvencie excitujúcej sily ku štruktúrnej rezonancii a odporu konštrukcie voči vibráciám.

2.2.1 Meranie vibrácií

Vibrácie je možné merať alebo vyjadrovať v troch základných kvantifikáciách na základe dôrazu na rôzne časti spektra: posun, rýchlosť a akcelerácia. Pri meraní posunu vzhľadom na centrálny statický bod ide o relatívne meranie vibrácií využitím bezdotykových snímačov (laserových) alebo snímačov montovaných na samotné zariadenie využívajúcich kapacitanciu alebo v minulosti vírivé prúdy. Veľmi dôležité pri využití tejto metódy, je umiestnenie a relatívny pohyb samotného senzora voči stacionárnemu bodu a jeho precízna kalibrácia. Pri meraniach rýchlosti a zrýchlenia ide o absolútne meranie vibrácií snímačom pevne spojeným so zariadením. Podľa fyzikálnych zákonov pri nízkych frekvenciách budú mať vibrácie veľký posun a malú akceleráciu a pri vysokých frekvenciách to bude naopak. Preto meranie posunu je najvýhodnejšie pri monitorovaní a meraní vibrácií bez rotujúcich komponentov. Aj napriek schopnosti niektorých kapacitných snímačov posunu merať frekvencie vyššie ako 2 kHz je meranie amplitúdy vibračného posunu veľmi malé a nerozoznatelné od šumu meracieho zariadenia. Akcelerometrické senzory sú uplatniteľné pri meraní vibrácií rotačných strojov, avšak majú nedostatky pri meraní nižších frekvencií (Boyce, 2012a; Boyce, 2012b).


2.2.2 MEMS Akcelerometer

Mikroelektromechanické systémy alebo MEMS predstavuje elektromechanické zariadenie vyrobené pomocou mikroelektronických výrobných postupov. Tieto techniky vytvárajú mechanické snímacie štruktúry mikroskopickej veľkosti, zvyčajne na báze kremíku. Ich veľkosť je zvyčajne v rozsahu niekoľkých milimetrov až po menej ako jeden mikrometer.

Princíp merania MEMS akcelerometra je založený na zmene elektrickej kapacity kondenzátora, v dôsledku zmeny vzájomnej polohy elektród, nepohyblivej uchytenej na kremíkovej doske a pohyblivej elektróde, uloženej na seizmickej hmote, ktorá je pružinou ukotvená ku doske. Zmena kapacity akcelerometra je úmerná zrýchleniu meraného objektu.

Rozsah merania sa upravuje zmenou tuhosti systému ukotvenia. Vysoké merané frekvencie sa dosahujú pri nižšej hmotnosti seizmickej hmoty.

Akcelerometer môže merať statické gravitačné zrýchlenie pri snímaní náklonu a dynamické zrýchlenie spojené s pohybom, nárazom alebo vibráciami.



Obr. 3 Kapacitný akcelerometer s hrebeňovým usporiadaním

2.3 Spracovanie dát

Spracovanie dát predstavuje analýzu uložených meracích signálov využitím techník a metód spracovania za účelom extrakcie užitočných informácií z originálneho signálu. V mnohých prípadoch sú získané vibračné dáta zaťažené šumom merania prípadne prítomnosťou odľahlých hodnôt. Takéto dáta môžu podávať mylnú informáciu o skutočnostiach, ktoré sa môžu pozorovateľovi zdať zjavné pri pozorovaní grafických dát, avšak pri ďalšom počítačovom spracovaní alebo využití pri vývoji digitálneho modelu prostredníctvom strojového učenia môžu spôsobiť vznik chybných modelov. Z týchto dôvodov je nevyhnutné pedspracovanie získaných dát. Pedspracovanie dát predstavuje nie len odstránenie odľahlých hodnôt a filtrovanie šumu, ale aj transformácia dát do formy, ktorá môže odhaliť ďalšie dôležité informácie o pozorovanom objekte. Techniky a algoritmy spracovania dát môžu byť rozdelené do troch oblastí: časovej, frekvenčnej a časovo-frekvenčnej (Lei, 2017a).

2.3.1 Techniky predspracovania dát

Škálovanie dát – alebo normalizácia dát znamená úpravu rozsahu alebo zmenu reprezentácie dát. Využíva sa v prípade snahy o zvýšenie zrozumiteľnosti dát reprezentovaním hodnôt v známych jednotkách. Omnoho dôležitejšie uplatnenie má však pri zlepšovaní účinnosti algoritmov strojového učenia, najmä pri zhlukovacích algoritmoch (angl. Clustering algorithms), ktoré počítajú vzdialenosť dvoch bodov využitím Euklidovej vzdialenosti, kedy element so širokým rozsahom hodnôt môže mať štatisticky väčšiu váhu, ako nemenej dôležitý element. V takýchto prípadoch sa najčastejšie využíva z-skóre normalizácia dát. Tá upravuje dáta tak, aby boli centrovane okolo 0 so smerodajnou odchýlkou rovnou 1. Takýmto spôsobom môžeme pri tvorbe algoritmov strojového učenia pracovať s meraniami v rôznych jednotkách.

$$Z = \frac{s_i - \mu}{\sigma} \quad (1)$$

z je z-skóre

s_i je i -ty člen dátového súboru s

μ je aritmetický priemer hodnôt dátového súboru s


σ je smerodajná odchýlka dátového súboru s

Pri zobrazovaní vibračných dát vo frekvenčnej oblasti je využitie lineárneho škálovania najlepšie pre diagnostiku a reportovanie vibračných elementov voľným okom. Logaritmické škálovanie sa využíva pri monitorovaní nakoľko odhaľuje menej výrazné prvky, ktoré môžu byť výraznými indikátormi zmeny stavu strojného zariadenia (Beebe, 2004).

Filtrovanie dát – je metóda odstraňovania šumu a nechcených komponentov signálu. Jej využitie je vhodné v prípade, že vieme ako veľmi je meranie zaťažené šumom a poznáme rozsah frekvencií, ktorý s najvyššou pravdepodobnosťou zobrazí užitočné vlastnosti pre sledovanie stavu a predikcie. Šum merania môže predstavovať prítomnosť frekvencií mimo rozsahu frekvencií daného šírkou pásma na prenos signálu (Lei, 2017b).

Reprezentácia vo frekvenčnej oblasti – predstavuje transformáciu dát z časovej alebo priestorovej oblasti do frekvenčnej oblasti za účelom extrakcie užitočných informácií z dát, označovaných aj ako indikátory stavu. Využíva sa pri tom matematická štúdia Fourierová analýza, ktorá skúma spôsob, akým sa dá funkcia znázorniť a aproximovať sumou jednoduchších trigonometrických funkcií. Tieto trigonometrické funkcie v prípade analýzy zvukového

a vibračného spektra predstavujú jednotlivé komponenty spektra rôznych frekvencií alebo analýzy dát získaných zo statických alebo dynamických modelov zariadenia.



Obr. 4 Zobrazenie vibrácií stroja vo frekvenčnej oblasti a identifikácia anomálie

2.4 Identifikácia indikátorov stavu

Pri tvorbe algoritmov prediktívnej údržby je identifikácia indikátorov stavu kľúčovou úlohou. Predstavujú vlastnosti systému, ktoré sa predvídateľne menia v závislosti od degradácie systému. Indikátorom stavu môžu byť ktorákoľvek vlastnosť systému využiteľná pri rozlišovaní normálneho správania systému od jeho poruchového správania alebo predpovedanie zostávajúcej životnosti. Indikátor stavu zhlukuje podobné stavy systému a odlišuje ich od ostatných stavov. Môže ísť o využitie výstupov z jednoduchšej analýzy dát v časovej oblasti, akou je priemerná hodnota dát v čase, analýzy signálu vo frekvenčnej oblasti akou je sledovanie frekvencie píku magnitúdy a komplexnejšia analýza založená na modely systému odvodená z prispôbenia systémových údajov modelu a vykonanie ďalšieho spracovania (Isermann, 2006).

2.4.1 Indikátory stavu v časovej oblasti

Využitie indikátorov stavu v časovej oblasti je jednou zo základných metód, kde sú merané vibrácie zobrazené v čase ako posun, rýchlosť alebo akcelerácia. Dávajú predstavu o celkovom stave systému na základe zmeny jeho vibrácií v čase. Zmena indikátorov stavu v časovej oblasti napovedá o vývoji poruchy. Nevýhodou analýzy časovej domény je to, že môže byť ťažké odhaliť odlišné vzorce alebo odlišné poruchy od seba navzájom, pretože rôzne zdroje vibrácií vedú k superpozícii vibrácií, vytvárajúc komplexnejší signál obsahujúci informácie zo všetkých zdrojov vibrácií, čo vedie k obmedzeniam toho, čo je možné rozpoznať v komplexnom signáli (Osswald, 2019).

Kvadratický priemer (RMS) – je označovaný aj ako efektívna hodnota a využíva sa v elektrotechnike a pri meraní signálu, kedy môže meraný signál predstavovať sínusoidu, v ktorej sa vyskytujú záporné hodnoty. Táto metrika je vhodná pri monitorovaní celkovej úrovne vibrácií nakoľko opotrebovanie zariadenia súvisí s jej nárastom avšak nie je citlivá na lokálne maximá vibrácií. Tento parameter je citlivý na zmeny rýchlosti alebo záťaže (Večeř et al., 2005).

$$s_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N (s_i)^2} \quad (2)$$

s_{rms} je kvadratický priemer

s_i je i -ty člen datasetu s

N je počet bodov v datasete s

Delta RMS – je rozdiel dvoch závislých hodnôt RMS. Predstavuje trend úrovne vibrácií, pomocou ktorého je možné sledovať zmeny signálu. Teoreticky je poškodenie zariadenia spojené s prudkejšou zmenou úrovne vibrácií, ktorú dokážeme pomocou tejto metriky identifikovať (Večeř et al., 2005).

$$s_{rms} = s_{rms}(t + 1) - s_{rms}(t) \quad (3)$$

Maximálna hodnota – predstavuje maximálnu amplitúdu výchylky signálu v určenom časovom intervale. Tento kvalitatívny údaj nie je väčšinou využívaný samostatne a jeho osobité vyhodnotenie vyžaduje expertízu odborníkom (Zhu et al., 2014).

$$s_{Peak} = \max(s_1, s_2, \dots, s_N) \quad (4)$$

Činiteľ výkyvu – je podiel maximálnej hodnoty signálu v určenom časovom intervale a kvadratického priemeru signálu. Uplatnenie má pri meraní signálov pozostávajúcich z úzkych píkov vysokých amplitúd, ktoré môžu predstavovať poškodenie jedného zubu na hriadeli motora, avšak znamenajú minimálnu zmenu hodnoty RMS. Tento parameter pomáha indikovať poškodenie zariadenia v jeho skorých štádiách (Večeř et al., 2005).

$$CF = \frac{s_{Peak}}{s_{rms}} \quad (5)$$

CF je činiteľ výkyvu (z ang. „Crest factor“)

s_{Peak} je maximálna amplitúda výchylky

s_{rms} je kvadratický priemer

Výberový koeficient špicatosti – hovorí o koncentrácií hodnôt okolo ich strednej hodnoty, inak povedané o tom ako plochá alebo špicatá je distribúcia hodnôt. Za prítomnosti strmších píkov vibračného signálu, bude aj distribúcia strmšia a hodnota koeficientu špicatosti bude vyššie. Signál s vysokou hodnotou výberového koeficientu špicatosti je často produkovaný poškodeným zariadením (Večeř et al., 2005).

$$g_2 = \frac{N * \sum_{i=1}^N (s_i - \bar{s})^4}{(\sum_{i=1}^N (s_i - \bar{s})^2)^2} \quad (6)$$

g_2 je výberový koeficient špicatosti

N je počet bodov z časovej histórie signálu s

s_i je i -ty bod z časovej histórie signálu s

Výberový koeficient šikmosti – je založený na porovnaní koncentrácie malých hodnôt a koncentrácie veľkých hodnôt. predstavuje mieru asymetrie vibračného signálu. V prípade vzniku negatívneho alebo pozitívneho zošikmenia signálu je táto hodnota indikátorom možnej poruchy zariadenia (Zhu et al., 2014).

$$g_1 = \frac{\sqrt{N} * \sum_{i=1}^N (s_i - \bar{s})^3}{(\sum_{i=1}^N (s_i - \bar{s})^4)^{\frac{3}{2}}} \quad (7)$$

g_1 je výberový koeficient šikmosti

N je počet bodov z časovej histórie signálu s

s_i je i -ty bod z časovej histórie signálu s

Výberová smerodajná odchýlka – je nezáporný parameter, ktorý definuje rozptyl kvantitatívnych hodnôt priradených k meranej veličine. Je všeobecne definovaná ako druhá odmocnina rozptylu hodnôt n nezávislých meraní získaných pri rovnakých podmienkach (Cekan et al., 2015).

$$s_{std} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (s_i - \bar{s})^2} \quad (8)$$

s_{std} je výberová smerodajná odchýlka

N je počet bodov z časovej histórie signálu s

s_i je i -ty bod z časovej histórie signálu s

Tvarový faktor – z definície predstavuje podiel kvadratického priemeru (RMS) a aritmetického priemeru. Tvarový faktor závisí od tvaru signálu, pričom je nezávislý od jeho rozmeru.

$$s_{Shape} = \frac{s_{rms}}{s_{mean}} \quad (9)$$

s_{Shape} je tvarový faktor

s_{rms} je kvadratický priemer

s_{mean} je aritmetický priemer

2.4.2 Indikátory stavu vo frekvenčnej oblasti

Frekvenčná oblasť môže byť vnímaná ako spektrum, kde sú frekvencie vyobrazené na horizontálnej osi a amplitúda na vertikálnej. Najrozšírenejšia technika frekvenčnej analýzy stacionárneho vibračného signálu je využitie algoritmu Rýchlej Fourierovej Transformácie (FFT z angl. Fast Fourier Transformation). Pri voľbe vhodných techník spracovania signálu je možné identifikovať zmeny vo frekvenciách vibrácií spôsobených chybným komponentom a posúdiť stav sledovaného zariadenia. Transformáciou do frekvenčnej oblasti sa však stráca informácia

o časovej závislosti spektra analyzovaného signálu. Znamená to, že nedokážeme presne povedať, kedy sa udalosť stala. Táto vlastnosť je problémom pri analyzovaní nestacionárnych charakteristík vibračného signálu, akými sú odchýlky, trendy, náhle zmeny, začiatky a konce udalostí. V takomto prípade je výhodné pozrieť sa na časové a frekvenčné korelácie vibračného signálu.

$$Y_k = \sum_{n=0}^{N-1} s_n e^{-i2\pi kn/N} \quad k = 0, 1, \dots, N-1 \quad (10)$$

Y_k je Fourierová transformácia

S je vektor komplexných čísel

N je dĺžka vektora s

2.5 Kvalita indikátorov stavu


Ako bolo v kapitole 2.4 uvedené, indikátory stavu predstavujú charakteristiky systému, využívané pri rozlišovaní normálneho správania systému od poruchového alebo predpovedaní zostávajúcej životnosti. To je dosahované ich schopnosťou zhľukovať podobné stavy systému a odlíšiť ich od ostatných. Práve táto kvalita indikátorov stavu je kľúčová pre akúkoľvek prácu súvisiacu s vyhodnocovaním stavu zariadenia. V prípade, že hodnota indikátora stavu predpovedateľne závisí od rozsahu zmeny sledovanej vlastnosti systému a dokáže túto zmenu vlastnosti odlíšiť od iných zmien, hovoríme o rozlišovacej schopnosti. Tá z fyziky predstavuje minimálny rozdiel hodnôt sledovanej veličiny, ktorý je určité zariadenie schopné ešte rozlíšiť, v tomto prípade určitý indikátor stavu. Vizualizácia dát je jednou z najdôležitejších techník efektívneho vyhodnocovania kvality malého počtu indikátorov stavu. V prípade väčšieho množstva indikátorov stavu využívame pokročilú metódu analýzy hlavných komponentov.

2.5.1 Vizualizácia dát

Aj napriek tomu, že vizualizácia dát nie je považovaná za techniku vied o údajoch je často využívaná v ich kontexte. Vizualizácia dát umožňuje ľahké porozumenie komplexných údajov s niekoľkými atribútmi a ich základné vzťahy. Hlavnými výhodami je možnosť zahrnúť veľké množstvo dátových bodov na jedinom grafe a tým pádom pomáhajú vytvoriť si lepší obraz o dlhodobých trendoch, ktoré sa komplikovane interpretujú v samotných číslach. Zobrazenie v karteziánskej súradnicovej sústave umožňuje preskúmať vzťah medzi jednotlivými atribútmi


avšak maximálne v troch dimenziách. Štvrtú dimenziu dokážeme rozlíšiť rozdielnou farbou či tvarom dátových bodov v závislosti od pridaného atribútu. V prípade väčšej dimenzionality sa stretávame s problémom neriešiteľným základnými vizualizačnými technikami a sme nútený zvoliť iné metódy. Na základe množstva zobrazených atribútov rozlišujeme medzi jednorozmernou a viacrozmernou dátovou vizualizáciou (Kotu & Deshpande, 2019a).

Korelačný graf – je jedným z najúčinnejších a najjednoduchších dostupných grafov. Dátové body sú označené v karteziánskom priestore pozdĺž súradnicových osí na základe ich hodnoty. Jedným z kľúčových pozorovaní, ktoré možno vyvodiť z korelačného grafu, je existencia vzťahu medzi dvoma skúmanými atribútmi. Ak sú atribúty lineárne korelované, potom sú dátové body bližšie k imaginárnej priamke. Ak nie sú v korelácii, dátové body sú rozptýlené. Okrem základnej korelácie môžu korelačné grafy tiež naznačovať existenciu vzorov alebo skupín zoskupení v údajoch a identifikovať odľahlé hodnoty v údajoch, ktoré môžu predstavovať chybové meranie alebo anomáliu (Kotu & Deshpande, 2019a).




Obr. 5 Korelačný graf, vpravo silná korelačná závislosť, vľavo slabá korelačná závislosť

Histogram – je základnou technikou pre pochopenie frekvencie výskytu hodnôt. Zobrazuje distribúciu dát zobrazením frekvencie ich výskytu v určitom rozsahu. Na horizontálnej osi vidíme hodnoty atribútu a na vertikálnej frekvenciu výskytu. Pre spojité hodnoty dát je dôležité špecifikovať dĺžku intervalov alebo inak povedané rozsahy jednotlivých stĺpcov histogramu (Kotu & Deshpande, 2019a).




Obr. 6 Histogram, vpravo dobre odlíšiteľné jednotlivé triedy pre danú dĺžku intervalu, vľavo zle odlíšiteľné dáta pre danú dĺžku intervalu

Krabicový graf – predstavuje štandardizovaný spôsob zobrazenia distribúcie dát ako zhrnutie piatich číselných hodnôt: minimum, prvý kvartil, medián, tretí kvartil a maximum. Dokáže nám napovedať o prítomnosti odľahlých hodnôt, či sú dáta symetrické a ako pevne sú zoskupené.



Obr. 7 Krabicový graf, vpravo kvalitný indikátor stavu dobre reprezentujúci jednotlivé výkonnostné stupne. Vľavo indikátor stavu, ktorý neseparuje hodnoty dostatočne.


Rovnobežné súradnice – moderná metóda vizualizácie viacrozmerných dát, ktorá dáta transformuje do dvojrozmerného priestoru. Každý atribút je zobrazený na jednej priamke s určenou polohou na horizontálnej osi a hodnoty sú zobrazené na vertikálnej osi. Prehľadnosť a praktické využitie je podmienené normalizáciou dát. Zakladá sa na predpoklade, že určité vlastnosti zobrazené v trojrozmernom priestore, dokážu vytvoriť rozlíšiteľné vzory v dvojrozmernom (Kotu & Deshpande, 2019a).



Obr. 8 Graf rovnobežných súradníc

2.5.2 Analýza hlavných komponentov

Analýza hlavných komponentov (PCA z angl. Principal component analysis) predstavuje štatistickú metódu, ktorej úlohou je redukcia dimenzionality dátového súboru s veľkým počtom navzájom závislých premenných pri snahe zachovať najväčší rozptyl. Je jednou z najstarších a najpoužívanějších techník viacrozmerovej analýzy. Využíva pri tom ortogonálnu transformáciu pre identifikáciu hlavných komponentov, ako nového súboru premenných, ktoré sú vzájomne nekorelované. V prvom kroku hľadáme lineárnu kombináciu prvkov vektorového priestoru, v našom prípade premenných alebo indikátorov stavu, ktorá má maximálny rozptyl okolo ich priemernej hodnoty. Tá predstavuje prvý hlavný komponent (PC1). Následne hľadáme ďalšiu lineárnu kombináciu, ktorá je nekorelovaná s predošlou a zároveň má maximálny možný rozptyl. Tento postup opakujeme pokiaľ nenájdeme p -tu lineárnu kombináciu, kde p predstavuje pôvodný počet premenných. Predpokladom však je redukcia dimenzionality a preto sa očakáva, že väčšina rozptylu dátového súboru bude popísaná v prvých k hlavných komponentoch kde platí, že $k < p$.



Obr. 9 Porovnanie korelačných grafov pred PCA vľavo a po PCA vpravo


2.6 Implementácia strojového učenia

Strojové učenie je proces tvorby indukčného modelu, ktorý sa na základe obmedzeného množstva historických dát učí hľadať základné štruktúry alebo vzory, ktoré sú užitočné pre pochopenie vzťahov v údajoch, ktoré nemusia byť rovnaké ako tie, na ktorých sa učil.

Základom algoritmov proaktívnej a prediktívnej údržby sú modely strojového učenia. Tieto modely pracujú s indikátormi stavu, získanými napríklad metódami uvedenými v kapitole 3.4. Využitím indikátorov stavu určujú aktuálny stav systému alebo predpovedajú jeho budúci stav. V prvom prípade hovoríme o algoritmoch detekcie a diagnostiky poruchy. Tie predstavujú klasifikačné problémy. V druhom o algoritmoch predpovedajúcich zástávajúcu životnosť zariadenia. Tu hovoríme o regresných úlohách.

2.6.1 Detekcia a diagnostika poruchy – klasifikačné metódy

V klasifikácii alebo predikcii triedy, využívame informácie získané z pozorovaných nezávislých premenných na usporiadanie vzoriek dát do dvoch alebo viacerých tried či skupín. V zmysle proaktívnej údržby to znamená, že sa pokúšame určiť typ poruchy na základe jeho závislosti od indikátorov stavu. Klasifikačné problémy patria do skupiny strojového učenia nazývanej aj indukčné učenie s učiteľom. Existuje viacero klasifikačných algoritmov, pričom ich aplikácia závisí od konkrétnej úlohy a od povahy dostupného súboru údajov.




Obr. 10 Ilustrácia klasifikácie súboru dát

Rozhodovacie stromy – sú najviac intuitívnou a v dátovej analytike najfrekvencovanejšie využívanou klasifikačnou technikou jednoduchou na interpretáciu. Využíva súbor podmieňovacích pravidiel, ktoré sa učí postupne využitím tréningových dát jeden po druhom. Po naučení sa pravidla sa n-tica, na ktorú sa pravidlo vzťahuje odstráni. Tento proces pokračuje až do splnenia terminálnych podmienok. V každom prípade však musí byť odpoveď alebo cieľová premenná kategorického charakteru. Využitie rozhodovacích stromov ponúka efektivitu diagnostiky poruchy avšak dokáže identifikovať iba jednu poruchu v danom okamihu. Pri sledovaní porúch rotačných zariadení ako sú motory sa využívajú náhodné lesy ako moderná metóda, stavajúca mnoho rozhodovacích stromov pre zlepšenie klasifikácie. Variabilita týchto rozhodovacích stromov spočíva vo využití náhodných podmnožín datasetu, čo umožňuje náhodnému lesu pozrieť sa na dáta z viacerých perspektív a každý strom sa teda sústreďuje na jemné zmeny vzťahu medzi prediktorom a výsledkom predikcie (Kotu & Deshpande, 2019b; Lo et al. 2019; Mishra, 2018a).

Naivný Bayesovský klasifikátor – má základy v štatistike a teórií pravdepodobnosti. Využíva pravdepodobnostný vzťah medzi indikátorom stavu a triedou dát. Tento algoritmus vytvára silný predpoklad vzájomnej nezávislosti atribútov, ktorý nemusí byť pravdivý. Z tohto dôvodu je nazývaný naivný. Jeho výhody spočívajú v potrebe malého množstva tréningových dát, ale aj jednoduchej štruktúre, či vysokej výpočtovej rýchlosti a presnosti. Jednoduchosť a robustnosť algoritmu je kompenzovaná nedostatkami v podobe zavedených predpokladov. (Kotu & Deshpande, 2019b; Zhang, 2018).

Metóda podporných vektorov – inak nazývaná aj SVM predstavuje výkonný nástroj strojového učenia pre klasifikáciu údajov a predikciu, ktorý podáva výborné výsledky pri generalizácii využitím iba malého množstva tréningových dát. SVM odkazuje na multidisciplinárny charakter dátovej analytiky, nakoľko prepája tri vedné oblasti: počítačové vedy, matematickú štatistiku a matematickú optimalizáciu. Vo všeobecnosti sa SVM pokúša nájsť podporné vektory, predstavované dátovými bodmi, ktoré definujú takú hyperplochu, ktorá maximalizuje priestor medzi dátami jednotlivých tried. Množstvo podporných vektorov zvyšuje komplexnosť problému a preto s počtom tried klesá jeho účinnosť. V reálnych prípadoch z praxe však bývajú niektoré dátové body chybné klasifikované. Algoritmus SVM dátové body na nesprávnej strane hyperplochy penalizuje. To znamená, že je povolené limitované množstvo chybných klasifikácií. Ak dokážeme triedy separovať priamkou hovoríme o lineárnej SVM, v opačnom prípade o nelineárnej/kernelovej SVM. Metóda bola úspešne využitá v aplikáciách

diagnostiky poruchy analógového obvodu alebo známom Tennessee Eastmanovom industriálnom procese (Mishra, 2018a; Lo et al. 2019).



Obr. 11 Vľavo: dataset s úplne separovateľnými triedami. Nekonečné množstvo priamok by mohlo dávať nulovú chybu. Vpravo: lineárna separácia tried na základe metódy podporných vektorov. Čiernou farbou vyznačené dáta predstavujú podporné vektory (Kuhn, 2013).

2.6.2 Evaluácia klasifikačného modelu

Na validáciu kvality klasifikačných modelov sa využíva niekoľko hlavných nástrojov: matica zámeny (CM z angl. confusion matrix), krivka operačnej charakteristiky prijímača (ROC z angl. receiver operating characteristics) alebo plocha pod ROC krivkou (AUC z angl. area under an ROC curve). Najjednoduchšie pochopiteľnou metrikou je práve CM, ktorá je vhodná pre binomickú aj viac triedovú predikciu (Kotu & Deshpande, 2019d). V súvislosti s CM je dôležité porozumieť základným spôsobom vyhodnotenia presnosti klasifikácie:

Skutočne pozitívny prvok (TP z angl. True positive) – dostaneme, ak je predikovaná aj skutočná trieda pozitívna.

Falošne pozitívny prvok (FP z angl. False positive) – dostaneme, ak je predikovaná trieda pozitívna a skutočná trieda negatívna.

Falošne negatívny prvok (FN z angl. False negative) – dostaneme, ak je predikovaná trieda negatívna a skutočná trieda pozitívna.

Skutočne negatívny prvok (TN z angl. True negative) – dostaneme, ak je predikovaná aj skutočná trieda negatívna.

Základom CM je matica 2x2 kde sú predikované triedy usporiadané horizontálne v riadkoch a skutočné triedy vertikálne v stĺpcoch (Tab. 1). Ideálny stav klasifikácie je dosiahnutý vtedy, ak sú prvky nachádzajúce sa na diagonále väčšie ako 0 (TP a TN) a ostatné prvky rovné 0 (FP a FN).

Tab. 1 Matica zámeny (CM z angl. Confusion matrix)

		Skutočná trieda	
		Pozitívna	Negatívna
Predikovaná trieda	Pozitívna	TP	FP
	Negatívna	FN	TN

Predstavíme si niekoľko termínov, ktoré sa často využívajú v súvislosti s evaluáciou klasifikačného výkonu.

Citlivosť (z angl. sensitivity alebo recall) – je definovaná ako pomer skutočne odhalených tried ku všetkým relevantným prípadom. Je daná rovnicou 11.

$$Citlivosť = \frac{TP}{TP+FN} \quad (11)$$

Správnosť (z angl. precision) – je definovaná ako pomer správne predikovaných tried ku všetkým relevantným prípadom. Je daná rovnicou 12.


$$Správnosť = \frac{TP}{TP+FP} \quad (12)$$

Presnosť (z angl. accuracy) – je definovaná ako schopnosť klasifikátora vybrať všetky správne prípady a zamietnuť všetky nesprávne. V prípade 100% presnosti to znamená, že TP = 50% prípadov a zároveň TN = 50% prípadov.

$$Presnosť = \frac{TP+TN}{TP+FP+TN+FN} \quad (13)$$

2.6.3 Predikcia zostávajúcej životnosti – regresné metódy

Základom tejto metódy je fitovanie dát funkciou so snahou predpovedať vzdialenú budúcu hodnotu alebo triedu závislého atribútu, kombinovaním atribútov prediktorov. Fitovanie dát funkciou zahŕňa viacero techník. Najznámejšími sú lineárne regresné modely, využívané pri numerickej predikcii v prípadoch, kedy dokáže byť vzťah medzi prediktorom a odpoveďou interpretovaný využitím lineárnych závislostí a logistické regresné modely pre klasifikáciu. Problémom týchto modelov je, že s rastom množstva prediktorov sa znižuje schopnosť získať dobrý model a tiež interpretovateľnosť modelu (Kotu & Deshpande, 2019c; Mishra, 2018b).



Obr. 12 Ilustrácia lineárnej regresie a predikcie zostávajúcej životnosti

3 Cieľ práce

Cieľom bakalárskej práce je návrh algoritmu na identifikáciu stavu jednosmerného motora s komutátorom spracovaním a vyhodnotením procesných charakteristík zariadenia. Využijú sa pritom vibračné odtlačky jednosmerného motora získané neinvazívnymi metódami. Algoritmus má slúžiť ako základ automatizovaného systému, ktorý získané dáta využije na naučenie vhodne zvoleného mechanizmu strojového učenia, výsledkom ktorého bude digitálny model daného zariadenia. Tento model sa následne využije na predikciu nemerateľných veličín, ako i na krátkodobú predikciu potreby servisných zásahov.

4 Metodika práce a metódy skúmania


4.1 Objekt skúmania

Objektom nášho skúmania v tejto práci je planetárny jednosmerný elektromotor s komutátorom DSMP420-24-0104-BF. Ide o malý motor s uhlíkovými zberačmi a výstupným hriadeľom umiestneným v guľôčkovom ložisku. Na motore je osadená planétová prevodovka s frézovaným oceľovým ozubením. Pri našom skúmaní sa zameriame na jeho vibračné charakteristiky pri rôznych výkonových stupňoch a typoch uchytenia, za bežných podmienok, predstavujúcich izbovú teplotu a atmosférický tlak. V kapitole 2.1.2 sme uviedli, že mechanicky indukované vibrácie môžu byť zapríčinené nerovnováhou, nesprávnym uložením, nedostatočným príkonom a neúmerným zaťažením motora (pozri 2.1.2 Vibrácie elektrických motorov). Na základe uvedeného by mala zmena uvedených prevádzkových parametrov znamenať zmenu vibračných charakteristík, ktorú by sme mali byť schopní zaznamenať a na základe dát získaných ich sledovaním identifikovať indikátory stavu. S ich pomocou budeme predpovedať neznámy výkonový stupeň motora a jeho uchytenie.

4.2 Spôsob získavania údajov a ich zdroje

4.2.1 Hardvérové riešenia

Na získavanie vibračných dát meraných akcelerometricky, čo odpovedá absolútnym vibráciám zariadenia vzhľadom na gravitačné zrýchlenie Zeme, využijeme MEMS akcelerometrickú jednotku Accel Board - HW REV.2.02 osadenú akcelerometrickým senzorom ADXL330 s charakteristikami uvedenými v Tab. 2. Senzor ADXL330 je kompaktný trojosí akcelerometer s analógovými napäťovými výstupmi na jednom plošnom vodiči (Obr. 13).




Obr. 13 Technický nákres MEMS akcelerometrickej jednotky Accel Board - HW REV.2.02

Tab. 2 Tabuľka špecifikácií akcelerometrického senzora ADXL330

Parameter	Minimálne	Odporúčané	Maximálne	Jednotka
Merateľný rozsah	± 3	$\pm 3,6$	± 10	g
Vstupné napätie	$-0,3$		$7,0$	V
Citlivosť (x,y,z)	270	300	330	mV/g
Hustota šumu (x,y)		280		$\mu\text{g}/\sqrt{\text{Hz}}$ rms
Hustota šumu (z)		350		$\mu\text{g}/\sqrt{\text{Hz}}$ rms
Šírka pásma (x,y)		1600^*		Hz
Šírka pásma (z)		550^*		Hz
Operačná teplota	-25		70	°C

* hodnoty sú uvedené pre stav bez externého filtrovania signálu

Táto akcelerometrická jednotka je vodivo spojená s jednodoskovým počítačom Arduino 101 založenom no module Intel® Curie™ a vlastným vývojovým prostredím Arduino IDE.



Obr. 14 Technický náčrt jednodoskového mikropočítača Arduino 101

4.2.2 Softvérové riešenia


Na predspracovanie vibračných dát a identifikáciu indikátorov stavu sme využili možnosti programovacieho prostredia MATLAB s vlastným programovacím jazykom, ktorý priamo vyjadruje matice a polia. Integrované funkcie pre výpočty, vizualizácie a programovanie zjednodušujú riešenie problémov a sú jednoducho aplikovateľné pri tvorbe algoritmu na

sledovanie stavu zariadenia. Ponúka tiež pokročilé nástroje na predspracovanie dát, identifikáciu a testovanie indikátorov stavu a zostrojovanie modelov strojového učenia.

4.3 Pracovný postup

4.3.1 Pripojenie zariadenia a príprava pracovného prostredia

Jednosmerný motor sme dvoma skrutkami pevne upevnili zo strany hriadeľa na podložku. Na rovnakej podložke bol uchytený aj nastaviteľný regulátor príkonu s riadením pomocou impulzovej šírkovej modulácie (PWM) Kemo PowerControl DC 5A a meracia akcelerometrická jednotka Accel Board - HW REV.2.02. Jednosmerný motor sme vodivo spojili s nastaviteľným regulátorom príkonu podľa odporúčaného postupu a ten následne do elektrickej siete. Akcelerometrickú jednotku sme spolu s nastaviteľným regulátorom príkonu pripojili ku mikrokontroléru Arduino 101 pripojenému ku počítaču s príslušným softvérom. Pripojenie je znázornené na Obr. 15. Pre účely získavania dát sme sa pokúsili zabezpečiť dostatočnú izoláciu voči okolitým zdrojom vibrácií.



Obr. 15 Zobrazenie skutočného objektu skúmania a polohy akcelerometra

4.3.2 Postup merania a získavania dát

Pre účely získavania kvalitných vibračných dát sme vytvorili program v programovacom prostredí MATLAB. Program najprv nastaví výkon motora na maximálny a následne po dobu troch minút necháva motor spustený pre zvýšenie jeho teploty. Po prejdení tejto doby začína program vykonávať merania, opakované každú sekundu. To je doba, ktorá predstavuje periódu posielania dát z mikrokontroléra do počítača. Získané dáta zapisuje do riadkov tabuľky ako samostatné časové tabuľky pre každú meranú os, spolu s časom merania, identifikačným kódom motora, výkonnostným stupňom a numerickým označením pre typ uchytenia. Program vykoná 200 meraní a vypne motor na dve minúty pre jeho ochladenie. V ďalšej fáze nastaví výkon motora o desať percent nižší ako predošlý a postup merania opakuje, kým motor nedosiahne 0% výkonu, čo odpovedá jeho vypnutiu. Vtedy údaje zapísané v tabuľke uloží do počítača.

Tab. 3 Ukážka zaznamenaných údajov pre meranie uskutočnené na motore s identifikačným číslom 2 pri výkone 100% a uchytení typu 1.

No.	Time	Engine_ID	Vibration_X	Vibration_Y	Vibration_Z	Power	Mounted
1	03-May-2020 21:35:53	2	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	100	1
2	03-May-2020 21:35:54	2	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	100	1
3	03-May-2020 21:35:56	2	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	100	1
4	03-May-2020 21:35:57	2	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	100	1
5	03-May-2020 21:35:58	2	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	100	1
6	03-May-2020 21:35:59	2	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	100	1
7	03-May-2020 21:36:00	2	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	100	1
8	03-May-2020 21:36:01	2	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	100	1
9	03-May-2020 21:36:02	2	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	<i>2500x1 timetable</i>	100	1

Pre získanie vibračných dát rôzne uchyteného motora, je potrebné manuálne upraviť uchytenie pomocou dvoch skrutiek upevňujúcich motor ku podložke a upraviť numerické označenie typu uchytenia v programe. Túto informáciu si program pri každom spustení série meraní vypýta od používateľa a ponúkne mu známe možnosti uchytenia priradené ku numerickým hodnotám. Postup sme opakovali pre štyri elektromotory rovnakého typu.

Tab. 4 Tabuľka priradení typu uchytenia ku programovému označeniu

Typ uchytenia	Programové označenie typu uchytenia
Obe skrutky sú pevne utiahnuté	1
Obe skrutky sú povolené o 180°	0,75
Pravá skrutka pevne utiahnutá, bez ľavej skrutky	0,5
Ľavá skrutka pevne utiahnutá, bez pravej skrutky	0,25
Bez skrutiek	0

4.3.3 Postup predspracovania dát

Nakoľko výstupné vibračné dáta z akcelerometra predstavujú iba numerickú reprezentáciu a nemajú špecifikovanú jednotku, rozhodli sme sa ich škálovať využitím experimentálnych údajov a kalibračnej krivky na hodnoty predstavujúce násobky gravitačného zrýchlenia ($g = 9,81\text{m}\cdot\text{s}^{-2}$). V kapitole 2.2 sme uviedli, že meraním rýchlosti a zrýchlenia získavame informáciu o absolútnych vibráciách čo znamená, že akcelerometrom dokážeme merať statické gravitačné zrýchlenie Zeme (pozri 2.2 Získavanie dát). To nám poslúži ako referencia pre zostavenie kalibračnej čiary. Nakoľko meranie v jednotlivých osiach môže mať rôznu citlivosť presvedčili sme sa o rovnakej citlivosti zaznamenaním údajov pre rôzne polohy snímača tak, aby vždy smer merania v jednej osi bol oproti pôsobeniu gravitačnej sily. Potvrdilo sa nám, že odchýlka citlivosti merania je zanedbateľná. Z opakovaného merania sme zistili, že pri vodorovnej polohe akcelerometra, kedy sme predpokladali zrýchlenie 0 g v smere osí x a y a zrýchlenie 1 g v smere osi z, zodpovedala zrýchleniu 0 g v smere osí x a y hodnota 300 na zvislej osi grafu a zrýchleniu 1 g v smere osi z priemerná hodnota 360. Niekoľkými meraniami pri intenzívnom, náhodnom kmitavom pohybe akcelerometra sme zistili merateľný rozsah v neznámych hodnotách, ktorý bol 0 až 600. Získané údaje pre známe hodnoty gravitačného zrýchlenia sme aproximovali lineárnou funkciou za predpokladu lineárnej závislosti veličín. Extrapoláciou priamky sme odhadli zodpovedajúce gravitačné zrýchlenie pre krajný rozsah výstupných hodnôt merania a nastavili sme parametre škálovanej funkcie.

4.3.4 Identifikácia indikátorov stavu

Uložené dáta po zlúčení predstavujúce 40000 meraní sú posielané do programu, ktorý iteratívnym postupom pre každé meranie vypočíta hodnoty indikátorov stavu. V tomto kroku chceme vyextrahovať čo najviac indikátorov stavu, ktoré môžu niesť užitočné informácie o stave motora a ich správanie sa mení predvídateľným spôsobom. Ako indikátor stavu môže slúžiť každá hodnota, ktorá je závislá od skúmaného parametra. Aplikovaním poznatkov z kapitoly 2.4 vieme identifikovať nasledujúce indikátory: aritmetický priemer (mean), kvadratický priemer (rms), maximálna hodnota (max), vzdialenosť maxima a minima (peak2peak), činiteľ výkyvu (peaktorms), výberový koeficient špicatosti (kurtosis), výberový koeficient šikmosti (skewness), výberová smerodajná odchýlka (std) a tvarový faktor (shapefactor). Tieto indikátory vieme získať pre dáta zo všetkých osí a tiež dáta spracované fourierovou transformáciou. To predstavuje spolu 54 indikátorov stavu, pre každé jedno meranie. Identifikované indikátory stavu sú ukladané spolu s časom merania, identifikačným kódom motora, výkonnostným stupňom a numerickým označením pre typ uchytenia.

Tab. 5 Ukážka niektorých identifikovaných indikátorov stavu pre meranie uskutočnené na motore s identifikačným číslom 2 pri výkone 100% a uchytení typu 1.

No.	Time	Engine_ID	Power	Mounted	std_y	rms_y	mean_y	skewness_y	kurtosis_y
1	03-May-2020...	2	100	1	0,0305	0,0434	-0,0309	-0,1946	2,1484
2	03-May-2020...	2	100	1	0,0301	0,0432	-0,0310	-0,1809	2,2158
3	03-May-2020...	2	100	1	0,0312	0,0431	-0,0297	-0,1848	2,2447
4	03-May-2020...	2	100	1	0,0312	0,0431	-0,0297	-0,1848	2,2447
5	03-May-2020...	2	100	1	0,0315	0,0442	-0,0310	-0,1479	2,2423
6	03-May-2020...	2	100	1	0,0319	0,0443	-0,0308	-0,1447	2,2018
7	03-May-2020...	2	100	1	0,0312	0,0439	-0,0309	-0,2091	2,1603
8	03-May-2020...	2	100	1	0,0299	0,0415	-0,0288	-0,3286	2,3097
9	03-May-2020...	2	100	1	0,0299	0,0415	-0,0288	-0,3286	2,3097
10	03-May-2020...	2	100	1	0,0295	0,0421	-0,0300	-0,1600	2,3524
11	03-May-2020...	2	100	1	0,0308	0,0428	-0,0297	-0,2627	2,1813
12	03-May-2020...	2	100	1	0,0297	0,0424	-0,0303	-0,1865	2,1895
13	03-May-2020...	2	100	1	0,0297	0,0424	-0,0303	-0,1865	2,1895
14	03-May-2020...	2	100	1	0,0324	0,0441	-0,0300	-0,1998	2,2093

4.3.5 Vyhodnocovanie kvality indikátorov stavu

Kvalitu indikátorov stavu dokážeme vyhodnotiť rôznymi spôsobmi. Ako bolo uvedené v kapitole 2.5 jedným zo spôsobov hodnotenia kvality indikátorov stavu je ich vizualizácia. Tento spôsob hodnotenia je jednoduchý, avšak vyžaduje zvyčajne zdĺhavé a manuálne prehľadávanie jednotlivých grafických zobrazení a jeho úspešnosť často súvisí s dobrou znalosťou ich významu. Vizualizáciu preto využijeme ako jednu možnosť výberu vhodných indikátorov stavu a ponecháme len indikátory, ktoré zjavne preukazujú korelačnú závislosť s výkonovým stupňom alebo typom uchytenia. Kvalitu indikátorov stavu zvolených pomocou metód vizualizácie overíme na predikčnej úspešnosti modelu, ktorú porovnáme s úspešnosťou modelu natrénovanom na všetkých indikátoroch. Následne implementujeme analýzu hlavných komponentov, ktorá nám pomôže redukovať dimenzionalitu dátového súboru spôsobom, ktorý zachová najväčšiu disperziu medzi dátovými bodmi a zároveň jeho výstupom budú vzájomne nekorelované premenné. Táto metóda by mala značne zjednodušiť trénovaný model.

Je potrebné mať na pamäti, že indikátory stavu, ktoré dobre reprezentujú výkonový stupeň motora, môžu zlyhávať pri rozlišovaní typov uchytenia a naopak. Inak povedané, kvalita indikátorov stavu môže byť relatívna a hodnotená v závislosti od toho, ako vystihuje charakter skúmaného stavu motora. V tomto prípade sa zaujímate o rozlíšiteľnosť výkonového stupňa alebo typu uchytenia. V opačnom prípade môže indikátor stavu preukazovať kvalitu v absolútnom zmysle a dokážeme rozlíšiť výkonový stupeň aj typ uchytenia súčasne. Voľba kritérií hodnotenia je závislá od cieľov práce. V našom prípade sa pokúsime o vytvorenie kvalitného algoritmu strojového učenia s vysokou schopnosťou predpovedať stavy, avšak nie nutne v rámci jedného klasifikačného modelu. Preto pri hodnotení kvality indikátorov stavu pomocou vizualizácie berieme ohľad na kvalitu indikátorov stavu v relatívnom aj absolútnom zmysle a na základe toho vytvárame tri datasety.

Prvý dataset – pozostáva z ôsmich indikátorov stavu, ktoré sa na základe vizualizácie dát preukázali ako dobre rozlišujúce desať výkonových stupňov motora (10, 20, 30, 40, 50, 60, 70, 80, 90, 100% výkonu). Indikátory sme zhodnotili na základe subjektívneho prieskumu pomocou krabicových grafov z hľadiska rozptylu hodnôt a rozlišovacej schopnosti. Vysoká výsledná suma hodnotenia indikátora stavu hovorí o jeho vysokej kvalite a naopak (Tab. 6A). Najlepšie indikátory boli zvolené na základe najvyšších hodnôt a sú v Tab. 6 zvýraznené modrým podfarbením.

Tab. 6 Tabuľka subjektívneho prieskumu kvality indikátorov stavu pomocou krabicových grafov z hľadiska rozptylu hodnôt a rozlišovacej schopnosti. Na vytvorenie krabicového grafu bol použitý dátový súbor s 10000 meraniami pre motor s identifikačným označením 1 zahŕňajúcim merania pre všetky výkonové stupne a možnosti uchytenia na základe Tab. 4.

Indikátory v časovej oblasti (A/B)			Indikátory vo frekvenčnej oblasti (A/B)		
Indikátor	Rozptyl	Rozlíšenie	Indikátor	Rozptyl	Rozlíšenie
Std_x	4 / 1	3 / 1	Std_x	3 / 1	2 / 2
Std_y	5 / 1	4 / 1	Std_y	2 / 5	1 / 4
Std_z	5 / 1	4 / 1	Std_z	1 / 3	1 / 1
Shapefactor_x	4 / 1	2 / 1	Shapefactor_x	3 / 4	1 / 3
Shapefactor_y	5 / 1	4 / 1	Shapefactor_y	3 / 2	3 / 2
Shapefactor_z	5 / 1	4 / 1	Shapefactor_z	4 / 1	4 / 1
Rms_x	3 / 3	2 / 3	Rms_x	3 / 1	2 / 2
Rms_y	3 / 4	3 / 3	Rms_y	3 / 4	1 / 5
Rms_z	3 / 4	2 / 4	Rms_z	2 / 3	1 / 4
Mean_x	1 / 5	1 / 5	Mean_x	3 / 1	5 / 1
Mean_y	1 / 5	1 / 5	Mean_y	5 / 1	4 / 1
Mean_z	1 / 3	1 / 3	Mean_z	4 / 1	4 / 1
Skewness_x	4 / 3	3 / 1	Skewness_x	3 / 1	2 / 1
Skewness_y	3 / 4	1 / 2	Skewness_y	5 / 2	5 / 1
Skewness_z	3 / 1	2 / 1	Skewness_z	5 / 2	4 / 1
Kurtosis_x	4 / 5	2 / 1	Kurtosis_x	-	-
Kurtosis_y	4 / 3	3 / 1	Kurtosis_y	-	-
Kurtosis_z	3 / 3	2 / 1	Kurtosis_z	-	-
Peak2peak_x	-	-	Peak2peak_x	1 / 5	1 / 5
Peak2peak_y	-	-	Peak2peak_y	1 / 5	1 / 5
Peak2peak_z	-	-	Peak2peak_z	1 / 4	1 / 4
Peaktorms_x	4 / 3	1 / 1	Peaktorms_x	2 / 1	2 / 1
Peaktorms_y	2 / 2	1 / 1	Peaktorms_y	4 / 2	5 / 1
Peaktorms_z	3 / 2	1 / 2	Peaktorms_z	5 / 3	4 / 1
Max_x	-	-	Max_x	1 / 5	1 / 5
Max_y	-	-	Max_y	1 / 5	1 / 5
Max_z	-	-	Max_z	1 / 4	1 / 4

Legenda tabuľky:

- 5 – veľmi dobré hodnotenie; 4 – nízky; 3 – stredný ; 2 – vysoký; 1 – veľmi vysoký;
- (A) – hodnotenie kvality indikátorov výkonu, **modré podfarbenie** najlepších
- (B) – hodnotenie kvality indikátorov uchytenia, **zelené podfarbenie** najlepších
- (C) – **šedé podfarbenie** celkovo najlepšie hodnotené indikátory, prekryv zvýraznený

Druhý dataset – pozostáva z ôsmich indikátorov stavu, ktoré sa na základe vizualizácie dát preukázali dobrou rozlišovacou schopnosťou pre päť typov uchytenia (Tab. 4). Vysoká výsledná suma hodnotenia indikátora stavu hovorí o jeho vysokej kvalite a naopak (Tab. 6B). Najlepšie indikátory boli zvolené na základe najvyšších hodnôt a sú v Tab. 6 zvýraznené zeleným podfarbením.


Tretí dataset – pozostáva z ôsmich indikátorov stavu, ktoré v dôsledku komplikovanej vizualizácie 50 tried boli zvolené na základe najlepších hodnôt sumy rozlíšenia a rozptylu pre oddelené pozorovania výkonu a uchytenia.

Je dôležité uviesť, že niektoré indikátory zjavne neodpovedali stavu a boli vylúčené. Medzi týmito indikátormi stavu boli maximálna hodnota (max) a vzdialenosť maxima a minima (peak2peak) v časovej oblasti z dôvodu malej rozlišovacej schopnosti meracieho zariadenia a výberový koeficient špicatosti (kurtosis) vo frekvenčnej oblasti, ktorého anomálny charakter a veľké množstvo odľahlých hodnôt neodpovedal zmenám výkonu ani uchytenia. Preto ďalej v práci budeme za všetky indikátory považovať 45 zostávajúcich indikátorov, ktoré boli v Tab. 6 hodnotené.

Pri metóde analýzy hlavných komponentov dátového súboru sa stáva pojem relatívnej kvality v závislosti od charakteru skúmaného stavu absurdným sám o sebe. Primárnym dôvodom je, že táto metóda neberie ako taká ohľad na charakter spoločne združených dátových bodov a či sa odlišujú práve výkonovým stupňom alebo uchytením. Pri snahe zachovať v komponentoch informáciu iba o výkonovom stupni alebo uchytení, by sme túto metódu museli aplikovať na dátový súbor s meraniami homogénnymi pre nepozorované charakteristiky. Teda zabezpečiť, že sa uchytenie nebude meniť v čase pri pozorovaní výkonu a naopak. Toto však nie je možné v priemyselnej aplikácii na viacerých zariadeniach. Uvedeným nenaznačujeme úplnú neschopnosť poradiť si s klasifikáciou individuálnych charakteristík viacerých zariadení v priemysle. Ide len o fakt, ktorý môže znamenať náchylnosť na chyby predikcie.

Na základe týchto tvrdení môžeme sformulovať predpoklad, že hlavné prednosti tejto metódy sa ukážu pri trénovaní jedného modelu pre rozlišovanie oboch skúmaných charakteristík súčasne.

V prípade použitia metódy PCA je dôležité predspracovanie vstupných dát. Z dátového súboru odstránime dáta pre merania, ktoré mali aspoň tri indikátory odľahlé oproti ostatným indikátorom meraní pre rovnaký výkonový stupeň a uchytenie. Následne jednotlivé indikátory normalizujeme využitím ich z-skóre a aplikujeme PCA. Pre trénovanie modelov zvolíme taký počet komponentov, aby spolu objasňoval 95% disperzie dát, čo pre nás predstavovalo prvých 8 komponentov (Obr. 16).



Obr. 16 Graf zobrazenia hlavných komponentov. Červenou farbou sú vyznačené hlavné komponenty objasňujúce 95% disperzie dát.

4.3.6 Tvorba modelov strojového učenia

Na tvorbu modelov strojového učenia využívame v prvom kroku programovú aplikáciu Classification Learner v rámci programovacieho prostredia MATLAB. Aplikácia ponúka možnosť trénovať veľké množstvá algoritmov pre klasifikáciu dát využitím strojového učenia s učiteľom. To znamená, že pre dáta, z ktorých sa model učí, je známa správna výstupná hodnota. Tieto dáta sa súhrnne nazývajú trénovací dataset. Algoritmus sa pomocou trénovacieho datasetu učí pravidlá, pre úspešné klasifikovanie príslušnosti k určitej triede. Pri tvorbe modelov strojového učenia pre klasifikáciu je dôležitý relatívny pomer množstva trénovacích dát, ku počtu klasifikovaných tried. Z pravidla by malo byť pre dosiahnutie dobrých výsledkov množstvo trénovacích dát omnoho väčšie ako počet predikovaných tried. Bez ďalšieho overenia úspešnosti však môže dôjsť ku takzvanému „preučeniu“, kedy model úspešne vyhodnocuje triedy trénovacích dát, avšak pri predikcii stavu na základe iných dát úspešnosť zlyháva. Z tohto dôvodu sa úspešnosť modelu overuje na testovacom datasete, o ktorom model pri učení sa nevie. O dobrom modeli môžeme hovoriť ak má rovnakú alebo blízku úspešnosť predikcie pre trénovacie aj testovacie dáta. V prípade splnenia tejto podmienky dobrého modelu, môžeme využiť indikátory stavu inej skupiny meraní pre optimalizáciu hyperparametrov, ktoré predstavujú ukryté parametre modelov strojového učenia. Optimalizáciou hyperparametrov dokážeme s vysokou úspešnosťou zabrániť preučeniu modelov strojového učenia.

V rámci aplikácie Classification Learner sme natrénovali všetky dostupné algoritmy pre dátový súbor pozostávajúci zo 40000 meraní pre štyri rôzne motory pri rôznych výkonových stupňoch a typoch uchytenia a zvolili sme najlepší na základe presnosti na validačnom datasete,

ktorý predstavoval 25% náhodne zvolených prvkov datasetu nevyužitých pri trénovaní algoritmu, pri predikcii výkonu, uchytenia a súčasne výkonu a uchytenia. Zo všetkých modelov a rôznych kombinácií predspracovania indikátorov (škálovanie, odstránenie odľahlých hodnôt, analýza hlavných komponentov) sa jednoznačne javil náhodný les ako najlepší algoritmus na predikciu. V priemere bola presnosť náhodného lesa na validačnom datasete vyššia ako 90% a čas trénovania modelov sa pohyboval okolo 100 sekúnd pri využití všetkých indikátorov. Na základe veľmi dobrých výsledkov sme sa rozhodli pri ďalšom riešení postupovať s využitím modelov náhodného lesa. Vytvorili sme jeden spoločný model náhodného lesa, ktorého parametre sú uvedené v Tab. 7 a na základe predikovaných tried a využitých indikátorov sme optimalizovali všetky jeho hyperparametre, čím sme získali 9 optimalizovaných modelov náhodného lesa špecificky podľa ich aplikácie. Optimalizované parametre modelov sú zhrnuté v Tab. 8.

Tab. 7 Parametre neoptimalizovaného modelu náhodného lesa

Parametre modelu	Výkon a uchytenie
Metóda	<i>Bag</i>
Maximálny počet rozdelení	<i>38113</i>
Počet agentov	<i>30</i>

Tab. 8 Parametre optimalizovaných modelov náhodného lesa

Použité indikátory	Všetky indikátory	8 indikátorov zvolených	Prvých 8 hlavných komponentov z	
Predikcia	stavu	vizualizáciou	PCA	Parametre modelu
Výkon	<i>Bag</i>	<i>Bag</i>	<i>Bag</i>	Metóda
	<i>8058</i>	<i>7887</i>	<i>27832</i>	Max. počet rozdelení
	<i>454</i>	<i>478</i>	<i>346</i>	Počet agentov
	-	-	-	Miera učenia
Uchytenie	<i>Bag</i>	<i>Bag</i>	<i>Bag</i>	Metóda
	<i>14948</i>	<i>32652</i>	<i>2466</i>	Max. počet rozdelení
	<i>431</i>	<i>181</i>	<i>192</i>	Počet agentov
	-	-	-	Miera učenia
Výkon a uchytenie	<i>AdaBoost</i>	<i>AdaBoost</i>	<i>Bag</i>	Metóda
	<i>1696</i>	<i>3177</i>	<i>5342</i>	Max. počet rozdelení
	<i>397</i>	<i>223</i>	<i>13</i>	Počet agentov
	<i>0,99912</i>	<i>0,99921</i>	-	Miera učenia


Pri optimalizácii hyperparametrov sme využili Bayesovskú optimalizáciu s 50 iteráciami a zostrojili graf minimálnej chyby klasifikácie (Obr. 17). Graf zobrazuje nasledujúce informácie:

Odhadovaná minimálna chyba klasifikácie - zodpovedá odhadu vypočítanému optimalizačným procesom pri zväžení doterajších množín hyperparametrov.

Zistená minimálna klasifikačná chyba - zodpovedá najlepšej doteraz pozorovanej minimálnej klasifikačnej chybe vypočítanej optimalizačným procesom.

Najlepší bod hyperparametrov – odpovedá výsledkom optimalizácie. Získané parametre nie vždy odpovedajú minimálnej zistenej klasifikačnej chybe, ale minimalizujú hornú hranicu intervalu spoľahlivosti.

Hyperparametre minimálnej chyby – odpovedá parametrom pri minimálnej zistenej klasifikačnej chybe.



Obr. 17 Graf minimálnej chyby klasifikácie pre optimalizovaný model.

5 Výsledky práce

V práci sme využívali 1 univerzálny digitálny model náhodného lesa a 9 modelov náhodných lesov, optimalizovaných špecificky pre potreby danej klasifikácie a využité prediktory. Všetky modely boli vyexportované z aplikácie Classification Learner. Tieto modely sme učili na tréningovom datasete pozostávajúcom z 24298 meraní. Pre každý z troch klasifikačných problémov boli využité tri rôzne sady prediktorov.

Prvá sada prediktorov pozostávala zo 45 indikátorov stavu uvedených v kapitole 4.3.5 Vyhodnocovanie kvality indikátorov stavu.

Druhá sada prediktorov obsahovala 8 indikátorov stavu zvolených vizualizačnými technikami, ktoré sú uvedené v Tab 6.

Tretia sada prediktorov predstavovala prvých 8 hlavných komponentoch získaných metódou PCA, ktoré zodpovedali 95,23% objasnenej variability dát.

Následne sme predikovali stav rovnakých zariadení, aké boli použité pri učení, na základe nových dát. Predikčnú úspešnosť modelov sme zhodnotili dvoma validáciami presnosti. Prvá bola validácia modelov na automaticky a náhodne oddelených 25 percentách meraní z dátového súboru ako testovací dataset pred učením, čo predstavovalo 8099 meraní. Druhá validácia bolo overenie presnosti na validačnej vzorke datasetu, ktorá nevstupovala do programu a bola manuálne oddelená, ktorá predstavovala 5717 meraní. Výsledky a pozorovania budú v nasledujúcich riadkoch zhrnuté.

Všetky funkcie a zdrojové kódy využité v metodologickej časti práce a výsledkoch práce sú spolu s ukážkou získaných vibračných dát a digitálnych modelov uverejnené na nasledujúcom webovom portály: https://github.com/MarekWadinger/bachelors_thesis

5.1 Klasifikácia výkonového stupňa


Využitím strojového učenia sme predikovali 10 výkonových stupňov štyroch jednosmerných elektromotorov s komutátorom DSMP420-24-0104-BF. Univerzálny neoptimalizovaný model náhodného lesa sme učili na troch rôznych sadách prediktorov. Vyhodnotili sme testovaciu a validačnú presnosť predikcie spolu s časom učenia (Tab. 9A). Následne sme využili modely s optimalizovanými hyperparametrami a zopakovali sme vyhodnotenie (Tab. 9B). Uvedené hodnoty v tabuľke sú aritmetickým priemerom výsledkov piatich učení s uvedenou smerodajnou odchýlkou.

Tab. 9 Výsledky predikčnej úspešnosti a časov tréovania pri klasifikácií výkonového stupňa.


	Použité indikátory	Všetky indikátory	8 indikátorov zvolených vizualizáciou	Prvých 8 hlavných komponentov z PCA
	Vyhodnotené parametre	stavu	vizualizáciou	PCA
(A)	Testovacia presnosť [%]:	92,7 ± 0,5	82,5 ± 0,4	89,2 ± 0,2
	Validačná presnosť [%]:	93,9 ± 0,3	85,4 ± 0,3	90,7 ± 0,2
	Čas tréovania modelu [s]:	5,9 ± 0,6	3,6 ± 0,1	4,0 ± 0,1
(B)	Testovacia presnosť [%]:	93,6 ± 0,2	83,0 ± 0,6	89,6 ± 0,3
	Validačná presnosť [%]:	94,8 ± 0,1	86,4 ± 0,1	91,6 ± 0,2
	Čas tréovania modelu [s]:	83 ± 2	88 ± 2	56 ± 1

Na základe Tab. 9 môžeme zhodnotiť, že najvyššou presnosťou sa preukázali modely naučené na všetkých indikátoroch stavu. Pri porovnaní modelov učených na 8 parametroch vidíme lepšie výsledky pri využití hlavných komponentov z PCA. Optimalizované modely sa vo všetkých prípadoch preukázali ako presnejšie, avšak na úkor času tréovania, ktorý vypovedá o komplexnosti modelov. V časoch tréovania neoptimalizovaného modelu odhadujeme závislosť od počtu prediktorov využitých pri tréovaní. Tento odhad však môže byť vyvrátený tréovaním viacerých modelov s rôznym počtom prediktorov. Čas tréovania optimalizovaného modelu na prvých 8 hlavných komponentoch z PCA je výrazne nižší ako čas tréovania ostatných optimalizovaných modelov. To na prvý pohľad vypovedá o tom, že hlavné komponenty sú lepšími prediktormi. Vierohodnejším pohľadom je však prikladanie dôležitosti výrazne odlišným parametrom optimalizovaného modelu na základe Tab. 8, ktoré môžu byť priamym dôsledkom prvého pohľadu.


Výsledné hodnoty presnosti nám podľa definície z kapitoly 2.6.2 Evaluácia klasifikačného modelu hovoria vo všeobecnosti o schopnosti správne klasifikovať jednotlivé prípady. V prípade klasifikácie viacerých tried je však jej výpovedná hodnota veľmi malá a nedokáže nám napovedať o presnosti predikcie jednotlivých tried. Využili sme preto CM na vyhodnotenie citlivosti a správnosti univerzálného modelu, ako jednotnej referencie pri porovnávaní (Obr. 18, 19, 20). Percentuálne údaje pod maticou predstavujú správnosť predikcie v prvom riadku a chybu správnosti v druhom (doplnok správnosti ku 100%) a tie napravo od matice citlivosti v prvom stĺpci vľavo a chybu citlivosti vpravo.



Obr. 18 CM 4. učenia univerzálneho modelu náhodného lesa pri klasifikácii 10 výkonových stupňov využitím všetkých indikátorov stavu.



Obr. 19 CM 2. učenia univerzálneho modelu náhodného lesa pri klasifikácii 10 výkonových stupňov využitím 8 indikátorov zvolených vizualizáciou.



Obr. 20 CM 2. učenia univerzálneho modelu náhodného lesa pri klasifikácii 10 výkonových stupňov využitím prvých 8 hlavných komponentov z PCA.

Na základe CM môžeme tvrdiť, že najnižšia správnosť predikcie bola zaznamenaná pri nižších výkonových stupňoch v prípade každého modelu, kedy model chybné predpovedal o jednu triedu nižší prípadne vyšší výkonový stupeň. Najhoršie hodnoty dosahoval vo všetkých prípadoch model trévaný na 8 indikátoroch zvolených vizualizáciou. Najväčšej odchýlky predikcie od skutočnosti sa dopustil v dvoch prípadoch a to pri nesprávnom určení najvyššieho výkonového stupňa ako 60% výkonu a najnižšieho ako 50 % výkonu. Prvá odchýlka by mohla viesť ku domnienke, že zariadenie potrebuje údržbu pred uplynutím životnosti dielcov a druhá neskorú reakciu na kriticky nízky výkon.

5.2 Klasifikácia uchytenia


V tejto časti práce sa budeme venovať výsledkom predikcie 5 typov uchytenia elektromotora podľa Tab. 4. Tieto typy boli rozlíšené v rámci možností, ktoré boli realizovateľné úpravou utiahnutia dvoch skrutiek upevňujúcich elektromotor ku podložke. Univerzálny neoptimalizovaný model náhodného lesa sme učili na troch rôznych sadách prediktorov. Vyhodnotili sme testovaciu a validačnú presnosť predikcie spolu s časom učenia (Tab. 10A). Následne sme využili modely s optimalizovanými hyperparametrami a zopakovali sme vyhodnotenie (Tab. 10B). Uvedené hodnoty v tabuľke sú aritmetickým priemerom výsledkov piatich učení s uvedenou smerodajnou odchýlkou.

Tab. 10 Výsledky predikčnej úspešnosti a časov tréovania pri klasifikácii uchytenia.


	Použité indikátory	Všetky indikátory	8 indikátorov zvolených vizualizáciou	Prvých 8 hlavných komponentov z PCA
	Vyhodnotené parametre	stavu		
(A)	Testovacia presnosť [%]:	96,9 ± 0,2	74,3 ± 0,4	94,5 ± 0,4
	Validačná presnosť [%]:	97,6 ± 0,1	78,5 ± 0,2	95,1 ± 0,1
	Čas tréovania modelu [s]:	5,3 ± 0,2	4,0 ± 0,1	3,6 ± 0,1
(B)	Testovacia presnosť [%]:	97,3 ± 0,3	75,4 ± 0,5	94,2 ± 0,2
	Validačná presnosť [%]:	98,0 ± 0,1	78,8 ± 0,2	95,6 ± 0,1
	Čas tréovania modelu [s]:	66 ± 2	40,8 ± 0,6	31,9 ± 0,3

Na základe údajov zhrnutých v tabuľke jasne vidíme, že indikátory zvolené vizualizáciou ako prediktory dávali najnižšiu presnosť predikcie. Učenie sa na hlavných komponentoch z PCA dávalo modelu presnosť iba o 3% nižšiu ako bola presnosť dosahovaná použitím všetkých


indikátorov pri výrazne nižšom čase tréovania. Ďalšie aspekty evaluácie modelov boli vyhodnotené na základe CM (Obr. 21,22,23).



Obr. 21 CM 4. učenia univerzálneho modelu náhodného lesa pri klasifikácii 5 typov uchytenia využitím všetkých indikátorov stavu.



Obr. 22 CM 3. učenia univerzálneho modelu náhodného lesa pri klasifikácii 5 typov uchytenia využitím 8 indikátorov zvolených vizualizáciou.



Obr. 23 CM 4. učenia univerzálneho modelu náhodného lesa pri klasifikácii 5 typov uchytenia využitím prvých 8 hlavných komponentov z PCA.

Výsledky z CM spolu ukazujú, že najväčšiu chybu správnosti mali modely pri predikcii uvoľnenia oboch skrutiek (programová hodnota 0.75). Táto chyba môže byť spôsobená nehomogénnym uvoľnením skrutiek pri všetkých meraniach a tým pádom mohol byť pre tento program stav vyhodnotiteľný ako akýkoľvek iný v závislosti od momentu sily utiahnutia, ktorý mohol byť vyšší alebo nižší ako predpokladaný a rovnako sa mohol líšiť na ľavej a pravej skrutke.

5.3 Klasifikácia výkonového stupňa a uchytenia

V poslednej podkapitole výsledkov práce zhrnieme výsledky predikcie 50 tried ako kombinácií všetkých typov uchytenia a výkonových stupňov. Táto časť práce sa vyznačovala najdlhšími časmi tréningovania a komplikovanejšou interpretáciou výsledkov. Postup tréningovania modelov bol rovnaký ako v skorších príkladoch a výsledky sme zhrnuli v Tab. 11A pre neoptimalizovaný model a v Tab. 11B pre optimalizované modely.

Tab. 11 Výsledky predikčnej úspešnosti a časov tréningovania pri klasifikácii výkonového stupňa a uchytenia.

	Použité indikátory	Všetky indikátory	8 indikátorov zvolených vizualizáciou	Prvých 8 hlavných komponentov z PCA
	Vyhodnotené parametre	stavu		
(A)	Testovacia presnosť [%]:	92,3 ± 0,3	86,3 ± 0,5	87,0 ± 0,4
	Validačná presnosť [%]:	93,3 ± 0,1	89,0 ± 0,1	89,5 ± 0,3
	Čas tréningovania modelu [s]:	10,7 ± 0,1	7,8 ± 0,5	9,3 ± 0,2
(B)	Testovacia presnosť [%]:	93,3 ± 0,2	87,6 ± 0,1	87,9 ± 0,6
	Validačná presnosť [%]:	94,6 ± 0,0	89,9 ± 0,0	90,2 ± 0,1
	Čas tréningovania modelu [s]:	664 ± 8	119,7 ± 0,7	155 ± 2

Z tabuľky sú opäť zjavné najvyššie presnosti pre modely tréningované na všetkých prediktoroch a druhé najlepšie pre modely využívajúce hlavné komponenty z PCA. Redukcia dimenzionality dátového súboru potvrdila aj v tomto prípade, že s ňou súvisia kratšie časy tréningovania modelov, čo v tomto prípade znamená až štvornásobne kratší čas pre optimalizované modely. Predpoklad vyslovený v kapitole 4.3.5 Vyhodnocovanie kvality indikátorov, ktorý očakával vyššiu relatívnu presnosť modelov tréningovaných na hlavných komponentoch sa nepotvrdil v porovnaní s ostatnými modelmi. Rozdiel presnosti medzi modelmi používajúcimi 8 hlavných komponentov a tými, ktoré využívajú 8 indikátorov zvolených vizualizáciou je v priemere desať krát menší ako priemerný rozdiel medzi modelmi tréningovanými na 8 hlavných komponentoch a tými na všetkých indikátoroch. Dôkladnejšie preskúmanie využitím CM naznačilo už pozorované trendy. Teda modely mali nižšiu mieru správnosti predikcie pri nižších výkonových stupňoch a typoch uchytenia, kedy boli obe skrutky plne utiahnuté alebo obe uvoľnené. Zaujímavým pozorovaním je, že v prípadoch voľného uchytenia, kedy sme očakávali veľkú disperziu a teda aj chybovosť bola správnosť predikcie najvyššia (Obr 24, 25, 26).

[illegible][illegible]

Obr. 24 CM 2. učenia univerzálneho modelu náhodného lesa pri klasifikácii výkonu a uchytania využítím všetkých indikátorov.

[illegible][illegible]

Obr. 25 CM 1. učenia univerzálneho modelu náhodného lesa pri klasifikácii výkonu a uchytenia využitím 8 indikátorov zvolených vizualizáciou.

[illegible]

Obr. 26 CM 5. učenia univerzálneho modelu náhodného lesa pri klasifikácii výkonu a uchytenia využitím prvých 8 hlavných komponentov z PCA.

6 Diskusia

Vo výsledkoch práce sme sa presvedčili, že dokážeme klasifikovať výkonnostný stupeň a uchytenie motora na základe identifikovaných indikátoroch stavu. Najlepšie výsledky predikcie sme získavali pri modeloch, ktoré využívali na svoje tréovanie väčšie množstvo prediktorov, čo sa však nevyhnutne prejavilo na dlhších časoch tréovania modelov. Redukciou dimenzionality priestoru vizuálnou selekciou 8 indikátorov a využitím analýzy hlavných komponentov (PCA) na získanie 8 parametrov s najvyššou disperziou sme ďalej skúmali vplyv, dimenzionality a PCA na kvalitu modelov. Na základe výsledkov konštatujeme, že voľba kvalitných indikátorov stavu pomocou vizualizácie je kritická, pre celkovú presnosť takéhoto modelu. Tento postup však predstavuje zdĺhavé manuálne prehľadávanie dát zobrazených rôznymi vizuálnymi technikami, ktoré nemusia vždy viesť ku voľbe indikátorov najvhodnejších pre učenie konkrétneho modelu. PCA tento proces značne zjednodušila automatizovaným hľadaním navzájom nekorelovaných parametrov s najväčším rozptylom vo vektorovom priestore. S rovnakým počtom prediktorov, predstavujúcich v tomto prípade hlavné komponenty sa nám podarilo dosiahnuť vyššiu presnosť predikcie na testovacom aj validačnom dátovom súbore a tým pádom preukázať, prečo je táto najstaršia technika viacrozmerovej analýzy veľmi vhodná pre podobné aplikácie a dôležitá v aplikáciách, kde počet parametrov je veľmi vysoký.

Úspešnosť predikcie by bolo možné zvýšiť viacerými spôsobmi. Voľbou kvalitnejšej akcelerometrickej jednotky by bolo možné získať lepšie vibračné dáta. V súvislosti so zberom dát je dôležité aj to, aby mikrokontrolér umožňoval využitie plného potenciálu akcelerometra, čo závisí od množstva informácií, ktoré dokáže uchovať, spracovať a poslať do počítača. Úpravou umiestnenia meracieho člena na základni prípadne pripevnením na motor by bolo možné nájsť polohu, kde vibrácie podliehajú najnižšiemu skresleniu. Zaznamenaním uhlovej rýchlosti hriadeľa a preskúmaním prevodov by sme mohli byť schopný zaznamenať informáciu o frekvencii vibrácií súvisiacich s rotačným pohybom a tým pádom filtrovať efektívne šum merania. Ďalej zapojením meracieho člena teploty motora, by sme dokázali sledovať, akým spôsobom vplýva teplota na vibračné charakteristiky. Počas experimentu na motore sme mali možnosť pozorovať, že sa hodnoty indikátorov stavu spojito a málo výrazne menili v čase počas priebehu počiatočných experimentov za konštantného výkonu a uchytenia, čo sme pripisovali zmene prevádzkovej teploty. Preto by bolo ďalším logickým krokom zmerať experimentálne vplyv prevádzkovej teploty na zmenu vibračných charakteristík a preskúmať, ako sa prejavuje na úspešnosti predikcie. Nakoľko sme sa v práci nevenovali vplyvu teploty, pokúsili sme sa jej

negatívny dopad eliminovať predohriatím zariadenia pred uskutočnením série meraní a tiež rozdeliť merania na intervaly, medzi ktorými malo zariadenie možnosť znížiť svoju teplotu. Identifikovaním väčšieho množstva indikátorov stavu, ktoré by vypovedali o výkone alebo uchytaní by sme mali možnosť získať lepšie informácie o stave zariadenia a ďalej zvýšiť úspešnosť klasifikácie. Posledným návrhom zlepšenia algoritmu je dizajnovanie indikátorov stavu (z angl. feature engineering), ktoré by nám dalo možnosť ďalej upraviť indikátory a vytvoriť nové, ktoré by prepájali informácie niekoľkých parametrov spôsobom, ktorý by zdôrazňoval klasifikačné hranice medzi dvoma sledovanými stavmi zariadenia.

7 Záver

V bakalárskej práci sme riešili problematiku prediktívnej dátovej analytiky s využitím strojového učenia. Preskúmaním súčasného stavu riešenia problematiky sme sa oboznámili s hlavnými stratégiami plánovania údržby a na základe štatistických údajov sme spoznali ich súčasné využitie v priemysle. Zhrnuli sme teoretické poznatky ku skúmanej tematike využitím literatúry, vedeckých prác a reportov, v ktorých sme opísali jednotlivé tvorby algoritmu strojového učenia a prípravy dát. Výstupy z tejto časti práce nám poslúžili ako základný stavebný kameň pre návrh vlastného algoritmu na identifikáciu stavu planetárneho jednosmerného elektromotora s komutátorom DSMP420-24-0104-BF, ako objektu zastupujúceho elektromotory početne využívané v priemyselných aplikáciách. V metodickej časti práce sme identifikovali objekt skúmania a popísali hardvérové a softvérové riešenia. V pracovnom postupe sme uviedli chronologickú postupnosť návrhu algoritmu, ktorá pozostávala súhrnne z piatich krokov.

1. Získavanie vibračných dát
2. Predspracovanie dát
3. Identifikácia indikátorov stavu
4. Vyhodnotenie kvality indikátorov stavu
5. Tvorba modelov strojového učenia

Výstupom z algoritmu boli digitálne modely strojového učenia, ktoré sa na základe získaných dát učili hľadať abstraktné súvislosti a predikovať výkonový stupeň a uchytenie elektromotora. Vo výsledkoch práce sme zhodnotili úspešnosť modelov strojového učenia z hľadiska ich presnosti, citlivosti a správnosti pri predikovaní uchytenia a výkonu motora. Všetky modely využité vo výsledkoch práce boli modely náhodných lesov, nakoľko sa vyznačovali najvyššou úspešnosťou predikcie na testovacom dátovom súbore. Okrem toho náhodné lesy sú menej náchylné na pretrénovanie a pozostávajú z rozhodovacích stromov, ktoré sú sami o sebe jednoduchými klasifikačnými algoritmami. Na základe dobrých výsledkov evaluačných metrík hodnotíme, že navrhnutý algoritmus vieme úspešne využiť na predikciu stavu zariadenia z nameraných procesných charakteristík. Navyše sa nám podarilo analyzovať hlavné komponenty a zjednodušiť model tak, aby dokázal iba pomocou ôsmich takýchto komponentov robiť podobne úspešné predikcie ako model trénovaný na 45 indikátoroch stavu. Na základe požiadaviek na minimálnu úspešnosť predikcie, by bolo možné ďalej testovať minimálny počet hlavných komponentov potrebný na splnenie tejto požiadavky. S redukciou dimenzionality dátového súboru sa spájal aj kratší čas na učenie jednotlivých modelov.

Nakoľko sa predpokladá, že abnormálna zmena uchytenia a výkonnostný stupeň v dôsledku vznikajúcej poruchy sa nevyskytuje okamžite a zvyčajne vieme sledovať proces degradácie z prevádzkového stavu do poruchového, dokážeme robiť krátkodobé predikcie potreby údržby zariadenia na základe výstupov z algoritmu v reálnom čase. Zo záverov práce vyplýva ako otvorená otázka možnosť tvorby algoritmu strednodobej a dlhodobej predikcie, využívajúceho regresnú analýzu. Výstupný model regresnej analýzy by dokázal na základe trendov zmeny stavu zariadenia, určiť budúci stav zariadenia a teda pomôcť pri plánovaní servisného zásahu do budúcnosti. Pre takýto model, by sme však potrebovali merania z dlhšieho časového obdobia pre zariadenie vykazujúce v danom čase určitý trend degradácie.

Zoznam použitej literatúry

- ÁGOSTON, K. 2015. Fault Detection of the Electrical Motors Based on Vibration Analysis. ISSN 2212-0173, 2015, vol. 19, s. 547-553.
- BEEBE, R.S. 2004. Predictive Maintenance of Pumps Using Condition Monitoring. ISBN 1856174085, 2004.
- BERTOLINI, T. 2012. Vibrations and Noises in Small Electric Motors. ISBN 978-3-86236-035-2, 2011.
- BOYCE, M.P. 2012a. 16 - Spectrum Analysis. In Gas Turbine Engineering Handbook (Fourth Edition). ISBN 9780123838421, 2012, s. 651-673.
- BOYCE, M.P. 2012b. 19 - Control Systems and Instrumentation. In Gas Turbine Engineering Handbook (Fourth Edition). ISBN 9780123838421, 2012, s. 721-768.
- CEKAN, P. et al. 2015. Analysis of Deviation In The Measurement Of Vibrations. In Research Papers Faculty of Materials Science and Technology Slovak University of Technology, Sciendo, vol. 23(36), s. 9-15.
- DEIGHTON, M.G. 2016. Chapter 5 - Maintenance Management. In Facility Integrity Management. ISBN 9780128017647, 2016, s. 87-139.
- DELOITTE. 2017. Predictive Maintenance. Position Paper - Deloitte Analytics Institute [online]. Issue 7/2017. [cit. 2020.04.20] Dostupné na internete: https://www2.deloitte.com/content/dam/Deloitte/de/Documents/deloitte-analytics/Deloitte_Predictive-Maintenance_PositionPaper.pdf
- HUGHES, A. – DRURY, B. 2019. Chapter 3 - D.C. motors. In Electric Motors and Drives (Fifth Edition). ISBN 9780081026151, 2019, s. 89-129.
- ISERMANN, R. 2006. Fault-Diagnosis Systems: In an Introduction from Fault Detection to Fault Tolerance, Springer. ISBN 978-3-540-30368-8.
- KIM, S. 2017. Chapter 1 - Fundamentals of electric motors. In Electric Motor Control, Elsevier. ISBN 9780128121382, 2017, s.1-37.
- KOTU, V. – DESHPANDE, B. 2019a. Chapter 3 - Data Exploration. In Data Science (Second Edition). ISBN 9780128147610, 2019, s. 39-64.
- KOTU, V. – DESHPANDE, B. 2019b. Chapter 4 - Classification. In Data Science (Second Edition). ISBN 9780128147610, 2019, s. 65-163.
- KOTU, V. – DESHPANDE, B. 2019c. Chapter 5 - Regression Methods. In Data Science (Second Edition). ISBN 9780128147610, 2019, s. 165-197.

- KOTU, V. – DESHPANDE, B. 2019c. Chapter 8 – Model Evaluation. In Data Science (Second Edition). ISBN 9780128147610, 2019, s. 263-279.
- KRUPITZER, Ch. et al. 2020. A Survey on Predictive Maintenance for Industry 4.0.
- KUHN, M. – JOHNSON, K. 2013. Chapter 13 - Nonlinear Classification Models. In Applied Predictive Modeling, Springer. ISBN 978-1-4614-6849-3, 2013, s. 329-367.
- LEI, Y. 2017a. 1 - Introduction and background. In Intelligent Fault Diagnosis and Remaining Useful Life Prediction of Rotating Machinery, Butterworth-Heinemann. ISBN 9780128115343, 2017, s. 1-16.
- LEI, Y. 2017b. 2 - Signal processing and feature extraction. In Intelligent Fault Diagnosis and Remaining Useful Life Prediction of Rotating Machinery, Butterworth-Heinemann. ISBN 9780128115343, 2017, s. 17-66.
- LO, N. et al. 2019. Review of Machine Learning Approaches in Fault Diagnosis applied to IoT System. In International Conference on Control, Automation and Diagnosis ICCAD'19.
- MISHRA, S. – DATTA-GUPTA, A. 2018a. Chapter 8 - Data-Driven Modeling. In Applied Statistical Modeling and Data Analytics, Elsevier. ISBN 9780128032794, 2018, s. 195-224.
- MISHRA, S. – DATTA-GUPTA, A. 2018b. Chapter 4 - Regression Modeling and Analysis. In Applied Statistical Modeling and Data Analytics, Elsevier. ISBN 9780128032794, 2018, s. 69-96.
- MITAL, Al. et al. 2014. Designing for Maintenance, In Product Development (Second Edition), Elsevier. ISBN 9780127999456, 2014, s. 203-268.
- OKOH, P. – HAUGEN, S. 2013. Maintenance-related major accidents: Classification of causes and case study. In Journal of Loss Prevention in the Process Industries. 26.
- OSSWALD, G. 2019. Vibration analysis for predictive maintenance of a rotary pump. Štokholm: Kth Royal Institute of Technology School of Industrial Engineering and Management, 2019.
- PELLICCIONE, A. – VAVRA, B. 2019. 2019 Plant Engineering Maintenance Report [online]. [cit. 2020.05.25] Dostupné na internete: <https://www.plantengineering.com/articles/a-race-against-time/>
- PENG, Y. et al. 2010. Current status of machine prognostics in condition-based maintenance: a review. In the International Journal of Advanced Manufacturing Technology. s. 97–313.
- RAHMAN, M.F. 2018. 30 - Motor Drives. In Power Electronics Handbook (Fourth Edition). ISBN 9780128114070, 2018, s. 945-1021.
- SHIN, J. – JUN, H. 2015. On condition-based maintenance policy. In Journal of Computational Design and Engineering. ISSN 2288-4300, 2015, vol. 2, no. 2, s. 119-127.

- VEČERŮ, P. et al. 2005. Condition Indicators for Gearbox Condition Monitoring Systems. In Acta Polytechnica. ISSN 1805-2363, vol. 45, no. 6/2005, s. 35-43. Praha: České vysoké učení technické v Praze, 2005.
- XU, J. – XU, L. 2017. Chapter Eight - Maintenance Decision Support, In Integrated System Health Management, Academic Press. ISBN 9780128122075, 2017, s. 377-432.
- ZHANG, N. et al. 2018. Naive Bayes Bearing Fault Diagnosis Based on Enhanced Independence of Data. Sensors 18, no. 2: 463.
- ZHU, J. et al. 2014. Survey of condition indicators for condition monitoring systems. In PHM 2014 - Proceedings of the Annual Conference of the Prognostics and Health Management Society. s. 635-647.