



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA STROJNÍHO INŽENÝRSTVÍ

FACULTY OF MECHANICAL ENGINEERING

ÚSTAV AUTOMATIZACE A INFORMATIKY

INSTITUTE OF AUTOMATION AND COMPUTER SCIENCE

**MODERNÍ VIBRODIAGNOSTIKA STROJŮ A
HODNOCENÍ DATOVÝCH SOUBORŮ
NEURONOVÝMI SÍTĚMI**

MODERN VIBRODIAGNOSTICS OF MACHINES AND EVALUATION OF DATASETS BY NEURAL NETWORKS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Tomáš Koníček

VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. Miloš Hammer, CSc.

BRNO 2024

ZADÁNÍ

Cíle, kterých má být dosaženo:

Pojednejte stručně o technické diagnostice, rozeberte vibrodiagnostiku strojů a zařízení a proveďte rešerši sledování vibrací pomocí moderních on-line systémů. Rozeberte možnosti zpracování získaných datových souborů, pojednejte i o neuronových sítích s důrazem na jejich využití ve vibrodiagnostice. Zaměřte se na rozbor vibračního monitoringu od firmy Siemens SIPLUS CMS. Popište jednotlivé hardwarové a softwarové komponenty. Zaměřte se na diagnostiku strojů. Data se budou získávat měřením na reálném modelu, který je k dispozici a který je vybaven systémem SIPLUS CMS, který funguje ve spolupráci s programovatelným automatem SIMATIC S7-1200. Získaná data budou odeslána přes protokol FTP k dalšímu zpracování v programu Matlab. K jejich hodnocení použijte vybraných neuronových sítí. Výsledky náležitě vyhodnoťte.

Charakteristika problematiky úkolu:

Vibrodiagnostika je jedna z důležitých diagnostických metod, které slouží k popisu a rozboru stavu strojů. I tato metoda prodělala složitý vývoj, v současné době se diagnostická data získávají přímo z řídicích systémů (PLC) s využitím vhodného hardwaru a softwaru. Začíná se rozvíjet pokročilá vibrodiagnostika, která využívá k hodnocení dat neuronových sítí. Diplomová práce se zaměřuje na systémy firmy Siemens, které mají označení SIPLUS CMS. Datové soubory budou zpracovány v softwarovém prostředí Matlab s využitím neuronových sítí.

Základní literární prameny:

BILOŠ, Jan a Alena BILOŠOVÁ. Aplikovaný mechanik jako součást týmů konstruktérů a vývojářů: studijní opora. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, Fakulta strojní, 2012. 142 s. ISBN 978-80-248-2755-1.
SIMATIC S7- 1200. Firemní materiál Siemens, s.r.o. 12 s. 2012. Dostupné z: axima-obchod.cz/admin-data/storage/get/2041-brochure-s7-1200web.pdf.
HAVEL, Josef. SIMATIC S7-1200. Krok za krokem. 142 s. Firemní materiál. Firma Siemens, s.r.o. 2012. Praha.
Firemní materiály Siemens, s.r.o., 2023. Dostupné z: new.siemens.com/cz/cs.html.
BERGER, Hans. Automatisieren mit SIMATIC S7-1200. Public MCD Verlag, 751 s. Germany, 2017.
ČSN ISO 17359. Monitorování stavu a diagnostika strojů - Obecné pokyny. Praha: Úřad pro technickou normalizaci, metrologii a státní zkušebnictví, 2018.
HELEBRANT, František a Jiří ZIEGLER. Technická diagnostika a spolehlivost II. Vibrodiagnostika. Ostrava: VŠB - Technická univerzita, 2004. 178 s. ISBN 80-248-0650-9.
ČSN ISO 20816-1. Vibrace – Měření a hodnocení vibrací strojů - Část 1: Obecné pokyny. Praha: Úřad pro technickou normalizaci, metrologii a státní zkušebnictví, 2017.
Matlab Help (on-line) MathWorks, Inc. (cit. 2023-05-22). Dostupné z [http:// www.mathworks.com/help](http://www.mathworks.com/help).
VOLNÁ, Eva. Neuronové sítě. Studijní opora k inovovanému předmětu: Neuronové sítě (KIP/NESI1). Ostravská univerzita v Ostravě. 2013. 86 s. ISBN 978-80-7464-329-3.

ABSTRAKT

Tato diplomová práce se zaměřuje na technickou diagnostiku s důrazem na vibrodiagnostiku strojů a zařízení. Cílem je provést rešerši sledování vibrací pomocí moderních on-line systémů a zkoumat možnosti zpracování získaných datových souborů s využitím neuronových sítí. Analyzuje se vibrační monitoring od firmy Siemens SIPLUS CMS, včetně popisu jednotlivých hardwarových a softwarových komponent. Práce se dále zaměřuje na diagnostiku strojů s využitím reálného modelu vybaveného systémem SIPLUS CMS ve spolupráci s programovatelným automatem SIMATIC S7-1200. Získaná data budou přenášena přes protokol FTP k dalšímu zpracování v programu Matlab. Budou navrženy a použity modely neuronových sítí, které budou natrénovány na naměřených datech. Bude použit model konvolučních neuronových sítí. Výsledky budou vyhodnoceny a bude vznesen závěr.

ABSTRACT

This Master's thesis focuses on technical diagnostics with an emphasis on vibrodiagnostics of machines and equipment. The aim is to carry out research on vibration monitoring using modern on-line systems and to investigate the possibilities of processing the acquired data files using neural networks. Vibration monitoring from Siemens SIPLUS CMS is analyzed, including a description of individual hardware and software components. The work also focuses on machine diagnostics using a real model equipped with the SIPLUS CMS system in cooperation with the SIMATIC S7-1200 programmable automaton. The obtained data will be transferred via the FTP protocol for further processing in the Matlab program. Neural network models will be designed and used, which will be trained on the measured data. Convolutional neural network model will be used. The results will be evaluated and a conclusion will be drawn.

KLÍČOVÁ SLOVA

Vibrace, měření, on-line systémy, diagnostika, technická diagnostika, Siemens, Siplus CMS, Siemens S7-1200, matlab, neuronové sítě, konvoluce, vlnková transformace, zpracování signálu, Fourierova transformace, umělá inteligence

KEYWORDS

Vibration, measurement, online systems, diagnostics, technical diagnostics, Siemens, Siplus CMS, Siemens S7-1200, matlab, neural networks, convolution, wavelet transform, signal processing, Fourier transform, artificial intelligence



2024

BIBLIOGRAFICKÁ CITACE

KONÍČEK, Tomáš. *Moderní vibrodiagnostika strojů a hodnocení datových souborů neuronovými sítěmi* [online]. Brno, 2024 [cit. 2024-04-03]. Dostupné z: <https://www.vut.cz/studenti/zav-prace/detail/157554>. Diplomová práce. Vysoké učení technické v Brně, Fakulta strojního inženýrství, Ústav automatizace a informatiky. Vedoucí práce Miloš Hammer.

PODĚKOVÁNÍ

Chtěl bych poděkovat své rodině , přítelkyni, kamarádům a svému vedoucímu práce za jejich podporu a trpělivost.

ČESTNÉ PROHLÁŠENÍ

Prohlašuji, že, že tato práce je mým původním dílem, vypracoval jsem ji samostatně pod vedením vedoucího práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury.

Jako autor uvedené práce dále prohlašuji, že v souvislosti s vytvořením této práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následku porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestně právních důsledků.

V Brně dne 20. 5. 2024

.....

Bc. Tomáš Koníček

OBSAH

1	ÚVOD.....	15
2	TECHNICKÁ DIAGNOSTIKA.....	17
2.1	Technická diagnostika a pojmy	17
2.2	Metody a dělení technické diagnostiky	18
3	VIBRODIAGNOSTIKA.....	21
3.1	Vibrační signál	21
3.2	Snímače.....	24
3.2.1	Snímače výchylky.....	25
3.2.2	Snímače rychlosti	26
3.2.3	Snímače zrychlení.....	27
4	ON-LINE SYSTÉMY	28
4.1	ABB Ability Smart Sensor TM.....	29
4.2	Adash A3800.....	30
4.3	Skf @ptitude Analyst.....	30
4.4	PRUFTECHNIK VibGuard	31
4.5	Siemens SIPLUS CMS	32
5	MOŽNOSTI ZPRACOVÁNÍ DATOVÝCH SOUBORŮ	34
5.1	Fourierova transformace	34
5.1.1	Diskrétní Fourierova transformace.....	35
5.2	Hilbertova transformace.....	36
5.3	Metoda činitele výkmitu Crest factor	37
6	NEURONOVÉ SÍTĚ	38
6.1	Obecný popis a použití.....	38
6.2	Formální neuron	38
6.3	Perceptron.....	38
6.4	Klasifikace vzorů.....	39
6.5	Aktivační funkce	39
6.6	Hluboké neuronové sítě	41
6.7	Konvoluční neuronové sítě	42
6.8	Vrstvy CNN.....	43
6.8.1	Konvoluční vrstva.....	44
6.8.2	Pooling vrstvy.....	45
6.8.3	Batch Normalization.....	47
6.8.4	Fully connected layer.....	48
7	ZKOUMANÝ MODEL	49
7.1	Schéma modelu a popis	49

7.2	Popis hardwaru	50
7.2.1	SINAMIC V90	50
7.2.2	SIMATIC S7-1200	50
7.2.3	CMS VIB-Sensor S03.....	52
7.2.4	Popis softwaru	53
8	PRAKTICKÁ ČÁST.....	57
8.1	Měření na modelu, získávání a předzpracování dat.....	57
8.2	Reprezentace dat	59
8.3	Přístup první, 1D - CCN.....	60
8.3.1	Návrh konvoluční neuronové sítě.....	60
8.3.2	Trénink konvoluční neuronové sítě	62
8.3.3	Návrh dalších sítí	63
8.4	Přístup druhý, 2D - CNN s Wavelet transform	64
8.4.1	Tvorba wavelet transform datasetu.....	65
8.4.2	Návrh neuronové sítě pro wavelet dataset	66
9	ZHODNOCENÍ A DISKUZE.....	69
9.1	Vyhodnocení přístupu 1, CCN-1	69
9.2	Vyhodnocení přístupu 1, CCN-2, CNN-3, CNN-4, CNN-5	71
9.3	Vyhodnocení přístupu 2	73
10	ZÁVĚR.....	77
	SEZNAM POUŽITÉ LITERATURY.....	79

1 ÚVOD

Průmysl 4.0 představuje evoluční posun ve výrobním paradigmatu, označující čtvrtou průmyslovou revoluci. Tento trend je charakterizován integrací kyberneticko-fyzikálních systémů a moderních digitálních technologií, jako je internet věcí, umělá inteligence, rozšířená realita, robotika a analýza dat, do výrobního procesu. Tato integrace vytváří vysoce propojený a inteligentní ekosystém, který umožňuje monitorování v reálném čase, prediktivní údržbu a efektivnější a flexibilnější výrobní procesy.

Historie monitorování strojních procesů sahá až do pozdních 18. století, kdy se používaly mechanické snímače. Postupem času se objevily analogové elektrické senzory a s nimi spojené technologické inovace. V současné době, v éře Průmyslu 4.0, se používají inteligentní senzory, které přinášejí významné vylepšení ve sledování a sběru dat.

S rozvojem technologií Průmyslu 4.0 se stále více zaměřujeme na sběr a analýzu dat v reálném čase, zejména z sensorů zabudovaných přímo do strojních zařízení, jako jsou rotační stroje. To umožňuje identifikaci vzorců a predikci poruch pomocí pokročilé analytiky a umělé inteligence.

V této práci bude rozebrána technická diagnostika s důrazem na vibrodiagnostiku a popis signálu. Bude provedena rešerše monitorovacích systémů s následným zaměřením na systém Siemens, jehož komponenty je osazen poskytnutý model rotačního stroje, na kterém bude provedena praktická část.

Cílem praktické části bude naměřit signál z vibračních sensorů umístěných na modelu a tyto data následně pomocí FTP serveru přenést do programovacího prostředí Matlab, kde budou dále zpracovávána a vyhodnocena.

Tato práce se zabývá využitím hlubokých konvolučních neuronových sítí k řešení klasifikačních úloh monitorování stavu strojů.

2 TECHNICKÁ DIAGNOSTIKA

2.1 Technická diagnostika a pojmy

Technická diagnostika je vědní a současně praktický obor, zabývající se metodami a prostředky zjišťování skutečného technického stavu objektů v reálném čase, bez jejich demontáže nebo destrukce.

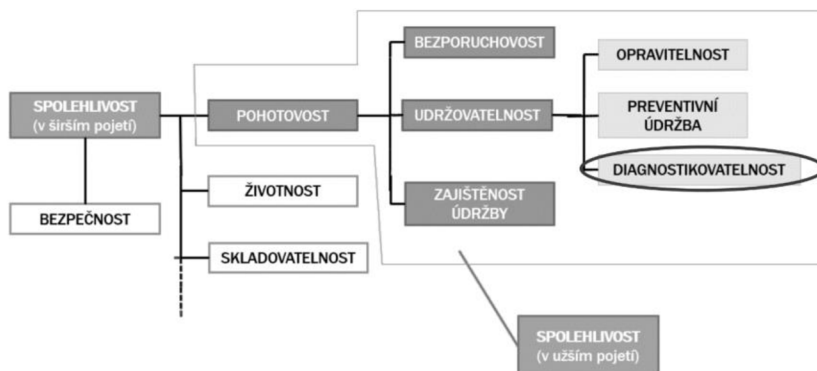
Je to disciplína zaměřená na identifikaci a analýzu poruch, defektů nebo nedostatků v technických systémech, zařízeních či procesech. Hlavní záměr je zjištění skutečného technického stavu objektu v reálném čase. Využívá moderní technologie a metody k monitorování, testování a hodnocení stavu technických zařízení s cílem zajišťovat bezpečný a efektivní provoz. Při zkoumání se soustředí na bezdemontážní a nedestruktivní přístupy. Diagnostika může být aplikována na širokou škálu odvětví, včetně průmyslu, dopravy, energetiky a dalších oblastí.

Cílem technické diagnostiky je identifikovat, analyzovat a monitorovat stav technických zařízení, systémů nebo procesů s účelem předcházet poruchám, prodlužovat životnost zařízení a zvyšovat jejich spolehlivost. Také zvyšuje bezpečnost provozu, kdy může chránit pracovníky před nečekanými vlivy poškození stroj. [1]

V následujícím jsou uvedeny některé důležité pojmy.

Spolehlivost

Chápání pojmu spolehlivost a jeho definice se postupem času měnil. Proto existuje několik definic spolehlivosti. První a nejstarší definice spolehlivosti je spjata s bezporuchovostí. Také by se dalo konstatovat, že spolehlivost je „kvalita v čase“. „Pravděpodobnost, s jakou bude objekt schopen plnit bez poruchy požadované funkce po stanovenou dobu a v daných provozních podmínkách“. Dále by se dala definovat jako obecná vlastnost výrobku plnit požadované funkce po stanovenou dobu a ve stanovených provozních podmínkách, která se vyjadřuje dílčími vlastnostmi jako jsou bezporuchovost, životnost, opravitelnost, apod. [2]



Obrázek 1: Zařazení spolehlivosti, převzato z [2]

Diagnostikovatelnost

Je operace prováděná za účelem sledování a zjištění poruchového stavu, identifikace vady a lokalizace porouchané části. [2]

Diagnostická veličina

Nejčastěji to bývá jednoduchá, měřitelná, fyzikální veličina, která charakterizuje stav objektu. Například: Tlak [Pa], Teplota [C], Intenzita zvuku (Hluk) [dB], Zrychlení (Vibrace) [m/s^2], Elektrické veličiny (napětí, proud, odpor ...) [2]

Diagnostické prostředky

Jsou přístroje, pomůcky a pomocná zařízení sloužící k realizaci diagnostických metod. Diagnostické prostředky se zpravidla umísťují na diagnostická pracoviště. Ta mohou být umístěna ve stálých objektech nebo mohou být mobilní. Diagnostické prostředky musí zabezpečit zejména [2]:

- objektivnost kontroly a hodnocení diagnostických parametrů
- přesnost, věrohodnost a stálost zjištěných hodnot
- možnost měření bez demontáže objektu, případně měření při jeho činnosti
- minimální dobu pro přípravu přístroje a k provedení měření

Diagnostický systém

Je to organizovaný soubor tvořený objektem diagnostiky, diagnostickými prostředky, jejich obsluhou a souborem pracovních postupů (diagnostických algoritmů, metod a metodik). Slouží k realizaci diagnostického procesu, to znamená zjištění technického stavu objektu pomocí zvolených metod. Diagnostický systém se skládá z [2]:

- Objektu diagnostiky – stroj, zařízení, kde zjišťujeme stav
- Diagnostický prostředek – měřicí přístroj
- Obsluha – člověk, který diagnostický přístroj obsluhuje (diagnostik)
- Pracovní postup – metodiky a postupy pro diagnostiku

2.2 Metody a dělení technické diagnostiky

Dělení technické diagnostiky

1) Podle diagnostických veličin [1,2, 3]

- a) Diagnostika deformace
- b) Diagnostika tlaku
- c) Termodiagnostika – Měření teplot, a to buď bodově, nebo plošně (termovize). Pomocí měření povrchové teploty lze zjistit místa s odlišnou s teplotou a z toho usuzovat důvody rozdílných teplot. Mezi důvody může patřit zvýšené tření v důsledku nedostatku maziva, elektrický zkrat, nedostatek chladicí kapaliny atd. Pomocí termovize dokážeme poměrně jednoduše odhalit přetěžované části zařízení. Termovizní snímky se obvykle doplňují o barevnou fotografii z důvodu vyššího rozlišení.

- d) Vibrodiagnostika – Signál od vibrací nese informace o příčině vibrací a jeho analýzou různými metodami lze zjistit vznikající nebo rozvíjející se závadu. U rotačních strojů je to obvykle metoda, která pokrývá nejvíce možných vyskytujících se závad. Vibrační diagnostiku podrobněji popisují normy ČSN ISO 13373-1: Monitorování stavu a diagnostika strojů – Monitorování stavu vibrací – Část 1: Obecné postupy a ČSN ISO 13373-2: Monitorování stavu a diagnostika strojů - Monitorování stavu vibrací - Část 2: Zpracování, prezentace a analýza vibračních dat. [1]
- e) Hluková diagnostika – Posuzuje stav zařízení podle hluku.
- f) Tribodiagnostika – Jedná se o analýzu maziv. Plní se dva základní úkoly:
Seldování stavu maziva – Zhoršování stavu maziva může docházet z různých důvodů jako: oxidace, vniknutí vody, vniknutí cizích látek atd.
Ferrografie (analýza nečistot a otěrových částic) – Analýzou materiálu a jeho tvaru vyskytujícím se v mazivu se odhaduje místo a důvod opotřebení zařízení.
- g) Elektrodiagnostika – Provádí se analýzou elektrických veličin, na jejich základě se odhaduje poškození stroje. Využívá se primárně u točivých elektrických strojů – motorů a generátorů. Mezi sledované veličiny patří například elektrický proud.
- h) Provozní diagnostika – Využívají se všechny dostupné provozní parametry, které se periodicky zapisují. Problematikou se zabývá norma ČSN ISO 17359 - Monitorování stavu a diagnostika strojů – Obecné pokyny.

Tabulka 1: Příklad sledování provozních parametrů dle ČSN ISO 17359

Typ stroje: Čerpadlo	Změna symptomu nebo parametru										
	Závada	Únik kapaliny	Měření délek	Výkon	Tlak nebo vakuum	Otáčky	Vibrace	Teplota	Doba do běhu	Znečištění oleje	Netěsnos oleje
Poškozené oběžné kolo		
Poškozené ucpávky					
Excentrické oběžné kolo					
Poškozené ložisko	
Opotřebené ložisko		
Chybná montáž						.					
Nevyváženost						.					
Nesouosost		.				.					

* Když se vyskytne závada, může se vyskytnout indikovaný symptom nebo změna parametru.

- 2) Podle diagnostických prostředků [2, 3]
- a) ONLINE diagnostika – Umožňuje monitorování stavu zařízení v reálném čase během provozu. Tento typ diagnostiky využívá senzory a speciální softwarové systémy k průběžnému sběru dat o stavu zařízení. Díky online diagnostice lze detekovat potenciální problémy ihned po jejich vzniku a přijmout opatření pro minimalizaci rizika výrobních výpadků.

- b) OFFLINE diagnostika – Provádí se mimo provozní dobu zařízení, obvykle při plánovaných údržbářských inspekcích nebo při odstávkách zařízení. Tento typ diagnostiky může zahrnovat provádění testů, inspekci zařízení nebo analýzu historických dat. I když off-line diagnostika nenabízí okamžité informace jako online diagnostika, stále je nezbytná pro dlouhodobou analýzu a plánování údržby.
- 3) Podle zařízení [2, 3]
- a) Diagnostika čerpadel – zaměřuje se na monitorování jejich výkonu, otáček a průtoku kapaliny, čímž je umožňováno detekci možných poruch nebo opotřebení.
 - b) Diagnostika ventilátorů – sledují se jejich otáčky, tlak a průtok vzduchu, což přispívá k identifikaci případných nedostatků v chodu či opotřebení.
 - c) Diagnostika obráběcích strojů – zahrnuje sledováním vibrací, teploty a úrovně opotřebení nástrojů, což přispívá k prevenci poruch a zajištění optimálního výkonu strojů.
 - d) Diagnostika pohonů – analyzují se vibrace, teplota a úroveň opotřebení ložisek a převodů, což umožňuje odhalování možných poruch a plánování údržby.
 - e) Diagnostika elektrických strojů – provádí se pomocí měření proudů, napětí a teploty, což umožňuje identifikaci přetížení, přehřátí nebo jiných elektrických problémů.
 - f) Diagnostika ložisek strojů – sledují se vibrace, teplota a hladina opotřebení ložisek, což pomáhá předcházet jejich poruchám a prodlužovat jejich životnost.

3 VIBRODIAGNOSTIKA

Vibrodiagnostika je jedna z metod technické diagnostiky, která se zabývá měřením vibrací. V praxi je velmi používanou a efektivní, protože se jedná o bezdemontážní nedestruktivní metodu. To umožňuje provádět měření bez nutnosti do zásahu provozu zařízení, kdy to v mnoha případech není ani možné (rozměrné parní turbíny v elektrárnách) nebo by to bylo nákladné z důvodu vysoké ceny prostojů (automobilová výroba). Jak už z názvu vibrodiagnostiky vyplývá, hlavním nosičem informací jsou vibrace neboli mechanické kmitání a chvění. [5,6]

„Vibrace vznikají pohybem pružného tělesa nebo prostředí, jehož jednotlivé body kmitají kolem své rovnovážné polohy (konkrétně chodem strojů a přístrojů, motorů dopravních či jiných prostředků, ale i třeba lodní paluby vlivem mořských vln).“ [5]

Hlavním cílem vibrodiagnostiky je určit skutečný stav zařízení na základě zpracování signálu. To umožňuje předcházet fatálním poruchám, plánovat prediktivní údržbu a minimalizovat prostoje. [5]

3.1 Vibrační signál


Slovo vibrace si můžeme představit jako některou z forem kmitavého pohybu, a to konkrétně kmitavého pohybu mechanického. Jedná se tedy o periodický děj, který můžeme popsat matematicky pomocí harmonické funkce. S tím se pojí charakteristické parametry jako je frekvence, perioda a amplituda. Jako nejjednodušší příklad si můžeme představit mechanické kmitání vynucené, kdy je oscilátor periodicky buzen budící silou o dané frekvenci. Avšak v technické praxi se s čistou harmonickou budící silou setkáváme se pouze zřídka, většinu skutečných budících sil vyskytujících se v oblasti rotačních zařízení lze vyjádřit součtem harmonických sil. Proto lze popsat vlastnosti periodické síly a její vliv na vibrační odezvu pomocí harmonické síly a odezvy. [1, 5]

Působí-li na pružně uložené tělese periodická budící síla

$$f(t) = F \cdot \sin(\omega t + \varphi_F) \quad (1)$$

bude kmitání tělesa po ustálení přechodových jevů na stejné kruhové frekvenci (ω) ale obecně s jinou amplitudou. Takovéto kmitání nazýváme vynucené kmitání. Výchylku kmitání při ustáleném stavu si pak můžeme vyjádřit jako [1]:


$$x(t) = X \cdot \sin(\omega t + \varphi_F - \varphi) \quad (2)$$



Obrázek 2: Vynucené kmitání způsobené harmonickou budící silou, převzato z [1]

Impulzní budící síla

Při působení impulsní síly na těleso dochází k jeho vychýlení z rovnovážné polohy a následnému volnému kmitání na jedné nebo více vlastních frekvencích. Toto chování můžeme pozorovat u různých objektů, například u skleničky, na kterou poklepeme, nebo u zvonu, který rozeznáme. V technické praxi se záměrné rázové buzení využívá technické praxi pro testování a diagnostiku konstrukcí a strojů. Naopak nezáměrné rázové buzení se může vyskytnout například při závadách ve valivých ložiscích. [1]



Obrázek 3: Reakce soustavy na impulzní budící sílu, převzato z [1]

Pro podrobnější popis vibrací si uvedeme více používaných základních veličin. Při kmitavém pohybu tělesa s hmotností m uloženým na pružném uložení s tuhostí k vykonává po vychýlení z rovnovážné polohy harmonický kmitavý pohyb na vlastní frekvenci. Pokud neuvažujeme tlumení b , tak platí, že těleso bude kmitat na vlastní frekvenci [1]:

$$\Omega = \sqrt{\frac{k}{m}} \quad (3)$$

a průběh výchylky bude:


$$x(t) = X_a \cdot \sin(\Omega \cdot t - \varphi) \quad (4)$$

V běžné technické praxi se však setkáme častěji s frekvencí f vyjádřenou v hertziích počtem cyklů za sekundu než s kruhovou frekvencí omega [1]:

$$f = \frac{\Omega}{2\pi} \quad (5)$$

Dále pak převrácenou hodnotou frekvence f je perioda T :

$$T = \frac{1}{f} = \frac{2\pi}{\omega} \quad (6)$$



Obrázek 4: Kmitavá pohyb a základní veličiny, převzato z [1]

Kromě maximální amplitudy se pro hodnocení vibrací používají i další veličiny, které zohledňují různé aspekty kmitání [1]

Efektivní hodnota (RMS): 0,707násobek amplitudy. Reprezentuje skutečnou efektivní hodnotu a energetickou úroveň vibrací.

$$x_{ef} = 0,707 \cdot x_a \quad (7)$$

Střední hodnota (Average): 0,637násobek amplitudy. Ukazuje průměrnou výchylku kmitání v čase.

$$x_{stř} = 0,637 \cdot x_a \quad (8)$$

Rozkmit (Peak-to-peak): Dvojnásobek amplitudy. Udává maximální rozsah výchylky kmitání.

$$x_{šp-šp} = 2 \cdot x_a \quad (9)$$

DKW: umožňuje kvalitativní diagnostiku celkového stavu valivého kontaktu ložiska. Jedná se o naměřené efektivní hodnoty a špičkové hodnoty zrychlení vibrací při počátečním stavu ložiska, které se porovnávají s aktuálním stavem, aby se vypočítalo DKW. Diagnostická charakteristická hodnota DKW vykazuje vysokou korelaci stavem poškození valivých ložisek, a proto má velký význam. [7]

Diagnostická charakteristická hodnota (DKW) se vypočítá podle následujícího vzorce:

$$DKW(t) = \frac{a_{max}(t) \cdot a_{eff}(t)}{a_{max}(0) \cdot a_{eff}(0)} \quad (10)$$

DKW	Bearing state
< 1	Improvement of the technical state (e.g. after start-up phase)
> 1 to 2	Good running characteristic
> 2 to 5	Effect of damage-accelerating influencing factors
> 5 to 50	Effect of the damaging process
> 50	Formation of a damage with the risk of a failure

Obrázek 5: Vyhodnocení ukazatele DKW, převzato z [7]


3.2 Snímače

Pro měření veličiny popisující kmitavý pohyb lze naměřit kteroukoliv ze tří veličin: výchylku, rychlost nebo zrychlení. Tyto veličiny jsou navzájem vázány matematickými vztahy a získání jedné můžeme dopočítat ostatní dvě. Výchylka se většinou udává v milimetrech a znamená změnu polohy. Její první derivací podle času získáme rychlost (rychlost změny výchylky) s jednotkou mm/s . Druhou derivací výchylky podle času, nebo první derivací rychlosti získáváme zrychlení neboli změnu rychlosti v čase. Obvykle se ve vibrodiagnostice používá jednotka mm/s^2 nebo g . [1,5,6] Rychlost se vždy o 90° opoždí za výchylkou a zrychlení o dalších 90° za rychlostí. [1]

$$x(t) = X \cdot \sin(\omega t) \quad (11)$$

$$v(t) = \frac{dx}{dt} = X \cdot \omega \cdot \cos(\omega t) \quad (12)$$

$$a(t) = \frac{dv}{dt} = X \cdot \omega^2 \cdot \sin(\omega t) \quad (13)$$




Obrázek 6: Vztah mezi výchylkou, rychlostí a zrychlením, převzato z [1]

Teoreticky by nám mělo stačit změřit pouze jednu veličinu a pomocí ní si dopočítat ostatní. To však nemusí být vždy výhodné. Na rozdíl od modelových situací se

v praxi setkáváme s vnějšími nepříznivými vlivy, které do měření vnáší šum a zhoršují jeho přesnost. Proto je důležité volit měřenou veličinu tak, aby měla co největší poměr signálu k šumu. Šumu se tím ale nezbavíme, ten bude přítomen vždy, ale můžeme ho volbou vhodného senzoru zmenšit. [1,5,6]

Na obrázku můžeme vidět, že pro běžná měření je nejlepší volbou použít senzor pro měření rychlosti a to z důvodu, že pokrývá typický rozsah pracovních otáček, s kterými se můžeme běžně setkat. S narůstající frekvencí by bylo vhodné zvážit, jestli nezačít měřit veličinu zrychlení, jako například při měření zubových frekvencí. [1,5,6]



Obrázek 7: Omezení při měření, převzato z [1]

Snímače tedy můžeme rozdělit podle měřené veličiny na:

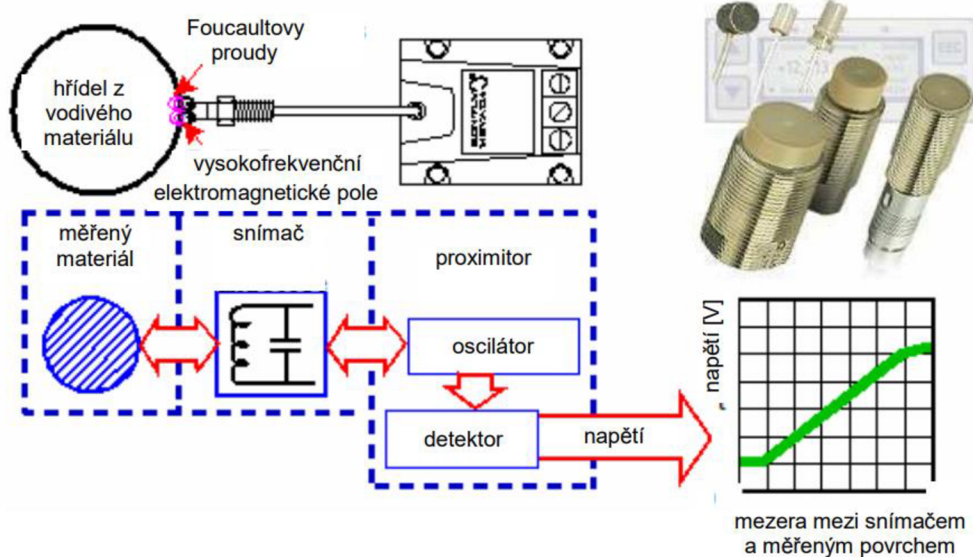
- Snímače výchylky
- Snímače rychlosti (velometry)
- Snímače zrychlení (akcelerometry)

Použitelný frekvenční a dynamický rozsah se u jednotlivých typů snímačů liší. Volba správného snímače se odvíjí od aplikace, stejně tak i od frekvenčního rozsahu, který můžeme na diagnostikovaném zařízení očekávat. Nyní si uvedeme něco málo ke každému typu snímačů a popíšeme jejich konstrukci.

3.2.1 Snímače výchylky

Existuje několik typů snímačů pro měření výchylky, vzdálenosti nebo polohy, přičemž nejstarším typem je kontaktní mechanické klouzátko, avšak v současnosti je častěji používaným bezkontaktní snímač na bázi vířivých proudů. Dalšími typy jsou laserové, ultrazvukové, kapacitní a indukční snímače. Snímače výchylky jsou používány převážně pro měření vibrací hřídelů, sledují relativní vibrace hřídele vůči statorové části,


typicky vůči ložisku. Snímač výchylky na bázi vířivých proudů funguje měřením vzdálenosti mezi špičkou snímače a vodivým povrchem. Systém se skládá ze samotného snímače a proximatoru, který generuje vysokofrekvenční střídavý proud, indukující vířivé proudy ve vodivém materiálu cílové plochy, což se projevuje na změně impedance cívky. Signál je modulován na tuto vlnu a následně demodulován, přičemž vysoká frekvence elektromagnetického pole zvyšuje závislost měření na celkovém odporu. Každé poškození kabelů ohrožuje kvalitu měření, přičemž po ovlivnění nosné vlny a vířivých proudů proměnnou vzdáleností cílové plochy při vibracích je signál přiveden do demodulátoru a vyhodnocovací jednotky. Tyto senzory mají poměrně malý rozsah vzdálenosti, ve které je výstupní signál lineární (typicky v rozsahu 0,25 až 2,3 mm)



Obrázek 8: Schéma systému se snímačem výchylky, převzato z [1]

3.2.2 Snímače rychlosti

Snímače rychlosti se využívají pro měření vibrací u rotačních strojů již dlouhou dobu a často se používají dodnes. Principem jejich funkce je elektromagnetická indukce, kde pohybující se cívka v magnetickém poli generuje napětí na vývodech. Velikost tohoto napětí je přímo úměrná relativní rychlosti mezi cívkou a magnetickým polem, která odpovídá rychlosti vibrací měřeného stroje. Samotný snímač se skládá z permanentního magnetu a cívky uložené na pružinách, která zůstává v klidu díky své setrvačnosti, zatímco magnet kmitá s pouzdem. Frekvenční rozsah snímače je omezen mechanickými parametry jeho součástí, obvykle je použitelný v rozmezí 10 až 1000 Hz. Montáž snímače vyžaduje ohled na citlivou osu a ochranu před bočními vibracemi. I přes svou citlivost a relativní levnost jsou tyto snímače náchylné na otřesy a vhodné jsou spíše pro trvalé montáže na stroji. V moderní době se objevují laserové snímače, ale jejich vysoká cena často omezuje jejich použití v praxi.




Obrázek 9: Snímač rychlosti, převzato z [1]

3.2.3 Snímače zrychlení

Snímače zrychlení neboli akcelerometry jsou v současné době nejčastěji používanými snímači a to hlavně pro nepohyblivé části diagnostikovaných strojů z důvodu, že oproti výše zmíněným snímačům nemají tolik nevýhod.

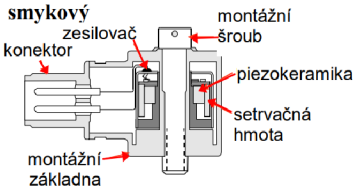
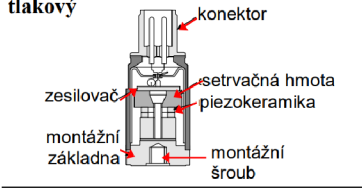
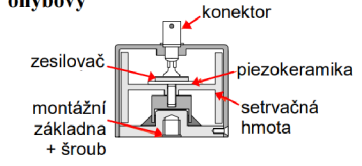
Akcelerometr pracuje na základě deformace destičky z materiálu s piezoelektrickými vlastnostmi, což vyvolává vznik elektrického náboje přímo úměrného této deformaci. Destička je situována mezi dvěma hmotami, přičemž jedna z nich slouží jako referenční setrvačná hmota a druhá je spojena s pouzdem snímače, které je zase pevně propojeno se skříní měřeného stroje. Tato sestava je pružně uložena, což zajišťuje vysoký poměr tuhosti a hmotnosti a vysokou rezonanční frekvenci snímače. Při kmitání měřeného stroje se také pohybuje hmota spojená s pouzdem snímače, což vyvolává deformaci piezoelektrického prvku a vytváří elektrický náboj, který je přímo úměrný zrychlení stroje. Díky tomu akcelerometr dokáže měřit absolutní vibrace, zatímco snímače výchylky zachycují relativní vibrace rotoru vzhledem k ostatním částem stroje.



Obrázek 10: Snímač zrychlení (tlakový typ), převzato z [1]

Konstrukce akcelerometru umožňuje jeho montáž na skříní stroje bez ohledu na orientaci, díky tuhému systému hmoty a pružiny, který nezávisí na postavení snímače,

což je výhodou oproti snímačům rychlosti. Nicméně je klíčové, aby piezoelektrický prvek nebyl vystaven jinému typu namáhání než vibracím. Proto je důležité, aby místo pro upevnění snímače bylo hladké a rovné, aby nedocházelo k deformaci jeho základny při montáži. Teplotní změny a nadměrný utahovací moment při upevňování šroubem mohou vést k nežádoucím deformacím základny a tím i k falešným signálům. Tlakový typ akcelerometru je nejvíce citlivý na tato parazitní namáhání. Existují tři hlavní typy akcelerometrů - tlakový, ohybový a smykový, s různými výhodami a nevýhodami, které jsou uvedeny v tabulce. Smykový typ, jako například delta-shear, je nejběžnějším a nejčastěji používaným typem akcelerometru pro měření absolutních vibrací, jelikož je dostatečně citlivý, odolný a nevykazuje nedostatky tlakového typu.

Typ akcelerometru	výhody	nevýhody
<p>smykový</p> 	<p>široký frekvenční rozsah relativně odolný nízký teplotní vliv</p>	<p>menší citlivost</p>
<p>tlakový</p> 	<p>široký frekvenční rozsah odolný na rázy</p>	<p>náchylný na teplotní vlivy náchylný na deformaci základny</p>
<p>ohybový</p> 	<p>měří velmi nízké frekvence má velmi vysokou citlivost</p>	<p>křehký, citlivý na rázy</p>

Obrázek 11: Typy akcelerometrů, převzato z [1]

4 ON-LINE SYSTÉMY


V dnešní době je průmysl jedním z nejrychleji se rozvíjejících odvětví. S nástupem moderních technologií a konceptu Průmyslu 4.0 se klade důraz na digitalizaci a automatizaci výrobních procesů. Průmysl 4.0 představuje revoluci v průmyslové výrobě, kde se propojují fyzické a digitální světy, což umožňuje vznik inteligentních továren a celých výrobních řetězců.

Součástí Průmyslu 4.0 je také technická diagnostika, která hraje klíčovou roli v udržování a optimalizaci provozu zařízení. Jedním z hlavních trendů v diagnostice je vývoj a nasazení on-line diagnostických systémů, které umožňují neustálé monitorování stavu zařízení za provozu. To znamená, že lze identifikovat potenciální problémy až před jejich vznikem a minimalizovat tak neplánované výrobní výpadky. Existuje několik firem, které se specializují na vývoj a implementaci on-line diagnostických systémů. Tyto systémy umožňují nejen průběžné monitorování stavu zařízení, ale také automatickou

analýzu naměřených dat a včasnou detekci anomálií. Díky nim jsou podniky schopny lépe plánovat údržbu, minimalizovat náklady spojené s neplánovanými opravami a maximalizovat výkonnost svých zařízení. [5]

Diagnostické systémy se tradičně dělí na dvě hlavní kategorie: offline a online diagnostika. Zatímco offline diagnostika se provádí mimo provozní dobu zařízení, online diagnostika umožňuje monitorování zařízení v reálném čase během jeho provozu. To poskytuje daleko komplexnější a aktuálnější informace o stavu zařízení.

V poslední době se začíná více využívat umělá inteligence pro analýzu dat z on-line diagnostických systémů. Tato technologie umožňuje identifikovat vzory a trendy v datech, což může vést k předpovězení možných závad a potenciálně i prevenci poruch před jejich vznikem. S rozvojem technologií a novými možnostmi v oblasti technické diagnostiky se očekává další růst využití on-line systémů a implementace umělé inteligence pro přesnější a efektivnější monitorování a údržbu průmyslových zařízení. [7]



Obrázek 12: Průběh trendu naměřených dat v závislosti na potřebě opravy, převzato z [7]

4.1 ABB Ability Smart Sensor TM

ABB Ability™ Condition Monitoring pro hnací ústrojí je řešení, které shromažďuje data z pohonů, motorů, čerpadel a dalších aplikací. Kombinuje konektivitu a analýzu dat a umožňuje hodnocení založené na odborných znalostech, která mohou zlepšit výkon, spolehlivost a efektivitu každé součásti hnacího ústrojí i hnacího ústrojí jako celku.

ABB Ability™ Smart Sensor, klíčový prvek digitálního pohonného ústrojí, převádí tradiční motory, čerpadla a obecné stroje na chytrá, bezdrátově připojená zařízení. Měří klíčové parametry z povrchu zařízení, které lze použít k získání smysluplných informací o jeho stavu a výkonu, což uživatelům umožňuje identifikovat neefektivitu jejich systému a snížit rizika související s provozem a údržbou. Údržbu lze plánovat spíše podle skutečných potřeb než na základě obecných plánů. To prodlužuje životnost zařízení, snižuje náklady na údržbu a snižuje nebo zabraňuje neplánovaným prostojům. [9]



Obrázek 13: ABB Ability™ Smart Sensor, převzato z [9]

4.2 Adash A3800

A3800 je kompaktní online monitorovací a diagnostický systém navržený pro zvýšení spolehlivosti stroje. Jeho kompaktní velikost umožňuje přímé umístění na DIN lištu v rozváděči. Jednotka je vybavena volitelnými AC a DC vstupními kanály, v rozsahu od 4 do 16 kanálů, s oddělenými AC a DC kanály. Každá skupina 4 kanálů umožňuje plně simultánní měření, přepínání mezi skupinami pomocí multiplexování. Navíc může A3800 fungovat jako výkonný vícekanálový analyzátor s konfigurací a ovládním spravovaným pomocí softwaru DDS. [10]

Mezi další zařízení patří A3716, A3800 a A3900 II.



Obrázek 14: Adash A3800, převzato z [10]

4.3 Skf @ptitude Analyst

Je komplexní softwarové řešení s výkonnými diagnostickými a analytickými schopnostmi. SKF @ptitude Analyst poskytuje rychlé, efektivní a spolehlivé ukládání, analýzu a vyhledávání komplexních informací o majetku. Je škálovatelný podle vašich


specifických potřeb, ať už se jedná o inspekce operátora, on-line a periodický sběr dat z monitorování stavu nebo hloubkovou analýzu vibrací a odborné poradenství. [11]



Obrázek 15: Skf @ptitude Analyst, převzato z [11]

4.4 PRUFTECHNIK VibGuard

VIBGUARD IIoT se může pochlubit 12, 16 nebo 20 analogovými kanály, které optimalizují monitorování vibrací a zpracování signálu. Analyzuje časové signály, charakteristické hodnoty, FFT spektra, dráhy kinetických vln a točivý moment pro komplexní přehled o stavu stroje. Díky pokročilým nástrojům pro zpracování alarmů a softwaru OMNITREND Asset View umožňuje prediktivní strategie údržby. Jeho flexibilní možnosti instalace, včetně kompatibility na DIN lištu, zajišťují bezproblémovou integraci do průmyslových zařízení. [11]



Obrázek 16: VIBGUARD IIoT , převzato z [11]

4.5 Siemens SIPLUS CMS



Obrázek 17: Modul SIEMENS SIPLUS CMS, převzato z [12]

Siemens Simplus CMS (Condition Monitoring System) je komplexní řešení navržené pro nepřetržité monitorování točivých strojů v průmyslovém prostředí. Využívá se k detekci časných příznaků poruch strojů, umožňuje prediktivní strategie údržby, aby se zabránilo neplánovaným prostojům a optimalizoval výkon zařízení. [8]

Simplex CMS integruje různé monitorovací technologie, jako je analýza vibrací, monitorování teploty a analýza oleje, aby poskytoval holistický pohled na stav stroje. Nepřetržitým shromažďováním a analýzou dat ze senzorů instalovaných na zařízení, jako jsou motory, čerpadla a turbíny, může Simplex CMS identifikovat abnormality v chování stroje, které mohou naznačovat potenciální problémy. [8]

System nabízí pokročilé analytické funkce, včetně analýzy trendů, diagnostiky chyb a algoritmů strojového učení, které umožňují interpretovat shromážděná data a generovat užitečné poznatky. Mezi jeho hlavní funkce a vlastnosti patří [8, 12]:

Vlastnosti systému:

- Palubní software pro analýzu založenou na parametrech a frekvenčně selektivní analýzu
- Snadná archivace dat ve vlastní paměti systému (800 MB)
- Možnosti připojení: 4 IEPE snímače zrychlení vibrací na SM 1281, 1 rotační snímač rychlosti, až sedm modulů SM 1281 na CPU S7-1200

Funkcionalita systému CMS

- Analýza dat založená na parametrech nebo frekvenčně selektivní
- Analytické algoritmy v modulu monitorování stavu SM 1281
- Analýza trendů
- Limitní sledování frekvenčních pásem
- Ukládání hrubých dat v různých kategoriích využití, aktivní přenos do PC pro analýzu dat

- Online streamování dat o vibracích do analytického softwaru CMS X-Tools

Z toho plynou výhody a možnosti:

- Včasné odhalení mechanického poškození
- Plánovaná údržba místo spontánní opravy
- Pro diagnostiku a vizualizaci není potřeba žádný další software
- Snadná archivace dat
- Analyzuje do nejmenších detailů, např. pro detekci opotřebení zubů v převodovce
- Monitorování pohonů s proměnnými otáčkami

5 MOŽNOSTI ZPRACOVÁNÍ DATOVÝCH SOUBORŮ

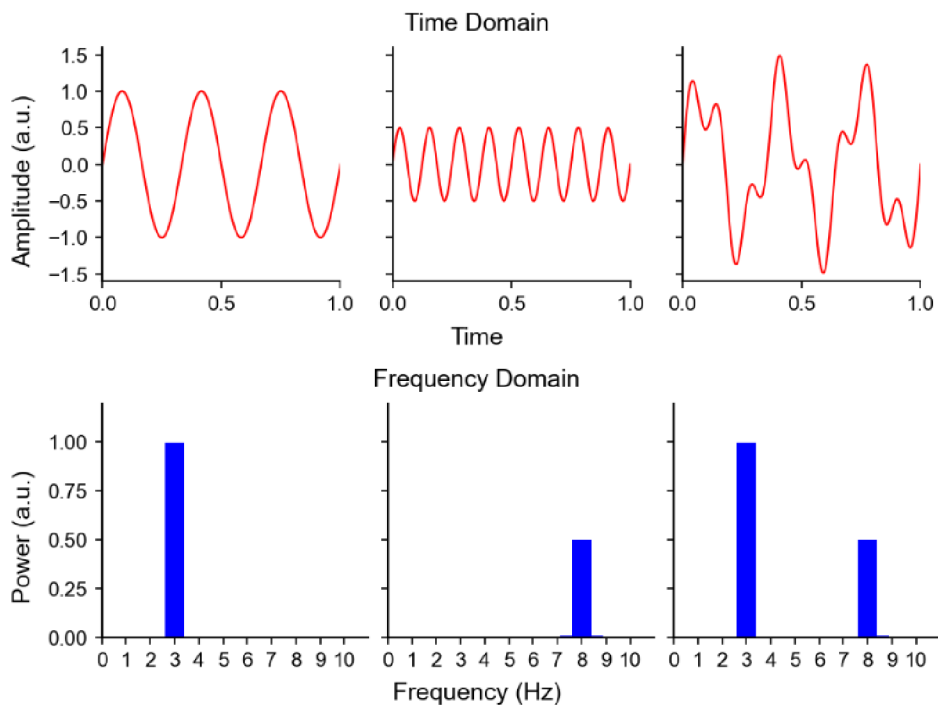
5.1 Fourierova transformace

Z běžného vibrodiagnostického signálu v časové doméně je i pro zkušeného vibrodiagnostika většinou nemožné vznést nějaká tvrzení o signálu, protože v signálu se kromě informací o kmitání nachází mnoho vnějších veličin jako vnější šum, rozlišitelnost čidla, elektrický šum ze sítě atd. Proto se v technické praxi používají různé transformace, které pomáhají ze signálu vyextrahovat dodatečné informace, které v časové oblasti jdou pouze těžce rozeznat. Jednou z těchto transformací je Fourierova transformace. [1, 6]

Fourierovou transformací rozložíme původní časový signál do posloupnosti harmonických funkcí s rozdílnými frekvencemi tak, aby součet těchto funkcí co nejlépe aproximoval původní signál. Výsledkem Fourierovy transformace je tedy kmitočtové neboli frekvenční spektrum, které reprezentuje periodické jevy v časovém průběhu. Tato transformace nám umožňuje tedy v signálu vidět jednotlivé frekvenční komponenty, z kterých si pak vibrodiagnostik může vyvodit a porovnat, jestli se neshodují například s ložiskovými frekvencemi. [1, 6]

Jako nejčastější variantou fourierovy transformace bývá implementována rychlá Fourierova transformace FFT. Použití algoritmu FFT často znamená, že jsme omezeni pouze na hodnoty N , které jsou mocninou čísla 2, jako jsou 256, 512, a tak dále. Toto omezení není obecně platné pro diskretní Fourierovu transformaci, avšak je to nezbytná podmínka pro rychlost algoritmu FFT, která má zásadní význam při frekvenční analýze. Počet hodnot ve frekvenčním spektru je poloviční ve srovnání s počtem hodnot v časovém signálu, přičemž f_{max} je rovna polovině vzorkovací frekvence $f_{vz} = \frac{1}{\Delta t}$. Toto je spojeno s Shannonovým vzorkovacím teorémem, který stanoví, že vzorkovací frekvence musí být alespoň dvojnásobně vyšší než frekvence nejvyšší harmonické složky v měřeném signálu. [6]

V reálném měření může signál ze senzoru obsahovat různé rušivé složky, některé s náhodným charakterem a jiné jako harmonické složky vyšších frekvencí, než je maximální frekvence kmitočtových složek stanovená Shannonovým vzorkovacím teorémem. Náhodný rušivý signál obvykle nemá významný vliv na výsledky kmitočtové analýzy. Avšak, v případě, kdy je vzorkovací frekvence nižší, než je žádoucí vzhledem k nejvyšší frekvenci měřeného signálu, se může ve frekvenčním spektru objevit "nepravé" výrazné maximum, známé jako "špička". Obecně platí, že každá složka s frekvencí $f_s > f_{max}$ vytvoří maximum ve frekvenčním spektru FFT u frekvence, která je obvykle více než dvojnásobkem f_{max} . [6]



Obrázek 18: Ukázka převodu mezi časovou a frekvenční oblastí, převzato z [13]

5.1.1 Diskrétní Fourierova transformace

Nyní si blíže ukážeme a matematicky nastíníme průběh diskrétní fourierovy transformace. Tato transformace bude použita, protože měřený signál je vzorkován, a tudíž je diskrétní.


„Signál $x(t)$ je získáván prostřednictvím měření, a vzhledem k neexistenci matematického popisu tohoto signálu je nutné využít numerické metody. Při digitálním zpracování signálu pomocí analogově-číslicového převodníku se provádí vzorkování signálu v časové doméně, což zahrnuje snímání signálu v pravidelných intervalech T_{vz} s frekvencí vzorkování f_{vz} . Vzhledem k omezenému množství N naměřených vzorků, které jsou obvyklé v praxi, je nezbytné použít diskrétní Fourierovu transformaci (DFT). Hlavní myšlenka DFT spočívá v rozkladu měřeného signálu $x(t)$ do sady periodických funkcí s periodou T v časovém rozmezí $(-T/2, T/2)$. Signál $x(t)$ lze následně vyjádřit pomocí Fourierovy řady dle vztahů níže.“ [6]

Kde $F(f_k)$ je diskrétní Fourierova transformace (DFT) [6]:

$$F(f_k) = \sum_{n=0}^{N-1} x(t_n) e^{-\frac{j2kn}{N}} \quad \text{pro } k = 0, 1, \dots, N-1 \quad (14)$$

A $x(t_n)$ je zpětnou DFT [6]:

$$x(t_n) = \frac{1}{N} \sum_{k=0}^{N-1} F(f_k) e^{\frac{j2kn}{N}} \quad (15)$$




Obrázek 19: Spektra DFT pro měření s dobrým a špatným ložiskem

Na obrázku 19 ve SPEKTRU 1 můžeme vidět typický průběh zdravého kuličkového ložiska, případně s malým naznačením začínajícího poškození projevujícím se zvýšenými hodnotami ve spektru ve velmi nízkých frekvencích. Ve SPEKTRU 2 naopak vidíme typický průběh pozdního stádia opotřebení kuličkového ložiska, kdy se můžeme vidět velmi vysoké špičkové hodnoty v nízkých frekvencích, které jsou od sebe poměrně rovnoměrně rozestoupeny, pravděpodobně o násobky otáčivé frekvence. Dále můžeme pozorovat velmi výrazný vysokofrekvenční šum ve velmi vysokých frekvencích hlavně okolo 20 kHz . [6]

Vyhodnocení a vznesení diagnózy pomocí analýzy hodnot spekter je velmi oblíbená a častá diagnostická metoda v technické praxi.

5.2 Hilbertova transformace




Obrázek 20: Hilbertova obálka spektra

Analytický signál – uměle vytvořený komplexní signál, z výchozího reálného signálu. Je to komplexní funkce se spojitým časem. Imaginární část komplexního signálu je definována tak, aby umožnila snadno analyzovat modulační efekty. K vytvoření imaginární části analytického signálu je využita Hilbertova transformace. Hilbertova

transformace je původně definována v časové oblasti. Pro její praktický výpočet se však využívá její výpočet pomocí FT. Hilbertovu transformaci využíváme ve vibrodiagnostice pro vyhodnocování obálek amplitudově modulovaných signálů v časové oblasti. Obálku je možné přibližně měřit analogovými obvody, ale je-li k dispozici měřicí technika umožňující digitální spektrální analýzu, nabízí Hilbertova transformace přesný algoritmus pro analýzy obálek. U amplitudově modulovaných signálů je spektrum soustředěno kolem středního kmitočtu. [6]

5.3 Metoda činitele výkmitu Crest factor

Činitele výkmitu K_v je poměr špičkového napětí ku efektivní hodnotě zrychlení. Tento poměr se nejčastěji vyhodnocuje v časové posloupnosti ve frekvenčním pásmu 1 Hz až 10 kHz. [6]



Obrázek 21: Časový průběh crest factoru, převzato z [6]

Křivka na obrázku prezentuje typický trend činitele výkmitu v závislosti na míře poškození ložiska. Na začátku se poměr hodnoty výkmitu k efektivní hodnotě je relativně stálý. S postupujícím vývojem poruchy však krátkodobé rázy začnou ovlivňovat růst výkmitové úrovně, přičemž jejich dopad na efektivní hodnotu zůstává relativně malý. Dále se hodnota výkmitu zrychlení zvětšuje až do určité hranice. Postupně se poškození ložiska prohlubuje, což vede k vytváření rázů při každém průchodu ložiskového elementu. Tyto rázy postupně ovlivňují úroveň efektivní hodnoty, avšak jejich vliv na velikost výkmitu postupně klesá. Na konci životnosti ložiska může činitel výkmitu klesnout na svou původní hodnotu, i přesto, že obě hodnoty významně vzrostly. [6]

$$K_v = \frac{a_v}{a_{ef}} = \frac{Peak}{RMS} \quad (16)$$

Efektivní a výkmitová hodnota zrychlení jsou zaznamenány ve stejném grafu, kde je činitel výkmitu stanoven jako podíl těchto dvou křivek. Metoda přináší několik výhod, včetně jednoduchosti a nízkých nákladů. Avšak, je náchylná k ovlivnění z jiných zdrojů zrychlení a poskytuje pouze hrubou orientaci o stavu ložiska, což je nutné brát v úvahu při interpretaci výsledků. [6]

6 NEURONOVÉ SÍTĚ

6.1 Obecný popis a použití

Každá neuronová síť je složena z formálních neuronů, které jsou vzájemně propojeny tak, že výstup jednoho neuronu je vstupem do (obecně i více) neuronů. Obdobně jsou terminály axonu biologického neuronu přes synaptické vazby spojeny s dendrity jiných neuronů. Počet neuronů a jejich vzájemné propojení v síti určuje architekturu (topologii) neuronové sítě. Z hlediska využití rozlišujeme v síti vstupní, pracovní (skryté, mezilehlé, vnitřní) a výstupní neurony. Šíření a zpracování informace v síti je umožněno změnou stavů neuronů ležících na cestě mezi vstupními a výstupními neurony. Stavů všech neuronů v síti určují stav neuronové sítě a synaptické váhy všech spojů představují konfiguraci neuronové sítě. Neuronová síť se v čase vyvíjí, mění se stav neuronů, adaptují se váhy. V souvislosti se změnou těchto charakteristik v čase je účelné rozdělit celkovou dynamiku neuronové sítě do tří dynamik a uvažovat pak tři režimy práce sítě: organizační (změna topologie), aktivní (změna stavu) a adaptivní (změna konfigurace). Uvedené dynamiky neuronové sítě jsou obvykle zadány počátečním stavem a matematickou rovnicí, resp. pravidlem, které určuje vývoj příslušné charakteristiky sítě (topologie, stav, konfigurace) v čase. Změny, které se řídí těmito zákonitostmi probíhají v odpovídajících režimech práce neuronové sítě. Konkretizací jednotlivých dynamik pak obdržíme různé modely neuronových sítí vhodné pro řešení různých tříd úloh. [16, 20]


6.2 Formální neuron

Základem matematického modelu neuronové sítě je formální neuron. Jeho struktura je schematicky zobrazena na obrázku. Formální neuron Y (dále jen neuron) má obecně n reálných vstupů, které modelují dendrity a určují vstupní vektor $x = (x_1, \dots, x_n)$. Tyto vstupy jsou ohodnoceny reálnými synaptickými váhami tvořícími vektor $w = (w_1, \dots, w_n)$. Ve shodě s neurofyzilogickou motivací mohou být synaptické váhy i záporné, čímž se vyjadřuje jejich inhibiční charakter. [16]

$$y = b + \sum_{i=1}^n w_i x_i \quad (17)$$

6.3 Perceptron

Je nejjednodušším modelem dopředné neuronové sítě s učením s učitelem. Sestává pouze z jednoho neuronu. Perceptron byl modelován v roce 1957 Frankem Rosenblattem. Přes úvodní nadšení bylo později zjištěno, že jeho užití je velmi omezené, neboť je možné jej použít pouze ke klasifikaci lineárně separovatelných kategorií. [16]



Obrázek 22: Perceptron, převzato z [14]

6.4 Klasifikace vzorů


Rozpoznávání vzorů (Pattern Recognition) je jednou z nejdůležitějších aplikací teorie neuronových sítí. Obecně tento proces probíhá ve dvou krocích: nejprve je nutné určit charakteristický rys objektů a potom podle něj objekty klasifikovat. Máme-li n navzájem různých vstupů, můžeme použít jim odpovídajících n různých symbolů a vytvořit z nich množinu, kterou nazýváme charakteristický vektor (feature vector). Tento n - rozměrný vektor charakterizuje n - rozměrný charakteristický prostor (feature space). Podstatou správného rozpoznávání je určení vhodného tvaru tzv. rozlišovací funkce (discriminant function). Rozlišovací funkce je matematicky popsána rovnicí nadroviny. Určení takovéto hranice nebývá většinou v praxi tak jednoduché. Existuje mnoho způsobů, jak stanovit její tvar rozlišovací funkce, např. metodou klasifikace s užitím nejbližších sousedů (nearest neighbour classification), lineární klasifikací (linear classifiers), statistickými technikami (Bayesian classification) apod. Lineární metody klasifikace jsou nejbližší aplikacím teorie umělých neuronových sítí. Jedním ze způsobů, jež umožňuje nalézt rovnici oddělující hadroviny je algoritmus adaptace perceptronu. [16, 20]

6.5 Aktivační funkce

Aktivační funkce v neuronových sítích je matematická operace, která definuje výstupní signál neuronu na základě vážené sumy jeho vstupů. Tato funkce určuje, zda a v jaké míře má neuron reagovat na daný vstup. Její použití je důležité z důvodu přidání nelinearity do modelu. Bez nelinearity by totiž celá neuronová síť s lineárními vrstvami byla ekvivalentní jedné lineární vrstvě, což by omezilo schopnost modelu aproximovat složité a nelineární vzory v datech. To umožňuje modelovat složité vzory. Mezi nejpoužívanější aktivační funkce řadíme:

Step funkce


Jednoduchá aktivační funkce, která vydává hodnotu 1, pokud je vstupní signál vyšší než určitý práh, a 0 v opačném případě. [21]



Obrázek 23: Step funkce, převzato z [17]

Sigmoidní funkce


Transformuje vstup na hodnoty v rozmezí 0 až 1. Větší výpočetní náročnost ve velkých modelech a hlubokých sítích. [21]



Obrázek 24: Sigmoid funkce, , převzato z [17]

ReLU (Rectified Linear Unit)


Velmi populární aktivační funkce, pro záporný vstup vrací nulu (nelineární chování) a pro kladný vstup vrací výstup (linearita). Je výpočetně efektivní, kombinuje v sobě linearitu i nelinearitu, urychluje učení a řeší problém mizejícího gradientu. [21]



Obrázek 25: ReLu funkce, převzato z [17]

Softmax funkce


Často používaná v poslední vrstvě sítí pro klasifikaci. Transformuje vstup do pravděpodobnostního rozdělení pro více tříd. [21]



Obrázek 26: Softmax funkce, převzato z [17]

6.6 Hluboké neuronové sítě

Hluboká neuronová síť se od jednodušších modelů odlišuje tím, že je poskládána z více vrstev, jako v lidském mozku. Většinou obsahuje jednu vstupní a jednu výstupní vrstvu a několik skrytých vrstev. To umožňuje extrahovat a abstrahovat hierarchie příznaků z dat, což umožňuje modelu automaticky identifikovat a reprezentovat stále složitější vzorce informací obsažených ve vstupních datech. Tyto sítě jsou schopny se učit a adaptovat na různorodé úlohy, od rozpoznávání obrazu a řeči po překlad přirozeného jazyka. [16,18, 20]

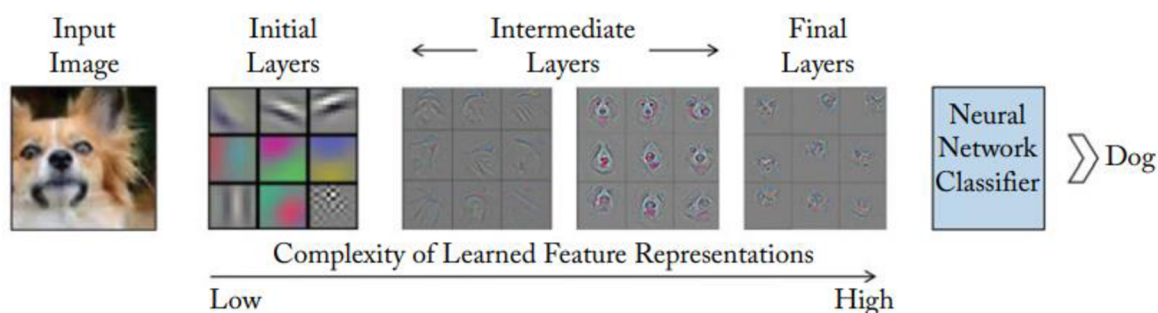


Obrázek 27: Hluboká neuronová síť se třemi skrytými vrstvami o 9 plně propojených neuronech, převzato z [16]

6.7 Konvoluční neuronové sítě

CNN jsou jednou z nejoblíbenějších kategorií neuronových sítí, zejména pro vysoko rozměrná data (např. obrázky a videa), lze je však použít i pro jednorozměrná data (lidská řeč, jednokanálový vibrační signál). CNN pracují způsobem, který je velmi podobný standardním neuronovým sítím. Klíčový rozdíl však spočívá v tom, že každá jednotka ve vrstvě CNN je dvourozměrný (nebo vysoko rozměrný) filtr, který je konvolován se vstupem dané vrstvy. To je zásadní pro případy, kdy se chceme učit vzory z vysokodimenzionálních vstupních médií, např. obrázků nebo videí. Filtry CNN zahrnují prostorový kontext tím, že mají podobný (ale menší) prostorový tvar jako vstupní médium, a využívají sdílení parametrů, čímž výrazně snižují počet učitelných proměnných. [18, 19]

Tyto koncepty si přiblížíme v následujících podkapitolách.



Obrázek 28: CNN se v počátečních vrstvách učí příznaky (features) nízké úrovně, po nichž následují složitější reprezentace příznaky střední a vyšší úrovně, které se používají pro klasifikaci.

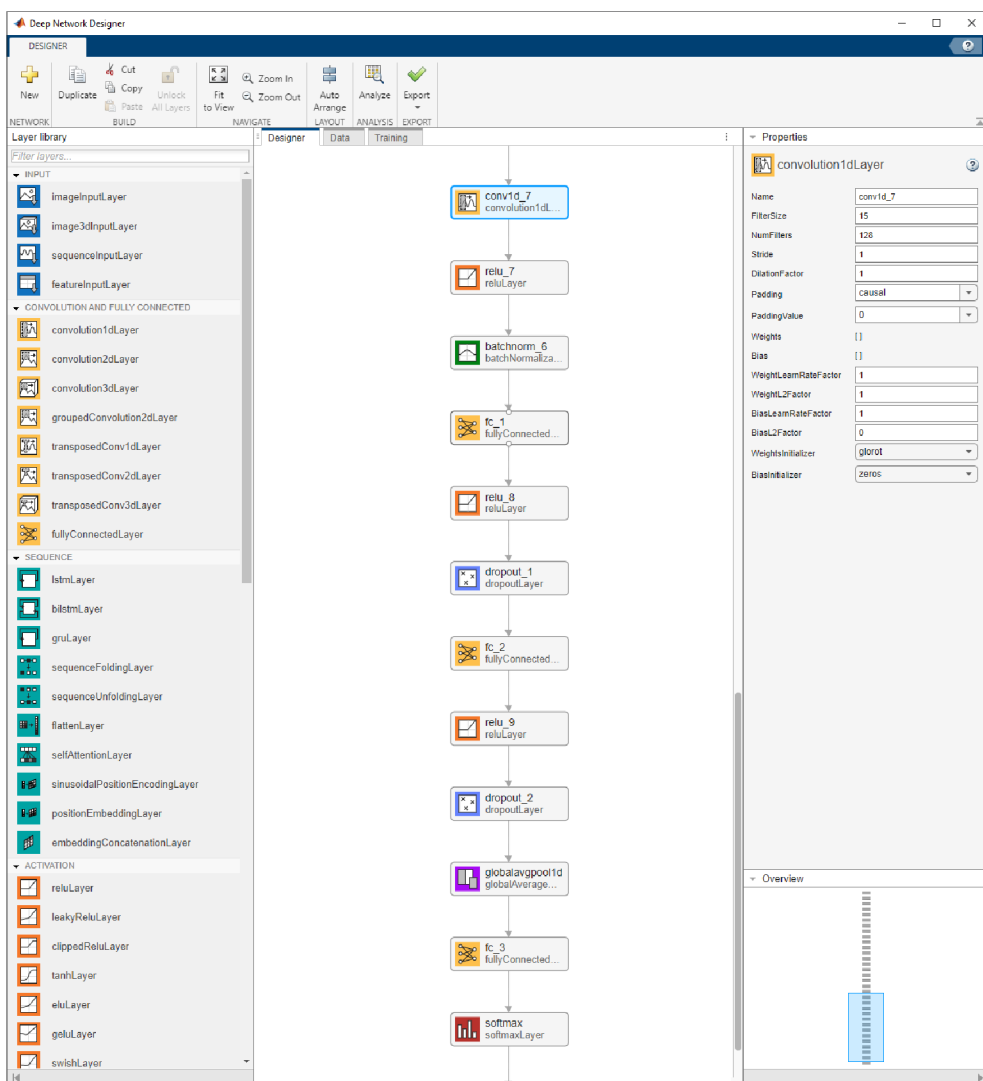
Nejranější formou CNN byl model Neocognitron, který navrhl Kunihiko Fukushima (Fukushima a Miyake, 1982). Skládal se z několika vrstev, které se automaticky učily hierarchii abstrakcí příznaků pro rozpoznávání vzorů. Neocognitron byl motivován zásadní prací Hubela a Wieselova (rok 1959) o primární zrakové kůře, která prokázala, že neurony v mozku jsou uspořádány ve formě vrstev. Tyto vrstvy se učí rozpoznávat vizuální vzory tak, že nejprve extrahují lokální rysy a následně je kombinují, aby získaly reprezentace vyšší úrovně. Trénování sítě probíhalo pomocí pravidla posilovacího učení (reinforced learning). Významným vylepšením oproti Neocognitronu byl model LeNet navržený LeCunem (1989), kde se parametry modelu učily pomocí zpětného šíření chyb (backpropagation). Tento model CNN byl úspěšně použit k rozpoznávání ručně psaných číslic. [22]

CNN jsou užitečnou třídou modelů pro paradigmatu učení s učitelem (supervised learning) i bez učitele (unsupervised learning). Mechanismus učení s učitelem je takový, když jsou známy vstupy do systému a požadované výstupy tak se model učí mapování mezi nimi. V mechanismu učení bez učitele nejsou požadované výstupy pro danou sadu vstupů známy a cílem modelu je odhadnout základní rozdělení vzorků vstupních dat.

Klasifikátor neuronové sítě je totožný s MLP (vícevrstvý perceptron), který byl popsán v kapitole výše. [18, 19]

6.8 Vrstvy CNN

CNN se skládá z několika základních stavebních bloků, které se nazývají vrstvy CNN. V této části se budeme zabývat těmito stavebními bloky a jejich funkcí v architektuře CNN. Všimněte si, že některé z těchto vrstev implementují základní funkce, jako je normalizace, pooling, konvoluce a plně propojené vrstvy. Těmito základními vrstvami se v této části zabýváme nejdříve, abychom si vytvořili základní představu o vrstvách CNN. [21, 22]



Obrázek 29: Ukázka vývojového prostředí Matlab - Deep Network Designer

6.8.1 Konvoluční vrstva

Konvoluční vrstva je nejdůležitější součástí konvoluční neuronové sítě. Skládá se ze sady filtrů nazývaných také konvoluční jádra nebo kernel, které se konvolují s daným vstupem a vytvářejí výstupní matici hodnot. [22]

Konvoluční jádro (Kernel)

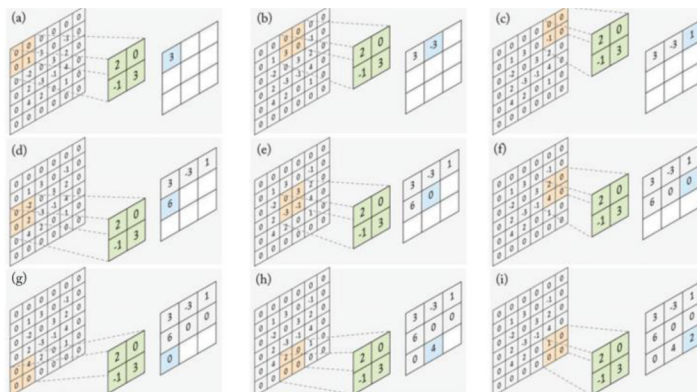
Každý filtr v konvoluční vrstvě si můžeme představit jako n-rozměrnou matici diskretních čísel, jako například 3x3 na obrázku 30. Hodnoty každého filtru (váhy) jsou učeny a upravovány během průběhu učení konvoluční sítě CNN. Při první iteraci trénování CNN jsou hodnoty filtru nastaveny náhodně. Poté se při daných vstupně-výstupních dvojicích během postupu učení v několika různých iteracích vyladí. [22]

-1	0	1
-2	0	2
-1	0	1

Obrázek 30: Konvoluční jádro (kernel) o velikosti 3x3. Na obrázku je použit kernel pro detekci hran

Konvoluce

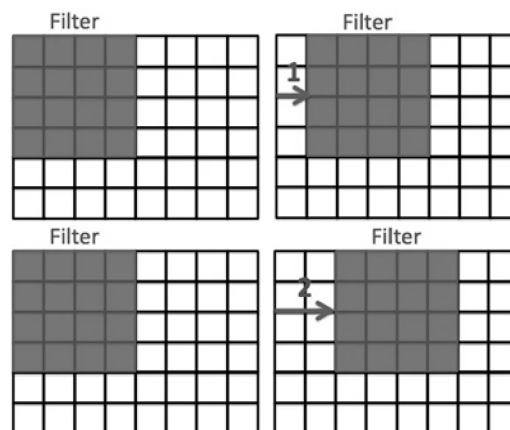
V CNN je konvoluce klíčová operace pro extrahování příznaků z dat, obvykle obrázků. Malý filtr s váhami (jádro) se posouvá po vstupních datech pixel po pixelu a provádí elementární součin s odpovídajícími pixely. Výsledky se sčítají a dávají novou hodnotu pro danou pozici ve výstupní matici (feature map). Tento proces se opakuje pro všechny pozice filtru, čímž se vytvoří mapa. Konvoluce umožňuje síti detekovat lokální vzory, je invariantní k posunutí a snižuje počet parametrů, čímž zlepšuje efektivitu a zabraňuje přeučení. [22]



Obrázek 31: Proces konvoluce s konvolučním jádrem 2x2 na vstupní matici 6x6 s krokem = 2, převzato z [22]

Stride


Důležitým parametrem pro konvoluci je velikost kroku (stride), který ovlivňuje, jak se filtr posouvá po vstupních datech během procesu konvoluce. Standardně se filtr posouvá o jeden pixel v obou směrech (horizontálně a vertikálně) pro každou pozici ve výstupní mapě (feature map). Stride větší než 1 umožňuje filtru přeskokovat pixely, což vede k menším výstupním mapám. [21, 22]



Obrázek 32: Ukázka parametru stride při konvoluci, na horním obrázku stride = 1, na dolním stride = 2, převzato z [22]

6.8.2 Pooling vrstvy

Max pooling



Obrázek 33: Max pooling s oknem [2 2] a stride = [1 1], převzato z [22]

Max pooling je důležitá operace v konvolučních neuronových sítích (CNN), která slouží ke snižování rozměrů aktivačních map a zefektivnění výpočtu. Funguje tak, že v předem definovaném okně (tzv. "poolingu") vybere maximální hodnotu aktivačních funkcí a tuto hodnotu použije jako výstupní hodnotu pro danou pozici v poolované mapě viz obrázek. Její její definice a parametry v prostředí matlab jsou:


„Vrstva 2-D max pooling provádí downsampling rozdělením vstupu na obdélníkové oblasti poolingů a následným výpočtem maxima každé oblasti.“ [21]

PoolSize – určuje dimenzi poolovacího regionu, zapisuje se např. [2 2]

Stride – jak bylo uvedeno dříve, stride určuje velikost kroku poolovacího okénka, zapisuje se v jednotlivých dimenzích např. [3 2]

Mezi hlavní důvody použití této vrstvy patří snížení rozměrů čímž snižuje počet parametrů a výpočetní náročnost. Tyto vlastnosti jsou vhodné zejména u hlubokých sítí s velkým počtem vrstev. Zároveň tím max pooling vrstva zavádí robustnost proti okolnímu šumu v datech, protože vybírá maximální hodnoty v okně. To ale zároveň vede i k nevýhodám, jako je ztráta prostorové informace. To může mít za následek malé posunutí v prostoru nebo v čísle vzorků a může to činit problémy při úlohách kde se požaduje přesná lokalizace objektů. Zároveň se jedná o nelineární operaci, která může zkomplikovat analýzu chování sítě. [21, 22]


Average pooling



Obrázek 34: Average pooling s oknem [2 2] a stride = [1 1], převzato z [22]

Tato vrstva vypočítá průměr aktivací funkcí v okně a tuto hodnotu použije jako výstup. Average pooling má tendenci být méně náchylný k šumu než max pooling, ale může ztratit více informací o maximálních hodnotách. [21, 22]

Global pooling




Obrázek 35: Global pooling, převzato z [22]

Je vrstva, která slouží k agregaci informací z celé aktivační mapy a sloučí je do jediné hodnoty. Na rozdíl od standardních poolingových vrstev, které operují s předem definovanými okny, global pooling zohledňuje všechny aktivační funkce v mapě. [21, 22]

Typ poolingové vrstvy, která se používá v CNN, závisí na specifické úloze a požadavcích. Max pooling je obvykle dobrou volbou pro rozpoznávání objektů, zatímco average pooling může být vhodnější pro úkoly, kde je důležitá celková informace o vstupu. Global pooling se obvykle používá na konci sítě, aby se získal vektorový reprezentace vstupu. Stochastic pooling a fractional pooling se používají méně často, ale mohou být užitečné pro specifické úkoly. [21, 22]

6.8.3 Batch Normalization




Obrázek 36: Modré data před normalizací, červené po dávkové normalizaci, převzato z [23]

Batch normalization je technika v neuronových sítích, která se často používá k urychlení učení a zlepšení stability sítě. Tato technika je implementována pomocí speciální vrstvy nazývané batch normalization vrstva, která normalizuje vstupy každé vrstvy v síti na nulový průměr a jednotkový rozptyl pomocí statistik vybraných z trénovacích dávek (nebo "batch"). To pomáhá předcházet problémům jako je ztráta gradientu a může významně zlepšit stabilitu a rychlost učení neuronové sítě. Batch normalization vrstvy jsou často umístěny před aktivační funkce v každé vrstvě neuronové sítě a mohou hrát klíčovou roli v úspěchu moderních hlubokých sítí. [22, 23]

„Dávková normalizační vrstva normalizuje mini dávku dat napříč všemi pozorováními pro každý kanál nezávisle. Chcete-li urychlit trénování konvoluční neuronové sítě a snížit citlivost na inicializaci sítě, použijte dávkové normalizační vrstvy mezi konvolučními vrstvami a nelineárními vrstvami, například vrstvami ReLu.“ [24]

6.8.4 Fully connected layer




Obrázek 37: Plně propojené vrstvy

Plně propojené vrstvy, často nazývané také jako fully connected (FC) nebo dense vrstvy, jsou základním stavebním kamenem mnoha neuronových sítí, zejména v hlubokém učení. V těchto vrstvách jsou všechny neurony propojeny se všemi neurony z předchozí vrstvy, což znamená, že každý vstup je spojen s každým výstupem. Plně propojené vrstvy často následují po konvolučních nebo pooling vrstvách a předcházejí vrstvám s klasifikačními funkcemi. Tyto vrstvy jsou často používány k extrakci vysokoúrovňových funkcí a kombinaci různých aspektů vstupních dat. Při trénování sítě jsou váhy mezi jednotlivými neurony aktualizovány pomocí algoritmů zpětné propagace chyby, což umožňuje síti adaptovat se na daný úkol. Plně propojené vrstvy jsou důležitou součástí mnoha architektur neuronových sítí a mají široké využití při klasifikaci, regresi a dalších úlohách strojového učení. [22, 25]

7 ZKOUMANÝ MODEL

7.1 Schéma modelu a popis



Obrázek 38: Schéma modelu, převzato z [7]

V této části bude popsán reálný model, bude ukázáno jeho schéma a bude pojednáno o hardwarové a softwarové části. Jedná se o zařízení umožňující měřit hodnoty vibrací jak off-line, tak on-line a vyhodnocovat data buď přímo na stroji pomocí spektrogramů, ukazatelů DKW nebo vlastních ukazatelů, nebo také umožňuje stažení surového (raw) signálu po síti ze stroje k dalšímu zpracování, jako je například Matlab.

Reálný model se skládá:

- Podstavec
- Servomotor
- Servo pohon SINAMICS V90
- PLC SIMATIC S7-1200
- Měřicí systém SIPLUS CMS SM1281
- Dotýková obrazovka (HMI) SIMATIC HMI TP700 Comfort
- Hřídel s rotorem pro montáž nevyváhy
- Ložiskové domečky s možností výměny ložiska a několika úchyty pro senzor
- Senzor pro měření vibrací CMS VIB-Sensor S03

7.2 Popis hardwaru

7.2.1 SINAMIC V90



Obrázek 39: SINAMIC V90, převzato z [28]

Pohyb modelového rotoru je řízen pomocí servomotoru SINAMICS V90, který je kompaktním zařízením propojeným s PLC SIMATIC. Jeho otáčky lze snadno regulovat podle potřeby. Toto zařízení se běžně využívá v dopravních systémech, ale pro naše účely je dostatečné. Komunikace může probíhat přes PROFINET, USS, Modbus RTU nebo pulzní rozhraní. Výkon servomotoru se pohybuje v rozsahu od 50 w do 7 kW. Obsahuje integrované bezpečnostní prvky, které aktivuje stisknutím připojeného tlačítka. Dále je možné použít různé typy integrovaných enkodérů podle potřeby aplikace. Veškeré nastavení lze provádět v prostředí TIA Portal. [28]

7.2.2 SIMATIC S7-1200



Obrázek 40: Nalevo SIMATIC S7-1200, napravo rozšiřující signálové moduly, převzato z [26]

Programovatelný logický automat SIMATIC S7-1200 je hlavním řídicím prvkem v našem modelu. K systému se lze připojit pomocí vývojového prostředí TIA portál, v kterém lze zařízení konfigurovat a programovat softwarovou část, která se následně nahrává do PLC. Zařízení se dodává v široké škále provedení, v našem případě se jednalo o PLC s centrální řídicí jednotkou CPU, 8 digitálními vstupy, 6 digitálními výstupy a 2 vstupy pro analogové signály. Zařízení se připevňuje na DIN lištu a jej rozšířit o rozšiřující moduly, jako například „Signal modules“, které mají vlastní kompaktní CPU a rozšíří sestavu o několik vstupů a výstupů. Těchto modulů lze k PLC přiřadit několik. Dále lze připojit „Speciální moduly“ rozšiřují oblast použití celého systému, např. pro Condition Monitoring, integrovanou technologii vážení, simulaci vstupního signálu nebo pro rozšíření rezervy energie pro hodiny reálného času S7-1200 přídavnou bateriovou deskou. Další užitečným rozšířením je „Komunikační modul“. Komunikační moduly rozšiřují komunikační možnosti PLC SIMATIC S7-1200 o další funkce a rozhraní. Komunikační moduly S7-1200 podporují sériovou komunikaci, PROFIBUS, IO-Link, AS-Interface a několik mobilních standardů. Napájení PLC je realizováno externě pomocí odděleného zdroje napětí. Komunikace probíhá na protokolu Profibus po ethernetovém kabelu s konektorem RJ-45. [26]



Obrázek 41: SIMATIC HMI TP700 Comfort, převzato z [27]

Dotykový panel SIMATIC HMI TP700 Comfort, jak z názvu vyplývá, slouží jako human – machine – interface neboli prostředí pro komunikaci uživatele s strojem. Jedná se o robustní řešení s úhlopříčkou sedmi palců. HMI panel disponuje programovatelnou pamětí 12 megabytů, která se dá rozšířit pomocí přenosného USB disku. Zařízení neobsahuje žádná tlačítka, nýbrž pouze softwarově definované. Dotykový panel komunikuje s ostatními zařízeními na protokolu Profibus po ethernetovém kabelu s konektorem RJ-45 a chová se jako samostatné zařízení, nikoli pouze jako zobrazovací médium jako to bývá například u počítačových monitorů. [27]

7.2.3 CMS VIB-Sensor S03



Obrázek 42: Použitý vibrační senzor, převzato z [29]

Pro systém Siemens SIPLUS CMS se doporučuje použít senzor SIPLUS CMS VIB-Sensor S03, který má tyto vlastnosti [29]:

- Frekvenční rozsah systému sahá od 0,2 Hz do 3 kHz, což zajišťuje komplexní monitorovací schopnosti v širokém spektru vibrací.
- S měřicím rozsahem 10G dokáže systém přesně detekovat a analyzovat vibrace s vysokým stupněm citlivosti.
- Citlivost systému je dimenzována na 500 mV/G (+/-10 %), což umožňuje přesné měření a detekci i jemných změn úrovně vibrací.
- Systém je vybaven MIL konektorem nahoře a nabízí robustní a spolehlivé rozhraní pro bezproblémové připojení a přenos dat.

General information	
Product type designation	VIB-Sensor S03
Product description	piezoelectric sensor for connection to SIPLUS CMS1200 or SIPLUS CMS2000
Installation type/mounting	
Installation and mounting instructions	incl. mounting bolts UNF 1/4-28 on M6 and M8
Input current	
Type of power supply	IEPE 2 to 10 mA
Encoder	
Encoder signals, IEPE	
• Signal voltage (DC), min.	10 V
• Signal voltage (DC), max.	14 V
Integrated Functions	
Measuring functions	
• Physical measuring principle	Piezo-quartz recorder with integrated evaluation electronics
• Operating range of sensor at +/- 3 dB, min.	0.2 Hz
• Operating range of sensor at +/- 3 dB, max.	3 000 Hz
• Resonance frequency	16 kHz
Measuring range	
— Measurement range vibration acceleration, max.	10 gn
— Sensitivity, typ.	500 mV/gn
Degree and class of protection	
IP degree of protection	IP65
Standards, approvals, certificates	
CE mark	Yes
RCM (formerly C-TICK)	Yes
KC approval	Yes
EAC (formerly Gost-R)	Yes
China RoHS compliance	Yes
Ambient conditions	
Ambient temperature during operation	
• min.	-50 °C
• max.	121 °C
Cables	
Cable length, max.	30 m
connection method	
Type of connection	MIL-C5015
Mechanics/material	
Material of housing	Stainless steel

Obrázek 43: Tabulka parametrů čidla VIB - Sensor S03, převzato z [29]

7.2.4 Popis softwaru

Pro získání dat na poskytnutém modelu byl použit pro tuto práci software, který se již vyskytoval v modelu. Vývojem tohoto softwaru se zabýval Ing. Vojtěch Marek v práci Analýza vibrací pomocí moderních on-line systémů z roku 2023 pod vedením doc. Ing. Miloše Hammera, CSc..

K tvorbě softwaru bylo použito vývojové prostředí společnosti Siemens AG. a to TIA Portal. Toto prostředí obsahuje program STEP 7, který byl použit pro vývoj softwaru PLC. Dále byl použit WinCC, kterým se vytvořil software pro HMI panel.

TIA Portal

Totally Integrated Automation Portal je komplexní softwarová platforma, která umožňuje programování a správu různých typů automatizačních zařízení na jednom místě. Díky této flexibilitě je možné efektivněji pracovat se všemi zařízeními v rámci firmy a zároveň ušetřit náklady, protože není potřeba kupovat a instalovat více aplikací.

TIA Portal po instalaci poskytuje kompletní sadu softwarů pro práci s produkty od společnosti Siemens, a to vše v jednom uživatelském rozhraní. Mezi tyto softwary patří STEP 7 pro programovatelné automaty, WinCC pro vizualizaci HMI panelů, SINAMICS Startdrive, SIMOCODE ES a SIMOTION SCOUT TIA. Díky tomu není nutné instalovat každý software zvlášť ani spouštět více aplikací současně. [30]

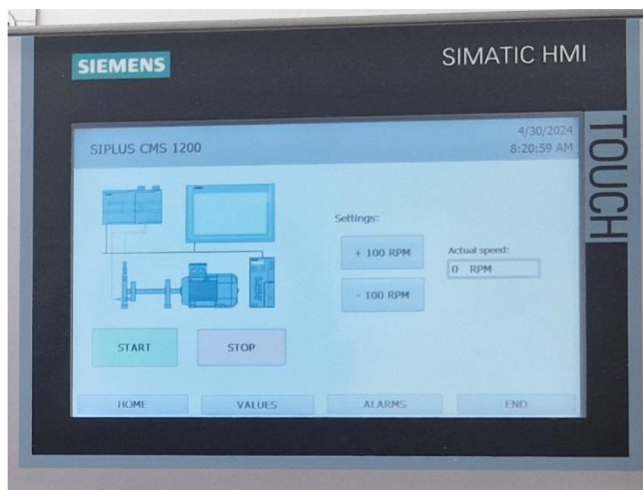
STEP 7

STEP 7 je programovací prostředí primárně určené pro vytváření řídicích programů, které běží uvnitř PLC a dalších propojených zařízení v síti. Tento software nabízí uživatelům tři typy programových bloků: organizační blok (OB), funkce (FC) a funkční blok (FB), které jsou strukturovány v určité hierarchii. Organizační blok je nejvyšší v hierarchii a provádí se cyklicky v primárním nastavení každých 100 ms. V něm jsou definovány instrukce, které PLC provádí ve stanoveném pořadí, obvykle označené jako OB1. Funkce představují algoritmy vytvořené uživatelem a vracejí hodnoty do definovaných výstupních proměnných. Pro každou funkci lze definovat vstupní, výstupní, in/out proměnné nebo konstanty. Funkční bloky mají podobnou strukturu jako funkce, ale s jedním klíčovým rozdílem: provádějí volání datových bloků (DB) při každé jejich interakci. Datové bloky reprezentují vztah k současnému stavu funkčního bloku. Pro lepší pochopení této struktury lze tento vztah ilustrovat na příkladu FB pro řízení servomotoru, který funguje v organizačním bloku a zavolává se k němu datový blok pro kontrolu řízení motoru 1, obsahující proměnné pro start/stop, změnu rychlosti otáčení atd. Dále je možné zavolat stejný funkční blok s různými datovými bloky. Například, stejný FB pro řízení motoru můžeme zavolat s jiným datovým blokem pro kontrolu řízení motoru 2. Tímto způsobem můžeme řídit více motorů pomocí jednoho funkčního bloku v rámci jednoho programového bloku. Tento přístup umožňuje efektivní a flexibilní programování automatizačních systémů pomocí STEP 7 v TIA Portal. [30]

WinCC

WinCC je software navržený zejména pro vytváření vizualizace pro HMI panely, které slouží k interakci s uživatelem. Jeho uživatelské rozhraní umožňuje intuitivní tvorbu vizuálních prvků pomocí metody drag & drop, což znamená, že uživatel vybírá z nabídky dostupných grafických objektů, jako jsou tlačítka, texty, stupnice atd., a jednoduše je přetahuje na pracovní plochu. Přimo v rámci této pracovní plochy je možné sledovat výsledný obraz. Objekty mohou být dynamické, což znamená, že lze pro ně vytvářet animace nebo pohyby pomocí záložky Animations. Dále lze pomocí záložky Events nastavit reakci na interakci s objekty, například po kliknutí na ně. Spolupráce mezi programy STEP 7 a WinCC je realizována pomocí tzv. Tagů, které fungují jako proměnné, jimž je přiřazeno jméno a datový typ. Tyto Tagy umožňují přímou komunikaci mezi PLC a HMI panelem. Propojení proměnných se provádí v záložce HMI tags. Pokud je zapotřebí vytvořit více aktivních obrazovek, lze vytvořit jednotlivé návrhy v záložce

Screens a definovat podmínky pro jejich zobrazení na panelu. WinCC poskytuje také možnost vytvářet vizualizace s pevným pozadím, což předchází nepříjemnému osvětlení očí při interakci s panelem. Kromě toho umožňuje nahrávat vlastní symboly nebo obrázky, což přispívá k individualizaci vizualizací. Celkově je doporučováno vytvářet vizualizace s tmavším pozadím, aby nedocházelo k ozařování očí při časté interakci s panelem. [30]



Obrázek 44: Rozhraní HMI pro obsluhu modelu

Web server a komunikace

Při práci s modelem bylo zapojení komunikačních kabelů již úspěšně dokončeno. Řídící PLC je propojeno se servomotorem a HMI panelem pomocí sběrnice PROFINET, což je průmyslový standard Ethernetu pro automatizaci v průmyslových aplikacích. Pro nahrání vytvořených programů je nezbytné připojit PC k PLC prostřednictvím síťového kabelu Ethernet. Poté je možné v prostředí TIA Portal nalézt zařízení, které jsou v tomto projektu konfigurovány na síti s adresou 192.168.1.xx. Po identifikaci zařízení může uživatel přejít do režimu on-line konfigurace a nahrát vytvořený software do PLC. Po úspěšném nahrání a rychlém restartu je PLC opět plně funkční. Pro práci s vibračním monitorem CMS je vhodné připojení k zařízení přes webový server. Přístup k webovému serveru diagnostické karty je potřeba povolit v nastavení hardwarové konfigurace modulu v TIA Portalu. Po otevření webového prohlížeče a zadání IP adresy karty (např. 192.168.1.6) se uživatel dostane na úvodní stránku modulu. Po přihlášení administrátorského účtu je možné konfigurovat nastavení, sledovat aktuální hodnoty nebo pracovat se surovými daty. [30]


FTP server a měření

Pro důkladnější analýzu vibrací mimo ekosystém produktů Siemens je možné naměřit surová data. Je potřeba na webovém serveru na adrese 192.168.1.6 nastavit

interval měření surových dat v záložce Raw data recording. Po uplynutí času se provede automatické uložení souboru ve formátu .wav do složky /rawdata na kartě. Přístup k těmto souborům je možný pomocí komunikačního protokolu FTP. Uživatel může využít Windows Explorer a zadat cestu ftp://admin:0000@192.168.1.6/rawdata, kde "admin" je uživatelské jméno a "0000" heslo. Po úspěšném přihlášení je možné kopírovat potřebné soubory z karty na lokální disk a následně je zpracovávat v externím prostředí, jako je například Matlab. [30]


8 PRAKTICKÁ ČÁST

8.1 Měření na modelu, získávání a předzpracování dat



Obrázek 45: Reálný model, na kterém bylo provedeno měření

Měření bylo realizováno na reálném modelu osazeném PLC S7 – 1200, vibrační monitorovací kartou, snímačem pro měření vibrací, rotorem s možností montáže nevyváhy, ložiskovým domečkem s možností výměny ložiska, HMI panelem pro obsluhu a nastavování rychlosti a možností se připojit pomocí UTP kabelu k webserveru PLC




Obrázek 46: Ložiskový domeček



Obrázek 47: Nepoškozené ložisko 11

Jako první bylo do ložiskového domečku nainstalováno nepoškozené ložisko l1, s kterým pak bylo provedeno měření, následně bylo vyměněno za ložisko s vadou vnějšího kroužku. Vadné ložisko s chybou na vnějším kroužku bylo zvoleno z důvodu projevu závady ve zrychlení, které se většinou projevuje ve frekvencích od 3kHz po 10kHz.



Obrázek 48: Rotor s nevyváhou n3



Obrázek 49: Ložisko s vadou l2

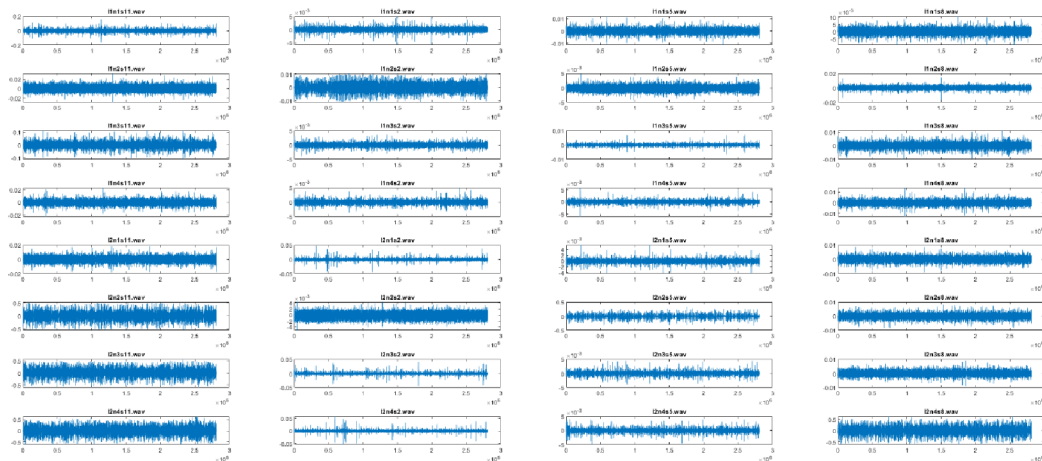
Pro každé měření s ložiskem bylo určeno několik stupňů nevyváhy, kterou bylo realizováno pomocí metrického šroubu a různým počtem podložek, které byly zváženy. Pro měření byla vybrána porucha nevyváhou z toho důvodu, že tato nevyváha se projeví v datech v rychlosti a ve spektru rychlosti bude reprezentována jako jedna silná frekvence. Druhy provedených měření a jejich konfigurace a značení jsou zaznamenány v tabulce níže.

Tabulka 2: Druhy a značení měření

		Otáčky 1100 ot/min	Otáčky 200 ot/min	Otáčky 500 ot/min	Otáčky 800 ot/min
Vývaha	Ložisko 1 - bez vady	l1n1s11	l1n1s2	l1n1s5	l1n1s8
Nevývaha 10,6g	Ložisko 1 - bez vady	l1n2s11	l1n2s2	l1n2s5	l1n2s8
Nevývaha 16g	Ložisko 1 - bez vady	l1n3l11	l1n3s2	l1n3l5	l1n3s8
Nevývaha 21,4g	Ložisko 1 - bez vady	l1n4s11	l1n4s2	l1n4s5	l1n4s8
Vývaha	Ložisko 2 - s vadou	l2n1s11	l2n1s2	l2n1s5	l2n1s8
Nevývaha 10,6g	Ložisko 2 - s vadou	l2n2s11	l2n2s2	l2n2s5	l2n2s8
Nevývaha 16g	Ložisko 2 - s vadou	l2n3s11	l2n3s2	l2n3s5	l2n3s8
Nevývaha 21,4g	Ložisko 2 - s vadou	l2n4s11	l2n4s2	l2n4s5	l2n4s8

8.2 Re prezentace dat

Získaná data jsou ve formě surového signálu uložené v souboru WAV Audio File (.wav). Celkem bylo naměřeno 32 datových souborů. Každý datový soubor reprezentuje jednu variantu nastavení a to z množiny 2 ložisek (bez vady, s vadou na vnějším kroužku), 4 velikosti otáčivé rychlosti ($n_1 = 200$ ot/min, $n_2 = 500$ ot/min, $n_3 = 800$ ot/min, $n_4 = 1100$ ot/min) a 4 druhy nevyváhy (vývaha, nevyváha 10,6g, nevyváha 16g, nevyváha 21,4g). Každý datový soubor je 60 sekund dlouhý záznam o vzorkovací frekvenci 48 kHz, který v matlabu reprezentujeme jako 1D vektor o 2 8125 000 vzorcích.



Obrázek 50: Matice zobrazení naměřených signálů

Získané signály byly segmentovány pomocí překrývajícího se okna s 50% překrytím na 500, 1000 a 5000 datových bodů, přičemž pro každý stav nastavení experimentu bylo získáno příslušné množství segmentů. Jednorozměrné segmenty pak byly naskládány řádek po řádku, aby se vytvořila dvourozměrná matice jako vstup CNN. Následně byla vstupní data rozdělena do tréninkových, validačních a testovacích sad v poměru 0,6:0,2:0,2.

```
clear all;
audioFiles = dir('*.*wav');
N = length(audioFiles);
window = 500; %velikost okénka
delka = round(2812500/(window*0.5)-1); %počet segmentů

for i = 1:32
    file = audioFiles(i).name;
    data = audioread(file);
    data = data(:,1); %bereme pouze první sloupec

    ds = buffer(data,window,window/2)'; %rozdělení dat s 50% overlap
    ds = ds(2:end,:); %vyhodi první řádek kde jsou 0 kvůli overlapu

    for iii =1:height(ds)
        all_data(iii+ i*delka - delka,1) = {ds(iii,:)}; %original data
    end

    VAR1 = file(1:end-4); %vytvori
    popisek
    labels(1 + i*delka - delka:i*delka,1) = convertCharsToStrings(VAR1); %zapise
    popisek do labels
```

```
    labels = categorical(labels);
end
numberObservations = height(all_data);
randomizedIndices = randperm(numberObservations);
numberTraining = floor(0.6*numberObservations);
numberValidating = floor(0.2*numberObservations);

dataTrain    = all_data(randomizedIndices(1:numberTraining),:);
dataValid    = all_data(randomizedIndices(numberTraining+1:numberTraining +
numberValidating),:);
dataTest     = all_data(randomizedIndices(numberTraining + numberValidating+1:end),:);

labelTrain   = labels(randomizedIndices(1:numberTraining),:);
labelValid   = labels(randomizedIndices(numberTraining+1:numberTraining + numberValidating),:);
labelsTest   = labels(randomizedIndices(numberTraining + numberValidating+1:end),:);

save data_RAW_500_32CLASS.mat dataTrain dataValid dataTest labelTrain labelValid labelsTest
```

Tímto bylo připraveno 6 vektorů, dataTrain, dataValid, dataTest, labelTrain, labelValid a labelTest. Nyní si popíšeme přípravu architektury.

8.3 Přístup první, 1D - CCN

8.3.1 Návrh konvoluční neuronové sítě

Jelikož připravená data jsou ve formě nezpracovaného signálu a tudíž nich nejsou vyextrahovány příznaky (features), tak bylo rozhodnuto použití konvoluční neuronové sítě CNN s několika konvolučními filtry, které tyto features z nezpracovaných dat dokáží vyextrahovat a naučit se je rozpoznávat. Trénování neuronové sítě je proces, při kterém se síť učí rozpoznávat vzory v datech a přizpůsobuje své váhy a parametry tak, aby minimalizovala chybovou funkci. Zde si krátce popíšeme, jak probíhá trénování neuronové sítě:

Nejprve se inicializují váhy (weights and biases) a ostatní parametry sítě náhodně nebo pomocí předem určených hodnot jednotlivých vrstev. Následně se připraví data. Tato data obvykle obsahují vstupy (například obrázky nebo vektory čísel) a odpovídající cílové hodnoty (například kategorie nebo labels). Tato trénovací data se postupně předávají síti jednotlivými dávkami (takzvanými "minibatch") během každé iterace trénování. Pro každou dávku se vypočítají výstupy sítě pro dané vstupy. Tyto výstupy se porovnají s cílovými hodnotami a vypočítá se chybová funkce, která měří rozdíl mezi předpovězenými a skutečnými hodnotami. Následně se provede zpětná propagace chyby. To je algoritmus používaný k výpočtu gradientu chybové funkce vzhledem ke všem vahám sítě. Tento gradient se používá k aktualizaci vah sítě tak, aby se minimalizovala chybová funkce. Na základě toho se váhy sítě se aktualizují pomocí optimalizačního algoritmu (například stochastický gradientový sestup nebo adams), který určuje, jak moc se váhy změní na základě vypočtených gradientů. Celý proces předávání dat, výpočtu chybové funkce, zpětné propagace a aktualizace vah se opakuje pro každou dávku trénovacích dat až do dosažení určeného počtu iterací (epoch) nebo kritéria ukončení trénování. Po skončení trénování se výkon sítě obvykle vyhodnocuje na zvláštním

testovacím datasetu, který nebyl použit při trénování. To umožňuje posoudit, jak dobře síť generalizuje na nová data.

Bylo rozhodnuto tedy navrhnout 5 konvolučních neuronových sítí a trénovat na nich vždy stejný dataset a následně porovnat jejich výkonost.

První konvoluční síť


Vrstva	Název vrstvy	Parametry vrstvy
1	SequenceInputLayer	1×5000
2	convolution1dLayer 1	64 filters with kernel 3×1 with stride [1 1]
3	Batch Normalization 1	–
4	reluLayer 1	–
5	convolution1dLayer 2	128 filters with size 3×1 with stride [1 1]
6	Batch Normalization 2	–
7	reluLayer 2	–
8	convolution1dLayer 3	256 filters with size 3×1 with stride [1 1]
9	Batch Normalization 3	–
10	reluLayer 3	–
11	convolution1dLayer 4	128 filters with size 1×7 with stride [1 1]
12	Batch Normalization 4	–
13	reluLayer 4	–
14	convolution1dLayer 5	256 filters with size 1×7 with stride [1 1]
15	Batch Normalization 5	–
16	reluLayer 5	–
17	Fully Connected 1	128
18	reluLayer 6	–
19	DropoutLayer	30%
20	flattenLayer	–
21	globalAveragePooling1dLayer	–
22	Fully Connected 2	32
24	Softmax	–
25	Classification	–

Dále bylo empiricky zvoleno miniBatchSize = 256 a počet trénovacích epoch = 15. Rychlost počátečního učení InitialLearnRate = 0.01 z důvodu, že bylo empiricky zjištěno, že s použitou sítí a daty dosahuje dobré konvergence a tvar loss křivky je dobrý. Jako řešič byl zvolen Adam (Adaptive Moment Estimation). Ten je populární volbou pro trénování neuronových sítí díky efektivitě, rychlosti konvergence a

robustnosti. Tento algoritmus v sobě kombinuje vlastnosti adaptivních gradientových metod s momentum, což umožňuje lépe řešit některé problémy tradičních optimalizačních algoritmů.

8.3.2 Trénink konvoluční neuronové sítě

Jakmile tyto parametry byly nastaveny, tak se spustilo trénování, které probíhalo na stroji s grafickou kartou nVidia GTX 1080 Ti a procesorem Intel i7 – 8700k s 32GB RAM. Trénování sítě 1 trvalo zhruba 120 minut. Zde na obrázku můžeme vidět graf učení. Schopnost klasifikace se v počátcích pohybovala okolo 3%, což odpovídá náhodnému odhadu do 32 tříd. Díky vhodně zvoleným konvolučním vrstvám a ostatním parametrům se již během první epochy podařilo dostat zhruba na 60% úspěšnost při klasifikaci do 32 tříd. Vývoj úspěšnosti klasifikace se následně zpomalil a pohyboval se po trajektorii připomínající logaritmickou funkci. Parametr learning rate byl zvolen taky vhodně, o čemž svědčí pohled na křivku ztrátové funkce. Volba learning rate se často provádí empiricky, protože závisí na mnoha věcech, jako složitost souboru dat a architektury sítě. Velký učicí krok vede k nestabilitě a kolísání ztrátové funkce, zatímco malý krok vede k pomalému učení.



Obrázek 51: Trénink neuronové sítě č. 1

8.3.3 Návrh dalších sítí

Konvoluční neuronová síť číslo 2

SequenceInputLayer	1 × 5000
convolution1dLayer 1	64 filters with kernel 3 × 1 with stride [1 1]
Batch Normalization 1	–
reluLayer 1	–
convolution1dLayer 2	128 filters with size 3 × 1 with stride [1 1]
Batch Normalization 2	–
reluLayer 2	–
convolution1dLayer 3	256 filters with size 3 × 1 with stride [1 1]
Batch Normalization 3	–
reluLayer 3	–
convolution1dLayer 4	128 filters with size 1 × 7 with stride [1 1]
Batch Normalization 4	–
reluLayer 4	–
Fully Connected 1	128
reluLayer 6	–
DropoutLayer	30%
flattenLayer	–
globalAveragePooling1dLayer	–
Fully Connected 2	32
Softmax	–
Classification	–

Konvoluční neuronová síť číslo 3

SequenceInputLayer	1 × 5000
convolution1dLayer 1	64 filters with kernel 3 × 1 with stride [1 1]
Batch Normalization 1	–
reluLayer 1	–
convolution1dLayer 2	128 filters with size 3 × 1 with stride [1 1]
Batch Normalization 2	–
reluLayer 2	–
convolution1dLayer 3	256 filters with size 3 × 1 with stride [1 1]
Batch Normalization 3	–
reluLayer 3	–
Fully Connected 1	128
reluLayer 4	–
DropoutLayer	30%
flattenLayer	–
globalAveragePooling1dLayer	–
Fully Connected 2	32
Softmax	–
Classification	–

Konvoluční neuronová síť číslo 4

SequenceInputLayer	1 × 5000
convolution1dLayer 1	64 filters with kernel 3 × 1 with stride [1 1]
Batch Normalization 1	–
reluLayer 1	–
convolution1dLayer 2	128 filters with size 3 × 1 with stride [1 1]
Batch Normalization 2	–
reluLayer 2	–
Fully Connected 1	128
reluLayer 3	–
DropoutLayer	30%
flattenLayer	–
globalAveragePooling1dLayer	–
Fully Connected 2	32
Softmax	–
Classification	–

Konvoluční neuronová síť číslo 5

SequenceInputLayer	1 × 5000
convolution1dLayer 1	64 filters with kernel 3 × 1 with stride [1 1]
Batch Normalization 1	–
reluLayer 1	–
Fully Connected 1	128
reluLayer 2	–
DropoutLayer	30%
flattenLayer	–
globalAveragePooling1dLayer	–
Fully Connected 2	32
Softmax	–
Classification	–

V každé další konvoluční síti byla odstraněna trojice: konvoluční vrstva, dávková normalizace a ReLu aktivační funkce. To se provedlo z experimentálního důvodu, kdy bylo cílem zkoumat, jak se bude měnit klasifikační schopnost daných sítí a jak bude klesat výpočetní náročnost. Dalo by se předpokládat, že mělčí síť s méně vrstvami budou mít horší schopnosti v rozpoznávání vzorů z důvodu, že kvůli méně konvolučním filtrům nedokáží vyextrahovat z výchozích nezpracovaných dat dostatek charakteristických rysů k následné úspěšné klasifikaci.


8.4 Přístup druhý, 2D - CNN s Wavelet transform

Jako další typ neuronové sítě byla zvolena opět konvoluční neuronovou síť, do které tentokrát budou vstupovat naměřená data ve formě obrázků. Od tohoto přístupu se očekává rychlejší konvergence k cílené přesnosti z důvodu, že do sítě vstupuje vlnovková transformace, která do trénování vnáší další dimenzi a to frekvenční. Při použití nezpracovaného signálu se pohybujeme na časově – amplitudové dimenzi (Time series), nyní se budeme pohybovat na časově – frekvenčně – amplitudové.

Vlnovky transformace je vhodná jako vstup do konvolučních neuronových sítí pro několik důvodů, zejména pokud jde o analýzu signálů z vibrací rotujících strojů. Vlnovky

jsou matematické funkce, které mají schopnost rozkládat signály na různé frekvenční složky a časové rozlišení, což umožňuje zachytit jak nízkofrekvenční, tak vysokofrekvenční detaily signálu. Tato schopnost je zvláště důležitá při diagnostice vibrací, protože různé frekvence mohou indikovat různé typy vibrací a problémy v rotujícím stroji, jako jsou nevyváženosti, ložiskové vadyně, nebo opotřebení ložisek.


Použití wavelet transformace jako vstupu do CNN umožňuje síti efektivně extrahovat relevantní informace z vibrací a automaticky naučit se rozpoznávat vzory, které jsou spojeny s různými stavůmi rotujícího stroje. CNN poté může vytvářet vlastní hierarchii funkcí pro klasifikaci a identifikaci vadných stavů stroje na základě těchto extrahovaných vlastností.



Obrázek 52: Zvolená vlnovka Daubechies 4 (db4)


8.4.1 Tvorba wavelet transform datasetu

Jako parametry pro tvorbu datasetu tvořícího vlnovkové transformace bylo rozhodnuto, že pro analýzu vadných ložisek bude vhodné vyjít z maximální otáčkové frekvence, která byla při měření použita a to z toho důvodu, aby v okénku byl vždy zachycen alespoň jeden průběh závady na ložisku. Signál byl tedy rozdělen na stejně dlouhé úseky a to po 500 vzorcích s 50% překrytím, které reprezentují úsek zhruba 10 ms signálu. Takto navolené datové úseky se zpracovaly matlabovým skriptem a vytvořil se dataset o snímcích vlnovkové transformace o rozměrech 875 x 656 x 3 pixelů.



Obrázek 53: Vlnková transformace při vadném ložisku, malé nevyvaze a 800 ot/s

Následně tyto zobrazení museli být zmenšeny 5x, čímž vznikly zobrazení o rozměrech 175 x 132 x 2, které se jeví pro trénování neuronové sítě jako ideální, protože obsahovaly dostatek informace a zároveň nekladly vysoké nároky na výpočetní paměť. Tím vznikl hotový dataset.



Obrázek 54: Ukázka dané třídy z datasetu. Lze vidět opakující se vzory v datech.

8.4.2 Návrh neuronové sítě pro wavelet dataset

Pro tento dataset byla empiricky navržena konvoluční neuronová síť s parametry v tabulce. Vrstvy maxpooling jsou použity k postupnému zmenšování prostorových rozměrů obrázků po každé konvoluční vrstvě. Tím dochází k redukci počtu parametrů v modelu a zvyšuje se toleranci na posunutí objektů na obrázku, čímž se zlepšuje přizpůsobivost modelu. To pomáhá snižovat případné přeučení a zvyšuje obecnost


modelu. Batch normalization je technika normalizace aktivací v konvolučních neuronových sítích, která normalizuje výstupy z každé vrstvy, aby měly nulový průměr a jednotkovou varianci. Tímto způsobem se zlepšuje stabilita a rychlost učení sítě, což vede k rychlejší konvergenci a zvyšuje se obecnost modelu. Konvoluční vrstvy byly zvoleny s velikostí filtru 2×2 z důvodu, že empiricky jeví nejlepší vlastnosti. Poté i přes to se však nepovedlo předejít overfitingu. Proto se zavedla Dropout vrstva. Dropout vrstva je důležitou součástí konvolučních neuronových sítí (CNN), která slouží k regulaci přeučení (overfitting) a zvyšuje obecnost modelu. Principem Dropout vrstvy je náhodné deaktivování (vypnutí) určitého procenta neuronů v síti během tréninku. Tato deaktivace je prováděna s určitou pravděpodobností, která je nastavena jako hyperparametr vrstvy. Tím, že náhodně vypínáme určité neurony, Dropout vrstva v podstatě simuluje trénink více různých sítí s různými architekturami v rámci jednoho tréninkového průchodu. Tento proces pomáhá zabránit tomu, aby se jednotlivé neurony spoléhaly na konkrétní sousední neurony a vytvářely tak silné závislosti, které by mohly vést k přeučení.

Tabulka 3: Parametry konvoluční sítě pro vlnkovou transformaci

Vrstva	Název vrstvy	Parametry vrstvy
1	ImageInputLayer	132 x 175 x 3
2	Convolution2dLayer 1	16 filters with kernel 2×2 with stride [1 1]
3	Batch Normalization	–
4	reluLayer	–
5	maxPooling2dLayer	Pool size = [2 2]
6	Convolution2dLayer 2	32 filters with kernel 2×2 with stride [1 1]
7	Batch Normalization	–
8	reluLayer	–
9	maxPooling2dLayer	Pool size = [2 2]
10	Convolution2dLayer 3	64 filters with kernel 2×2 with stride [1 1]
11	Batch Normalization	–
12	reluLayer	–
13	maxPooling2dLayer	Pool size = [2 2]
14	Convolution2dLayer 4	128 filters with kernel 2×2 with stride [1 1]
15	Batch Normalization	–
16	reluLayer	–

Vrstva	Název vrstvy	Parametry vrstvy
17	maxPooling2DLayer	Pool size = [2 2]
18	flattenLayer	–
19	Fully Connected 2	32
20	DropoutLayer	50%
21	globalAveragePooling1dLayer	–
22	Fully Connected 2	8
24	Softmax	–

S následnou architekturou se provedlo trénování na datasetu a klasifikaci do 8 tříd.



Obrázek 55: Obrázek trénování CNN s Wavelet transformation daty

$$Přesnost = \frac{\text{Počet správných předpovědí}}{\text{Celkový počet předpovědí}} \quad (18)$$

Přesnost (Precision): Přesnost měří podíl správných pozitivních předpovědí mezi všemi pozitivními předpověďmi. Udává, kolik z předpovězených pozitivních případů je skutečně pozitivních. Tato metrika je důležitá zejména v případech, kdy je důležité minimalizovat falešně pozitivní případy.

$$Precision = \frac{\text{Pravdivé pozitivní výsledky}}{\text{Pravdivé pozitivní výsledky} + \text{Falešně pozitivní výsledky}} \quad (19)$$

Citlivost (Recall): měří podíl pravdivých pozitivních předpovědí mezi všemi skutečnými pozitivními případy. Udává, kolik pozitivních případů bylo modelem správně předpovězeno. Tato metrika je důležitá zejména v případech, kde je důležité minimalizovat falešně negativní případy.

$$Recall = \frac{\text{Pravdivé pozitivní výsledky}}{\text{Pravdivé pozitivní výsledky} + \text{Falešně negativní}} \quad (20)$$

Skóre F1: Skóre F1 je harmonický průměr přesnosti a citlivosti. Poskytuje rovnováhu mezi přesností a citlivostí, zejména pokud existuje nerovnováha mezi počtem pozitivních a negativních případů.

$$Skore\ F1 = 2 * \left(\frac{\text{Precision} * \text{Recal}}{\text{Precision} + \text{Recal}} \right) \quad (21)$$

Specifičnost: Specifičnost měří podíl pravdivých negativních předpovědí mezi všemi skutečnými negativními případy. Udává, kolik negativních případů bylo modelem správně předpovězeno. Tato metrika je užitečná pro vyvážení mezi falešně pozitivními a falešně negativními případy.

$$Specifičnost = \frac{\text{Pravdivé negativní výsledky}}{\text{Pravdivé negativy} + \text{Falešně pozitivní}} \quad (22)$$

Tyto metriky poskytují náhled na různé aspekty výkonnosti modelu neuronové sítě a pomáhají vyhodnotit jeho účinnost při klasifikaci případů v různých třídách. Tato metrika je důležitá zejména v případech, kde je důležité minimalizovat falešně pozitivní případy.


Tabulka 4: Vybrané metriky pro síť č. 1

Precision	0.912
Citlivost	0.897
Specifičnost	0.996
Přesnost	0.897
F1 Skóre	0.888


Celkově lze konstatovat, že model dosahuje vysoké přesnosti a specifičnosti, ale mírně nižší citlivost a F1 skóre. Z tohoto vyhodnocení lze usuzovat, že model je schopen dobře rozpoznávat negativní případy, ale může být méně úspěšný v identifikaci pozitivních případů. Vzhledem k cíli detekovat špatné ložisko a nevyváženost na rotační soustavě pomocí CNN jsou tyto metriky velmi důležité. Vyšší precision a recall naznačují, že model je schopen spolehlivě detekovat špatná ložiska s minimálním počtem falešných pozitivních a falešných negativních identifikací. Specifičnost 99.6% naznačuje, že model má minimální tendenci k identifikaci správných ložisek jako špatných. Celkově lze tedy říci, že model dosahuje vysoké spolehlivosti při detekci špatných ložisek a je schopen minimalizovat riziko falešných poplachů nebo nevhodných oprav.

9.2 Vyhodnocení přístupu 1, CCN-2, CNN-3, CNN-4, CNN-5


Následně byly vytvořeny a natrénovány na stejných datech další 4 konvoluční neuronové sítě, u kterých si už pouze nastíníme architekturu a ukážeme výsledky.




Obrázek 57: Matice záměn CCN-2



Obrázek 58: Matice záměn CCN-3



Obrázek 59: Matice záměn CCN-4



Obrázek 60: Matice záměn CCN-5

Tabulka 5: Porovnání výkonnostních metrik sítí

Sít'	Precision [%]	Citlivost [%]	Specifičnost [%]	Přesnost [%]	F1 skóre [%]	Délka učení [min]
CNN - 1	91,25	89,79	99,67	89,74	88,81	120
CNN - 2	91,42	84,80	99,51	84,94	89,90	85
CNN - 3	91,04	86,02	99,54	86,01	84,62	66
CNN - 4	88,07	84,87	99,50	84,51	85,47	34
CNN - 5	82,29	75,73	99,20	75,42	72,49	19

Výsledky prezentovaných konvolučních neuronových sítí (CNN) poskytují užitečný vhled do jejich schopnosti klasifikovat data ve vibrodiagnostice, zejména při detekci stavu ložiska. Každá síť vykazuje určité silné a slabé stránky vzhledem k různým metrikám výkonnosti a délce tréninku.

Nejlepší výsledky v přesnosti dosáhla CNN 2 s hodnotou 91.42%, což naznačuje schopnost této sítě přesně identifikovat pozitivní instance (v tomto případě správně detekovat vadná ložiska). To je klíčovým aspektem ve vibrodiagnostice, kde přesná identifikace problémů může vést k rychlejší a efektivnější údržbě.

Nicméně, pokles citlivosti u této sítě na 84.80% naznačuje, že CNN 2 může mít tendenci opomíjet některé skutečné pozitivní instance, což může být problematické v kontextu vibrodiagnostiky, kde je důležité minimalizovat falešně negativní výsledky.

CNN 1 vykazuje vysokou citlivost a specifičnost (89.79% a 99.67% odpovídající), což naznačuje schopnost této sítě efektivně rozlišovat mezi pozitivními a negativními instancemi. Tato schopnost je zvláště důležitá při minimalizaci falešně pozitivních a falešně negativních výsledků, což je klíčové pro spolehlivou vibrodiagnostiku.

CNN 3 dosahuje vyvážených výsledků mezi přesností, citlivostí a specifičtostí, což může být výhodné v situacích, kdy je třeba vyvážit různé aspekty výkonnosti.

Na druhé straně, CNN 4 a CNN 5 vykazují nižší výkonnostní metriky v porovnání s ostatními sítěmi, což může znamenat, že nejsou tak schopné přesně klasifikovat data, a to ani s ohledem na vyváženost mezi pozitivními a negativními instancemi.

CNN 2 může mít vyšší přesnost než CNN 1, i když má nižší citlivost, kvůli jiné prioritě při klasifikaci. Přesnost měří, jak velký podíl pozitivních výsledků je skutečně pozitivních, zatímco citlivost měří, jak velký podíl skutečně pozitivních případů je detekován jako pozitivní. Pokud je cílem minimalizovat falešně pozitivní výsledky, může být lepší mít vyšší přesnost (jako je tomu v případě CNN 2), i když to znamená nižší citlivost. Naopak, pokud je cílem minimalizovat falešně negativní výsledky, může být důležitější mít vyšší citlivost (jako je tomu u CNN 1).

CNN 4 a CNN 5 jsou méně úspěšné než ostatní sítě pravděpodobně kvůli jejich jednodušší architektuře. Tyto sítě mají méně vrstev a parametrů než CNN 1 a CNN 2, což

může znamenat, že jsou méně schopné zachytit složité vzory a charakteristiky dat ve vibrodiagnostice. CNN 4 a CNN 5 mají nižší kapacitu učení a mohou být méně flexibilní při adaptaci na různé podmínky a situace v datech z vibrodiagnostiky, což vede k jejich horší výkonnosti v porovnání s ostatními sítěmi.

Při použití konvolučních neuronových sítí (CNN) ve vibrodiagnostice rotujícího stroje je klíčové pečlivě zvážit jak konečné výsledky, tak i vlastnosti a charakteristiky jednotlivých sítí. Především je nutné brát v úvahu potřeby diagnostického procesu a prioritizovat mezi přesností a citlivostí detekce.

Síť s vyšší přesností může být vhodnější, pokud je cílem minimalizovat falešně pozitivní výsledky. To znamená, že se snažíme omezit situace, kdy je stroj označen jako vadný, ačkoliv ve skutečnosti problém není přítomen. V takových případech by se preferovala síť, která dosahuje vysoké přesnosti a snižuje tak riziko zbytečných oprav nebo výměn komponentů.

Naopak, síť s vyšší citlivostí je preferována, pokud je prioritou minimalizace falešně negativních výsledků. To znamená, že se snažíme minimalizovat případy, kdy síť nerozpozná skutečný problém na rotujícím stroji. V těchto případech je důležité zajistit, aby síť měla co nejmenší pravděpodobnost přehlédnutí skutečného problému.

Dále je třeba zohlednit délku tréninku a výpočetní náročnost jednotlivých sítí, zejména pokud se aplikují v reálném čase na velká množství dat z vibrodiagnostiky. Síť s komplexnější architekturou a vyšší kapacitou učení mohou vyžadovat delší tréninkové časy a větší výpočetní prostředky. V takových případech je nutné vyvážit potřeby vibrodiagnostiky s dostupnými zdroji.

Z výše uvedených úvah je tedy doporučeno pečlivě vybrat síť v závislosti na konkrétních potřebách vibrodiagnostiky rotujícího stroje. Jestliže je prioritou minimalizace falešně pozitivních výsledků, síť s vyšší přesností, jako je CNN 2, může být vhodnou volbou. Naopak, pokud je klíčové minimalizovat falešně negativní výsledky, může být vhodnější síť s vyšší citlivostí, jako je CNN 1.

9.3 Vyhodnocení přístupu 2

I přes maximální snahu zabránit přeučení (overfitting) a implementování několika obecně známých a fungujících metod se model vždy zastavil na validační přesnosti okolo 80%. V případě že se trénování nechalo běžet delší dobu, například po dobu 30 epoch, trénovací přesnost vždy dosahovala ke 100%, ale validační pouze 80%. Toto byly nejlepší výsledky modelu, které se s naší výpočetní kapacitou podařilo dosáhnout. K trénování byla použita stejná data, která byla použita pro trénování předešlých sítí, takže by se alo usoudit, že problém v datovém souboru nejspíše neleží. Nicméně se dá konstatovat, že architektura navržené sítě a volba zpracování vstupních dat nebyla navržena úplně špatně, protože model vykazoval rychlý nárůst trénovací přesnosti a poklesu ztrátové funkce už po zhruba 2 epochách a 100 iteracích, které zabraly přibližně 6 minut, což se dá považovat za dobrý výsledek.

Tabulka 6: Matice záměn

True Class	Predicted Class							
	S11	S5	S1	S	S11	S5	S11	S5
S11	511				1		17	
S5	11	394		2	118	14	3	58
S1	30	11	118	3	411	2	3	38
S	10			613				7
S11			1		608			1
S5	2				29	305		72
S11	1	1		1	2		609	
S5	5			4	17	13	2	59

Začneme tím, že se podíváme na diagonálu matice záměn, což představuje správně klasifikované příklady. Vidíme, že model má vysokou přesnost (tzv. accuracy) v klasifikaci většiny tříd, což je pozitivní znak. To naznačuje, že model je schopen rozpoznat a klasifikovat vzorky s vysokou úspěšností.

Nicméně, při bližším zkoumání mimo diagonálu, můžeme identifikovat určité oblasti, ve kterých model má potíže. Například, vidíme, že existují chyby v klasifikaci kombinací tříd, které představují špatné ložisko (l2) a velkou nevyváhu (n4), což může být kritické pro vibrodiagnostiku, neboť špatné ložisko s velkou nevyváhou může indikovat závažné problémy s rotujícím strojem. Tato identifikace umožňuje zaměřit se na zlepšení výkonu modelu v těchto konkrétních oblastech.

Dalším aspektem, který je důležitý pro vyhodnocení modelu, je zkoumání vlivu různých rychlostí otáčení na klasifikaci. Z matice záměn je zřejmé, že model dosahuje vysoké přesnosti při klasifikaci vzorků jak při 500 otáčkách za minutu (S5), tak i při 1100 otáčkách za minutu (S11). Tento výsledek naznačuje, že model je schopen efektivně rozpoznávat vzorky při různých rychlostech otáčení, což je klíčové pro praktické použití v reálném světě, kde se rychlosti rotujících strojů mohou měnit.

Hodnota precision je 0.884, což naznačuje, že model má relativně nízkou míru falešně pozitivních předpovědí, což je pozitivní, zejména pokud chceme minimalizovat riziko falešně diagnostikovaných problémů.

Sensitivity neboli citlivost, je míra, která udává, jak moc jsou negativní případy správně identifikovány modelem. Hodnota sensitivity je 0.819, což znamená, že model má relativně dobrou schopnost detekovat skutečné pozitivní případy. To je důležité pro vibrodiagnostiku, protože nám to umožňuje identifikovat problémy v čase, což může pomoci při prevenci poruch a opravách strojů.

Specificity neboli specifická, je míra, která udává, jak moc jsou negativní předpovědi modelu skutečně negativní. Hodnota specificity je 0.975, což ukazuje na vysokou schopnost modelu správně identifikovat skutečně negativní případy. Tato vlastnost je také klíčová pro vibrodiagnostiku, protože nám to umožňuje minimalizovat falešně pozitivní výsledky a zajistit, že nejsou přehlíženy žádné potenciální problémy.

Accuracy, neboli přesnost celková, je míra, která udává, jak moc jsou všechny předpovědi modelu správné. Hodnota accuracy je 0.823, což ukazuje na celkově dobrý výkon modelu při klasifikaci vzorků. To znamená, že model dosahuje dobré úspěšnosti při klasifikaci vzorků do správných tříd.

Celkově lze tedy říci, že natrénovaný model pro vibrodiagnostiku ložisek dosahuje solidních výsledků, přičemž je schopen správně klasifikovat většinu vzorků. Má relativně vysokou přesnost, citlivost a specifitu, což znamená, že je schopen efektivně identifikovat a klasifikovat problémy u rotujících strojích. Avšak existují určité oblasti, ve kterých by mohl být model vylepšen, zejména při klasifikaci kombinací tříd představujících špatné ložisko a velkou neváhu.

Tabulka 7: Vybrané metriky CNN modelu pro vlnovkovou transformaci

Precision	0.884
Citlivost	0.819
Specifičnost	0.975
Přesnost	0.823
F1 Skóre	0.804

10 ZÁVĚR

Diplomová práce byla rozdělena do dvou částí. V první části se zaměřovala na zavedení teorie technické diagnostiky, kterou popsala a zavedla základní pojmy a rozdělení, následným hlubším zaměřením na vibrodiagnostiku točivých strojů zařízení, kde popsala vibrační signál včetně matematického popisu a uvedla další proměnné používané pro vyhodnocování vibračního signálu. Následně se věnovala rozdělení, popisu snímačů vibrací, kdy je popsala a uvedla schémata a použití. Poté se přesunula na rešerši on-line systému pro monitoring vibrací, kde uvedla jejich důležitost pro použití v dnešním světě a výhody plynoucí z jejich použití a provedla výběr komerčně dostupných systémů, které jednotlivě popsala. Při rešerši on-line systémů se náležitě zaměřila na systém SIEMENS SIPLUS CMS, který byl použit pro praktickou část. Následoval popis metod pro získávání dodatečných informací ze signálu, které se běžně při vibrodiagnostice používají, a to rychlou Fourierovu transformaci FFT, u které bylo uvedeno nastávající změny při přechodu mezi časovou a frekvenční doménou a zavedli matematický popis pro tuto transformaci, Hilbertovu obálkovou transformaci a výpočet krest faktoru, jakožto jednoduchého identifikátoru stavu ložisek. Poté se práce věnovala zavedení teorie neuronových sítí, které byly klíčové pro splnění hlavního cíle práce. Práce zavedla formální neuron, popsala klasifikaci vzorů a uvedla aktivační funkce, kdy se následně přesunula k hlubokým neuronovým sítím a konvolučním neuronovým sítím, u kterých popsala mechanismus jejich fungování, použití a následně se věnovala jednotlivým vrstvám použitých v CNN, které byly použity pro praktickou část.

V druhé části, části praktické se práce věnovala reálnému modelu, na kterém proběhlo získání dat. Model byl složen z Programovatelného automatu SIMATIC S7-1200, osazen vibrační měřicí kartou SIPLUS CMS SM1281 spolu se senzorem zrychlení CMS VIB-Sensor S03. Model byl poháněn servomotorem, řízeným pomocí servopohonu SINAMICS V90, který roztáčel hřídel s rotorem s možností montáže neváhy a výměnným ložiskovým domečkem. Model se obsluhoval pomocí HMI dotykového panelu HMI TP700 Comfort. Následoval popis softwaru použitého v zařízení a vývojových prostředí. Byl popsán způsob získání naměřených dat přes FTP server.

Dále se práce věnovala samotnému měření, kdy zavedla metodiku a zvolila kombinace různých rychlostí (200 až 1100 ot/min), neváh (0 až 21,4 g) a ložisek (poškozené/nepoškozené), z kterých se udělala tabulka měření, která se posléze naměřila a stáhla z FTP serveru. Se získaných dat byly vytvořeny různé datasey pro vyhodnocení a natrénování neuronových sítí. Následoval návrh architektury neuronových sítí, kdy se v práci uvedly pouze 2 přístupy, protože s jinými metodami nešlo dosáhnout rozumných výsledků. První přístup bylo použití nezpracovaného signálu rozděleného do dávek po 5000 vzorcích o 32 třídách, které vstupovaly do konvolučních sítí. Bylo navrženo 5 CNN, kdy v každé další byl zmenšován počet vrstev, aby se zkoumala výkonost vůči výpočetní náročnosti. V druhém přístupu byla použita vlnkovou transformaci, kdy se data převedly do časově-frekvenčně-amplitudové oblasti a vznikl dataset obsahující 8 tříd

zobrazení, kterými následně byla natrénována CNN. Zároveň byly vyhodnoceny i jiné metriky sítí, které se běžně používají, mezi které patří matice záměn, přesnost, citlivost, specifická atd.

Následovalo vyhodnocení, kdy se první přístup velmi osvědčil a dosahoval velmi dobrých výsledků po 15 epochách při klasifikaci do 32 tříd, a to napříč rozmanitou hloubkou sítí. Nejhlubší síť dosahovala přesnosti 89,74% po 120 minutách tréninku a síť s pouze 1 konvoluční vrstvou dosáhla 75,42% po 19 minutách tréninku. Vyhodnocení druhého přístupu dopadlo podobně jako u prvního, kdy bylo použito 5 konvolučních vrstev, které dosáhly 82,3% přesnosti.

Z výsledků se dá vyvodit, že neuronové sítě jsou vhodnou metodou pro vyhodnocování datových souborů, jelikož dosahují vysoké rozlišitelnosti při klasifikaci do velkého počtu tříd při tréninku na hardwaru pro spotřebitele. Pro další pokračování práce by se dalo prozkoumat další metody neuronových sítí, jako jsou rekurentní neuronové sítě, které by mohly být také vhodné pro tento typ datových souborů. Dále by se použité metody mohly zopakovat s větším množstvím dat na výkonnějším výpočetním hardwaru.

SEZNAM POUŽITÉ LITERATURY

- [1] BILOŠ, Jan a BILOŠOVÁ, Alena. Aplikovaný mechanik jako součást týmů konstruktérů a vývojářů: studijní opora. Ostrava: Vysoká škola báňská – Technická univerzita Ostrava, Fakulta strojní, 2012. ISBN 978-80-248-2755-1.
- [2] HAMMER, Miloš. Technická diagnostika, současné trendy v technické diagnostiky [přednáška]. Brno: VUT v Brně, 5. 11. 2021.
- [3] HELEBRANT, František a ZIEGLER, Jiří. Technická diagnostika a spolehlivost. Ostrava: VŠB – Technická univerzita, 2004. ISBN 80-248-0650-9.
- [4] HAMMER, Miloš. Význam technické diagnostiky, senzory a měření – základní pojmy a terminologie [přednáška]. Brno: VUT v Brně, 29. 10. 2021.
- [5] HAMMER, Miloš. Vibrodiagnostika [přednáška]. Brno: VUT v Brně, 29. 10. 2021.
- [6] TOMEH, Elias. Technická diagnostika: vibrační diagnostika strojů a zařízení. Liberec: Technická univerzita v Liberci, 2015. ISBN 978-80-7494-174-0
- [7] SIEMENS AG. Monitoring of Machine Vibration Variables with a SIPLUS CMS1200 SM 1281 Condition Monitoring System. Online. <https://support.industry.siemens.com/>. 2020. Dostupné z: <https://support.industry.siemens.com/cs/document/109480750/monitoring-of-machine-vibration-variables-with-a-siplus-cms1200-sm-1281-condition-monitoring-system?dti=0&lc=en-CZ>. [cit. 2024-05-11]
- [8] SIEMENSAG. 109480750_CMS_SM1281_RMS_DOC_V30_en.pdf. Online. <https://support.industry.siemens.com/>. 2020. Dostupné z: <https://support.industry.siemens.com/cs/document/109480750/monitoring-of-machine-vibration-variables-with-a-siplus-cms1200-sm-1281-condition-monitoring-system?dti=0&lc=en-CZ>. [cit. 2024-05-11]
- [9] ABB [on-line] [cit. 2024-05-10]. Dostupné z: <https://new.abb.com/motors-generators/motoren-generatorservice/advanced-services/smart-sensor>
- [10] A3800 – on-line monitorovací systém [online]. Adash, 2023 [cit. 2023-04-09]. Dostupné z: <https://adash.com/cs/online-merici-systemy/a3800>
- [11] SKF [on-line] [cit. 2024-05-10]. Dostupné z: <https://www.skf.com/id/products/condition-monitoring-systems/software/aptitude-analyst>
- [11] VIBGUARD IIOT [on-line] [cit. 2024-05-11]. Dostupné z: <https://www.pruftechnik.com/en-US/Products-and-Services/Condition-Monitoring-Systems/Online-Condition-Monitoring/Online-Condition-Monitoring-Systems/VIBGUARD-IIoT/>
- [12] SIEMENS AG. [on-line] [cit. 2024-05-11]. Dostupné z: <https://support.industry.siemens.com/cs/pd/641172?ptdi=td&dl=en&lc=en-CZ>
- [13] Decomposing Fourier transforms – an introduction to time – frequency decomposition [online] [cit. 2024-05-10]. Dostupné z: <https://dibsmethodsmeetings.github.io/fourier-transforms/>

- [14] A Quantum Model for Multilayer Perceptron [on-line] [cit. 2024-05-10]. Dostupné z:
https://www.researchgate.net/figure/The-graph-of-a-perceptron-x1-xm-are-input-signals-w1-wm-are-the-weights_fig1_327392288
- [15] Perceptron [on-line] [cit. 2024-05-10]. Dostupné z:
<https://cs.wikipedia.org/wiki/Perceptron>
- [16] VOLNÁ, Eva. Neuronové sítě. Studijní opora k inovovanému předmětu: Neuronové sítě (KIP/NESI1). Ostravská univerzita v Ostravě. 2013. 86 s. ISBN 978-80-7464-329-3.
- [17] Machine Learning for Materials Developments in Metals Additive Manufacturing [on-line] [cit. 2024-05-10]. Dostupné z:
https://www.researchgate.net/publication/341310767_Machine_Learning_for_Materials_Developments_in_Metals_Additive_Manufacturing
- [18] Exploring deep learning & CNN [on-line] [cit. 2024-05-10]. Dostupné z:
<https://www.rsipvision.com/exploring-deep-learning/>
- [19] Learn about Convolutional Neural Networks [on-line] [cit. 2024-05-10]. Dostupné z:
<https://www.mathworks.com/help/deeplearning/ug/introduction-to-convolutional-neural-networks.htm>
- [20] Neural Networks [on-line] [cit. 2024-05-10]. Dostupné z:
<https://www.mathworks.com/discovery/neural-network.html>
- [21] List of deep learning layers [on-line] [cit. 2024-05-10]. Dostupné z:
<https://www.mathworks.com/help/deeplearning/ug/list-of-deep-learning-layers.html>
- [22] KHAN, Salman; RAHMANI, Hossein; SHAH, Syed Afaq Ali a BENNAMOUN, Mohammed. A Guide to Convolutional Neural Networks for Computer Vision. 2018. Morgan & Claypool Publishers, 2018. ISBN 978-1681730219.
- [23] Batch normalization explained visually [on-line] [cit. 2024-05-10]. Dostupné z:
<https://towardsdatascience.com/batch-norm-explained-visually-how-it-works-and-why-neural-networks-need-it-b18919692739>
- [24] BatchNormalizationLayer [on-line] [cit. 2024-05-10]. Dostupné z:
www.mathworks.com/help/deeplearning/ref/nnet.cnn.layer.batchnormalizationlayer.html
- [25] FullyConnectedLayer [on-line] [cit. 2024-05-10]. Dostupné z:
<https://www.mathworks.com/help/deeplearning/ref/nnet.cnn.layer.fullyconnectedlayer.html>
- [26] Siemens AG. Product overview for SIMATIC S7- 1200 [on-line]. [cit. 2024-05-10]. Dostupné z:
<https://www.siemens.com/global/en/products/automation/systems/industrial/plc/s7-1200.html>
- [27] Siemens AG. Data sheet SIMATIC HMI TP700 Comfort. [cit. 2024-05-10].
- [28] Siemens AG. Product overview for SIMATIC S7- 1200 [on-line]. [cit. 2024-05-10]. Dostupné z: <https://assets.new.siemens.com/siemens/assets/api/uuid:67cb266b-341a->

4194-86df-27a11b258647/e20001-a590-p670-x-7600-sb-sinamics-v90-starter-kit-en-72dpi.pdf

[29] Siemens AG. VIB - Sensor S03 [on-line]. [cit. 2024-05-10]. Dostupné z:

<https://mall.industry.siemens.com/mall/en/WW/Catalog/Product/6AT8008-2AA02-0AA0>

[30] MAREK, Vojtěch. *Analýza vibrací pomocí moderních on-line systémů*. Brno, 2023.

Dostupné také z: <https://www.vut.cz/studenti/zav-prace/detail/149560>. Diplomová práce. Vysoké učení technické v Brně, Fakulta strojního inženýrství, Ústav automatizace a informatiky. Vedoucí práce Miloš Hammer.

