



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA STROJNÍHO INŽENÝRSTVÍ

FACULTY OF MECHANICAL ENGINEERING

## ÚSTAV KONSTRUOVÁNÍ

INSTITUTE OF MACHINE AND INDUSTRIAL DESIGN

## VÝVOJ METODY PRO DIAGNOSTIKU OPOTŘEBENÍ KLUZNÉHO LOŽISKA

DEVELOPMENT OF A METHOD FOR DIAGNOSING WEAR IN A PLAIN BEARING

### DIPLOMOVÁ PRÁCE

MASTER'S THESIS

### AUTOR PRÁCE

AUTHOR

Bc. Filip Burk

### VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. Milan Omasta, Ph.D.

BRNO 2026





# ZADÁNÍ DIPLOMOVÉ PRÁCE

|                   |                                      |
|-------------------|--------------------------------------|
| Ústav:            | Ústav konstruování                   |
| Student:          | <b>Bc. Filip Burk</b>                |
| Studijní program: | Konstrukční inženýrství              |
| Studijní obor:    | bez specializace                     |
| Vedoucí práce:    | <b>doc. Ing. Milan Omasta, Ph.D.</b> |
| Akademický rok:   | 2025/26                              |

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

## Vývoj metody pro diagnostiku opotřebení kluzného ložiska

### Stručná charakteristika problematiky úkolu:

Kluzná ložiska nacházejí uplatnění v řadě aplikací, kde je dosahováno malé rychlosti a dynamického zatížení. Příkladem je uložení rotoru větrné elektrárny. Za těchto podmínek nelze spoléhat na plně rozvinutý hydrodynamický mazací film. Monitoring stavu povrchu ložiska a mazacího filmu je proto klíčový pro zajištění spolehlivosti chodu stroje. Akustická emise představuje metodu, která může poskytnout potřebné informace o chování a stavu pomaloběžných kluzných kontaktů.

Typ práce: výzkumná

Výstup práce: aplikovaný výsledek (Fužit, Fprum, Gprot, Gfunk, R)

Projekt: TAČR

**Cíle diplomové práce:**

Hlavním cílem práce je vývoj metody využívající akustickou emisi pro diagnostiku opotřebení kluzné vrstvy u axiálních kloubových ložisek s využitím metod strojového učení. Vývoj metody bude realizován na modelovém kluzném kontaktu za zrychleného opotřebení.

Dílčí cíle diplomové práce:

- na základě analýzy problematiky identifikovat klíčové parametry AE a definovat metodologii včetně testovatelných hypotéz,
- realizovat technickou integraci měřicího řetězce akustické emise do vybrané konfigurace tribometru,
- stanovit charakteristické vlastnosti signálu pro identifikaci tribologických jevů se zaměřením na kvantifikaci opotřebení,
- provést sérii měření pro ověření odezvy metody a vytvoření datové sady pro návrh a validaci modelu predikce opotřebení,
- kriticky zhodnotit citlivost metody vůči degradačním procesům a připravit výsledky pro publikační účely.

Požadované výstupy: průvodní zpráva.

Rozsah práce: cca 72 000 znaků (40 – 50 stran textu bez obrázků).

Časový plán, struktura práce a šablona průvodní zprávy jsou závazné:

<https://www.ustavkonstruovani.cz/texty/magisterske-studium-ukoncení/>

**Seznam doporučené literatury:**

STACHOWIAK, G. W. a A. W. BATCHELOR. Engineering tribology. 3rd ed. Boston: Elsevier Butterworth-Heinemann, 2005. ISBN 0750678364.

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2025/26

V Brně, dne

L. S.

---

prof. Ing. Martin Hartl, Ph.D.  
ředitel ústavu

---

doc. Ing. Jiří Hlinka, Ph.D.  
děkan fakulty

## ABSTRAKT

Segmentová kluzná ložiska s kompozitními PTFE povlaky tvoří kritický tribologický uzel v uložení hlavní hřídele offshore větrných elektráren, kde sférická geometrie segmentů kompenzuje nesouosost hřídele při přenosu vysokého axiálního zatížení. Progresivní frettingové opotřebení povlaku způsobované oscilačním pohybem hřídele ohrožuje integritu celé sestavy a absence metody pro predikci zbytkové tloušťky povlaku v reálném čase znemožňuje přejít od reaktivní k plánované prediktivní údržbě. Za účelem řešení tohoto problému bylo provedeno 18 tribologických zkoušek na modulárním rotačním tribometru s axiálním zatěžováním v nekonformní čtyřkuličkové konfiguraci simulující akcelerované opotřebení; signál AE byl vzorkován na frekvenci 1 MHz a z každého datového bloku byly extrahovány příznaky zachycující statistické a frekvenční charakteristiky signálu spolu s provozními podmínkami kontaktu. Bylo implementováno, optimalizováno a vyhodnoceno na nezávislé testovací sadě pět architektur hlubokého učení - MLP, RNN, LSTM, GRU a hybridní CNN-GRU. Architektura CNN-GRU dosáhla nejlepší predikční přesnosti s koeficientem determinace  $R^2 = 0,838$ ; SHAP analýza identifikovala kumulativní RMS signálu akustické emise jako jeden z nejvýznamnějších příznaků. Paralelní charakterizace útlumu metodou Hsu-Nielsenových zdrojů prokázala, že intenzita signálu AE systematicky roste s klesající tloušťkou povlaku v obou kontaktních geometriích - konformní i nekonformní. Výsledky dokládají životaschopnost diagnostického přístupu kombinujícího AE s rekurentními neuronovými sítěmi pro kvantitativní predikci opotřebení PTFE povlaků a zakládají teoretický základ pro přenos metody do provozních podmínek.

## KLÍČOVÁ SLOVA

akustická emise, predikce opotřebení, hluboké učení, tribologie, kluzné ložisko

## ABSTRACT

Segment plain bearings with composite PTFE coatings serve as critical tribological components in the main shaft support of offshore wind turbines, where the spherical geometry of the segments compensates for shaft misalignment under high axial loading. Progressive fretting wear of the coating driven by oscillatory shaft motion threatens the integrity of the entire assembly, and the absence of a real-time method for predicting residual coating thickness prevents the transition from reactive to planned predictive maintenance. To address this, 18 tribological tests were conducted on a modular rotational tribometer with axial loading in a non-conforming four-ball configuration simulating accelerated wear; the AE signal was sampled at 1 MHz and features capturing the statistical and frequency characteristics of the signal along with contact operating conditions were extracted from each data block. Five deep learning architectures - MLP, RNN, LSTM, GRU and a hybrid CNN-GRU - were implemented, optimised and evaluated on an independent test set. The CNN-GRU architecture achieved the best predictive performance with a coefficient of determination  $R^2 = 0,838$ ; SHAP analysis identified cumulative acoustic emission RMS as one of the most significant feature. Parallel attenuation characterisation using the Hsu-Nielsen source method demonstrated that AE signal intensity increases systematically with decreasing coating thickness, in both conforming and non-conforming contact geometry. The results demonstrate the viability of a diagnostic approach combining AE with recurrent neural networks for quantitative prediction of wear in PTFE coatings and establish a theoretical foundation for transfer of the method to operational conditions.

## KEYWORDS

acoustic emission, wear prediction, deep learning, tribology, plain bearing





## BIBLIOGRAFICKÁ CITACE

BURK, Filip. *Vývoj metody pro diagnostiku opotřebení kluzného ložiska*. Online, diplomová práce. Milan OMASTA (vedoucí práce). Brno: Vysoké učení technické v Brně, Fakulta strojního inženýrství, 2026. Dostupné z: <https://www.vut.cz/studenti/zav-prace/detail/170563>. [cit. 2026-05-17].



## PODĚKOVÁNÍ

Tímto děkuji vedoucímu práce doc. Ing. Milanu Omastovi Ph.D. za vedení a mentorování v průběhu vypracovávání této práce. Dále děkuji rodině, partnerce a přátelům za podporu při studiu.

## PROHLÁŠENÍ AUTORA O PŮVODNOSTI PRÁCE

Prohlašuji, že diplomovou práci jsem vypracoval samostatně, pod odborným vedením doc. Ing. Milana Omasty Ph.D. současně prohlašuji, že všechny zdroje obrazových a textových informací, ze kterých jsem čerpal, jsou řádně citovány v seznamu použitých zdrojů.




.....

Podpis autora

## PROHLÁŠENÍ O POUŽITÍ NÁSTROJŮ UMĚLÉ INTELIGENCE

Prohlašuji, že při zpracování diplomové práce jsem využil nástrojů umělé inteligence, konkrétně jazykových modelů Claude Sonnet 4.6 (Anthropic) a Gemini 2.5 Pro (Google), a to výhradně jako pomocných prostředků pro formátování a jazykovou úpravu textu a sepisování částí kódu. Veškerý odborný obsah, výzkumná data, analýzy a závěry jsou výsledkem mé vlastní práce. Zodpovědnost za správnost a původnost předkládaného díla nesu v plném rozsahu já jako autor.



.....  
Podpis autora



# OBSAH

|                                                                         |           |
|-------------------------------------------------------------------------|-----------|
| <b>ZADÁNÍ DIPLOMOVÉ PRÁCE</b>                                           | <b>4</b>  |
| <b>ABSTRAKT</b>                                                         | <b>6</b>  |
| <b>KLÍČOVÁ SLOVA</b>                                                    | <b>6</b>  |
| <b>ABSTRACT</b>                                                         | <b>7</b>  |
| <b>KEYWORDS</b>                                                         | <b>7</b>  |
| <b>BIBLIOGRAFICKÁ CITACE</b>                                            | <b>9</b>  |
| <b>PODĚKOVÁNÍ</b>                                                       | <b>11</b> |
| <b>PROHLÁŠENÍ AUTORA O PŮVODNOSTI PRÁCE</b>                             | <b>11</b> |
| <b>PROHLÁŠENÍ O POUŽITÍ NÁSTROJŮ UMĚLÉ INTELIGENCE</b>                  | <b>12</b> |
| <b>OBSAH</b>                                                            |           |
| <b>1 ÚVOD</b>                                                           | <b>18</b> |
| <b>2 PŘEHLED SOUČASNÉHO STAVU POZNÁNÍ</b>                               | <b>20</b> |
| 2.1 Otázky a cíle pro systematickou rešerši                             | 20        |
| 2.2 Rešeršní metody                                                     | 21        |
| 2.3 Teoretické základy akustické emise                                  | 22        |
| 2.3.1 Definice a fyzikální podstata AE                                  | 22        |
| 2.3.2 Zdroje akustické emise                                            | 23        |
| 2.3.3 Šíření a útlum elastických vln                                    | 26        |
| 2.3.4 Snímání a digitalizace signálu                                    | 29        |
| 2.3.5 Hsu-Nielsenův test (Pencil Lead Break)                            | 31        |
| 2.3.6 Parametry signálu                                                 | 31        |
| 2.4 Akustická emise v tribologii                                        | 33        |
| 2.4.1 Vztah AE s třecími mechanismy                                     | 33        |
| 2.4.2 Korelace AE s třením a opotřebením                                | 33        |
| 2.4.3 Diagnostika mazacích režimů a specifika vysoce zatížených uložení | 34        |
| 2.5 Identifikace mechanismů opotřebením                                 | 34        |
| 2.5.1 Frekvenční analýza tribologických jevů                            | 34        |
| 2.5.2 Statistické momenty a typologie signálu v časové oblasti          | 35        |

|            |                                                                                          |           |
|------------|------------------------------------------------------------------------------------------|-----------|
| 2.5.3      | Detekce přechodových stavů opotřebení                                                    | 36        |
| <b>2.6</b> | <b>Strojové učení pro tribodiagnostiku z akustické emise</b>                             | <b>36</b> |
| 2.6.1      | Algoritmy vyhlazování dat                                                                | 37        |
| 2.6.2      | Normalizace dat a prevence úniku informací                                               | 38        |
| 2.6.3      | Analýza architektur hlubokého učení pro 1D časové řady                                   | 39        |
| 2.6.4      | Regularizace a interpretabilita modelů v režimu omezených dat                            | 42        |
| 2.6.5      | Transformace a regrese z 2D časově-frekvenčních domén                                    | 43        |
| <b>2.7</b> | <b>Vývoj a technická omezení modulárního rotačního tribometru s axiálním zatěžováním</b> | <b>43</b> |
| <b>2.8</b> | <b>Analýza současného stavu poznání</b>                                                  | <b>44</b> |
| <b>3</b>   | <b>CÍL PRÁCE</b>                                                                         | <b>46</b> |
| 3.1        | Cíle práce                                                                               | 46        |
| 3.2        | Výzkumné otázky a hypotézy                                                               | 46        |
| <b>4</b>   | <b>MATERIÁL A METODY</b>                                                                 | <b>48</b> |
| <b>4.1</b> | <b>Metodika</b>                                                                          | <b>49</b> |
| 4.1.1      | Predikce opotřebení ve 4-ball konfiguraci (H1)                                           | 49        |
| 4.1.2      | Charakterizace útlumu (H2)                                                               | 50        |
| <b>4.2</b> | <b>Materiál a testovací podmínky</b>                                                     | <b>50</b> |
| 4.2.1      | Charakteristika testovaného vzorku                                                       | 50        |
| 4.2.2      | Testovací podmínky                                                                       | 52        |
| <b>4.3</b> | <b>Experimentální zařízení a přístrojové vybavení</b>                                    | <b>54</b> |
| 4.3.1      | Technicko-funkční návrh měřicí konfigurace                                               | 54        |
| 4.3.2      | Spodní část konfigurace                                                                  | 56        |
| 4.3.3      | Horní část konfigurace                                                                   | 59        |
| 4.3.4      | Měření třecí síly                                                                        | 60        |
| 4.3.5      | Upnutí motoru                                                                            | 61        |
| 4.3.6      | Modifikace sestavy pro charakterizaci útlumu (H2)                                        | 62        |
| 4.3.7      | Měřicí řetězec a akviziční systém                                                        | 63        |
| <b>4.4</b> | <b>Metody</b>                                                                            | <b>64</b> |
| 4.4.1      | Metodika experimentu a měření opotřebení                                                 | 64        |
| 4.4.2      | Metodika akvizice a digitálního zpracování dat                                           | 66        |
| 4.4.3      | Digitální zpracování signálu a extrakce příznaků                                         | 66        |
| 4.4.4      | Předzpracování dat a tvorba datasetu                                                     | 68        |
| 4.4.5      | Implementace modelů hlubokého učení                                                      | 70        |
| 4.4.6      | Metrika hodnocení predikcí                                                               | 71        |
| 4.4.7      | Strategie ladění a optimalizace modelů                                                   | 73        |

|          |                                                                             |            |
|----------|-----------------------------------------------------------------------------|------------|
| 4.4.8    | Metoda pro charakterizaci útlumu AE (H2)                                    | 74         |
| 4.4.9    | Softwarové nástroje pro akvizici a zpracování dat (H2)                      | 76         |
| 4.4.10   | Metodika ověření přenositelnosti signálu v nekonformní konfiguraci (4-ball) | 78         |
| <b>5</b> | <b>VÝSLEDKY</b>                                                             | <b>80</b>  |
| 5.1      | Výsledky predikce neuronových sítí (H1)                                     | 80         |
| 5.1.1    | Dopředná neuronová síť (MLP – Baseline model)                               | 80         |
| 5.1.2    | Rekurentní neuronová síť v konfiguraci Many-to-Many (RNN M2M)               | 83         |
| 5.1.3    | Rekurentní neuronová síť LSTM                                               | 85         |
| 5.1.4    | Rekurentní neuronová síť GRU                                                | 88         |
| 5.2      | Charakterizace útlumu v závislosti na tloušťce vrstvy (H2)                  | 91         |
| 5.2.1    | Hybridní model CNN-GRU                                                      | 91         |
| 5.2.2    | Analýza amplitudových a energetických parametrů                             | 93         |
| 5.2.3    | Analýza strukturálních parametrů a jev stagnace                             | 95         |
| 5.2.4    | Výsledky ověření přenositelnosti signálu v nekonformní konfiguraci (4-ball) | 96         |
| <b>6</b> | <b>DISKUZE</b>                                                              | <b>101</b> |
| 6.1      | Interpretace výsledků                                                       | 101        |
| 6.1.1    | Korelace AE s intenzitou tribologického procesu                             | 101        |
| 6.1.2    | Frekvenční charakterizace signálu a spektrální příznaky                     | 102        |
| 6.1.3    | Výkonnostní hierarchie architektur neuronových sítí                         | 103        |
| 6.1.4    | Materiálový útlum a impedanční diskontinuita polymerního povlaku            | 104        |
| 6.1.5    | Statistická charakterizace signálu – jev stagnace Kurtosis a Duration       | 105        |
| 6.1.6    | Přenositelnost konfigurace na konformní geometrii kontaktu                  | 106        |
| 6.1.7    | Implementace systému pro diagnostiku kluzné vrstvy                          | 107        |
| 6.2      | Verifikace hypotéz                                                          | 108        |
| 6.2.1    | Hypotéza H1                                                                 | 108        |
| 6.2.2    | Hypotéza H2                                                                 | 109        |
| 6.3      | Limity studie                                                               | 110        |
| 6.3.1    | Omezení datasetu a generalizační schopnosti modelů                          | 110        |
| 6.3.2    | Riziko přeučení a informačního úniku                                        | 111        |
| 6.3.3    | Interpretace významu kumulativních příznaků                                 | 111        |
| 6.3.4    | Omezení přenositelnosti do provozních podmínek                              | 112        |
| <b>7</b> | <b>ZÁVĚR</b>                                                                | <b>113</b> |
| <b>8</b> | <b>VÝSLEDEK VÝZKUMU PODLE RIV</b>                                           | <b>115</b> |
| <b>9</b> | <b>SEZNAM POUŽITÝCH ZDROJŮ</b>                                              | <b>116</b> |



|           |                                                    |            |
|-----------|----------------------------------------------------|------------|
| <b>10</b> | <b>SEZNAM POUŽITÝCH ZKRATEK, SYMBOLŮ A VELIČIN</b> | <b>120</b> |
| 10.1      | Seznam použitých zkratek                           | 120        |
| 10.2      | Seznam použitých symbolů                           | 121        |
| 10.3      | Seznam použitých veličin                           | 122        |
| <b>11</b> | <b>SEZNAM OBRÁZKŮ A GRAFŮ</b>                      | <b>123</b> |
| <b>12</b> | <b>SEZNAM TABULEK</b>                              | <b>126</b> |
| <b>13</b> | <b>SEZNAM PŘÍLOH</b>                               | <b>127</b> |

# 1 ÚVOD

Segmentová kluzná ložiska s kompozitními PTFE povlaky představují klíčový tribologický uzel v uložení hlavní hřídele větrných elektráren - zejména offshore instalací vyšší výkonové třídy, kde výměna poškozeného ložiska vyžaduje nákladnou jeřábovou techniku a způsobuje výpadky výroby v délce týdnů. Kluzné segmenty jsou konstruovány jako dělené a sférické, což jim umožňuje jednak snadnou výměnu přímo ve strojovně gondoly, jednak kompenzaci úhlové nesouososti hřídele při přenosu vysokého axiálního zatížení. Dominantním mechanismem poškození povlaku je fretting - opotřebení vzniklé oscilačním mikropohybem kontaktních ploch pod vysokým normálovým zatížením, způsobovaným turbulentní povahou větrného pole a cyklickými změnami výkonu turbíny. Absence spolehlivé metody pro predikci zbytkové tloušťky povlaku v reálném čase znemožňuje přejít od reaktivní k plánované prediktivní údržbě, a právě tuto mezeru adresuje předkládaná práce.

Metoda akustické emise (AE) umožňuje bezkontaktně sledovat degradační procesy přímo v průběhu provozu, neboť senzory AE zachycují přechodné elastické vlny generované při tření povrchů, praskání výztužných vláken kompozitu a při přechodech mezi opotřebovacími režimy. Ve srovnání s tradičními diagnostickými přístupy, jako jsou vibrační analýza nebo periodická vizuální kontrola, nabízí AE vyšší citlivost na počáteční stádia poškození a nevyžaduje odstavení zařízení. Publikované práce potvrzují, že energetické a frekvenční parametry signálu AE korelují s intenzitou tribologického procesu u kovových i polymerních kontaktů. Specifickým rysem polymerních vrstev je jejich tlumicí účinek na šíření elastických vln, jehož intenzita závisí na tloušťce vrstvy - skutečnost dosud systematicky necharakterizovaná pro kompozitní kluzné povlaky v axiálně zatěžívaných uzlech.

Přímá predikce míry opotřebení z AE signálu nicméně představuje netriviální úlohu. Surový signál je stochastický, nelineární a vysoce dimenzionální; konvenční prahové metody nejsou schopny spolehlivě zachytit složité vazby mezi příznaky signálu a okamžitým stavem opotřebení. Metody hlubokého učení, zejména rekurentní architektury (LSTM, GRU) schopné modelovat sekvenční charakter degradace, prokázaly v posledních letech slibné výsledky při predikci opotřebení tribologických systémů. Klíčovou výzvou, dosud nedostatečně adresovanou v literatuře, zůstává sestavení robustního end-to-end diagnostického řetězce pro polymerní kluzné vrstvy - od akvizice surového signálu AE přes extrakci příznaků až po validaci predikčního modelu na reálných experimentálních datech.

Tato práce se zabývá vývojem diagnostického řetězce pro predikci opotřebení kompozitní kluzné vrstvy sférického kloubu GE20-AW s využitím signálu AE a hlubokého učení. Výzkum je veden prostřednictvím dvou paralelních hypotéz: H1 postuluje, že intenzita tribologického procesu se projevuje v měřitelných parametrech AE a lze ji využít jako vstup pro predikci úbytku materiálu; H2 předpokládá, že tloušťka polymerní vrstvy systematicky ovlivňuje útlum přenášeného signálu AE. K ověření H1 bylo provedeno 18 tribologických zkoušek na modulárním rotačním tribometru v nekonformní konfiguraci čtyř kuliček s

Bayesovsky optimalizovanými modely MLP, RNN, LSTM, GRU a CNN-GRU; k ověření H2 byla využita metoda Hsu-Nielsenových zdrojů ve dvou kontaktních geometriích. Práce přináší kvantitativní srovnání predikční přesnosti jednotlivých architektur, analýzu klíčových příznaků metodou SHAP a výsledky charakterizace útlumu v závislosti na tloušťce povlaku.

## 2 PŘEHLED SOUČASNÉHO STAVU POZNÁNÍ

Komplexní uchopení řešené problematiky vyžaduje nejprve precizní definování metody akustické emise (AE). Následující text proto přibližuje teoretické základy této metody, fyzikální principy šíření vln a specifika jejich využití v oblasti tribodiagnostiky. Detailní popis vztahu mezi procesem opotřebení a odezvou signálu u různých typů materiálů nastíní možnosti identifikace konkrétních degradačních režimů, kterých lze dosáhnout vhodným zpracováním surových dat. Tato schopnost monitoringu byla v řadě publikovaných studií experimentálně ověřena právě u kluzných prvků s polymerními či kompozitními vrstvami, kde AE dovoluje citlivě sledovat jevy jako praskání výztužných vláken nebo kritický přechod z kluzného povlaku na kovový substrát. Jelikož se snímáný signál projevuje jako stochastický šum s diskrétními impulsy, věnuje se další část rešerše moderním metodám jeho vyhodnocení pomocí neuronových sítí, které představují v současnosti nejúčinnější nástroj pro automatizovanou klasifikaci stavu a predikci životnosti. Rešerši uzavírá popis vývoje a technických omezení modulárního rotačního tribometru s axiálním zatěžováním a syntéza identifikovaných mezer v současném stavu poznání, které tato práce adresuje.

### 2.1 Otázky a cíle pro systematickou rešerši

Užitím akustické emise pro měření povlakovaných segmentových ložisek vzniká nutnost nejprve zanalyzovat a vyzkoušet reakci jednotlivých povlaků na poškození vznikající v kontaktu segmentového ložiska. Dále pak zvolit vhodné parametry signálu a vyhodnocovací metody pro správnou interpretaci výsledků.

Smysl této systematické rešerše je tedy zvolení adekvátního přístupu k testování a vyhodnocení jednotlivých povlaků. Povlaky bývají z kombinací speciálních polymerů jako například PTFE s aditivy, kovových slitin jako například Karbid-chrom nebo speciální povlaky DLC, které jsou v posledních letech velmi popularizovány pro své vlastnosti vysoké odolnosti a tvrdosti při zachování poměrně nízkého koeficientu tření. Jedná se tedy o škálu materiálů různých tvrdostí, pevností a elastických chování. Ne všechny povlaky budou svými vlastnostmi přívětivé k šíření vln AE. Měla by být tedy snaha zanalyzovat práce zabývající se simulacemi šíření elastických vln v těchto materiálech nebo najít praktické práce testující s těmito materiály.

**1. Co bude moct signál Akustické emise vypovědět o monitorování poškození ložiska?**

Zvolení správných měřených parametrů akustické emise, které budou s největší pravděpodobností moct vypovědět o průběhu poškození ložiska. Nalézt parametry, které bude ovlivňovat změna v opotřebení, tření či dalších významných parametrech.

**2. Jak výraznou roli bude hrát typ povlaku ložiska pro šíření vln?**

Zjištění chování stejných nebo podobných materiálů použitých na povlaky. Nalézt teoretické přístupy k výpočtu šíření vln v testovaných materiálech.

**3. Jaké existují metody zpracování signálu AE pro identifikaci poškození kluzných kontaktů?**

Zvolení správných analytických metod pro správné vyhodnocení signálu AE a dosažení vytyčených cílů.

## 2.2 Rešeršní metody

Z výše uvedených rešeršních dotazů byly vytvořeny ekvivalentní formulace pro zadání na stránkách Scopus a Web of Science. Na základě relevantnosti obsahu a faktorů jako je H-index nebo IF faktor, byly z jednotlivých článků byly vybrány ty nejvhodnější. K rešeršním dotazům pak byly přidány i další články. Ty byly nejčastěji nalezeny při průběžné rešerši tématu akustické emise a svými specifikacemi se hodily do některého rešeršního dotazu. Na základě Rešeršních dotazů byl vytvořen PRISMA diagram pro snadnější orientaci při rozřazování článků k jednotlivým rešeršním dotazům.

**Rešeršní dotaz 1.**


((acoustic AND emission) OR (acoustic AND signal)) AND (\*experiment\*) AND (damage OR wear) AND (monitoring OR observation) AND (bearing OR bushing) AND propagation AND NOT (cement OR concrete OR pipe OR pipeline OR rock)

**Rešeršní dotaz 2.**

(acoustic AND emission) AND (transmission OR propagation) AND ((stress OR elastic) AND wave) AND material AND polymer AND NOT (concrete OR pipe OR pipeline)

**Rešeršní dotaz 3.**

(acoustic AND emission) AND data AND (processing OR analysis OR interpretation) AND (wear OR friction OR fretting) AND sliding AND NOT (concrete OR pipe OR pipeline)



Obr. 2-1: Rešeršní struktura diplomové práce

## 2.3 Teoretické základy akustické emise

### 2.3.1 Definice a fyzikální podstata AE

#### Historický kontext

Pojem akustická emise se v odborné literatuře poprvé objevil v souvislosti s výzkumem plastické deformace kovů v laboratorním prostředí. Původně čistě vědecký zájem o sledování pohybu dislokací a deformací krystalické mřížky se postupně transformoval v robustní diagnostickou metodu využívanou v širokém spektru průmyslových odvětví. Zatímco v počátcích byla metoda spojována především s hodnocením integrity velkorozměrových konstrukcí, jako jsou tlakové nádoby či mostní objekty, v posledních letech nachází své nezastupitelné místo při sledování dynamických procesů v tribologických uzlech [1].

## Akustická emise jako fyzikální jev

Z fyzikálního hlediska je tento jev definován jako generování přechodných elastických vln, které vznikají v důsledku rychlého uvolnění energie z lokalizovaných zdrojů uvnitř materiálu. Tyto signály jsou vyvolány náhlými nestabilitami v mikrostruktuře, ke kterým dochází vlivem nevratných změn. Mezi primární zdroje patří zejména plastická deformace, iniciace a propagace trhlin či fázové transformace v krystalické mřížce. V kontextu tribologie jsou pak klíčovými zdroji interakce nerovností povrchů při tření a vznik otěrových částic. Energie uvolněná v místě zdroje se následně transformuje do mechanického napětového pulzu, který se šíří materiálem ve formě sférických objemových či povrchových elastických vln směrem k povrchu tělesa.

## Akustická emise jako metoda NDT

Na základě popsaného fyzikálního principu byla vyvinuta metoda zkoušení akustickou emisí (AT – Acoustic Emission Testing), která v oblasti nedestruktivního testování (NDT) zaujímá unikátní postavení. Od tradičních metod, jako jsou ultrazvuk (UT) nebo rentgenografie (RT), se fundamentálně liší svým pasivním charakterem. Zatímco zmíněné aktivní metody do materiálu energii vysílají, senzory AE pouze naslouchají zvukům generovaným samotným materiálem v reakci na vnější mechanické či tepelné působení [1]. Zásadní rozdíl spočívá rovněž v detekci dynamických dějů v reálném čase; zatímco ultrazvuk identifikuje statické geometrické anomálie, metoda AE dokáže zaznamenat proces vzniku poškození přímo v momentě jeho propagace. Metoda je navíc integrální, což znamená, že senzory umístěné na povrchu dokážou monitorovat celý objem součásti současně, nikoliv pouze lokální místo pod sondou.

## Přenosový řetězec a citlivost metody

Samotné fungování metody je podmíněno existencí kontinuální přenosové trasy, která zahrnuje cestu signálu od jeho zdroje přes přenosové médium, jako je těleso ložiska či hřídel, až k povrchu, kde je zachycen piezoelektrickým snímačem. Vysoká citlivost celého diagnostického řetězce spočívá ve schopnosti detekovat mikroskopické posuny v materiálu v řádu nanometrů, které vyvolávají měřitelné makroskopické elastické vlny. Právě tato schopnost identifikovat počáteční stadia degradace ještě před vznikem viditelných poškození činí z akustické emise ideální nástroj pro prediktivní údržbu a moderní tribodiagnostiku.


### 2.3.2 Zdroje akustické emise

Pro správnou interpretaci dat je nezbytné pochopit, jaký typ události v materiálu generuje konkrétní formy signálu. Zdroje akustické emise lze klasifikovat podle časového průběhu uvolněné energie a podle fyzikální podstaty mechanismu porušení.

## Klasifikace signálu: Spojitá a nárazová emise

Z hlediska makroskopického pozorování a tvaru vlnového průběhu (waveform) rozlišujeme dva základní typy akustické emise [1, 2].

Prvním typem je nárazová emise (Burst Emission) Obr. 2-2. Tento signál je generován diskrétními, vysokoenergetickými událostmi, které mají velmi krátké trvání v řádech mikrosekund. Signál má charakteristický tvar tlumené oscilace s ostrým náběhem (rise time) a následným exponenciálním poklesem amplitudy. Fyzikálním zdrojem těchto rázů je typicky vznik a skokové šíření trhliny, lom vmětku nebo dopad cizího tělesa. V kontextu tribologie je nárazová emise nejčastěji spojena s průchodem větší abrazivní částice kontaktní zónou, případně s delaminací povrchové vrstvy. Výskyt těchto signálů, kvantifikovaný jako počet hitů (Hits), obvykle indikuje vznik nevratného poškození materiálové struktury a přímo koreluje s aktivitou deformačního mechanismu.



Obr. 2-2: Nárazová akustická emise s popisem [3]

Druhým typem je spojitá emise (Continuous Emission). K té dochází v případě, kdy je generován rychlý sled velkého množství nízkoenergetických událostí, které se v čase vzájemně překrývají. Jednotlivé rázové vlny tak splývají do jednoho nepřetržitého signálu bez rozeznatelných počátků a konců, který svým charakterem připomíná šum s proměnlivou amplitudou. Zdrojem spojité emise je na mikroskopické úrovni hromadný pohyb dislokací (plastická deformace) nebo dynamika tekutin (turbulence). V tribodiagnostice je však spojitá emise primárním nositelem informací o tření. Její intenzita, vyjádřená efektivní hodnotou (RMS), úzce souvisí se stavem mazacího filmu a drsností povrchů. Nárůst amplitudy spojité emise tak často slouží jako včasný indikátor přechodu do režimu mezního mazání [1].



## Mikromechanismy vzniku AE

Podle Nazarchuka [4] lze vznik akustické emise přirovnat k náhlému porušení vnitřní rovnováhy materiálu. Představme si, že vnitřní struktura materiálu je protkána neviditelnou sítí sil – tzv. napěťovým polem. Pokud v materiálu dojde k lokální změně (např. prasknutí vlákna nebo posunu krystalické mřížky), toto pole se musí v daném místě okamžitě „přeskupit“ (redistribuovat), aby našlo novou rovnováhu. Pokud je tato reorganizace vnitřního napětí dostatečně rychlá, uvolní se přebytečná energie ve formě mechanického impulsu. Je však důležité zdůraznit, že ne každá deformace generuje měřitelný signál. Aby emise vznikla, musí být proces dostatečně dynamický a uvolněná energie natolik silná, aby dokázala rozkmitat strukturu tělesa v celém jeho objemu.


Na úrovni krystalické mřížky jsou primárními nositeli tohoto děje dislokace. Jakmile vnější zatížení překročí mez kluzu, dochází k jejich lavinovitému pohybu, často iniciovanému aktivací Frank-Readových zdrojů. Tento mechanismus, úzce spjatý s plastickou deformací, produkuje zpravidla nízkoeenergetickou, spojitou emisi. Charakter výsledného signálu je však silně determinován mechanickými vlastnostmi dané látky. Materiály s vysokou pevností a křehkou strukturou generují výraznější AE, protože se v nich elastická energie uvolňuje nárazově. Naproti tomu u tvárných materiálů dochází k postupnému „tečení“ (viskóznímu tlumení), při kterém se značná část energie pohltí vnitřním třením. Deformační proces je v takovém případě z hlediska akustické odezvy výrazně „tišší“ [4].

Energeticky nejvýznamnějším zdrojem je pak vznik a šíření trhliny. Z fyzikálního hlediska je tento děj definován jako náhlé vytvoření nového volného povrchu uvnitř materiálu. V okamžiku lomu dochází k okamžité relaxaci elastického napětí v okolí čela trhliny. Tato náhlá změna rovnováhy uvolní přebytečnou elastickou energii ve formě vlnění o vysoké amplitudě. U povlakovaných ložisek je tento mechanismus typický pro únavové vydrolování (pitting) nebo odtržení povlaku od substrátu [2].

### Kaiserův a Felicity efekt

Při periodickém či cyklickém namáhání materiálů se projevují specifické jevy související s vnitřní „pamětí“ struktury, které v diagnostice AE hrají klíčovou roli při hodnocení stability poškození.

Prvním z nich je Kaiserův efekt (viz Obr. 2-3), popsáný Josephem Kaiserem v roce 1950, který definuje princip nevratnosti akustické emise. Tento jev stanovuje, že materiál, který byl v minulosti vystaven určité úrovni zatížení, nebude při opětovném namáhání generovat žádnou detekovatelnou emisi, dokud aktuální hladina zatížení nepřekročí předchozí maximální hodnotu  $F_{max}$ . Fyzikální podstatou je vyčerpání dostupných zdrojů emise (např. stabilizace polohy dislokací nebo dočasné zastavení růstu trhliny) během primárního cyklu. Pokud je materiál strukturálně stabilní, zůstává v oblasti pod předchozím maximem akusticky neaktivní [2].



Obr. 2-3: Kaiserův efekt [4]

V případě, že v materiálu dochází k významné progresi poškození, Kaiserův efekt přestává platit a nastupuje tzv. Felicity efekt. Akustická emise se v takovém scénáři začíná objevovat již při zatížení nižším, než bylo předchozí dosažené maximum. Tento jev indikuje rozvoj strukturálních změn, jako je růst únavových trhlin nebo degradace polymerní matrice, i při nižších energetických hladinách. Pro kvantifikaci závažnosti tohoto stavu se využívá tzv. Felicity Ratio (FR), definované vztahem:

$$FR = \frac{F_{AE}}{F_{max}} \quad (2-1)$$

kde  $F_{AE}$  představuje zatížení, při kterém se znovu objevila emise, a  $F_{max}$  je maximální zatížení z předchozího cyklu. Hodnota  $FR < 1$  (v praxi typicky pod hranicí 0,95) je v tribodiagnostice považována za varovný signál strukturální nestability, který může předcházet katastrofickému selhání ložiska [2].


### 2.3.3 Šíření a útlum elastických vln

Proces uvolnění energie v místě zdroje iniciuje šíření elastické vlny materiálem. Charakter tohoto děje je determinován geometrií součásti, materiálovými vlastnostmi a fundamentálními fyzikálními zákony vlnění. Je nezbytné zdůraznit, že signál zachycený senzorem na povrchu tělesa je vždy modifikovanou verzí původního impulzu. Pro korektní interpretaci naměřených dat je proto klíčové porozumět mechanismům transformace vlnových módů a příčinám energetických ztrát během přenosu signálu.

## Objemové vlnové módy

V pevných látkách se elastické vlnění nešíří jako homogenní entita, ale rozpadá se do několika specifických módů, které se liší směrem kmitání částic a rychlostí šíření. V nekonečném izotropním prostředí (uvnitř masivního materiálu) dominují tzv. objemové vlny, které dělíme na longitudinální a transverzální.

Primárním módem jsou vlny longitudinální (podélné, tlakové), u nichž částice materiálu kmitají rovnoběžně se směrem šíření vlny ve formě cyklického zhušťování a zředňování hmoty (viz Obr. 2-4 vlevo). Jedná se o nejrychlejší typ vln, které k senzoru dorazí jako první. Sekundárním módem jsou vlny transverzální (příčné, stříhové), kde částice kmitají kolmo na směr šíření (viz Obr. 2-4 vpravo). Tyto vlny dosahují přibližně 60 % rychlosti vln podélných a jejich šíření je omezeno výhradně na pevná skupenství [2, 4].



Obr. 2-4: vlevo) Schématické šíření longitudinálních vln; vpravo) Schématické šíření transverzálních vln, a) Horizontálně polarizovaná vlna, b) Vertikálně polarizovaná vlna [4]

## Povrchové a deskové vlny

V praktických technických aplikacích, kde jsou snímače umístěny na vnějším povrchu součástí, hrají dominantní roli vlny povrchové, známé jako Rayleighovy vlny. Vznikají interakcí objemových vln s volným povrchem materiálu a zasahují do hloubky odpovídající přibližně jedné vlnové délce. Částice při nich vykonávají eliptický pohyb proti směru šíření. Ačkoliv je jejich rychlost nižší než u vln transverzálních (cca 90 %), jejich význam pro diagnostiku je kritický. Energie povrchových vln totiž klesá se vzdáleností výrazně pomaleji než u vln objemových, což z nich činí hlavní nositele informace při měření na větší vzdálenosti od zdroje [2, 4].

Specifickým případem jsou vlny deskové (Lambovy vlny), které se šíří v tělesech se dvěma rovnoběžnými volnými povrchy. Jako tenkostěnné konstrukce jsou v tomto kontextu klasifikovány objekty typu plechů, trubek či skořepinových komponent, jejichž tloušťka je typicky 3 až 5 mm nebo méně. Pokud je tloušťka materiálu srovnatelná s vlnovou délkou signálu, dochází ke vzniku složitých vlnových módů, které jsou definovány jako normální vlny transportující energii podél struktury. Tyto vlny se dělí na symetrické a asymetrické a

vykazují výrazný disperzní charakter, což znamená, že jejich rychlost šíření je závislá na frekvenci. Tento jev vede k postupné deformaci tvaru impulsu a jeho rozplývání v čase během šíření materiálem. [4].

### Rychlost šíření a vliv materiálu

Rychlost šíření informace o poškození materiálem je dána jeho fyzikálními konstantami. Konkrétně jde o modul pružnosti ( $E$ ) a hustotu ( $\rho$ ). případně Poissonovo číslo ( $\nu$ ). Pro longitudinální vlnu v neomezeném prostředí platí vztah [2]:

$$c_L = \sqrt{\frac{E(1-\nu)}{\rho(1+\nu)(1-2\nu)}} \quad (2-2)$$

Z tohoto vztahu vyplývá zásadní rozdíl pro tribodiagnostiku různých materiálů. V konstrukční oceli se rychlost podélných vln pohybuje okolo 5 900 m/s. Naproti tomu v polymerních materiálech, jako jsou kompozitní vložky kluzných ložisek, je modul pružnosti řádově nižší. To vede k výrazně nižší rychlosti šíření, typicky v rozsahu 2 000 – 2 500 m/s.

### Geometrický a materiálový útlum

Pokles amplitudy signálu AE se vzrůstající vzdáleností od zdroje je způsoben dvěma odlišnými fyzikálními mechanismy: geometrickým rozptylem a materiálovou absorpcí. Celkový útlum určuje, jak velká část původní energie dorazí k senzoru a zda bude signál detekovatelný nad prahem šumu.

### Geometrický útlum

Geometrický útlum nesouvisí s vlastnostmi materiálu, ale s tím, jak se energie vlnoplochy rozprostírá do prostoru. U objemových vln v masivu se energie šíří všemi směry do koule. Aby byl zachován zákon zachování energie, musí amplituda  $A$  klesat nepřímo úměrně vzdálenosti  $r$ :

$$A \propto \frac{1}{r} \quad (2-3)$$

U povrchových vln se energie šíří pouze po ploše, tedy po válcové vlnoploše. Energie se rozprostírá do menšího objemu, a proto amplituda klesá výrazně pomaleji. Pokles je úměrný druhé odmocnině vzdálenosti:

$$A \propto \frac{1}{\sqrt{r}} \quad (2-4)$$

Z porovnání vztahů (2-3) a (2-4) vyplývá, že povrchové vlny jsou schopny přenést detekovatelný signál na mnohem větší vzdálenost než vlny objemové [4].

## Materiálový útlum

Druhým faktorem je materiálový útlum, při kterém dochází ke skutečné ztrátě energie a její přeměně na teplo v důsledku vnitřního tření a rozptylu na hranicích zrn. Amplituda v tomto případě klesá exponenciálně podle vztahu:

$$A = A_0 \cdot e^{-\alpha x} \quad (2-5)$$

kde  $A_0$  je počáteční amplituda,  $x$  je vzdálenost a  $\alpha$  je součinitel útlumu materiálu. V kovech je tento útlum relativně nízký a signál se šíří daleko. Naopak polymery a kompozity vykazují vysoký útlum způsobený jejich viskoelastickým chováním. Polymerní řetězce fungují jako tlumiče a efektivně pohlcují zejména vysokofrekvenční složky signálu. Materiál se chová jako přirozený filtr typu dolní propust. Signál o frekvenci 500 kHz, který by v oceli urazil metry, může být v polymeru zcela utlumen již po několika centimetrech. Pro experimentální praxi to implikuje nutnost umístit senzor co nejblíže ke zdroji tření [1, 4].

## Akustická impedance a přechody

Při průchodu vlnění z jednoho materiálu do druhého dochází na rozhraní k odrazu části energie. Příkladem může být přechod z ocelového hřídele do kompozitního pouzdra a následně do senzoru. Poměr přenesené energie závisí na akustické impedanci  $Z$  obou prostředí.

$$Z = \rho \cdot c \quad (2-6)$$

Veličina  $\rho$  představuje hustotu a  $c$  rychlost zvuku v daném materiálu. Čím větší je rozdíl impedancí, tím větší je odraz energie zpět do materiálu. Nejhorší přenos nastává na rozhraní mezi kovem a vzduchem, protože vzduch má velmi nízkou impedanci. Z tohoto důvodu je nezbytné používat mezi povrchem ložiska a senzorem vazební médium, jako je vazelína nebo lepidlo. Toto médium zajistí akustický most a minimalizuje ztráty odrazem [1, 2].

### 2.3.4 Snímání a digitalizace signálu

Pro následné zpracování signálu akustické emise pomocí algoritmů strojového učení je nezbytná transformace spojitého fyzikálního děje do digitální formy. Výstupem piezoelektrického senzoru je spojitý analogový signál  $x(t)$ , který reprezentuje časový průběh mechanického napětí na povrchu materiálu. Aby bylo možné tento signál analyzovat v počítači, musí projít procesem analogově-digitální (A/D) konverze. Tento proces se skládá ze dvou fundamentálních kroků. Prvním je diskretizace v čase neboli vzorkování a druhým je diskretizace v amplitudě neboli kvantizace [1].

## Vzorkování a Shannon-Nyquistův teorém

Proces vzorkování převádí spojitou funkci  $x(t)$  na posloupnost diskretních hodnot  $x[n]$  odebíraných v pravidelných intervalech  $T_s$ . Klíčovým parametrem je vzorkovací frekvence (2-7). Podle teorie signálů detailně popsané ve Vetterliho práci [5] není tento převod bezztrátový automaticky. Podmínku pro věrnou rekonstrukci signálu definuje Shannon-Nyquistův vzorkovací teorém (2-8). Ten stanovuje, že vzorkovací frekvence musí být minimálně dvojnásobkem nejvyšší frekvence  $f_{max}$  obsažené v měřeném signálu.

$$f_s = \frac{1}{T_s} \quad (2-7)$$

$$f_s \geq 2 \cdot f_{max} \quad (2-8)$$

Podle Nyquistova teorému je pro korektní analýzu signálů do frekvence  $500 \text{ kHz}$  nutná vzorkovací frekvence minimálně  $1 \text{ MS/s}$ . Toto pásmo je pro tribodiagnostiku kluzných ložisek klíčové. Dle studií Genga et al. [6] a Haseho et al. [7] se právě ve frekvenčním rozsahu  $100 \text{ kHz}$  až  $400 \text{ kHz}$  vyskytuje dominantní část energie spojená s třením a mikroskopickým praskáním asperit. Pro zabránění vzniku aliasingu je však nezbytné zajistit, aby frekvence nad  $500 \text{ kHz}$  byly před digitalizací odfiltrovány.

## Aliasing a ochrana integrity dat

Pokud vzorkovací frekvence nepokryje celé spektrum signálu, dochází k jevu zvanému aliasing neboli falšování frekvencí. Frekvenční složky signálu, které jsou vyšší než Nyquistova frekvence, se při digitalizaci "překlopí" do nižšího frekvenčního pásma. Vznikají tak falešné frekvence, které v původním signálu neexistovaly [5].

$$f_{alias} = |f - k \cdot f_s| \quad (2-9)$$

Tento jev je pro diagnostiku kritický, neboť může vést k chybné interpretaci dat. Vysokofrekvenční šum nebo signál z praskání materiálu by se vlivem aliasingu mohl jevit jako nízkofrekvenční třecí složka. Pro zajištění validity měření je proto nezbytné, aby frekvence přesahující limit karty (v tomto případě  $500 \text{ kHz}$ ) byly před A/D převodem potlačeny analogovým filtrem typu dolní propust (Anti-aliasing filter).

## Kvantizace a bitová hloubka

Zatímco vzorkování diskretizuje časovou osu, kvantizace diskretizuje osu amplitudovou. Spojité napětí ze senzoru je mapováno na konečnou množinu diskretních hladin. Počet těchto hladin  $L$  je dán bitovou hloubkou  $N$  daného A/D převodníku.

$$L = 2^N \quad (2-10)$$

Moderní akviziční systémy využívané pro tyto účely (např. s 20bitovým rozlišením) se vyznačují výrazným kvalitativním posunem oproti standardním 12-bitovým nebo 16-bitovým zařízením. Zatímco 16-bitový převodník dělí měřicí rozsah na 65 536 úrovní, 20-bitový převodník poskytuje rozlišení  $2^{20} = 1\,048\,576$  úrovní.


V praxi tato hodnota determinuje citlivost systému na nejmenší měřitelné změny napětí. Při nastaveném vstupním rozsahu  $\pm 10\text{ V}$  (celkové rozpětí 20 V) je teoretický nejmenší rozlišitelný krok napětí (LSB - Least Significant Bit) dán vztahem:

$$V_{LSB} = \frac{V_{range}}{2^N} = \frac{20}{1\,048\,576} \approx 19,07\mu\text{V} \quad (2-11)$$

Díky tomuto rozlišení je měřicí řetězec schopen detekovat i velmi slabé signály doprovázející počáteční fáze opotřebení, aniž by tyto informace zanikly v kvantizačním šumu. To umožňuje detailní analýzu jemných změn v textuře signálu, které by u méně citlivých zařízení nebyly rozeznatelné [5].

### 2.3.5 Hsu-Nielsenův test (Pencil Lead Break)

Hsu-Nielsenův test (test studující vnitřní útlum) představuje standardizovanou metodu simulace umělého zdroje AE podle normy ASTM E976. Princip spočívá v lomu grafitové tuhy (obvykle 0,5 mm a tvrdosti 2H) o povrch tělesa pod úhlem 30°. Tento děj generuje krátký, širokopásmový akustický impuls, který se svými vlastnostmi (rychlost uvolnění energie) blíží reálným zdrojům AE, jako je iniciace trhliny. V experimentální praxi se využívá především k ověření kvality akustické vazby snímače, kalibraci měřicího řetězce a studiu útlumových charakteristik materiálu.



Obr. 2-5: Hsu-Nielsen AE zdroj [8]

### 2.3.6 Parametry signálu

Surový signál akustické emise získaný digitalizací představuje rozsáhlý datový soubor, který je v surové formě pro přímou diagnostiku obtížně využitelný. Pro efektivní hodnocení stavu

tribologického systému je nezbytné provést redukci dat a extrahovat specifické příznaky (features). Tyto parametry kondenzují informaci o energii, tvaru rozdělení pravděpodobnosti a frekvenčním složení signálu. Zpracování dat ze surového signálu AE se v literatuře běžně realizuje v několika rovinách, kterými jsou energetická analýza, analýza tvaru signálu a frekvenční analýza.

### Energetické a amplitudové parametry

Základní hodnocení intenzity procesu opotřebení vychází z parametrů vypočtených přímo z časového průběhu napětí  $x(t)$ . Nejpoužívanějším parametrem v tribodiagnostice je efektivní hodnota (RMS – Root Mean Square). Tato veličina je přímo úměrná energii signálu a u kluzných ložisek vykazuje silnou korelaci s intenzitou tření a tloušťkou mazacího filmu. Pro diskrétní signál o délce  $N$  vzorků je RMS definována vztahem (2-12).

$$x_{RMS} = \sqrt{\frac{1}{N} \sum_{n=1}^N x[n]^2} \quad (2-12)$$

Zatímco RMS průměruje energii v čase a reaguje na změny se zpožděním, pro detekci náhlých událostí je využívána špičková hodnota (Peak) (2-13). Ta odpovídá maximální absolutní amplitudě signálu v daném časovém okně a indikuje nejvyšší okamžité uvolnění energie, například při vzniku trhliny.

$$x_{PEAK} = \max(|x[n]|) \quad (2-13)$$

### Statistické parametry a bezrozměrné faktory

Pro rozlišení mezi stochastickým šumem (běžné tření) a deterministickými poruchami (rázy) jsou využívány pokročilé statistické momenty vyšších řádů. Špičatost (Kurtosis) popisuje strmost rozdělení pravděpodobnosti amplitud signálu (2-14). Pro normální gaussovske rozdělení (stabilní tření) je hodnota Kurtosis blízka 3. Výrazný nárůst této hodnoty indikuje výskyt impulsních jevů v signálu, což je typické pro poškození povrchu.

$$Kurtosis = \frac{\frac{1}{N} \sum_{n=1}^N (x[n] - \bar{x})^4}{\left( \frac{1}{N} \sum_{n=1}^N (x[n] - \bar{x})^2 \right)^2} \quad (2-14)$$

Šikmost (Skewness) měří asymetrii rozdělení signálu kolem střední hodnoty. V ideálním případě je signál AE symetrický (Skewness = 0). Odchylka od nuly může indikovat specifické mechanismy, jako je jednosměrné plastické deformování nebo vliv usměrňovacích efektů v přenosové trase [5]:



$$S = \frac{E[(x - \mu)^3]}{\sigma^3} \quad (2-15)$$

Pro citlivou detekci počínajícího poškození je sada parametrů rozšířena o bezrozměrné diagnostické faktory, které kombinují špičkové a průměrné hodnoty.

## 2.4 Akustická emise v tribologii

### 2.4.1 Vztah AE s třecími mechanismy

V tribologickém kontaktu nedochází k interakci povrchů plošně, nýbrž na úrovni mikroskopických nerovností (asperit). Jak uvádí Geng [6] ve své souhrnné studii, tření a s ním spojené opotřebení je dynamickým procesem lokálních změn vnitřní struktury materiálu. Během relativního pohybu povrchů dochází k elastické a plastické deformaci asperit, mikrořezání (micro-cutting) a k praskání adhezivních spojů. Každá tato diskretní mikro-událost je spojena s náhlým uvolněním akumulované deformační energie. Zatímco část této práce je disipována ve formě tepla, zbývající podíl je vyzářen do objemu tělesa ve formě tranzientních elastických vln, tedy akustické emise [6]. Signál AE je tak přímou odezvou na nevratné změny v materiálu a na rozdíl od měření celkové třecí síly nese informaci o samotné fyzikální podstatě degradace povrchu.

### 2.4.2 Korelace AE s třením a opotřebením

Kvantifikace vztahu mezi signálem AE a úbytkem materiálu je stěžejním předpokladem pro vývoj prediktivních modelů opotřebení. Energetické parametry signálu AE, zejména efektivní hodnota (RMS) a absolutní energie, vykazují silnou korelaci s disipovaným třecím výkonem. Jak dokládají studie [9, 10], existuje přímá úměra mezi nárůstem hodnoty AE RMS a intenzitou kontaktu asperit. Dále například Strablegg [11] úspěšně zavedl parametr SRMS (RMS škálované na třecí výkon), který bezprostředně koreluje se stavem opotřebení. Korelaci integrálu RMS signálu v čase s kumulativním úbytkem materiálu (wear volume) se zabývali i Boness a McBride [12] nebo Hase [7], kteří potvrdili, že rostoucí uvolněná elastická energie přímo úměrně odpovídá objemu opotřebovaných částic.

Při testování polymerních a kompozitních kluzných vrstev je signál AE generován specifickými mechanismy, jako je deformace polymerní matrice, vytrhávání zpevňujících plniv či počínající delaminace vrstvy. Tyto procesy generují tranzientní signály (burst emise) dávno předtím, než se makroskopicky projeví změnou koeficientu tření (COF), nebo teploty. Zatímco opotřebení je z povahy věci kumulativní proces, AE poskytuje okamžitou (in-situ) informaci o rychlosti tohoto opotřebení (wear rate). Z tohoto důvodu je integrace parametrů

AE v čase, korigovaná o aktuální provozní parametry (jako je střední hodnota axiální síly  $F_{a,mean}$ ), optimálním vstupem pro trénování umělých neuronových sítí (ANN) k predikci celkového opotřebení.

### 2.4.3 Diagnostika mazacích režimů a specifika vysoce zatížených uložení


Z hlediska tribodiagnostiky nabízí AE unikátní nástroj pro identifikaci přechodů mezi jednotlivými režimy mazání, definovanými Stribeckovou křivkou. V oblasti hydrodynamického mazání, kde jsou povrchy plně odděleny mazací vrstvou, je generována pouze minimální akustická emise vlivem vnitřního tření (stříhu) kapaliny. Při ztenčení mazacího filmu a přechodu do smíšeného a následně mezního tření dochází k postupnému nárůstu přímého kontaktu asperit. To se projevuje strmým nárůstem parametrů AE, jelikož signál začíná být dominován elasticko-plastickou deformací kovu a polymeru [10, 13]. Metoda AE dokáže reagovat na tyto přechody mazacího filmu v řádu milisekund.

## 2.5 Identifikace mechanismů opotřebení

Při dlouhodobém monitorování tribologických uzlů představuje klasická analýza jednotlivých událostí (tzv. hit-based analysis, zaměřená na detekci každé izolované mikrotrhliny) značnou výpočetní i datovou zátěž. V moderní tribodiagnostice, zaměřené na sledování celkových trendů a predikci objemu opotřebení, se proto stále častěji uplatňuje metodika segmentálního měření kontinuální emise, v literatuře označovaná jako tzv. *wavestreaming* [14]. Tento přístup spočívá v pravidelném zaznamenávání krátkých bloků surového signálu, což zabraňuje zahlcení výpočetní kapacity, avšak zachovává dostatek informací pro identifikaci makroskopických změn v tribosystému. Následující podkapitoly popisují teoretické nástroje, jak lze z takto získávaných spojitých segmentů identifikovat probíhající mechanismy degradace.

### 2.5.1 Frekvenční analýza tribologických jevů

Analýza frekvenčního spektra představuje stěžejní nástroj pro odlišení různých tribologických mechanismů, neboť odlišné fyzikální procesy generují elastické vlny s různou dominantní frekvencí. Podle komplexní studie Haseho [7] lze tyto mechanismy klasifikovat do odlišných pásem. Adhezivní opotřebení, spojené s plastickou deformací a trháním lokálních spojů, typicky generuje signály v nižším frekvenčním pásmu Obr. 2-6. Naproti tomu abrazivní opotřebení (mikrořezání) a vznik trhlin se projevují vysokofrekvenčními složkami, které často přesahují hranici 500 kHz [7].



Obr. 2-6: Korelační mapa frekvenčních spekter AE pro jevy zahrnující deformaci a lom [7]

Při reálném monitoringu polymerních a kompozitních materiálů je však nutné zohlednit tlumicí vlastnosti samotného materiálu (low-pass charakteristiku) i limitace standardních měřicích řetězců (kde se vzorkovací frekvence často pohybují v jednotkách MS/s). Jak vyplývá z publikovaných experimentů, k úspěšné identifikaci změny mechanismu opotřebení není nezbytně nutné analyzovat signál AE v řádech megahertzů. Vhodnou alternativou je sledování relativních změn ve vymezeném frekvenčním okně (např. do 500 kHz). Posun těžiště frekvenčního spektra (Spectral Centroid) či změna špičkové frekvence (Peak Frequency) směrem k vyšším hodnotám v čase spolehlivě indikuje přechod od mírného adhezivního zajištění k tvrdé abrazi nebo vzniku částic třetího tělesa [15].

## 2.5.2 Statistické momenty a typologie signálu v časové oblasti

Při analýze datových segmentů tvořených převážně stochastickým šumem tření ztrácí klasická prahová detekce amplitud (nastavení fixního prahu pro detekci "hitů") svou vypovídací hodnotu [14]. Identifikace mikroskopických procesů v kontaktu je proto v moderních přístupech založena na výpočtu statistických momentů vyšších řádů (definovaných v kap. 2.3.4) přes celý měřený segment.

Fyzikální podstata tohoto přístupu vychází z rozdílu mezi spojitou a nárazovou emisí. Jak uvádí souhrnná studie Fenga a kol. [9], ustálené smykové tření (sliding friction) a mírné opotřebení (mild wear) generují spojitý signál s amplitudami odpovídajícími Gaussovu

normálnímu rozdělení, kde se hodnota špičatosti (Kurtosis) pohybuje blízko hodnoty 3. Pokud však v kontaktu začne docházet k závažnějším formám poškození, jako je mikrořezání tvrdými částicemi, delaminace povlaku nebo vytrhávání polymerní matrice, tyto diskrétní jevy naruší ustálené rozdělení amplitud. Výskyt vysokoenergetických tranzientních projevů na pozadí spojitého třecího šumu znamená, že se v signálu začnou objevovat ojedinělé extrémní amplitudy (špičky). Tento nárůst odchylek od normálního rozdělení se okamžitě projeví markantním nárůstem hodnot Kurtosis a Skewness (šikmosti) v analyzovaném okně [9]. Sledování těchto statistických parametrů tak poskytuje robustní a výpočetně efektivní indikátor závažnosti opotřebení (wear severity), nezávislý na absolutní amplitudě signálu.

### 2.5.3 Detekce přechodových stavů opotřebení

Každý tribologický systém prochází během svého životního cyklu charakteristickými fázemi: fází záběhu (running-in), fází ustáleného opotřebení (steady-state) a finální fází rapidní degradace (severe wear). Včasná detekce přechodu mezi ustáleným stadiem a rapidní degradací je hlavním cílem prediktivní údržby.

Metoda AE vykazuje pro tuto úlohu zásadně vyšší citlivost než konvenční metody (měření teploty či koeficientu tření). Zatímco makroskopické parametry mají značnou setrvačnost, parametry AE reagují na bezprostřední změnu fyzikálních podmínek v kontaktu [10]. Zvýšená disipace energie spojená se změnou mechanismu opotřebení se projevuje skokovým nárůstem efektivní hodnoty signálu a uvolněné absolutní energie. Ve studii zabývající se testováním leteckých kompozitních ložisek [14] i v experimentech s polymery PEKK [15] bylo prokázáno, že vyhlazený trend energetických parametrů AE (např. pomocí klouzavých průměrů) úzce koreluje s reálným úbytkem objemu materiálu (wear rate). Extrakce těchto plynulých časových řad z periodicky snímaných datových bloků (waviestreamů) tak vytváří ideální množinu příznaků pro následné modelování degradace pomocí algoritmů strojového učení.

## 2.6 Strojové učení pro tribodiagnostiku z akustické emise

Využití metod strojového učení a umělých neuronových sítí pro vyhodnocování diagnostických dat představuje komplexní proces, který vyžaduje přísně systematický přístup. Běžně zavedenou strukturu vývoje predikčních modelů je nutné v inženýrské praxi modifikovat a obohatit o hluboké poznatky z dané domény – v tomto případě z oblasti triboinformatiky a analýzy akustické emise. Obecný postup začíná u samotného datasetu, kde je klíčová filtrace surového signálu, eliminace šumu a extrakce vhodných statistických či popisných příznaků. Na to bezprostředně navazuje fáze preparace, která zahrnuje čištění

dat, volbu optimální metody normalizace a bezpečné rozdělení datasetu tak, aby se absolutně předešlo nežádoucímu úniku informací (tzv. data leakage) mezi trénovací a testovací množinou ještě před samotným předložením dat algoritmu.

Na pečlivě předzpracovaná data plynule navazuje fáze modelování. Zde hraje zásadní roli průzkumová analýza, identifikace vzájemných závislostí parametrů (například pomocí korelačních matic), pokročilý feature engineering a především volba vhodné architektury neuronové sítě. Správně zvolená topologie modelu i metoda učení musí úzce korespondovat s charakterem vstupních dat a fyzikální podstatou řešeného problému. Následující část rešerše tento obecný řetězec kroků detailně rozebírá a aplikuje na něj specifika predikce kumulativního opotřebení. V literatuře se pro tuto predikci využívají algoritmy vyhlazování dat a principy sekvenčního učení. Zásadní je zde volba vhodných architektur hlubokého učení pro zpracování vícerozměrných časových řad.

### 2.6.1 Algoritmy vyhlazování dat

Diskrétní časové řady statistických a popisných příznaků, extrahované z periodicky ukládaných segmentů diagnostického signálu, přirozeně obsahují určitou míru stochastického šumu a lokálních výkyvů. Ačkoliv je v delším časovém horizontu jasně patrný celkový trend degradace, tyto mezisegmentové fluktuace, způsobené běžným mechanickým a provozním hlukem stroje, znesnadňují neuronové síti nalezení správných nelineárních vazeb. Pro efektivní učení predikčního modelu je proto nezbytné provést korelaci a filtraci dat, která omezí šum, ale striktně zachová fyzikální podstatu trendu.

Běžně využívané metody sice data vyhladí, avšak mohou do signálu zanášet fázové zpoždění (časový posun křivky) nebo zkreslit významné lokální extrémy. V odborné literatuře zaměřené na předzpracování signálů je jako vhodné řešení často uváděna aplikace Savitzky-Golay (S-G) filtru. Tento algoritmus využívá přístup lokálního prokládání polynomu (tzv. local polynomial regression). Díky tomuto matematickému přístupu je S-G filtr efektivní v zachování výšky a šířky lokálních vrcholů signálu [16].

Úspěšnost a opodstatněnost tohoto přístupu v kontextu předzpracování dat pro strojové učení potvrzuje studie zaměřená na monitorování stavu konstrukcí (SHM) [16]. V tomto výzkumu byl aplikován S-G filtr pro předzpracování zašuměných senzorických dat před jejich předložením umělým neuronovým sítím. Analýza signálů ukázala, že S-G filtr vyhladil šum z dat s vysokou hustotou, přičemž zachoval užitečné informace. Výsledky dále prokázaly, že takto filtrovaná data poskytují lepší korelaci pro identifikaci poškození. Při testování na experimentálních datech vedla aplikace S-G filtru ke snížení chybovosti neuronových sítí a k mírnému zkrácení doby jejich trénování. Z toho vyplývá, že aplikace filtru na vstupní data předkládá síti fyzikálně relevantnější trend oproti surovému signálu, což vede ke zvýšení spolehlivosti diagnostiky.

## 2.6.2 Normalizace dat a prevence úniku informací

Předložením vícerozměrných dat neuronové síti je nezbytné zajistit, aby všechny vstupní parametry (příznaky) měly srovnatelný rozsah hodnot. V tribologických experimentech často dochází ke stavu, kdy vstupní veličiny, jako je energie akustické emise a mechanické síly, vykazují rozdíly v řádech jednotek až desítek tisíc. Bez adekvátní úpravy měřítek by parametry s vyššími absolutními hodnotami neúměrně dominovaly výpočtu ztrátové funkce a gradientů, což by vedlo k numerické nestabilitě a neschopnosti modelu efektivně konvergovat.

V inženýrské praxi se využívají dva základní přístupy: Min-Max scaling (normalizace) a Z-score standardizace. Normalizace transformuje data do fixního rozsahu, nejčastěji  $< 0, 1 >$ , což je vhodné pro algoritmy, které nepředpokládají konkrétní rozdělení dat. Naopak standardizace transformuje data tak, aby měla nulový průměr a jednotkovou směrodatnou odchylku [2]. Tento přístup je výhodný v situacích, kdy je žádoucí sledovat rozptyl (směrodatnou odchylku) v rámci datasetu a eliminovat vliv odlehklých hodnot, čímž se minimalizuje zkreslení plynoucí z rozdílných magnitud jednotlivých příznaků [17].

Zcela zásadním aspektem při přípravě dat je zamezení tzv. úniku dat (data leakage). K tomuto nežádoucímu jevu dochází, pokud informace z testovací sady (která má sloužit jako neznámá pro finální validaci) proniknou do procesu trénování. V kontextu normalizace to znamená, že parametry pro transformaci (např. průměr a směrodatná odchylka) musí být vypočteny výhradně z trénovací sady. Tyto jednou stanovené parametry jsou následně aplikovány na testovací data [18]. Tímto postupem je zaručeno, že model při testování pracuje s daty, která jsou sice škálována konzistentně s tréninkem, ale jejichž statistické charakteristiky nebyly sítě během učení předem známy.

U časových řad z tribologických testů je navíc nutné dbát na chronologickou integritu. Dataset nesmí být dělen náhodným promícháním (tzv. random shuffle) jednotlivých segmentů, neboť by hrozilo, že se síť naučí rozpoznávat specifické vzorce v čase, které jsou v tréninku i testu identické. Data by měla být dělena po celých nezávislých testech, čímž se simuluje reálný provoz, kde model predikuje stav nového, doposud neviděného komponentu.

Pro další zvýšení stability a rychlosti učení se přímo do architektur sítí integrují mechanismy vnitřní normalizace, jako je Batch Normalization. Tato technika normalizuje výstupy jednotlivých vrstev v rámci každé trénovací dávky (batch). Pomáhá udržovat aktivace v optimálním rozsahu, čímž zrychluje konvergenci modelu a částečně funguje jako regularizační prvek snižující riziko přeučení. V úlohách, kde je velikost dávky velmi malá nebo kde záleží na specifických rysech jednotlivých vzorků, se pak uplatňuje Instance Normalization, která provádí transformaci nezávisle pro každý vzorek, což je klíčové pro zachování specifických trendů v signálu.


### 2.6.3 Analýza architektur hlubokého učení pro 1D časové řady

Volba vhodné architektury neuronové sítě je kritickým krokem, který určuje schopnost modelu extrahovat relevantní rysy z diagnostických signálů a následně predikovat progresi opotřebení. V závislosti na formátu vstupních dat a požadavcích na výstupní predikci se v literatuře uplatňují různé topologie, od základních dopředných sítí až po komplexní sekvenční a hybridní modely.


#### Dopředné sítě (MLP) a základní rekurentní struktury (RNN)

Vícevrstvý perceptron (MLP) Obr. 2-7, označovaný také jako plně propojená neuronová síť (FCNN), představuje základní architekturu pro regresní úlohy v tribologii. Tato struktura se skládá ze vstupní vrstvy, několika skrytých vrstev a výstupní vrstvy, přičemž každý uzel je propojen se všemi uzly v následující vrstvě [18]. V kontextu diagnostiky ložisek MLP typicky využívá nelineární aktivační funkce, jako je ReLU (Rectified Linear Unit), pro transformaci extrahovaných příznaků. Hlavním omezením MLP je však absence vnitřní paměti; síť vyhodnocuje každý časový segment izolovaně, což ignoruje kumulativní charakter procesu opotřebení.

K překonání tohoto nedostatku se využívají standardní rekurentní neuronové sítě (RNN) Obr. 2-8. Tyto sítě zavádějí zpětné vazby, které umožňují přenášet informace z předchozích časových kroků do aktuálního výpočtu. Pro účely rekonstrukce trajektorie opotřebení se využívá topologie Many-to-Many, kde síť pro každou sekvenci vstupních segmentů generuje odpovídající sekvenci predikcí. RNN jsou však v praxi omezeny problémem mizejícího gradientu (vanishing gradient), který jim brání v efektivním učení u velmi dlouhých časových řad [19].



Obr. 2-7: Schéma architektury MLP (dopředná vícevrstvá síť): vstupní vrstva → skryté vrstvy [256, 128, 64] → výstupní neuron.




Obr. 2-8: Schéma architektury RNN: rozvinutá rekurentní buňka se skrytým stavem  $h_t$ .

### Pokročilé sekvenční modely (LSTM, GRU) a hybridní architektury


Architektura Long Short-Term Memory (LSTM) Obr. 2-9 byla navržena specificky pro řešení nedostatků standardních RNN. LSTM buňka obsahuje komplexní mechanismus brán (vstupní, zapomínací a výstupní brána), který reguluje tok informací a umožňuje síti udržovat dlouhodobou paměť bez degradace gradientu [19]. Zjednodušenou, ale často stejně efektivní alternativu představuje Gated Recurrent Unit (GRU) Obr. 2-10, která kombinuje brány do kompaktnější struktury, což vede k nižšímu počtu parametrů a rychlejšímu trénování při zachování schopnosti modelovat časové závislosti.

Srovnávací studie naznačují, že neexistuje univerzálně nejlepší model, ale hybridní přístupy často vykazují vyšší stabilitu. Konkrétně architektury jako LSTM-RNN nebo LSTM-GRU kombinují robustnost LSTM při extrakci dlouhodobých trendů s výpočetní efektivitou jednodušších vrstev [19]. Tyto modely jsou obzvláště vhodné pro scénáře s omezeným množstvím trénovacích dat, kde plně komplexní modely mohou inklinovat k přeučení.



Obr. 2-9: Schéma architektury LSTM: buňka s paměťovým stavem  $C_t$  a třemi branami (vstupní, zapomínací, výstupní),






Obr. 2-10: Schéma architektury GRU: zjednodušená buňka s resetovací a aktualizací branou

### Konvoluční neuronové sítě (1D-CNN) pro časové řady

Konvoluční neuronové sítě (CNN), primárně známé z oblasti počítačového vidění, lze adaptovat pro 1D signály pomocí jednorozměrných konvolučních jader. Hlavní výhodou CNN je schopnost automaticky detekovat lokální vzorce (patterns) a rysy v signálu bez nutnosti manuálního feature engineeringu [20]. V oblasti diagnostiky ložisek vykazují vysokou účinnost zejména reziduální sítě (ResNet-1D), které díky "přeskakujícím propojením" (shortcut connections) umožňují trénování hlubších struktur a extrakci vysoce diskriminačních rysů z vibračních či AE signálů. Nicméně, pro úlohy predikce kontinuálního úbytku materiálu v čase jsou CNN méně přirozené než rekurentní modely, neboť se primárně zaměřují na prostorové (lokální) rysy v rámci okna, nikoliv na dlouhodobou časovou kontinuitu.



Obr. 2-11: Schéma hybridní architektury CNN-GRU: paralelní větve konvoluční extrakce příznaků a rekurentního zpracování, sloučené před výstupní vrstvou.

## Paralelní fúze domén a duální vstupy (1D a 2D)

Moderním trendem v diagnostice ložisek je paralelní zpracování dat v různých doménách. Tato strategie využívá hybridní modely, které kombinují výhody CNN a GRU/LSTM Obr. 2-11. Typická architektura využívá duální vstup: jedna větev modelu zpracovává 1D časový signál (pomocí GRU/LSTM pro zachování časových korelací), zatímco druhá větev zpracovává 2D reprezentaci téhož signálu, nejčastěji spektrogram získaný spojitou vlnkovou transformací (CWT) nebo STFT [21].

Tento přístup umožňuje modelu současně extrahovat globální časové trendy i lokální frekvenčně-prostorové rysy. V literatuře je doloženo, že fúze těchto dvou typů informací v hlubších vrstvách sítě vede k výraznému zvýšení robustnosti modelu vůči šumu a k přesnější diagnostice vad v porovnání s modely využívajícími pouze jeden typ vstupu.

### 2.6.4 Regularizace a interpretabilita modelů v režimu omezených dat

Při aplikaci hlubokého učení v tribologické diagnostice představuje jeden z hlavních problémů omezená velikost trénovacích datasetů (tzv. small-data regime). Zatímco moderní architektury neuronových sítí excelují při trénování na milionech vzorků, v inženýrské praxi jsou k dispozici často pouze desítky run-to-failure testů. V tomto scénáři se stává kritickým faktorem komplexita zvoleného modelu. Studie naznačují, že u úloh s velmi omezeným počtem vzorků mohou nízko-komplexní modely (jako jsou mělké dopředné sítě či jednodušší konvoluční struktury) dosahovat srovnatelných, nebo dokonce lepších výsledků v generalizaci než vysoce komplexní architektury typu „State-of-the-Art“, které mají v takových podmínkách silnou tendenci k přeučení [22].

K potlačení jevu přeučení (overfitting) a zajištění stability modelu se využívají standardní regularizační techniky. Klíčovým nástrojem je vrstva Dropout, která během procesu učení náhodně vypíná definovanou část neuronů (v diagnostických úlohách ložisek se typicky volí poměr 0,5), čímž nutí síť hledat robustnější reprezentace rysů namísto fixace na šum v datech [18]. Výzkum potvrzuje, že Dropout si zachovává svou roli efektivního regularizátoru i v případě extrémně malých datasetů. Dalším významným prvkem je augmentace dat, která uměle zvyšuje rozmanitost tréninkové sady pomocí transformací původních signálů, což vede k výraznému zlepšení schopnosti modelu generalizovat na neviděná testovací data [22].

Kromě samotné přesnosti predikce je v technické diagnostice kritickým požadavkem interpretabilita. Aby bylo možné predikce modelu využít pro zodpovědné rozhodování o údržbě strojů, je nutné kvantifikovat, které statistické příznaky vstupního signálu mají na odhad opotřebení největší vliv. K tomuto účelu se v literatuře využívají frameworky založené na SHAP (Shapley Additive Explanations), které umožňují nahlédnout do „černé skříňky“ neuronové sítě a validovat, zda se model učí na základě fyzikálně relevantních parametrů (např. nárůst energie RMS), nebo na základě falešných korelací v datech [20].

## 2.6.5 Transformace a regrese z 2D časově-frekvenčních domén

Alternativní a vysoce účinný přístup k analýze diagnostických signálů představuje jejich transformace z jednorozměrné časové řady do dvourozměrné časově-frekvenční domény. Tento proces umožňuje převést signály akustické emise nebo vibrací na vizuální reprezentace, jako jsou spektrogramy, které zachycují bohatší informaci o dynamických interakcích v čase a frekvenci současně. Hlavní výhodou tohoto postupu je, že určité vzorce spojené s poruchami a opotřebením, které jsou v 1D doméně skryté, se v časově-frekvenčním zobrazení stávají výrazně zřetelnějšími a snadněji identifikovatelnými pro algoritmy hlubokého učení [23].

V literatuře se pro tento účel uplatňuje několik standardních matematických transformací. Krátkodobá Fourierova transformace (STFT) poskytuje spektrogramy s fixním rozlišením, což je limitující při analýze signálů s rychlými přechodovými jevy. Naproti tomu Spojitá vlnková transformace (CWT) generuje skalogramy pomocí škálování a posunu tzv. mateřské vlnky (mother wavelet). CWT nabízí flexibilní, víceúrovňové rozlišení, což ji činí ideálním nástrojem pro analýzu nestacionárních signálů, jako je akustická emise. Mezi další pokročilé metody patří Hilbert-Huangova transformace (HHT) a Wigner-Villeova distribuce (WVD), přičemž každá z těchto metod nabízí specifický pohled na energetické rozložení signálu v čase [24]. Takto vytvořené obrazy jsou následně analyzovány pomocí 2D konvolučních neuronových sítí (2D-CNN), které dokáží automaticky extrahovat prostorové rysy, textury a hrany, čímž eliminují nutnost manuálního návrhu příznaků.

Špičkovou úroveň v diagnostice ložisek představují tzv. paralelní fúzní architektury. Tyto modely využívají duální vstup: jedna větev sítě (typicky založená na LSTM) zpracovává původní 1D časový signál pro zachování dlouhodobých časových korelací, zatímco druhá větev (2D-CNN) analyzuje odpovídající časově-frekvenční obraz pro extrakci lokálních spektrálních rysů [21]. Výstupy z obou větví jsou v hlubších vrstvách sítě kombinovány (fúzovány), což umožňuje modelu učit se z prostorových i časových perspektiv současně. Studie potvrzují, že tato kombinace domén vede k výraznému zvýšení robustnosti modelu vůči šumu a k vyšší přesnosti predikce v porovnání s modely využívajícími pouze jeden typ reprezentace dat [21].

## 2.7 Vývoj a technická omezení modulárního rotačního tribometru s axiálním zatěžováním

Modulární rotační tribometr s axiálním zatěžováním byl pod označením R\_MAT 3 vyvinut na Fakultě strojního inženýrství již v 70. letech minulého století. V takové podobě bylo využíváno zejména pro testy axiálních valivých ložisek, mezikruhových kontaktů (konfigurace ring-on-ring) a testy zadírání ve čtyřkuličkové konfiguraci. V minulých letech

bylo zařízení přepracováno pro testy konformních kontaktů za velmi vysokého zatížení (až 100 kN) a extrémně nízkých kluzných rychlostí (viz Obr. 2-12), což jsou podmínky, které standardní laboratorní přístroje (např. čtyřkuličkové testery) nedokážou kvůli své geometrii a limitům zatěžování věrně simulovat. Tyto úpravy zahrnovaly zvýšení únosnosti a tuhosti vřetene, zvýšení tuhosti rámu, přechod na hydraulické zatěžování, významné přepracování měřicího řetězce a konstrukci pohonu využívajícího zdvižné elektropřevodovky pro malé kluzné rychlosti.

Ve výchozí podobě je zařízení pro účely této práce vyhovující z hlediska konstrukce rámu stroje, hydraulického zatěžování a nové konstrukce vřetene zkušebního vzorku.



Obr. 2-12: Původní stav modulárního rotačního tribometru s axiálním zatěžováním

## 2.8 Analýza současného stavu poznání

Provedená rešeršní studie potvrzuje, že metoda vysokofrekvenční akustické emise (AE) představuje dominantní nástroj pro in-situ monitorování tribologických procesů, zejména v režimech mezného a smíšeného tření [25, 26]. Ačkoliv odborná literatura uspokojivě popisuje kauzální vztah mezi nárůstem energetických parametrů AE (např. RMS, energie) a celkovým úbytkem materiálu [27, 28], identifikuje tato analýza mezeru v systematické validaci těchto poznatků u specifických polymerních kompozitů v řízených laboratorních podmínkách. Existující studie se často zaměřují na kvalitativní popis jevů, avšak absentuje v nich metodika, která by propojila zrychlené laboratorní testy nekonformního kontaktu, jako je kontakt kuliček se sférickým povrchem u samo-mazných ložisek [14], s exaktními regresními modely pro predikci objemového úbytku. Vývoj takové laboratorní metody je

klíčovým krokem pro ověření reálných možností predikce opotřebení pomocí umělé inteligence před jejím nasazením do komplexních průmyslových systémů.

Z hlediska datového zpracování analýza odhalila, že metodika se v oblasti diagnostiky ložisek soustředí primárně na klasifikaci diskrétních stavů (např. identifikaci vad) nebo na odhad zbývající životnosti (RUL) [29, 30]. Chybí však přístupy zaměřené na spojitou regresi trajektorie opotřebení z reálných senzorických dat zatížených šumem. Jako kritický prvek se zde jeví aplikace lokální polynomiální regrese pomocí filtru Savitzky-Golay, který na rozdíl od standardních metod vyhlazování eliminuje stochastické výkyvy bez vnesení fázového zpoždění [16]. Zachování časové integrity diagnostických informací je nezbytnou podmínkou pro to, aby model dokázal správně interpretovat dynamiku degradace v průběhu celého životnostního testu.

Poslední významnou výzvou je architektonický návrh hlubokých neuronových sítí z hlediska zachování fyzikální logiky predikce. U úloh predikce kumulativního opotřebení je nezbytné, aby výstup modelu respektoval monotónní charakter procesu – tedy aby predikovaná hodnota v čase neklesala [31]. Ačkoliv řešerše popisuje implementaci architektur od MLP přes 1D-CNN až po rekurentní sítě (RNN) [19, 20], chybí jejich systematické srovnání právě z pohledu schopnosti rekonstruovat hladký a fyzikálně konzistentní trend opotřebení v podmínkách omezeného laboratorního datasetu. Experimentální validace schopnosti rekurentních modelů (LSTM, GRU) využít časovou paměť k potlačení nereálných regresních výkyvů [19] je proto hlavním předpokladem pro vytvoření robustního systému predikce.

## 3 CÍL PRÁCE

### 3.1 Cíle práce

Hlavním cílem práce je vyvinout a validovat diagnostický řetězec pro kvantitativní predikci zbývajících tloušťky kompozitního PTFE povlaku sférického kloubu GE20-AW s využitím signálu akustické emise a metod hlubokého učení, realizovaný na modelovém kluzném kontaktu za podmínek akcelerovaného opotřebení.

**Dosažení hlavního cíle je podmíněno splněním následujících dílčích cílů:**

- návrh a realizace testovací konfigurace pro vznik akcelerovaného opotřebení kompozitní kluzné vrstvy na modulárním rotačním tribometru včetně integrace měřicího řetězce akustické emise a doplňkové senzorky,
- vybudování akvizičně-zpracovatelského řetězce pro synchronní sběr signálu AE a provozních veličin, extrakce statistických a spektrálních příznaků a sestavení databáze tribologických experimentů s referenčními hodnotami opotřebení,
- návrh datové pipeline pro předzpracování, normalizaci a trénink predikčních modelů,
- implementace a vzájemné porovnání adekvátních architektur neuronových sítí z hlediska přesnosti predikce tloušťky povlaku a schopnosti generalizace na neviděných experimentech,
- experimentální charakterizace závislosti útlumu AE signálu na tloušťce polymerního povlaku metodou Hsu-Nielsenových zdrojů ve dvou kontaktních konfiguracích a posouzení přenositelnosti diagnostického přístupu.

Práce má charakter výzkumně-vývojový, přičemž hlavním cílem je vývoj metody, který se ale silně opírá o realizaci aktivit aplikovaného výzkumu. Práce je realizována rámci projektu TAČR.

Výstupem projektu jsou aplikované výsledky v podobě zkušebního zařízení, snímače a souvisejících postupů diagnostiky stavu kluzného ložiska.

### 3.2 Výzkumné otázky a hypotézy

Vývoj diagnostických metod v této práci se opírá o výzkumné otázky a související hypotézy. Primárním cílem práce není ověření konkrétních hypotéz, nicméně vyvíjené metody vycházejí z předpokladů, které lze poměrně jasně vyjádřit jako hypotézy. Ověřením „funkčnosti“ vyvíjených metod se lze současně vyjádřit k ověření platnosti hypotéz.

Výzkumné otázky:

- O1:** Které statistické a spektrální příznaky signálu akustické emise nesou dominantní diagnostickou informaci pro predikci tloušťky kompozitního PTFE povlaku kluzného ložiska, a jsou tato zjištění konzistentní s fyzikálními předpoklady o mechanismu tribologického opotřebení?
- O2:** Jaký je dominantní fyzikální mechanismus útlumu signálu akustické emise při průchodu kompozitním polymerním povlakem: materiálová viskózní absorpce, nebo impedanční diskontinuita na rozhraní kov–polymer?

Hypotézy:

- H1: Intenzita tribologického procesu v ložisku ovlivňuje intenzitu generovaného signálu akustické emise.**

Tato hypotéza vychází z předpokladu, že disipace energie při tření a rychlost objemového opotřebení mají stejný fyzikální původ jako zdroje signálu AE v kluzném uzlu. Intenzita tribologického procesu (vyjádřená např. prací třecích sil) je tedy v přímé korelaci s energetickými parametry AE. Pokud by se tato korelace neprokázala, může to indikovat, že signály z tribologického procesu jsou překryty šumem okolí nebo jinými dominantními zdroji signálu.

Hypotéza se opírá o zjištění Genga et al. [6], že signál AE je přímou odezvou na nevratné mikrostrukturní změny v kluzném kontaktu, a z principu formulovaného Bonnessem a McBridem [12], podle něž je kumulativní integrál RMS signálu přímo úměrný objemovému opotřebení materiálu. Předpokladem je, že tato fyzikální vazba je dostatečně konzistentní napříč různými provozními podmínkami testování.


- H2: Intenzita signálu akustické emise vzrůstá s klesající tloušťkou polymerního povlaku ložiska.**

Předpokládá se, že polymerní povlak působí jako tlumicí prvek pro přenos signálu AE od zdroje k senzoru. S progresivním úbytkem materiálu (opotřebením) dochází ke snižování útlumu způsobeného jednak viskoelastickými vlastnostmi samotného polymeru a jednak existencí materiálového rozhraní mezi povlakem a kovovým substrátem. Úplné odstranění povlaku eliminuje toto rozhraní, což vede k výraznému nárůstu intenzity detekovaného signálu generovaného z vnějších i vnitřních zdrojů.

Hypotéza vychází z teorie šíření elastických vln v heterogenních médiích a z principu impedanční diskontinuity na rozhraní materiálů s výrazně odlišnou akustickou impedancí, jak ji formuloval Nazarchuk [4]. Předpokladem je, že útlum způsobený polymerní vrstvou je měřitelný pro dostupný rozsah tloušťek povlaku a převažuje nad ostatními útlumovými mechanismy v testovacím systému.

## 4 MATERIÁL A METODY

V této kapitole je popsán metodický postup vycházející z hypotéz stanovených v kapitole 3.1. Jsou zde definovány dvě výzkumné větve směřující k ověření těchto předpokladů prostřednictvím řízeného experimentu. V rámci metodiky pro hypotézu H1 je navrženo testovací zařízení a postup pro vyvolání akcelerovaného opotřebení polymerního kluzného povlaku při kontinuálním měření akustické emise s následným využitím umělých neuronových sítí pro predikci úbytku materiálu.



Obr. 4-1: Přehledové schéma metodiky diplomové práce: dvě paralelní metodické větve (H1 – predikce opotřebení pomocí ANN; H2 – charakterizace útlumu AE) s mapováním na kapitoly diskuze.

K ověření hypotézy H2 je využita metoda Hsu-Nielsenových zdrojů (test studující vnitřní útlum) zaměřená na charakterizaci útlumu AE signálu v závislosti na tloušťce polymerního



povlaku. Měření je provedeno ve dvou konfiguracích – konformní geometrii odpovídající tribometrickému uzlu a nekonformní geometrii s uspořádáním 4-ball – s cílem ověřit přenositelnost diagnostického přístupu na odlišné kontaktní geometrie.

## 4.1 Metodika

Metodický postup této diplomové práce je koncipován jako ucelený inženýrský cyklus, který logicky integruje fázi konstrukční, experimentální a analytickou. Celková strategie řešení směřuje od návrhu modifikovaného testovacího uzlu přes akvizici vysokofrekvenčních diagnostických dat AE až po finální validaci predikčních modelů na bázi umělých neuronových sítí. Tento postup byl zvolen s ohledem na potřebu vytvořit robustní laboratorní metodiku pro sledování degradace specifických kompozitních polymerních vrstev u sférických kloubových vzorků GE20-AW v režimu akcelerovaného poškození. Celý proces je rozdělen do dvou metodických větví využívajících modulární rotační tribometr s axiálním zatěžováním v odlišných konfiguracích.

### 4.1.1 Predikce opotřebení ve 4-ball konfiguraci (H1)

Prvotní fáze řešení v rámci této větve se zaměřuje na vývoj a implementaci experimentální konfigurace schopné vyvolat cílenou degradaci kluzné vrstvy v časovém horizontu vhodném pro laboratorní zkoušky. Jádrem tohoto návrhu je přechod od původního konformního kontaktu k nekonformnímu uspořádání využívajícímu čtyři kuličky v pevně upnuté sestavě, které rotují vůči sférickému povrchu ložiska. Tato konfigurace umožňuje dosáhnout vysokých kontaktních tlaků při zachování stability měření. Jako základní platforma byl zvolen modulární rotační tribometr s axiálním zatěžováním, na který je zkonstruována testovací sestava včetně pohonného ústrojí. Součástí konstrukčního návrhu je rovněž specifikace měřicího řetězce pro AE a integrace doplňkové senzoriky pro monitoring provozních stavů.

Navazující etapa představuje vlastní experimentální činnost a akvizici primárních dat. Metodika experimentu je založena na realizaci tribologických zkoušek s odstupňovanou dobou trvání, během nichž je pomocí vlastních skriptů v prostředí Python zajištěna segmentová akvizice vysokofrekvenčního signálu AE. Klíčovým prvkem této fáze je definování metodiky extrakce příznaků, kdy jsou pro každý nasnímaný segment v reálném čase vypočítávány relevantní statistické a popisné veličiny (např. RMS, absolutní energie či parametry distribuce amplitudy). Referenční hodnoty opotřebení (ground truth) jsou získávány prostřednictvím ex-situ analýzy úbytku materiálu v definovaných kontrolních bodech před testem, v jeho průběhu a po ukončení zkoušky. Vzhledem k tomu, že přímé měření úbytku probíhá pouze v diskrétních intervalech, je pro účely trénování modelů a

vytvoření spojitého cílového vektoru využita interpolace naměřených hodnot mezi jednotlivými kontrolními body.

Finální část metodického postupu tvoří analytické zpracování dat a aplikace algoritmů hlubokého učení. Tento proces začíná ošetřením a preparací datasetu, která zahrnuje analýzu korelací mezi extrahovanými příznaky AE, interpolovanými hodnotami opotřebení a doplňkovými daty z ostatních senzorů, následovanou normalizací datových sad. Specifický důraz je kladen na preprocessingový řetězec, kde je k eliminaci stochastického šumu a vyhlazení trendů u vybraných veličin využit filtr Savitzky-Golay, zvolený pro svou schopnost zachovat fyzikální integritu signálu bez vnesení fázového zpoždění. Metodika hodnocení modelů je postavena na srovnání dopředných vícevrstevných perceptronů (MLP) a rekurentních architektur (RNN, LSTM, GRU). Cílem analýzy je kriticky posoudit přesnost predikce jednotlivých modelů, jejich schopnost generalizace a dodržení fyzikální podmínky monotonicity predikovaného opotřebení na nezávislých testovacích sadách.

#### 4.1.2 Charakterizace útlumu (H2)

Pro studium vlivu tloušťky polymerní vrstvy na parametry signálu AE je využita modifikovaná sestava, kde je horní držák kuliček nahrazen upínkou s celým sférickým kloubem. Vzhledem k požadavku na vysoké axiální zatížení, které se stanovilo na 15 kN, je z měřicího řetězce demontován silový senzor limitovaný hodnotou 5 kN. Velikost zátěžné síly  $F_a$  je v tomto případě určena analyticky z tlaku v pneumatickém okruhu pístu podle vztahu:

$$F_a = p \cdot S \quad (4-1)$$

kde  $p$  je tlak v pneumatickém systému a  $S$  je účinná plocha pístu. Vlastní měření spočívá v detekci AE hitů generovaných v horním kloubu při použití vzorků s odstupňovanou tloušťkou povlaku. Výsledkem je sledování korelace mezi zbytkovou tloušťkou vrstvy a energetickými parametry detekovaných událostí AE.

### 4.2 Materiál a testovací podmínky

#### 4.2.1 Charakteristika testovaného vzorku

Pro experimentální účely byla zvolena axiální sférická kluzná ložiska typu GE20-AW (výrobce Schaeffler/INA). Jedná se o bezúdržbové ložisko odpovídající normě DIN ISO 12240-3. Tato ložiska jsou konstrukčně navržena pro přenos vysokých axiálních sil při


relativně nízkých kluzných rychlostech a jsou určena pro aplikace s jednostranným zatížením.

### Konstrukční a technické parametry

Vzorek se skládá ze dvou oddělitelných částí: hřídelového kroužku s vypouklým kulovým povrchem a tělesového kroužku s odpovídajícím dutým kulovým povrchem. Geometrie ložiska zajišťuje konformní kontakt na kulové ploše, což umožňuje kompenzaci nesouososti hřídele vůči tělesu. Hlavní technické a rozměrové parametry jsou uvedeny v tabulce níže viz Tab. 4-1.

Tab. 4-1: Specifikace ložiska GE20-AW

| Parametr                    | Označení | Hodnota [jednotka] |
|-----------------------------|----------|--------------------|
| Průměr díry ložiska         | d        | 20 mm              |
| Vnější průměr ložiska       | D        | 55 mm              |
| Celková výška ložiska       | T        | 20 mm              |
| Šířka vnitřního kroužku     | B        | 14,3 mm            |
| Dynamická únosnost, axiální | Ca       | 225 000 N          |
| Statická únosnost, axiální  | C0a      | 376 000 N          |
| Hmotnost                    | m        | cca 0,26 kg        |



Obr. 4-2: Dokumentace sférického testovaného vzorku [32]

### Materiálové provedení vzorku


Materiálová skladba ložiska GE20-AW je koncipována pro zajištění dlouhodobého bezúdržbového provozu v režimu suchého tření Obr. 4-3. Kluzná dvojice je tvořena dvěma funkčně odlišnými povrchy, které spolu tvoří konformní kontakt. Hřídelový kroužek ložiska disponuje vypouklým kulovým povrchem, který je opatřen elektrolyticky naneseným povlakem z tvrdého chromu. Tato úprava zajišťuje vysokou povrchovou tvrdost proti plochy, vynikající odolnost proti korozivním vlivům a minimalizuje adhezivní opotřebení při vzájemném pohybu s kluzným materiálem tělesového kroužku.

Klíčovým prvkem tribosystému je speciální kompozitní kluzná vrstva, nanesená na vnitřním kulovém povrchu tělesového kroužku. Jedná se o pokročilý kompozitní materiál na bázi tkaniny z PTFE (polytetrafluorethylen), která je fixována v matrici z vysoce pevné syntetické pryskyřice a následně pevně spojena s ocelovým tělesem ložiska. Tato struktura kombinuje vynikající kluzné vlastnosti teflonových vláken s mechanickou stabilitou nosné pryskyřice. Díky inherentně nízkému koeficientu tření PTFE nevyžaduje ložisko po celou dobu své životnosti žádné domazávání. Kromě vysoké únosnosti pro statické i dynamické zatížení

vykazuje kompozitní kluzná vrstva díky svému kompozitnímu charakteru také výrazné tlumicí schopnosti, které přispívají k absorpci rázů a vibrací vznikajících v mechanickém uložení. Technická specifikace výrobce zaručuje zachování těchto tribologických a mechanických charakteristik v širokém operačním rozsahu teplot, konkrétně od  $-50\text{ }^{\circ}\text{C}$  do  $+150\text{ }^{\circ}\text{C}$ .

#### 4.2.2 Testovací podmínky

Pro experimentální ověření schopnosti predikce opotřebení byla navržena testovací konfigurace pro akcelerované opotřebení využívající čtyři ocelové kuličky o průměru 3/4 palce (cca  $19,05\text{ mm}$ ), které jsou přitlačovány k funkční ploše sférického ložiska GE20-AW. Tato materiálová dvojice představuje kontakt tuhého tělesa (ložisková ocel) a vrstveného tělesa tvořeného polymerním kompozitním povlakem o tloušťce  $t = 0,5\text{ mm}$  na tuhém ocelovém substrátu (viz Obr. 4-3).



Obr. 4-3: Náhled do kontaktu kuliček se sférickým ložiskem a rozkladem kontaktních sil pro jednu kuličku  $D_k = 19,05\text{ mm}$ ,  $\alpha = 41,4^{\circ}$  se schématem rozkladu sil pro jednu kuličku

#### Rozklad sil v kontaktu

V rámci definování testovacích podmínek a fyzikálního principu zkoušky je nezbytné provést detailní rozbor rozložení sil v nekonformním kontaktu čtyř kuliček se sférickým vzorkem. Prostřednictvím silového rozkladu a na základě znalosti geometrického uspořádání (stykového úhlu  $\alpha$ ) lze analyticky stanovit jednotlivé reakční síly v bodech styku kuliček s funkční plochou ložiska, viz Obr. 4-3.

Pro výpočet normálové síly působící kolmo na kluznou vrstvu ložiska je zaveden zjednodušující předpoklad vycházející ze symetrie zkušebního uzlu. Vzhledem k rovnoměrnému uspořádání čtyř kontaktních bodů se radiální složky kontaktních sil (síly v rovině kolmé k hlavní ose rotace) vzájemně eliminují. Tento předpoklad umožňuje redukovat výpočetní model na silovou rovnováhu v hlavní axiální ose tribometru, kde je celková zatěžovací síla rovnoměrně distribuována mezi jednotlivé kuličky v závislosti na jejich geometrické poloze vůči sférickému povrchu ( $F = \frac{F_{axiální}}{4}$ ) Obr. 4-3. Výsledná síla působící kolmo na kontaktní povrch sférického vzorku pak odpovídá rovnici (4-2).

$$F_k = \frac{F}{\cos \alpha} = \frac{650}{\cos 41,4^\circ} = 866,5 \text{ N} \quad (4-2)$$

### Mechanika kontaktu vrstveného tělesa

Zátěžné konstantní síly byly zvoleny v rozsahu 150 N až 650 N se stálou frekvencí otáčení vřetene ( $n$ ) 50 ot/min, což odpovídá lineární kluzné rychlosti přibližně 100 mm/s. Tato rychlost je pro kompozitní materiály na bázi PTFE považována za kritickou hranici Obr. 4-4, při které dochází k výrazné tepelné expozici v kontaktu a akceleraci deformačních mechanismů. Kritická oblast kompozitní kluzné vrstvy je závislá na závislosti rychlosti s kontaktním tlakem.

Při stanovení kontaktního namáhání v tomto uzlu existuje zásadní rozdíl mezi teoretickým modelem a reálným kontaktem. Hertzova teorie pro ideální kontakt dvou ocelových těles uvažuje materiálovou homogenitu a vysoký modul pružnosti, což pro kompozitní kluznou vrstvu neplatí. Vlivem nízké tuhosti a vysoké stlačitelnosti kompozitní kluzné vrstvy dochází k výraznému ponoření ocelové kuličky do povlaku, které zásadně mění distribuci tlaku i velikost stykové plochy oproti teoretickému předpokladu. Simulace kontaktu vícevrstevných materiálů jsou výpočetně náročné, proto je v této práci kontaktní namáhání pokryto variací zatěžovací síly v jednotlivých testech.

Právě deformace polymerní matrice při ponoření kuličky a napěťová koncentrace na rozhraní povlak-substrát jsou klíčovými zdroji signálu akustické emise. Rozsah zatížení 150 – 650 N byl zvolen tak, aby pokryl přechod od elastické deformace povlaku k fázi progresivního opotřebení a plastického toku kompozitní kluzné vrstvy při různých kluzných rychlostech (viz Obr. 4-4). Takto definované podmínky zajišťují generování diagnostických dat s dostatečnou informační hodnotou pro trénink neuronových sítí.

#### Application ranges (Figure 5)

Max. contact pressure:

■ dynamic

$$p = 200 \text{ N/mm}^2$$

■ static

$$p_0 = 300 \text{ N/mm}^2 \text{ (due to support-body material)}$$

Max. sliding velocity:

$$v = 100 \text{ (220) mm/s}$$

Thermal load limits:

$$p = 200 \text{ N/mm}^2 \rightarrow v_{\max} = 5 \text{ mm/s}$$

$$v = 100 \text{ mm/s} \rightarrow p_{\max} = 5 \text{ N/mm}^2$$


■ Max. specific output:

$$p \cdot v = 2\,500 \text{ (5\,000) N/mm}^2 \cdot \text{mm/s for } p = 50 \text{ N/mm}^2.$$

■ Coefficient of friction:

$$\mu = 0.02 \text{ to } 0.2$$

Special requirements are necessary for the values given in parentheses. Please consult ELGES in such cases.



Obr. 4-4: Aplikační oblast pro kompozitní kluznou vrstvu [33]

## 4.3 Experimentální zařízení a přístrojové vybavení


Základem experimentální činnosti bylo využití modulárního rotačního tribometru s axiálním zatěžováním. Na tento mechanický základ byla navržena a zkonstruována vlastní testovací konfigurace pro akcelerované zkoušky opotřebení, doplněná o dedikovaný měřicí řetězec pro akvizici vysokofrekvenčního signálu akustické emise (AE) a provozních parametrů.

### 4.3.1 Technicko-funkční návrh měřicí konfigurace

Hlavní rám použitého tribometru je tvořen třemi masivními ocelovými sloupky, které tuhým způsobem spojují horní a spodní ocelovou desku. V horní desce je uložen rotor poháněný elektromotorem prostřednictvím řemenového převodu, zatímco ve spodní desce je usazen zatěžovací mechanismus tvořený pneumatickým pístem. Tento píst je schopen vyvodit maximální zátěžnou sílu v axiálním směru až 100 kN (viz Obr. 4-5 pozice 7). Návrh nové testovací konfigurace (na Obr. 4-5 – vlevo, zvýrazněna zeleně) vycházel z primárního požadavku na vytvoření adekvátních podmínek pro tribologické zkoušky kluzných sférických ložisek při dodržení celkové zástavbové výšky 224 mm.

Konstrukční proces byl zahájen vývojem stacionární spodní části uzlu a rotujícího horního držáku kuliček (pozice 1, 2, 3 na Obr. 4-5). Požadavek na plynulou aplikaci axiálního zatížení (pozice 7 na Obr. 4-5) do hodnoty přibližně 1 kN je realizován využitím stávajícího pístu v kombinaci s vloženou zátěžnou pružinou. Pružina zde působí jako poddajný člen zajišťující jemnou regulaci přítlaku a kompenzaci poklesu axiální síly vyvolaného úbytkem

materiálu vlivem opotřebení během testu. Vzhledem k existující platformě vřetena a zátěžového systému byly připojovací rozměry nové konfigurace těmto rozhraním plně přizpůsobeny.




Obr. 4-5: vlevo) Zeleně zvýrazněná část, která byla navržena v rámci této DP, vpravo) Modulární rotační tribometr s axiálním zatěžováním s testovací konfigurací. 1.Horní držák kuliček, 2.Domek pro uložení vzorku a upevnění senzorů, 3.Spodní část konfigurace – vedení zatěžovacího členu se senzorem, 4.Řemenový převod vedený od Elektromotoru, 5.Rotor tribometru, 6.Snímač třecí síly, 7.Zatěžovací člen

Během konstrukčního návrhu bylo klíčové optimalizovat prostorové uspořádání tak, aby představovalo ideální kompromis mezi přístupností pro výměnu vzorků, funkcí zátěžné pružiny a zajištěním vysoké tuhosti a souososti celého uzlu. Za účelem efektivní manipulace byl navržen odnímatelný domek pro uložení vzorku fixovaný k sestavě středovým šroubem (Obr. 4-6, pozice 3). Protikus sestavy je tvořen čtyřmi testovacími kuličkami přesně ustavenými do upínací misky (Obr. 4-6, pozice 1), která je následně zajištěna k horní upínce (Obr. 4-6, pozice 13) radiálními stavěcími šrouby. Horní upínka pak zajišťuje propojení misky pro kuličky s rotorem. Prostorové uspořádání komponent spodní stacionární části (Obr. 4-6, pozice 4, 5, 9, 10, 11) bylo navrženo s cílem minimalizovat úhlové odchylky při omezeném vertikálním prostoru. Snímání třecího momentu je realizováno nepřímo měřením reakční síly pomocí siloměru na rameni o přesně definované délce (Obr. 4-6, pozice 7, 8), z níž je následně moment analyticky dopočítán.

Vlastní montáž testovací konfigurace je realizována dle systematického postupu, který zahrnuje v úvodní fázi ustavení základní stavitelné upínací desky (Obr. 4-6, pozice 12). Následně je na zátěžný píst se středěním (Obr. 4-6, pozice 6) osazena zátěžná pružina. Další krok spočívá v nalisování lineárního vedení do vnějšího tělesa vedení (Obr. 4-6, pozice 9 a 10) a jejich společném nasazení na pružinu. Spojovací šrouby k upínací desce jsou v této fázi dotaženy pouze částečně, aby byla zachována možnost budoucího vystředění celého



vnějšího uzlu. Do vnějšího vedení je poté vložena dosedací vložka pružiny s integrovaným senzorem síly a následně je nasunut píst lineárního vedení (Obr. 4-6, pozice 4, 5 a 11). K rotoru tribometru je připevněna horní upínka (Obr. 4-6, pozice 13), do které se fixuje miska s testovacími kuličkami (Obr. 4-6, pozice 1). Kompletace spodní části je dokončena vsazením domku se vzorkem a instalovaným ramenem pro přenos třecí síly (Obr. 4-6, pozice 2, 3 a 8) do pístu lineárního vedení. Senzor pro snímání třecí síly (Obr. 4-6, pozice 7) je následně ustaven do rovnoběžné polohy s ramenem. Kritickým krokem je vystředění horní upínky vůči domku vzorku (Obr. 4-6, pozice 3 a 13) pomocí číselníkového úchylkoměru. Po dosažení požadované přesnosti, kdy úhlová odchylka nepřesahuje 0,1 mm, jsou finálně dotaženy šrouby vnějšího vedení (Obr. 4-6, pozice 9).



Obr. 4-6: Střední oblast konfigurace. 1.Miska s kuličkami, 2.Vzorek-Sférické kluzné ložisko, 3.Domek pro uložení vzorku a senzorů, 4.Píst lineárního vedení, 5.Senzor axiální síly, 6.Pneumatický píst, 7.Senzor snímání třecí síly, 8.Rameno pro přenos třecí síly, 9.Vnější vedení, 10. Lisované lineární vedení, 11.Zátěžná pružina s vodícím dílem, 12. Stavitelná upínací deska, 13. Horní upínka

#### 4.3.2 Spodní část konfigurace

Po kompletaci rotačního uzlu následovalo sestavení spodní stacionární části konfigurace. Tato podsestava tvoří základnu pro aplikaci zátěžné síly a je klíčová pro přesné měření třecího momentu i diagnostických signálů. Spodní část konfigurace Obr. 4-7 (vpravo) sestává z následujících funkčních komponent:



1. **Hlavní tělo s kluznými pouzdry:** Základní nosný prvek stacionární části, který zajišťuje tuhost celého uzlu a díky nalisovaným lineárním pouzdrům definuje přesné vedení pohyblivého pístu.
2. **Zátěžová vložka a axiální siloměr:** Vložka sloužící jako dosedací plocha pro zátěžnou pružinu, k níž je pevně přišroubován senzor pro přímé měření axiální síly působící na vzorek.
3. **Lineární píst a uložení hřídele:** Píst osazený sériově uspořádanými ložisky, který nese hřídel domku vzorku. Tato konstrukce zajišťuje plynulý vertikální posuv nezbytný pro kompenzaci opotřebení a zároveň umožňuje volnou rotaci domku pro potřeby měření třecího momentu.
4. **Instrumentovaný domek vzorku:** Odnímatelná jednotka určená pro přesné uložení sférického ložiska a integraci diagnostických senzorů (AE a teplota). Domek je doplněn o demontovatelné rameno, které přenáší reakční třecí sílu na externí siloměr.


V rámci první části (1) byla navržena součást hlavního těla. Zajišťuje pevné upnutí celé sestavy na upínací desku tribometru pomocí 6 šroubů M10 po obvodu a příruby se šesti závitovými dírami M10 na opačné straně desky. Do hlavního těla byly vybrány k zalisování kluzné pouzdra MPBZ50 s poměrem délek tak aby pokryly celou délku hlavního těla. Také byla z její strany vyfrézovaná drážka pro vedení kabelu knoflíkového siloměru.

Druhá oblast (2) zahrnuje vložku pro pružinu a samotný knoflíkový silový senzor. Vložka pro pružinu, jak už napovídá název zajišťuje precizní dosednutí pružiny, která má zajišťovat plynulé zatížení. Vnější průměr má uložení s vůlí vůči vodícím kluzným pouzdrům. Knoflíkový silový senzor je SAUTER Y500-C1 (více v kapitole senzoriky). Ten je pomocí třech šroubů M4 připevněný k vložce pro pružinu.


Část třetí (3) zajišťuje úlohu oddělení zatěžovací síly od rotačního momentu vyvinutého třením v části (4). Je zde vodící píst s vnějším uložením s vůlí a vnitřkem uzpůsobeným pro uložení dvou kuželíkových ložisek 30202 od firmy SKF s uspořádáním do „O“. Dále je umístěna hřídel domku na vnitřním průměru ložisek zajišťující spojení s domkem v části (4). V této hřideli je po celé její délce vytvořena závitová díra M8 pro pevné upnutí vůči domku a z druhé strany. Na jejím čele jsou pak dvě přesné kolíkové díry o průměru 3 mm sloužící pro aretaci otáčení domku při utahování šroubu M8. Zespod vodícího pístu je šrouby M3 po obvodu přimontovaná dosedací součást pro knoflíkový senzor síly.

Část čtvrtá (4) (viz Obr. 4-8) je nejpodstatnější součástí této spodní sestavy. Domek je navržen tak aby umožnil pevné upnutí testovaného vzorku pomocí přechodného uložení a dvou postranních stavěcích šroubů M6. Vzorek je tedy montován a demontován pomocí lisování. Zalisování se provádí pomocí ručního lisu na dílně. Vylisování pomocí čtyř šroubů M6 ze spodní strany domku. Jsou zde dva připojené senzory pomocí šroubovacích slotů. Prvním je senzor AE typu MIDI s předpínacím přípravkem (detailně popsany v následujících odstavcích). Druhým je termočlánek MSNDM6 typu K se šroubovaným

připojením. Rameno pro přenos třecí síly na ohybový senzor je alokováno na protější straně senzorů. Skládá se ze hřídele s vnitřním a vnějším závitem na koncích a dosedací kostky pro ohybový senzor s průchozím otvorem s kuželovým zahloubením pro upnutí vůči hřídeli. Vnitřní otvor pro dosednutí hřídele domku je navržen jako uložení s mírnou vůlí, aby bylo možné ho sejmout rukou z důvodu omezeného místa vně tribometru.




Obr. 4-7: Vlevo) Implementovaná konstrukce spodní části konfigurace, Vpravo) CAD model sestavy spodní části konfigurace s popisky



Obr. 4-8: Domek pro uložení testovaného vzorku s popisem částí a součástí

Pro kontinuální měření akustické emise a eliminování vnějších jevů byl pro senzor AE typu MIDI vytvořen předpínací přípravek Obr. 4-9. Umožňuje vyvinout předpětí senzoru vůči vzorku pomocí stlačení pružiny zašroubováním (až 15 N). Pro minimalizaci parazitních strukturálních vibrací z rámu tribometru jsou mezi tělem senzoru a vodící maticí pružiny umístěné dvě O-těsnění. V kontaktu piezoelektrického členu s testovaným vzorkem byla při každém testu nanесena specializovaná ultrazvuková vazelínka.



Obr. 4-9: Vlevo) CAD návrh předpínací sestavy senzoru AE, Vpravo) Funkční model předpínací sestavy AE

### 4.3.3 Horní část konfigurace

Zajištění přesného a stabilního přenosu krouticího momentu bez vnesení parazitních vibrací či excentricity je primárním úkolem horní rotující části měřicí konfigurace. Tento uzel slouží k rovnoměrnému upnutí zkušebních kuliček tak, aby nedocházelo k jejich protáčení nebo axiálnímu či radiálnímu vyosení. Díky striktnímu tolerování a přesnému středění součástí minimalizuje celá sestava vliv házivosti na samotný proces testování. Horní rotující část konfigurace (viz Obr. 4-10) se skládá ze dvou hlavních funkčních celků:

1. **Horní upínka:** Slouží jako tuhý adaptér a rozhraní mezi rotorem tribometru a držákem vzorků, přičemž zajišťuje centrické uložení celé sestavy s minimální házivostí.
2. **Miska s kuličkami:** Vyjímatelná podsestava s tvarově přesnými dosedacími plochami, která fixuje čtveřici zkušebních kuliček do přesně definované kontaktní geometrie.

Horní upínka (1) byla zkonstruována jako přesný adaptér, jehož úkolem je eliminovat nepřesnosti vznikající při montáži a rotaci. K rotoru tribometru je pevně fixována pomocí šesti šroubů. Pro zaručení maximální přesnosti je uložení na obou funkčních rozhraních – tedy mezi upínkou a rotorem i mezi upínkou a miskou – navrženo jako přechodné. Při výrobě byl kladen extrémní důraz na dodržení geometrických tolerancí souososti, házivosti a kruhovitosti, což je nezbytné pro potlačení vlivu případného vyosení kuliček na měřený třecí moment. Aretace misky v upínce je bezpečně zajištěna pomocí tří radiálně umístěných stavěcích šroubů M4 po obvodu dílce.




Obr. 4-10: Vlevo) Miska s kuličkami, Uprostřed) Horní část konfigurace, Vpravo) CAD model horní části konfigurace

Konstrukce misky s kuličkami (2) vychází z praktických požadavků na efektivní obsluhu experimentu. Musí umožňovat rychlou demontáž z upínky, bezproblémovou výměnu opotřeбенých kuliček a snadné čištění od zbytků otěrových částic. Mezi kritické a přesně tolerované parametry tohoto dílu patří vnější průměr válce a vnitřní šikmá dosedací plocha. Vnější průměr je lícován v přísném souladu s tolerancemi horní upínky, zatímco vnitřní plocha má předepsaný přesný úhel sklonu, souosost a házivost vůči vnějšímu referenčnímu válci. Kuličky jsou v misce středěny a upínány prostřednictvím kuželovitého protikusu, který zaručuje jejich vzájemně přesné dosednutí. Vzhledem k vysokým nárokům na rovinnost (koplanaritu) všech čtyř kontaktních bodů bylo při finální kompletaci sestavy nutné kuličky lokálně vypodložit tenkými kalibračními plíšky.

#### 4.3.4 Měření třecí síly

Nedílnou součástí měřicí smyčky je systém pro snímání třecí síly, který je realizován pomocí ohybového snímače CB 30-3Q1 (viz Obr. 4-11). Tento senzor je upevněn na jednom z nosných sloupků tribometru pomocí polohovatelného držáku, který umožňuje přesné výškové nastavení vůči měřicímu rameni. Tento držák je složen ze dvou upínek a dvou vložek spojených pomocí dvou šroubů M10. Rameno o délce 99,5 mm, které je pevně spojeno s domkem vzorku, přenáší tečný odpor vznikající v kontaktu přímo na čelo snímače. Při instalaci byl kladen důraz na kolmost dotyku ramene a snímače, aby byla eliminována chyba měření způsobená nevhodným rozložením silových složek. Správné ustavení senzoru bylo ověřeno měřením úhlové odchylky.



Obr. 4-11: Ohybový snímač pro měření třecí síly s upínacím držákem

### 4.3.5 Upnutí motoru

Oblast pohonu testovací konfigurace je umístěna na horní části původního tribometru. Hlavní částí je elektromotor 1LE1004-1AB42-2AA4 od firmy Siemens s výkonem 2,2 kW. Výběr elektromotoru vycházel z požadavků na víceúčelové testování na tomto zařízení. Tento motor se již se nacházel ve vlastnictví Ústavu Konstruování na VUT.

Potenciální třecí moment (rovnice (4-4), který by mohl vzniknout v kontaktu byl spočítán z maximální normálové síly  $F_k$  známé (rovnice (4-2) a přibližného koeficientu kinematického tření ( $\mu_{dry}$ ) pro kontakt ocel na ocel za sucha jenž činí přibližně 0,42. Vypočítaná třecí síla působí na kontaktním poloměru ( $R_t$ ) 19,737 mm. Výkon elektromotoru potřebný pro kritický stav testování (rovnice (4-5) je 0.0347 kW. Zvolený motor je tedy více než dostatečný.

$$F_{tmax} = F_k \cdot \mu_{dry} = 866,5 \cdot 0,42 = 364 \text{ N} \quad (4-3)$$

$$M_{tmax} = F_t \cdot R_t = 364 \cdot 19,737 = 7,18 \text{ N} \cdot \text{m} \quad (4-4)$$


$$P_{tmax} = M_{tmax} \cdot 2 \cdot \pi \cdot \frac{n}{60} = 7,18 \cdot 2 \cdot \pi \cdot \frac{50}{60} = 0.0376 \text{ kW} \quad (4-5)$$

Připojení elektromotoru ke zbytku konstrukce tribometru bylo provedeno pomocí L-úchyty složeného ze dvou součástí. Těmi jsou horizontální a vertikální úchyty motoru smontované k sobě šrouby M10. L-úchyt je na několika místech přimontovaný k základní konstrukci tribometru pomocí šroubů M10 a M12.

Řemenový převod byl navržen na převodový poměr 0,8 tedy do výkonu. Řemenice u motoru byla vybrána 80 zubová HDB 80-5M 15-1610. Řemenice u tribometru byla zvolena HDB



64-5M 15-1210 s 64 zuby. Kompatibilní ozubený řemen s řemenicemi byl zvolen HTD\_05M-0890-15. Pro předpínání řemenu byl vytvořen jednoduchý napínák řemenu.



Obr. 4-12: CAD model upnutí elektromotoru s řemenovým převodem

#### 4.3.6 Modifikace sestavy pro charakterizaci útlumu (H2)

Za účelem realizace experimentální metodiky pro ověření hypotézy H2 bylo nutné přistoupit k modifikaci stávající měřicí konfigurace. Úprava se zaměřuje primárně na spodní stacionární uzel a horní upínku protikusu sférického ložiska. Hlavní konstrukční změna spodní části spočívá v demontáži axiálního siloměru a doplnění vložky pro pružinu o dosedací člen (viz Obr. 4-13), který zajišťuje přímý přenos síly na píst. Tato úprava byla nezbytná z důvodu požadavku na vysoké axiální zatížení, které překračuje měřicí rozsah původního senzoru (limit 5 kN).

Z domku pro uložení vzorku byly pro tuto konfiguraci odstraněny doplňkové senzory s výjimkou piezoelektrického snímače AE a jeho předpínací mechanické sestavy. Jelikož v této sestavě chybí prvek pro přímé měření síly, je celkové aplikované zatížení stanovováno nepřímou ze známé kontaktní plochy pístu a tlaku hydraulického média, který je monitorován na tlakoměru čerpadla. Maximální velikost zátěžné síly  $F_a$  je v této konfiguraci limitována statickou únosností pomocných ložisek SKF 30202 ( $C_0 = 14,6$  kN), přičemž bezpečná provozní hodnota byla stanovena na 14 kN.


Průměr kontaktní plochy zatěžovacího pístu  $d_p$  činí 33 mm. Odpovídající obsah kontaktní plochy  $S_p$  je definován vztahem (4-9):

$$S_{pist} = \frac{\pi \cdot D_{pist}^2}{4} = \frac{\pi \cdot 33^2}{4} = 855,3 \text{ mm} \quad (4-6)$$

Výsledný zatěžovací tlak ( $p$ ) potřebný pro dosažení požadované síly je následně analyticky dopočítán dle vztahu (4-10):

$$P_{pist} = \frac{F_{H2}}{S_{pist}} = \frac{14\,000}{855,3} = 16,37 \text{ MPa} \quad (4-7)$$

Kromě úpravy spodního uzlu byla pro fixaci protikusů (kloubů) sférického ložiska navržena a vyrobena nová upínací hlava rotoru tribometru (Obr. 4-13). Konstrukce hlavy umožňuje zalisování kloubu ložiska do tělesa upínky, čímž je zaručena přesná souosost s osou rotace vřetena. Po celkové kompletaci je horní i spodní část sestavy vzájemně ustavena pomocí číselníkového úchylkoměru, aby byla minimalizována házivost a zajištěno striktně lineární silové působení v kontaktu.



Obr. 4-13: Upravená konfigurace pro ověření vlivu tloušťky vrstvy na prostupnost signálu AE

#### 4.3.7 Měřicí řetězec a akviziční systém

Pro komplexní monitoring tribologického kontaktu v rámci konfigurace tribometru byl navržen měřicí řetězec, který integruje snímače provozních veličin s vysokofrekvenční diagnostikou akustické emise. Snímání axiálního zatížení zajišťuje knoflíkový snímač síly

SAUTER CO 500-Y1 se jmenovitým měřicím rozsahem do 5000 *N*, jenž je integrován přímo v silové ose zatěžovacího mechanismu. Třecí moment je měřen nepřímo prostřednictvím ohybového tenzometrického snímače SAUTER CB 30-3Q1 s kapacitou 300 *N*, který zaznamenává reakční sílu na rameni (*R*) o přesně definované délce 99,5 *mm*. To umožňuje výpočet třecího momentu v daný okamžik Rov. (4-8). Volba těchto řad snímačů byla podmíněna jejich unifikovanými montážními rozměry. To v případě potřeby umožňuje operativní záměnu za citlivější varianty v rámci jedné rodiny senzorů. Monitoring tepelného stavu na vnějším průměru sférického kroužku ložiska GE20-AW pak doplňuje termočlánek typu K instalovaný do závitového otvoru M6 v domku vzorku.

$$F_t = \frac{M_t}{R} \quad (4-8)$$

Klíčovým prvkem celého diagnostického systému je širokopásmový senzor akustické emise typu MIDI od společnosti DAKEL. Ten je v kombinaci se specificky navrženým předpínacím uložením pro maximální efektivitu senzoru. Tento senzor má průměr 6 *mm* a průměr dotykové plochy 5 *mm*. Frekvenční odezva snímače vykazuje stabilitu v pásmu 150–400 *kHz*. V oblasti nad 500 *kHz* je patrný strmý pokles relativní citlivosti, která zde klesá pod hranici –20 *dB* oproti hlavnímu pracovnímu pásmu.

Digitalizaci všech naměřených signálů zajišťuje multifunkční akviziční karta National Instruments USB-6451, jejíž výběr byl podmíněn především poměrem ceny, počtem analogových kanálů a možností programování v prostředí Python. Karta umožňuje vzorkování s frekvencí až 1 *MS/s* na kanál, což je nezbytné pro zachování informační hodnoty vysokofrekvenčního AE signálu. Určitou technologickou limitací zvoleného hardwaru je sdílená časová základna pro všechny analogové vstupy, která neumožňuje nastavit odlišné vzorkovací frekvence pro jednotlivé kanály. Z tohoto důvodu jsou i nízkofrekvenční veličiny, jako jsou síly a teplota, snímány na frekvenci 1 *MHz* a jejich následná úprava downsamplingem na efektivní frekvenci 10 *kHz* probíhá softwarově v rámci post-processingu nebo přímo v měřicím skriptu.

## 4.4 Metody


### 4.4.1 Metodika experimentu a měření opotřebení

Soubor realizovaných experimentů zahrnoval zkoušky v rozsahu axiálního zatížení 150 *N* až 650 *N* při konstantní frekvenci otáčení 50 *ot/min*. Jednotlivé úrovně zatížení byly pro každý test voleny náhodně, aby bylo zajištěno rovnoměrné pokrytí sledovaného intervalu a eliminována systematická chyba měření. Celková doba trvání experimentu byla stanovena



na tři až čtyři hodiny, což představuje časový úsek umožňující rozvoj měřitelných degradací polymerní kompozitní kluzné vrstvy při zvolené kritické kluzné rychlosti 100 mm/s.

Základním referenčním bodem pro stanovení absolutního opotřebení byla precizní souřadnicová metrologie. Před zahájením a po ukončení každého experimentu byl sférický vzorek zaměřen na souřadnicovém měřicím stroji (CMM). Měření bylo realizováno snímáním profilových křivek ve čtyřech ortogonálních rovinách, označených jako severní (N), jižní (S), východní (E) a západní (W). Z těchto 2D průřezů byla následně vypočtena průměrná hloubka vtisku a celkový objemový úbytek materiálu, což posloužilo jako kalibrační báze pro dynamický model opotřebení.



Obr. 4-14: Ložisko GE20-AW s vyznačenými rovinami měření na CMM

Pro zachycení nelineární progresse degradace v čase byla polovina realizovaných testů podrobena proceduře průběžného monitorování hmotnosti. U této skupiny vzorků probíhalo vážení na analytických vahách s rozlišením 0,001 g v osmi definovaných časových etapách (v 10., 20., 30., 45., 60., 90., 120. a 180. minutě). U zbývajících poloviny testů bylo opotřebení měřeno pouze v počátečním a finálním stavu pomocí CMM, přičemž jejich vnitřní časový průběh byl následně rekonstruován matematickým modelem.

Transformace diskrétních měření na spojitý časový vektor opotřebení byla realizována pomocí výpočetního skriptu v jazyce Python *01\_calculate\_wear.py* s využitím skokového kubického Hermitova interpolačního polynomu (PchipInterpolator). Tato metoda byla zvolena pro zajištění striktní monotonicity výsledné křivky, čímž je eliminováno riziko nereálných oscilací hodnot úbytku materiálu v čase. Algoritmus u referenčních testů s váhovými kontrolními body vytváří charakteristickou křivku úbytku, která je v závěru škálována na absolutní hodnoty hloubky a objemu zjištěné metrologickou analýzou na CMM.

U testů, u kterých nebylo prováděno průběžné vážení, využívá algoritmus metodu adaptivní aproximace. Na základě průměrné axiální síly ( $F_a$ ) naměřené v jednotlivých segmentech daného testu skript identifikuje v databázi dva nejbližší referenční experimenty s průběžným měřením. Mezi charakteristickými tvary těchto dvou křivek je následně provedena lineární aproximace, která určí výsledný průběh opotřebení pro aktuální hodnoty zatížení. Tento

postup umožňuje pro každý sekundový segment akustické emise v celém datasetu přiřadit odpovídající hodnotu kumulativního opotřebení. Metodický postup propojující precizní mechanické měření s numerickou interpolací tak vytváří fyzikálně konzistentní cílový vektor pro následnou implementaci rekurentních neuronových sítí.

#### 4.4.2 Metodika akvizice a digitálního zpracování dat

Pro zajištění synchronního sběru dat a jejich následné primární zpracování byl v prostředí Python vyvinut modulární akviziční skript *Long\_Segment\_test\_ALL\_logging-Final.py* využívající architekturu paralelního zpracování (multiprocessing). Tento přístup umožňuje efektivní separaci výpočetně náročných úloh, jako je vysokofrekvenční vzorkování, digitální filtrace v reálném čase, vizualizace a ukládání dat na disk, čímž je eliminováno riziko ztráty vzorků při vysokých datových tocích. Akviziční logika je založena na metodě segmentového měření, které je momentálně konfigurováno pro záznam jedné a půl sekundy signálu v pravidelných minutových intervalech.

Digitální řetězec zpracovává signály ze čtyř typů senzorů s odlišnými nároky na vzorkovací frekvenci a kvalitu signálu. Signál AE je zaznamenáván surový (bez digitální filtrace) - pásmová propust Butterworth 4. řádu v pásmu 50 – 490 kHz je aplikována až v postprocessingu při konverzi TDMS→HDF5. Vlastní akvizice AE probíhá na frekvenci 1 MHz, zatímco signály z pomocných senzorů, zahrnující axiální zatěžovací sílu, reakční třecí sílu a teplotu, jsou podrobeny softwarovému downsamplingu na efektivní frekvenci 10 kHz. Tento proces zajišťuje redukci nadbytečných dat u nízkofrekvenčních veličin při plném zachování časové synchronizace se signálem AE.

Finální data jsou ukládána ve strukturovaném binárním formátu TDMS (Technical Data Management Streaming), který je optimalizován pro vysokorychlostní zápis rozsáhlých datových polí. Skript je navržen tak, aby na začátku každého měření provedl kalibraci AE na referenční nulu, čímž kompenzuje DC offset vznikající při napájení předzesilovačů ze sítě. Pro vizuální kontrolu experimentu bez ovlivnění stability zápisu je implementováno real-time zobrazování dat ze všech senzorů do diagnostických grafů. Takto segmentovaná, předzpracovaná surová data tvoří základ pro následnou extrakci statistických příznaků a tvorbu tréninkových datasetů pro modely hlubokého učení.

#### 4.4.3 Digitální zpracování signálu a extrakce příznaků

Po ukončení fáze akvizice a uložení dat ve formátu TDMS, respektive jejich následné konverzi do hierarchické struktury HDF5, následuje proces digitálního zpracování a extrakce příznaků pomocí python skriptu *TDMS\_TO\_HDF5\_time\_freq\_crop.py*. Tento krok převádí surový vysokofrekvenční signál na kompaktní sadu deskriptivních příznaků vhodnou pro trénování neuronových sítí. Výpočetní pipeline je realizována v prostředí Python s využitím

knihovny `scipy.stats` a paralelního zpracování dat pomocí `ProcessPoolExecutor`, což umožňuje efektivní distribuci zátěže při analýze gigabytových datových souborů vzniklých vzorkováním na frekvenci 1 MHz.

Vlastní proces extrakce probíhá pomocí python skriptu `HDF5_data_statistics+plot-MULTIPLE-update_17.2.2026.py` na úrovni jednotlivých 1,5sekundových segmentů, které byly zaznamenány v minutových intervalech. Každý segment signálu AE je před extrakcí filtrovaný pásmovou propustí Butterworth 4. řádu (50–490 kHz) při konverzi TDMS→HDF5 a je popsán sadou statistických příznaků. Dále jsou počítány doplňkové příznaky: faktor tvaru vlny (`Shape_Factor`), absolutní energie, entropie amplitudového histogramu, percentilové vrcholové hodnoty (`Peak_Amp`) a jim odpovídající Crest faktory ve třech hladinách (99,9 / 99,0 / 90,0 %), počet průchodů nulou (`ZCR`) a spektrální příznaky: frekvenční centroid, dominantní frekvence (`Peak_Frequency`, `RMS_Frequency`) a pásové energetické poměry (`BER_Band1–4`) v pásmech 50–150, 150–250, 250–350 a 350–490 kHz.

Souběžně s analýzou signálu AE probíhá zpracování dat z doplňkové senzorky, zahrnující axiální sílu ( $F_a$ ), reakční třecí sílu ( $F_t$ ) a teplotu. Vzhledem k tomu, že tyto veličiny byly vzorkovány na nižší efektivní frekvenci (10 kHz), je pro každý segment akustické emise vypočítána průměrná hodnota těchto parametrů. Tímto postupem dochází k časové synchronizaci vysokofrekvenční diagnostiky s provozními parametry tribometru.

Závěrečná fáze zpracování dat je realizována prostřednictvím skriptu `02_merge_all.py`, který integruje extrahované statistické příznaky, průměrované hodnoty ze senzorů a vypočtené hodnoty opotřebení z interpolačního modelu popsaného v kapitole 4.4.1. Tento algoritmus agreguje data ze všech realizovaných experimentů do jedné strukturované matice ve formátu CSV. Výsledný dataset obsahuje pro každý časový úsek kompletní vektor příznaků AE synchronizovaný s aktuální hloubkou a objemem opotřebení polymerní vrstvy.

Paralelně s extrakcí statistických příznaků v časové oblasti je pro každý segment signálu AE vypočtena i časově-frekvenční reprezentace ve formě logaritmického výkonového spektrogramu. K výpočtu je využita Krátkodobá Fourierova transformace (STFT) s Hannovým oknem délky  $N_{win} = 2048$  vzorků, překrytím 1536 vzorků (75 %), čímž je dosaženo časového rozlišení 0,512 ms na snímek a frekvenčního rozlišení přibližně 488 Hz/bin. Výsledná matice výkonové spektrální hustoty je ořezána na frekvenční pásmo 50 – 490 kHz, odpovídající pásmové propusti digitálního filtru aplikovaného při akvizici, a převedena na logaritmické měřítko v decibelech. Pro zajištění jednotné vizuální škály napříč všemi segmenty a testy je provedena globální normalizace: průchodem přes celý dataset jsou stanoveny globální meze 2. a 98. percentilu výkonu v dB (konkrétně –120 dB jako spodní hranice –90 dB jako horní hranice); tyto hodnoty jsou uloženy a použity pro lineární škálování do rozsahu {0 ; 1}. Výsledný spektrogram je bilineárně přesamplován na velikost 128 × 128 pixelů a uložen jako soubor float32 formátu NumPy (.npy). Každý

spektrogram tak tvoří kompaktní 2D otisk frekvenčního obsahu daného segmentu a slouží jako vstup do konvoluční větve hybridního modelu CNN-GRU.

Pro exploraci vzájemných vztahů mezi extrahovanými příznaky byla v rámci trénovací sady sestavena Pearsonova korelační matice (Příloha 18). Analýza potvrzuje předpokládanou skupinovou strukturu vstupního prostoru: energetické parametry AE\_RMS, E\_abs a V\_rms vykazují vzájemnou vysokou korelaci, přičemž jejich kumulativní deriváty (AE\_RMS\_Corrected\_Cumsum) tvoří samostatnou skupinu s výraznou autokorelací vůči pořadí segmentu v čase. Pásové energetické poměry BER\_Band1–4 jsou navzájem antikorelované, neboť sumárně pokrývají celé sledované frekvenční pásmo. Přestože vysoká vzájemná korelace mezi příznaky může v lineárních modelech způsobovat multikolinearitu, regularizované rekurentní neuronové sítě (dropout, L2 regularizace) jsou vůči tomuto jevu robustní. Finální posouzení přínosu jednotlivých příznaků k predikci bylo proto realizováno post-hoc metodou SHAP na natrénovaných modelech, která je pro nelineární modely metodicky přesnější než prahování korelačního koeficientu.

#### 4.4.4 Předzpracování dat a tvorba datasetu

Následná fáze zpracování dat, která tvoří společný a kriticky důležitý základ pro všechny uvažované architektury predikčních modelů, se zaměřuje na transformaci agregované matice příznaků do podoby optimalizované pro proces strojového učení. Vzhledem k tomu, že proces degradace polymerní kompozitní kluzné vrstvy má ireverzibilní a kumulativní charakter, je primární dataset v úvodu rozšířen o odvozené veličiny reprezentující historii zatěžování kontaktu. Jedná se především o výpočet kumulativního součtu vybraných statistických parametrů, jako je kumulativní efektivní hodnota akustické emise (AE\_RMS\_Corrected\_Cumsum). Tento příznak poskytuje modelu informaci o energetické bilanci tření, což je klíčové pro odlišení identických okamžitých hodnot signálu AE nacházejících se v diametrálně odlišných fázích životnosti ložiska.

Dalším nezbytným krokem v pipeline předzpracování je eliminace stochastického šumu a vysokofrekvenčních fluktuací v extrahovaných příznacích. Tyto fluktuace přirozeně vznikají v důsledku diskrétního segmentového měření, kdy je zaznamenána vždy pouze jedna sekunda signálu v minutových intervalech. K vyhlazení časových řad je ve skriptu implementován jednorozměrný digitální filtr Savitzky-Golay. Tento filtr využívá metodu lokální polynomiální regrese nejmenších čtverců, čímž vyhlazuje data bez výrazného fázového zpoždění a degradace užitečného signálu. V rámci algoritmu byly parametry filtru empiricky optimalizovány na délku okna 11 vzorků (window\_length=11) a polynom 3. řádu (polyorder=3). Toto konkrétní nastavení zajišťuje dostatečně široký záběr pro potlačení lokálních odchylek měření, avšak díky kvadratickému polynomu nedochází k nežádoucímu „zploštění“ strmých nárůstů AE signálu, které indikují náhlé strukturální změny.

Vzhledem k výrazné heterogenitě vstupních dat, která zahrnují veličiny v diametrálně odlišných fyzikálních jednotkách a řádech (od milivoltů u příznaků AE až po stovky newtonů u zatěžovací síly), je provedena striktní normalizace datového souboru. Pro tento účel byl zvolen standardizační algoritmus (StandardScaler / MinMaxScaler), který transformuje příznaky do jednotného měřítka. Klíčovým inženýrským aspektem této fáze je prevence tzv. úniku informací (data leakage) z testovací do trénovací množiny. Z tohoto důvodu je standardizační model inicializován (operace fit) výhradně na datech patřících do trénovací množiny, ze kterých extrahuje referenční statistiky (průměr a směrodatnou odchylku, respektive minimum a maximum). Tyto identické, již fixní parametry jsou následně použity pro transformaci (operace transform) testovací množiny. Testovací data jsou tak normalizována „naslepo“ vzhledem k vlastním statistikám, což věrně simuluje chování modelu v reálném provozním nasazení, kdy statistické rozložení budoucích dat není předem známo. Významným prvkem je rovněž zahrnutí hodnoty axiálního zatížení jako samostatného normalizovaného příznaku, což síti umožňuje dynamicky korigovat váhy v závislosti na aktuálních provozních podmínkách testu.

Závěrečným úkonem při tvorbě datasetu je strategické rozdělení dat na trénovací a testovací množinu. Aby bylo možné objektivně zhodnotit generalizační schopnosti modelů, je využito rozdělení na úrovni celých experimentálních testů (tzv. Group Shuffle Split nebo per-case split). Dataset je rozdělen v poměru 85 % trénovacích dat ku 15 % testovacích dat. Při tomto procesu je využit fixní generátor pseudonáhodných čísel (random\_state=42), který garantuje plnou reprodukovatelnost rozdělení při opakovaných spuštěních skriptu a umožňuje objektivní srovnávání odlišných architektur neuronových sítí na naprosto identických datech. Zatímco samotné testy (případy) jsou do obou množin rozděleny náhodně, vnitřní chronologická posloupnost jednosekundových segmentů v rámci každého testu zůstává striktně zachována (shuffle=False v rámci časové řady). Toto zachování časové souslednosti je absolutní nutností zejména pro následnou implementaci rekurentních sítí (RNN/LSTM), které pro své učení vyžadují kauzální návaznost historických dat v čase.

Pro hybridní model CNN-GRU je každý trénovaný datový bod složen ze dvou synchronizovaných vstupů: (1) spektrogramu ve tvaru  $128 \times 128$  pixelů, načteného ze souboru .npy, a (2) vektoru tabulárních příznaků AE. Párovací klíč (Case\_ID, Segment\_Order) zajišťuje, že oběma větvím sítě odpovídá vždy identický časový segment měření. Spektrogramy jsou předpočítány offline skriptem compute\_spectrograms.py a indexovány souborem spec\_index.csv, který je načten při inicializaci datové sady. Toto oddělené předpočítání zamezuje opakované STFT transformaci při každé epoše tréninku a výrazně zkracuje celkovou dobu výpočtu.

#### 4.4.5 Implementace modelů hlubokého učení

Pro realizaci a trénink predikčních modelů byl využit programovací rámec PyTorch s akcelerací výpočtů na GPU prostřednictvím rozhraní CUDA. Celkem bylo implementováno a vzájemně porovnáno pět architektur: statická dopředná síť MLP jako referenční baseline, tři rekurentní varianty (RNN, LSTM, GRU) s postupně komplexnějším mechanismem paměti a hybridní model CNN-GRU kombinující extrakci spektrálních příznaků z AE spektrogramů se sekvenčním zpracováním v GRU. Finální hyperparametry všech modelů byly určeny automatizovanou Bayesovskou optimalizací (Optuna). Sdílenou ztrátovou funkcí pro všechny architektury je Huberova ztráta (SmoothL1Loss), která kombinuje robustnost vůči odlehlým hodnotám s hladkostí gradientu v okolí nuly, a optimizátor Adam s předčasným zastavením (patience = 15 epoch).

Vícevrstvý perceptron (MLP) zpracovává každý časový segment nezávisle bez sekvenční paměti; historická informace je zahrnuta pouze prostřednictvím kumulativních příznaků na vstupu. Výsledná architektura tvoří tři plně propojené skryté vrstvy s 256, 128 a 64 neurony a aktivační funkcí ReLU. Vstupní i skrytý dropout jsou nastaveny na hodnotu 0,20. Optimalizace probíhala algoritmem Adam s rychlostí učení  $1,5 \times 10^{-4}$  a byla ukončena po 17 epochách na základě předčasného zastavení.

Standardní rekurentní neuronová síť (RNN) v konfiguraci Many-to-Many zavádí sekvenční paměť a pro každý časový krok predikuje odpovídající hodnotu opotřebení. Implementovaná topologie využívá dvě vrstvy Vanilla RNN buněk se 64 skrytými stavy, příznakovým dropoutem 0,20 a rekurentním dropoutem 0,10. Trénink s Adamem ( $lr = 3 \times 10^{-4}$ ) byl ukončen po 30 epochách.

Architektura Long Short-Term Memory (LSTM) rozšiřuje RNN o mechanismus tří bran (vstupní, zapomínací a výstupní), který cíleně reguluje tok informací a umožňuje modelovat dlouhodobé závislosti bez degradace gradientu. Třívrstvá implementace se 128 skrytými stavy na vrstvu využívá výrazně silnější regularizaci (příznakový i rekurentní dropout 0,35), která zpomalila konvergenci, ale omezila přeučení. Optimalizace Adamem s  $lr = 2,3 \times 10^{-4}$  trvala 42 epoch.

Gated Recurrent Unit (GRU) představuje kompaktnější alternativu LSTM se dvěma branami (resetovací a aktualizací), která při nižším počtu parametrů dosahuje srovnatelné schopnosti modelovat časové závislosti. Dvouvrstvá implementace s 256 skrytými stavy a nižší regularizací (příznakový dropout 0,15, rekurentní 0,10) umožnila rychlou konvergenci při vysoké rychlosti učení  $1,0 \times 10^{-3}$  – trénink byl ukončen po pouhých 22 epochách, nejrychleji ze všech testovaných architektur.

Hybridní model CNN-GRU rozšiřuje architekturu GRU o konvoluční větev pro extrakci spektrálních příznaků z předpočítaných AE spektrogramů ( $128 \times 128$  pixelů). CNN blok tvoří tři konvoluční vrstvy s postupně rostoucím počtem filtrů ( $1 \rightarrow 16 \rightarrow 32 \rightarrow 64$ ), každá následována aktivací ReLU a adaptivním průměrovacím poolingem na výstupu celého

bloku. Plně propojená vrstva redukuje konvoluční embedding na 64 příznaků, které jsou spojeny s vektorem 16 tabulárních příznaků AE. Vzniklý 80-dimenzionální vektor tvoří vstup do GRU části shodné s modelem GRU (2 vrstvy, 256 skrytých stavů, dropout 0,15/0,10). Celý model je trénován end-to-end, přičemž CNN část se učí extrahovat frekvenční příznaky relevantní pro predikci opotřebení souběžně s optimalizací rekurentní části. Optimalizace Adamem s  $lr = 1,0 \times 10^{-3}$  trvala 27 epoch.

#### 4.4.6 Metrika hodnocení predikcí

K objektivnímu posouzení přesnosti, stability a generalizačních schopností navržených modelů hlubokého učení byl definován komplexní systém evaluačních metrik. Vyhodnocení výkonnosti modelů představuje kritický krok nejen pro vzájemné porovnání odlišných architektur (MLP versus varianty RNN), ale především pro kvantifikaci spolehlivosti in-situ predikce v reálném průmyslovém nasazení. Analýza chybovosti je v rámci vyvinutých skriptů prováděna nezávisle jak na trénovací, tak na testovací množině. Srovnání hodnot metrik mezi těmito dvěma sadami slouží jako hlavní indikátor správného průběhu učení a umožňuje včasnou detekci nežádoucího jevu přeučení (overfitting), kdy by model pouze memoroval trénovací data a selhával na datech neviděných. Výpočet metrik je realizován pomocí knihovny scikit-learn, přičemž jsou využity čtyři komplementární statistické ukazatele doplněné o kvalitativní hodnocení fyzikální smysluplnosti.

Základní optimalizační a hodnoticí metrikou je střední kvadratická chyba (MSE – Mean Squared Error) Rov. (4-9). Tato metrika vypočítává průměr druhotných mocnin rozdílů mezi skutečnou hodnotou opotřebení zjištěnou metrologickým měřením a hodnotou predikovanou neuronovou sítí. Z matematické podstaty umocnění na druhou vyplývá klíčová vlastnost MSE: tato metrika silně penalizuje výrazné odchylky (outliery). V kontextu tribologické diagnostiky je tento přístup vysoce žádoucí, neboť velká chyba v odhadu opotřebení může v reálném provozu vést k neočekávané havárii ložiska. Model optimalizovaný na minimalizaci MSE má tedy přirozenou tendenci vyhýbat se extrémním chybám predikce. MSE lze definovat jako Rov. (4-9), kde  $n$  představuje celkový počet hodnocených vzorků (časových segmentů),  $Y_i$  je skutečná (referenční) hodnota opotřebení pro  $i$ -tý vzorek a  $\hat{Y}_i$  je odpovídající hodnota opotřebení predikovaná modelem neuronové sítě.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (4-9)$$

Pro snazší inženýrskou interpretaci výsledků je MSE doplněna o odmocninu ze střední kvadratické chyby (RMSE – Root Mean Squared Error) Rov. (4-10). Její hlavní výhoda spočívá v návratu do původních fyzikálních jednotek sledované veličiny (např. milimetry u hloubky opotřebení nebo milimetry krychlové u objemu). RMSE tak poskytuje jasnou a intuitivní představu o velikosti predikční chyby ve stejném měřítku, v jakém je definován

samotný technický požadavek na přesnost diagnostického systému. Stejně jako MSE si i RMSE zachovává citlivost vůči lokálním extrémům.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (4-10)$$

Pro získání představ o průměrné velikosti chyby napříč celým datasetem je využívána střední absolutní chyba (MAE – Mean Absolute Error) Rov. (4-11). Na rozdíl od předchozích metrik počítá MAE pouze s absolutními hodnotami odchylek, čímž poskytuje lineární penalizaci chyb. Hodnota MAE tak exaktně vyjadřuje, o kolik se model v průměru mýlí v každém jednotlivém časovém segmentu, aniž by byl tento výsledek disproportčně zkreslen několika málo segmenty s vysokou chybovostí. V kombinaci s RMSE tak MAE pomáhá identifikovat, zda je chybovost modelu rozložena rovnoměrně (pokud jsou hodnoty MAE a RMSE podobné), nebo zda model generuje lokální extrémní odchylky (pokud je RMSE výrazně vyšší než MAE).

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (4-11)$$

Poslední kvantitativní metrikou je koeficient determinace ( $R^2$  skóre), který představuje statistickou míru vysvětlující podíl rozptylu závislé proměnné, který je model schopen predikovat z nezávislých proměnných. Hodnota  $R^2$  se pohybuje v intervalu od záporných hodnot (pro model horší než prostý průměr) až do hodnoty 1,0 pro absolutně přesnou predikci. V kontextu této práce exceluje  $R^2$  metrika především ve schopnosti zhodnotit, jak přesně neuronová síť zachycuje celkový trend a dynamiku degradační křivky, a to nezávisle na absolutním měřítku dat. To je obzvláště cenné při porovnávání výkonnosti modelů napříč různými úrovněmi zátěžných sil, kde se absolutní hodnoty opotřebení mohou řádově lišit.  $R^2$  lze definovat jako Rov. (4-12), kde  $SS_{res}$  (reziduální součet čtverců) reprezentuje rozptyl chyb predikce modelu (sumu druhých mocnin rozdílů mezi skutečnou a predikovanou hodnotou) a  $SS_{tot}$  (celkový součet čtverců) vyjadřuje celkovou přirozenou variabilitu skutečných naměřených dat vůči jejich průměrné hodnotě.

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (4-12)$$

Nad rámec čistě statistických metrik je do metodiky hodnocení zahrnuto také expertní posouzení fyzikální smyslnosti predikovaných časových řad. Neuronové sítě jsou z podstaty matematické aproximátory, které nerespektují fyzikální zákony. Mohou tak teoreticky generovat predikce, které indikují pokles hodnoty opotřebení v čase, což u nevratného tribodegradačního procesu není fyzikálně možné. Křivky predikovaného



opotřebení jsou proto podrobeny analýze dodržení podmínky monotonicity a posouzení stability, čímž je zaručeno, že vybrané modely nejen minimalizují statistickou chybu, ale zároveň věrně reprezentují reálné chování opotřebovávané kompozitní kluzné vrstvy.

#### 4.4.7 Strategie ladění a optimalizace modelů

Vzhledem k implementaci pěti odlišných architektur (MLP, RNN, LSTM, GRU a CNN-GRU) je nezbytným krokem proces systematického ladění hyperparametrů (finetuning), jehož cílem je nalezení optimální rovnováhy mezi výpočetní kapacitou modelů a jejich schopností generalizace na neviděných datech. Strategie ladění je rozdělena do tří po sobě jdoucích fází, které reflektují specifika predikce opotřebení z vysokofrekvenčních dat akustické emise.

V první fázi je pozornost věnována srovnání základních (baseline) konfigurací jednotlivých modelů při identickém nastavení vstupních příznaků a normalizačních metod. Cílem je identifikovat, jakým způsobem se projevuje vnitřní mechanika architektur – zejména schopnost hradlových mechanismů (Gates) u LSTM a GRU jednotek udržet paměťovou stopu o kumulativním opotřebení v průběhu dlouhých experimentálních sekvencí (3–4 hodiny). Tato fáze slouží k eliminaci problémů s mizejícím gradientem, který je typický pro standardní (Vanilla) RNN síť.

Druhá fáze zahrnuje automatizovanou optimalizaci hyperparametrů s využitím Bayesovského přístupu prostřednictvím knihovny Optuna. Tento rámec umožňuje efektivní prohledávání hyperparametrického prostoru, kde jsou u každé architektury laděny především tyto parametry:

V rámci druhé fáze byly pro každou architekturu systematicky laděny: dimenze skrytého prostoru (hidden\_size, num\_layers), síla regularizace (feature\_dropout, recurrent\_dropout resp. input a hidden dropout u MLP), rychlost učení (lr – learning rate) a penalizace váhových norem (weight\_decay). Pro rekurentní architektury byl navíc laděn koeficient monotonicity loss (mono\_lambda), který penalizuje fyzikálně nesmyslné lokální přírůstky opotřebení v čase, a délka počáteční zahřevné sekvence (WARMUP\_SEGMENTS), po kterou není monotonicí penalizace aplikována. Výsledné optimální hyperparametry nalezené Bayesovskou optimalizací jsou shrnuty v Tab. 4-2.

Tab. 4-2: Finální hyperparametry modelů po Bayesovské optimalizaci (Optuna)

| Hyperparametr              | MLP                  | RNN                  | LSTM                 | GRU                  |
|----------------------------|----------------------|----------------------|----------------------|----------------------|
| hidden_sizes / hidden_size | [256, 128, 64]       | 64                   | 128                  | 256                  |
| num_layers                 | 3                    | 2                    | 3                    | 2                    |
| input / feature dropout    | 0,20                 | 0,20                 | 0,35                 | 0,15                 |
| hidden / recurrent dropout | 0,20                 | 0,10                 | 0,35                 | 0,10                 |
| Learning rate (Adam)       | $1,5 \cdot 10^{-4}$  | $3,0 \cdot 10^{-4}$  | $2,3 \cdot 10^{-4}$  | $9,99 \cdot 10^{-4}$ |
| weight_decay               | $5,26 \cdot 10^{-6}$ | $2,45 \cdot 10^{-5}$ | $2,96 \cdot 10^{-6}$ | $4,61 \cdot 10^{-6}$ |
| mono_lambda                | 0,0                  | 2,0                  | 2,0                  | 2,0                  |
| WARMUP_SEGMENTS            | –                    | 5                    | 15                   | 5                    |

Hybridní model CNN-GRU sdílí identické hyperparametry rekurentní části s modelem GRU (viz Tab. 4-2). Konvoluční větev CNN nebyla předmětem Bayesovské optimalizace – její architektura (tři konvoluční bloky  $1 \rightarrow 16 \rightarrow 32 \rightarrow 64$  filtrů) byla zvolena jako pevná na základě standardních praktik pro 1D/2D spektrogramové modely. Třetí fáze ladění zahrnovala závěrečné ověření výkonnosti všech pěti architektur na identické testovací sadě za plně reprodukovatelných podmínek (`random_state = 42`), jejichž výsledky jsou prezentovány v kapitole Výsledky.

#### 4.4.8 Metoda pro charakterizaci útlumu AE (H2)

Postup této doplňující metodiky spočívá v měření útlumu signálu AE při definovaném zatížení v závislosti na tloušťce kluzné vrstvy. K excitaci elastických vln je využita standardizovaná metoda Hsu-Nielsenova testu (Pencil Lead Break – PLB) a následná analýza parametrů detekovaných AE hitů. Pro účely měření byla připravena sada vzorků s odstupňovanou tloušťkou polymerního povlaku v rozsahu od  $500 \mu\text{m}$  do  $230 \mu\text{m}$ . Samotný experiment spočívá v aplikaci PLB pulzu na kloub sférického ložiska, přičemž odezva je snímána senzorem AE umístěným na spodním kroužku ložiska. Instrumentace senzoriky a parametry akviziční karty jsou identické jako u předchozích. Pro zajištění statistické významnosti je u každého vzorku provedeno 10 validních pulzů. Získané záznamy jsou následně manuálně kontrolovány s cílem eliminovat parazitní hity vznikající například sekundárním odrazem tuhy. Výsledná data jsou korelována v závislosti na tloušťce povlaku (osa x) a sledovaných popisných parametrech AE (osa y).

Pro experimentální ověření vlivu tloušťky kluzné vrstvy na útlum signálu AE byla připravena sada osmi vzorků ložisek GE20-AW s odstupňovanou tloušťkou kompozitní

kluzné vrstvy. Specifikace jednotlivých vzorků a naměřené tloušťky jejich funkčních vrstev jsou uvedeny v Tab. 4-3. Tato série zahrnuje vzorky v rozsahu tlouštěk od přibližně 500  $\mu m$  až po přibližně 230  $\mu m$ . Je zde zahrnut i vzorek zcela bez kluzné vrstvy (pouze ocelový substrát), který slouží jako referenční etalon pro stanovení základního přenosu signálu tělem ložiska.

Všechny testy studující vnitřní útlum byly realizovány při axiálním zatížení  $F_a = 14 \text{ kN}$ . Volba této hodnoty vychází z maximální únosnosti ložisek v sestavě a předpokladu dosažení stavu „akustické saturace“ na rozhraní mezi jednotlivými komponenty sestavy. Při tomto zatížení dochází k dostatečné deformaci mikronerovností kontaktních ploch, čímž je minimalizován vliv proměnné akustické impedance kontaktu a dominantním faktorem ovlivňujícím přenos vlnění se stává samotný útlum v materiálu povlaku.

Tab. 4-3: Připravené vzorky s upravenou tloušťkou kluzného povlaku pro testování míry útlumu

| Vzorek     | Tloušťka vzorku |         |
|------------|-----------------|---------|
| Sample_01  | 434             | $\mu m$ |
| Sample_02  | 507,33          | $\mu m$ |
| Sample_03  | 411             | $\mu m$ |
| Sample_04  | 327             | $\mu m$ |
| Sample_05  | 450,33          | $\mu m$ |
| Sample_06  | 419             | $\mu m$ |
| Sample_07  | 264             | $\mu m$ |
| No_coating | 0               | $\mu m$ |

Za účelem zajištění vysoké opakovatelnosti Hsu-Nielsenova testu byly pro běžnou mikrotužku (průměr tuhy 0,5 mm, tvrdost 2H) navrženy a metodou 3D tisku vyroben speciální polohovací přípravek Obr. 4-15.



Obr. 4-15: Mikrotužka s přípravkem pro správné provedení testu studujícího vnitřní útlum na konformní konfiguraci

První z přípravků (úhlový adaptér) se fixuje přímo na koncovku mikrotužky a definuje konstantní sklon tuhy vůči povrchu vzorku pod úhlem 30°. Druhý přípravek (délkový doraz) slouží k rychlému a přesnému nastavení délky vysunutí tuhy (3 mm) před každým testem.

Tato kombinace přípravků z části eliminuje lidský faktor při aplikaci rázů a zaručuje, že každý z deseti provedených pulzů na vzorek disponuje identickou energií zdroje.

Testování probíhalo pomocí sady 10 testů studujících vnitřní útlum na každém vzorku. Měření probíhalo pomocí měřicího skriptu v pythonu na kartě NI USB 6451. Měřicí skript ukládá signál AE a při překročení prahové hodnoty 0,1 V spustí záznam hitu. U každého zaznamenaného hitu bylo pomocí python skriptu provedeno zobrazení v časové a časově-frekvenční (STFT) doméně. Na základě těchto dvou domén se následně vyhodnocovaly jednotlivé hity.

#### 4.4.9 Softwarové nástroje pro akvizici a zpracování dat (H2)

Pro realizaci experimentu a následnou analýzu signálu AE byl v prostředí Python vyvinut modulární řetězec skriptů. Tento systém zajišťuje celý proces od prvotního zachytu dat přes jejich filtraci a vizualizaci až po finální statistické vyhodnocení vlivu tloušťky vrstvy.


##### Akvizice dat (AE\_continuous\_event\_test.py)

Prvotní zachyt signálu byl realizován pomocí akvizičního skriptu využívajícího knihovnu nidaqmx pro komunikaci s měřicí kartou NI USB 6451. Skript pracuje s vzorkovací frekvencí 1 MHz a využívá algoritmus kontinuálního sledování s nastavitelnou prahovou úrovní (Threshold). Pro účely Hsu-Nielsenových testů byl práh stanoven na  $\pm 0,1$  V.


Při detekci překročení prahové úrovně dojde k uložení tzv. hitu, přičemž skript využívá kruhový buffer pro zápis 10 ms signálu před samotným triggerem (Pre-trigger) a definovanou dobu dozvuku (Ring-down timeout) 0,5 ms pro ukončení záznamu události. Aby se předešlo zápisu parazitních odrazů tuhy, byla definována mrtvá doba (Dead time) 70 ms. Data jsou ukládána ve formátu TDMS pro zachování vysoké věrnosti záznamu a metadat o měření.

##### Vizualizace a kontrola hitů (AE\_evaluate.py)

Zaznamenané hity byly následně individuálně kontrolovány pomocí skriptu pro časově-frekvenční analýzu. Pro každý hit je generován graf v časové doméně (průběh napětí) Obr. 4-16 a v doméně časově-frekvenční s využitím krátkodobé Fourierovy transformace (STFT) Obr. 4-17. Před samotným zobrazením je signál filtrován digitální pásmovou propustí typu Butterworth (4. řádu) v rozsahu 50 kHz až 490 kHz. Tato vizualizace slouží k manuální validaci integrity rázů a k vyloučení událostí ovlivněných šumem nebo sekundárními dopady tuhy.



Obr. 4-16: Hit v časové doméně (nahore: surový signál, dole: filtrovaný signál bandpass filtrem 50-490 kHz)



Obr. 4-17: Hit AE v časově-frekvenční doméně

### Výpočet popisných parametrů (AE\_parametry.py)

Kvantifikace útlumu probíhá skrze výpočet standardních popisných parametrů AE pro každý validní hit. Skript extrahuje z filtrovaného signálu následující veličiny:

- **Energetické parametry:** Absolutní energie [ $aJ$ ], RMS a špičková amplituda [ $V$ ].
- **Časové parametry:** Doba trvání hitu (*Duration*), doba nárůstu k maximu (*Rise time*) a počet překmitů přes práh (*Counts*).
- **Statistické a frekvenční parametry:** Špičatost (*Kurtosis*), šikmost (*Skewness*), frekvenční těžiště (*Frequency Centroid*) a dominantní frekvence.

Výsledky jsou pro každý vzorek exportovány do souhrnných CSV reportů, které tvoří vstupní data pro finální syntézu.

Korelace s tloušťkou vrstvy (AE\_grafy\_tloušťka.py)

Závěrečnou fází metodiky je statistické zpracování závislostí mezi tloušťkou polymerní vrstvy a extrahovanými parametry AE. Skript automaticky páruje data z předchozí analýzy s informacemi o tloušťce vzorků (Tab. 4-3). Výstupem jsou korelační grafy, kde je na ose x vynesena tloušťka povlaku [ $\mu\text{m}$ ] a na ose y sledovaný parametr (např. energie nebo amplituda). Pro zvýšení výpovědní hodnoty jsou v grafech vyneseny průměrné hodnoty z deseti měření doplněné o chybové úsečky (směrodatnou odchylku) a proloženy aproximační křivkou, která ilustruje trend útlumu signálu.

#### 4.4.10 Metodika ověření přenositelnosti signálu v nekonformní konfiguraci (4-ball)

Cílem této části experimentu je stanovení metodiky pro přenos (transfer) predikčního modelu opotřebení ze zrychlených laboratorních testů v nekonformní konfiguraci (4-ball) na reálnou provozní aplikaci s konformním kontaktem. Tato kapitola popisuje specifický postup měření útlumu AE signálu v uspořádání čtyř kuliček, který slouží k definici tzv. přenosové funkce systému.

Pro generování standardizovaného akustického impulsu byla opět využita metoda Hsu-Nielsenova zdroje (test studující vnitřní útlum). Aby byla zajištěna maximální opakovatelnost a shoda s testy v konformní konfiguraci, byl navržen a pomocí aditivní technologie FDM tisku (materiál PLA) vyroben speciální polohovací přípravek Obr. 4-18. Tento přípravek zajišťuje fixaci tuhy typu 2H o průměru 0,5 mm v přesném úhlu 30° vůči povrchu kuličky a definuje délku vysunutí tuhy na 3 mm. Bod zlomu byl lokalizován na jednu ze čtyř kuliček v rovině horizontálně procházející jejím středem, což simuluje primární zdroj akustické emise vznikající v místě tribologického kontaktu.



Obr. 4-18: Mikrotužka s přípravkem pro správné provedení testu studujícího vnitřní útlum na 4-ball konfiguraci

Důležitým aspektem měření bylo stanovení reprezentativního axiálního zatížení. Vzhledem k tomu, že rozsah zatížení v rámci zrychlených testů opotřebení (ověřování hypotézy H1) se pohyboval v rozmezí 150 N až 650 N, byla pro srovnávací testy studující vnitřní útlum zvolena střední hodnota 400 N. Tato volba je podložena fyzikální teorií akustické saturace rozhraní. Neconformní bodový kontakt (koule na kouli) vyvolává i při relativně nízkých zatíženích vysoké kontaktní tlaky (Hertzovy tlaky). Předpokládá se, že v celém testovaném rozsahu (150–650 N) dochází k úplnému dotlačení polymerní vrstvy k ocelovému substrátu, čímž je minimalizována diskontinuita akustické impedance na tomto rozhraní. Přenos

signálu přes rozhraní se tak stává stabilním a nezávislým na dalším zvyšování tlaku, což umožňuje přímé srovnání s vysokozátěžovými testy reálného ložiska.

Sběr dat a následné zpracování signálu probíhalo identickým způsobem jako u konformních vzorků, za využití stejného řetězce senzorů a vyhodnocovacích skriptů. To umožňuje exaktní srovnání parametrů, jako je amplituda, energie a frekvenční spektrum, a stanovení geometrického offsetu (Transfer Factoru) v decibelech. Tento koeficient následně slouží jako kalibrační konstanta pro neuronovou síť (NN), která díky němu dokáže predikovat stav reálného ložiska na základě dat získaných v laboratorních podmínkách zrychleného opotřebení.

## 5 VÝSLEDKY

V rámci ověření první výzkumné hypotézy (H1) bylo implementováno a vzájemně porovnáno pět architektur hlubokého učení: referenční dopředná síť MLP, tři rekurentní varianty (RNN, LSTM, GRU) s postupně komplexnějším paměťovým mechanismem a hybridní model CNN-GRU rozšiřující architekturu GRU o konvoluční extrakci spektrálních příznaků z AE spektrogramů. Výkonnost každého modelu byla kvantifikována čtveřicí evaluačních metrik (MSE, MAE, RMSE,  $R^2$ ) vyčíslených nezávisle na trénovací a testovací množině, doplněnou o kvalitativní hodnocení fyzikální smysluplnosti predikovaných křivek opotřebení.

V rámci druhé výzkumné větve (H2) byly prostřednictvím PLB testů (Hsu-Nielsenova metoda) analyzovány amplitudové a energetické parametry signálu AE v závislosti na tloušťce kluzné vrstvy. Výsledky konformní konfigurace byly srovnány s nekonformní konfigurací 4-ball za účelem posouzení přenositelnosti predikčního modelu na odlišnou kontaktní geometrii.

### 5.1 Výsledky predikce neuronových sítí (H1)

V této kapitole jsou prezentovány a analyzovány výsledky dosažené pomocí navržených architektur hlubokého učení. Hlavním kritériem pro posouzení úspěšnosti jednotlivých modelů je jejich schopnost generalizace, tedy přesnost predikce na testovací (neviděné) množině dat. Pro objektivní srovnání výkonnosti jsou u každého modelu uvedeny definované statistické metriky (MSE, MAE, RMSE,  $R^2$ ) vyčíslené nezávisle pro trénovací a testovací sadu. Dále je provedeno vizuální zhodnocení predikovaných křivek opotřebení s důrazem na jejich fyzikální smysluplnost a dodržení podmínky monotonicity, která je pro nevratný proces opotřebení polymerní vrstvy klíčová.

#### 5.1.1 Dopředná neuronová síť (MLP – Baseline model)

Model MLP byl trénován s architekturou tří skrytých vrstev [256, 128, 64], vstupním a skrytým dropoutem 0,20 a ztrátovou funkcí Huber (SmoothL1Loss). Optimalizace proběhla algoritmem Adam s rychlostí učení  $1,5 \cdot 10^{-4}$  a byla ukončena po 17 epochách na základě kritéria časné zástavy. Dosažené evaluační metriky jsou shrnuty v


Tab. 5-1.




Tab. 5-1: Hodnoty evaluačních metrik pro model MLP

| Metrika | Trénovací | Testovací |
|---------|-----------|-----------|
| MSE     | 0,0717    | 0,3523    |
| MAE     | 0,1848    | 0,4524    |
| RMSE    | 0,2678    | 0,5936    |
| R2      | 0,9283    | 0,7529    |


Metriky vykazují generalizační mezeru mezi trénovací ( $R^2 = 0,928$ ) a testovací sadou ( $R^2 = 0,753$ ;  $\Delta \approx 0,18$ ). Tento rozdíl neodráží klasické přeučení - model byl trénován pouhých 17 epoch s early stoppingem - ale je primárně způsoben architektonickým omezením MLP: absence sekvenční paměti vede k tomu, že každý časový krok je vyhodnocován nezávisle na historii, čímž model není schopen zachytit dlouhodobé trendy opotřebení. Na neviděných testech tato neschopnost generalizovat sekvenční závislosti snižuje přesnost.



Obr. 5-1: Predikce zbývající tloušťky povlaku v závislosti na segmentech pro jednotlivé testovací vzorky (1 segment = 1 minuta). – model MLP.



Obr. 5-2: Evaluační grafy predikce opotřebení pro model MLP – testovací množina.



Obr. 5-3: Evaluační grafy predikce opotřebení pro model MLP – trénovací množina.

Na vizualizaci testovací množiny jsou datové body v grafu Predictions vs. Actual uspořádány do souběžných pruhů namísto shluků podél ideální diagonály - model pro různé testovací vzorky predikuje kvalitativně podobné průběhy bez ohledu na konkrétní trajektorii opotřebení daného testu. Graf reziduí vykazuje strukturovaný vzor s kladnými rezidui narůstajícími při vyšších hodnotách predikované proměnné - model v oblasti vyšší tloušťky povlaku systematicky podhodnocuje skutečnost. Histogram reziduí má bimodální charakter s hlavním vrcholem u nuly a výrazným ramenem v kladné oblasti (rezidua až +1,5).

Individuální predikce pro tři testovací vzorky odhalují mechanismus tohoto chování. U vzorků Sample015\_550N ( $R^2 = 0,811$ ) a Sample022\_410N ( $R^2 = 0,793$ ) model zachycuje obecný klesající trend opotřebení, avšak s počátečním posunem - predikovaná hodnota startuje pod skutečnou tloušťkou 0,500 mm. Jelikož MLP každý segment vyhodnocuje nezávisle bez sekvenční paměti, nemá informaci o počáteční hodnotě povlaku. U vzorku Sample017\_200N dosahuje model nejnižší přesnosti ( $R^2 = 0,464$ ) - průběh opotřebení při 200 N je výrazně pomalejší než průměrný trend trénovacích dat.


### 5.1.2 Rekurentní neuronová síť v konfiguraci Many-to-Many (RNN M2M)

Model RNN byl trénován ve dvouvrstvé rekurentní architektuře s 64 skrytými stavy na vrstvu, feature dropoutem 0,20 a rekurentním dropoutem 0,10. Jako ztrátová funkce byla použita Huber loss, optimalizace proběhla algoritmem Adam s rychlostí učení  $3 \cdot 10^{-4}$  a byla ukončena po 30 epochách. Dosažené evaluační metriky jsou shrnuty v Tab. 5-2.


Tab. 5-2: Hodnoty evaluačních metrik pro model RNN M2M

| Metrika | Trénovací | Testovací |
|---------|-----------|-----------|
| MSE     | 0,0928    | 0,3061    |
| MAE     | 0,2214    | 0,4383    |
| RMSE    | 0,3047    | 0,5532    |
| R2      | 0,9072    | 0,7854    |

Metriky vykazují menší generalizační mezeru oproti modelu MLP – trénovací  $R^2 = 0,907$ , testovací  $R^2 = 0,785$  ( $\Delta \approx 0,12$ ). Lepší přenos na testovací sadu potvrzuje, že sekvenční zpracování RNN umožňuje zachytit časové závislosti v datech, které statický MLP přehlíží. Zbývající mezera není projevem klasického přeučení, ale odráží heterogenitu testovacích vzorků ( $n = 3$ ) a omezenou velikost testovací sady.




Obr. 5-4: Predikce zbývající tloušťky povlaku v závislosti na segmentech pro jednotlivé testovací vzorky (1 segment = 1 minuta).– model RNN.



Obr. 5-5: Evaluační grafy predikce opotřebení pro model RNN (Many-to-Many) – testovací množina.

Vizualizace testovací množiny (Obr. 5-5) ukazuje lepší shodu predikce se skutečností oproti modelu MLP. V grafu Predictions vs. Actual jsou datové body soustředěny blíže k ideální diagonále, přičemž sekvenční charakter dat je patrný ve spirálovité struktuře residuálního grafu - odraz toho, že model zpracovává data jako časové trajektorie. Residuální distribuce je symetričtější kolem nuly s rozsahem přibližně  $-1,0$  až  $+1,5$  a zřetelnějším vrcholem blíže nule oproti MLP.

Z individuálních predikcí (Obr. 5-4) je zřejmé, že RNN výrazně zlepšuje predikci u vzorku Sample017\_200N ( $R^2 = 0,615$  oproti  $0,464$  u MLP), kde pomalý průběh opotřebení model sekvenčně sleduje lépe. Naopak u Sample015\_550N ( $R^2 = 0,575$ ) je přesnost nižší než u MLP ( $0,811$ ) - predikovaná křivka vykazuje větší oscilace kolem skutečné hodnoty v důsledku přenosu šumu z předchozích kroků. Nejlepší výsledek podává Sample022\_410N ( $R^2 = 0,892$ ), kde model přesně sleduje klesající trajektorii po překonání počátečního posunu. Tento systémový počáteční posun je sdílen všemi testovanými architekturami (podrobněji viz kap. 5.1.1).



Obr. 5-6: Evaluační grafy predikce opotřebení pro model RNN (Many-to-Many) – trénovací množina.


### 5.1.3 Rekurentní neuronová síť LSTM

Model LSTM byl trénován ve třívrstvé architektuře se 128 skrytými stavy, výrazně vyšším feature i rekurentním dropoutem  $0,35$  a ztrátovou funkcí Huber. Optimalizace algoritmem

Adam s rychlostí učení  $2,3 \cdot 10^{-4}$  trvala 42 epoch - nejvíce ze všech testovaných architektur. Agresivní regularizace zpomalila konvergenci, ale omezila přeučení. Dosažené evaluační metriky jsou shrnuty v Tab. 5-3.

Tab. 5-3: Hodnoty evaluačních metrik pro model LSTM

| Metrika        | Trénovací | Testovací |
|----------------|-----------|-----------|
| MSE            | 0,1431    | 0,3527    |
| MAE            | 0,2141    | 0,4478    |
| RMSE           | 0,3782    | 0,5939    |
| R <sup>2</sup> | 0,8569    | 0,7527    |




Obr. 5-7: Predikce zbývající tloušťky povlaku v závislosti na segmentech pro jednotlivé testovací vzorky (1 segment = 1 minuta). – model LSTM.

Výsledný R<sup>2</sup> na testovací sadě (0,753) je prakticky totožný s modelem MLP, přestože LSTM je výrazně složitější architektura se sekvenční pamětí. Rozdíl  $\Delta \approx 0,10$  mezi trénovací (R<sup>2</sup> = 0,857) a testovací sadou (R<sup>2</sup> = 0,753) představuje mírnou generalizační mezeru - nikoli klasické přeučení. Agresivní regularizace (dropout 0,35) a předčasné zastavení na 42. epoše přeučení úspěšně omezily; nižší test R<sup>2</sup> je z části způsobeno heterogenní obtížností testovacích vzorků (n = 3), zejména vzorkem Sample017\_200N (R<sup>2</sup> = 0,357) s atypicky


pomalým průběhem opotřebení při nízkém zatížení 200 N. Na vizualizaci testovací množiny dominuje asymetrická residuální distribuce s vrcholem v záporné oblasti ( $\sim -0,5$ ), tedy model systematicky nadhodnocuje skutečnou hodnotu opotřebení. Na rozdíl od MLP, který podhodnocoval, LSTM díky dlouhodobé paměti přenáší historicky vysoké hodnoty do predikcí a reaguje se zpožděním na zrychlující se opotřebení.

Individuální predikce odhalují polarizaci výkonu napříč testovacími vzorky. U vzorku Sample022\_410N dosahuje LSTM nejlepšího výsledku ze všech testovaných modelů ( $R^2 = 0,934$ ) - po překonání počátečního posunu křivky konvergují a predikce věrně kopíruje trajektorii opotřebení. Naopak u vzorku Sample017\_200N ( $R^2 = 0,357$ ) dosahuje LSTM nejhoršího výsledku ze všech modelů - hluboká paměť způsobuje, že model predikuje rychlejší pokles, než nízká zátěž 200 N reálně produkuje. Vzorek Sample015\_550N ( $R^2 = 0,727$ ) vykazuje dobrou shodu trendů s mírným přechodným rozptylem.



Obr. 5-8: Evaluační grafy predikce opotřebení pro model LSTM – testovací množina.





Obr. 5-9: Evaluační grafy predikce opotřebení pro model LSTM – trénovací množina.


#### 5.1.4 Rekurentní neuronová síť GRU

Model GRU byl trénován ve dvouvrstvé architektuře s 256 skrytými stavy, nízkým feature dropoutem 0,15 a rekurentním dropoutem 0,10. Optimalizace algoritmem Adam s vysokou rychlostí učení  $1,0 \cdot 10^{-3}$  a ztrátovou funkcí Huber byla ukončena po pouhých 22 epochách - nejrychlejší konvergence ze všech testovaných modelů. Velký počet skrytých stavů (256) v kombinaci s vysokou rychlostí učení umožnil rychlé zachycení dominantních trendů, ovšem za cenu méně jemné adaptace na trénovací sekvence. Dosažené evaluační metriky jsou shrnuty v Tab. 5-4.

Tab. 5-4: Hodnoty evaluačních metrik pro model GRU

| Metrika        | Trénovací | Testovací |
|----------------|-----------|-----------|
| MSE            | 0,2670    | 0,2603    |
| MAE            | 0,3980    | 0,3806    |
| RMSE           | 0,5167    | 0,5102    |
| R <sup>2</sup> | 0,7330    | 0,8175    |







Obr. 5-10: Predikce zbývající tloušťky povlaku v závislosti na segmentech pro jednotlivé testované vzorky (1 segment = 1 minuta) – model GRU.

Model GRU dosahuje nejlepšího výsledku na testovací sadě ze všech dosud testovaných architektur ( $R^2 = 0,818$ ), přičemž testovací metriky ( $MSE = 0,260$ ,  $RMSE = 0,510$ ) jsou nižší než trénovací ( $MSE = 0,267$ ,  $RMSE = 0,517$ ). Tento obrácený vztah - testovací  $R^2$  převyšující trénovací  $R^2$  ( $0,733$ ) - není paradoxem, ale odrazem velmi rychlé konvergence: model trénoval pouze 22 epoch s agresivní rychlostí učení  $1,0 \cdot 10^{-3}$ , což vedlo k zachycení obecných trendů opotřebení bez přílišné adaptace na specifika jednotlivých trénovacích sekvencí. Nižší trénovací  $R^2$  signalizuje mírné podfitování na trénovacích datech, nikoli problém s generalizací. Testovací sada se ukázala jako méně variabilní, čímž model dosáhl přesnějších predikcí. Analýza SHAP odhaluje, že model se primárně opírá o TC\_Mean (teplota kontaktu, střední SHAP  $0,090$ ) a AE\_RMS\_Corrected\_Cumsum (kumulativní RMS energie,  $0,074$ ), zatímco spektrální deskriptory (AE\_Spectral\_Centroid, AE\_Spectral\_Spread) přispívají zanedbatelně.

Individuální predikce testovacích vzorků (Obr. 5-10) ukazují relativně homogenní výkon napříč vzorky - bez výrazné polarizace typické pro LSTM. Model zachycuje klesající trajektorie opotřebení s dobrým sledováním trendu, přičemž počáteční posun zůstává přítomen u všech vzorků - systémový efekt sdílený všemi architekturami (viz kap. 5.1.1).



Obr. 5-11: Evaluační grafy predikce opotřebení pro model GRU – testovací množina.



Obr. 5-12: Evaluační grafy predikce opotřebení pro model GRU – trénovací množina.

## 5.2 Charakterizace útlumu v závislosti na tloušťce vrstvy (H2)

V této podkapitole je vyhodnocen vliv tloušťky polymerní vrstvy na přenos a transformaci diagnostického signálu AE. Cílem experimentu bylo ověřit citlivost vybraných parametrů na úbytek materiálu a popsat fyzikální mechanismy útlumu při průchodu viskoelastickým prostředím.


### 5.2.1 Hybridní model CNN-GRU

Hybridní model CNN-GRU rozšiřuje architekturu čistého GRU o konvoluční větev pro extrakci spektrálních příznaků z AE spektrogramů ( $1 \times 128 \times 128$ ). CNN blok tvoří tři konvoluční vrstvy ( $1 \rightarrow 16 \rightarrow 32 \rightarrow 64$  filtrů) zakončené adaptivním průměrovacím poolingem a plně propojenou vrstvou generující 64-dimenzionální embedding. Tento embedding je konkatenován s 16 tabulkovými příznaky a tvoří 80-dimenzionální vstup do GRU části (2 vrstvy, 256 skrytých stavů, dropout 0,15/0,10). Optimalizace algoritmem Adam s rychlostí učení  $1,0 \cdot 10^{-3}$  a Huber loss byla ukončena po 27 epochách. Dosažené evaluační metriky jsou shrnuty v Tab. 5-5.


Tab. 5-5: Hodnoty evaluačních metrik pro hybridní model CNN-GRU

| Metrika        | Trénovací | Testovací |
|----------------|-----------|-----------|
| MSE            | 0,1446    | 0,2315    |
| MAE            | 0,2682    | 0,3463    |
| RMSE           | 0,3802    | 0,4811    |
| R <sup>2</sup> | 0,8554    | 0,8377    |

Hybridní model CNN-GRU dosahuje nejlepšího výsledku na testovací sadě ze všech testovaných architektur ( $R^2 = 0,838$ ) a zároveň nejmenší generalizační mezery ( $\Delta \approx 0,018$  mezi trénovacím  $R^2 = 0,855$  a testovacím  $R^2 = 0,838$ ). Tento výsledek potvrzuje synergii obou složek: CNN blok zachycuje frekvenčně-časové vzory v AE spektrogramech, které tabulkové příznaky nepokrývají, a GRU část integruje tuto informaci do sekvenčního kontextu opotřebení. Na vizualizaci testovací množiny jsou datové body soustředěny nejbližší k ideální diagonále ze všech modelů, residuální distribuce je symetričtější s výrazným vrcholem u nuly a rozsahem přibližně  $-1,0$  až  $+1,0$ . Absence analýzy SHAP pro tento model je způsobena složitostí hybridní architektury - atribuce vstupního příspěvku CNN embeddings vyžaduje specializované metody interpretability pro vícemodální vstupy.




Obr. 5-13: Predikce zbývající tloušťky povlaku v závislosti na segmentech pro jednotlivé testovací vzorky (1 segment = 1 minuta) – model CNN-GRU.



Obr. 5-14: Evaluační grafy predikce opotřebení pro model CNN-GRU – testovací množina.

Individuální predikce testovacích vzorků (Obr. 5-13) vykazují nejhomogennější výkon napříč vzorky ze všech testovaných modelů. Spektrální embedding z CNN umožňuje modelu rozlišit různé režimy opotřebení i u vzorků s atypickými průběhy - konkrétně vzorek Sample017\_200N, který způsoboval největší pokles přesnosti u LSTM, je predikován s vyšší věrností díky zachycení specifického spektrálního profilu nízkozátěžového kontaktu. Počáteční posun predikce zůstává přítomen (systémový efekt, viz kap. 5.1.1).



Obr. 5-15: Evaluační grafy predikce opotřebení pro model CNN-GRU – trénovací množina.

## 5.2.2 Analýza amplitudových a energetických parametrů


Pro hodnocení energetického úbytku byly analyzovány parametry špičková amplituda ( $A_{pk}$ ), efektivní hodnota napětí ( $V_{rms}$ ) a absolutní energie ( $E_{abs}$ ). Naměřené hodnoty byly proloženy regresní křivkou (znázorněna přerušovanou čarou na Obr. 5-16, Obr. 5-17, Obr. 5-18), která definuje charakter útlumu pomocí exponenciální funkce Rov. (5-1):

$$y = a \cdot e^{x \cdot b} + C \quad (5-1)$$


kde  $y$  představuje sledovaný parametr AE,  $x$  tloušťku vrstvy v mikrometrech.

Z naměřených dat (Obr. 5-16, Obr. 5-17, Obr. 5-18) je patrný výrazný klesající trend se zvyšující se tloušťkou povlaku. Extrémní pokles hodnot při srovnání referenčního vzorku bez povlaku (No\_coating) s nejtenčím testovaným povlakem vypovídá o tom, že k největší


ztrátě energie dochází právě na rozhraní ocelový substrát – polymerní povlak. Tento jev je způsoben diskontinuitou akustické impedance na materiálovém přechodu. Plynulý charakter proložené křivky u vzorků s povlakem dále naznačuje, že v samotném polymerním objemu dochází k relativně rovnoměrnému útlumu signálu.



Obr. 5-16: Charakteristika špičkové amplitudy na základě tloušťky povlaku



Obr. 5-17: Charakteristika energie hitu nad prahem v závislosti na tloušťce povlaku




Obr. 5-18: Charakteristika RMS v závislosti na tloušťce povlaku 75  $\mu s$  po překročení prahové hodnoty


### 5.2.3 Analýza strukturálních parametrů a jev stagnace

Kromě energetické úrovně byla sledována také transformace tvaru a struktury signálu pomocí parametrů špičatost (Kurtosis) a délka trvání hitu (Duration). Tyto závislosti jsou vyneseny na Obr. 5-19, Obr. 5-20.

U těchto veličin lze pozorovat odlišné chování. Po počátečním přechodu z oceli na polymer dochází k výrazné stagnaci na přibližně stejné hodnotě bez ohledu na další nárůst tloušťky materiálu. Z tohoto charakteru lze odvodit, že polymerní povlak utlumuje a transformuje AE hit do určité míry již při průchodu první vrstvou materiálu, čímž zásadně mění jeho dobu trvání a statistickou špičatost (kurtosis). Jakmile dojde k této prvotní transformaci impulsu, zůstává časový a strukturální charakter signálu pro tloušťky v rozsahu 264 až 507  $\mu m$  stabilní.



Obr. 5-19: Charakteristika špičatosti (kurtosis) vůči tloušťce povlaku



Obr. 5-20: Charakteristika délky AE hitu vůči tloušťce povlaku

#### 5.2.4 Výsledky ověření přenositelnosti signálu v nekonformní konfiguraci (4-ball)

Výsledky realizovaných testů studujících vnitřní útlum v nekonformní konfiguraci (4-ball) byly podrobeny komparativní analýze s daty získanými z měření konformních kontaktů kloubového ložiska. Cílem tohoto srovnání bylo posoudit vliv geometrie kontaktu na přenos akustického signálu a verifikovat možnost přenosu predikčního modelu. Pro vyhodnocení byly zvoleny klíčové parametry: špičková amplituda ( $A_{pk}$ ), efektivní hodnota napětí ( $V_{rms}$ ) a absolutní energie ( $E_{abs}$ ).



Naměřené hodnoty byly pro obě konfigurace vyneseny v semi-logaritmickém měřítku a proloženy lineární regresní funkcí (ve smyslu rovnice (5-2)). Při proložení trendu byl záměrně vynechán bod odpovídající nulové tloušťce povlaku (No coat), aby byl demonstrován čistý materiálový trend útlumu v polymerní vrstvě a eliminováno zkreslení způsobené odlišným charakterem vazby na rozhraní kov-kov.


$$y = k \cdot x + q \quad (5-2)$$

Kde  $y$  představuje sledovaný parametr AE,  $x$  tloušťku polymerního povlaku,  $k$  směrnici přímký reprezentující intenzitu útlumu v materiálu a  $q$  konstantu definující teoretický počátek trendu


Na grafech vyobrazených na Obr. 5-21 (Amplituda), Obr. 5-22 (RMS) a Obr. 5-23 (Absolutní energie) jsou vyneseny průměrné hodnoty s vyznačenými chybovými úsečkami (modré body pro konformní kontakt, červené body pro nekonformní 4-ball kontakt).

Při srovnání vzorků bez povlakového systému (No coat) dosahuje nekonformní konfigurace 4-ball ve všech sledovaných parametrech výrazně nižších hodnot než konformní ložisko. Rozdíl v naměřené špičkové amplitudě činí  $1,16 V$ , u parametru absolutní energie je tento pokles ještě markantnější. Naopak u vzorků v neporušeném stavu s plnou tloušťkou povlaku ( $\sim 500 \mu m$ ) vykazují obě testovací konfigurace srovnatelné výsledky a naměřené hodnoty se u obou typů kontaktu téměř shodují.


V oblasti tloušťky povlaku přibližně  $330 \mu m$  vykazují data u konfigurace 4-ball odchylku od stanoveného lineárního trendu. V tomto bodě jsou naměřené hodnoty všech tří parametrů ( $A$ ,  $V_{RMS}$ ,  $E_{abs}$ ) u nekonformního kontaktu vyšší než u kontaktu konformního. Amplituda u 4-ball konfigurace zde dosahuje hodnoty průměrně  $\sim 1,12 V$ , zatímco u konformního ložiska byla ve stejné lokalitě naměřena hodnota  $\sim 0,68 V$ . Podobný trend, kdy hodnoty u 4-ballu převyšují hodnoty konformního kontaktu, je patrný i u efektivního napětí a celkové energie hitu.



Obr. 5-21: Porovnání charakteristik špičkové amplitudy na základě tlouřtky povlaku pro konformní a 4-ball konfiguraci při aplikaci testu studujícího vnitřní útlum




Obr. 5-22: Porovnání charakteristik energie hitu nad prahem v závislosti na tlouřtce povlaku pro konformní a 4-ball konfiguraci při aplikaci testu studujícího vnitřní útlum




Obr. 5-23: Porovnání charakteristik RMS v závislosti na tloušťce povlaku 75  $\mu$ s po překročení prahové hodnoty pro konformní a 4-ball konfiguraci při aplikaci testu studujícího vnitřní útlum

Dále byly v rámci měření sledovány parametry Duration (doba trvání hitu) Obr. 5-24 a Kurtosis (špičatost signálu) Obr. 5-25.

Kurtosis vykazuje pro obě konfigurace výrazně odlišné chování v závislosti na tloušťce povlaku. U nepoškozeného vzorku ( $\sim 500 \mu\text{m}$ ) jsou hodnoty konformní konfigurace nízké ( $\sim 3$ ), zatímco 4-ball dosahuje výrazně vyšší úrovně ( $\sim 16$ ). S klesající tloušťkou na  $\sim 330 \mu\text{m}$  narůstá Kurtosis u konfigurace 4-ball na přibližně 26,5 s extrémně vysokým rozptylem naměřených dat, zatímco konformní konfigurace zůstává stabilní. Při úplné absenci povlaku (No coat) se situace obrací - konformní konfigurace vykazuje výrazný nárůst špičatosti ( $\sim 18,5$ ), kdežto hodnota 4-ball klesá na  $\sim 5$ . Parametr Duration (Obr. 5-24) vykazuje odlišný charakter - doba trvání AE hitu je pro obě konfigurace méně citlivá na tloušťku povlaku a vykazuje výraznější vliv geometrie kontaktu než materiálového útlumu povlaku.



Obr. 5-24: Porovnání špičatosti (Kurtosis) vůči tloušťce povlaku pro konformní a 4-ball konfiguraci při aplikaci testu studujícího vnitřní útlum



Obr. 5-25: Porovnání charakteristik délky AE hitu vůči tloušťce povlaku pro konformní a 4-ball konfiguraci při aplikaci testu studujícího vnitřní útlum


## 6 DISKUZE

### 6.1 Interpretace výsledků

#### 6.1.1 Korelace AE s intenzitou tribologického procesu

Základním předpokladem pro vývoj predikčního systému bylo prokázat, že signál akustické emise nese kvantifikovatelnou informaci o intenzitě probíhajícího tribologického procesu. Tento předpoklad nachází oporu jak v teorii, tak ve výsledcích dosažených v předkládané práci. Studie Genga et al. [6] prokázala, že AE je přímou odezvou na nevratné mikrostrukturní změny v kontaktu: každá plastická deformace asperity, každé mikrořezání a každý adhezivní spoj, jehož přetržení uvolní elastickou energii, generuje měřitelný AE signál. Na rozdíl od měření celkové třecí síly, která integruje makroskopický výsledek kontaktu, AE nese informaci o fyzikální podstatě degradace povrchu v reálném čase.

Kvantitativní vazbu mezi energetickými parametry AE a objemem opotřebení formulovali Boness a McBride [12]: integrál efektivní hodnoty signálu RMS v čase,  $\int \text{RMS} dt$ , je přímo úměrný kumulativnímu objemovému úbytku materiálu. Tohoto principu využívá i předkládaná práce prostřednictvím vstupního příznaku AE\_RMS\_Corrected\_Cumsum, konkrétně kumulativního součtu (cumsum) korigovaného RMS signálu AE.



Obr. 6-1: SHAP analýza pro architekturu GRU

Rozhodujícím potvrzením fyzikální koherence predikčního modelu je SHAP analýza architektury GRU Obr. 6-1. Model spontánně identifikoval jako druhý nejvýznamnější prediktor právě AE\_RMS\_Corrected\_Cumsum (střední SHAP hodnota 0,074), a to bez jakéhokoliv explicitního fyzikálního předpisu. Skutečnost, že síť sama „znovuobjevuje“

integrační princip Bonesse a McBride [12] jako klíčový prediktor opotřebení, představuje silné zpětné potvrzení fyzikální validity naučené reprezentace. Dominantní prediktor je zde střední teplota kontaktu TC\_Mean (SHAP 0,090) - nese duální fyzikální informaci: jednak reflektuje celkovou disipovanou třecí práci (integrativní míra opotřebení), jednak ovlivňuje viskoelastické vlastnosti polymerního povlaku, jejichž teplotní závislost přímo moduluje rychlost opotřebení. Towsyfyan et al. [10] v kontextu tribologie mechanických těsnění podobně prokázali, že nárůst AE RMS je přímým odrazem přechodu do režimu smíšeného a mezního tření, tedy stavu zvýšené kontaktní intenzity.

### 6.1.2 Frekvenční charakterizace signálu a spektrální příznaky

Analýza frekvenčního obsahu AE signálu je nezbytnou součástí interpretace tribologického procesu, neboť odlišné fyzikální mechanismy poškození generují elastické vlny v různých frekvenčních pásmech. Hase et al. [7] systematicky zmapovali tato pásma: adhezivní opotřebení spojené s plastickou deformací asperit se projevuje v nižším frekvenčním pásmu, zatímco abrazivní opotřebení (mikrořezání) a vznik trhlin generují vysokofrekvenční složky přesahující 500 kHz. Geng et al. [6] specifikovali, že pro tribologii kluzných uzlů je dominantní energetická oblast signálu AE v rozmezí 100 – 400 kHz. Toto pásmo je v předkládané práci plně pokryto vzorkovací frekvencí 1 MS/s (Nyquistova mez 500 kHz), přičemž anti-aliasingový filtr odstraňuje složky nad 500 kHz.

Výsledky SHAP analýzy modelu GRU ukazují, že tabulkové spektrální deskriptory, konkrétně Spectral Centroid a Spectral Spread, přispívají k predikci zanedbatelně. Toto zjištění neimplikuje, že frekvenční informace je irelevantní; naopak, ukazuje, že skalární agregace spektra do jednoho čísla (těžiště nebo šířka) ztrácí podstatnou část diagnosticky cenné informace. Hybridní model CNN-GRU tuto mezeru překonává: konvoluční blok zpracovává plný AE spektrogram (1×128×128) a extrahuje 64dimenzionální embedding zachycující frekvenčně-časové vzory nedostupné tabulkovým příznakům. Právě tento přístup - zpracování 2D časově-frekvenční reprezentace CNN větví – je doporučován v literatuře jako metoda umožňující simultánní extrakci globálních časových trendů a lokálních spektrálních rysů [21]. Praktickým důkazem přínosu spektrálního embeddingu je výrazně lepší predikce vzorku s nízkým zatížením (Sample017\_200 N) Obr. 5-10: tento vzorek má specifický spektrální profil odpovídající nízkozátěžovému kontaktu, který tabulkové příznaky nedokážou od průměrného trénovacího vzoru odlišit, ale CNN jej identifikuje skrze charakteristický vzor ve spektrogramu.

Dalším faktorem komplikujícím spektrální analýzu bylo elektromagnetické rušení způsobené pohonem tribometru. Přestože bylo zajištěno uzemnění měřicího řetězce a aplikována pásmová filtrace, v naměřených AE signálech se vyskytovalo několik stacionárních interferenčních frekvencí konzistentních skrze celý test. Tato rušivá složka pravděpodobně přispívala k systematickému zkreslení hodnot Spectral Centroid, čímž

snižovala jejich diagnostickou hodnotu jako vstupního příznaku. Hybridní model CNN-GRU tento problém potenciálně překonává: konvoluční blok zpracovávající plný AE spektrogram se pravděpodobně naučil rozlišit stacionární interferenční frekvence od dynamicky se měnících složek spektra nesoucích informaci o stavu opotřebení.

### 6.1.3 Výkonnostní hierarchie architektur neuronových sítí

Porovnání výkonnosti pěti architektur neuronových sítí (Tab. 6-1) odhaluje hierarchii výkonnosti, která ve svém celku odráží míru využití sekvenčního kontextu a spektrální informace, avšak s jednou konzistentně vysvětlitelnou anomálií - shodou MLP a LSTM a překvapivým výsledkem RNN oproti složitější LSTM. Model MLP bez sekvenční paměti dosahuje  $R_{test}^2 = 0,753$ . Rekurentní modely obecně tuto hodnotu překonávají v závislosti na efektivitě svého paměťového mechanismu ve vztahu k dostupnému datasetu, přičemž hybridní CNN-GRU s kombinací spektrogramů a sekvenční paměti dosahuje nejlepšího výsledku  $R_{test}^2 = 0,838$ .

Tab. 6-1: Souhrnné srovnání evaluačních metrik a hyperparametrů testovaných architektur neuronových sítí

| Model   | R <sup>2</sup> _train | R <sup>2</sup> _test | Gen. mezera | Epoch | Dropout   | Architektura           |
|---------|-----------------------|----------------------|-------------|-------|-----------|------------------------|
| MLP     | 0,928                 | 0,753                | 0,175       | 17    | 0,20      | 3 vrstvy [256,128,64]  |
| RNN M2M | 0,907                 | 0,785                | 0,122       | 30    | 0,20/0,10 | 2 vrstvy, 64 skrytých  |
| LSTM    | 0,857                 | 0,753                | 0,104       | 42    | 0,35      | 3 vrstvy, 128 skrytých |
| GRU     | 0,733                 | 0,818                | -0,085      | 22    | 0,15/0,10 | 2 vrstvy, 256 skrytých |
| CNN-GRU | 0,855                 | 0,838                | 0,018       | 27    | 0,15/0,10 | CNN+GRU hybridní       |

Fyzikální příčina hierarchie spočívá v charakteru predikovaného procesu. Opotřebení polymerní vrstvy je nevratný, kumulativní děj: aktuální tloušťka povlaku závisí na integraci veškeré disipované třecí energie od počátku testu. MLP každý segment vyhodnocuje bez kontextu předchozích kroků, čímž ztrácí informaci o nashromážděné degradaci. Rekurentní modely udržují skrytý stav  $h_t$ , který tuto historii kumuluje - čím efektivnější paměťový mechanismus ve vztahu k dostupnému objemu dat, tím přesnější predikce trajektorie opotřebení - s výhradou, že přílišná kapacita sítě v podmínkách malého datasetu může výhodu paměti eliminovat. Yunita et al. [19] ve srovnávací studii architektur pro časové řady potvrzují, že GRU a LSTM systematicky překonávají MLP v úlohách, kde je podstatný sekvenční kontext – výsledky předkládané práce jsou s tímto závěrem v plném souladu.

Záporná hodnota generalizační mezery u GRU ( $\Delta = -0,085$ ) není indikátorem metodické chyby, nýbrž odráží stochastičnost rozdělení dat při malém počtu testovacích experimentů. Testovací množina (15 % z 18 testů, tj. přibližně 2–3 experimenty) může náhodně obsahovat testy s monotonnějším a snáze predikovatelným průběhem opotřebení, než je průměr trénovací sady. Kombinace silné regularizace (dropout 0,15/0,10) a vysoké rychlosti učení ( $lr = 10^{-3}$ ) navíc vede k suboptimální konvergenci na trénovacích datech při zachování dobré generalizace.

Paradox spočívající v nižším výkonu architektury LSTM oproti GRU navzdory vyšší komplexnosti je přímou ilustrací fenoménu popsánoho Brigato a Iocchim [22]: v podmínkách malého datasetu (small-data regime) mohou nízko-komplexní modely dosahovat srovnatelných nebo lepších výsledků než State-of-the-Art architektury. LSTM disponuje třemi branovými mechanismy (vstupní, zapomínací, výstupní), čímž se zvyšuje počet trénovaných parametrů. Při tréninkovém datasetu čítajícím řádově desítky sekvencí tato kapacita nemůže být plně využita – agresivní regularizace (dropout 0,35) nutná k potlačení přeučení zároveň omezuje schopnost sítě naučit se jemnější zákonitosti. Analogický princip vysvětluje i zdánlivě překvapivý výsledek jednoduché Vanilla RNN ( $R_{test}^2 = 0,785$ ) překonávající LSTM ( $R_{test}^2 = 0,753$ ): dvouvrstvá RNN se 64 skrytými stavy čítá výrazně méně trénovaných parametrů než třívrstvá LSTM se 128 stavy a je proto v podmínkách malého datasetu efektivněji regularizovanou architekturou - v přímé analogii s výhodou GRU nad LSTM.

Hybridní model CNN-GRU dosahuje nejlepšího výsledku ( $R_{test}^2 = 0,838$ ) a zároveň nejmenší generalizační mezery mezi trénovací a testovací sadou ( $\Delta = 0,018$ ). Tato kombinace výkonu a robustnosti potvrzuje synergii obou složek, předpokládanou řešerší [21]: CNN blok zachycuje frekvenčně-časové vzory v AE spektrogramech, které tabulkové příznaky nepokrývají, a to i přes elektromagnetické rušení pohonu tribometru, jež systematicky zkresluje skalární spektrální agregáty jako Spectral Centroid (viz kap. 6.1.2). Konvoluční blok zpracovávající plný spektrogram pravděpodobně selektivně ignoruje stacionární interferenční frekvence a reaguje na dynamicky se měnící složky nesoucí informaci o opotřebení. GRU větev pak integruje tuto spektrální reprezentaci do sekvenčního kontextu opotřebení. Výsledkem je model schopný efektivně zpracovávat heterogenní testovací podmínky, jak dokazuje zlepšená predikce vzorku Sample017\_200N.

#### 6.1.4 Materiálový útlum a impedanční diskontinuita polymerního povlaku

Výsledky testů studujících vnitřní útlum demonstrují, že průchod signálu AE polymerní vrstvou kompozitní kluzná vrstva se řídí exponenciálním útlumovým zákonem (Obr. 5-16, Obr. 5-17, Obr. 5-18). Experimentálně proložená regresní funkce  $y = a \cdot e^{(x \cdot b)} + C$  viz Rov. (5-1) je strukturálně identická se zákonem materiálového útlumu formulovaným



Nazarchukem [4]:  $A = A^0 \cdot e^{-\alpha x}$ , kde  $\alpha$  je součinitel útlumu materiálu a  $x$  vzdálenost od zdroje. Konstanta  $C$  v regresní funkci reprezentuje asymptotu odpovídající systémovému šumu a signálům z okolí měřicí soustavy. Tato shoda funkcionálního tvaru potvrzuje, že dominantním útlumovým mechanismem v polymerní vrstvě je viskózní absorpce – přeměna energie elastické vlny na teplo prostřednictvím vnitřního tření v polymerní matici.

Klíčovým a neintuitivním poznatkem je to, že největší pokles amplitudy,  $V_{rms}$  a absolutní energie nenastává plynule v průběhu opotřebení povlaku, ale skokem - při přechodu z holého ocelového substrátu (No\_coat) na nejtenčí testovaný povlak ( $264 \mu m$ ). Tento skok nelze vysvětlit materiálovým útlumem v samotném polymeru, neboť  $264 \mu m$  tenká vrstva nemůže způsobit pokles o celé řády. Fyzikální příčinou je impedanční diskontinuita na rozhraní kov–polymer. Akustická impedance oceli ( $\sim 46 MRayl$ ) a polymerního kompozitu ( $\sim 3 - 5 MRayl$ ) se liší o řád velikosti. Energie přenesená přes materiálové rozhraní závisí na míře impedančního přizpůsobení obou prostředí – při výrazné neshodě je velká část energie odražena zpět do substrátu a k senzoru nedorazí. Přítomnost jakékoli polymerní vrstvy – bez ohledu na její tloušťku – vytváří kritickou impedanční bariéru, přičemž každý další přírůstek tloušťky přidává pouze graduální viskózní útlum. Tento závěr je konzistentní s teorií šíření elastických vln popsanou v rešerši: povrchové vlny, které jsou hlavními nositeli informace při měření, jsou impedančními přechody výrazněji ovlivněny než vlny objemové.

#### 6.1.5 Statistická charakterizace signálu – jev stagnace Kurtosis a Duration

Odlišné chování strukturálních parametrů Kurtosis a Duration oproti energetickým parametrům (Obr. 5-19, Obr. 5-20) odhaluje fundamentální rozdíl mezi dvěma typy informace nesené AE signálem: energetickou hladinou impulsu a morfologií jeho tvaru. Feng et al. [9] ve své přehledové studii uvádějí, že Kurtosis blízká Gaussovskému rozdělení amplitud (v Pearsonově konvenci  $\approx 3$ , v konvenci excess kurtosis  $\approx 0$ ) odpovídá stabilnímu, mírně adhezivnímu tření bez výrazných impulzních jevů. Výrazný nárůst Kurtosis indikuje přítomnost diskrétních vysokoenergetických událostí (mikrořezání, delaminace, průchod abrazivní částice kontaktem) na pozadí spojitě třecí emise.

V kontextu testů studujících vnitřní útlum je tento princip v plném souladu s naměřenými daty: při plném povlaku ( $\sim 500 \mu m$ ) vykazuje konformní konfigurace Kurtosis  $\approx 3$ , což odpovídá situaci, kdy polymerní vrstva pohltí impulzní charakter test studující vnitřní útlum zdroje a signál u senzoru se blíží gaussovskému rozdělení. Přítomnost polymeru tedy nejen tlumí amplitudu, ale aktivně transformuje charakter signálu od impulzního k difúznímu. Fyzikálním mechanismem je viskoelastická dolnopropustní (low-pass) charakteristika polymeru: vysokofrekvenční složky signálu - zodpovědné za ostrý náběh a krátkou dobu trvání impulsu, jsou preferenčně absorbovány, zatímco nízké frekvence

prochází s menším útlumem. Tato frekvenčně selektivní absorpce nastává primárně na rozhraní kov–polymer, kde dochází k nevratné transformaci morfologie impulsu.

Stagnace Kurtosis a Duration v rozsahu 264 – 500  $\mu m$  má přímý praktický důsledek: tyto parametry nemohou sloužit jako spolehlivé ukazatele tloušťky v rámci polymerní vrstvy. Jsou však citlivé na kvalitativní přechod polymer/kov: při No\_coat konformní konfigurace Kurtosis skokově vzrůstá na  $\sim 18,5$ , čímž signalizuje radikálně odlišný stav povrchu bez tlumicí polymerní vrstvy. Tato vlastnost může být využita pro detekci kritického stavu „holý kov“, kdy polymer byl zcela opotřebován a hrozí poškození ocelového substrátu.

### 6.1.6 Přenositelnost konfigurace na konformní geometrii kontaktu

Srovnání konformní a nekonformní (4-ball) konfigurace testů studujících vnitřní útlum poskytuje poznatky o přenositelnosti predikčního přístupu na odlišnou geometrii kontaktu (Obr. 5-21, Obr. 5-22, Obr. 5-23). Při plném povlaku ( $\sim 500 \mu m$ ) dosahují obě konfigurace srovnatelných hodnot všech tří energetických parametrů, přičemž rozdíly jsou v rámci chybových úseček. Toto chování potvrzuje, že při plném pokrytí substrátu polymerem dominuje materiálový útlum nad geometrickým efektem kontaktu. Jinými slovy: výsledky naznačují, že diagnostický přístup založený na energetických parametrech AE může být potenciálně přenositelný mezi konformní a nekonformní geometrií kontaktu za podmínky intaktní polymerní vrstvy. Experiment však primárně ověřuje přenositelnost fyzikálního diagnostického principu, nikoliv plně validovanou generalizaci konkrétního modelu hlubokého učení mezi odlišnými kontaktními konfiguracemi.

Při absenci povlaku (No\_coat) nastává výrazná divergence: nekonformní 4-ball konfigurace vykazuje amplitudu nižší o 1,16 V oproti konformní konfiguraci (Obr. 5-21). Příčinou je geometrický útlum bodového kontaktu: test studující vnitřní útlum impuls prochází rozhraním s malou efektivní kontaktní plochou, čímž dochází k výraznějšímu geometrickému rozptylu energie. Tento asymetrický efekt je zdokumentován i chováním Kurtosis (Obr. 5-23): konformní kov–kov kontakt vykazuje Kurtosis  $\sim 18,5$  (silně impulzní charakter), zatímco 4-ball dosahuje pouze  $\sim 5$  - hodnoty blízké gaussovskému rozdělení dle Fenga et al. [9]. Bodový kontakt tak paradoxně „maskuje“ intenzitu test studující vnitřní útlum události do statisticky mírného tvaru signálu, a to i při přímém kovovém kontaktu bez jakékoliv tlumicí vrstvy.

Anomální odchylka 4-ball konfigurace od lineárního trendu útlumu při tloušťce  $\sim 330 \mu m$  Obr. 5-21 představuje z hlediska fyzikálního pochopení nejzajímavější výsledek experimentální části. Naměřené hodnoty  $A_{pk}$ ,  $V_{rms}$  a  $E_{abs}$  u 4-ball překračují hodnoty konformní konfigurace ( $A_{pk}$ :  $\sim 1,12 V$  vs.  $\sim 0,68 V$ ) jsou vyšší u 4-ball konfigurace než u konfigurace konformní. Fyzikální příčinou jsou dva souběžné efekty. Za prvé, v průběhu akcelerovaných tribologických testů vznikla v kontaktní oblasti opotřebovaná dráha se sníženou lokální tloušťkou povlaku. Kuličky 4-ball konfigurace dosedají při testu

studujícího vnitřní útlum do této dráhy, takže AE signál prochází tenčí vrstvou s nižším útlumem, než odpovídá nominální tloušťce 330  $\mu\text{m}$ . Za druhé, dosednutí kuliček do opotřeбенé konkávní dráhy zvětšuje efektivní kontaktní plochu oproti kontaktu s rovnou neopotřeбенou plochou, čímž se zlepšuje akustická vazba na rozhraní. Celá konfigurace testu studujícího vnitřní útlum je přitom statická bez rotace a bez třecí síly, takže se Felicity efekt v tomto případě neuplatňuje. Tato anomálie má přímý praktický dopad: přenesení predikčního modelu z konformní na nekonformní geometrii není v oblasti středního opotřeбенí ( $\sim 330 \mu\text{m}$ ) spolehlivé bez geometricky specifické kalibrace, přičemž nekonformní konfigurace může nadhodnocovat skutečnou intenzitu AE signálu.

### 6.1.7 Implementace systému pro diagnostiku kluzné vrstvy

Na základě dosažených výsledků byl vytvořen funkční softwarový systém pro predikci zbývajících tloušťek kluzné vrstvy v reálném čase nazvaný `realtime_predictor`. Jako predikční jádro je nasazena architektura CNN-GRU s hodnotou  $R_{test}^2 = 0,838$ .

Signál AE je pořizován v segmentech délky 1,5 sekundy vzorkovací frekvencí 1  $\text{MS/s}$  s pásmovou propustí 50 – 490  $\text{kHz}$ , přičemž každý segment odpovídá jednomu měřicímu intervalu přibližně 1 minuty délky testu. Z každého segmentu je extrahováno celkem 16 vstupních příznaků: 13 statistických a spektrálních popisných parametrů signálu AE, konkrétně poměry pásmové energie ve čtyřech frekvenčních pásmech (BER Band 1–4), Crest Factor a Peak Amplitude na 90. percentilu, korigovaná efektivní hodnota RMS spolu s jejím kumulativním součtem a mezihodnotovým přírůstkem, tvarový faktor, spektrální těžiště, spektrální rozptyl a míra průchodů nulou, a tři provozní parametry: střední axiální síla `Fa_Mean`, střední teplota kontaktu `TC_Mean` a identifikátor měřicího bloku. Před vstupem do modelu jsou všechny parametry vyhlazeny Savitzky-Golayovým filtrem (11 segmentů, polynom 3. stupně, kauzální režim), čímž je přesně replikováno předzpracování z tréninku.

Souběžně je z AE signálu téhož segmentu metodou STFT vypočítán spektrogram (`nperseg` = 2048, `noverlap` = 1536, `nfft` = 2048) s frekvenčním ořezem na pásmo 50 – 490  $\text{kHz}$ . Obraz je normalizován na základě globálního  $\text{dB}$  rozsahu stanoveného z trénovacích dat a interpolován na rozměr  $128 \times 128$  pixelů jako vstup konvolučního bloku CNN. Model tak simultánně zpracovává skalární popisné parametry nesoucí statistiku celého segmentu i prostorovou frekvenčně-časovou reprezentaci spektrogramu zachycující lokální spektrální vzory.

Normalizace vstupů je aplikována výhradně s parametry uloženými v souboru `scaler.json`, odvozenými z trénovací sady: viz Rov. (6-1). Živá data nejsou nikdy použita k přepočtu normalizačních parametrů. Výstupní predikce je zpětně převedena na fyzikální jednotky denormalizací viz Rov. (6-2), kde cílovou veličinou je zbývajících tloušťka kluzné vrstvy vyjádřená v milimetrech.

$$x_{norm} = \frac{(x - X_{mean})}{X_{std}} \quad (6-1)$$

kde  $x$  je aktuální hodnota popisného parametru z živého měření,  $X_{mean}$  je střední hodnota daného parametru stanovená z trénovací sady a  $X_{std}$  je jeho směrodatná odchylka stanovená z trénovací sady.

$$\hat{t} = \hat{y}_{norm} \cdot y_{std} + y_{mean} \quad (6-2)$$

kde  $\hat{y}_{norm}$  je výstup modelu v normalizovaném prostoru,  $y_{mean}$  je střední hodnota cílové veličiny z trénovací sady a  $y_{std}$  je její směrodatná odchylka.

Klíčovým aspektem implementace je udržování skrytého stavu GRU vrstvy napříč segmenty. Model nevyhodnocuje každý segment izolovaně, ale průběžně akumuluje kontext průběhu celého testu v rekurentní paměti v souladu s topologií Many-to-Many používanou při tréninku. Systém je provozován ve dvou režimech: v režimu watch sleduje zdrojovou složku a zpracovává každý nově přichozí soubor ve formátu TDMS bezprostředně po jeho uložení, přičemž aktuální predikce je průběžně zobrazována v živém grafu spolu s odpovídajícím spektrogramem; v režimu simulate je sekvence přehrávána ze stávajícího sloučeného datasetu pro offline ověření a ladění.

Výstupem systému je kontinuální trajektorie zbývající tloušťky kluzné vrstvy jako funkce provozního času, průběžně ukládaná do souboru CSV. Systém byl ověřen v režimu simulate přehráváním dat ze stávajícího datasetu; nasazení v režimu watch při aktivním měření na tribometru nebylo v rámci předkládané práce realizováno. Systém je přesto plně připraven k implementaci, neboť predikční model, normalizační parametry i akvizičně-předzpracovatelský řetězec jsou exportovány ve formě přenositelných souborů připravených k nasazení v prostředí reálného měření.

## 6.2 Verifikace hypotéz

### 6.2.1 Hypotéza H1

**Hypotéza H1 byla formulována takto:** „*Intenzita tribologického procesu v ložisku ovlivňuje intenzitu generovaného signálu akustické emise.*“ Podtextem hypotézy je předpoklad, že tato korelace je dostatečně silná a konzistentní, aby ji bylo možné využít jako základ pro predikci tloušťky polymerního povlaku prostřednictvím umělých neuronových sítí.

Hypotéza H1 je **potvrzena**. Primárním argumentem je úspěšnost predikce: všech pět testovaných architektur dosahuje na testovací sadě koeficientu determinace  $R^2$  v rozmezí

0,753–0,838 (Tab. 6-1, Tab. 5-1 až Tab. 5-5). Pokud by AE signál nekoreloval s tribologickým procesem, nebo pokud by tato korelace byla příliš slabá či nestabilní, tudíž žádný z modelů by nebyl schopen predikovat tloušťku povlaku nad úrovní průměrné hodnoty ( $R^2 \approx 0$ ). Dosažená úroveň  $R^2 = 0,838$  u nejlepšího modelu CNN-GRU prokazuje, že AE signál nese dostatečně bohatou a konzistentní informaci o stavu tribologického rozhraní.

Druhým argumentem je výsledek SHAP analýzy modelu GRU – kapitola 5.1.4: parametr AE\_RMS\_Corrected\_Cumsum (kumulativní součet korigovaného AE\_RMS signálu po odstranění montážních diskontinuit mezi měřicími bloky) se ukázal jako druhý nejvýznamnější prediktor s hodnotou 0,074. Tento parametr přímo kvantifikuje celkovou disipovanou akustickou energii, přičemž korelace kumulativního RMS s objemovým opotřebením je principem zformulovaným Bonnessem a McBridem [12] a potvrzeným řadou dalších autorů [6, 7, 11]. Fakt, že model tuto fyzikálně motivovanou veličinu identifikuje jako klíčovou, potvrzuje, že predikce není výsledkem náhodných korelací v datech, nýbrž odrazem skutečného fyzikálního vztahu mezi AE a tribologickým procesem.

Třetím argumentem je samotná hierarchie výkonnosti architektur: progresivní zlepšení od MLP přes RNN ke GRU a CNN-GRU je fyzikálně motivováno. Opotřebením je kumulativní proces, tudíž modely s paměťovým mechanismem, které dokáží sledovat historii AE signálu v čase, přirozeně predikují lépe než statický MLP. Tato skutečnost implicitně potvrzuje, že AE signál v průběhu testu nese informaci o narůstajícím kumulativním opotřebením, nikoli pouze o okamžitém stavu kontaktu.

## 6.2.2 Hypotéza H2

**Hypotéza H2 byla formulována takto:** „*Intenzita signálu akustické emise vzrůstá s klesající tloušťkou polymerního povlaku ložiska.*“ Podtextem je předpoklad, že polymerní povlak působí jako tlumicí prvek - s progresivním opotřebením dochází ke snižování útlumu a nárůstu detekované intenzity AE.

Hypotéza H2 je **potvrzena pro energetické parametry signálu a podmíněně potvrzena pro parametry strukturální**. Toto rozlišení je fyzikálně motivované a představuje nový poznatek přesahující původní formulaci hypotézy.

Pro parametry  $A_{pk}$ ,  $V_{rms}$  a  $E_{abs}$  byl prokázán monotónní klesající trend s narůstající tloušťkou povlaku, popsáný exponenciální regresní funkcí Rov. (5-1) (Obr. 5-16, Obr. 5-17, Obr. 5-18). Funkcionální tvar tohoto trendu odpovídá teorii materiálového útlumu dle Nazarchuka [4], přičemž dominantní příspěvek k celkovému útlumu pochází z impedanční diskontinuity na rozhraní kov–polymer, nikoliv z viskózní absorpce v samotném objemu polymeru. Tato skutečnost znamená, že intenzita signálu AE je citlivá primárně na přítomnost polymerní vrstvy jako takové, nikoli na drobné variace její tloušťky v rozsahu

264 – 500  $\mu\text{m}$ . Pro energetické parametry je tedy hypotéza H2 potvrzena v celém testovaném rozsahu tloušťek (0 – 500  $\mu\text{m}$ ).

Pro strukturální parametry Kurtosis a Duration hypotéza H2 platí pouze pro přechod kov-polymer, nikoliv monotónně v celém rozsahu tloušťky (Obr. 5-19, Obr. 5-20). V rozsahu 264 – 500  $\mu\text{m}$  tyto parametry stagnují: polymer transformuje morfologii impulsu primárně na rozhraní, přičemž přidávání dalšího materiálu tvar signálu dále nemění. Tato podmíněnost má konkrétní diagnostické implikace: pro sledování tloušťky povlaku v průběhu opotřebení nelze spoléhat na Kurtosis ani Duration jako monotónní indikátory degradace v oblasti polymerní vrstvy. Tyto parametry jsou však citlivé na kvalitativní přechod z částečně opotřebovaného na zcela opotřebovaný povrch (No\_coat), a mohou proto sloužit jako binární indikátory kritického stavu.

Experimenty s nekonformní 4-ball konfigurací ukázaly, že přenositelnost modelu postaveného na konformní geometrii je spolehlivá pouze v oblasti plného povlaku (~500  $\mu\text{m}$ ), kde obě konfigurace vykazují srovnatelné energetické parametry. V oblasti středního opotřebení (~330  $\mu\text{m}$ ) a při No\_coat se výsledky divergují, a to z důvodu nižší lokální tloušťky povlaku v opotřebované dráze a zvětšené efektivní kontaktní plochy při dosednutí kuliček do opotřebované konkávní dráhy. Hypotéza H2 je tedy platná jako obecný fyzikální princip, avšak jeho kvantitativní projevy jsou závislé na geometrii kontaktu a nemohou být bez kalibrace přenášeny mezi konfiguracemi s rozdílnou kontaktní geometrií.

## 6.3 Limity studie

### 6.3.1 Omezení datasetu a generalizační schopnosti modelů

Navzdory dosažené vysoké predikční přesnosti je nutné interpretovat výsledky s ohledem na omezený rozsah experimentální databáze. Dataset byl vytvořen na základě 18 tribologických experimentů, přičemž jednotlivé trénovací vzorky vznikaly segmentací kontinuálních časových řad akustické emise. Ačkoliv tento přístup významně rozšiřuje počet dostupných datových segmentů, jednotlivé vzorky nejsou z hlediska statistické nezávislosti plně ekvivalentní samostatným experimentálním realizacím.

Časové segmenty pocházející z jednoho experimentu sdílejí provozní podmínky a charakter šumu měřicího řetězce; dynamika degradace se však v průběhu testu přirozeně vyvíjí a mezi segmenty konstantní není. Riziko záměny interpolační schopnosti modelu za skutečnou generalizaci je navíc výrazně sníženo použitou strategií Group Shuffle Split, při níž jsou celé experimentální běhy přiřazeny výhradně do trénovací, nebo výhradně do testovací množiny - model proto na testovacích datech nemůže využít znalost konkrétní experimentální trajektorie získané při tréninku. Dosažené hodnoty evaluačních metrik je nicméně vhodné

interpretovat s vědomím omezeného počtu nezávislých experimentálních realizací a nepovažovat je za potvrzení robustnosti při výrazně odlišných provozních podmínkách.

### 6.3.2 Riziko přeučení a informačního úniku

Použité architektury hlubokého učení obsahují značné množství trénovatelných parametrů vzhledem k velikosti experimentální databáze, což přirozeně zvyšuje riziko přeučení modelů (overfittingu). Toto riziko bylo redukováno kombinací feature dropoutu, rekurentního dropoutu, časné zástavy tréninku (early stopping) a Bayesovské optimalizace hyperparametrů. Přesto nelze zcela vyloučit, že modely zachytily i specifické charakteristiky konkrétních experimentálních běhů, které nemusí být obecně přenositelné na výrazně odlišné provozní podmínky.

Riziko informačního úniku (data leakage) bylo v práci systematicky eliminováno na dvou úrovních. Na úrovni rozdělení dat zajišťuje strategie Group Shuffle Split, že celé experimentální běhy jsou přiřazeny výhradně do trénovací nebo testovací množiny — žádný segment z testovacího experimentu se proto nevyskytuje v trénovacích datech. Na úrovni předzpracování byla normalizace tabulárních příznaků inicializována výhradně z trénovací sady; testovací data jsou transformována s fixními parametry odvozenými z tréninku, čímž je vyloučen únik statistik testovací sady do procesu učení.

### 6.3.3 Interpretace významu kumulativních příznaků

Analýza SHAP identifikovala kumulativní energetické parametry akustické emise, zejména AE\_RMS\_Corrected\_Cumsum, jako druhý nejvýznamnější vstupní příznak modelu. Tento výsledek je fyzikálně dobře interpretovatelný, protože degradace polymerní vrstvy představuje ireverzibilní kumulativní proces, při němž dochází k postupné disipaci mechanické energie v kontaktní oblasti - kumulativní součet AE\_RMS tak přímo odráží princip formulovaný Bonnessem a McBridem [12].

Použití kumulativních příznaků přináší legitimní metodickou otázku: zda model predikuje opotřebení na základě fyzikálního obsahu signálu, nebo primárně sleduje monotónní časový trend kumulativní veličiny. Dostupná data tuto obavu do značné míry vyvracejí. Dominantním prediktorem není AE\_RMS\_Corrected\_Cumsum, nýbrž střední teplota kontaktu TC\_Mean (SHAP 0,090 vs. 0,074), která není monotónní ani ryze časovou proměnnou - závisí na aktuálním zatížení a stavu tribologického rozhraní. Dále, samotný příznak AE\_RMS\_Corrected\_Cumsum nenese informaci o čase, nýbrž o kumulované akustické energii: dva testy ve stejném časovém bodě ale při odlišném zatížení vykazují odlišné hodnoty cumsum. Konečně, výkonnostní rozdíly mezi architekturami - od MLP ( $R_{test}^2 = 0,753$ ) po CNN-GRU ( $R_{test}^2 = 0,838$ ) - by neexistovaly, kdyby model pouze fitoval triviální monotónní trend; ten by zvládla i statická síť bez paměti.

Skutečnost, že model identifikuje jako klíčové příznaky nesoucí kumulativní fyzikální informaci o tribologickém procesu, není metodickým omezením, nýbrž shodou reprezentace modelu s charakterem predikovaného jevu: opotřebení je kumulativní a nevratný děj, jehož predikce přirozeně vyžaduje příznaky zachycující historii procesu. Tento aspekt je relevantní pro návrh budoucích experimentů - konkrétně pro posouzení, zda modely trénované na jiných zatěžovacích profilech zachovají fyzikální interpretovatelnost dominantních příznaků.

#### 6.3.4 Omezení přenositelnosti do provozních podmínek

Navržený diagnostický řetězec byl validován v laboratorních podmínkách na modulárním tribometru s definovanou kontaktní geometrií a řízenými provozními podmínkami. Přestože výsledky potvrzují vysoký potenciál kombinace akustické emise a sekvenčních neuronových sítí pro monitorování opotřebení kluzné polymerní vrstvy, přímý přenos do reálného provozu segmentových ložisek ve větrných elektrárnách zatím nelze považovat za plně ověřený.

V reálných provozních podmínkách lze oproti laboratornímu prostředí očekávat několik zásadních rozdílů. Vyšší úroveň provozního šumu, rozdílná přenosová cesta akustického signálu a variabilita montáže senzorů mohou ovlivnit absolutní amplitudu i frekvenční obsah detekovaného signálu způsoby, které bez kalibračních měření na cílové konfiguraci nelze předem kvantifikovat. Variabilita zatížení a teplotních podmínek je v práci částečně ošetřena zahrnutím axiální síly  $F_a\_Mean$  a střední teploty kontaktu  $TC\_Mean$  jako vstupních příznaků modelu; rozsah provozních podmínek reálné větrné elektrárny však může přesáhnout trénovací distribuci datasetu. V reálném provozu lze rovněž očekávat širší spektrum degradačních mechanismů než v kontrolovaném laboratorním prostředí.

Klíčovým omezením přenositelnosti je skutečnost, že posunutí amplitud a frekvenčních charakteristik AE signálu při přechodu na odlišnou kontaktní konfiguraci nebo instalační podmínky nelze spolehlivě kvantifikovat bez dedikovaných kalibračních dat na cílové sestavě. Přímý přenos natrénovaného modelu proto bez konfiguračně specifické kalibrace nelze garantovat. Další výzkum by měl být zaměřen na rozšíření experimentální databáze o data z odlišných kontaktních geometrií a provozních podmínek, jež by umožnila buď rekalicaci modelu na cílovou konfiguraci, nebo trénink reprezentace příznaků robustní vůči konfiguračním změnám.



## 7 ZÁVĚR

Práce se zabývá dvěma paralelními větvemi výzkumu: predikčním modelováním objemového úbytku polymerního kluzného povlaku segmentového ložiska metodami hlubokého učení na základě signálu akustické emise (AE) a experimentální charakterizací přenosu AE signálu v závislosti na tloušťce povlaku. Predikční model vychází z databáze 18 tribologických testů provedených na modulárním rotačním tribometru s axiálním zatěžováním, z jejichž průběhu bylo extrahováno 16 statistických příznaků popisujících časovou dynamiku AE signálu a provozní podmínky kontaktu. Bylo trénováno a porovnáno pět architektur neuronových sítí: vícevrstvý perceptron (MLP), rekurentní síť RNN, LSTM a GRU a hybridní model CNN-GRU. Přenositelnost diagnostického přístupu na jiné geometrie byla ověřena pomocí Hsu-Nielsenových zdrojů v konformní i nekonformní (4-ball) konfiguraci.

První hypotéza (H1), předpokládající dostatečnou korelaci AE signálu s intenzitou tribologického procesu pro predikci objemového úbytku, je potvrzena. Všechny testované architektury dosahují na testovacích datech koeficientu determinace  $R^2$  v rozsahu 0,753 až 0,838. Hybridní model CNN-GRU, kombinující extrakci spektrálních příznaků ze spektrogramů AE pomocí konvoluční sítě (CNN) s rekurentním zpracováním časové sekvence (GRU), dosahuje nejlepšího výsledku ( $R^2_{\text{test}} = 0,838$ ) a zároveň nejnižší generalizační mezery ( $\Delta = 0,018$ ), což prokazuje nejlepší rovnováhu přesnosti a schopnosti zobecnit naučené vzory na nová data. Analýza SHAP pro model GRU identifikuje teplotu kontaktu TC\_Mean a kumulativní korigovaný RMS signál AE\_RMS\_Corrected\_Cumsum jako dvě dominantní vstupní proměnné.

Druhá hypotéza (H2), předpokládající nárůst intenzity AE signálu s klesající tloušťkou polymerní vrstvy, je potvrzena pro energetické parametry AE\_RMS, E\_abs, V\_rms a A\_pk, které vykazují exponenciální závislost s ubývajícím tloušťkou. Dominantním fyzikálním mechanismem je akustická impedanční nespojitost na rozhraní ocel (~46 MRayl) - polymer (~3 až 5 MRayl), způsobující progresivní pokles tlumení AE signálu s tenčící se polymerní vrstvou. Pro strukturální parametry Kurtosis a Duration platí H2 pouze podmíněně: v rozsahu tloušťky 264 až 500  $\mu\text{m}$  tyto parametry stagnují, výrazný nárůst nastává až při přechodu na kovový substrát. Výsledky Hsu-Nielsenových testů v nekonformní (4-ball) konfiguraci ukazují, že přenositelnost konformního modelu je spolehlivá v oblasti plného povlaku (~500  $\mu\text{m}$ ), zatímco v oblasti středního opotřebení (~330  $\mu\text{m}$ ) dochází k divergenci způsobené nižší lokální tloušťkou v opotřebované dráze a větší kontaktní plochou.

Práce prokazuje, že kombinace signálu akustické emise a metod hlubokého učení tvoří perspektivní základ pro bezkontaktní sledování stavu polymerního povlaku v průmyslových podmínkách. Navržený diagnostický řetězec - od sběru surového AE signálu přes blokovou korekci a extrakci statistických příznaků až po predikci zbytkové tloušťky povlaku - je plně

zdokumentován a připraven pro rozšíření na různé typy povlakových materiálů, tribologické konfigurace i implementaci v online predikčním režimu.

Budoucí postup bude zahrnovat implementaci diagnostického systému do testovacího zařízení simulujícího reálný tribologický proces uložení hlavní hřídele rotoru větrné elektrárny.

## 8 VÝSLEDEK VÝZKUMU PODLE RIV

Výsledkem této práce je funkční vzorek a užitný vzor tribometru a metody.

OMASTA, M.; BURK, F.; LOVEČEK, L.: *Zařízení pro testování vibračního opotřebení materiálů kluzných ložisek*. (2024) URL:

<https://dokumenty.ustavkonstruovani.cz/om202503071>. (Funkční vzorek)

OMASTA, M.; BURK, F.; LOVEČEK, L.; Vysoké učení technické v Brně, Antonínská 548/1, 602 00 Brno, Veverčí, Česká republika DAIDO METAL CZECH s.r.o., Švédské valy 1309/6, 627 00 Brno, Slatina, Česká republika: *Zařízení pro diagnostiku stavu kluzného ložiska*. 39145, Užitný vzor. (2026)

V rámci dalšího vývoje byl také vyvinut funkční vzorek snímače akustické emise pro monitorování stavu kluzného ložiska:

OMASTA, M.; BURK, F.; LOVEČEK, L.: *Snímač akustické emise pro monitorování stavu kluzného ložiska*. (2026) URL:

<https://intranet.ustavkonstruovani.cz/FileDownload/getProjectPdf/509/>. (Funkční vzorek)

## 9 SEZNAM POUŽITÝCH ZDROJŮ

- [1] PRIBÁŇ, Miroslav. *Akustická emise (AE)-teorie a praxe provozních kontrol konstrukcí*. 2012.
- [2] MILLER, R.K. *Nondestructive Testing Handbook - Chapter 10. Acoustic Emission testing* [online]. 2003. Dostupné z: doi:10.1
- [3] CALABRESE, Luigi a Edoardo PROVERBIO. *A Review on the Applications of Acoustic Emission Technique in the Study of Stress Corrosion Cracking* [online]. B.m.: Multidisciplinary Digital Publishing Institute (MDPI). 1. březen 2021. ISSN 26245558. Dostupné z: doi:10.3390/cmd2010001
- [4] NAZARCHUK, Zinoviy, Valentyn SKALSKYI a Oleh SERHIYENKO. *Foundations of Engineering Mechanics Acoustic Emission Methodology and Application* [online]. nedatováno. Dostupné z: <http://www.springer.com/series/3582>
- [5] VETTERLI, Martin., Jelena. KOVAČEVIĆ a Vivek K.. GOYAL. *Foundations of signal processing*. B.m.: Cambridge University Press, 2016. ISBN 110703860X.
- [6] GENG, Zhe, Debashis PUHAN a Tom REDDYHOFF. Using acoustic emission to characterize friction and wear in dry sliding steel contacts. *Tribology International* [online]. 2019, **134**, 394–407. ISSN 0301679X. Dostupné z: doi:10.1016/j.triboint.2019.02.014
- [7] HASE, Alan, Hiroshi MISHINA a Masaki WADA. Correlation between features of acoustic emission signals and mechanical wear mechanisms. *Wear* [online]. 2012, **292–293**, 144–150. ISSN 00431648. Dostupné z: doi:10.1016/j.wear.2012.05.019
- [8] TEODORCZYK, Michał. Influence of Aggregate Gradation on the Longitudinal Wave Velocity Changes in Unloaded Concrete. In: *IOP Conference Series: Materials Science and Engineering* [online]. B.m.: Institute of Physics Publishing, 2017. ISSN 1757899X. Dostupné z: doi:10.1088/1757-899X/245/3/032084
- [9] FENG, Peipei, Pietro BORGHESANI, Wade A. SMITH, Robert B. RANDALL a Zhongxiao PENG. *A Review on the Relationships between Acoustic Emission, Friction and Wear in Mechanical Systems* [online]. 2020 [vid. 2024-03-31]. ISSN 00036900. Dostupné z: doi:10.1115/1.4044799
- [10] TOWSYFYAN, Hossein, Fengshou GU, Andrew D. BALL a Bo LIANG. Modelling acoustic emissions generated by tribological behaviour of mechanical seals for condition monitoring and fault detection. *Tribology International* [online]. 2018, **125**, 46–58. ISSN 0301679X. Dostupné z: doi:10.1016/j.triboint.2018.04.021
- [11] STRABLEGG, Christopher, Philipp RENHART, Florian SUMMER a Florian GRÜN. Methodology, validation & signal processing of acoustic emissions for

- selected lubricated tribological contacts. *Materials Today: Proceedings* [online]. 2022, **62** [vid. 2024-04-02]. ISSN 22147853. Dostupné z: doi:10.1016/j.matpr.2022.04.553
- [12] BONESS, R J, S L MCBRIDE a M SOBCZYK. *Wear studies using acoustic emission techniques*. 1990.
- [13] KÖNIG, F., J. MARHEINEKE, G. JACOBS, C. SOUS, Ming J. ZUO a Zhigang TIAN. Data-driven wear monitoring for sliding bearings using acoustic emission signals and long short-term memory neural networks. *Wear* [online]. 2021, **476**. ISSN 00431648. Dostupné z: doi:10.1016/j.wear.2021.203616
- [14] REVILL, P., A. CLARKE, R. PULLIN a G. DENNIS. Acoustic emission monitoring of wear in aerospace self-lubricating bearing liner materials. *Wear* [online]. 2021, **486–487**. ISSN 00431648. Dostupné z: doi:10.1016/j.wear.2021.204102
- [15] YAHIAOUI, M., F. CHABERT, J. Y. PARIS, V. NASSIET a J. DENAPE. Friction, acoustic emission, and wear mechanisms of a PEKK polymer. *Tribology International* [online]. 2019, **132**, 154–164. ISSN 0301679X. Dostupné z: doi:10.1016/j.triboint.2018.12.020
- [16] DE OLIVEIRA, Mario A., Nelcileo V.S. ARAUJO, Rodolfo N. DA SILVA, Tony I. DA SILVA a Jayantha EPAARACHCHI. Use of Savitzky-Golay filter for performances improvement of SHM systems based on neural networks and distributed PZT sensors. *Sensors (Switzerland)* [online]. 2018, **18**(1). ISSN 14248220. Dostupné z: doi:10.3390/s18010152
- [17] SHABANA, Shabana, Jagadesh Kumar JATAVALLABHULA, Ramaraju Nagarjuna KUMAR, Ravikiran CHINTHALAPUDI a Bridjesh PAPPULA. Towards Intelligent Tribology: Predicting Wear and Friction in WC–Co Coatings with Machine Learning. *Journal of Bio- and Tribo-Corrosion* [online]. 2025, **11**(3). ISSN 21984239. Dostupné z: doi:10.1007/s40735-025-01005-9
- [18] NAKAI, Taketo, Renguo LU, Hiroshi TANI, Shinji KOGANEZAWA a Jinqing WANG. Early-Stage Damage Diagnosis of Rolling Bearings Based on Acoustic Emission Signals Interpreted by Friction Behavior and Machine Learning. *Lubricants* [online]. 2026, **14**(2). ISSN 20754442. Dostupné z: doi:10.3390/lubricants14020095
- [19] YUNITA, Ariana, MHD Iqbal PRATAMA, Muhammad Zaki ALMUZAKKI, Hani RAMADHAN, Emelia Akashah P. AKHIR, Andi Besse FIRDAUSIAH MANSUR a Ahmad Hoirul BASORI. *Performance analysis of neural network architectures for time series forecasting: A comparative study of RNN, LSTM, GRU, and hybrid*

- models* [online]. B.m.: Elsevier B.V. 1. prosinec 2025. ISSN 22150161. Dostupné z: doi:10.1016/j.mex.2025.103462
- [20] POLIAK, Milos, Lukasz PAWLIK a Damian FREJ. Explainable Deep Learning for Bearing Fault Diagnosis: Architectural Superiority of ResNet-1D Validated by SHAP. *Electronics (Switzerland)* [online]. 2025, **14**(24). ISSN 20799292. Dostupné z: doi:10.3390/electronics14244875
- [21] FU, Guanghua, Qingjuan WEI a Yongsheng YANG. Bearing fault diagnosis with parallel CNN and LSTM. *Mathematical Biosciences and Engineering* [online]. 2024, **21**(2), 2385–2406. ISSN 15510018. Dostupné z: doi:10.3934/mbe.2024105
- [22] BRIGATO, Lorenzo a Luca IOCCHI. *A Close Look at Deep Learning with Small Data*. nedatováno.
- [23] ZENG, Zhen, Rachneet KAUR, Suchetha SIDDAGANGAPPA, Tucker BALCH a Manuela VELOSO. From Pixels to Predictions: Spectrogram and Vision Transformer for Better Time Series Forecasting. In: *ICAIF 2023 - 4th ACM International Conference on AI in Finance* [online]. B.m.: Association for Computing Machinery, Inc, 2023, s. 82–90. ISBN 9798400702402. Dostupné z: doi:10.1145/3604237.3626905
- [24] ORHAN, Ahmet, Nikolay YORDANOV, Merve ERTARĞIN, Marin ZHILEVSKI a Mikho MIKHOV. A Comparative Study of Time–Frequency Representations for Bearing and Rotating Fault Diagnosis Using Vision Transformer. *Machines* [online]. 2025, **13**(8). ISSN 20751702. Dostupné z: doi:10.3390/machines13080737
- [25] BERGMANN, Philipp, Florian GRÜN, Florian SUMMER, István GÓDOR a Gabriel STADLER. Expansion of the metrological visualization capability by the implementation of acoustic emission analysis. *Advances in Tribology* [online]. 2017, **2017**. ISSN 16875923. Dostupné z: doi:10.1155/2017/3718924
- [26] STRABLEGG, Christopher, Florian SUMMER, Philipp RENHART, Michael PUSTERHOFER a Florian GRÜN. In-depth study of direct and derived acoustic emission parameters and their information content for classifying lubricated tribological sliding contacts. *Tribology International* [online]. 2023, **190**, 109028. ISSN 0301-679X. Dostupné z: doi:https://doi.org/10.1016/j.triboint.2023.109028
- [27] HANCHI, J a B E KLAMECKI. *Acoustic emission monitoring of the wear process*. 1991.
- [28] BENABDALLAH, H. S. a D. A. AGUILAR. Acoustic emission and its relationship with friction and wear for sliding contact. *Tribology Transactions* [online]. 2008, **51**(6), 738–747. ISSN 10402004. Dostupné z: doi:10.1080/10402000802044324
- [29] LI, Huiqin, Zhengxin ZHANG, Tianmei LI a Xiaosheng SI. A review on physics-informed data-driven remaining useful life prediction: Challenges and opportunities.

- Mechanical Systems and Signal Processing* [online]. 2024, **209**. ISSN 10961216. Dostupné z: doi:10.1016/j.ymssp.2024.111120
- [30] KÖNIG, F., G. JACOBS, A. STRATMANN a D. CORNEL. Fault detection for sliding bearings using acoustic emission signals and machine learning methods. *IOP Conference Series: Materials Science and Engineering* [online]. 2021, **1097**(1), 012013. ISSN 1757-8981. Dostupné z: doi:10.1088/1757-899x/1097/1/012013
- [31] CHAO, Qun, Yong HU a Chengliang LIU. Physics informed neural networks for detecting the wear of friction pairs in axial piston pumps. *Reliability Engineering and System Safety* [online]. 2025, **261**. ISSN 09518320. Dostupné z: doi:10.1016/j.ress.2025.111144
- [32] *SCHAEFFLER CZ. GE20-AW Spherical plain bearing* [online]. Praha: Schaeffler CZ, ©2026 [cit. 2026-05-16]. *Schaeffler medias* [online]. 2026 [vid. 2026-05-16]. Dostupné z: <https://medias.schaeffler.cz/cs/product/rotary/valiva-a-kluzna-loziska/kluzna-loziska/kloubova-loziska/kloubova-loziska%2C-bezudržbova/ge20-aw-a/p/347618>
- [33] *Elgoglide ® Maintenance-Free High Performance Plain Bearings. Technical Product Information TPI 102*. Steinhagen: Helmut ELGES GmbH, 2000. [online]. nedatováno [vid. 2026-05-14]. Dostupné z: [https://www.schaeffler.com > tpi > tpi102\\_de\\_us](https://www.schaeffler.com > tpi > tpi102_de_us)

# 10 SEZNAM POUŽITÝCH ZKRATEK, SYMBOLŮ A VELIČIN

## 10.1 Seznam použitých zkratk

|      |                                   |
|------|-----------------------------------|
| AE   | Akustická Emise                   |
| CAD  | Computer-Aided Design             |
| CMM  | Coordinate Measuring Machine      |
| CNN  | Convolutional Neural Network      |
| CWT  | Continuous Wavelet Transform      |
| FCNN | Fully Connected Neural Network    |
| FSI  | Fakulta strojního inženýrství     |
| GRU  | Gated Recurrent Unit              |
| LSTM | Long Short-Term Memory            |
| M2M  | Many-to-Many                      |
| MAE  | Mean Absolute Error               |
| MLP  | Multi-Layer Perceptron            |
| MSE  | Mean Squared Error                |
| NDT  | Non-Destructive Testing           |
| NI   | National Instruments              |
| PEKK | Polyether Ketone Ketone           |
| PHM  | Prognostics and Health Management |
| PLB  | Pencil Lead Break                 |
| PTFE | Polytetrafluoroethylene           |
| RMS  | Root Mean Square                  |
| RMSE | Root Mean Squared Error           |
| RNN  | Recurrent Neural Network          |



|      |                                     |
|------|-------------------------------------|
| RUL  | Remaining Useful Life               |
| SHAP | Shapley Additive Explanations       |
| SHM  | Structural Health Monitoring        |
| STFT | Short-Time Fourier Transform        |
| TDMS | Technical Data Management Streaming |
| USB  | Universal Serial Bus                |
| VUT  | Vysoké učení technické v Brně       |

## 10.2 Seznam použitých symbolů

|           |                                          |
|-----------|------------------------------------------|
| $A$       | amplituda AE signálu [V; dB]             |
| $A_0$     | počáteční amplituda AE signálu [V; dB]   |
| $\alpha$  | koeficient útlumu elastické vlny [dB/mm] |
| $c$       | rychlost šíření elastické vlny [m/s]     |
| $C_0$     | statická únosnost ložiska [N]            |
| $d_p$     | průměr kuličky [mm]                      |
| $E$       | Youngová modul pružnosti [GPa]           |
| $E_{ae}$  | absolutní energie AE signálu [aJ]        |
| $f$       | frekvence [Hz]                           |
| $f_{max}$ | maximální frekvence [Hz]                 |
| $F_a$     | axiální síla [N]                         |
| $F_k$     | kontaktní síla na kuličku [N]            |
| $F_t$     | třecí síla [N]                           |
| $h_t$     | skryty stav rekurentní vrstvy [-]        |
| $k$       | kurtóza (špičatost) [-]                  |
| $L$       | délka šíření vlny [m]                    |
| $\mu$     | koeficient tření [-]                     |

|           |                                         |
|-----------|-----------------------------------------|
| $\nu$     | Poissonovo číslo [-]                    |
| $R_2$     | koeficient determinace [-]              |
| $\rho$    | hustota materiálu [kg/m <sup>3</sup> ]  |
| $t$       | tloušťka kluzné vrstvy [mm]             |
| $T_s$     | perioda vzorkování [us]                 |
| $V_{RMS}$ | efektivní hodnota napětí signálu AE [V] |
| $Z$       | akustická impedance [MRayl]             |

### 10.3 Seznam použitých veličin

|           |                                              |
|-----------|----------------------------------------------|
| $t$       | zbývající tloušťka kluzného povlaku [mm]     |
| $F_a$     | axiální síla (vstupní provozní parametr) [N] |
| $F_t$     | třecí síla [N]                               |
| $T_c$     | teplota kontaktu [°C]                        |
| $\mu$     | koeficient tření [-]                         |
| $V_{RMS}$ | efektivní hodnota (RMS) signálu AE [V]       |
| $E_{ae}$  | absolutní energie AE signálu [aJ]            |
| $\alpha$  | koeficient útlumu AE signálu [dB/mm]         |
| $Z$       | akustická impedance materiálu [MRayl]        |
| $f$       | vzorkovací / analyzovaná frekvence [Hz]      |
| $R^2$     | koeficient determinace modelu [-]            |
| MAE       | střední absolutní chyba predikce [mm]        |
| RMSE      | odmocnina ze střední kvadratické chyby       |

# 11 SEZNAM OBRÁZKŮ A GRAFŮ

|                                                                                                                                                                                                                                                                                                                                                                                                                        |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Obr. 2-1: Rešeršní struktura diplomové práce.....                                                                                                                                                                                                                                                                                                                                                                      | 22 |
| Obr. 2-2: Nárazová akustická emise s popisem [3].....                                                                                                                                                                                                                                                                                                                                                                  | 24 |
| Obr. 2-3: Kaiserův efekt [4] .....                                                                                                                                                                                                                                                                                                                                                                                     | 26 |
| Obr. 2-4: vlevo) Schématické šíření longitudinálních vln; vpravo) Schématické šíření transversálních vln, a) Horizontálně polarizovaná vlna, b) Vertikálně polarizovaná vlna [4] .....                                                                                                                                                                                                                                 | 27 |
| Obr. 2-5: Hsu-Nielsen AE zdroj [8] .....                                                                                                                                                                                                                                                                                                                                                                               | 31 |
| Obr. 2-6: Korelační mapa frekvenčních spekter AE pro jevy zahrnující deformaci a lom [7] .....                                                                                                                                                                                                                                                                                                                         | 35 |
| Obr. 2-7: Schéma architektury MLP (dopředná vícevrstvá síť): vstupní vrstva → skryté vrstvy [256, 128, 64] → výstupní neuron.....                                                                                                                                                                                                                                                                                      | 39 |
| Obr. 2-8: Schéma architektury RNN: rozvinutá rekurentní buňka se skrytým stavem $h_t$ .....                                                                                                                                                                                                                                                                                                                            | 40 |
| Obr. 2-9: Schéma architektury LSTM: buňka s paměťovým stavem $C_t$ a třemi branami (vstupní, zapomínací, výstupní), .....                                                                                                                                                                                                                                                                                              | 40 |
| Obr. 2-10: Schéma architektury GRU: zjednodušená buňka s resetovací a aktualizací branou .....                                                                                                                                                                                                                                                                                                                         | 41 |
| Obr. 2-11: Schéma hybridní architektury CNN-GRU: paralelní větve konvoluční extrakce příznaků a rekurentního zpracování, sloučené před výstupní vrstvou. ....                                                                                                                                                                                                                                                          | 41 |
| Obr. 2-12: Původní stav modulárního rotačního tribometru s axiálním zatěžováním.....                                                                                                                                                                                                                                                                                                                                   | 44 |
| Obr. 4-1: Přehledové schéma metodiky diplomové práce: dvě paralelní metodické větve (H1 – predikce opotřebení pomocí ANN; H2 – charakterizace útlumu AE) s mapováním na kapitoly diskuze.....                                                                                                                                                                                                                          | 48 |
| Obr. 4-2: Dokumentace sférického testovaného vzorku [32] .....                                                                                                                                                                                                                                                                                                                                                         | 51 |
| Obr. 4-3: Náhled do kontaktu kuliček se sférickým ložiskem a rozkladem kontaktních sil pro jednu kuličku $D_k = 19,05 \text{ mm}$ , $\alpha = 41,4^\circ$ se schématem rozkladu sil pro jednu kuličku.....                                                                                                                                                                                                             | 52 |
| Obr. 4-4: Aplikační oblast pro kompozitní kluznou vrstvu [33] .....                                                                                                                                                                                                                                                                                                                                                    | 54 |
| Obr. 4-5: vlevo) Zeleně zvýrazněná část, která byla navržena v rámci této DP, vpravo) Modulární rotační tribometr s axiálním zatěžováním s testovací konfigurací. 1.Horní držák kuliček, 2.Domek pro uložení vzorku a upevnění senzorů, 3.Spodní část konfigurace – vedení zatěžovacího členu se senzorem, 4.Řemenový převod vedený od Elektromotoru, 5.Rotor tribometru, 6.Snímač třecí síly, 7.Zatěžovací člen ..... | 55 |

|                                                                                                                                                                                                                                                                                                                                                                                                             |    |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Obr. 4-6: Střední oblast konfigurace. 1.Miska s kuličkami, 2.Vzorek-Sférické kluzné ložisko, 3.Domek pro uložení vzorku a senzorů, 4.Píst lineárního vedení, 5.Senzor axiální síly, 6.Pneumatický píst, 7.Senzor snímání třecí síly, 8.Rameno pro přenos třecí síly, 9.Vnější vedení, 10. Lisované lineární vedení, 11.Zátěžná pružina s vodícím dílem, 12. Stavitelná upínací deska, 13. Horní upínka..... | 56 |
| Obr. 4-7: Vlevo) Implementovaná konstrukce spodní části konfigurace, Vpravo) CAD model sestavy spodní části konfigurace s popisky .....                                                                                                                                                                                                                                                                     | 58 |
| Obr. 4-8: Domek pro uložení testovaného vzorku s popisem částí a součástí .....                                                                                                                                                                                                                                                                                                                             | 58 |
| Obr. 4-9: Vlevo) CAD návrh předpínací sestavy senzoru AE, Vpravo) Funkční model předpínací sestavy AE .....                                                                                                                                                                                                                                                                                                 | 59 |
| Obr. 4-10: Vlevo) Miska s kuličkami, Uprostřed) Horní část konfigurace, Vpravo) CAD model horní části konfigurace.....                                                                                                                                                                                                                                                                                      | 60 |
| Obr. 4-11: Ohybový snímač pro měření třecí síly s upínacím držákem .....                                                                                                                                                                                                                                                                                                                                    | 61 |
| Obr. 4-12: CAD model upnutí elektromotoru s řemenovým převodem.....                                                                                                                                                                                                                                                                                                                                         | 62 |
| Obr. 4-13: Upravená konfigurace pro ověření vlivu tloušťky vrstvy na prostupnost signálu AE.....                                                                                                                                                                                                                                                                                                            | 63 |
| Obr. 4-14: Ložisko GE20-AW s vyznačenými rovinami měření na CMM .....                                                                                                                                                                                                                                                                                                                                       | 65 |
| Obr. 4-15: Mikrotužka s přípravkem pro správné provedení testu studujícího vnitřní útlum na konformní konfiguraci.....                                                                                                                                                                                                                                                                                      | 75 |
| Obr. 4-16: Hit v časové doméně (nahore: surový signál, dole: filtrovaný signál bandpass filtrem 50-490 kHz).....                                                                                                                                                                                                                                                                                            | 77 |
| Obr. 4-17: Hit AE v časově-frekvenční doméně .....                                                                                                                                                                                                                                                                                                                                                          | 77 |
| Obr. 4-18: Mikrotužka s přípravkem pro správné provedení testu studujícího vnitřní útlum na 4-ball konfiguraci .....                                                                                                                                                                                                                                                                                        | 78 |
| Obr. 5-1: Predikce zbývající tloušťky povlaku v závislosti na segmentech pro jednotlivé testovací vzorky (1 segment = 1 minuta). – model MLP. ....                                                                                                                                                                                                                                                          | 81 |
| Obr. 5-2: Evaluační grafy predikce opotřebení pro model MLP – testovací množina. ....                                                                                                                                                                                                                                                                                                                       | 82 |
| Obr. 5-3: Evaluační grafy predikce opotřebení pro model MLP – trénovací množina.....                                                                                                                                                                                                                                                                                                                        | 82 |
| Obr. 5-4: Predikce zbývající tloušťky povlaku v závislosti na segmentech pro jednotlivé testovací vzorky (1 segment = 1 minuta).– model RNN.....                                                                                                                                                                                                                                                            | 84 |
| Obr. 5-5: Evaluační grafy predikce opotřebení pro model RNN (Many-to-Many) – testovací množina. ....                                                                                                                                                                                                                                                                                                        | 84 |
| Obr. 5-6: Evaluační grafy predikce opotřebení pro model RNN (Many-to-Many) – trénovací množina. ....                                                                                                                                                                                                                                                                                                        | 85 |

|                                                                                                                                                                                                         |     |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Obr. 5-7: Predikce zbývající tloušťky povlaku v závislosti na segmentech pro jednotlivé testovací vzorky (1 segment = 1 minuta). – model LSTM.....                                                      | 86  |
| Obr. 5-8: Evaluační grafy predikce opotřebení pro model LSTM – testovací množina. ...                                                                                                                   | 87  |
| Obr. 5-9: Evaluační grafy predikce opotřebení pro model LSTM – trénovací množina. ..                                                                                                                    | 88  |
| Obr. 5-10: Predikce zbývající tloušťky povlaku v závislosti na segmentech pro jednotlivé testované vzorky (1 segment = 1 minuta) – model GRU.....                                                       | 89  |
| Obr. 5-11: Evaluační grafy predikce opotřebení pro model GRU – testovací množina. ...                                                                                                                   | 90  |
| Obr. 5-12: Evaluační grafy predikce opotřebení pro model GRU – trénovací množina....                                                                                                                    | 90  |
| Obr. 5-13: Predikce zbývající tloušťky povlaku v závislosti na segmentech pro jednotlivé testovací vzorky (1 segment = 1 minuta) – model CNN-GRU.....                                                   | 92  |
| Obr. 5-14: Evaluační grafy predikce opotřebení pro model CNN-GRU – testovací množina. ....                                                                                                              | 92  |
| Obr. 5-15: Evaluační grafy predikce opotřebení pro model CNN-GRU – trénovací množina. ....                                                                                                              | 93  |
| Obr. 5-16: Charakteristika špičkové amplitudy na základě tloušťky povlaku .....                                                                                                                         | 94  |
| Obr. 5-17: Charakteristika energie hitu nad prahem v závislosti na tloušťce povlaku .....                                                                                                               | 94  |
| Obr. 5-18: Charakteristika RMS v závislosti na tloušťce povlaku 75 $\mu s$ po překročení prahové hodnoty .....                                                                                          | 95  |
| Obr. 5-19: Charakteristika špičkatosti (kurtosis) vůči tloušťce povlaku.....                                                                                                                            | 96  |
| Obr. 5-20: Charakteristika délky AE hitu vůči tloušťce povlaku.....                                                                                                                                     | 96  |
| Obr. 5-21: Porovnání charakteristik špičkové amplitudy na základě tloušťky povlaku pro konformní a 4-ball konfiguraci při aplikaci testu studujícího vnitřní útlum .....                                | 98  |
| Obr. 5-22: Porovnání charakteristik energie hitu nad prahem v závislosti na tloušťce povlaku pro konformní a 4-ball konfiguraci při aplikaci testu studujícího vnitřní útlum .....                      | 98  |
| Obr. 5-23: Porovnání charakteristik RMS v závislosti na tloušťce povlaku 75 $\mu s$ po překročení prahové hodnoty pro konformní a 4-ball konfiguraci při aplikaci testu studujícího vnitřní útlum ..... | 99  |
| Obr. 5-24: Porovnání špičkatosti (Kurtosis) vůči tloušťce povlaku pro konformní a 4-ball konfiguraci při aplikaci testu studujícího vnitřní útlum.....                                                  | 100 |
| Obr. 5-25: Porovnání charakteristik délky AE hitu vůči tloušťce povlaku pro konformní a 4-ball konfiguraci při aplikaci testu studujícího vnitřní útlum .....                                           | 100 |
| Obr. 6-1: SHAP analýza pro architekturu GRU .....                                                                                                                                                       | 101 |

## 12 SEZNAM TABULEK

|                                                                                                                  |     |
|------------------------------------------------------------------------------------------------------------------|-----|
| Tab. 4-1: Specifikace ložiska GE20-AW .....                                                                      | 51  |
| Tab. 4-2: Finální hyperparametry modelů po Bayesovské optimalizaci (Optuna) .....                                | 74  |
| Tab. 4-3: Připravené vzorky s upravenou tloušťkou kluzného povlaku pro testování míry<br>útlumu .....            | 75  |
| Tab. 5-1: Hodnoty evaluačních metrik pro model MLP .....                                                         | 81  |
| Tab. 5-2: Hodnoty evaluačních metrik pro model RNN M2M .....                                                     | 83  |
| Tab. 5-3: Hodnoty evaluačních metrik pro model LSTM .....                                                        | 86  |
| Tab. 5-4: Hodnoty evaluačních metrik pro model GRU .....                                                         | 88  |
| Tab. 5-5: Hodnoty evaluačních metrik pro hybridní model CNN-GRU .....                                            | 91  |
| Tab. 6-1: Souhrnné srovnání evaluačních metrik a hyperparametrů testovaných architektur<br>neuronových sítí..... | 103 |

## 13 SEZNAM PŘÍLOH

Příloha 1 - 01\_calculate\_wear.py

Příloha 2 - Long\_Segment\_test\_ALL\_logging-Final.py

Příloha 3 - TDMS\_TO\_HDF5\_time\_freq\_crop.py

Příloha 4 - HDF5\_data\_statistics+plot-MULTIPLE-update\_17.2.2026.py

Příloha 5 - 02\_merge\_all.py

Příloha 6 - compute\_spectrograms.py

Příloha 7 - AE\_continuous\_event\_test.py

Příloha 8 - AE\_evaluate.py

Příloha 9 - AE\_parametry.py

Příloha 10 - AE\_grafy\_tloušťka.py

Příloha 11 - mlp\_pipeline\_v2.py

Příloha 12 - rnn\_pipeline\_v2.py

Příloha 13 - LSTM\_pipeline\_v2.py

Příloha 14 - GRU\_pipeline\_v2-GRU.py

Příloha 15 - GRU\_pipeline\_v3-GRU-CNN.py

Příloha 16 - DATA/

Příloha 17 - CMM\_DATA/

Příloha 18 – Korelační matice/