



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA STROJNÍHO INŽENÝRSTVÍ

FACULTY OF MECHANICAL ENGINEERING

ÚSTAV MECHANIKY TĚLES, MECHATRONIKY A BIOMECHANIKY

INSTITUTE OF SOLID MECHANICS, MECHATRONICS AND BIOMECHANICS

REŠERŠE METOD POUŽITÍ KOMBINACE DATA-DRIVEN A MODEL-BASED METOD V OBLASTI DIAGNOSTIKY TECHNICKÝCH SOUSTAV

POSSIBILITIES OF USE OF DATA-DRIVEN AND MODEL-BASED METHODS IN DIAGNOSTICS - STATE OF THE ART

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Aida Fazlić

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jiří Kovář, Ph.D.

BRNO 2021

Zadání bakalářské práce

Ústav: Ústav mechaniky těles, mechatroniky
a biomechaniky

Studentka: **Aida Fazlić**

Studijní program: Aplikované vědy v inženýrství

Studijní obor: Mechatronika

Vedoucí práce: **Ing. Jiří Kovář, Ph.D.**

Akademický rok: 2020/21

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách a se Studijním a zkušebním řádem VUT v Brně určuje následující téma bakalářské práce:

Rešerše metod použití kombinace data-driven a model-based metod v oblasti diagnostiky technických soustav

Stručná charakteristika problematiky úkolu:

Trendem v oblasti diagnostiky technických soustav je dnes použití kombinace data--driven a model-based metod – někdy také označováno jako hybridní přístup. Tento přístup umožňuje přesnější diagnostiku technické soustavy, nicméně s rostoucím počtem metod není snadné zvolit k tomuto úkolu vhodnou kombinaci metod.

Cíle bakalářské práce:

Provedte rešerši stávajícího stavu v uvedené oblasti – kombinace data-driven a model-based metod v diagnostice technických soustav.

Vyberte typickou technickou soustavu v oblasti výrobních strojů a navrhnete vhodnou kombinaci metod za účelem její diagnostiky.

Seznam doporučené literatury:

CZICHOS, H., Handbook of Technical Diagnostics, 2013, ISBN: 3642258492.

KADRY, S., Diagnostics and Prognostics of Engineering Systems: Methods and Techniques, 2012, ISBN: 1466620951.

Termín odevzdání bakalářské práce je stanoven časovým plánem akademického roku 2020/21.

V Brně dne

L. S.

.....
prof. Ing. Jindřich Petruška, Ph.D.
ředitel ústavu

.....
doc. Ing. Jaroslav Katolický,
děkan fakulty

Abstrakt

Tato práce se zabývá data-driven a model-based metodami v oblasti diagnostiky technických soustav a použitím kombinace data-driven a model-based metod. Tato kombinace bývá v literatuře nejčastěji označována jako hybridní přístup.

Abstract

This thesis describes data-driven and model-based methods in the field of diagnostics of technical systems and the use of a combination of data-driven and model-based methods. This combination is often known in the literature as a hybrid approach.

Klíčová slova

Diagnostika, model-based metody, data-driven metody, hybridní přístup, Digital Twin, RUL, CNCMT

Keywords

Diagnostics, Model-based methods, Data-driven methods, Hybrid approach, Digital Twin, RUL, CNCMT

Bibliografická citace

FAZLIĆ, Aida. *Rešerše metod použití kombinace data-driven a model-based metod v oblasti diagnostiky technických soustav* [online]. Brno, 2021 [cit. 2021-04-24]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/131924>. Bakalářská práce. Vysoké učení technické v Brně, Fakulta strojního inženýrství, Ústav mechaniky těles, mechatroniky a biomechaniky. Vedoucí práce Jiří Kovář.

Čestné prohlášení

Prohlašuji, že jsem bakalářskou práci „Rešerše metod použití kombinace data-driven a model-based metod v oblasti diagnostiky technických soustav“ vypracovala samostatně s použitím odborné literatury a pramenů uvedených v seznamu, který tvoří přílohu této práce.

19. května 2021

.....

Aida Fazlić

Poděkování

Nejprve bych chtěla poděkovat Vládě České republiky za to, že mi poskytla kurz češtiny a že mi poskytnutím stipendia umožnila studium na VUT.

Chtěla bych poděkovat i vedoucímu mé práce panu Ing. Jiřímu Kovářovi, Ph.D. za doporučení a rady.

Nakonec děkuji své rodině a přátelům, kteří mě vždy povzbuzovali.

Obsah

1	Úvod.....	6
2	Motivace a cíl práce	7
3	Současný stav řešené problematiky	8
3.1	Diagnostika technických soustav	8
3.2	Data-driven metody v oblasti diagnostiky	10
3.3	Model-based metody v oblasti diagnostiky.....	15
3.4	Kombinace data-driven a model-based metod – hybridní metoda.....	18
3.4.1	Digital Model, Digital Shadow a Digital Twin (DT) koncept	20
4	Zaměření na konkrétní oblast.....	25
4.1	Diagnostika a prognostika hybridní metodou na konkrétním příkladu CNC obráběcího stroje za účelem udržování jeho kvality	25
4.2	Aplikace data-driven, model-based a hybridní metody na CNCMT	25
4.3	Metody zachování funkčnosti řezného nástroje CNCMT	26
5	Závěr	30
6	Seznam použitých zdrojů	31

1 Úvod

S rozvojem průmyslu začal být přikládán velký význam vývoji diagnostických a prognostických metod za účelem detekce a odstraňování poruch technických systémů. Je-li použita správná kombinace diagnostických metod a je-li porucha detekována včas, je možné dosáhnout obrovských úspor ve výrobě – a právě to mě motivovalo k provádění rešerše těchto metod.

Termín diagnostika se poprvé začal používat v medicíně, tedy ke klasifikaci nemocí u živých bytostí. Tento termín byl později z medicíny převzat do dalších oblastí, například v oblasti technologie se začal používat kolem 70. let minulého století. Tento termín pochází z řeckého slova *diagnosis*, které se překládá jako posuzování. Účelem diagnostiky technického systému je proto posoudit jeho stav. Diagnostika je sada činností, které určují aktuální stav technického systému, ale také předpovídají jeho chování v určitém časovém období. Současný stav technického systému se skládá z řady charakteristik, jako je jeho schopnost vykonávat funkce a jeho správnost v provozu. Aby bylo možné provést analýzu takového systému, je nutné použít předchozí znalosti systému, vhodné modely a algoritmy k lokalizaci poruchy, ke kontrole současné spolehlivosti technického systému a předpovědi jeho chování v budoucnu. Výsledkem diagnózy může být buď konstatování, zda systém nefunguje správně, nebo popis fáze, ve které se systém nachází (systém není plně funkční ani nefunkční, je určen stav systému umístěného někde mezi těmito dvěma extrémy).

Při diagnostice velmi složitých technických systémů mohou nastat potíže. V případech, kdy je systém složitý, je nutné použít kombinaci diagnostických metod, které poskytnou nejpřesnější výsledky. Ve většině případů se při diagnostice technických systémů používají některé kombinace klasických metod, ale v některých případech se používají metody speciálně vyvinuté pro určitý technický systém.

Následující kapitoly jsou výsledkem četných výzkumů diagnostiky moderní doby. V této bakalářské práci jsou tyto výzkumy spojeny do jednoho celku, kde jsou vysvětleny základní principy práce všech diagnostických metod a také jsou v poslední kapitole vysvětleny na příkladu, kde bylo provedeno srovnání tří nejdůležitějších metod: data-driven, model-based a hybridní.

2 Motivace a cíl práce

Diagnostika technických systémů přispívá k významnému snížení nákladů ve výrobním procesu z toho důvodu, že je možné včas odhalit příčiny, které povedou k selhání systému, a přijmout tak veškerá nezbytná opatření k prevenci vzniku poruchy. Tento ekonomický efekt a skutečnost, že v posledních letech se diagnostika technických soustav stává stále důležitější a vyvíjejí se nové a moderní metody diagnostiky, byly mojí motivací při zkoumání tohoto tématu.

Hlavním cílem této práce bylo vysvětlit princip fungování různých metod v oblasti diagnostiky technických systémů.

Jednotlivé subcíle, které měly být splněny, jsou následující:

- rešerše současného stavu poznání diagnostických metod technických soustav;
- porovnání výhod a nevýhod data-driven a model-based metod v oblasti diagnostiky technických soustav;
- rešerše kombinace data-driven a model-based metod v diagnostice technických soustav – hybridní přístup;
- diskuse o použití těchto diagnostických metod na konkrétním příkladu CNC obráběcího stroje.

3 Současný stav řešené problematiky

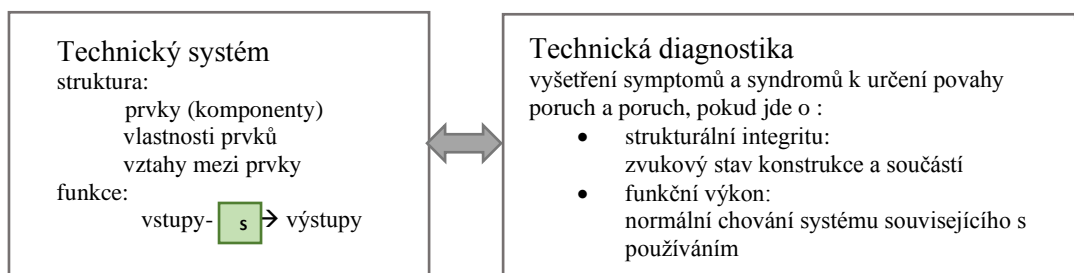
Tato kapitola se zabývá výzkumem moderní doby týkajícím se data-driven, model-based a hybridních metod.

3.1 Diagnostika technických soustav

Mezi termíny diagnostika chyb (angl. fault diagnostics) a diagnostika poruch (angl. failure diagnostics) je rozdíl. Druhý zmíněný termín se používá, když chceme říci, že některá část systému vůbec neplní svoji funkci. První termín znamená diagnostiku poruchy, která nezpůsobí úplné zhroucení systému, tj. systém může fungovat normálně, i když je v něm chyba.

Prvním krokem v technické diagnostice je zjistit, zda vůbec došlo k selhání systému. Pokud se zjistí, že v systému došlo k poruše, určí se její umístění, typ a intenzita. Intenzita selhání může určit, zda selhání systému povede k neimplementaci funkcí, které by měl systém provádět. Diagnostika technických soustav tedy nejen identifikuje poruchu, ale pracuje i na jejím odstranění a také přijímá opatření, která zabrání vzniku nových poruch. Zmíněný první krok diagnostiky technických systémů, který si všimne odchylky provozu systému od provozu, který je považován za normální, se označuje jako detekce poruchy. Cílem je pak určit část systému, která způsobila dysfunkci – tento krok je v diagnostice nazýván izolace poruch.

Jedním z nejdůležitějších parametrů, které je při diagnostice třeba vzít v úvahu, je čas. Pro správnost diagnostických výsledků je důležité rozlišit, zda k poruše dochází po delší dobu (např. únavová porucha), nebo po dobu kratší (např. křehký lom). Dříve byla technická diagnostika používána pouze v oblasti makrotechnologií, ale s jejím vývojem se začala uplatňovat také v oblasti mikrotechnologií a nanotechnologií.



Obr. 3.1: Systémový přístup k aplikaci technické diagnostiky [vlastní zpracování dle: 1]

K diagnostice technických systémů lze přistupovat dvěma způsoby, induktivním a deduktivním. Zatímco primárním předmětem studia deduktivního schválení je porucha systému a teprve potom příčina nebo více příčin, které k tomuto selhání vedly, induktivní metoda zdůrazňuje možné příčiny, které povedou k selhání. Příkladem induktivního přístupu je FMEA (angl. Failure modes and effects analysis). Termín používaný k označení jednoho z deduktivních přístupů v technické diagnostice je FTA (angl. Fault

tree analysis) a používá se ke studiu procesu selhání. Tento přístup představuje i spojení mezi příčinami, které společně mohou vést k selhání systému. Jednou z metod technické diagnostiky je také SHM (angl. Structural health monitoring), při které se senzory používají za účelem monitorování systému a chování poruch. Příčinou poruchy může být často materiál, ze kterého je stroj vyroben, proto je termín NDE (angl. Nondestructive evaluation) spojen s technickou diagnostikou a označuje skupinu metod, které se zabývají analýzou poškození systémových materiálů jako příčiny poruchy. Příklady NDE jsou rentgenografie, ultrazvuk a termografie. Existuje celkem 14 takových metod NDE a jsou kvantitativní povahy. Mohou přesně měřit defekty v systému, ke kterým dochází v reakci na záměrně vyvolané podněty. Reakce na tento podnět je však sledována a zaznamenávána pomocí senzorů. Záměrně indukovaná stimulace soustavy slouží k získání a zaznamenání nových poznatků o systému, ale musí mít nízkou intenzitu, protože nesmí ovlivnit funkčnost analyzovaného systému. Materiály lze rozdělit do několika kategorií, například přírodní materiály, kovové materiály, polovodiče, anorganické nekovové materiály, organické materiály a kompozity. Existuje taky další rozdělení technických materiálů, a sice na konstrukční, funkční a inteligentní materiály. Mechanické zatížení je také jedním z faktorů, které mohou způsobovat poruchy technického systému, jako jsou deformace, dotvarování, únava a praskliny. Kromě mechanických zátěží, které ovlivňují funkčnost systému, mohou mít vliv také tepelná, elektromagnetická, environmentální a tribologická zátěž.



Obr. 3.2: Únavová trhлина dutého hřídele [2]

Tato kapitola uvádí několik rozdělení technik a metod používaných v diagnostice technických systémů. Největší a nejdůležitější rozdělení je však založeno na tom, zda je model systému navržen v diagnostice nebo ne a na tomto základě se diagnostické metody dělí na data-driven metody a model-based metody. Rozdíl mezi nimi spočívá v tom, že data-driven metody nepoužívají modely, protože systém je příliš složitý, aby bylo možné navrhnout jeho model. Data-driven metody proto využívají informace o chování systémů shromážděných po určitou dobu. Kombinace zmíněných dvou metod se označuje jako hybridní metoda.

3.2 Data-driven metody v oblasti diagnostiky

„Data-driven diagnostika obecně klasifikuje poruchy pomocí klasifikátorů získaných z tréninkových dat pomocí nominálních dat a dat z různých poruch.“ [3]

Rozvoj technologie a hromadná výroba přispěly k vytvoření moderních diagnostických metod, k nimž patří i data-driven metody. Název data-driven je relativně nový. Tato metoda se používá, když se technický systém skládá z velkého počtu komponent, takže kvůli jeho složitosti není možné vytvořit matematický model systému. Jedním z důvodů, proč jsou data-driven metody široce používány, je také skutečnost, že se v posledních letech hromadily a ukládaly informace o výrobních procesech. Data-driven metoda využívá data PHM, což jsou data shromážděná pomocí senzorů umístěných na technickém systému, která mohou detekovat poruchu na technickém stroji. V této práci bude vysvětleno několik základních konceptů potřebných k pochopení data-driven metody v diagnostice. Jedním z těchto termínů je klasifikace.

„Klasifikace je proces hledání sady modelů, které popisují a odlišují datové třídy nebo koncepty, aby bylo možné model použít k předpovědi třídy objektů, jejichž označení třídy není známé. Odvozený model je založen na analýze souboru tréninkových dat.“ [4]

Běžné používané klasifikátory jsou bayesovské, statistické, fuzzy logické a neural network klasifikátory.

Další dělení klasifikátorů je podle učení funkce z trénovacích dat, a to na učení s učitelem a bez učitele. U učení s učitelem jsou výstupní data známa. Za účelem klasifikace dat je nutná podobnost mezi tréninkovými a výstupními daty. Naproti tomu učení bez učitele není podmíněno skutečností, že výstupní data musí být známa. Klasifikace touto metodou se provádí pouze na základě vzájemné podobnosti tréninkových dat.

Termín tréninková data se používá ve strojírenství a znamená data, která nesou informace o technickém systému a na jejichž základě je trénován algoritmus strojového učení a je navržen model. Problém, který může nastat při použití data-driven metody a při tréninku diagnostického systému, lze představit na příkladu výroby nového stroje, s nímž se uživatel nebo výrobce dosud neseťkal a který je navržen novými moderními metodami. Od výroby takového zařízení až po výskyt prvních poruch mohou uplynout roky. Všechny informace, které v průběhu času o novém zařízení shromáždíme, mohou později sloužit jako tréninková data při trénování klasifikátorů. V procesu trénování klasifikátoru je vždy třeba vzít v úvahu, že může dojít ke zcela nové poruše, která se nikdy předtím nestala nebo nebyla zaznamenána. Takové neznámé poruchy komplikují diagnostický proces, ale cílem diagnostiky je rozpoznat takové poruchy, s nimiž jsme se dosud neseťkali. Cílem tréninku klasifikátorů je dát uložená data s podobnými charakteristikami do jedné třídy. Zda jsou data podobná nebo ne a zda patří do určité třídy, se rozhoduje pomocí euklidovské vzdálenosti mezi vzorky dat. Měří se vzdálenost souřadnic vektoru hmotnosti jednoho data od těžiště. Po tréninku klasifikátoru je získáno několik datových tříd a každá z nich má své vlastní hmotnostní centrum. Pokud je euklidovská vzdálenost mezi vzorkem dat a těžištěm třídy malá, znamená to, že u vzorku dat je větší pravděpodobnost, že bude sdílet podobné charakteristiky s jinými daty v této třídě a že do ní bude patřit.

Datové skupiny, které nemají popisné hodnoty, jsou odmítnuty nebo se jim přiřazuje Not a Number value (NaN). Každá třída musí být označena. Štítek musí být co nejvíce popisný a jeho popis by měl obsahovat, jak dlouho a s jakou jistotou může technický systém vykonávat své funkce, například: „Stroj bude fungovat rok s jistotou devadesáti procent.“ Při provádění technické diagnostiky bude vzorek dat vždy přiřazen ke třídě. Zda byla klasifikace provedena správně, lze také určit pomocí funkce členství ve třídě:

$$„y = \max \left(1 - C \frac{S}{S_{max}}; 0 \right)“ \quad [4] \quad (3.1)$$

kde proměnná y představuje hodnotu členství, S je euklidovská vzdálenost nového vzorku od mediánu a S_{max} je euklidovská vzdálenost nejvzdálenějších tréninkových dat od těžiště. C je členská konstanta a pro tuto konstantu je obvykle zvolena hodnota 0,5. Maximální spolehlivost diagnózy bude v případě, že $y = \max(1; 0)$. Tato lineární funkce ne vždy poskytuje přesné výsledky, a proto se někdy používají složitější sigmoidní funkce.

Klasifikátory jedné třídy (angl. one-class classifiers) se často používají při klasifikaci dat, kde je každá třída nezávislá na ostatních. Klasifikátory jedné třídy používají pravděpodobnostní a nepravděpodobnostní metody. Mezi tyto klasifikátory patří OSVM (angl. Weibull-calibrated one-class support vector). OSVM analyzuje reziduální data pomocí klasifikační funkce. Pokud je výsledek této funkce označen jako pozitivní, znamená to, že analyzovaná reziduální data jsou reziduální data, která již byla zaznamenána a jsou použita jako tréninková data. Pokud je porucha přítomna v systému delší dobu, v tomto případě se Bayesovské vyhlazování nebo kombinace Bayesovského vyhlazování s OSVM používá v data-driven diagnostice, aby se dospělo k ještě přesnější klasifikaci.

Rozdělení data-driven algoritmů lze podrobněji představit na příkladu diagnostiky hardwarového systému. Používají se dva typy algoritmů: algoritmy strojového učení a statistické algoritmy. Algoritmy strojového učení určují typ poruchy a statistické algoritmy mohou detekovat pouze to, zda v systému vůbec došlo k chybě, nebo ne. ANN (angl. Artificial neural network), SVMS (angl. Support vector machines), FL (angl. fuzzy logic) i GA (angl. Genetic algorithms) patří do skupiny algoritmů strojového učení. Analýza hlavních komponent, bayesovská síť a Dempster-Shaferova teorie patří do skupiny statistických metod.

V následujících odrážkách jsou uvedeny algoritmy strojového učení:

- ANN je založen na porovnání odhadovaných hodnot se skutečnými systémovými hodnotami. Použití ANN může být nespolehlivé, pokud je velké množství tréninkových dat. Tyto algoritmy jsou účinné při filtrování šumu. ANN lze podrobněji představit na příkladu diagnostiky ložisek valivých prvků. [5] Tyto prvky mají velké uplatnění ve strojích a je velmi pravděpodobné, že pokud bude vadný pouze jeden prvek, bude vadný celý systém. V případě diagnózy těchto prvků představuje ANN sadu umělých neuronů, které klasifikují poruchy a které lze přizpůsobit vstupním informacím, jež dostávají. V této studii byla shromážděna data ze čtyř ložiskových stavů. Jeden z těchto stavů byl bez poruch a další tři měly poruchu, ale na různých místech. Systém, na kterém bylo

valivé ložisko instalováno, je mechanický systém poháněný motorem. Signály byly shromažďovány pomocí akcelerometru. Celkem bylo odebráno 30 vzorků s 3600 body. Přibližně 2/3 těchto dat byly použity ke tréninku klasifikátoru. Klasifikace údajů metodami ANN v případě valivých ložisek se ukázala jako velmi účinná.


- SVMS izoluje poruchu a používá Laplace multiplikátory a Karush-Kuhn-Tucker podmínky. SVMS lze použít například v diagnostice plynových turbín. V diagnostice technických systémů na základě dat byla navržena kombinace ANN a SVMS, kde ANN detekuje poruchu a SVM poruchu izoluje. SVMS je podrobně popsán v článku [6]. Zde je popsáno použití SVMS při diagnostice poruch ložisek. Ložiska jsou klíčovou součástí strojů, a proto bylo provedeno mnoho experimentů a byly na ně použity různé diagnostické návrhy. Vibrační spektra jsou analyzována v diagnostice ložisek. Ačkoli byla pro diagnostiku ložisek navržena řada algoritmů, jako jsou již zmíněné ANN nebo Markův model, lepší diagnostické výsledky poskytl SVMS, protože může pracovat s velkým množstvím vstupních informací shromážděných senzory. Účelem SVMS je najít spojení mezi signálem a stavem, ve kterém se systém nachází. Veškerá data použitá při vývoji těchto algoritmů v tomto konkrétním příkladu používala shromážděné informace zveřejněné na online webu Case Western University Bearing Data. Takto provedená klasifikace měla přesnost 76 %. Také v této studii byla navržena kombinace SVMS s DS, a tak byla přesnost diagnózy zvýšena až na 94 %.
- FL je metoda, která detekuje selhání a skládá se ze tří fází, a to fuzzifikace, inference a defuzzifikace. FL v kombinaci s ANN a SVMS poskytuje velmi dobré výsledky v oblasti diagnostiky. Fuzzy logika našla své největší uplatnění ve vibračních diagnostických systémech, což lze vysvětlit na příkladu diagnostiky rotujících částí strojního zařízení.[7] Fuzzy logika je založena na skutečnosti, že vztah mezi vstupem a výstupem představují jazykové proměnné. FL je snazší implementovat než ostatní zmíněné data-driven algoritmy a je také méně komplikované je implementovat než u model-based metody. Hlavní myšlenkou FL je, že každý vstup má svůj vlastní odpovídající výstup. Systém, nad nímž se provádí diagnostika, je vysvětlen řadou pravidel, příkladem jednoho takového pravidla v případě strojů s rotující hřídelí je následující:
„Pokud je hodnota zrychlení vibrací na základní frekvenci otáčení nízká; diagnostikované zařízení není vadné.“ [7]
- V této bakalářské práci jsou poslední zmíněnou skupinou algoritmů strojového učení GA. Ve srovnání s ostatními uvedenými algoritmy trvá jejich výpočet velmi dlouho. GA se používá v diagnostice plynových turbín a takto prováděná

diagnostika turbín poskytuje mnohem lepší výsledky než diagnostika prováděná pomocí ANN a SVMs.

Podrobnější seznam GA je uveden v článku, kde je diagnostika poruchy motorového rotoru prováděna kombinací FL a GA. [8] Nejprve je nutné vytvořit databáze normálního a abnormálního stavu motoru. Pokud pomocí těchto datových sad není možné vytvořit optimální klasifikační funkci, další krok se označuje jako „crossover and mutation“. V tomto kroku se vytvoří nová data, která jsou kombinací charakteristik již shromážděných dat. Každá data mají několik „genů“, které nesou určité vlastnosti, je provedeno křížení těchto genů a jsou získána nová data. Proto se tyto algoritmy označují jako genetické. Crossover se provádí zcela náhodně. V této studii bylo použito celkem 50 tréninkových vzorků. Pro dosažení ještě lepších výsledků byla kromě algoritmů GA použita fuzzy logika.

Statistické algoritmy zahrnují analýzu hlavních komponent, která se používá, když je velikost dat příliš velká, a jejich rozdělení je uvedeno v následujících odrážkách:

- Bayesovská síť je založena na skutečnosti, že příčiny poruchy jsou seskupeny, přičemž každé skupině je přiřazena příslušná chyba. Může být použita při diagnostice odstředivého kompresoru elektrárny.
Článek [9] ukazuje využití bayesovské sítě na příkladu prognózy kapacity baterie. V tomto experimentu bylo použito 34 lithium-iontových baterií a během jejich nabíjení, vybíjení a impedance byly vytvořeny datové soubory. Některé z charakteristik shromážděných datových sad byly teplota, napětí a výstupní proud. Každá z těchto 34 baterií byla vybita v jinou dobu, tj. zatímco hodnoty uvedených charakteristik byly odlišné. Získané algoritmy pro klasifikaci jsou proto různé a ukázalo se, že měly vynikající výsledky v predikci kapacity baterie. Tento článek také ukazuje, jak předzpracování dat dále zlepšuje výsledky prognózy zbývajících výdrže baterie.
- Dempster-Shaferova teorie je podobná bayesovským sítím. Výhodou této metody je, že je možné detekovat více poruch najednou.
Podrobnější informace o Dempster-Shaferově teorii je možné dohledat viz [10] na příkladu diagnostiky poruchy valivého ložiska. Dempster-Shaferova teorie se liší od již zmíněných metod používaných při diagnostice poruch ložisek v tom, že ke sběru dat se používá více senzorů. V tomto experimentu byly nainstalovány čtyři senzory (viz obr. č. 3.3).



Obr. 3.3: Zkušební stav převodovky vysokorychlostního vlaku [10]

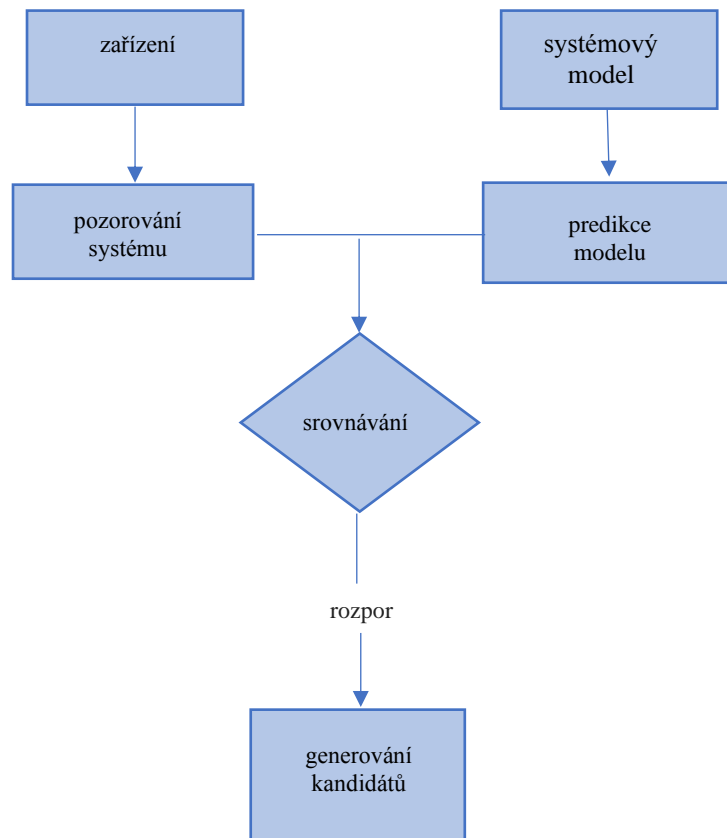
Všechna data shromážděná těmito senzory byla sloučena. Klasifikace touto metodou na příkladu valivých ložisek je přesnější než všechny dosud zmíněné klasifikátory. Rovněž bylo zjištěno, že čím více senzorů je zapojeno do procesu sběru dat, tím větší je přesnost diagnostiky. Přesnost diagnostiky při zohlednění všech čtyř senzorů je více než 90 %.

Data-driven metody v diagnostice technických soustav nejsou ideální; jedním z důvodů je nedostatek významných údajů při trénování klasifikačních algoritmů nebo správa obrovského množství dat. Nepotřebná data systému lze v některých případech odstranit pomocí programu OSA-OBM.

Kapitola 3.3 vysvětluje model-based metodu, která se používá, když data-driven metoda v diagnostice neposkytuje požadované výsledky.

3.3 Model-based metody v oblasti diagnostiky


„V model-based diagnostice se izolace poruch provádí hlavně porovnáním sady reziduálních generátorů s různými signaturami poruch za účelem výpočtu kandidátů na diagnostiku.“ [3]



Obr. 3.4: Postup model-based metody [vlastní zpracování dle: 13]

Výše uvedená diagnostická metoda nachází uplatnění v různých průmyslových oblastech, jako je výroba motorových vozidel, robotů atd. V případě použití této diagnostické metody je nutné navrhnout model systému, který lze následně analyzovat. Aby bylo možné model vytvořit, je nutné znát jeho fyzikální vlastnosti. Reziduál je detekován model-based metodami a představuje nesoulad mezi dvěma výstupy a může sloužit jako indikátor, že v systému došlo k poruše. Bohužel ani tato metoda, stejně jako data-driven metoda v diagnostice, není zcela dokonalá. V případě, že je systém příliš složitý a není možné vytvořit jeho matematický model, provede se diagnostika systému jinými metodami. Složitost modelu systému lze někdy zjednodušit, ale tak aby stále zachovával své základní vlastnosti.

Tvorbu modelu lze provést pomocí diferenciálních rovnic (ODE). Modely iniciace trhlin se často používají při diagnostice poruch technických systémů. Model-based metody se liší od data-driven metod v tom, že mají tu výhodu, že mohou detekovat neznámá neočekávaná selhání. Jedním ze softwarů, který lze použít k vytvoření modelu a se kterým jsem se setkala také při studiu, je ANSYS.



Obr. 3.5: Příklad modelování v ANSYS – analýza kontaktního napětí v sestavě čelního kola [14]

Model-based metody v oblasti diagnostiky technických systémů lze rozdělit na abduktivní diagnostiku a diagnostiku založenou na konzistenci. Hlavní rozdíl mezi nimi spočívá v tom, že diagnostika založená na konzistenci používá model, který je označen jako nominální. Tento model je ve stavu bez poruch; a možné je pak předvídat různé poruchy které mohou nastat. Abduktivní metoda bere v úvahu model, který není v nominálním stavu, to znamená, že je vadný. Důležitým jménem v model-based diagnostice je Reiter, protože byl jedním z prvních lidí, kteří navrhli diagnostiku založenou na konzistenci. De Kleer a Kohlas se později pokusili zmíněný přístup v diagnostice vylepšit. Diagnostické výsledky obou studií stále obsahovaly chyby. Pokrok v modelové diagnostice přinesl Pearl, který propojil bayesovské sítě s modelovou diagnostikou.

V diagnostice založené na konzistenci může být systém reprezentován jako sada:

$$„\varphi = (SD, COMPS, OBS)“ \quad [15] \quad (3.2)$$

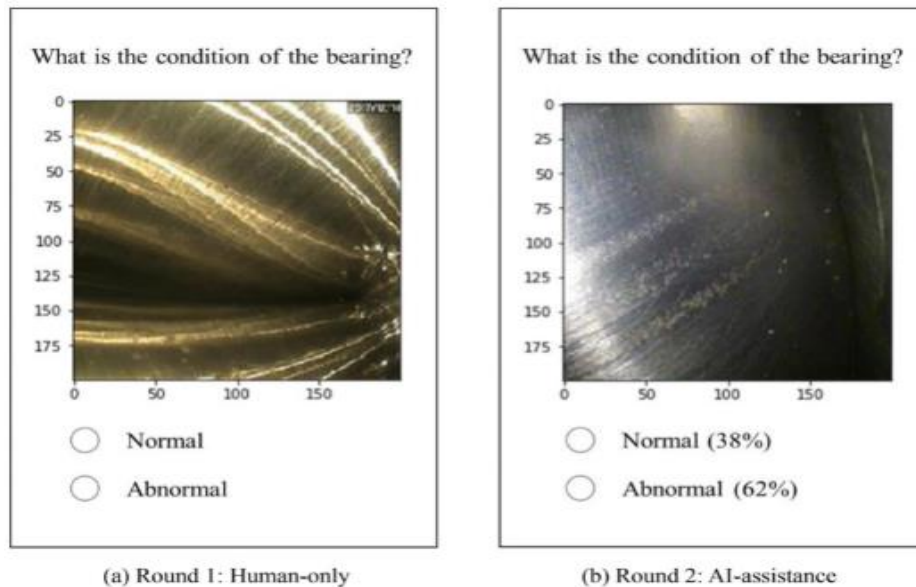
kde SD představuje nominální chování systému, $COMPS$ představuje potenciální vadné komponenty systému a OBS je skupina algoritmů, které definují pozorování systému. Nejistotu, zda součást systému bude mít poruchu, lze představovat jako rozdělení

pravděpodobnosti *COMPS*. Ačkoli Kohlas, De Claire a Pearl přispěli k vývoji model-based diagnostiky, jejich výzkum nepřinesl zcela uspokojivé výsledky. Ve všech třech těchto výzkumech vycházíme z předpokladu, že komponenty technického systému jsou na sobě částečně nebo zcela nezávislé. To by znamenalo, že pokud je jedna součást vadná, neovlivní to poruchu jiné součásti soustavy. Ve skutečných situacích není tento způsob myšlení správný, protože vadná součást může často ovlivnit funkčnost ostatních součástí a dokonce i celého systému.

Rozdělení model-based metod lze podrobněji představit na příkladu diagnostiky hardwarového systému. [16] V tomto případě lze model-based metodu rozdělit do dvou podskupin, a to jsou detekce a izolace poruch (FDI) a diagnostická umělá inteligence (AI). Metody FDI lze dále rozdělit na redundanci hardwaru a analytickou redundanci. Ačkoli hardwarová redundance prokáže identifikaci poruchy, jejím hlavním úkolem je zajistit bezpečnost systému, pokud již k chybě došlo. Na druhou stranu analytická redundance pro hlavní úkol má detekci chyb. Termín „nulová hypotéza“ označuje takový jev, kdy je systém bezchybný. Jakýkoli jiný stav než tento vede k detekci poruchy. Hlavní problém se všemi těmito metodami může nastat, když dojde k takzvaným falešným poplachům. Jedním ze způsobů, kterými lze omezit výskyt detekce poruchy, pokud v systému není porucha, je založen na skutečnosti, že pokud dojde k odchylce od normálního stavu, musí se zohlednit více než jednou.

Je možné najít podrobné informace o FDI viz [17]. Zde je zobrazena aplikace těchto algoritmů na platformě UAV (angl. Unmanned aerial vehicle). V tomto experimentu byla detekce i izolace poruch prováděna současně, což je největší výhodou těchto algoritmů. Nevýhodou FDI je, že ačkoliv byly poruchy detekovány a izolovány včas, nebylo možné tyto poruchy identifikovat pomocí těchto algoritmů.

AI je podrobně popsána ve velmi zajímavém experimentu viz [18]. AI se zde studuje na obnovitelných energetických systémech, na větrných farmách. Cílem bylo dosáhnout co nejlepší prediktivní údržby větrných farem. Studie inteligence AI byla následující: Nejprve bylo pořízeno 2301 snímků s přibližně 138 převodovkami větrných turbín. Do experimentu bylo zapojeno také 54 lidí, kteří byli technickými odborníky. Každému z nich byly ukázány snímky pořízené z turbín a jejich úkolem bylo identifikovat poruchy ložiska. Experti to nejprve provedli sami bez pomoci někoho jiného a poté s pomocí AI (viz obr. 3.6).



Obr. 3.6 Uživatelské rozhraní pro kontrolní úkol [18]

Pro vytvoření modelu AI, který by diagnostikoval poruchu, byla velikost obrázků změněna na $150 \times 150 \times 3$ pixely. Závěr dosažený na konci tohoto experimentu je, že predikce údržby větrné turbíny jsou téměř 5krát účinnější, když byla v prognóze použita pomoc AI.

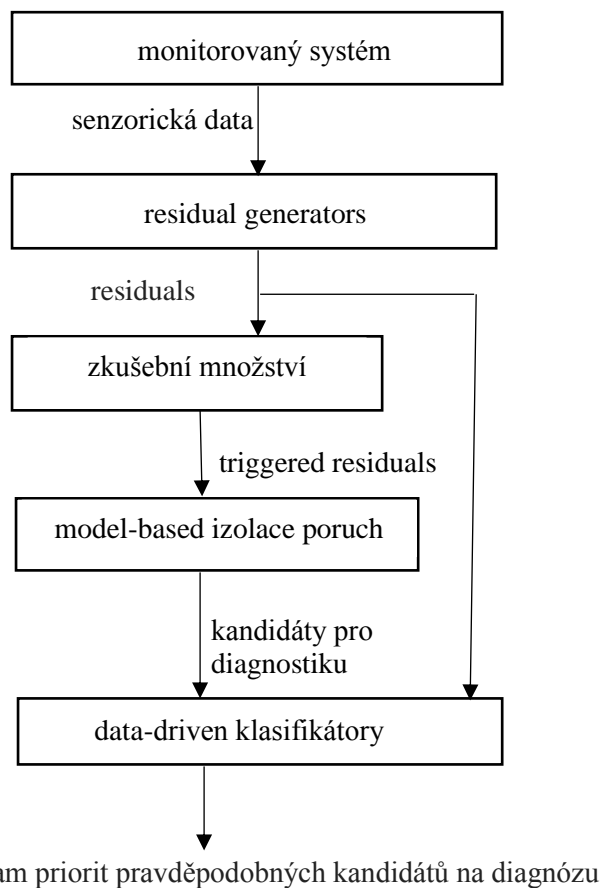
Ačkoli model-based metoda v diagnostice je ve většině případů pokročilejší a poskytuje lepší výsledky než data-driven metoda, není ani tato metoda ideální.

3.4 Kombinace data-driven a model-based metod – hybridní metoda

Obě zmíněné metody v oblasti diagnostiky mají své výhody a nevýhody. Z ekonomického hlediska je data-driven metoda levnější než model-based metoda. Na rozdíl od model-based metody ji lze vzhledem k její jednoduchosti aplikovat i na složité systémy. Přesnost je ale vyšší v model-based diagnostice, protože na rozdíl od data-driven diagnostiky lze přesně určit hranici mezi nominálním systémem a vadným systémem. Data-driven metody se také více zajímají o poruchy pouze určitých systémových komponent, zatímco model-based metody provádějí diagnostiku systému jako celku. V této práci je zmíněno, že metody založené na datech závisí na dříve dostupných a shromážděných znalostech týkajících se systému. Pokud během diagnostiky není k dispozici dostatečné množství takových dat, poruchu v systému nebude možné identifikovat a izolovat. Další výhodou model-based metod je, že mají deterministický přístup, což znamená, že vstup v těchto metodách není náhodná hodnota, ale je přesně určen, což v diagnostice poskytuje lepší výsledky. Stručně řečeno, obě tyto metody mají své výhody a nevýhody v závislosti na tom, na jakou soustavu jsou aplikovány. Skutečnost, že obě metody mají výhody i nevýhody, vedla k vytvoření nové metody, která

je kombinací těchto dvou metod – hybridní metody. Této metodě a jejímu popisu je věnována tato kapitola.

Data-driven podíl v hybridní metodě slouží ke klasifikaci problému, zatímco model-based část hybridní metody slouží k izolaci problému. V této práci je již zmíněn význam pojmu „nulová hypotéza“, který označuje systém v nominálním stavu. Pokud systém není v nominálním stavu, mohou diagnostické metody v důsledku toho najít poruchy, které v systému ve skutečnosti nejsou. Hybridní metoda takové „falešné“ diagnostické výsledky odmítá. V data-driven kroku hybridní diagnostiky se pravděpodobnost, že se chyba skutečně nachází v systému, vypočítá seřazením poruch podle pravděpodobnosti, že se skutečně v systému vyskytují.



Obr. 3.7: Schéma návrhu diagnostického systému [3]

FSM (angl. Fault Signature Matrix) v hybridní metodě ukazuje spojení mezi reziduálními generátory a poruchami, kde jeden reziduál může být spojen nejen s jedním, ale také s více poruchami. Sada $F = \{f_1, f_2, \dots, f_{n_f}\}$ označuje takovou sadu, která zahrnuje všechny poruchy, ke kterým mohlo v systému dojít. Ten provádějící diagnostiku už tyto poruchy zná, protože již byly pozorovány dříve ve stejném nebo podobném systému. Pokud je v systému zjištěna nová neznámá chyba, sada F se rozšíří na sadu F^* . Pokud je systém v nominálním stavu, nebudou aktivovány žádné reziduály. Když je reziduál aktivován, je spojen s diagnózami ze sady D , kde D je sada diagnostických kandidátů d. [3]

reziduál	$f_{\omega af}$	f_{pim}	f_{pic}	f_{Tic}
r_1	X	X		
r_2	X		X	
r_3		X		X
r_4		X	X	
r_5	X			
r_6				X

Tab. 3.1: FSM [vlastní zpracování dle: 3]

Diagnostičtí kandidáti, mezi nimiž nebylo zjištěno žádné spojení s reziduálními generátory, jsou odmítnuti. Tento krok v procesu hybridní diagnostiky se nazývá „fault isolation“. Je však velmi běžné, že jeden reziduál je spojen s více diagnostickými kandidáty. Aby se těmto situacím zabránilo, je další krok hybridní metody vázán na data-driven metodu, protože se používají data-driven klasifikátory. Hybridní metoda používá jak klasifikátory jedné třídy (nazývané také klasifikátory anomálií), tak klasifikátory více tříd. SVDD (angl. Support data vector decision) je druh klasifikátoru používaného k seřazení diagnostických kandidátů v hybridní metodě. Klasifikace pomocí SVDD bere v úvahu všechny diagnostické kandidáty, ale pro kandidáty s nízkým hodnocením je velmi nepravděpodobné, že jsou správným výsledkem diagnostiky:

$$„rank(F_l) = \frac{1}{N} \sum_{k=1}^N C_{F_l}^R(r_k).“ \quad [3] \quad (3.3)$$

kde je chyba modelována jako klasifikátor $C_{F_l}^R$, $R = \{r_1, r_2, \dots, r\}$ označuje sadu reziduí, $rank(F_l)$ označuje rank minimálního kandidáta pro diagnostiku a N je počet reziduí, která se aktivovala při výskytu poruchy v systému. Vždy existuje šance, že se vyskytne neznámá porucha, kterou nelze identifikovat na základě již existujících tréninkových dat. Pořadí takových neznámých diagnostických kandidátů se provádí pomocí vzorce:

$$„rank(F_l) = \frac{1}{N} \sum_{k=1}^N (1 - \bigwedge_{F_l \in D_{min}} C_{F_l}^R(r_k)).“ \quad [3] \quad (3.4)$$

kde D_{min} představuje sadu minimálních kandidátů na diagnostiku. V systému může současně dojít k několika poruchám, což je důvod, proč jsou klasifikátory trénovány, aby ve zvláštních případech mohly rozpoznat více poruch. Když je detekována neznámá chyba, všechna pozorování a závěry z ní vyvozené se použijí k aktualizaci existujících algoritmů založených na datech.

3.4.1 Digital Model, Digital Shadow a Digital Twin (DT) koncept

V kapitole 4 je hybridní metoda představena na příkladu CNCMT, který je založen na konceptu Digital Twin (DT). Z tohoto důvodu bude tento koncept podrobněji vysvětlen v následujícím textu, který je výsledkem výzkumu publikovaného v [19] a [20].


„DT je simulační proces, který integruje multidisciplinární, multi-fyzikální proměnné, multi-scale a multi-pravděpodobnost tím, že plně využívá fyzický model, aktualizaci senzorů a historická provozní data.“ [21]

„DT je nositelem modelu a dat, jež mohou provádět fyzické mapování ve virtuálním prostoru a poté propojovat fyzický svět a digitální svět.“ [21]

Digital Twin je velmi důležitý v prognóze RUL (angl. Remaining Useful Life) technických systémů. Klasická diagnostika analyzuje chyby, které se již vyskytly, a příčiny, které k nim vedly, ale v poslední době je přisuzován ještě větší význam prognóze poruch. PHM (angl. Prognostic and Health Management) je název používaný k označení této nové disciplíny ve strojírenství. Skládá se hlavně ze tří kroků, a to sběru a zpracování dat, výpočtu RUL a přijetí opatření, která pomohou zachovat funkčnost systému. Existují různé metody výpočtu RUL a jeden z neznámějších konceptů se nazývá Digital Twin, který kromě historických dat o systému používá také digitální modely. Model Digital Twin se vyznačuje tím, že musí být neustále aktualizován, aby digitální model nebyl statický, ale aby simulace měla vždy stejné parametry jako skutečný stroj. Approach DT zkoumá jak reálná data systému, tak data získaná digitálním modelem.

Někdy se místo názvu Digital Twin používají názvy Digital Shadow a Digital Model. Tyto pojmy, stejně jako přehled literatury, kde jsou použity, jsou uvedeny v článku [22]. Ačkoli se tyto termíny často používají jako synonyma, existuje mezi nimi rozdíl podle úrovně integrace. Úroveň integrace představuje závislost digitálního objektu na fyzickém modelu.


Digital Model má nejnižší úroveň integrace. To znamená, že mezi fyzickým systémem a digitálním modelem nedochází k žádné výměně dat. Pokud se změní parametry na fyzickém systému, data na modelu nebudou aktualizována v reálném čase. To je patrné z obr. č. 3.8. Některou literaturu, kde byl použit termín Digital Model je možné dohledat viz [23], [24], [25].



Obr. 3.8: Datový tok v Digital Model [22]


Digital Shadow je digitální objekt, který se mění v závislosti na změně parametrů fyzického systému, ale fyzický systém se nemění, pokud se změní stav digitálního

objektu. To lze vidět na obr. č. 3.9. Některou literaturu, kde byl použit termín Digital Shadow je možné dohledat viz [26], [27] a [28].



Obr. 3.9: Datový tok v Digital Shadow [22]

Digital Twin je plně integrovaný objekt, což znamená, že digitální objekt závisí na fyzickém systému a naopak. To lze vidět na obr. č. 3.10. Některou literaturu, kde byl použit termín Digital Twin je možné dohledat viz [29], [30] a [31].



Obr. 3.9: Datový tok v Digital Twin [22]

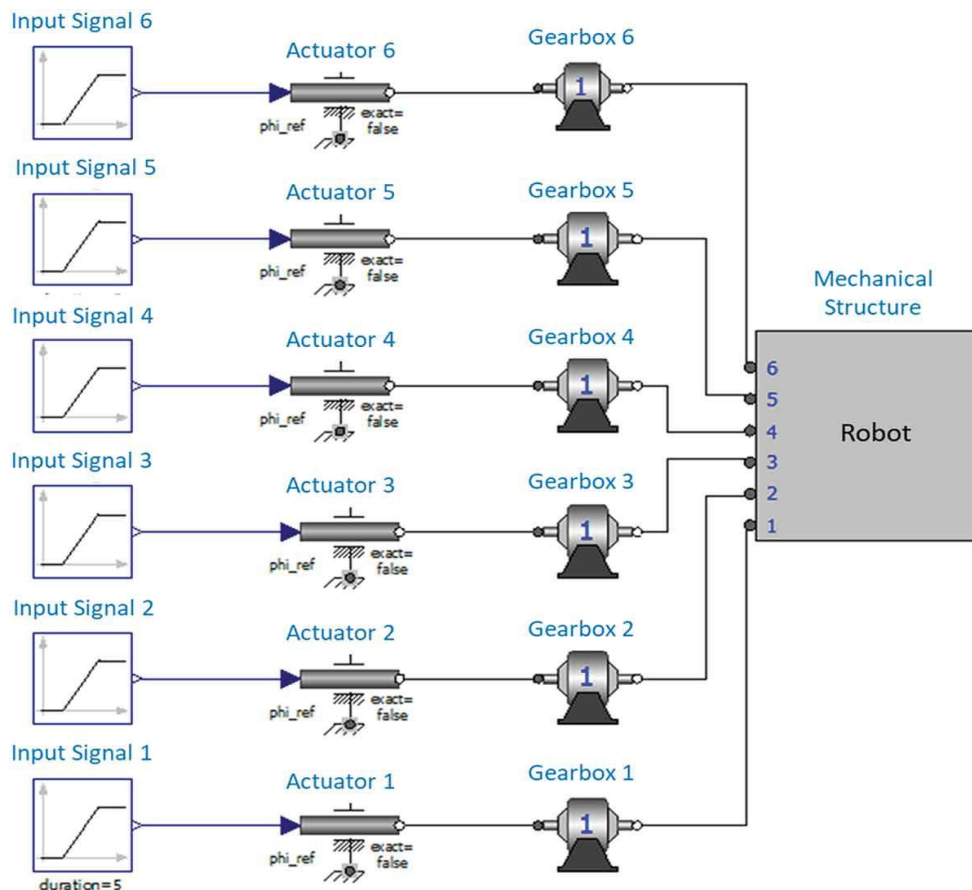
Ačkoli Digital Twin je v literatuře nejčastěji používaným termínem, tento termín se obecně nepoužívá správně a odkazuje na termín Digital Shadow nebo Digital Model. Digital Shadow je v literatuře nejčastěji popsán, i když je někdy mylně označován jako Digital Twin.

Deep Digital Twins (DDT) jsou speciální kategorií konceptu Digital Twin. Liší se od běžného DT v tom, že odhad RUL s DDT nezávisí na historických datech. Místo toho je model vytvořen přímo z provozních zdravých aktiv dat. K vytvoření takového modelu není nutná znalost fyziky celého systému, protože jsou simulovány pouze určité součásti systému.

DT lze lépe vysvětlit na příkladu šestiosé robotické struktury. V této práci je v kap. 4 prezentováno také podrobné srovnání hybridní metody založené na konceptu DT s model-based a data-driven metodami.

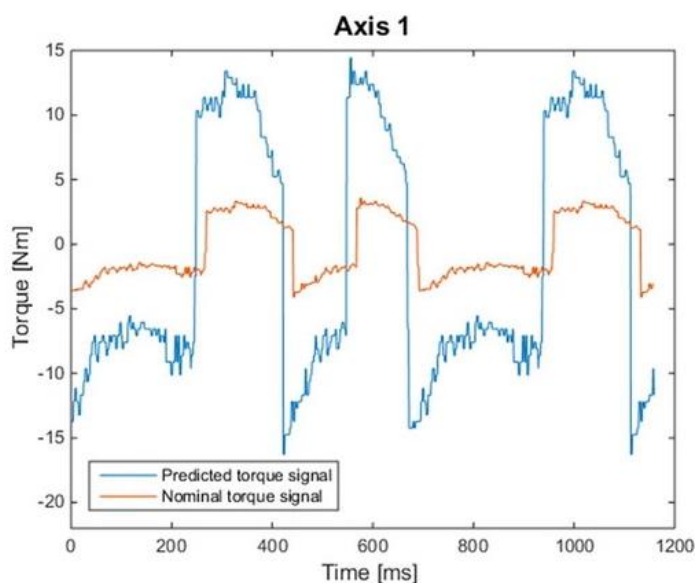
RUL predikce šestiosé robotické struktury pomocí DT

Koncept DT lze v tomto případě rozdělit do čtyř fází. První je vytvoření fyzického modelu robota. To lze znázornit na obr. č. 3.11.



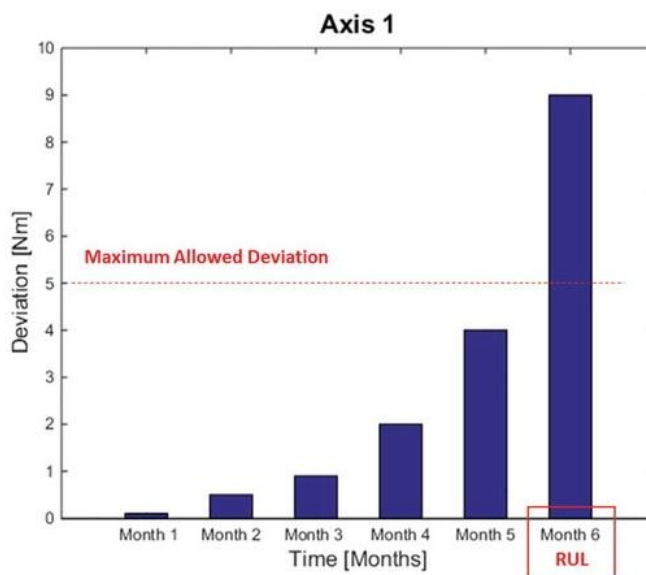
Obr. 3.11: Digitální model robota [19]

Pozorovaný robot měl celkem šest kloubů a šest os. V této fázi se modelují virtuální senzory a definují se parametry modelování. Parametry, které nejvíce ovlivňují činnost převodovky robota (což je součást, na které nejpravděpodobněji dojde k poruše), jsou Coloumbovo tření F_c a setrvačnost převodů J_m . Druhou fází je vyladění modelu během provozu. Zohledňuje se skutečná poloha a signál točivého momentu každé převodovky. Signály získané na reálném systému se používají dvakrát, poprvé, když se použijí jako vstup v digitálních modelech, pak se znovu použijí k porovnání dat reálného stroje se simulačním výstupem. Reálná data a simulační data jsou poté porovnána a tento proces se opakuje, dokud nejsou parametry robota a simulace stejné. Obr. č. 3.12 ukazuje srovnání predikovaných a nominálních signálů točivého momentu po šesti měsících.



Obr. 3.12: Porovnání predikovaných a nominálních signálů točivého momentu po 6 měsících [19]

Třetím krokem je aktivace simulace. Ve čtvrtém kroku se vypočítá RUL, po kterém se porovnávají signály nominálního točivého momentu a předpovídané signály v určitém časovém období. To je znázorněno na obr. č. 3.13.



Obr. 3.13: Výpočet RUL na základě maximální povolené odchytky [19]

Tato studie předpověděla šestiměsíční RUL převodovky. Abychom věděli, jaká maximální odchytka mezi nominálními daty a daty získanými simulací je povolena, než bude systém nefunkční, jsou zohledněna historická data.

4 Zaměření na konkrétní oblast

Abychom lépe porozuměli aplikaci data-driven, model-based a hybridních metod v oblasti diagnostiky technických soustav, v pokračování této práce bude vysvětlena na příkladu diagnostiky CNC obráběcích strojů (angl. CNC Machine Tool -CNCMT).

4.1 Diagnostika a prognostika hybridní metodou na konkrétním příkladu CNC obráběcího stroje za účelem udržování jeho kvality

Porucha, která může na CNCMT nastat, může vést k chybě ve výrobě, a proto bylo provedeno srovnání různých diagnostických metod, aby bylo možné najít tu nejúčinnější, aby byla co nejúčinnějším způsobem zachována funkčnost a přesnost CNCMT. Informace z této kapitoly jsou výsledkem výzkumů a experimentů publikovaných v článku [21].

CNC stroj se používá k výpočtu hřídelí a ovládání motorů, které lze použít k ovládání obráběcích nástrojů. CNCMT je výrobní zařízení, které je ve strojírenském průmyslu velmi důležité. Proto je taky velmi důležitá správná diagnostika CNCMT, údržba jeho funkčnosti i předpovědi poruch, které na něm mohou nastat. Aby mohla být diagnostika systému provedena správně, je důležité znát nejdůležitější vlastnosti CNC obráběcího stroje. Za prvé, CNCMT je systém, který se skládá z několika částí, které jsou na sobě navzájem závislé. Proto lze o CNCMT říci, že je to komplexní systém. Pokud je na jedné části CNCMT zjištěna chyba, nemusí to nutně znamenat, že CNCMT jako celek nebude i nadále plnit své funkce. CNCMT musí být proto analyzována a diagnostikována jako celek, nikoli z úrovně komponent. CNCMT je také časově proměnlivý systém, což znamená, že na podnět v různých časech nemusí reagovat stejně. Hybridní diagnostická metoda CNCMT je založena na konceptu Digital Twin (DT).

Koncept DT v případě diagnostiky CNCMT je určen k analýze opotřebení řezného nástroje. Předpovídá se RUL soustavy. Výsledkem je přijetí opatření k zabránění nefunkčnosti systému. Správná diagnostika této soustavy prováděná včas může ušetřit spoustu peněz.

Výzkumu a zdokonalení konceptu DT je skutečně přikládána velká důležitost, takže tento koncept byl navržen například také v diagnostice leteckých letadel NASA.


4.2 Aplikace data-driven, model-based a hybridní metody na CNCMT

Aby bylo možné vytvořit kombinaci data-driven metod a model-based metod, je nutné vytvořit vhodný hybridní algoritmus.

Při vytváření modelu systému CNCMT byly zohledněny všechny jeho mechanické, elektrické, hydraulické a tepelné vlastnosti. Aby byla metoda DT přesná, nestačí provést

pouze simulaci, ale také skutečný experiment. Vlastnosti systému, jako jsou vlastnosti materiálu, musí být stejné jak v simulaci, tak ve skutečném systému. Pokud není rozdíl mezi skutečným systémem a výsledky simulace diagnostiky zanedbatelný, je třeba model spravovat.

Data-driven metoda v diagnostice CNCMT se skládá z několika kroků. Prvním krokem je sběr dat CNCMT pomocí zapnutých senzorů (viz obr. 4.1).



Obr. 4.1: Instalace senzorů na obráběcím stroji [21]

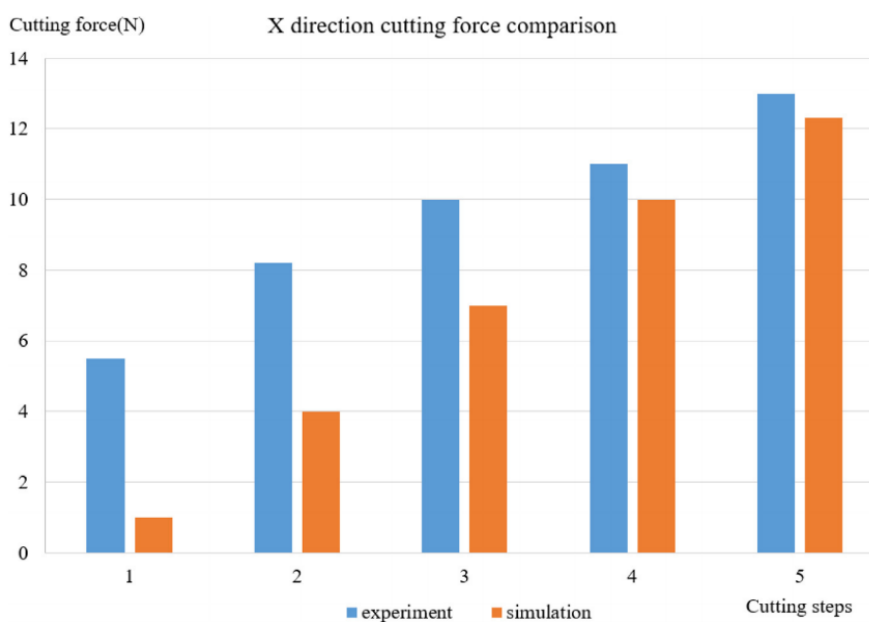
Data shromážděná senzory mohou obsahovat šum, který je třeba odstranit. Je také nutné vyloučit všechna data, která nejsou pro údržbu CNCMT relevantní. Posledním krokem je vytvoření diagnostických algoritmů, které jsou navrženy na základě dat shromážděných senzory. Model vytvořený pomocí dat získaných data-driven metodami se pak používá při návrhu hybridních algoritmů. Mezi nejčastěji používané algoritmy v hybridní metodě prognostiky a diagnostiky patří Karmanův filtr a částicový filtr. Tyto algoritmy mohou poskytnout poměrně přesnou předpověď RUL systému v diagnostice poruch, tj. je předpovězena doba, po kterou může CNCMT, která má poruchu, běžně vykonávat své funkce.

4.3 Metody zachování funkčnosti řezného nástroje CNCMT

CNCMT je komplexní systém, který se může skládat z částí, jako je ložisko, řezný nástroj a kuličkový šroub. Pro zachování správného fungování CNCMT lze prognostiku a

diagnostiku provádět samostatně u každé části CNCMT. Následně bude každé části CNCMT přidělena důležitost v její diagnostice jako celku. Tento přístup, při kterém se diagnostika CNCMT provádí na úrovni systému, se nazývá AHP (angl. Analytical Hierarchy Process). Řezný nástroj, který je podstatnou součástí CNCMT, bude považován za příklad zachování funkčnosti systému a diagnostiky různými metodami. Dříve se diagnostika a prognostika v případě řezných nástrojů spoléhaly pouze na předchozí zkušenosti s tímto nástrojem. Vývoj novějších metod ukázal, že DT hybridní metoda v tomto případě poskytuje nejlepší výsledky.

Při vytváření modelu řezného nástroje je nutné model zjednodušit vynecháním zbytečných detailů, které pro diagnostiku a prognostiku nejsou důležité. Po navržení požadovaného modelu se provede simulace, která dokáže vypočítat teplotu a napětí systému. Pokud je přítomno opotřebenění nástroje (což je v tomto případě porucha), budou tyto dva parametry použity při výpočtu míry opotřebenění nástroje během diagnostiky. Abychom věděli, zda je navržený model řezného nástroje správný, můžeme porovnat hodnotu simulací řezné síly a skutečné hodnoty, které by měly být přibližně podobné. To je taky znázorněno na obr. 4.2.



Obr. 4.2: Výsledky ověření přesnosti [21]

Pracovní podmínky a geometrie řezacího nástroje jsou proměnné parametry, a proto je nutná aktualizace modelu v reálném čase. Za účelem odstranění šumu z informací získaných pomocí senzorů byla použita metoda, která se nazývá five_three smoothing method. Nepotřebná data ve studii byla vyloučena výpočtem korelace mezi každou vlastností a opotřebením řezného nástroje. Tato korelace je označena r (Pearsonovo r) a byla vypočítána pomocí standardního korelačního koeficientu. V této studii bylo zjištěno, že největší korelace mezi řeznou silou a energií signálu je ve směru osy x . Rovněž porovnáním koeficientů r byl učiněn závěr, že akustická emise a vibrační signál jsou při diagnostice řezného nástroje mnohem méně relevantní než signál řezné síly.

Jelikož samotné data-driven a model-based metody neposkytují dobré výsledky v diagnostice řezných nástrojů, byla navržena hybridní metoda. V této studii byl použit algoritmus filtrování částic, který sloužil jako fúzní algoritmus pro data-driven a model-based metodu. V tomto výzkumu byla vada systému, která způsobila nefunkčnost řezného nástroje opotřebením. Cílem bylo zjistit, do jaké míry opotřebením ovlivní práci řezného nástroje. Prvním krokem hybridní metody byla inicializace částic (jejich počet byl nastaven na 200) pomocí Gaussova rozdělení. Algoritmus hybridní metody byl navržen následovně:

„(1) Inicializace proměnné a částice pomocí Gaussova rozdělení;

pro $n = 1$: kroky řezání

$$(2) \omega_t = \omega_{t-1} + A \delta_n v_s \exp\left(\frac{-B}{T}\right) dt + v_t;$$

$$(3) RUL_t = \text{Data} - \text{drivenModel}(\text{features}) + n_t;$$

Pro $i = 1:200$

(4) Vzorkování ze známé distribuce jako (2);

(5) Výpočet hodnoty predikce RUL_t částic podle (3);

(6) Výpočet hmotnosti ω_i každé částice na základě Gaussova rozdělení;

End;

$$(7) \text{Normalizace hmotnosti částic jako } \bar{\omega}_i = \frac{\omega_i}{\sum \omega_i}$$

(8) Převzorkování na základě normalizovaných hmotností částic;

(9) Výpočet střední hodnoty predikčních hodnot částic RUL_{est} jako odhad životnosti řezného nástroje;

End;“ [21]


Rovnice (2) je produktem model-based metody a rovnice (3) představuje data-driven podíl hybridní metody. Symboly v těchto rovnicích mají následující význam:

A	→ počáteční mez kluzu
B	→ koeficient kalení
T	→ teplota celkového povrchu
δ_n	→ napětí
ω_t	→ teoretická derivace opotřebením nástroje
v_s	→ relativní rychlost prokluzu mezi nástrojem a čipem

Tab. 4.1: Význam symbolů

Obr. 4.3 ukazuje vhodnost každé z těchto metod při diagnostice opotřebením na řezném nástroji a prognostiku RUL řezného nástroje. Byl učiněn závěr, že predikce RUL, stejně

jako diagnostika poruch v závěrečné fázi výzkumu pomocí hybridní metody se zhruba z 93,79 % shodovala se skutečnými hodnotami. U data-driven metod byla tato koincidence v závěrečné fázi 80,41 % a u model-based metod kolem 90 %.



Obr. 4.3: RUL predikce řezného nástroje různými metodami [21]

Tato studie porovnávala všechny tři metody používané v diagnostice a prognóze RUL na příkladu řezného nástroje. Dosažený závěr naznačuje, že nejúčinnější ve všech stádiích diagnostiky a prognózy je hybridní metoda. Při porovnávání data-driven metody a model-based metody, data-driven byla v tomto příkladu efektivnější v počáteční a mediální fázi, zatímco model-based metoda byla efektivnější v konečné fázi predikce RUL.

5 Závěr

V této bakalářské práci byl nejprve vysvětlen význam diagnostiky pro zachování funkčnosti technických soustav. Za účelem lepší údržby technických soustav jsou studovány a klasifikovány poruchy v systému, ale i příčiny poruch. Základní rozdělení diagnostických metod na model-based a data-driven je objasněno v kapitolách 3.2 a 3.3.

Hlavním cílem této bakalářské práce bylo vysvětlit výhody a nevýhody obou metod a popsat hybridní metodu, která je jejich kombinací, viz kap. 3.4. Návrh hybridní metody se může lišit v závislosti na tom, na jakou soustavu je aplikována. Bylo objasněno, že pro klasifikaci poruch je použit data-driven podíl v hybridní metodě, zatímco pro izolaci poruch je použit model-based podíl v hybridní metodě.

V tomto výzkumu jsou výše uvedené metody vysvětleny na příkladu CNC obráběcího stroje, konkrétně na řezném nástroji. Konkrétně všechny tři tyto metody byly používány jednotlivě na CNCMT. Návrh hybridní metody v tomto konkrétním příkladu byl objasněn v kapitole 4.

Podle zhodnocení získaných informací je můj závěr takový, že v diagnostice a prognóze technických soustav je hybridní metoda nejpřesnější a poskytuje nejlepší výsledky. Hybridní metodou lze dosáhnout výsledků s přesností 95 až 100 %. V případě diagnostiky řezného nástroje bylo pozorováno, že v konečné fázi diagnostiky a prognózy poskytuje model-based metoda lepší výsledky než data-driven metoda. Pokud bychom však měli diagnostikovat příliš složitý systém, nebylo by možné navrhnout jeho model a byla by upřednostněna data-driven metoda.

Proto jsou hybridní metody novým trendem v oblasti diagnostiky. V poslední době se jimi zabývá stále více výzkumů, protože poskytují velmi přesné výsledky a kombinují to nejlepší, co poskytují data-driven a model-based metody.

6 Seznam použitých zdrojů

- [1] CZICHOS, Horst. *Handbook of Technical Diagnostics: Fundamentals and Application to Structures and Systems* [online]. Berlin: Springer, 2013. ISBN 978 3 642 25849 7.
- [2] NEČAS, David. Lecture 3. *VUT Elearning* [online]. [cit. 2021-4-29]. Dostupné z: https://moodle.vutbr.cz/pluginfile.php/262826/mod_resource/content/1/5KS%203%202019%20%E2%80%93%20A.pdf
- [3] JUNG, Daniel, Kok Yew NG, Erik FRISK a Mattias KRYSANDER. Combining model-based diagnosis and data-driven anomaly classifiers for fault isolation. *Control Engineering Practice* [online]. 2018, 2018, (80), 147–156 [cit. 2021-4-29]. ISSN 09670661. Dostupné z: doi:10.1016/j.conengprac.2018.08.013
- [4] KADRY, Seifedine. *Diagnostics and Prognostics of Engineering Systems: Methods and Techniques*. United States of America: Engineering Science Reference, 2013. ISBN 978-1-4666-2095-7.
- [5] Zayeri, Reza & Attaran, Beherooz & Ghanbarzadeh, Afshin & Moradi, Shahrar. (2011). Artificial Neural Network Based Fault Diagnostics of Rolling Element bearings using Continuous Wavelet Transform. Proceedings - 2011 2nd International Conference on Control, Instrumentation and Automation, ICCIA 2011. 10.1109/ICCIAutom.2011.6356754.
- [6] HUI, K.H., M.H. LIM, M.S. LEONG a S.M. AL-OBAIDI. Dempster-Shafer evidence theory for multi-bearing faults diagnosis. *Engineering Applications of Artificial Intelligence* [online]. 2017 [cit. 2021-5-13]. ISSN 09521976. Dostupné z: doi:10.1016/j.engappai.2016.10.017
- [7] KOSTYUKOV, V.N. a A.V. ZAYTSEV. Using Adaptive Algorithms Based of Fuzzy Logic in Vibration Diagnostic Systems. *Procedia Engineering* [online]. 2016, (152) [cit. 2021-5-13].
ISSN 18777058. Dostupné z: doi:<https://doi.org/10.1016/j.proeng.2016.07.628>
- [8] Kuo, C.-C.; Liu, C.-H.; Chang, H.-C.; Lin, K.-J. Implementation of a Motor Diagnosis System for Rotor Failure Using Genetic Algorithm and Fuzzy Classification. *Appl. Sci.* **2017**, 7, 31. <https://doi.org/10.3390/app7010031>
- [9] L. E. Sturlaugson a J. W. Sheppard, "Principal component analysis preprocessing with Bayesian networks for battery capacity estimation," *2013 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, 2013, pp. 98-101, doi: 10.1109/I2MTC.2013.6555389.

- [10] Di, Pei & Yue, Jianhai & Jiao, Jing. (2017). Rolling bearing fault diagnosis based on information fusion using Dempster-Shafer evidence theory. *IOP Conference Series: Materials Science and Engineering*. 241. 012035. 10.1088/1757-899X/241/1/012035.
- [11] D. Jung, Data-Driven Open-Set Fault Classification of Residual Data Using Bayesian Filtering, in *IEEE Transactions on Control Systems Technology*, vol. 28, no. 5, pp. 2045–2052, Sept. 2020, doi: 10.1109/TCST.2020.2997648.
- [12] VACHTSEVANOS, George, Frank LEWIS, Michael ROEMER, Andrew HESS a Biqing WU. *Intelligent Fault Diagnosis and Prognosis for Engineering Systems*. New Jersey: Wiley, 2006. ISBN 978-0-0471-72999-0.
- [13] Shao Jiye and Guo Wei, A state searching method for model-based diagnosis, *The 2010 International Conference on Apperceiving Computing and Intelligence Analysis Proceeding*, 2010, pp. 466–469, doi: 10.1109/ICACIA.2010.5709942.
- [14] *Contact stress analysis in a spur gear assembly* [online]. 2014 [cit. 2021-4-29]. Dostupné z: <https://grabcad.com/library/contact-stress-analysis-in-a-spur-gear-assembly-1>
- [15] J. F. LUCAS, Peter. Bayesian model-based diagnosis. *International Journal of Approximate Reasoning* [online]. 2001, 2001, (27), 99–119 [cit. 2021-4-29]. ISSN 0888613X. Dostupné z: doi:10.1016/S0888-613X(01)00036-6
- [16] SKLIROS, C, Esperon MIGUEZ M, Fakhre A a Jennions IK. A review of model based and data driven methods targeting hardware systems diagnostics. *Diagnostyka* [online]. 2019, 2020, 2019(1), 4–17 [cit. 2021-4-29]. Dostupné z: doi:10.29354/diag/99603
- [17] HAYIEV, Chingiz. An Innovation Approach Based Sensor Fault Detection and Isolation. *IFAC-PapersOnLine* [online]. 2016 [cit. 2021-5-13]. Dostupné z: doi:<https://doi.org/10.1016/j.ifacol.2016.09.072>
- [18] SHIN, Won, Jeongyun HAN a Wonjong RHEE. AI-assistance for predictive maintenance of renewable energy systems. *Energy* [online]. 2021 [cit. 2021-5-13]. ISSN 0360-5442.
Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0360544221000244>
- [19] AIVALIOTIS, P., K. GEORGOULIAS a G. CHRYSSOLOURIS. The use of Digital Twin for predictive maintenance in manufacturing. *International Journal of Computer Integrated Manufacturing* [online]. [cit. 2021-5-13]. ISSN 0951192X. Dostupné z: doi:10.1080/0951192X.2019.1686173
- [20] WILKE, D.N., W. BOOYSE a S. HEYNS. Deep digital twins for detection, diagnostics and prognostics. *Mechanical Systems and Signal Processing* [online]. [cit. 2021-5-13]. ISSN 08883270. Dostupné z: doi:10.1016/j.ymsp.2019.106612

- [21] LUO, Weichao, Tianling HU, Yingxin YE, Chengrui ZHANG a Yongli WEI. A hybrid predictive maintenance approach for CNC machine tool driven by Digital Twin. *Robotics and Computer-Integrated Manufacturing* [online]. October 2020, October 2020, (65), 1–16 [cit. 2021-4-29]. ISSN 07365845. Dostupné z: doi:10.1016/j.rcim.2020.101974
- [22] KRITZINGER, Werner, Matthias KARNER, Georg TRAAR, Jan HENJES a Wilfried SIHN. Digital Twin in manufacturing: A categorical literature review and classification. *IFAC-PapersOnLine* [online]. 2018, , 1016-1022 [cit. 2021-5-18]. Dostupné z: doi:https://doi.org/10.1016/j.ifacol.2018.08.474
- [23] Cai, Yi; Starly, Binil; Cohen, Paul; Lee, Yuan-Shin (2017). Sensor Data and Information Fusion to Construct Digital-twins Virtual Machine Tools for Cyber-physical Manufacturing. In *Procedia Manufacturing*, 10, pp. 1031–1042.
- [24] Frazzon, Enzo Morosini; Albrecht, André; Hurtado, Paula Andrea (2016). Simulation-based optimization for the integrated scheduling of production and logistic systems. In *IFAC-PapersOnLine*, 49 (12), pp. 1050–1055.
- [25] Gyulai, Dávid; Pfeiffer, András; Kádár, Botond; Monostori, László (2016). Simulation-based Production Planning and Execution Control for Reconfigurable Assembly Cells. In *Procedia CIRP*, 57, pp. 445–450.
- [26] Friedrich, Christian; Lechler, Armin; Verl, Alexander (2014). Autonomous Systems for Maintenance Tasks – Requirements and Design of a Control Architecture. In *Procedia Technology*, 15, pp. 595–604.
- [27] Jain, Sanjay; Fong Choong, Ngai; Maung Aye, Khin; Luo, Ming (2001). Virtual factory. An integrated approach to manufacturing systems modeling. In *Int Jrnl of Op & Prod Mngemnt*, 21 (5/6), pp. 594–608.
- [28] Simons, Stephan; Abé, Patrick; Naser, Stephan (2017). Learning in the AutFab – The Fully Automated Industrie 4.0 Learning Factory of the University of Applied Sciences Darmstadt. In *Procedia Manufacturing*, 9, pp. 81–88.
- [29] Boschert, Stefan; Rosen, Roland (2016). Digital Twin—The Simulation Aspect. In Peter Hehenberger, David Bradley (Eds.): *Mechatronic Futures*. Cham: Springer International Publishing, pp. 59–74.
- [30] Bottani, E.; Cammardella, A.; Murino, T.; Vespoli, S. (2017). From the Cyber-Physical System to the Digital Twin: the process development for behaviour modelling of a Cyber Guided Vehicle in M2M logic.
- [31] Brenner, Beate; Hummel, Vera (2017). Digital Twin as Enabler for an Innovative Digital Shopfloor Management System in the ESB Logistics Learning Factory at Reutlingen - University. In *Procedia Manufacturing*, 9, pp. 198–205.

- [32] W, Borutzky. A Hybrid Bond Graph Model-based-Data Driven Method for Failure Prognostic. *Procedia Manufacturing* [online]. 2020, (42), 189–196 [cit. 2021-4-29]. Dostupné z: <https://www.sciencedirect.com/ezproxy.lib.vutbr.cz/science/article/pii/S2351978920306338>
- [33] WANG, Zhuo a Zhong-Sheng HOU. From model-based control to data-driven control: Survey, classification and perspective. *Information Sciences* [online]. 2013, 4. 8. 2012, (235), 4–32 [cit. 2021-4-29]. ISSN 00200255. Dostupné z: [doi:10.1016/j.ins.2012.07.014](https://doi.org/10.1016/j.ins.2012.07.014)
- [34] *CNC MAŠINE* [online]. Srbija: industrija.rs, 2019 [cit. 2021-4-29]. Dostupné z: <https://www.industrija.rs/vesti/clanak/cnc-masine?fbclid=IwAR2uh2OnjFqDM0A3Wc8hmbRquz1NO9zoeO5AwO33XQNkoPjJhDlkc1Occ44>
- [35] *The Essential Guide to Quality Training Data for Machine Learning* [online]. Cloudfactory, February 2020 [cit. 2021-4-29]. Dostupné z: https://www.cloudfactory.com/training-data-guide?fbclid=IwAR26-YddHZrvW1DvUf2Fxm5s2fYPCqF5imfu5aY_ZqRI-sUfp6aQeDDUiXs
- [36] W. Ziling, X. Aiqiang and Y. Zhiyong, Application of Model-based and Data-driven Techniques in Fault Diagnosis, *2007 8th International Conference on Electronic Measurement and Instruments*, 2007, pp. 3-451-3-454, doi: 10.1109/ICEMI.2007.4350953.
- [37] Medjaher, K., Zerhouni, N. Hybrid prognostic method applied to mechatronic systems. *Int J Adv Manuf Technol* 69, 823–834 (2013). <https://doi.org/10.1007/s00170-013-5064-0>
- [38] D. Jung, K. Y. Ng, E. Frisk and M. Krysander, A combined diagnosis system design using model-based and data-driven methods, *2016 3rd Conference on Control and Fault-Tolerant Systems (SysTol)*, 2016, pp. 177–182, doi: 10.1109/SYSTOL.2016.7739747.
- [39] Milovanovic, Zdravko & Papic, Ljubisa. (2007). Tehnička dijagnostika.

Seznam obrázků

3.1	Systémový přístup k aplikaci technické diagnostiky.....	8
3.2	Únavová trhлина dutého hřídele.....	9
3.3	Zkušební stav převodovky vysokorychlostního vlaku	14
3.4	Postup model-based metody	15
3.5	Příklad modelování v ANSYS – analýza kontaktního napětí v sestavě čelního kola.....	16
3.6	Uživatelské rozhraní pro kontrolní úkol	18
3.7	Schéma návrhu diagnostického systému	19
3.8	Datový tok v Digital Model.....	21
3.9	Datový tok v Digital Shadow.....	22
3.10	Datový tok v Digital Twin.....	22
3.11	Digitální model robota.....	23
3.12	Porovnání predikovaných a nominálních signálů točivého momentu po šesti měsících.....	24
3.13	Výpočet RUL na základě maximální povolené odchylky.....	24
4.1	Instalace senzorů na obráběcím stroji	26
4.2	Výsledky ověření přesnosti	27
4.3	RUL predikce řezného nástroje různými metodami	29