



SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE
FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Ing. Zuzana Képešiová

Autoreferát dizertačnej práce

**Inteligentné metódy diagnostiky a riadenia mechatronických
systémov**

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

v doktorandskom študijnom programe
v študijnom odbore
forma štúdia
Miesto a dátum

Mechatronické systémy
Kybernetika
denná
Bratislava, 31. 8. 2020



Dizertačná práca bola vypracovaná na Ústave automobilovej mechatroniky, Fakulte elektrotechniky a informatiky STU v Bratislave (FEI STUBA).

Predkladateľ: Ing. Zuzana Képešiová
Ústav automobilovej mechatroniky
FEI STUBA, Ilkovičova 3, 812 19 Bratislava

Školiteľ: prof. Ing. Danica Rosinová, PhD.
Ústav automobilovej mechatroniky
FEI STUBA, Ilkovičova 3, 812 19 Bratislava

Oponenti: prof. Ing. Juraj Spalek, PhD.
Katedra riadiacích a informačných systémov
FEI UNIZA, Univerzitná 8215/1, 010 26 Žilina

doc. Ing. Peter Schreiber, CSc.
Ústav aplikovanej informatiky, automatizácie a mechatroniky
MTF STUBA, Ulica Jána Bottu 2781/25, 91724 Trnava

Autoreferát bol rozoslaný:

Obhajoba dizertačnej práce sa bude konať dňa:

o.....h, na Fakulte elektrotechniky a informatiky STU v Bratislave,

Ilkovičova 3, 812 19 Bratislava, v miestnosti

prof. Dr. Ing. Miloš Oravec



SÚHRN

SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE
FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Študijný program:	Mechatronicke systémy
Názov študijného odboru:	Kybernetika
Dizertačná práca:	Inteligentné metódy diagnostiky a riadenia mechatronických systémov
Autor:	Ing. Zuzana Képešiová
Vedúci záverečnej práce:	prof. Ing. Danica Rosinová, PhD.
Konzultant:	prof. Ing. Štefan Kozák, PhD.
Miesto a rok predloženia práce:	Bratislava 2020

Mechatronicke systémy a zariadenia sú základnou zložkou priemyslu modernej doby, najnovšieho konceptu - Priemysel 4.0 (Industry 4.0). Priemysel 4.0. spája v sebe multidisciplinárne využitie širokého spektra vedných a aplikačných oblastí tak, aby bolo možné integrovať najnovšie poznatky z metód a algoritmov automatického riadenia, elektroniky, informačno-komunikačných technológií a umelej inteligencie do nových výrobkov, technológií a priemyselných procesov. Výsledkom a hlavným prínosom dizertačnej práce je autorkou navrhnutý, spracovaný a implementovaný moderný prístup k diagnostike a riadeniu mechatronických zariadení v sieti IIoT pre splnenie potrieb trhu po inovatívnych riešeniach spĺňajúcich koncept priemyselnej revolúcie Priemysel 4.0. Informácie o stave a prevádzke zariadenia sú automaticky posielané do výpočtovej jednotky umiestnenej v cloude. V cloude sú tieto dáta automaticky spracované umelou inteligenciou a je vyhodnotený stav sledovaného systému na báze určenia prípadnej chyby.

Kľúčové slová: mechatronicke systémy, Priemysel 4.0, umelá inteligencia, diagnostické postupy



ABSTRACT

SLOVAK UNIVERSITY OF TECHNOLOGY IN BRATISLAVA
FACULTY OF ELECTRICAL ENGINEERING AND INFORMATION TECHNOLOGY

Study Programme:	Mechatronic Systems
Study Branch:	Cybernetics
Dissertation Thesis:	Intelligent methods of diagnostics and control of mechatronic systems
Author:	Ing. Zuzana Képešiová
Supervisor:	prof. Ing. Danica Rosinová, PhD.
Consultant:	prof. Ing. Štefan Kozák, PhD.
Place and year of submission:	Bratislava 2020

Mechatronic systems and devices are a basic component of the modern industry, the latest concept - Industry 4.0. Industry 4.0. combines the multidisciplinary use of a wide range of scientific and application areas so that it is possible to integrate the latest knowledge from methods and algorithms of automatic control, electronics, information and communication technologies and artificial intelligence into new products, technologies and industrial processes. The result of the thesis is the author's design, development and implementation of a modern approach to diagnostics and control of mechatronic devices in the IIoT network to meet the needs of the market by providing innovative solutions fulfilling the concept of the latest industrial revolution Industry 4.0. Information about the device status and functioning is automatically sent to the computing unit located in the cloud. In the cloud, this data is automatically processed by artificial intelligence and the device's health is evaluated, a fault is detected and classified.

Key words: mechatronic systems, Industry 4.0, artificial intelligence, diagnostic practices



Obsah

Úvod	4
1 Inteligentná diagnostika v priemysle	7
2 Implementácia systému monitorovania a riadenia mechatronických systémov	9
2.1 Mechatronické zariadenie	10
2.1.1 Vlastnosti a špecifikácia zariadení	10
2.1.2 Ovládanie zariadenia	12
2.1.3 Komunikácia zariadenia s cloudom	12
2.2 Inteligentné vyhodnocovanie stavu zariadenia	14
2.2.1 Dáta definujúce zariadenia	15
2.2.2 Architektúra umelej neurónovej siete	18
2.2.3 Princíp vyhodnocovania stavu zariadenia navrhnutým riešením inteligentnej diagnostiky	22
2.3 Google Cloud Platform (GCP)	23
3 Testovanie navrhnutého riešenia a zhodnotenie výsledkov	24
4 Diskusia	32
Záver	34
Prínos pre vedu a prax	37
Publikačná činnosť autora	38
Zoznam použitej literatúry	41

STU

Ciele dizertačnej práce

Monitorovanie a riadenie mechatronických systémov v priemysle sú jeho neoddeliteľnou súčasťou a postupom času sa neustále zdokonaľujú. Monitorovanie takýchto zariadení je podstatnou zložkou životného cyklu mechatronických systémov, pretože od výsledku monitorovania sa odvíjajú aj ďalšie kroky ich životného cyklu akými sú údržba, riadenie či optimalizácia. Tieto technológie sú neustále rozvíjajúci sa a vyvíjajúci sa komplex, v ktorom je vždy priestor na rozvoj. Aktuálna, neustále napredujúca paradigma Industry 4.0. spája najnovšie informačno-komunikačné technológie akými sú IoT, Big Data, Cloudové výpočty, automatizované procesy či umelá inteligencia. Na základe analýzy dostupnej literatúry a výskumných projektov v oblasti diagnostiky chodu zariadenia v predošlej kapitole možno konštatovať, že inteligentná diagnostika zdravia zariadení a procesov sa zameriava predovšetkým na konkrétne zariadenia a procesy, jednu sledovanú systém opisujúcu hodnotu meniacu sa v čase, pričom sledovaná hodnota je vyhodnocovaná pre celý časový úsek ako jednotná, bez možnosti sledovania menších odchýlok, ktoré by mohli včas detegovať aj menšie výkyvy v správaní.

Požiadavky rozvíjajúceho sa priemyslu neustále rastú v každom smere, aby bola jeho expanzia zabezpečená s čo najhladším priebehom, ktorý zabezpečí čo najnižšie náklady pre jeho chod, ako aj pre aplikáciu zmien plánovaných ale aj neplánovaných. V priemyselnej oblasti jednou zo základných zložiek zabezpečujúcich znižovanie nákladov je udržiavanie dobrého zdravia zariadenia. Včasné odhalenie chyby zariadenia, prípadné odchýlky od štandardného pracovného režimu je kľúčovým aspektom pri plánovaní jeho prípadnej údržby s čo najmenším dopadom na výrobný proces, ako aj skoré zareagovanie na kritické stavy eliminujúce úplné zlyhanie systému.

Výskum a vývoj včasnej a efektívnej diagnostiky sledovaného systému v sieťach IIoT predstavuje multidisciplinárnu úlohu, nakoľko prepája sledovanie a riadenie mechatronického zariadenia, komunikáciu zariadenia s decentralizovanou výpočtovou jednotkou, spracovanie prichádzajúcich informácií, umelej inteligencie na predikciu zdravia a prípadnej chyby zariadenia s včasným zareagovaním na kritické stavy inštruovaním sledovaného systému na jeho zastavenie, aby sa predišlo neodvratiteľným poškodeniam spôsobených zlyhaním zariadenia.

Na základe analýzy súčasného stavu v študovanej oblasti sme stanovili nasledujúce základne ciele dizertačnej práce:

1. Návrh moderných metód monitorovania a riadenia mechatronických systémov na báze umelej inteligencie pre diagnostické postupy.
 - a. Definovanie požiadaviek na výsledný systém.
 - b. Koncept vlastného UI systému s využitím súčasných postupov sledovania a ovládania mechatronických systémov.
2. Implementácia moderných metód monitorovania a riadenia mechatronických systémov s dôrazom na diagnostiku zariadenia vzhľadom na monitorované veličiny za využitia najmodernejších prístupov.
 - a. Výber sledovaných mechatronických zariadení.
 - b. Inteligentná diagnostika zvolených systémov.
 - c. Komunikácia vybraných zariadení so systémom inteligentného monitorovania a riadenia.
 - d. Ukladanie dát o zariadeniach a ich riadenie na základe analýzy ich stavu.
3. Overenie navrhnutého riešenia diagnostiky mechatronických systémov na vybraných zariadeniach.

Zhrnutie možností využitia novej metodiky a nových metód monitorovania a riadenia mechatronických zariadení pre ich využitie v priemyselnej praxi (Industry 4.0) v oblasti mechatronických systémov.

STU

Úvod

Vyspelé krajiny dnes rýchlo reagujú na celosvetovú výzvu potreby rozvoja a modernizácie priemyselných výrobných. V mnohých európskych krajinách veľké spoločnosti vyvíjajú svoje vlastné metódy, prostriedky a stratégie na riešenie týchto naliehavých úloh. Súčasný stav v moderných digitalizovaných výrobných a technologických procesoch núti najmä malé a stredné podniky, aby sa prispôbili týmto výzvam a budovali moderné digitalizované továrne spolupracujúce s veľkými spoločnosťami, najmä v strojárskom a automobilovom priemysle. V mnohých krajinách je koncepcia inteligentného priemyslu národnou iniciatívou založenou na najnovšom výskume uskutočnenom na univerzitách a vo firmách s cieľom transformovať a posilniť odvetvia pomocou metodológie Industry 4.0. Spojenie pokročilých technologických a výrobných procesov s informačnými a komunikačnými technológiami, automatizáciou, umelou inteligenciou, Big Data, Analytics a Cloudových technológií je hnacou silou súčasnej priemyselnej revolúcie.

Industry 4.0 je aktuálna celosvetová výzva, ktorá umožňuje interdisciplinárne využitie širokého spektra vedných a aplikačných oblastí tak, aby bolo možné synergicky integrovať najnovšie poznatky z metód a algoritmov automatického riadenia, elektroniky, informačno-komunikačných technológií (IKT) a umelej inteligencie do nových výrobkov, technológií, priemyselných procesov, zdravotníctva alebo služieb.

Kyberneticko-fyzikálne (CPS) systémy reprezentujú základnú platformu Priemyslu 4.0, podľa ktorej sa dnes budujú moderné digitalizované inteligentné fabriky schopné zefektívniť svoju činnosť na všetkých úrovniach riadenia, autonómnej výmeny a spracovania informácií medzi strojmi, snímačmi a riadiacimi systémami pre zabezpečenie rýchlej a inteligentnej činnosti riadenia. CPS ako základná platforma Industry 4.0 predpokladá vzájomnú spoluprácu a komunikáciu rozhraní človek – stroj, človek – človek, stroj – stroj, a aj komunikáciu v rámci logistických systémov a produktov. Na uvedený trend je nevyhnutne potrebné reagovať aj z pozície vývoja, výskumu, implementácie a realizácie metód a algoritmov riadenia procesov. Kyberneticko-fyzikálna platforma predstavuje také integrované komplexné systémy, ktoré s využitím metód a algoritmov inteligentného riadenia, IKT, inteligentných prvkov a systémov, založených na Internete vecí (IoT), dokážu dať výrobkom a technológiám novú a vylepšenú funkcionalitu, nové konštrukčné vlastnosti a optimálnu súčinnosť dielčích procesov.

Ukazuje sa, že pre efektívne spracovanie dát môžeme dnes využiť cloudové výpočty, zatiaľ čo kyberneticko-fyzikálne systémy ovplyvňujú fyzické procesy a ich výstupy sa menia na základe vstupov z fyzického sveta. Celý princíp konceptu Industry 4.0 je dnes založený najmä na dátach, IoT a IIoT. Základom modernej štruktúry výroby je digitalizácia procesov od úrovne senzorov a regulátorov až po vyššie úrovne pre optimalizáciu a plánovanie výroby. Každá z týchto úrovní má určitý vstup a výstup, ktorý sa spracováva ďalej a posiela na vyššie úrovne. Tu je možné hovoriť o interaktívnom prepojení senzorov, zariadení, strojov, komplexných riešení, ľudí, zdrojov, plánovania a výsledných produktov. Hranica medzi digitálnym a fyzickým svetom sa stráca, čo zlepšuje pochopenie celého životného cyklu priemyslu a jeho častí. Čím sa pochopenie týchto prepojení prehĺbuje, tým narastá aj počet možností a príležitostí na vhodnejšie a rýchlejšie reagovanie na zmeny a získané skutočnosti o stave systému – fyzického zariadenia.

Predložená dizertačná práca je motivovaná technologickým rozvojom a novými požiadavkami automatizácie a digitalizácie procesov na základe inteligentných prístupov monitorovania a riadenia kybernetických/mechatronických zariadení. Rýchlosť napredovania technických vymožeností časom neustále rastie a tak je nutné pohotovo reagovať na vznikajúce zmeny tak, aby bola zabezpečená čo najvyššia efektívnosť prebiehajúcich procesov akými sú napríklad optimálne plánovanie, digitalizovaná výroba, alebo aj prediktívna údržba.

Cieľom dizertačnej práce je výskum, vývoj a nasadenie inteligentných postupov diagnostiky mechatronických zariadení v sieti IIoT v súlade s konceptom Industry 4.0 tak, aby boli zariadenia na základe výsledku analýzy obslužené a tak sa zamedzilo fatálnym následkom spojených so zlyhaním zariadenia.

Dizertačná práca využíva aktuálne výzvy moderných postupov modelovania a riadenia priemyselných procesov, ktoré sú dnes reprezentované kyberneticko-fyzikálnymi systémami. Jednou z najdôležitejších úloh pri zavádzaní metodológie konceptu Industry 4.0 do výroby je inteligentná diagnostika stavu zariadení použitím metód umelej inteligencie, čo predstavuje hlavné zámery predloženej dizertačnej práce.

V dizertačnej práci je navrhnutý, spracovaný a otestovaný koncept inteligentnej diagnostiky skupiny zariadení a ich riadenia na základe výsledkov diagnostiky v reálnom čase. Koncept je založený na metodológii Internetu vecí, kedy zariadenia komunikujú so vzdialenou výpočtovou



jednotkou. Táto výpočtová jednotka sa nachádza v decentralizovanom priestore cloudu, kde spracováva prichádzajúce informácie o chode zariadenia a pomocou umelej inteligencie sa rozhoduje o stave zariadenia. Výsledky diagnostiky zariadenia zapíše do databázy a na základe dosiahnutých výsledkov vyhodnotí, či sa zariadenie nachádza v kritickom stave.

Pôvodným a hlavným výsledkom dizertačnej práce je vývoj a implementácia inovatívnych prístupov inteligentnej diagnostiky a riadenia na základe monitorovania a návrhu unifikovanej inteligentnej diagnostiky kyberneticko-fyzikálnych zariadení na báze umelej inteligencie, ktoré sa opierajú o metódy hlbokého učenia, ktoré autorka dizertačnej práce rozšírila, modifikovala a pripravila na reálne použitie. Jedným z nových prínosov riešenia je aj zovšeobecnený koncept využívania získavania údajov o CPS zariadení. Ďalším prínosom práce je autorkou navrhnutý koncept spracovania získaných údajov tak, aby bolo možné realizovať diagnostiku stavu monitorovacieho zariadenia pomocou metód umelej inteligencie na diaľku - v decentralizovanom priestore cloudu pre široké spektrum zariadení.

1 Inteligentná diagnostika v priemysle

Za posledných niekoľko rokov sa princíp monitorovania a riadenia mechatronických systémov vyvíjal prudko vpred, rovnako ako aj technologické vylepšenia ako také. V rámci analýzy súčasného stavu sme sa venovali predovšetkým vedeckým výskumom v oblasti inteligentného monitorovania a vyhodnocovania rôznych stavov robotických systémov, na základe ktorých by bolo možné vyhodnotiť chybovosť systému a tak systém zastaviť, či upozorniť na vyslanie technika k oprave stroja včas. Jednotlivým riešeniam sa venujeme podľa spôsobu ich realizácie a algoritmov, na ktorých sú postavené.

Robotické a kybernetické systémy sa stávajú čoraz zložitejšími a automatické identifikovanie komplexnejším. Preto sa aktuálne smerovanie vyhodnocovania stavu a zdravia systému vykonáva na báze umelej inteligencie a to predovšetkým na báze umelých neurónových sietí. Pojem „zdravie“ pre technické zariadenia je ekvivalentom pre „stav“ zariadenia.

V posledných piatich rokoch sa využívali neurónové siete na diagnostikovanie chyby zariadenia s rôznorodými architektúrami. Boli použité jednoduché neurónové siete ako napríklad v štúdiu [1] alebo čoraz viac využívané hlboké neurónové siete ako v štúdiu [2]. Úspešnosť hlbokých neurónových sietí je vyššia než jednoduchých neurónových sietí či matematických modelov a s narastajúcim objemom dát sa oproti ostatným riešeniam úspešnosť naďalej zvyšuje. Od tejto skutočnosti sa odvíjali aj mnohé príspevky vo vedeckých časopisoch či konferenciách a na klasifikáciu stavu zariadenia využili hlboké neurónové siete. Nakoľko sa stav zariadenia mení v čase a je od neho závislý, je možné na klasifikáciu stavu zariadenia využiť aj konvulčné aj rekurentné siete. V prípade klasifikovania segmentov stavu zariadenia je možné použiť hlbokú neurónovú sieť ako v prípade [3], [4], [5] alebo [6], kde boli použité konvulčné neurónové siete.

Inou možnosťou je využitie rekurentných neurónových sietí ako v prípade článku [7] a [8]. Aj napriek tomu, že práve rekurentné siete sú orientované na časovo-orientované dáta, tak dopyt po nich nie je natoľko rozsiahly. Dôvodom môže byť vysoká časová náročnosť na výpočty počas tréningu sietí.

STU

Klasickým prístupom k riešeniu problému odhalenia chyby na prístroji sa javí využitie architektúry auto-enkódera, ktorému sa venujú štúdie [2], [7], [9], [10] a [11]. V rámci výskumu [9] bol použitý SAE – „Sparse Auto-Encoder“ – riedky auto-enkóder. Pod riedkym auto-enkóderom si predstavujeme taký euto-enkóder, ktorý nemá všetky prepojenia medzi susediacimi vrstvami prepojené, a tým nadobúda vlastnosť „riedky“.

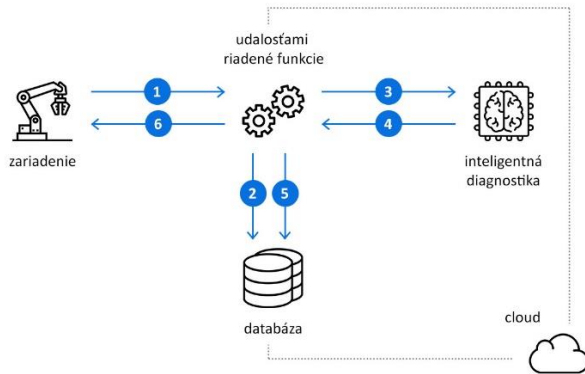
Po podrobnej analýze vybraných vedeckých prác zachytávajúcích prístupy k inteligentnej diagnostike zariadení je možné sledovať nasledovné trendy:

- Využívanie hlbokého učenia.
- Využívanie predovšetkým konvolučných neurónových sietí.
- Sledovanie zmien sledovanej veličiny opisujúcej stav zariadenia v čase.
- Získavanie vlastností sledovanej veličiny definujúcich jednotlivé stavy zariadenia.
- Využívanie auto-enkóderov na extrahovanie vlastností.

Prehľad výskumnej činnosti definovanej vybranými vedeckými prácami poukazuje na nedostatok daných prác v jednom alebo vo viacerých bodoch:

- Prispôsobivosť navrhnutého algoritmu na iný problém podobnej triedy nie je definovaný.
- Vytváranie modelov neurónových sietí na extrakciu vlastností je pre každý stav osobitne, čím sa zväčšuje časová a výpočtová náročnosť inteligentných algoritmov.
- Definovanie stavu zariadenia je na základe iba jednej sledovanej veličiny, čím sa zužuje spektrum odhaliteľných chýb.
- Definovanie stavu zariadenia je na základe celých časových blokov bez opakovanej predikcie v určitých bodoch, čo má za následok oneskorenie odhalenia prípadnej chyby.

2 Implementácia systému monitorovania a riadenia mechatronických systémov



Obr. 1 Základný návrh inteligentnej diagnostiky a riadenia daného zariadenia

Na základe definovaných potrieb a požiadaviek na systém sme navrhli riešenie tak, ako je zobrazené na Obr. 1. V takomto prípade nie je potrebné zaobštarávať vlastný server, a to ani ako cloudovú službu, nakoľko sa využívajú tzv. bez-serverové služby. Je možné využívať jednotlivé komponenty ponúkané cloudovým poskytovateľom a prepojiť ich na úrovni týchto služieb, bez nutnosti programovania vlastného serverového rozhrania.

Samotná implementácia systému pozostáva z troch hlavných prepojených bodov:

- **Mechatrické zariadenie** – sledované zariadenie.
- **Inteligentná diagnostika** – neuronová sieť na vyhodnocovanie stavu zariadenia na základe aktuálneho časového úseku.
- **Cloudové služby** – služby pre prepojenie zariadenia s výpočtovo náročnou inteligentnou diagnostikou vyhodnocujúcou aktuálny stav zariadenia, ako aj priebežné ukladanie sledovaných hodnôt a analýz.


2.1 Mechatronické zariadenie

Ako ukázkové zariadenie boli vybrané dva laboratórne systémy: FloatShield a MotoShield z rodiny Arduino Shieldov AutomationShield pre výučbu systémov riadenia a mechatronických systémov [12] [13]. Jedná sa o voľne dostupné a lacné riešenie, ktoré si na základe dodaných schém a programových knižníc môže človek zaobstarat' a vyhotovit' sám. Tieto zariadenia sú napojené na mikrokontrolér Uno R3+WIFI, aby bola zabezpečená kompatibilita programových knižníc a zároveň bola poskytnutá možnosť odosielať dáta zo zariadenia priamo na Cloud bez sieťového pripojenia, ale bezdrôtovo. Mechatronické zariadenia boli autorkou prispôsobené tak, aby vedeli bezdrôtovo komunikovať so vzdialenou výpočtovou jednotkou umiestnenou na cloude od poskytovateľa služieb Google Cloud Platform. Špecifikácia zariadení a spôsob ich úpravy je uvedený v nasledovných podkapitolách.

2.1.1 Vlastnosti a špecifikácia zariadení

Základný dizajn **FloatShield** sa skladá z priehľadnej vertikálnej trubice obsahujúcej loptičku, ktorá sa vznáša vo vnútri v dôsledku prúdenia vzduchu generovaného ventilátorom pripojeným ku konštrukčnej doske plošných spojov.

Trubica a senzor vzdialenosti sú prichytené pomocou 3D vytlačených častí. Cieľom je riadiť polohu lopty v trubici zmeranú senzorom vzdialenosti, ktorý vytvára jednoduchú spätnoväzbovú slučku s jednoduchým vstupom (SISO). Užívateľ môže tiež regulovať výkon ventilátora manuálne - pomocou potenciometra, ktorého výstup je potom upravený na signál modulovaný šírkou impulzu (PWM).



Obr. 2 Popis zariadenia FloatShield [13]

MotoShield implementuje motor vybavený redukciovou prevodovou stupňou ako ovládač a spätnú väzbu enkodéra. MotoShield umožňuje uskutočňovať množstvo experimentov v oblasti riadenia, od modelovania prvotných princípov a identifikácie systému ako šedej skrinky, riadenia rýchlosti a riadenia polohy. Rýchlosť otáčok motora môže používateľ regulovať pomocou potenciometra.

Hlavnou časťou MotoShieldu je jednosmerný motor s kefkou 6 V vybavený halovým snímačom polohy. Motorová jednotka má 6 výstupov, z ktorých 4 patria k snímačom. L33D H-mostík integrovaný obvod sa používa ako ovládač motora. L293D je veľmi praktický a ľahko použiteľný integrovaný obvod obsahujúci štvor kanálový H-mostík, ktorý mu umožňuje ovládať dva jednosmerné motory, jeden krokový motor alebo štyri ďalšie záťažové jednotky, ako sú solenoidy alebo relé. MotoShield tiež obsahuje operačný zosilňovač LM358, ktorý má dve úlohy.

Najprv odpočíta dve hodnoty napätia, a tým vypočíta úbytok napätia rezistorom použitým na meranie prúdu. Po druhé, zosilňuje odčítané napätie Arduina [13].



Obr. 3 Ukážka zariadenia MotoShield [13]


2.1.2 Ovládanie zariadenia

Ovládanie zariadenia je možné naprogramovať pomocou C/C++ v programe Arduino IDE. Programovanie riadenia na ATmega328 je potrebné dať do samostatného projektu a programovanie riadenia pre ESP8266 si vyžaduje vlastný projekt, ktorý sa na čip nahrá. Rozdielnosť je spôsobená odlišnou funkcionalitou jednotlivých čipov, ktoré následne medzi sebou komunikujú. Zatiaľ čo ATmega328 sa stará o priame ovládanie zariadenia, tak ESP8266 sa stará o komunikáciu zariadenia s online cloudovou výpočtovou jednotkou. Na naprogramovanie mechatronických zariadení budeme potrebovať knižnice: **AutomationShield knižnica** a **Google Cloud IoT JWT knižnica**.

2.1.3 Komunikácia zariadenia s cloudom

Obr. 4 opisuje komunikáciu medzi mechatronickým zariadením a cloudom. Samotný shield je zariadenie, ktoré sa priamo napája na vývojovú dosku tak, že pokrýva všetky vstupné PINy.

Shields z rodiny AutomationShield komunikujú so samotnou doskou pomocou I2C protokolu. Na doske UNO R3+Wifi sa nachádzajú 2 čipy a to ATmega328 a ESP8266. Shields komunikujú s čipom ATmega328, nakoľko tento čip má vstupné PINy s ním kompatibilné. PINy ESP8266 majú iné umiestnenie a charakter. PINy ATmega328 majú charakter samice, takže je možné naň Shield umiestniť, zatiaľ čo PINy čipu ESP8266 majú charakter samca. Tieto dva čipy na doske nie je potrebné prepájať dodatočným zapojením, nakoľko pri prepnutí spínača na doske do správnej polohy, sú tieto čipy schopné komunikovať medzi sebou pomocou sériovej komunikácie.



Obr. 4 Zariadenie FloatShield / MotoShield a jeho komunikácia s cloudom

Sériová komunikácia medzi čipmi závisí od vopred stanovených správ.

Tabuľka 1 Komunikácia medzi ESP8266 a ATmega328 pre FloatShield a MotoShield

Zariadenie	Odosielateľ Prijímateľ	Príkaz	Popis
FloatShield	ATmega328 ESP8266	<18.2, 77.3>	aktuálna výška loptičky [mm], otáčky ventilátora [%]
MotoShield	ATmega328 ESP8266	<18.2, 77.3, 80.7, 30.7>	úbytok napätia rezistorom [V], aktuálny odber motora [mA], rýchlosť otáčok [%], nastavená rýchlosť motora PID regulátorom

Mechatronické zariadenia majú na svojich oficiálnych stránkach definované základné príkazy pre ich monitorovanie a riadenie, avšak len na úrovni samotného zariadenia. To znamená, že zariadenia dáta nikam neodosielajú a je možné ich ovládať iba pomocou potenciometra, alebo mu vopred definovať jeho optimálne správanie. Preto sme navrhli a implementovali vlastný spôsob komunikácie založenom na sériovej komunikácii dvoch čipov, pričom jeden sa stará o komunikáciu s mechatronickým zariadením a druhý sa stará o komunikáciu s cloudom.

2.2 Inteligentné vyhodnocovanie stavu zariadenia

Inteligentná diagnostika porúch zariadení využíva niektoré schopnosti umelých neurónových sietí, ako sú extrakcia vlastností, segmentácia a klasifikácia. Na základe údajov senzora je možné extrahovať vlastnosti a vzorce detegovaného signálu. Extrahované znaky opisujú štruktúru zachytených signálov a môžu sa použiť na segmentáciu signálu naprieč jednotlivými časovými bodmi a na konci tieto kroky klasifikujú do vopred definovaných kategórií. Tieto 3 kroky na úspešnú detekciu a klasifikáciu poruchy zariadenia sú riešiteľné prostredníctvom hlbokého učenia, v ktorom kombinácia vytvára inteligentné riešenie diagnostiky zariadenia.

Najrelevantnejšie informácie na rozpoznanie poruchy zariadenia sú časovo-frekvenčné vlastnosti extrahované zo zaznamenaných signálov zo snímačov zariadenia. Vzhľadom na celý rad rôznych typov snímačov a sledovaných signálov, je možné povedať, že všetky majú jednu dimenziu rovnakú, a to čas. V zmysle hlbokých neurónových sietí existuje niekoľko typov blokov, medzi ktorými sú takzvané konvolučné neurónové siete (CNN) a rekurentné neurónové siete (RNN) vhodné na riešenie problému časových závislostí. RNN sa zvyčajne používajú v problémoch časových závislostí, pretože archivujú informácie o niekoľko krokov späť vo svojich jednotkách. Široko používanou formou RNN je dlhá krátkodobá pamäť (LSTM), ktorá prekonáva problém dlhodobých závislostí. Veľkou nevýhodou RNN je ich nízka výpočtová rýchlosť a problematické použitie paralelizmu. Hlavnou schopnosťou CNN je extrahovať vlastnosti zo vstupných údajov, či už sú to 2D dáta, ako sú obrázky, alebo 1D dáta, ako sú signály a jednosmerne orientované údaje. Hlavnou myšlienkou CNN je konvolučný proces, pri ktorom sa kombinujú filtre a vstupné údaje a konečný produkt predstavuje aktivačnú mapu vstupu. Popri CNN sa pri extrakcii prvkov poruchy zariadenia používa aj metóda zvaná auto-enkóder. Auto-enkóder slúži ako extraktor vlastností a rekonštrukciou dát na základe extrahovaných vlastností. Základným

STU

princípom auto-enkódera je zobrať uzly vstupnej vrstvy a spojiť ich do nižšieho počtu uzlov v skrytej vrstve, ktoré predstavujú extrahované prvky. Auto-enkóder rekonštruuje vstupné uzly na výstupných uzloch na základe vlastností získaných v skrytej vrstve. Auto-enkóder sa zvyčajne používa ako dátový kompresor na ukládanie veľkorozmerných údajov a ich reprezentáciu pomocou komprimovaných verzií. Tieto komprimované verzie predstavujú vlastnosti vstupných údajov. Po získaní vlastností je možné kategorizovať naučené vlastnosti a klasifikovať vždy, keď je signál chybný a ktorú poruchu predstavuje.

Namerané dáta zo zariadení, ako aj natrénované modely a zdrojové kódy je možné nájsť v prílohách dizertačnej práce.

2.2.1 Dáta definujúce zariadenia

Sledované zariadenia je možné monitorovať na základe dát zo senzorov. Preto, jednotlivé dáta meriame a merané hodnoty ukladáme. Pre algoritmy hlbokého učenia v prípade učenia s učiteľom je potrebné tieto dáta označiť a zaradiť do kategórií definujúcich stav zariadenia. Dáta označujeme a následne štandardizujeme aby sa predišlo zameriavaniu umelých neurónových sietí na okrajové hodnoty, ktoré sú výrazné svojou veľkosťou, avšak nemusia mať rovnako veľkú aj dôležitosť reprezentácie dát.

Nakoľko máme nie-len jednu sledovanú hodnotu, ale zameriavame sa na komplex sledovaných parametrov meniacich sa v čase, ktoré samotný mechatronický systém opisujú, mení sa nám charakter dát z 1D orientovaných na 2D. Samotnú prácu s dátami sme rozdelili do nasledovných krokov:

1. Získanie dát z reálneho prostredia.
2. Vzorkovanie dát – rozdelenie dát podľa kategórií na časové okná.
3. Rozdelenie dát na tréningové a validačné.
4. Štandardizácia dát.

Dáta sme získali namerali experimentovaním počas reálneho chodu zariadení v rôznych podmienkach vytvárajúcich chyby na zariadení. Definovali sme niekoľko typov chýb – odchýlok

od normálneho režimu, na ktorých detekciu sa zameriame v návrhu inteligentného systému. Sledované hodnoty pre zariadenia boli nasledovné:

- FloatShield – pozícia loptičky [mm], výkon ventilátora [%].
- MotoShield - úbytok napätia rezistorom [V], aktuálny odber prúdu motora [mA], rýchlosť otáčok [%], nastavená rýchlosť motora PID regulátorom [%].

Pre FloatShield sme zaznamenali viac ako 1 milión časových bodov zachytávajúcich 6 druhov stavov: 1 bezchybný stav a 5 chybových stavov. Stav, ich definície, označenie a percentuálny podiel v súbore experimentálnych dát sú opísané v Tabuľka 2. Pre MotoShield sme zaznamenali viac ako 2,5 milióna časových bodov zachytávajúcich 4 stavy: 1 bezchybný stav a 3 chybové stavy, pričom tieto chyby sa mohli vyskytovať v rôznych intenzitách a na rôznych častiach zariadenia. Definície a označenie chýb ako aj percentuálny podiel v celkovom experimentálnom datasete sú zobrazené v Tabuľka 3.

Tabuľka 2 Kompozícia datasetu pre diagnostiku zariadenia FloatShield

<i>Trieda</i>	<i>Popis</i>	<i>Podiel [%]</i>
0	Bez chyby	27
1	Stredne ťažký predmet padol do tuby	45
2	Ťažký predmet padol do tuby	3
3	Lahký predmet padol do tuby	18
4	Zaseknutá loptička	3
5	Loptička uvoľnená po zaseknutí	4

Tabuľka 3 Kompozícia datasetu pre diagnostiku zariadenia MotoShield

<i>Trieda</i>	<i>Popis</i>	<i>Podiel [%]</i>
0	Bez chyby	49
1	Zaseknuté teleso v ozubených kolieskach	25
2	Pôsobenie magnetu	25
3	Blokovaný motor	1

STU

Ako je vidieť v predchádzajúcich tabuľkách, datasety sú značne nevyvážené. Za bežných okolností je zariadenie v bezchybnom stave väčšinu času, preto spadá väčšinu času do práve jednej kategórie. Pre simulovanie rôznorodosti sú aj samotné datasety rôznorodé a nevyvážené. Riešenie problému tréningu algoritmov v prípade nevyváženého objemu záznamov pre rôzne stavy vzbudzuje v posledných rokoch záujem vzhľadom na exponenciálny nárast objemu získavaných informácií ako dôsledok digitalizácie v priemysle. S nárastom objemu dát sa pritom prehľbuje aj ich nevyváženosť.

Jedna vzorka zo získaného datasetu dosahuje rozmery (t, n) , kde hodnota t predstavuje počet sledovaných bodov času v rámci časového okna a hodnota n počet sledovaných parametrov. Ako dĺžka časového okna bola zvolená hodnota 256 kontinuálnych bodov času. Tieto časové okná sú vyberané zo získaných záznamov správania sa systému postupne pomocou pohybujúceho sa okna s krokováním 128 bodov času. FloatShield aj MotoShield majú nastavené krokovanie na 25ms, čo v prípade 256 bodov času predstavuje záznam o dĺžke približne 6,4 sekundy. Časové okno pre FloatShield teda naberá rozmery $(256, 2)$ a pre MotoShield $(256, 4)$.

Potom, čo sú dáta prerozdelené na jednotlivé vzorky fixnej dĺžky, je potrebné získané údaje rozdeliť na testovaciu a validačnú zložku. Údaje boli rozdelené do tréningového a validačného setu v pomere 90% záznamov v tréningovom sete a 10% vo validačnom sete proporcionálne pre každú triedu, aby sa zabezpečilo, že každá trieda má zástupcov tak v tréningovom sete, ako aj vo validačnom sete.

Posledným krokom pri spracovaní dát pred tréningom NN je normalizácia dát z tréningového aj validačného datasetu. Normalizácia dát je potrebná v prípade rozličného rozsahu parametrov, aby sa zabránilo favorizovaniu údajov s vyššími hodnotami, aj keď menšou výpovednou hodnotou. Pre tieto účely bola vybraná normalizácia pomocou Z-skóre, ktoré využíva na úpravu hodnôt strednú hodnotu a štandardnú deviáciu. Stredná hodnota a štandardná deviácia sa vypočítajú iba pre tréningový dataset. Následne sa princíp normalizácie aplikuje na tréningový dataset, validačný dataset a každé ďalšie namerané veličiny pripravené na predikciu práve s týmito hodnotami.

2.2.2 Architektúra umelej neurónovej siete

Výskum v oblasti zdravia mechatronických systémov sa zväčša zameriava na jednu sledovanú veličinu a sledovaný časový segment je vždy vyhodnocovaný ako celok, či menší blok. Je možné sledovať použitie ako jednoduchých NN, tak aj CNN a RNN. Vzhľadom na to, že RNN je pomalá na tréningovanie a nemusí dosahovať priaznivé výsledky bez kombinácie s CNN, rozhodli sme sa RNN do výsledného algoritmu nezaraďovať. Nakoľko cieľom nášho algoritmu je diagnostikovanie zdravia zariadenia v každom bode sledovaného času pre včasné odhalenie chyby, využili sme princíp segmentácie. Segmentácia je založená na získaných vlastnostiach, ktoré nám naše dáta opisujú a preto sme sa rozhodli zvoliť konvolučné bloky, ako podstatu diagnostického algoritmu, ktoré sú na hľadanie vlastností v nelineárne orientovaných dátach ideálne.

V prípade detekcie a klasifikácie porúch sa obvykle na extrahovanie vlastností vstupných údajov a klasifikáciu výstupu používajú zložené alebo riedke auto-ekodéry. V zmysle segmentácie sa používa auto-ekodér s maskovanými údajmi na klasifikáciu každej jednotky vstupného segmentu a nielen segmentu ako celku. Príkladom segmentovania auto-ekodérom je architektúra hlbkej neurónovej siete s U-tvarom nazývaná U-Net. U-Net je neurónová sieť navrhnutá pre sémantickú segmentáciu. Pôvodne určená na segmentáciu lekárskeho obrazov [14], ale preukázala sa tiež ako účinná na spracovanie signálu [15].

Architektúra U-net je plne konvolučná neurónová sieť pozostávajúca z blokov konvolúcie, max pooling, dekonvolúcie a spájania. Pre kombinovanú segmentáciu signálu bola použitá a autorkou dizertačnej práce adaptovaná architektúra U-Net. Navrhnutú modifikáciu architektúry, ktorá je jedným z pôvodných prínosov práce opisujeme v nasledujúcich odsekoch.

Architektúru U-Net sme zmenili pridaním dávkovej normalizácie po každej konvolúcii a pridávaním dropoutu (miery odstránenia prepojení uzlov medzi vrstvami) v konvolučnom bloku po prvej konvolúcii, ako je to vidieť na Obr. 5. Samotný dropout sa mení každou hĺbkovou vrstvou označujúcou hĺbku samotného modelu siete U-Net. Čím hlbšie je ekodér U-Net, tým sa dropout postupne zvyšuje podľa vopred definovanej zmeny dropoutu. V dekódovacej časti dropout neustále klesá na základe hĺbky siete. Podstatným nastavením, ktoré zaručuje variabilitu riešenia naprieč systémom s rôznym počtom sledovaných hodnôt je veľkosť pooling okna. Nakoľko v konečnom dôsledku chceme dostať výslednú predikciu ako maticu o veľkosti $(t, 1, c)$, kde t

STU

označuje počet časových bodov, 1 je na miesto počtu sledovaných hodnôt, pretože nás nezaujíma odpredikovaný stav pre každú premennú, ale pre systém ako taký v konkrétnom časovom bode, a napokon c , ktoré označuje počet tried / stavov, ktoré môže zariadenie nadobúdať. V každom bode tohto objektu dostávame pravdepodobnosť konkrétneho stavu v konkrétnom časovom bode. Aby sme takýto výstup z neurónovej siete dostali, tak sme U-Net architektúru modifikovali.

Nech máme ako vstup do neurónovej siete, ktorý chceme segmentovať, maticu M . Veľkosť matice M nech je daná hodnotou M_s ako:

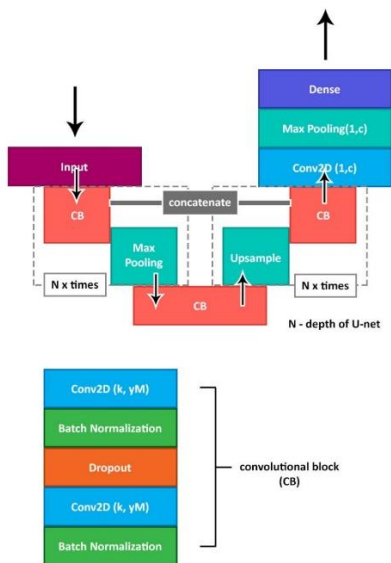
$$M_s = (x_M, y_M) \quad (1)$$

kde hodnota x_M predstavuje šírku matice M a y_M predstavuje výšku matice M . Nech máme k vstupnej matici M vstupnú masku vektor V_M . Tento vektor predstavuje segmentačný vektor po osi x a tak nadobúda veľkosť šírky matice M , x_M . Tento vektor môže nadobúdať hodnoty $< 0, c$), kde c označuje počet segmentačných tried. Maticu M následne rozšírime o ďalšiu dimenziu, čím ju zmeníme na objekt \bar{M} , a jej veľkosť \bar{M}_s bude nadobúdať rozmery $(x_M, y_M, 1)$. Vektor V_M upravíme pomocou metódy „one hot encoding“ na \bar{V}_M tak, aby nadobúdal iba hodnoty 0 alebo 1 a rozšírime ho o ďalšie dve dimenzie tak, aby nadobúdal rozmery $(x_M, 1, c)$, čím ho zmeníme na objekt s rovnakým počtom osí, ako objekt \bar{M} . Úlohou neurónovej siete je určiť masku objektu \bar{M} tak, aby sa zhodovala s jeho skutočnou maskou \bar{V}_M a nadobúdala rozmery $(x_M, 1, c)$. Klasická U-Net architektúra avšak predpovedá masku o veľkosti $(x_M, y_M, 1)$. V rámci architektúry a jej nastavení sme vykonali nasledujúce zmeny:

- Nastavenie veľkosti filtra pri konvolúcii na (k, y_M) , kde k označuje číslo v rozmedzí $(1, x_M)$.
- Nastavenie veľkosti okna poolingingu na $(c, 1)$.
- Zmenu poslednej konvolúcie tak, že veľkosť filtra nebude $(1,1)$ ale otočená veľkosť poolingingu, t.j. $(1, c)$ a aktivačná funkcia bude ReLu.
- Za poslednou konvolúciou bude nasledovať max pooling s otočenou veľkosťou filtra, t.j. $(1, c)$.
- Za max poolingom nasleduje výstupná plne prepojená vrstva s počtom uzlov c .

Vo výsledku dostávame segmentačný algoritmus, ktorý slúži ako segmentátor po x-ovej osi a nazývame ho **xAxis U-Net**. Jeho architektúra je znázornená na Obr. 5 **xAxis U-Net** **xAxis U-Net** je možné využiť aj na segmentovanie po y-ovej osi a to tak, že bude rozdielny oproti segmentačnom algoritme **xAxis U-net** v nasledovných bodoch:

- \bar{V}_M bude nadobúdať rozmery $(1, y_M, c)$.
- Veľkosť konvolučného filtra bude (x_M, k) .
- Veľkosť okna poolingingu bude $(1, c)$ a tým pádom, veľkosť otočeného okna poolingingu bude $(c, 1)$.



Obr. 5 **xAxis U-Net**

Na základe výsledkov algoritmu Ax search bola vybraná zostava modelu. Ax search je vyhľadávaci algoritmus pre hyperparametre modelu. Hľadaním bolo vybraných niekoľko hyperparametrov, ako napríklad: použitie dávkovej normalizácie, hĺbka xAxis U-Net siete,

STU

veľkosť konvolučného jadra k , počet filtrov v prvej hĺbkovej vrstve, pretože ich počet sa zvyšuje každou hĺbkovou vrstvou násobenou poradovým číslom, rýchlosť učenia, dropout a zmena dropoutu do hĺbky. Ako optimalizačný algoritmus sme vybrali ADAM.

Vzhľadom na vysoko nevyvážený dataset, je potrebné zvoliť adekvátnu chybovú funkciu, ako aj evaluačnú metriku. Keďže problém spočíva v definícii viacerých tried, typickým prístupom by bolo použitie kategorickej krížovej entropie ako chybovej funkcie, ale keďže je dataset veľmi nevyvážený, namiesto toho sme použili funkciu s názvom „focal loss“. Focal loss navrhnutá [16] sa zaoberá nerovnováhou pridaním váhového faktora α_t a parametra zaostrenia γ_t , ktorý sa končí definíciou ohniskovej straty ako:

$$FL(p_t) = -\alpha_t(1 - p_t)^\gamma \log(p_t) \quad (2)$$

kde $FL(p_t)$ označuje ohniskovú stratu podľa modelom odhadovanej pravdepodobnosti pre triedu s označením t , $p_t \in [0,1]$. Bola použitá chybová funkcia focal loss s odporúčanými hodnotami $\alpha_t = 0,25$ a $\gamma_t=2,0$.


Ako už bolo spomenuté, dataset je vysoko nevyvážený, a preto sa metrika hodnotenia opisujúca účinnosť poskytovaného riešenia musí zvoliť odlišne a to s dôrazom na skutočnú povahu údajov. V štúdiách [17] a [18] sa Matthewsov korelačný koeficient (MCC) zvolil ako vhodná metrika oproti AUC, Cohenov Kappa a F1 skóre pre vyhodnotenie úspešnosti modelu získanú z nevyváženého datasetu. Matthewsov korelačný koeficient sa rovná:

$$MCC = \frac{tp \times tn - fp \times fn}{\sqrt{(tp + fp)(tp + fn)(tn + fp)(tn + fn)}} \quad (3)$$

kde tn označuje skutočne nesprávne, tp sú skutočné správne, fn sú nesprávne nesprávne a fp sú nesprávne správne. Triedy signálov sú reprezentované ako polia dĺžky rovnajúce sa celkovému počtu tried pozostávajúcich iba z núl a jednotiek. Tam, kde sa vyskytuje číslo 1, to označuje index triedy, do ktorej signál prislúcha.

2.2.3 Princíp vyhodnocovania stavu zariadenia navrhnutým riešením inteligentnej diagnostiky

Zaznamenávané hodnoty zo zariadenia budú postupne predikované tak, že obsiahnu veľkosť časového okna 256 záznamov, tak ako bol model trénovaný, čo predstavuje približne 6,4 sekundy. Výsledok predikcie modelu je objekt o veľkosti $(t, 1, c)$, kde t označuje veľkosť časového okna vzhľadom na počet záznamov a c označuje počet stavov. V každom bode tejto matice je uchovaná hodnota v rozmedzí 0 až 1. Táto hodnota označuje pravdepodobnosť konkrétneho stavu zariadenia v danom časovom bode. Tento objekt pravdepodobností je následne konvertovaný na vektor hodnôt o dĺžke t , kde v každom bode času sa nachádza hodnota označujúca index stavu zariadenia, ktorému bol daný časový bod určený. Toto určenie stavu sa vyhodnotí ako index najvyššej hodnoty v čase bodu t . Nakoľko vyhodnocovanie stavu zariadenia každých 6,4 sekundy nemusí byť dostatočne efektívne, tak je stav zariadenia vyhodnocovaný od prvých 6,4 sekundy od zaznamenávania každú sekundu, čo predstavuje vždy posun o 40 hodnôt. Takúto metódu predikcie je možné označiť ako predikciu kľzavým oknom. Týmto spôsobom sa zaistí aktuálnosť údajov a prípadná korekcia nesprávne predikovaných hodnôt priemerovaním predikcií pre konkrétny časový bod.



Obr. 6 Predikcia kľzavým oknom

STU

2.3 Google Cloud Platform (GCP)

Google Cloud Platform je rozhranie, ktoré nám poskytuje široko-spektrálne cloudové služby. Na to, aby sme dokázali vytvoriť bez-serverový projekt, ktorý by nám poskytoval komunikáciu mechatronického zariadenia a diagnostického systému založeného na umelej inteligencii budeme potrebovať niekoľko služieb, ktoré toto rozhranie ponúka. Budeme potrebovať registrovať zariadenie, ako spárované v rámci IoT štruktúry pomocou IoT Core. Toto zariadenie bude komunikovať s cloudovými službami pomocou Pub/Sub komunikačného toku a preto bude potrebné aktivovať službu rovnakého názvu. Naše zaznamenané dáta si budeme ukladať do vhodnej databázy, akou je BigQuery. Na to, aby sme do tejto databázy uložili prichádzajúce údaje a zároveň aj predikcie umelej inteligencie definujúce stav zariadenia, využijeme Cloud Functions. Bez potreby fyzického či virtuálneho servera, budeme môcť tieto funkcie vždy spúšťať pri určitej udalosti. Aby sme mohli využívať nami natrénovaný model pri online predikciách, budeme potrebovať si ho spolu so zdrojovým kódom potrebným na predikciu uložiť v cloude a to v časti storage ako takzvaný bucket. Následne, keď máme zdrojové kódy aj s natrénovaným modelom umiestnené na cloude, môžeme k nim vytvoriť takzvanú rutinu, kód, ktorý sa spúšťa na požiadanie. V tomto prípade ide o rutinu z rodiny AI platform, v rámci ktorej si vytvoríme obsluhovateľný model.

Na to, aby sme mohli nastaviť GCP služby, budeme potrebovať:

- Prístup na stránku Google Cloud Platform
- OpenSSL
- Python environment

Ako užívateľsky príjemnejšia možnosť je využitie stránky Google Cloud Platform, no je možnosť vytvárania jednotlivých služieb a ich inštancií aj pomocou príkazového riadku buď priamo na stránke v administrátorskom rozhraní zapnutím GCP Shell, alebo stiahnutím si GCP SDK. Dostupný návod ako aj kódy ku konfigurácii GCP sú dostupné v prílohe dizertačnej práce.

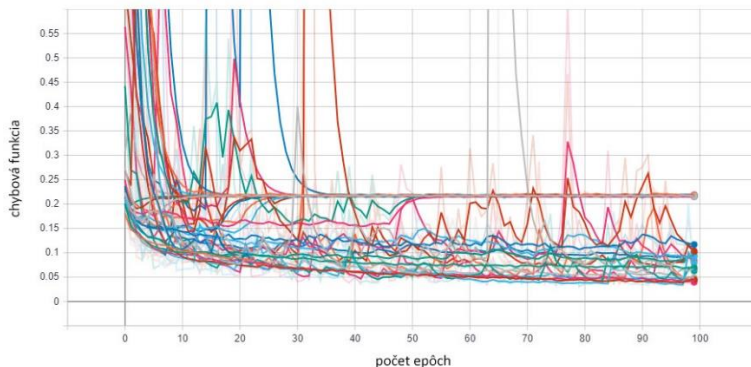
3 Testovanie navrhnutého riešenia a zhodnotenie výsledkov

Navrhovanú architektúru neurónovej siete sme natrénovali a otestovali na 30 rôznych nastaveniach architektúry za účelom nájdania čo najpresnejšie vyhodnocujúceho algoritmu a otestovania aplikovateľnosti na definovaný problém. Sieť sme ladili za pomoci inteligentného vyhľadávania hyperparametrov Ax search, založenom na Bayesovom optimalizačnom algoritme. Nastavenia architektúry boli vybrané z definovaných hladín ako sú uvedené v Tabuľka 4. Použilo sa učenie v dávkach, kde bolo 16 vzoriek na dávku, 100 krokov na epochu a 100 epoch na tréning.

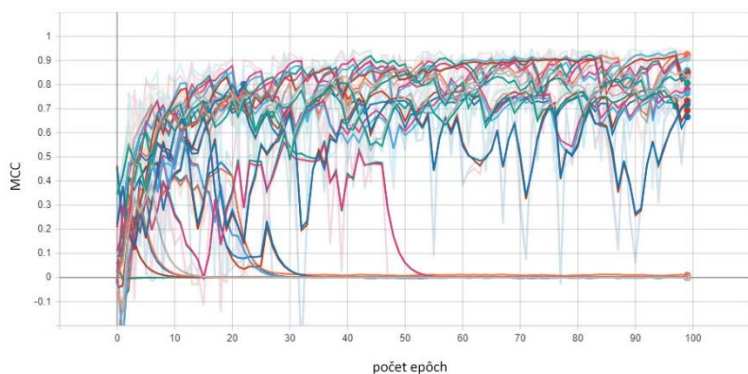
Tabuľka 4 Prvé spustenie hľadania hyperparametrov

<i>Hyperparameter</i>	<i>Minimálna hodnota</i>	<i>Maximálna hodnota</i>
<i>Veľkosť konvolučného filtra</i>	16	32
<i>Počet filtrov v prvej vrstve</i>	32	48
<i>Rýchlosť učenia</i>	0.0001	0.1
<i>Dropout</i>	0.01	0.2
<i>Zmena dropoutu do hĺbky</i>	0.001	0.1
<i>Hĺbka siete</i>	2	4

Počiatkové hľadanie parametrov prinieslo 10 rôznych nastavení architektúry, podľa ktorých bolo možné spozorovať jej určité správanie. Prvým viditeľným znakom bolo, že vysoká rýchlosť učenia spôsobovala, že sieť po niekoľkých epochách zlepšovania padla vo svojej efektívite na 0 a začala určovať triedu predikcie úplne náhodne, čo opisovala nulová hodnota MCC metriky. Samotná chybová funkcia taktiež stúpala a ustálila sa v okolí hladiny 0.2. Tento fenomén zachytávajú obrázky Obr. 7 Priebeh chybovej funkcie naprieč 100 epochami pre prvých 10 rôznych nastavení a Obr. 8 Priebeh vývoja MCC metriky naprieč 100 epochami pre prvých 10 rôznych nastavení. Ďalším znakom bol takmer nulový rozdiel v efektívite medzi architektúrou, ktorá mala hĺbku siete 4 a hĺbku siete 3. Rozdiel bol však viditeľný v rýchlosti učenia. Medzi hĺbkou 2 a 3 už rozdiely badateľné boli a sieť o hĺbke 3 dosahovala lepšie výsledky.



Obr. 7 Priebeh chybovej funkcie naprieč 100 epochami pre prvých 10 rôznych nastavení



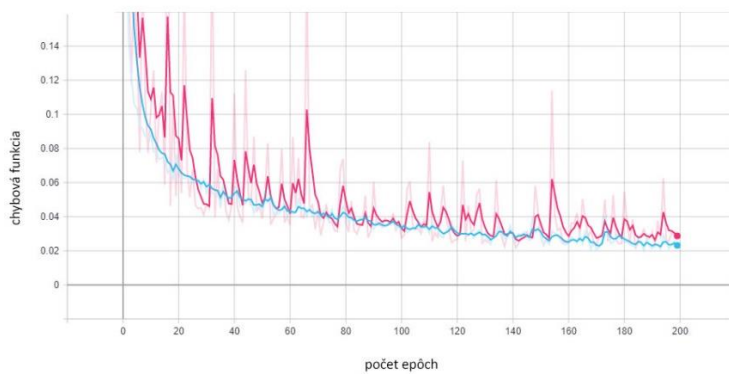
Obr. 8 Priebeh vývoja MCC metriky naprieč 100 epochami pre prvých 10 rôznych nastavení

Vzhľadom na dosahované výsledky bol priestor hyperparametrov upravený tak, ako je zobrazený v Tabuľka 5 Druhé spustenie hľadania hyperparametrov. Hĺbka siete bola fixne definovaná ako hodnota 3.

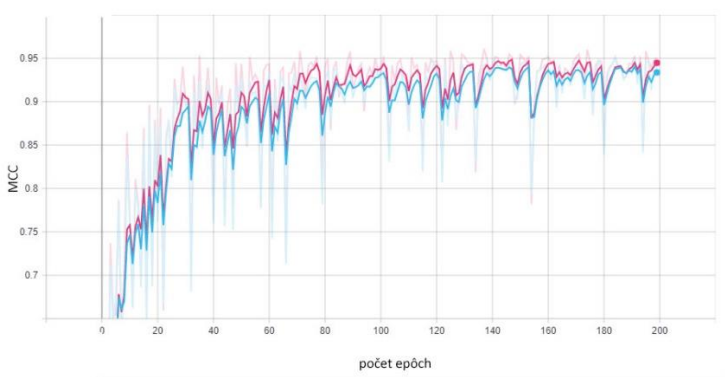
Tabuľka 5 Druhé spustenie hľadania hyperparametrov

<i>Hyperparameter</i>	<i>Minimálna hodnota</i>	<i>Maximálna hodnota</i>
<i>Veľkosť konvolučného filtra</i>	16	32
<i>Počet filtrov v prvej vrstve</i>	32	48
<i>Rýchlosť učenia</i>	0.00001	0.01
<i>Dropout</i>	0.01	0.2
<i>Zmena dropoutu do hĺbky</i>	0.0001	0.01

Rádovým znížením hladín rýchlosti učenia a spomalenia dropoutu do hĺbky sa úplne eliminoval problém modelov s náhodnou predikciou. Modelov v tejto konštelácii bolo vygenerovaných 20. Sledovaná hodnota bola maximálna hodnota validačnej metriky MCC v priebehu tréningu. Na základe tejto hodnoty bolo vybraných 5 najlepších modelov. Všetky dosahovali hodnotu MCC na validačnej vzorke v rozmedzí od 0,96 po 0,964. Po preskúmaní krivky chybovej funkcie bol viditeľný trend stúpania chybovej funkcie na validačnej vzorke v okolí 140 epochy v 3 prípadoch z 5 najlepších modelov. V takomto prípade už dochádza k pretrénovaniu modelu a model samotný už viac nie je schopný sa zlepšovať, preto bola vybraná konfigurácia, ktorá dosahovala v rámci hľadania hyperparametrov nižšie hodnoty, avšak aj po 200 epochách sa ešte stále model zlepšoval.



Obr. 9 Chybová funkcia vybraného modelu po druhom kole hľadani hyperparametrov



Obr. 10 MCC metrika vybraného modelu po druhom kole hľadání hyperparametrov

Takto vybraný model bol následne natrénovaný na 500 epochách. Aj keď sa na prvý pohľad zdalo, že by model mohol časom dosahovať lepšie výsledky, po 300 epochách sa začal pretrénovávať, do epochy 300 sa pohyboval v podobných hladinách a neskôr jeho chybová funkcia na validačných dátach začala rásť.

Model pre predikciu chýb na zariadení FloatShield pozostáva celkom z 14,737,928 parametrov, z ktorých je 14,734,408 trénovateľných parametrov a 3,520 nie sú trénovateľnými parametrami. Keďže model pre predikciu chýb na zariadení MotoShield sleduje dvakrát toľko hodnôt čo model pre FloatShield, tak obsahuje aj dvakrát toľko parametrov. Po natrénovaní segmentačných modelov dosahovali najvyššie validačné hodnoty MCC nasledovne:

Tabuľka 6 Výsledky MCC evaluačných metrick získaných modelov na testovacích dátach

<i>xAxis U-Net</i>	<i>Trénovacie MCC</i>	<i>Validačné MCC</i>
<i>FloatShield</i>	0.9467	0.9659
<i>MotoShield</i>	0.9808	0.9676

Vybraný a natrénovaný model pre FloatShield a MotoShield boli otestované na testovacích dátach. Pre bližšiu špecifikáciu výsledkov sa sledovalo klasifikačné skóre pozostávajúce z vlastností akými sú presnosť, sensitivita, F1 skóre, správnosť, makro priemer a vážený priemer. Presnosť je definovaná ako percentuálne vyjadrenie správne určených predikcií ako takých, to znamená, že správne model predikoval pozitívny aj negatívny výskyt danej triedy. Sensitivita je percentuálny podiel iba správne určených pozitívnych predikcií. F1 skóre sleduje vážený harmonický priemer presnosti a sensitivity, čiže sa zameriava predovšetkým na určenie správnych predikcií.


Tabuľka 7 Klasifikačné skóre diagnostického algoritmu pre FloatShield

	<i>Presnosť</i>	<i>Sensitivita</i>	<i>F1 skóre</i>	<i>Počet vzoriek</i>
0	0.99	0.99	0.99	29696
1	0.98	0.98	0.98	49664
2	0.96	0.93	0.94	3584
3	1.00	0.96	0.98	19456
4	0.99	1.00	0.99	3584
5	0.80	0.94	0.86	4352
<i>Správnosť</i>			0.98	110336
<i>Makro priemer</i>	0.95	0.97	0.96	110336
<i>Vážený priemer</i>	0.98	0.98	0.98	110336

Na základe Tabuľka 7 Klasifikačné skóre diagnostického algoritmu pre FloatShield je možné badať, že algoritmus diagnostiky zariadenia pre FloatShield má najväčší problém so stavom číslo 5 a ako druhý najhoršie určený stav je stav číslo 2. FloatShield je definovaný 2 premennými a jeho stav je zaraďovaný do jednej zo šiestich kategórií. Stav číslo 5 určuje prípad, kedy sa loptička uvoľnila zo zaseknutého stavu, avšak otáčky ventilátora sú neprimerane vysoké a postupne sa znižujú. V takomto prípade je loptička vyfúknutá na vrch tuby a nedosahuje želanú výšku. Jedná sa o extrém. V prípade chyby označenej číslom 2 sa jedná o opačný extrém, čo sa týka výšky loptičky. V tomto prípade je loptička tlačaná smerom nadol ťažkým telesom a ventilátor postupne navyšuje otáčky, aby loptičku dostal do požadovanej výšky.

Matica zámény nám zobrazuje podiel správne predikovaných tried stavov po diagonále a odchýlky v ostatných miestach matice. Podiel je uvádzaný v percentách. Y-ová os nám označuje skutočné

triedy stavov, zatiaľ čo x-ová os označuje predikované triedy stavov. Z matice zámény je možné vyčítať, v ktorých triedach stavov sa najviac algoritmus mýlil a za aké iné triedy svoje predikcie nahrádzal. V prípade predikcie stavu 2 aj stavu 5 si ich algoritmus najviac mýlil so stavom 1, ktorý označuje chybu, kedy do tuby padlo ľahké teleso, ktoré častokrát blokovalo výškový senzor a ventilátor dosahoval nižšie otáčky, než mal. Samotný charakter chýb je značne odlišný a preto je obťažné určiť príčinu tejto zlej predikcie.




Obr. 11 Matica zámény pre FloatShield

Vybraný a natrénovaný model pre MotoShield bol otestovaný a vyhodnotený na testovacích dátach. MotoShield má 4 sledované hodnoty a dosahuje 4 rôzne stavy. Tabuľka 8 vyobrazuje klasifikačné skóre diagnostického algoritmu pre MotoShield. Navrhnutá architektúra v prípade MotoShieldu dosahuje rovnaké až lepšie celkové výsledky v každom smere. Dôvodom môže byť väčší objem nameraných dát, väčší počet sledovaných hodnôt ako aj menší počet sledovaných stavov.

Tabuľka 8 Klasifikačné skóre diagnostického algoritmu pre MotoShield

	<i>presnosť</i>	<i>sensitivita</i>	<i>F1 skóre</i>	<i>Počet vzoriek</i>
0	1.00	1.00	1.00	150528
1	0.96	0.96	0.96	75520
2	0.96	0.97	0.96	75520
3	0.97	0.96	0.97	3072
<i>správnosť</i>			0.98	304640
<i>Makro priemer</i>	0.97	0.97	0.97	304640
<i>Vážený priemer</i>	0.98	0.98	0.98	304640

Najčastejšia zámena kategórií stavov vyplývajúca z matice zámény z Obr. 12 Matica zámény pre MotoShield je pre stav číslo 1. Stav číslo 1 opisuje prípad, kedy cudzie teleso zasahovalo do ozubených koliesok motorčeka. Najčastejšie je tento stav zamieňaný so stavom číslo 2, ktorý predstavuje prípad pôsobenia magnetu rôznej intenzity na rôznych miestach.



Obr. 12 Matica zámény pre MotoShield



Kroky toku dát sú definované v bodoch s ich priemerným trvaním v sekundách:

- Spustenie funkcie čítania prichádzajúcich dát od poslednej časovej pečiatky (0,003s).
- Prečítanie prichádzajúcich dát (0,288s).
- Vloženie dát do databázy (0,068s).
- Načítanie kľzavého okna za databázy (1,233s).
- Normalizácia dát a ich príprava (0,012s).
- Predikcia stavu v oblasti segmentačného okna (0,505s).
- Transformácia predikcie na tabuľkové dáta (0,012s).
- Uloženie predikcie do databázy (0,176s).

Spracovávanie rýchlosti jednotlivých krokov z celkového hľadiska trvá približne 2,3 sekundy. Tento čas by bolo možné skrátiť v bode predikcie výberom parametrov výkonnejších mašín a v bode načítania kľzavého okna priebežným premazávaním databázy s dočasnými dátami a ukladaním dát zmien do samostatnej databázy.

4 Diskusia

Novodobé informačno-komunikačné technológie v oblasti priemyslu udávajú smer, ktorým sa realizácia výrobných procesov uberá. Postupnou digitalizáciou jednotlivých častí tovární získavame nesmierny objem údajov o jednotlivých procesoch ale predovšetkým o stavoch zariadení. Práve mechatronické zariadenia sú jednou z hlavných základných zložiek výroby a od nich sa odvíjajú mnohé ďalšie postupy. Vhodným diagnostikovaním mechatronického systému je možné optimalizovať výrobné procesy tak, aby dochádzalo k výpadkom vo výrobe čo najmenej a bolo možné včas zachytiť vznikajúce chyby na zariadeniach a tak adekvátne nastaviť plánovanú údržbu.

V súčasnosti existuje viacero projektov a štúdií, ktoré sa zameriavajú na inteligentnú diagnostiku, avšak najčastejšie sa jednotlivé vedecké výskumy zameriavajú na konkrétne zariadenia, či sledovanie stavu zariadenia na základe jednej meranej veličiny, čo v mnohých prípadoch nemusí efektívne odhaliť vzniknutú chybu. Spôsob vyhodnocovania stavu zariadenia inteligentnými metódami sa zväčša vykonáva na základe predikcie stavu sledovaného časového úseku ako celku, bez možnosti náhľadu do jednotlivých bodov v čase, pričom jeden časový úsek je vyhodnotený iba raz, čo môže mať za následok zmazávanie a generalizovanie vlastností zariadenia a tým odstránenie skorej detekcie chyby na zariadení.

Z týchto dôvodov má dizertačná práca ako jeden z hlavných dôvodov navrhnuté a implementovať algoritmy inteligentnej diagnostiky mechatronických systémov pre včasné detegovanie chyby na zariadení. Ďalším cieľom dizertačnej práce je návrh a implementácia prepojenia inteligentnej diagnostiky s mechatronickým systémom v rámci konceptu Industry 4.0.

Autorkou navrhnuté algoritmy inteligentnej diagnostiky mechatronických zariadení prezentované v dizertačnej práci sú zovšeobecniteľné a je ich možné aplikovať na mechatronické systémy sledované v čase. Autorkou predstavený segmentačný algoritmus je možné využiť nie len v priemysle, ale v akomkoľvek odvetví, v ktorom je potrebná segmentácia dvojrozmerných vstupných dát po x-ovej alebo y-ovej osi. Takto navrhnutý inteligentný algoritmus postavený na princípoch hlbokého učenia je v rámci konceptu Industry 4.0 implementovaný a overený na modelových zariadeniach. Tieto inteligentné metódy diagnostiky mechatronických systémov sú

prepojené s reálnym zariadením a decentralizovanou výpočtovou jednotkou umiestnenou v cloude na základe autorkou navrhnutom komunikačnom koncepte.

V rámci narastajúcich požiadaviek na optimalizáciu výroby je záujem o inteligentné metódy diagnostiky zariadení a systémov čoraz väčší a ich včasné a úspešné vyhodnotenie ovplyvňuje celý chod výroby. Včasným detegovaním anomálií správania zariadenia je možné predísť neplánovaným odstávkam, je možné zníženie dopadu vzniknutej chyby na zariadenie a tak predísť kritickým situáciám. V kontraste s riešeniami poskytujúcimi identifikáciu a klasifikáciu stavu zariadenia v zhlukoch poskytuje riešenie predstavené v dizertačnej práci možnosti odhalenia chýb, ktoré sa za konvenčných podmienok môžu objaviť až v prípade, kedy táto chyba zasiahla systém dlhodobo, o mnoho skôr a na základe diagnostiky navrhnutej autorkou práce je možné sledovať a pozorovať vzory správania zariadenia, ktoré k dlhodobej chybe smerujú.

Navrhnutý princíp inteligentnej diagnostiky stavu mechatronických zariadení implementovaný do navrhnutého konceptu modernej komunikácie s výpočtovou jednotkou, ktorý je prezentovaný v rámci tejto dizertačnej práce napomáha rýchlejšiemu odhaleniu chyby zariadení a ich vzoroch ich postupného nástupu a výskytu.

Záver

Predložená dizertačná práca sa zaoberá aktuálnou problematikou diagnostiky stavu zariadenia a vhodného zareagovania v kritických prípadoch v kontexte Industry 4.0. Výsledkom práce je modulárne riešenie diagnostikovania stavu zariadenia v online priestore a včasná detekcia chyby na zariadení. Riešenie dizertačnej práce sa nespolieha na dávkové predikovanie stavu zariadenia, ale zameriava sa na jemnejšie spôsoby predikcie. Práca využíva moderný inteligentný prístup ku komunikácii zariadenia s výpočtovou jednotkou a analýzou nelineárnych spojitostí získaných zo zariadenia v každom bode času. Dizertačná práca je zložená zo siedmych kapitol.

Prínos dizertačnej práce spočíva v návrhu, vývoji a overení metodiky, inteligentných metód a algoritmov diagnostiky technologických zariadení, prostredníctvom najnovších architektúr hlbokých neurónových sietí. Autorka dizertačnej práce pomocou najnovších metód učenia a architektúry hlbokých neurónových sietí navrhla vlastný inteligentný systém diagnostiky, modifikovala tieto metódy a vylepšila pôvodné algoritmy modelovania stavov zariadení a procesov, tak boli využiteľné pre aplikácie v moderných priemyselných procesoch pre úlohy prediktívnej údržby. Oproti konvenčným postupom diagnostiky navrhovaný inteligentný prístup umožňuje na základe inteligentnej detailnej analýzy stavov jednotlivých zariadení vo výrobných a technologických procesoch analyzovať ich stav, predikovať údržbu a tým optimálne dohliadať nad poruchovosťou zariadení. Práca využíva moderný prístup ku komunikácii zariadenia s výpočtovou jednotkou a analýzou nelineárnych spojitostí vlastností získaných zo zariadenia v každom bode času.

Úvodné tri kapitoly sa zameriavajú na prieskum najnovších technológií v odvetví a ich budúce smerovaniu. Prvá kapitola sa zameriava na najnovšie trendy v oblasti informačno-komunikačných technológií v priemysle v znení paradigmy Industry 4.0. Dôraz kladie na koncept a prepojenie jednotlivých vlastností tohto najnovšieho smerovania technológií vo výrobe. Druhá kapitola sa zameriava na umelú inteligenciu a umelé neurónové siete. Vymedzuje základné pojmy a princípy inteligentných technológií v teórii aj v praxi. Zameriava sa na pochopenie komplexu hlbokého učenia, vhodného pre aplikovanie inteligentných technológií v oblasti BigData. Tretia kapitola sa venuje výskumným činnostiam za posledných 5 rokov v oblasti inteligentnej

diagnostiky stavu rôznorodých zariadení. Smeruje svoju pozornosť na spôsoby a aplikácie umelých neurónových sietí na detegovanie chyby zariadenia.

Na tretiu kapitolu nadväzuje kapitola štvrtá, ktorá pojednáva o cieľoch práce, je formulovaný problém, ktorý práca rieši. Je predstavený základný koncept komunikácie zariadenia s výpočtovou jednotkou a inteligentnej diagnostiky zariadenia.

Piata až siedma kapitola tvoria ťažisko dizertačnej práce, v rámci ktorých je uvedený originálny prístup a pracovné postupy, ako aj dosiahnuté výsledky práce. V rámci piatej kapitoly je prezentovaný autorkou vytvorený návrh systému monitorovania a riadenia mechatronických systémov s dôrazom na inteligentnú diagnostiku stavu zariadenia a vhodného zareagovania na prípadné vzniknuté kritické chyby. Návrh pozostáva z definovania požiadaviek na systém a následne navrhnutého konceptu riešenia rozdeleného na tri úrovne: úroveň zariadenia, úroveň výpočtovej jednotky – moderného decentralizovaného prístupu cez cloudové služby a napokon úroveň prepojenia jednotlivých komponentov v rámci cloudu aj mimo neho. Šiesta kapitola sa venuje opisu implementácie riešenia opísaného v dizertačnej práci. Autorkou navrhnutý spôsob komunikácie je implementovaný a predvedený na laboratórnych zariadeniach na výučbu ovládania a fungovania mechatronických systémov vzduchovej levitácie a motorčeka. Tieto zariadenia sú opísané po stránke konštrukcie, ovládania ako aj prepojenia so vzdialenou výpočtovou jednotkou pomocou bezdrôtovej komunikácie. Šiesta kapitola ďalej opisuje autorkou navrhnuté algoritmy inteligentného vyhodnocovania stavu zariadenia na základe viacerých nelineárne súvisiacich sledovaných hodnôt v čase. Definuje charakter získaných údajov zo zariadení, autorkou navrhnujej architektúry neurónovej siete tak, aby spĺňala podmienky jemného vyhodnocovania stavu zariadenia. Tento spôsob vyhodnocovania je definovaný na konci sekcie inteligentnej diagnostiky šiestej kapitoly. Posledná sekcia šiestej kapitoly sa venuje konfigurácii cloudových služieb, databáze údajov, prepojenia jednotlivých komponentov a autorkou navrhnutým algoritmom na obsluhovanie prichádzajúcich údajov zo zariadenia. Siedma kapitola sa venuje overeniu princípov navrhnutých algoritmov v offline aj v online priestore – a teda v produkčnom nasadení. Algoritmy sú testované a ich úspešnosť vyhodnocovaná na príkladoch. Na základe dosiahnutých výsledkov je možné konštatovať, že implementovaním metód inteligentnej diagnostiky je možné včas podchytiť a reagovať na vznikajúce či vzniknuté problémy spojené s behom zariadenia.

Výsledky dizertačnej práce sú prezentované v siedmej kapitole a predstavujú vedecký a aplikačný prínos k rozvoju študijného odboru kybernetika a mechatronika. Vedecko-aplikačné prínosy dizertačnej práce sú založené na návrhu, realizácii a verifikovaní systému kontinuálnej hĺbkovej inteligentnej diagnostiky zariadenia ako aj samotných algoritmov umelej inteligencie na rozoznávanie jednotlivých vlastností opisujúcich rôzne stavy zariadenia a ich aplikovaní v diagnostickom procese zdravia zariadenia. Prezentované autorkou navrhnuté metódy a postupy definované v dizertačnej práci využívajú princípy konceptu digitalizácie výroby Industry 4.0.

Prínosy dizertačnej práce je možné zhrnúť do nasledovných bodov:

- **Návrh metodiky komunikácie zariadenia s výpočtovou jednotkou v súlade s paradigmou Industry 4.0.**
- **Návrh vlastných inteligentných algoritmov na báze metód hlbokého učenia pre kontinuálnu diagnostiku zariadenia.**
- **Programová realizácia a implementácia navrhutej metodiky komunikácie zariadenia a inteligentnej jednotky v prostredí cloudu.**
- **Overenie efektivity navrhnutých inteligentných diagnostických algoritmov na báze hlbokého učenia ako aj navrhnutého a implementovaného online systému diagnostiky na dvoch mechatronických laboratórnych fyzikálnych modeloch.**

Dané prínosy dizertačnej práce definované v predošlých bodoch predstavujú posledné trendy v oblasti výskumu, vývoja a aplikovania nových postupov a prístupov monitorovania a riadenia mechatronických systémov na báze umelej inteligencie so zameraním na diagnostické postupy do praxe. Výsledky práce sú zovšeobecniteľné a je možné ich ďalej modifikovať pre ďalší výskum a technickú prax aj pre iné odvetvia priemyslu.

Prínos pre vedu a prax

- Analýza moderných prístupov informačno-komunikačných technológií
- Analýza spôsobov inteligentnej diagnostiky mechatronických zariadení
- Návrh algoritmov inteligentnej diagnostiky
- Návrh implementácie algoritmov inteligentnej diagnostiky v Industry 4.0
- Návrh vlastných segmentačných algoritmov
- Implementácia algoritmov inteligentnej diagnostiky
- Vytvorenie funkčného prototypu inteligentnej diagnostiky
- Využitie výsledkov merania a testovania úspešnosti inteligentnej diagnostiky pre laboratórne mechatronické zariadenia FloatShield a MotoShield
- Vytvorenie systému decentralizovanej komunikácie zariadenia s výpočtovou jednotkou za použitia moderných technológií cloudu
- Riešenie včasného odhaľovania chýb na mechatronických zariadeniach
- Možnosť aplikovania algoritmov inteligentnej diagnostiky na široké spektrum mechatronických zariadení
- Možnosť aplikovania spôsobu komunikácie a vyhodnocovania stavov rôznych zariadení

Publikačná činnosť autora

ADF Vedecké práce v ostatných domácich časopisoch

- **ADF01** KÉPEŠIOVÁ, Zuzana - KOZÁK, Štefan. An effective face detection algorithm for client-side web-based solutions. In Information Technology Applications = Aplikácie informačných technológií. Vol. 7, No. 2 (2018), s. 43-53. ISSN 1338-6468.
- **ADF02** KÉPEŠIOVÁ, Zuzana - KOZÁK, Štefan. Comparison of regularization and optimization methods for process recognition with use of deep neural network. In Information Technology Applications. Vol. 8, No. 2 (2019), s. 5-13. ISSN 1338-6468.
- **ADF03** KÉPEŠIOVÁ, Zuzana - CIGÁNEK, Ján - KOZÁK, Štefan. Detecting awareness state of a driver during driving. In Information Technology Applications. Vol. 8, No. 2 (2019), s. 45-56. ISSN 1338-6468.

AFC Publikované príspevky na zahraničných vedeckých konferenciách

- **AFC01** KÉPEŠIOVÁ, Zuzana - ROSINOVÁ, Danica - KOZÁK, Štefan. Comparison of optimization techniques for process recognition using deep neural network. In ACCS/PEIT 2019 : 6th International conference on advanced control circuits and systems; 5th International conference on new paradigms in electronics & information technology. Hurghada, Egypt. November 17-20, 2019. Danvers : IEEE, 2019, S. 191-196. ISBN 978-1-7281-6354-3. V databáze: IEEE: 9062866 ; DOI: 10.1109/ACCS-PEIT48329.2019.9062866.
- **AFC02** KÉPEŠIOVÁ, Zuzana - CIGÁNEK, Ján - KOZÁK, Štefan. Driver drowsiness detection using convolutional neural networks. In 2020 Cybernetics & Informatics (K&I) [elektronický zdroj] : 30th International Conference. Velké Karlovice, Czech Republic. January 29-February 1, 2020. 1. ed. Danvers : IEEE, 2020, [6] s. ISBN 978-1-7281-4381-1. V databáze: IEEE: 9039851 ; SCOPUS: 2-s2.0-85083114701 ; DOI: 10.1109/KI48306.2020.9039851.
- **AFC03** CIGÁNEK, Ján - KÉPEŠIOVÁ, Zuzana. Processing and visualization of medical images using machine learning and virtual reality. In 2020 Cybernetics &

Informatics (K&I) [elektronický zdroj] : 30th International Conference. Velké Karlovice, Czech Republic. January 29-February 1, 2020. 1. ed. Danvers : IEEE, 2020, [6] s. ISBN 978-1-7281-4381-1. V databáze: IEEE: 9039896 ; SCOPUS: 2-s2.0-85083113151 ; DOI: 10.1109/KI48306.2020.9039896.

AFD Publikované příspěvky na domácích vědeckých konferencích

- **AFD01** KÉPEŠIOVÁ, Zuzana - KOZÁK, Štefan. An effective face detection algorithm. In 2018 Cybernetics & Informatics (K&I) [elektronický zdroj] : 29th International Conference. Lazy pod Makytou, Slovakia. January 31-February 3, 2018. 1. vyd. Bratislava : Slovak Chemical Library, 2018, USB, [6] s. ISBN 978-1-5386-4420-1. V databáze: IEEE: 8337566 ; WOS: 000454633500037 ; SCOPUS: 2-s2.0-85050939647.
- **AFD02** KÉPEŠIOVÁ, Zuzana - ROSINOVÁ, Danica. Application of face detection algorithm on client's side of web solutions by using JavaScript library Tracking.js. In ELITECH'18 [elektronický zdroj] : 20th Conference of doctoral students. Bratislava, Slovakia. May 23, 2018. 1. ed. Bratislava : Vydavateľstvo Spektrum STU, 2018, CD-ROM, [6] p. ISBN 978-80-227-4794-3.
- **AFD03** KÉPEŠIOVÁ, Zuzana - KOZÁK, Štefan. Smart factory in Industry 4.0. In ELITECH'20 [elektronický zdroj] : 22nd Conference of doctoral students. Bratislava, Slovakia. May 27, 2020. 1. ed. Bratislava : Vydavateľstvo Spektrum STU, 2020, [6] s. ISBN 978-80-227-5001-1.
- **AFD04** KÉPEŠIOVÁ, Zuzana. Theoretical proposal of diagnostic and educational tool using digital twin and augmented reality. In ELITECH'19 [elektronický zdroj] : 21st Conference of doctoral students. Bratislava, Slovakia. May 29, 2019. 1. ed. Bratislava : Vydavateľstvo Spektrum STU, 2019, CD-ROM, [7] s. ISBN 978-80-227-4915-2.



ADM Vedecké práce v zahraničných časopisoch registrovaných v databázach Web of Science alebo SCOPUS

- **AFD01** KÉPEŠIOVÁ, Zuzana - KOZÁK, Štefan - ROSINOVÁ, Danica. Detection and Classification of Air Levitation Device Faults Based on Fully Convolutional Autoencoder Using Deep Learning. In Neural Computing and Applications. Poznámka: Článok v recenznom konaní

Riešiteľka projektov

- 016STU-4/2020 - Virtuálna a zmiešaná realita vo výučbe pre Industry 4.0
- 030STU-4/2017 - Laboratórium digitálnych tovární s podporou IoT

Ostatné

- Vedenie bakalárskych prác: 10ks

Zoznam použitej literatúry

- [1] S. Venkatesan, K. Manickavasagam, N. Tengen kai a N. Vijayalakshmi, „Health monitoring and prognosis of electric vehicle motor using intelligent-digital twin,“ *IET Electric Power Applications*, zv. 13, %1. vyd.9, p. 1328 – 1335, 2019.
- [2] Y. Xu, Y. Sun, X. Liu a Y. Zheng, „A Digital-Twin-Assisted Fault Diagnosis Using Deep Transfer Learning,“ *IEEE Access*, zv. 7, pp. 19990 - 19999, 2019.
- [3] X. Guo, L. Chen a C. Shen, „Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis,“ *Measurement*, zv. 93, pp. 490-502, 2016.
- [4] W. Zhang, C. Li, G. Peng, Y. Chen a Z. Zhang, „A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load,“ *Mechanical Systems and Signal Processing*, zv. 100, pp. 439-453, 2018.
- [5] O. Janssens, V. Slavkovikj, B. Vervisch, K. Stockman, M. Loccufer, S. Verstockt, R. Van de Walle a S. Van Hoecke, „Convolutional Neural Network Based Fault Detection for Rotating Machinery,“ *Journal of Sound and Vibration*, zv. 377, pp. 331-345, 2016.
- [6] L. Wen, X. Li, L. Gao a Y. Zhang, „A New Convolutional Neural Network-Based Data-Driven Fault Diagnosis Method,“ *IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS*, zv. 65, %1. vyd.7, pp. 5990-5998, 2018.
- [7] H. Liu, J. Zhou, Y. Zheng, W. Jiang a Y. Zhang, „Fault diagnosis of rolling bearings with recurrent neural network-based autoencoders,“ *ISA Transactions*, zv. 77, pp. 167-178, 2018.
- [8] H. Zhao, S. Sun a B. Jin, „Sequential Fault Diagnosis Based on LSTM Neural Network,“ *IEEE Access*, zv. 6, pp. 12929-12939, 2018.
- [9] F. Jia, Y. Lei, L. Guo, J. Lin a S. Xing, „A neural network constructed by deep learning technique and its application to intelligent fault diagnosis of machines,“ *Neurocomputing*, zv. 272, pp. 619-628, 2018.
- [10] W. Sun, S. Shao, R. Zhao, R. Yan, X. Zhang a X. Chen, „A sparse auto-encoder-based deep neural network approach for induction motor faults classification,“ *Measurement*, zv. 89,

pp. 171-178, 2016.

- [11] S. Haidong, J. Hongkai, Z. Huiwei a W. Fuan, „A novel deep autoencoder feature learning method for rotating machinery fault diagnosis,“ *Mechanical Systems and Signal Processing*, zv. 95, pp. 187-204, 2017.
- [12] T. Gergely, C. Peter, M. Gulan, E. Mikuláš, J. Kulhánek, G. Penzinger, M. Vdoleček, M. Podbielančík, M. Lučan, P. Šálka a D. Šroba, „FloatShield: An Open Source Air Levitation Device for Control Engineering Education,“ rev. *21st IFAC World Congress*, Berlin, 2020.
- [13] G. Takács, „AutomationShield,“ [Online]. Available: <https://github.com/gergelytakacs/AutomationShield/>. [Cit. 12 11 2019].
- [14] O. Ronneberger, P. Fischer a T. Brox, „U-Net: Convolutional Networks for Biomedical Image Segmentation,“ rev. *International Conference on Medical image computing and computer-assisted intervention*, 2015.
- [15] M. Perslev, M. H. Jensen, S. Darkner, P. J. Jennum a C. Igel, „U-Time: A Fully Convolutional Network for Time Series Segmentation Applied to Sleep Staging,“ rev. *33rd Conference on Neural Information Processing Systems (NeurIPS 2019)*, Vancouver, 2019.
- [16] T.-Y. Lin, . P. Goyal, . R. Girshick, . K. He a P. Dollár, „Focal Loss for Dense Object Detection,“ *IEEE Transactions on Pattern Analysis and Machine Intelligence*, zv. 42, %1. vyd.2, pp. 318 - 327, 2018.
- [17] G. Jurman, S. Riccadonna a C. Furlanello, „A Comparison of MCC and CEN Error Measures in Multi-Class Prediction,“ *PLoS ONE*, zv. 7, %1. vyd.8, 2012.
- [18] R. Delgado a X.-A. Tibau, „Why Cohen’s Kappa should be avoided as performance measure in classification,“ *PLoS ONE*, zv. 14, %1. vyd.9, 2019.