



**FAKULTA
ŠTROJNÍ
ČVUT V PRAZE**

Ústav mechaniky, biomechaniky a mechatroniky

**Analýza klepání motoru ze zvukového
záznamu**

**Engine knocking analysis based on sound
recording**

DIPLOMOVÁ PRÁCE

2024

Lukáš SPILKA

Studijní program: N0714A270002 – Aplikované vědy ve strojním inženýrství

Studijní obor: Mechatronika

Vedoucí práce: doc. Ing. Ivo Bukovský, Ph.D.



ZADÁNÍ DIPLOMOVÉ PRÁCE

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Spilka** Jméno: **Lukáš** Osobní číslo: **473449**
Fakulta/ústav: **Fakulta strojní**
Zadávající katedra/ústav: **Ústav mechaniky, biomechaniky a mechatroniky**
Studijní program: **Aplikované vědy ve strojním inženýrství**
Specializace: **Mechatronika**

II. ÚDAJE K DIPLOMOVÉ PRÁCI

Název diplomové práce:

Analýza klepání motoru ze zvukového záznamu

Název diplomové práce anglicky:

Engine knocking analysis based on sound recording

Pokyny pro vypracování:

Navrhněte a otestujte metodu detekce klepání vznětového motoru, pracujícího na duální provoz za využití a zpracování zvukového signálu.
Řešení se může skládat z kombinace metod a postupů vedoucích k řešení.
Prozkoumejte literaturu a studie zabývající se metodami detekce klepání. Zrevidujte teoretické znalosti o tom, jak zvukové signály vznikají v motoru a jak jsou ovlivněny klepáním.
Definujte testovací scénáře, které pokryjí různé provozní stavy motoru, včetně různých poměrů směsi paliv.
Navrhněte metody pro extrakci charakteristických vlastností ze zvukových signálů, které mohou indikovat přítomnost klepání, např. změny ve frekvenčním spektru, amplitudě, nebo v časové doméně.
Navrhněte algoritmy (konvenční či se strojovým učením) pro klasifikaci zvukových signálů a detekci klepání. Použijte vhodné trénovací a validační datové sady pro experimenty a ověření metody.
Vyberte vhodné opensource programovací jazyky a knihovny (např. Python s knihovnami jako NumPy, SciPy, scikit-learn, TensorFlow, PyTorch) pro vývoj softwarových modulů.
Naprogramujte SW moduly pro filtraci, normalizaci a odstranění šumu ze zaznamenaných zvukových signálů; pro předzpracování signálů, extrakci vlastností, a klasifikaci/detekci klepání. Zajistěte modulární a rozšiřitelný design.
Otestujte vyvinuté SW moduly na reálných zvukových datech získaných z experimentů. Shrňte a porovnejte výsledky metod a náležitě zdokumentujte .

Seznam doporučené literatury:

- [1] HEYWOOD, John B. Internal combustion engine fundamentals. New York: McGraw-Hill, 1988. McGraw-Hill series in mechanical engineering. ISBN 978-0-07-028637-5.
- [2] SMITH, Steven W. The scientist and engineer's guide to digital signal processing. 1st ed. San Diego, Calif: California Technical Pub, 1997. ISBN 978-0-9660176-3-2.
- [3] BUKOVSKY, Ivo, Gejza DOHNAL, Peter M. BENES, Kei ICHIJI a Noriyasu HOMMA. Letter on Convergence of In-Parameter-Linear Nonlinear Neural Architectures With Gradient Learnings. IEEE Transactions on Neural Networks and Learning Systems [online]. 2023, 34(8), 5189–5192. ISSN 2162-237X, 2162-2388.

Jméno a pracoviště vedoucí(ho) diplomové práce:

doc. Ing. Ivo Bukovský, Ph.D. U12110.3

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) diplomové práce:

Datum zadání diplomové práce: **13.02.2024** Termín odevzdání diplomové práce: **16.02.2024**

Platnost zadání diplomové práce: _____

doc. Ing. Ivo Bukovský, Ph.D.
podpis vedoucí(ho) práce

prof. Ing. Michael Valášek, DrSc.
podpis vedoucí(ho) ústavu/katedry

doc. Ing. Miroslav Španiel, CSc.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Diplomant bere na vědomí, že je povinen vypracovat diplomovou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v diplomové práci.

_____ Datum převzetí zadání

_____ Podpis studenta



PROHLÁŠENÍ

Prohlašuji, že jsem diplomovou práci vypracoval samostatně a pouze za použití podkladů uvedených v seznamu literatury.

V Praze, dne:

.....

Spilka Lukáš



PODĚKOVÁNÍ

Tímto bych rád poděkoval mé rodině za podporu při celém studiu a panu doc. Ing. Ivo Bukovskému, Ph.D. za velmi cenné rady, trpělivost a vedení diplomové práce.

ANOTAČNÍ LIST

Jméno autora:	Lukáš Spilka
Název Práce:	Analýza klepání motoru ze zvukového záznamu
Rok zpracování:	2024
Ústav:	Ústav mechaniky, biomechaniky a mechatroniky
Odbor:	Odbor mechaniky a mechatroniky
Vedoucí DP:	doc. Ing Ivo Bukovský, Ph.D.
Klíčová slova:	Klepání motoru, zpracování signálu, analýza hlavních komponent
Key words:	Engine knocking, signal processing, principal components analysis
Abstrakt:	Práce je zaměřena na řešení problematiky detekce klepání motoru pracujícího v duálním provozu za využití a zpracování zvukového signálu získaného z motoru.
Abstract:	The focus of the thesis is analysis of knocking detection of the engine that operates on dual fuel, using signal processing of the sound signal recorded on the engine.

OBSAH

1. Úvod	12
2. Klepání motoru.....	13
2.1. Metody detekce klepání.....	14
2.1.1. Přímé metody měření klepání.....	14
2.1.2. Analýza vibrací motorového bloku.....	15
2.1.3. Analýza teplot výfukového plynu	15
2.2. Frekvence klepání.....	15
2.3. Metriky měření klepání	17
2.3.1. Metriky KI v časové oblasti.....	17
2.3.2. Metriky KI ve Frekvenční oblasti	19
2.3.3. Metriky KO.....	19
3. Teorie.....	20
3.1. Fourierova transformace, FFT a DFT	20
3.2. PCA	20
3.3. SVD	22
3.4. Polární rozklad.....	23
3.5. Filtry.....	23
3.5.1. Butterwothův filtr.....	24
3.5.2. Chebyshevův filtr.....	25
3.6. ARIMA.....	27
3.7. LNU	27
4. Formulace úloh.....	29
4.1. Předpoklady systému	29
4.2. Lokalizace pálení motoru	30
4.3. Detekce a vyhodnocení klepání	31
5. Příprava a klasifikace vzorků	32
6. Lokalizace pálení.....	33
6.1. Teorie a navržený postup.....	33
6.2. Limitace	36
6.3. Nepoužité metody.....	36
6.3.1. Butterworthův filtr	36
6.3.2. Chebyshevův filtr.....	38
6.3.3. LNU	41
7. Rozlišení klepání	44
7.1. Metodika a testovací signály.....	44
7.2. MEL Spektrogram	45
7.3. PCA	47
7.4. SVD	49
7.5. Diskuze vyhodnocení klepání	52
7.6. Lokalizace anomálie pomocí LNU.....	54
8. Návrh predikce a rekonstrukce signálu	57

9. Navržený algoritmus.....	62
10. Vyhodnocení.....	65
11. Závěr.....	69
12. Zdroje	70

SEZNAM OBRÁZKŮ

Obrázek 1 – Porovnání neklepajícího (1) a klepajícího (2) provozu [2]	14
Obrázek 2 – Popis módů klepajících frekvencí [8]	16
Obrázek 3 – Doba přítomnosti klepající frekvence [8]	17
Obrázek 4 – Možné signály pro identifikaci klepání [6]	17
Obrázek 5– Hlavní komponenty dvou atributů	22
Obrázek 6 – Singulární rozklad [14]	23
Obrázek 7 – Ukázka získaného signálu	29
Obrázek 8 – Spektrogram neklepajícího signálu válce	31
Obrázek 9 – Spektrogram klepajícího signálu válce s vyznačeným klepáním.....	31
Obrázek 10 – Rekonstrukce Sinusového signálu se Zarušením	34
Obrázek 11 – Rekonstrukce signálu z motoru	35
Obrázek 12 – Porovnání a rozdíl filtrovaných signálů Butterworth – Chebyshev	41
Obrázek 13 – Aplikace LNU na kombinaci signálů (1) a (5).....	42
Obrázek 14 – Aplikace LNU na signál (1)	43
Obrázek 15 – Ilustrace výběru vyhodnocovaného signálu	45
Obrázek 16 – Spektrogram záznamu se silným klepáním, neupravený signál (6)	46
Obrázek 17 – Spektrogram záznamu bez klepání, upravený signál (8)	46
Obrázek 18 – Spektrogram záznamu s lehkým klepáním, upravený signál (7).....	47
Obrázek 19 – Spektrogram záznamu se silným klepáním, upravený signál (6)	47
Obrázek 20– PCA neklepajícího signálu	48
Obrázek 21 – PCA lehce klepajícího signálu	48
Obrázek 22 – PCA klepajícího signálu	49
Obrázek 23 – Porovnání SVD a zkráceného SVD [14]	50
Obrázek 24 - FFT neklepajícího signálu.....	54
Obrázek 25 – FFT klepajícího signálu	54
Obrázek 26 – Postup učení neuronu	55
Obrázek 27 - Detekce anomálie v klepajícím signálu.....	56
Obrázek 28 – Výstřižek konzole, určení nestacionarity	58
Obrázek 29 – Rekonstrukce jednoduchého signálu.....	61
Obrázek 30 – Moduly v navrženém algoritmu	62
Obrázek 31 – Diagram aktivit	64
Obrázek 32 – Počátek pálení signálu Test1 pomocí FFT Filtru	65
Obrázek 33 – Popis počátku a délky pálení	65
Obrázek 34 - Originální signál a vybraná část	66
Obrázek 35 - Spektrogram vybrané části.....	66
Obrázek 36 - PCA výstup signálu Test1.....	67
Obrázek 37 – SVD Výstup signálu Test1	67

SEZNAM GRAFŮ

Graf 1 – Přechodová charakteristika Butterworthova filtru s pásmovou propustí	25
Graf 2 – Ilustrace změny v šumu u Chebysheva filtru [18]	26
Graf 3 – Přechodová charakteristika Chebysheva filtru s pásmovou propustí	26
Graf 4 – porovnání originálního signálu a filtrovaného signálu pomocí Butterworthova filtru	37
Graf 5– Filtrovaný signál pomocí Butterworthova filtru	38

Graf 6 – porovnání originálního signálu a filtrovaného signálu pomocí Chebysheva filtru	39
Graf 7 – Filtrovaný signál pomocí Chebysheva filtru	40
Graf 8 – Korelační diagram SVD neklepajícího signálu	51
Graf 9 – Korelační diagram SVD lehce klepajícího signálu	51
Graf 10 – Korelační diagram SVD neklepajícího signálu	51
Graf 11– PCA s hranicemi	53
Graf 12 – SVD s hranicemi	53
Graf 13 – Závislost vybraných frekvencí na % plynu ve směsi	57
Graf 14 – Interpolovaná data pro frekvenci 3600 Hz	58
Graf 15 – Autokorelace předchozích 10 vzorků.....	59
Graf 16 – Částečná korelace předchozích 10 vzorků	59
Graf 17 – Předpověď ARIMA (2, 1, 3)	60

SEZNAM TABULEK

Tabulka 1 – použité vzorky	32
Tabulka 2 – Hodnoty Hlavních komponent v různých konfiguracích	53
Tabulka 3 – Vyhodnocení testovaných dat.....	67

SEZNAM POUŽITÝCH VELIČIN

a	průměr vrtání
A	matice
A	amplituda
B	zpětný operátor (Lag operátor, Backshift)
c_{∞}	rychlost zvuku v neporušeném plynu
col \mathbf{x}	sloupcový vektor \mathbf{x}
Cov(\mathbf{X})	kovarianční matice \mathbf{X}
d	řád diferenciace
e	chyba
f	frekvence
f	frekvence klepání
f(s)	Fourierova transformace
f(t)	funkce v závislosti na čase
F_0	frekvence
F_i	frekvence
H	pozitivní semidefinitní matice
H0	koeficient zesílení (passband gain)
H2(s)	přenosová funkce filtru 2. řádu
hop_length	počet vzorků mezi po sobě jdoucími snímky použití knihovny librosa()
i	index
I	jednotková matice
i, j	imaginární jednotka
J	kritérium pro minimalizaci
kl, kr	koeficienty pro návrh Chebysheva filtru
M	matice
N	index
n	řád filtru
n_components	počet hlavních komponent
n_fft	délka okna FFT při použití knihovny librosa()
n_válce	počet válců
p	řád modelu autogrese
P	tlak
p_filt	filtrovaná hodnota tlaku
Q	uvolněné teplo
q	řád modelu klouzavého průměru
R	šířka rušícího pásma
R_db	šířka rušícího pásma šumu (ripple)
s	komplexní proměnná z Laplaceovy transformace
Sxx	hustota výkonového spektra
t	čas
T(s)	Přenosová funkce Chebysheva filtru
T_i	Chebyshevův polynom i-tého stupně
t_pálení	doba pálení
U	Unitární čtvercová matice



U	unitární matice
U	zkrácené matice U
V	objem
V	vektor vlastních čísel kovarianční matice Cov(X)
V	Unitární čtvercová matice
V	matice
V	zkrácená matice V
w	vektor váhových koeficientů
W	unitární matice
w_i	i-tý váhový koeficient
win_length	délka okna zpracovávaného vzorku při použití knihovny librosa()
x	vektor vstupních hodnot
x	poloha
X	vektor, matice
x_i	i-tý bod vstupního vektoru
y_m	výstupní hodnota LNU
Zi	Standardizované skóre (z-score)
$\Delta\rho$	porucha hustoty
$\alpha_{m,n}$	koeficienty kmitacího módu
ε	koeficient výpočtu A
θ	úhel klikového hřídele
θ_i	koeficienty autoregrese
γ	Poissonovo číslo
ξ	koeficient tlumení
μ	průměrná odchylka
μ_k	parametr rychlosti učení
ω	úhlová frekvence
ω_n	úhlová frekvence
Σ_i	směrodatná odchylka
Σ	matice
$\bar{\Sigma}$	zkrácená matice suma
Θ	úhel klikové hřídel
θ_i	koeficienty klouzavého průměru

SEZNAM POUŽITÝCH ZKRATEK

°KH	stupně klikového hřídele
AEFD	average energy of frequency dissipated
AEHRO	average energy of heat released oscillations
AEPO	average energy of pressure oscillations
ARIMA	model autoregresního integrovaného klouzavého průměru
ATDC	after top dead center
BTDC	before top dead center
DFT	discrete Fourier transformation
FFT	fast Fourier transform
FT	Fourierova transformace
HONU	high order neural unit
KI	knock intensity
KO	knock onsets
LNU	linear neural unit
MAHRO	maximum amplitude of heat released oscillations
MAPO	maximum amplitude of pressure oscillations
PCA	principle components analysis
SEHRO	signal energy of heat released oscillations
SEPO	signal energy of pressure oscillations
SER	signal energy ration
STFT	short time fourier transform
SVD	single value decomposition
TDC	top dead center
TVE	treshold value exceeded

1. Úvod

Na produkci emisí skleníkových plynů se největší měrou z hlediska sektoru podílejí výroba elektřiny a tepla, doprava, průmyslová výroba a stavebnictví a zemědělství, v tomto pořadí, uvádí zdroj [1]. Přestože přesné množství emisí způsobených spalovacími motory, zejména pak těmi naftovými, je obtížné stanovit, nacházejí tyto motory využití ve všech uvedených odvětvích. Současný trend vývoje spalovacích motorů je zřejmý a logicky cílí na snižování emisí. Jednou z cest, jak dosáhnout snížení emisí vznětových motorů je změna chemického složení paliva, v tomto případě, však není o řeč o syntetických palivech. Řeč je o duálním provozu motoru, tedy substituci části nafty za zemní plyn, případně za plyny s vyššími uhlovodíky. Se změnou složení paliva na duální, však vyvstává několik otázek, na straně bezpečného a bezporuchového provozu, které je nutné vyřešit.

Naftové motory s duálním palivem jsou limitovány více faktory. Kromě klepání, zde hraje roli i mechanický návrh motoru, provozní podmínky, spalovací teploty a samozřejmě kvalita a množství plynu. Tato práce je zaměřena na detekci klepání. V případě přesnějšího vyhodnocení klepání, je možné zvýšit poměr plynu ku naftě. Současně je s tím zajištěn bezpečnější provoz motoru. V případě detekce klepání je totiž nutný zásah do řízení systému, tak aby motor oblast klepání opustil co nejrychleji.

Klepání motoru je jednou z hlavních limitací, která je přítomna u plynových motorů, zážehových motorů, i u duálního provozu vznětových motorů. V krajních případech může mít za následek až mechanické zničení motoru. Klepání je podle [2] nejčastěji způsobeno jednou ze dvou příčin, a to samovznícením nebo detonačním spalováním. Ke klepání může dojít ve válci, pouze v okamžiku, kdy je válec v expanzi, resp. v době těsně předtím. Z této znalosti vyplývá první úloha práce, a to návrh lokalizace pálení válce, tedy určení počátku a délky pálení. Ve chvíli, kdy je známo, v jakém čase dochází k pálení válce je nutné určit, jestli se jedná o klepání.

Detekce klepání je proces, při němž je definováno, jestli dochází ke klepání, případně kdy a jak intenzivně. Existuje řada metod, které jsou vhodné pro detekci klepání, a to od přímých metod za pomoci měření tlaku ve spalovací komoře, po nepřímé metody za využití například piezoelektrických snímačů klepání pro měření vibrací motoru. Druhou úlohou práce je návrh nepřímé metody detekce klepání, za využití zpracování zvukového záznamu z motoru. Pro vyhodnocení klepání je nezbytné mít k dispozici referenční naftový záznam a záznam hodnotící. Dále je nutná znalost přibližné klepající frekvence.

Výsledný systém, který byl pro účely práce navržen, bude moci sloužit k analytickým účelům pro vyhodnocení nahraných záznamů. Nejde o analýzu v reálném čase. Systém je navrhován jako analytický nástroj a cílem není plná automatizace procesu. To je dáno složitostí problémů, rozdíly mezi motory a možnou nejednoznačností u signálů i u vyhodnocení. Analýza klepání by měla být vždy prováděna odborníkem a systém by měl fungovat jako podpora při vyhodnocování klepání.

Přestože se práce zaměřuje na analýzu signálů z naftových motorů, pracujících v duálním provozu využívaných jako generátory, cílem je, aby byl výstup aplikovatelný i na jiná zařízení, typicky plynové motory. Využití na jiných aplikacích bude otázkou parametrizace navrženého systému.

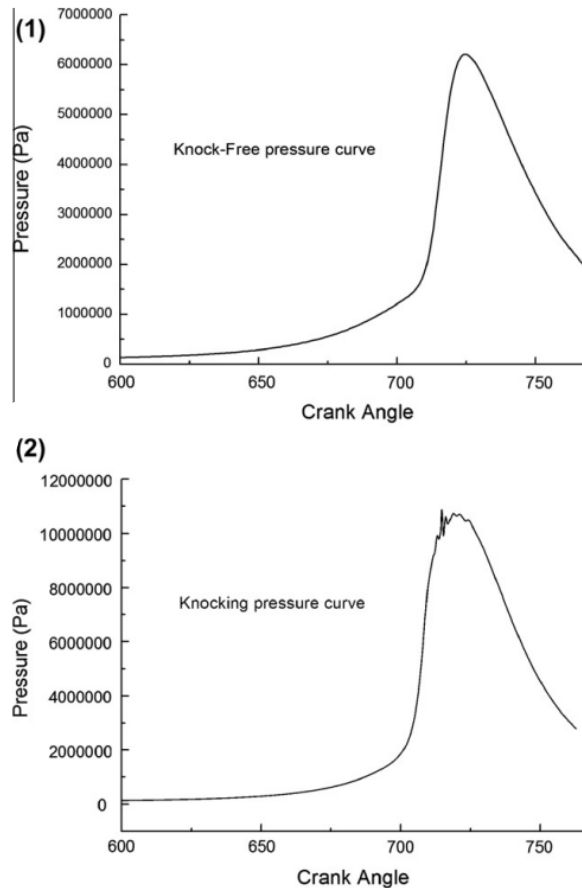
2. Klepání motoru

Vysvětlení klepání motoru se věnuje [3], které klepání popisuje jako projev abnormálního spalování směsi v motoru. Jedná se o jednu z hlavních bariér, která omezuje zlepšování termické účinnosti motoru. Výskyt klepání je pro provoz motoru nebezpečný a při jeho přítomnosti může dojít v krajních případech k poničení motoru. Konkrétně se může jednat o strukturální poškození motoru, zničení pístních kroužků, poničení hlavy pístu, koroze hlavy válce, nebo koruny pístu, a další. Cílem je zabránit výskytu klepání ve všech případech.

Za zdroje klepání jsou podle [2] v současnosti uvažovány dvě hlavní příčiny a to samovznícení (auto ignition) a detonační spalování (detonation). Samovznícení vede k zapálení směsi paliva v komoře válce a tím k velkému nárůstu energie v okamžiku, před zážehem (u zážehových motorů), nebo před vstřikem nafty (u vznětových motorů s duálním palivem). Tím dojde k vytvoření velkých lokálních tlaků a k šíření tlakových vln po spalovací komoře. Tento předčasný zážeh směsi je neřízený. Vzniká mimo jiné od horkých míst, která se vytvoří ve spalovacím prostoru – na pístu, na hranách talíře ventilu, na elektrodách zapalovací svíčky (u motorů se svíčkou), od usazeného karbonu. Podle [3] mohou být tvořeny i nehomogenitami v teplotě nebo v koncentracích, kdy může docházet k nerovnoměrnému prohoření směsi a tím pádem hrozí vznik klepání. V místě, kde teplota nebo tlak dosáhnou bodu samozápalu, směs se samovznítí. Samovznícením opět dojde k šíření tlakových vln uvnitř spalovacího prostoru v okamžiku před nebo po plánovaném zapálení směsi.

Teorie detonačního spalování uvedena v [3] předpokládá, že vznik klepání je dán šířením tlaku vzniklého vznícením dosud nespálené směsi v částech spalovacího prostoru, před čelem plamene, směrem od zdroje k hlavě pístu. Tlaková vlna narazí na stěny spalovací komory, od nichž se šíří dál a nerovnostmi v šíření, může také vznikat klepání. Porovnání neklepajícího a klepajícího provozu je ukázáno na obrázku 1, v závislosti tlaku na části spalovacího cyklu popsaného ve ° klikového hřídele¹.

¹ Jako časová jednotka se při výpočtech motorových parametrů často uvádí úhel natočení klikového hřídele, který je konzistentní se změnou rychlosti otáček na rozdíl od úhlové rychlosti, nebo času.



Obrázek 1 – Porovnání neklepajícího (1) a neklapajícího (2) provozu [2]

2.1. Metody detekce klepání

Metod pro určení klepání motoru existuje několik. Podle [3] lze rozdělit do dvou širších kategorií, a to na přímé a nepřímé. První z nich jsou zaměřeny na měření a analýzu vnitřních parametrů ve spalovacím prostoru. Ostatní metody jsou označovány jako nepřímé, mezi nimi jsou nejvýznamnější měření akustického tlaku nebo měření vibrací motoru.

Práce je zaměřena na analýzu klepání pomocí měření vibrací motoru a vyhodnocení těchto signálů. Tato metoda totiž poskytuje měření, které je levné, relativně jednoduché vzhledem k instalaci, je využitelné na širokém spektru aplikací apod. Dalším kladem metody je její odolnost, ta je dána tím, že sensory, nejsou v přímém kontaktu se spalovacím prostorem.

2.1.1. Přímé metody měření klepání

Přímé metody měření klepání popisuje článek [3]. Metody jsou využívány k analýze signálů spalovacích tlaků uvnitř válce. Cílem metody je podrobně zkoumat procesy ve spalovací komoře a zjistit, jak jsou ovlivněny klepáním. Metoda je často používána jako referenční pro kalibraci ostatních nepřímých metod. Typické vysokofrekvenční klepající projevy mají vztah k rezonančním frekvencím spalovací komory. Tyto rezonance jsou

vyvolány rychlým nárustem tlaku. Typické talkové křivky klepajícího a neklepajícího motoru jsou na obrázku 1.

Metody založené na měření spalovacího tlaku uvnitř válce mají několik nevýhod. Sensory používané pro měření tlaku jsou nákladné. Zároveň jsou v přímém kontaktu se spalovacím prostorem, to vede ke snížené životnosti a zhoršení přesnosti s nárustem doby použití. V případě využití více senzorů, např. jeden na každý válec, narůstá cena i na straně HW pro zpracování. Tyto metody jsou běžně využívány jako referenční pro kalibraci strategií k vyhodnocení klepání.

2.1.2. Analýza vibrační motorového bloku

Článek [3] dále popisuje nepřímé metody měření klepání. Tyto metody se zaměřují na určení klepání motoru na základě změny v dalších měřených parametrech motoru například u vibrační motoru. V okamžiku, kdy se motor začne klepat, začnou se v komoře motoru šířit tlakové vlny. Z hlediska mechaniky motoru jsou frekvence klepání závislé především na velikosti vrtání. Z hlediska nemechanického je výskyt klepání závislý na směsi paliva, rezonantních módech, lokální rychlosti vzduchu, teplotách sacího vzduchu apod. Tyto tlakové vlny ovlivňují vibrace motoru a ty mají jiná frekvenční pásma oproti provozu v neklepajícího motoru.

2.1.3. Analýza teplot výfukového plynu

Vzhledem k nutnosti předzpracování signálu, který může být snadno zarušen existují teorie, popsány v článku [4], které doporučují jako jednu z možných metod pro určení klepání měření teploty výfukového plynu. Autoři tvrdí, že je možné pozorovat korelaci mezi výskytem klepání a teplotou plynu na výfuku, která se při klepání snižuje.

2.2. Frekvence klepání

Výpočet frekvence klepání popisuje článek [5], který říká, že akustické vlny vytvořené klepáním motoru jsou podélné tlakové vlny, které se šíří adiabaticky. Akustické vlny jsou popsány vlnovou rovnicí (1)

$$\frac{\partial^2(\Delta\rho)}{\partial t^2} = c_\infty^2 \frac{\partial^2 \Delta\rho}{\partial x^2}, \quad (1)$$

kde $\Delta\rho$ je porucha hustoty plynu, c_∞ je rychlost zvuku v neporušeném plynu, t je časová souřadnice a x je prostorová souřadnice.

Pro zjednodušení rovnice je uvažováno, že proudění tekutiny je adiabatické a bez viskózní a vlna je předpokládána jako akustická, a tedy poruchy fyzikálních vlastností tekutiny jsou malé, tzn. $\Delta\rho \ll \rho_\infty$, kde $\Delta\rho$ je porucha hustoty a ρ_∞ neporušená hustota. Druhý předpoklad je nutný k linearizaci vlnové rovnice, ta ztrácí přesnost s nárustem poruch hustoty.

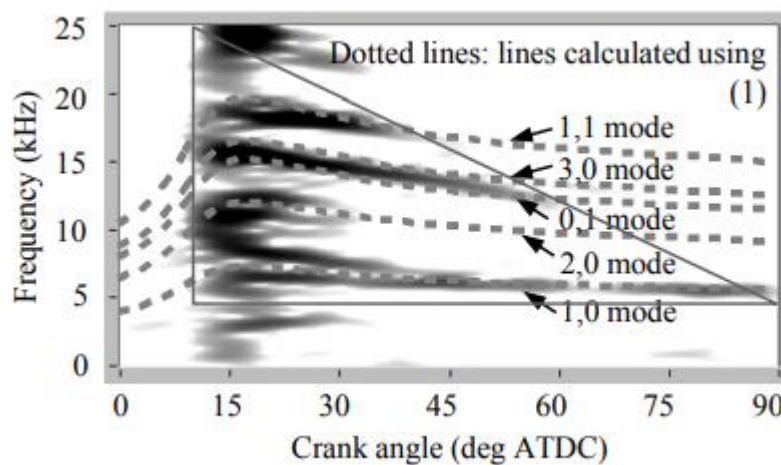
Z článků [6] a [7] jsou za pomoci Besselových rovnic určeny koeficienty kmitacího módu $\alpha_{m,n}$, ty odpovídají určitému frekvenčnímu módu, které jsou zobrazeny na obrázku 2. Rovnice (2) prezentuje vztah mezi $\alpha_{m,n}$, frekvencí klepání a průměrem válce

$$f_{m,n} = \frac{\alpha_{m,n}c}{2\pi a}. \quad (2)$$

Je nutné zmínit, že klepání je stochastický jev a je ovlivněno řadou vnějších parametrů jako na mj. teplotou spalovací směsi, geometrií motoru, provozem motoru, spalovacími parametry, a dalšími. Řešení rovnice pro reálný motor je možné pouze numericky. Rovnice (2) je však vhodný nástroj pro jednoduché určení přibližné hodnoty frekvence klepání motoru s válcovou komorou.

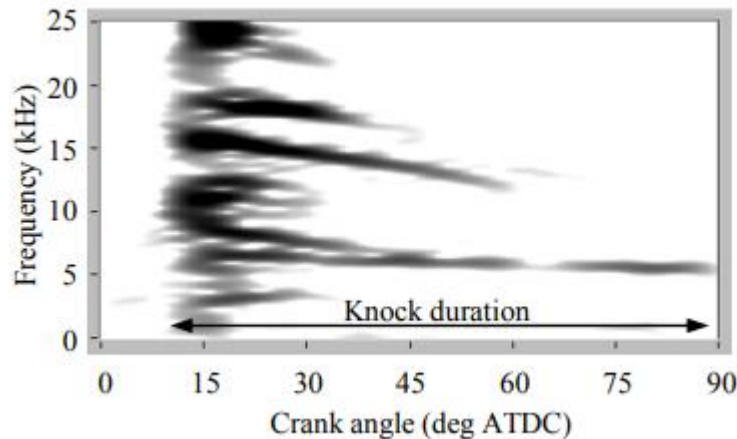
Existují články [6], které tvrdí, že většina vlnové energie se typicky nachází v nejnižším módu ($m=1, n=0$), kdy je $\alpha_{m,n} = \alpha_{1,0} = 1,841$. Je důležité zmínit, že takto vypočtené frekvence nemusí být nutně klepající, ale jsou charakteristické pro samotnou spalovací komoru. Je tedy možné je spojit i s neklepavým během motoru v případě dostatečně lokalizovaného uvolňování tepla a pokud je rychlost expanze srovnatelná s rychlostí zvuku.

Literatura [8] Kde $\alpha_{m,n}$ je první radiální režim vibrací a jeho hodnota je 1,841. Dále vysvětluje volbu c jako rychlosti zvuku ve spalovací komoře, která je stanovena na 900 m/s. A je vrtání válce, to je závislé na konstrukci motoru. Porovnání Koeficientů $\alpha_{m,n}$ a jejich vztah k frekvenci a době hoření za TDC je ukázáno na obrázku 2.



Obrázek 2 – Popis módů klepajících frekvencí [8]

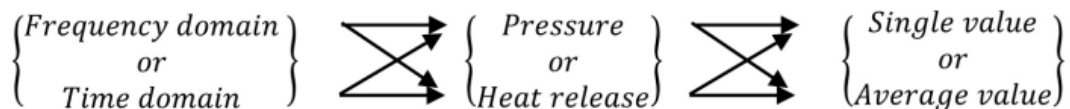
K identifikaci klepání je podle článku [8] možné využít i délku hoření, resp. klepání, která se může měnit oproti hoření neklepajícího motoru. Klepající vibrace mohou pokračovat až do 90°ATDC. To je způsobeno tím, že klepání vyvolává pokračující vibrace vzduchového sloupce ve spalovacím prostoru. Vliv otáček, výkonu a objemu motoru by neměl mít velký vliv na dobu možnosti pozorování klepání, ta se vždy blíží k 80-90 °KH, jak ukazují obrázky 2 a 3.



Obrázek 3 – Doba přítomnosti klepající frekvence [8]

2.3. Metriky měření klepání

V literatuře [5] se vyskytuje několik metrik, podle kterých lze hodnotit klepání motoru. Snahou je určit začátek klepání a jeho intenzitu.



Obrázek 4 – Možné metody identifikace klepání [6]

U Intenzity klepání (knock intensity – KI) lze podle [6] pracovat s daty v časové i frekvenční oblasti. Pro vyhodnocení je možné užívat data o tlaku a jeho derivace, nebo data o rychlosti uvolněného tepla a jejích derivací. Je možné využití jedné hodnoty, nebo jejich průměru, nebo integrace hodnot. Níže popsané metody v časové oblasti jsou založeny na analýze filtrovaného signálu o tlaku. Korektní analýza musí obsahovat informace o typu filtru, jeho řádu apod. využívané filtry jsou vysokofrekvenční nebo pásmové. Nízkofrekvenční část signálu je nejčastěji spojena s kompresí a standardním uvolňováním tepla.

Začátek klepání (knock onset – KO) je podle [6] možné měřit pouze v časové doméně. Fourierova transformace nezachovává časové informace o signálu. Jednou z metod pro určení začátku klepání je „threshold value exceeded“ – TVE (překonání hodnoty prahu). Začátek klepání je určen prvním úhlem klikového hřídele, kde je překročena předem definovaná hodnota signálu o tlaku (nebo jeho derivaci) po projití filtrem. Jedná se o jednoduchou metodu, která má však nevýhodu v rychlosti vyhodnocení. Klepání bude odhaleno o několik stupňů klikového hřídele později, protože je nutné nastavit práh dostatečně vysoko, aby se zamezilo oznámení falešné detekce.

2.3.1. Metriky KI v časové oblasti

Nejběžněji využívanou veličinou pro analýzu v časové oblasti je dle [5] tlak, resp. filtrovaná hodnota tlaku – p_{filt} . Metoda maximální amplitudy tlakových oscilací (Maximum

Amplitude of pressure oscillations) – MAPO, bere maximální amplitudu filtrované hodnoty tlaku při klepání (zdali se jedná o klepání, je určeno podle KO) a z této hodnoty je poté určena intenzita klepání

$$MAPO = \max\{P_{filt}\}. \quad (3)$$

Další iterací MAPO je podle [5] metoda Energie signálu tlakových oscilací (Signal Energy of pressure oscillations) – SEPO. Ta bere v potaz hodnotu integrálu 2. mocniny p_{filt} časové oblasti od začátku klepání θ_0 do $\theta_0 + \Delta\theta$. Kde θ určuje úhel na klikové hřídeli a $\Delta\theta$ je zpravidla 5-20°. Tím je snížen efekt rušení signálu a výpočet je dán následující rovnicí

$$SEPO = \int_{\theta_0}^{\theta_0+\Delta\theta} P_{filt}^2 d\theta. \quad (4)$$

Tato metoda je dále zpřesněna [5] výpočtem průměrné hodnoty SEPO na intervalu $\Delta\theta$. Metoda je nazvána Průměrná energie tlakových oscilací (Average energy of pressure oscillations) – AEPO podle následující rovnice

$$AEPO = \frac{1}{\Delta\theta} SEPO. \quad (5)$$

Článek [5] uvádí i další metody, které určují intenzitu klepání z filtrovaného signálu tlaku, resp. jeho derivací. Intenzitu klepání lze určit i analýzou rychlosti uvolněného tepla. Tu lze spočítat podle vzorce (6)

$$\frac{dQ}{d\theta} = \frac{\gamma}{\gamma-1} P \frac{dV}{d\theta} + \frac{\gamma}{\gamma-1} V \frac{dP}{d\theta}, \quad (6)$$

kde γ značí Poissonovo číslo $\frac{c_p}{c_v}$, V značí objem a P tlak. Analogicky s metodami založenými na tlaku, lze podle [5] zavést metriky Maximální amplituda oscilací rychlostí uvolněného tepla, Energie signálu oscilací rychlostí uvolněného tepla, a Průměrná energie oscilací rychlostí uvolněného tepla, jejich rovnice jsou poté následující

$$MAHRO = \max\left\{\left(\frac{dQ}{d\theta}\right)_{filt}\right\}, \quad (7)$$

$$SEHRO = \int_{\theta_0}^{\theta_0+\Delta\theta} \left(\frac{dQ}{d\theta}\right)_{filt}^2 d\theta, \quad (8)$$

$$AEHRO = \frac{1}{\Delta\theta} SEHRO. \quad (9)$$

Uvolněné teplo může být vypočteno buď z filtrovaného signálu tlaku, nebo ze signálu tlaku a následně filtrován. Z různých studií však vyplývá, že metody založené na analýze uvolněného tepla jsou často nepřesné a redundantní.

2.3.2. Metriky KI ve Frekvenční oblasti

Za použití Fourierovy transformace uvádí [5], lze signály tlaku nebo tepla převést do frekvenční oblasti. Průměrnou energii tlaku ve frekvenční oblasti lze určit integrací hustoty výkonového spektra na oblasti frekvencí $f_1 < f < f_2$ podle rovnice (10)

$$AEFD_{f_1-f_2} = \int_{f_1}^{f_2} S_{xx}(f) df, \quad (10)$$

kde S_{xx} je hustota výkonového spektra.

2.3.3. Metriky KO

Jak již bylo zmíněno [5], měření začátku klepání je možné pouze v časové oblasti. Vhodnou metodou popisuje [9] je metoda nazvaná Poměr energie signálu (Signal energy ratio) – SER, jejíž výpočet je podle rovnice (11)

$$SER = \frac{(\int_{\theta_0}^{\theta_0+\Delta\theta} P_{filt}^2 d\theta)^2}{(\int_{\theta_0-\Delta\theta}^{\theta_0} P_{filt}^2 d\theta)^{\frac{1}{2}}}, \quad (11)$$

Metoda počítá energii signálu v následujícím intervalu v čitateli, dělenou energií v předchozím intervalu. Hodnota SER je vypočtena v okolí TDC. Začátek klepání je pak určen jako okamžik natočení klikového hřídele s největší hodnotou SER. Metoda není vhodná pro určení KO v reálném čase, ale pro diagnostické účely posteriori.

3. Teorie

V předchozí kapitole byly představeny metody pro rozlišení klepání, které jsou známé a používané. Práce je zaměřena na analýzu pomocí nepřímé metody měření a návržení metody pro určení klepání nepřímo, pomocí zpracování změřeného signálu.

Kapitola je věnována popisu všech metod, modelů a matematických postupů, které jsou v práci využity. Cílem kapitoly je vysvětlit jejich funkčnost a základy na nichž, jsou metody postaveny. Aplikace metod na testovací signály a na signály reálné, jsou stejně jako ověření jejich funkčnosti v kapitolách věnovaných jejich využití.

3.1. Fourierova transformace, FFT a DFT

Pravděpodobně nejdůležitějším nástrojem pro zpracování signálu je Fourierova transformace a její variace DFT (Discrete Fourier transformation). Ty jsou popsány například v literatuře [10]. Ta popisuje, že každý signál má spektrum a je určen tímto spektrem. Signál může být zkoumán buď ve frekvenční nebo časové oblasti. Fourierova transformace slouží k přechodu mezi těmito oblastmi

$$f(s) = \int_{-\infty}^{\infty} f(t) e^{-j2\pi st} dt, \quad (12)$$

kde $f(s)$ je transformovaný signál a $f(t)$ je výchozí signál. V případě přechodu z frekvenční oblasti zpět do časové, lze použít inverzní Fourierovu transformaci. Ta je určena rovnicí (13)

$$f(t) = \int_{-\infty}^{\infty} f(s) e^{j2\pi st} ds. \quad (13)$$

Diskrétní Fourierovu transformaci je možné definovat jako (14)

$$\mathcal{F} = \sum_{k=p}^{p+N-1} f[k] \omega^{-k}, \quad (14)$$

DFT transformuje set N čísel řady $f[k]$ do jiného setu až do indexu $\mathcal{F}[p + N - 1]$ a ω je operátor dán rovnicí (15)

$$\omega = e^{\frac{2\pi i}{N}}. \quad (15)$$

Rychlá Fourierova transformace (FFT) označuje algoritmus pro řešení DFT, nejznámějším z nich je Cooley-Turkey popsán například v [11], který je použit i ve funkci `numpy.fft.ffft()` knihovny `numpy`. Algoritmus rozděluje DFT s velikostí složeného čísla do dvou menších DFT o velikostech N_1 a N_2 .

3.2. PCA

Analýza hlavních komponent, PCA (principal component analysis) se podle [12] zabývá vysvětlením variantně-kovariantní struktury souboru proměnných. K tomu využívá lineární kombinaci těchto veličin. Hlavními cíli metody jsou interpretace a redukce dat. Podle [13] je PCA jednou z nejpoužívanějších metod v oblasti analýzy dat sloužících pro redukci rozměrů datových souborů a současném zachování relevantních informací. Hlavní komponenty jsou nově nekorelované a téměř normálně distribuované proměnné, které

poskytují redukovanou reprezentaci dat. Tato reprezentace je následně vhodná pro další analýzu. Kompresi pomocí PCA udržuje všechna relevantní data a současně umožňuje analyzovat vztahy mezi proměnnými použitými pro tvorbu modelu. V případech, kdy je preferována práce s původními proměnnými může PCA sloužit jako pomocný nástroj pro výběr funkcí (Feature selection), s cílem určit, které proměnné v celém datovém souboru jsou nejvíce relevantní pro jeho popis.

Literatura [12] představuje rovnice (16) až (20) pro popis PCA. Matematicky jsou hlavní komponenty lineární kombinace p náhodných proměnných

$$\mathbf{X} = [x_1, x_2 \dots x_p]. \quad (16)$$

Geometricky tyto lineární kombinace popisují výběr nového souřadného systému, získaného rotací výchozího systému, kde $x_1, x_2 \dots x_p$ jsou výchozí osy. Nové osy reprezentují směry s maximální variabilitou a poskytují jednodušší a ekonomičtější popis kovarianční struktury. Pro výpočet hlavních komponent následně určíme standardizované skóre (z- score) podle rovnice (17)

$$\mathbf{Z}_i = \frac{\mathbf{X}_i - \boldsymbol{\mu}_i}{\sigma_i}; \quad i = 1, \dots, p, \quad (17)$$

kde \mathbf{X}_i je původní hodnota, která bude standardizována, σ_i je původní směrodatná odchylka a $\boldsymbol{\mu}_i$ je původní průměrná odchylka. Dále je určena kovarianční matice, ta je vypočtena podle rovnice (18)


$$\text{Cov}(\mathbf{X}) = (\mathbf{V}^{\frac{1}{2}})^{-1} \sum (\mathbf{V}^{\frac{1}{2}})^{-1} = \boldsymbol{\rho}. \quad (18)$$

Hlavní komponenty standardizovaných proměnných $\mathbf{Z}_i = [Z_1, Z_2, \dots Z_p]$ určené za pomoci $\boldsymbol{\rho}$ jsou rovny vlastních čísel \mathbf{V}_i podle rovnice (19), jsou potom \mathbf{Y}_i a je určena podle rovnice (20)

$$\mathbf{V}_i = \text{eig}(\text{Cov}(\mathbf{X}_i)), \quad (19)$$

$$\mathbf{Y}_i = \mathbf{V}_i \mathbf{Z}. \quad (20)$$

Na obrázku jsou ilustrována data s mírnou korelací. Z grafu je vidět, že největší kovariance je v rovině první hlavní komponenty.



Obrázek 5 – Hlavní komponenty dvou atributů

3.3. SVD

Singulární rozklad, neboli SVD (single value decomposition) je speciální rozklad matice, jeho popisem se zabývá např. článek [14], ten popisuje, že pro každou matici s komplexně sdruženými prvky, existuje singulární rozklad, který rozkládá matici X [n, m] do tří matic a to U , Σ , V podle rovnice (21)

$$X = U\Sigma V^*, \quad (21)$$

kde matice U je unitární čtvercová matice [n, n], jejíž sloupce jsou levé singulární vektory. Matice V je unitární čtvercová matice [m, m] jejíž sloupce jsou tvořeny pravými singulárními vektory. Hvězdička (*) značí Hermitovskou transpozici. Matice Σ [n, m] je matice s reálnými, nezápornými prvky na diagonále a nulami mimo diagonálu. Prvky diagonální matice Σ jsou singulární hodnoty a jsou řazeny od nejvyšší po nejnižší. Hodnota matice je rovna počtu nenulových prvků singulárních hodnot.

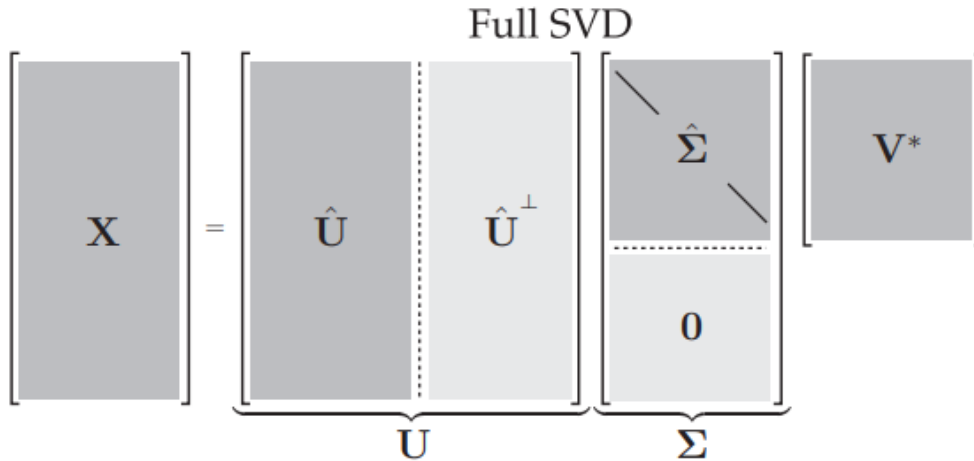
Pro singulární matice U a V platí, že její hermitovsky sdružená matice, je zároveň její inverzní

$$M^{-1} = M^H, \quad (22)$$

$$M^H M = M M^H = I, \quad (23)$$

$$M^H = M^{-T}, \quad (24)$$

kde I je jednotková matice.



Obrázek 6 – Singulární rozklad [14]

3.4. Polární rozklad

Polární rozklad (PD) je popsán v literatuře [15] jako rozklad matice, který je využit ke zobecnění matic. Jedná se o rozklad matice na součin hermitovské, pozitivně semidefinitní matice H a matice unitární U . Matice H je určena singulárními hodnotami, vypočtenými z vlastních čísel matice A . Matice U je potom určena jako násobek matice A a inverzní hodnoty matice H

$$A = UH, \quad \text{kde } U^*U = I, \quad (25)$$

$$H = (A^H A)^{\frac{1}{2}}. \quad (26)$$

Polární rozklad vždy existuje a je možné jej určit z výpočtu SVD a to podle rovnic (27) – (29)

$$A = (WV^*)(V\Sigma V^*), \quad (27)$$

$$U = WV^*, \quad (28)$$

$$H = V\Sigma V^*, \quad (29)$$

kde matice U, V, W jsou matice unitární a $W = U$ (z SVD).

3.5. Filtry

Využití filtrů v řídicích systémech je široké, od redukce šumu, rušení, aliasingu, po tlumení rezonancí. Různé zdroje [16] uvádějí, že je v řídicích jednotkách nejčastější využití filtrů s dolní propustí, které slouží k odfiltrování šumu. Přechodová funkce filtru 2. řádu je dána rovnicí (30). Jejich hlavní nedostatek spočívá v nestabilitě, která je způsobena fázovým posunem na přechodné frekvenci. V práci je předpoklad jejich využití pro první případ, tedy redukci šumu s cílem zvýraznění určité frekvence. Pro tento účel je navrženo využití filtrů s pásmovou propustí.

$$H_2(s) = \frac{H_0}{s^2 + \frac{\omega_0}{Q}s + \omega_0^2}, \quad (30)$$

kde platí (31) a Q je faktor kvality pro který platí rovnice (32), v níž ξ je koeficient tlumení

$$\omega_0 = 2\pi F_0, \quad (31)$$

$$Q = \frac{\xi}{2}. \quad (32)$$

Přenosová funkce filtru s horní propustí je podle [17] získána změnou čitatele na $H_0 s^2$. Odezva filtru s horní propustí je ekvivalentní té filtru s nízkou propustí s rozdílem, že frekvence je obrácená. Rovnice filtru s horní propustí 2. řádu je dána rovnicí (33)

$$H_2(s) = \frac{H_0 s^2}{s^2 + \frac{\omega_0}{Q} s + \omega_0^2}. \quad (33)$$

Standartně se v řídicích systémech vyskytují i filtry s pásmovou propustí, přenosová funkce je dána rovnicí (34), nebo s pásmovou zádrží

$$H_2(s) = \frac{H_0 \omega^2}{s^2 + \frac{\omega_0}{Q} s + \omega_0^2}. \quad (34)$$


3.5.1. Butterwothův filtr

Butterworthovy filtry, nebo maximálně ploché filtry jsou popsány v literatuře [16]. Mají totiž nejostřejší možný pokles pro každý řád, aniž by tvořili vrchol (peak) v Bodeho diagramu. Tyto filtry jsou používány právě z důvodu, že častým požadavkem v řídicích systémech je eliminace vrcholů. Tento přístup je často označován za konzervativní a umožnění vytvoření některých vrcholů může být výhodně využito, protože umožňuje ekvivalentní utlumení s kratším fázovým posunem při nižších frekvencích. 2pólový filtr s tlumícím koeficientem 0,707 je Butterwothův filtr 2. řádu. Zobecněná rovnice Butterworthova filtru s dolní propustí závisí na jeho řádu, v případě lichého je popsána rovnicí (35) v případě sudého potom rovnicí (36)

$$T(s) = \frac{\omega_n}{s + \omega_n} \prod_1^{(M-1)/2} \left(\frac{\omega_n^2}{s^2 + 2 \cos(\theta_i) \omega_n s + \omega_n^2} \right), \quad \theta_i = i \frac{180}{n} \quad (35)$$

$$T(s) = \prod_1^{M/2} \left(\frac{\omega_n^2}{s^2 + 2 \cos(\theta_i) \omega_n s + \omega_n^2} \right), \quad \theta_i = (i - 0,5) \frac{180}{n}, \quad (36)$$

kde: $e^{j\theta} + e^{-j\theta} = 2 \cos(\theta_i)$. Kombinací filtru s dolní propustí a filtru s horní propustí je možné získat filtr s pásmovou propustí, nebo filtr s pásmovou zádrží.



Graf 1 – Přejchodová charakteristika Butterworthova filtru s pásmovou propustí

3.5.2. Chebyshevův filtr

Publikace [17] uvádí jako další běžně využívaný filtr Chebyshevův. Jeho výhodou je menší přechodová oblast než u Butterworthova filtru stejného řádu. Ta je získána za cenu vzniku rušení (ripple) v průchozím pásmu. Počet vrcholů rušení je roven řádu. Póly Chebyshevova filtru mohou být určeny pomocí přesuvu pólů Butterworthova filtru doprava tak aby vytvořili elipsu, k tomu jsou využity koeficienty k_l a k_r podle rovnic (37) a (38)

$$k_l = \sinh A, \quad (37)$$

$$k_r = \cosh A, \quad (38)$$

kde A je:

$$A = \frac{1}{n} \sinh^{-1} \frac{1}{\varepsilon}, \quad (39)$$

n je řád filtru a ε je rovno:

$$\varepsilon = \sqrt{10^R - 1}, \quad (40)$$

kde R je:


$$R = \frac{R_{dB}}{10} \quad (41)$$

A R_{dB} je šířka rušícího pásma v dB. Ta je volena podle pozorování, jedná se o odchylku od střední hodnoty šumu v dB. Literatura [18] doporučuje konzervativně volbu 20 %. S rostoucím R_{dB} se zvyšuje amplituda šumu (ripple), která vede k rychlejšímu poklesu. Přenosová funkce je potom dána rovnicí (42)


$$T(s) = \frac{1}{\sqrt{1 + \varepsilon^2 T_n \left(\frac{s}{\omega_p} \right)^2}} \quad (42)$$

kde T_n je Chebyševův polynom n-tého stupně, který je daný dle [19] rovnicí (43)

$$T_{n+1}(x) = 2xT_n(x) - T_{n-1}(x). \quad (43)$$



Graf 2 – Ilustrace změny v šumu u Chebysheva filtru [18]



Graf 3 – Přejchodová charakteristika Chebysheva filtru s pásmovou propustí

3.6. ARIMA

Modely pro predikci časových řad lze podle [20] rozdělit do dvou hlavních proudů. Prvním z nich jsou lineární a druhým nelineární modely. Mezi lineární spadají například modely AR, MA, ARMA, nebo právě model autoregresního integrovaného klouzavého průměru – ARIMA. Mezi nelineární modely, lze zařadit například umělé neuronové sítě (ANN) nebo metodu podpůrných vektorů (SVM).

Tato kapitola je zaměřena pouze na lineární modely. Ty lze rozdělit na metody vhodné pro stacionární procesy, kam lze zařadit ARMA a metody vhodné pro nestacionární časové řady, kam lze zařadit metodu ARIMA. Principem modelu ARIMA je transformace nestacionární časové řady na stacionární a následně aplikace ARMA modelu pro analýzu dat. Model ARIMA lze popsat podle rovnice (44)

$$\left(1 - \sum_{i=1}^p \phi_i B^i\right) (1 - B)^d X_t = \left(1 + \sum_{i=1}^q \theta_i B^i\right) \varepsilon_t, \quad (44)$$

Kde B je zpětný (backshift) operátor, ten je aplikován na prvek X_t tak, aby určil jeho předchozí hodnotu, popisuje jej rovnice (44). p je řád autoregresního modelu (AR), který určuje počet kolik hodnot zpět je zkoumáno. d je řád diferenciace, tedy počet, kolikrát byla data upravena odečtením předchozích hodnot a q je řád modelu klouzavého průměru, tedy MA. Parametry ϕ_i jsou koeficienty AR části, θ_i jsou koeficienty části MA

$$BX_t = X_{t-1}. \quad (45)$$

3.7. LNU

Metoda lineární neuronové jednotky (LNU) je vhodná pro využití v případech kdy není znám model řídicího zařízení, je popsána v článku [21]. Metoda je navržena tak, aby se adaptovala na změny v procesu během provozu. Model nemusí být nutně lineární, lze použít i modely vyšších neuronových jednotek (HONU)

$$y_m = \sum_{i=0}^n w_i x_i = \mathbf{w}^T \mathbf{x}, \quad (46)$$

kde \mathbf{x} je vstupní vektor a \mathbf{w} je vektor váhových koeficientů. Obecně lze metodu zapsat podle rovnice (47)

$$y_m = \mathbf{w}^T \text{col} \mathbf{x}, \quad (47)$$

kde \mathbf{w} i $\text{col} \mathbf{x}$ jsou sloupcové vektory. Váhové koeficienty lze určit podle rovnice (48)

$$w(k+1) = w(k) - \mu_k \frac{\partial J}{\partial \mathbf{w}} = w(k) + \mu_n e(k) \text{col} \mathbf{x}(k), \quad (48)$$

kde J je kritérium, které je minimalizováno pomocí gradientního sestupu

$$J = \frac{1}{2} e(k)^2, \quad (49)$$

$$\frac{\partial J}{\partial \mathbf{w}} = e(k) \left(\frac{\partial J}{\partial \mathbf{w}} y(k) - \frac{\partial J}{\partial \mathbf{w}} y_m(k) \right) = e(k) (0 - \text{col} \mathbf{x}) = -e(k) \text{col} \mathbf{x}, \quad (50)$$

A chybu lze vyjádřit podle rovnice (51)

$$e(k) = y(k) - y_m(k), \quad (51)$$

Parametr μ_k představuje koeficient rychlosti učení. A je dán rovnicí (52), v níž koeficient $\varepsilon \approx 1e^{-5}$.

$$\mu_k = \mu \frac{1}{\varepsilon + \|\text{col}x(k)\|} \quad (52)$$

4. Formulace úloh


Během analýzy vzorků je nutné vyřešit řadu úloh. Hlavní z nich jsou definovány v této kapitole. Hlavní cíle jsou definovány jako lokalizace pálení motoru, stanovení klepání a návrh predikce průběhu spalování v další iteraci.

Lokalizace pálení motoru je nutná, neboť v jiném okamžiku nemůže dojít ke klepání motoru. Cílem je lokalizovat začátek a dobu pálení. Ve chvíli, kdy je pálení známo, dochází k významnému zjednodušení dat, pro další vyhodnocení je využita pouze právě určená část dat. Tyto data jsou následně využita pro analýzu klepání.

V určitých částech je vytvořena ukázka na simulovaném signálu, kde je znám průběh a ukázka na reálném signálu. Pro validaci by bylo vhodné, aby byla validace provedena na více různých vzorcích. Tato skutečnost je určena jako další postup. Cílem je najít vhodné metody a ověřit, jestli jsou zvolené metody použitelné a dostatečně přesné.

4.1. Předpoklady systému

Návrh systému počítá s tím, že pro každý válec je instalován jeden snímač klepání. Snímače klepání jsou piezoelektrické. A je umístován co nejbližší ke spalovacímu prostoru. Výstupem je elektrické napětí. Systém dále obsahuje synchronizační značku, aby bylo možné oddělit cykly motoru. Jeden impuls synchronizační značky přijde jednou za 4 cykly válce. Mezi dvěma značkami jsou tak vždy všechny 4 cykly válce, a právě jedno pálení. Jedna perioda signálu znamená celý 4dobý cyklus motoru. Nahraný signál včetně synchronizačních značek je ukázán na obrázku 7.



Obrázek 7 – Ukázka získaného signálu

Takovýto signál je získán pro každý válec motoru. Během návrhu analýzy jsou testy provedeny na jednom vzorku. Systém předpokládá, že je znám průměr vrtání válce, a tedy odhad klepající frekvence. Zároveň je předpokladem znalost provozu v určitých režimech, a to vždy naftový a duální s různými procenty substituce. Tyto získané signály jsou následně porovnávány. Cílem je na základě naftového provozu určit, jestli jsou odchylky provozu s duálním palivem projevem klepání. Takto získané nahrávky by měly být získány na

různých výkonových stupních. Dalším předpokladem je konstantní rychlost otáčení. Platí, že čím více měření, tím přesnějších výsledků bude dosaženo.

4.2. Lokalizace pálení motoru

Klepání, jako projev motoru, se může vyskytovat pouze v oblasti pálení motoru. Co nejpřesnější lokalizace pálení je nutná, protože ke klepání může docházet pouze v této oblasti. Tato zjištěná oblast zároveň snižuje nutnou výpočetní kapacitu a čas potřebný pro vyhodnocení. Snímač použitý pro záznam vzorků pracuje jako mikrofón, který snímá vždy jeden válec. Signál získaný ze snímače je tedy zvuk. Pro synchronizaci jsou použity synchronizační značky. Tím je docíleno toho, že v každém signálu je vždy zaznamenán celý cyklus válce, tedy – sání, komprese, expanze a výfuk. Součástí expanze je pálení, během něž může docházet ke klepání. Hlavním problémem je kvalita signálu. Ta je určena konstrukcí motoru, jeho velikostí, lokací nainstalovaného snímače, délkou kabelů i kvalitou instalace. Poslední dvě z výše zmíněných jsou definovány, určitým předpisem drsnosti a definovaným momentem utažení, přesto může při instalaci dojít k situacím, kdy není možnost tyto parametry splnit. Z tohoto důvodu je nutné, aby byla metoda dostatečně robustní.

Nejen, že se signály z různých motorů liší. Záznam také obsahuje velké množství zvukových interferencí. Tyto interference mohou být způsobeny vlivem ostatních válců, zavíráním ventilů sání a výfuku a řadou dalších zvuků, které generuje motor.

Frekvence pálení je rozsah frekvencí, v nichž probíhá pálení. Jedná se o rozsah, který je způsoben mechanickým návrhem motoru a dalšími parametry. Pro zjednodušení je v práci rozsah frekvencí navázán na frekvenci klepání a je počítán podle typu motoru. Je uvažováno, že pálicí frekvence je buď v okolí klepající frekvence, podle [6], anebo vzhledem k tomu, že frekvence nemusí být shodná byl stanoven vzorec odhadu frekvenčního pásma (56) pro typy motorů, kde je frekvence pálení odlišná od klepající frekvence. Při analýze může dojít ke zkreslení od frekvencí pálení ostatních válců. Tento projev je častý zejména u malých motorů, kde jsou válce blíže u sebe. V tomto případě bude ale rozdíl patrný v síle signálu, tedy v amplitudě. Frekvence ostatních rušení může být v určitých případech shodná s frekvencí pálení, její amplituda by ale měla být odlišná. V krajním případě neprůkaznosti je možné lokalizovat pálení ze vzorku, který se blíží klepání, a frekvenci je tedy snazší odhadnout.

Lokalizace pálení je tedy definována začátkem a dobou pálení. V případě, že doba pálení není zřejmá ze signálu, je možno ji prvotně určit dopočítáním podle vzorce (53) a následně validovat. Validace probíhá následně na signálu nahraného na duálním provozu. V případě duálního provozu je totiž pálení více patrné, to je způsobeno vyšší výhřevností zemního plynu, která vede ke zvýšeným projevům motoru


$$t_{\text{pálení}} = \frac{720}{4 \cdot n_{\text{válce}}} \cdot \quad (53)$$

4.3. Detekce a vyhodnocení klepání


Dalším úkolem je rozeznání klepání. Předpokladem pro tuto analýzu je znalost počátku a doby pálení. Tyto parametry jsou využity pro definici velikosti vyhodnocovacího okna. Cílem je určit charakteristiky provozu v různých režimech a rozhodnout, jestli se jedná o pálení, nebo klepání.

Všechny navrhované metody jsou postaveny na znalosti odhadu klepací frekvence. Vyhodnocení klepání je navrženo jako porovnání mezi naftovým a duálním provozem. Je využito znalosti, že klepající frekvence by se při nižších frekvencích a módech, měla projevit delší prezencí. Tento jev je ukázán na obrázku 9, pro prezentovaný vzorek *vzorek_1_neklepe*, a *vzorek_1_klepe*. je uvažováno, že motor má průměre vrtání 159 mm a odhadnutou frekvenci klepání podle rovnice

$$f = \frac{\alpha_{1,0}c}{\pi a} = \frac{1,841 \cdot 900}{\pi \cdot 159} = 3,32 \text{ kHz.} \quad (54)$$



Obrázek 8 – Spektrogram neklepajícího signálu válce



Obrázek 9 – Spektrogram klepajícího signálu válce s vyznačeným klepáním

Z obrázků 8 a 9 je patrné, že frekvence klepání, která je dominantní na obrázku 9 je v okolí vypočtené frekvence.

5. Příprava a klasifikace vzorků

Všechny zpracovávané vzorky jsou ve formátu .wav. Pro návrh systému a vyhodnocení je zvoleno 9 vzorků, jejich parametry jsou popsány v tabulce 1. Signály jsou vzaty ze stejného motoru (XY) a v rámci jednoho testování i stejného válce. Nahraný signál je vždy získán na pomoci snímače zvuku. Ten je naistalován u jednoho válce. Signál je převeden do .csv za použití knihovny librosa.

id	Název souboru	Formát	Typ motoru	Vrtání [mm]	Začátek pálení [index]	Délka pálení [index]	válec
1	Fir_3_1300kW_DSL	.wav	V16	159	300	190	3.
2	fir_3_1300kW_BF_22	.wav	V16	159	300	190	3.
3	fir_3_1300kW_BF_39	.wav	V16	159	300	190	3.
4	fir_3_1300kW_BF_43	.wav	V16	159	300	190	3.
5	fir_3_1300kW_BF_44	.wav	V16	159	300	190	3.
6	Knocking_one_cycle	.wav	V16	159	500	225	5.
7	Light_Knocking_one_cycle	.wav	V16	159	500	225	5.
8	Not_knocking_one_cycle	.wav	V16	159	500	225	5.
9	1st_Firing_Knocking	.wav	V16	159	25	150	1.
10	1st_Firing_Not_Knocking	.wav	V16	159	25	150	1.

Tabulka 1 – použité vzorky

6. Lokalizace pálení


Prvním dílčím problémem, který je nutné vyřešit je určení pálení motoru. Současná metoda spoléhá na instalaci synchronizační značky, tato instalace může být časově i ekonomicky náročná, složitá a v určitých případech až neproveditelná. Zjišťovanými veličinami jsou začátek a délka pálení. Klepání může být přítomné pouze v oblasti pálení, proto je tento krok navržen pro usnadnění dalšího vyhodnocování signálu.

6.1. Teorie a navržený postup

Pro lokalizaci pálení je použita Fourierova transformace. Metoda vychází ze znalosti rozpětí pálicí frekvence. Metoda je navržena tak, že signál zaznamenaný snímačem je převeden do frekvenční oblasti. Frekvence, které jsou mimo určené frekvenční pásmo, jsou vynulovány. Signál je následně zpětně převeden do časové oblasti a pálicí frekvence je viditelná díky velikosti amplitudy. Na následujících grafech je metoda ukázána na známém signálu sinusové funkce.

Sinusová funkce je definována parametry amplituda $A = 230$, frekvence $f_{original} = 50$ Hz, Frekvence zarušení $f_{zaruseni} = 100$ Hz, v oblasti od 150. do 200. vzorku

$$y(t) = A \cdot \sin(2 \cdot \pi \cdot f_{original} \cdot t). \quad (55)$$



Obrázek 10 – Rekonstrukce sinusového signálu se zarušením

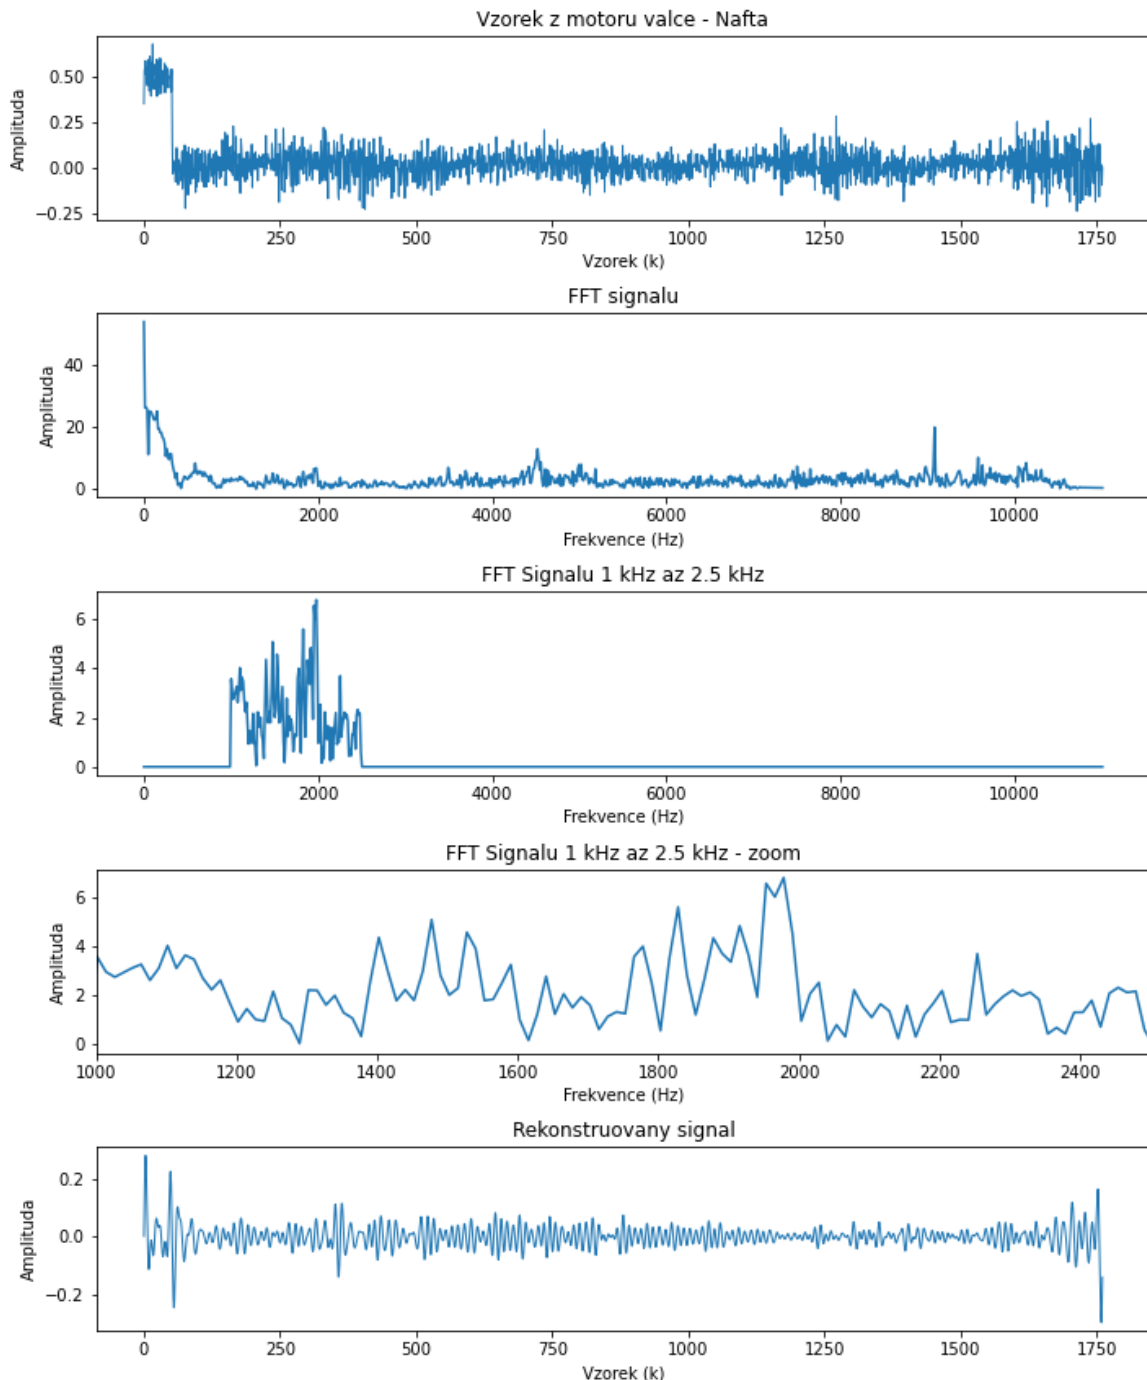
Obrázek 10 zobrazuje čtyři grafy. Je závislost vzorku na amplitudě. Dále je zobrazena FFT signálu, která je ve třetím grafu filtrována a jsou nechány pouze požadované frekvence. Poslední graf zobrazuje rekonstruovaný signál.

Z výše uvedených grafů je viditelné, že za pomoci metody je možné ze signálu určit klíčové hodnoty, a to začátek a délku doby, kde má signál zvolenou frekvenci. Po rekonstrukci je u signálu viditelná změna v amplitudě. Tato změna není v této fázi podstatná. Klíčová je zde volba frekvence. V případě simulace, kdy je hledaná frekvence známa je zvolena $\pm 25\%$.

V případě signálu získaného z motoru je volba rozsahu frekvence složitější. Při výpočtu frekvenčního pásma pálení bylo odměřeno, že pásmo vhodné pro odfiltrování je možno určit podle rovnice (55) a následně doladit. Pokud tato metoda není průkazná, je vhodné využít rovnici (2) a řídit se klepající frekvencí. Pokud ani tato metoda není průkazná je nutné přiblížit se klepání a rozšířit f_{firing_calc} na nižší straně

$$f_{firing_calc} = \frac{f_{knocking}}{2} \pm (0,25 \cdot f_{knocking}). \quad (56)$$

Pro ilustraci, pokud je spočtena frekvence klepajícího motoru vzorku (1) $f_{knocking} = 3,3 \text{ kHz}$ bude frekvenční pásmo pro $f_{firing_calc} = (0,825; 2,475) \text{ [kHz]}$.



Obrázek 11 – Rekonstrukce signálu z motoru

Obrázek 11 zobrazuje 5 grafů. Na prvním je signál v časové oblasti, kde je závislost indexu (k) na amplitudě, resp. na intenzitě hladiny zvuku (dB). Druhý Graf ukazuje četnost určité frekvence ve frekvenční oblasti. V grafu tři jsou ponechány pouze požadované frekvence. Předposlední graf je přiblížením grafu tři a poslední grafu ukazuje nově vytvořený rekonstruovaný signál, po odfiltrování nežádoucích frekvencí.

Z tabulky 1 víme, že začátek pálení by měl být v okolí indexu 300. Z posledního grafu na obrázku 7 vidíme anomálii v amplitudě v okolí index 300, která signalizuje začátek pálení. Celý proces pálení, zde není identifikovatelný, proto by byl volen podle rovnice (52).

V případě, kdy není vhodné užití rovnice (52), popisuje článek [22] další metody. Článek používá měření talku v motoru pro určení, kdy dochází ke klepání a dále vyhodnocuje tři metody pro určení délky klepání. První z těchto metod vypočítává klepání jako pevně volenou délku ve °KH, dále C-Window, kdy je počátek 10 °KH před největším naměřeným tlakem a zastavuje se 20 °KH za tímto tlakem. Poslední metoda T-Window začíná 20 vzorků před změřeným největším tlakem v motoru a končí 107 vzorků za tímto tlakem. Práce uvádí, že výsledky pro 2 poslední metody jsou ekvivalentní.

Metoda C-window je použitelná i v tomto případě, po přepočtu ° klikového hřídele na počet vzorků. Metoda T-window je použitelná rovněž, je nicméně nutné opět přepočíst počet vzorků při definici metody, kde byla vzorkovací frekvence podle [22] 44,1 kHz, počet vzorků při měření v práci.

6.2. Limitace

V průběhu testování se projeví nedostatky při lokalizaci prvního a posledního válce v pořadí pálení. V těchto oblastech totiž dochází k rušení od synchronizačních značek. Další postup je toto rušení odfiltrovat. Filtrace by však neměla být problematická, vzhledem ke známému průběhu signálu.

6.3. Nepoužité metody

V průběhu hledání použitelných metod bylo vytipováno větší množství metod, z nichž ne všechny vedly k relevantním výsledkům. V této kapitole jsou ve zkratce popsány metody, které nakonec z důvodu nevhodných výsledků nebyly vybrány a zdůvodnění jejich výsledků.


6.3.1. Butterworthův filtr

Zpočátku bylo pro filtraci signálu uvažováno použití Butterworthova filtru. Postup návrhu, výstupy a proč nebyl použit je popsáno v této kapitole. Prvním krokem při návrhu je volba frekvence pálení a rozptyl. Zde je vhodné zmínit, že frekvence pálení není známá. Rovnice (54), které slouží k jejímu odhadu, ale byl navržen až z výstupu po FFT analýze. Výsledky po použití rovnic (2) a (54) byly méně přesné po filtraci, jsou tedy voleny výsledky z metody popsané v kapitole 7.1, z důvodu přesnějších výsledků. Nicméně bude uvažováno, že frekvence pálení a rozptyl jsou známy, resp. vypočteny shodně $f_{firing_calc} = (0,825; 2,475)$ Hz, ty jsou následně normalizovány Nyquistovou frekvencí.

Dalším krokem je volba stupně filtru, v první iteraci je volen 2. stupeň jako kompromis mezi složitostí a strmostí poklesu.


Pro aplikaci je nejprve vypočtena Nyquistova frekvence, ty je určena podle Nyquist-Shannonovy věty jako $f_{vzork} > 2f_{max}$, kde f_{vzork} je frekvence vzorkování, která musí být

alespoň dvojnásobná maximální frekvenci měření, v opačném případě dojde k aliasingu. [17] V případě signálu, získaného z motoru je vzorkovací frekvence 22 050 Hz a největší možná měřená frekvence je tedy její polovina 11 025 Hz. Následně jsou vypočteny hodnoty parametrů „a“ a „b“, tedy čitatele a jmenovatele přenosové funkce, možné je také vypočíst nuly a póly a pracovat s nimi. Dále jsou vypočteny úhlové frekvence $w = \omega$ frekvenční přenos $h = T(s) = (H(s))$. Následně jsou zobrazeny grafy. Metoda je testována na signálu (1), stejně jako FFT, výsledky jsou na grafech níže.



Graf 4 – porovnání originálního signálu a filtrovaného signálu pomocí Butterworthova filtru

Graf 4 zobrazuje výstup použití Butterworthova filtru 2. řádu na signál z motoru. Výstupem je závislost indexu (i) na amplitudě (dB). Pouze filtrovaný signál je zobrazený na grafu 5.



Graf 5 – Filtrovaný signál pomocí Butterworthova filtru


Z grafu je patrné, že využití filtru je možné. Pálení by mělo začínat v okolí indexu 300, kde je možné pozorovat změnu amplitudy, ta je však relativně malá a bez přechodí znalosti začátku pálení by nebylo snadné jej odhalit. Výstupy z aplikace Butterworthova filtru mohou být způsobena ostrotí poklesu filtru. Signál obsahuje velké množství interferencí, které může být i ve frekvencích pálení a frekvencích v okolí pálení, tedy frekvencích, které jsou nechány v propusti. Tyto frekvence jsou rozšířeny o frekvence, které projdou přes filtr v důsledku strmosti poklesu. Jako řešení by se nabízelo zúžit pásmo propusti. Protože, ale frekvence pálení není známa a zároveň se může jednat o rozptyl, je vhodnější toto pásmo nechat spíše širší.

6.3.2. Chebyshevův filtr

Po zvolení nepoužití Butterworthova filtru, byl zvažován Chebyshevův filtr, který má podle teorie strmější hranu poklesu a měl by tedy signál filtrovat v tomto ohledu přesněji. Postup návrhu Chebysheva filtru je podobný s postupem u Butterworthova filtru. Prvním krokem je opět volba pálicí frekvence a rozsah pásmové propusti. Odhad pálicí frekvence je udělán na základě výsledku z FFT analýzy. Při návrhu filtru nebyla známa pálicí frekvence, v této kapitole je ilustrován postup volby v momentě, kdy frekvence, resp. její rozsah je znám. Frekvence jsou voleny shodně $f_{firing_calc} = (0,825; 2,475)$ Hz.


Dále je volen řád filtru, stejně jako u Butterworthova je zvolen 2. řád. Poté je určena Nyquistova frekvence stejně, podle Nyquist-Shannonovy věty jako $f_{vzork} > 2f_{max}$, kde $f_{vzork} = 22\,050$ Hz. Nyquistova frekvence je následně využita pro normalizaci signálů

pásmové propusti spodní i horní. Poté je zvolena hodnota R_{dB} , která je volena v db jako 0,5 dB. Metoda je testována opět na signálu (1). Níže jsou grafy s výsledky



Graf 6 – porovnání originálního signálu a filtrovaného signálu pomocí Chebysheva filtru

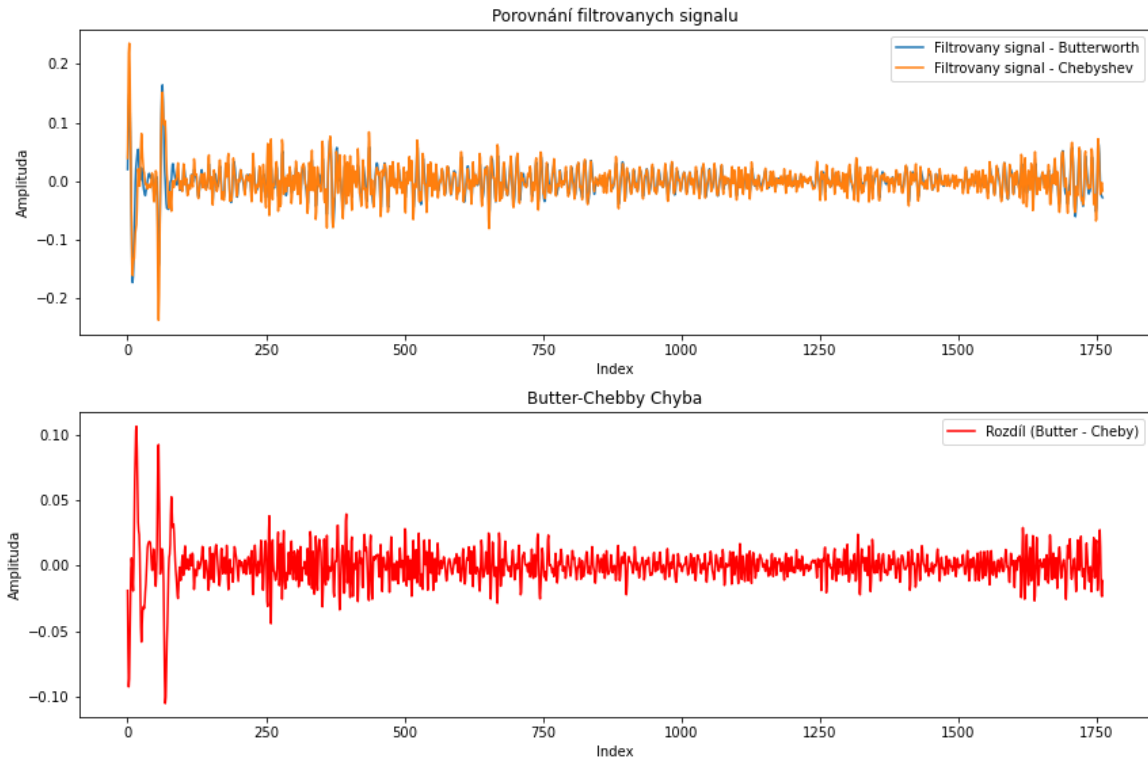
Graf 6 zobrazuje aplikaci Chebysheva filtru na signál z motoru. Na grafu je ukázána závislost indexu (i) signálu na amplitudě (dB). Samostatný výstup Chebysheva filtru je poté ukázaný na grafu 7.



Graf 7 – Filtrovaný signál pomocí Chebysheva filtru

Výstup je zde obdobný jako u Butterworthova filtru, možná i horší, ve smyslu horší identifikace. Graf 7 ukazuje, že pro identifikaci pálení není vhodný. V okolí indexu 300 je vidět nárůst amplitudy, není to však dostatečné pro identifikaci začátku pálení. Volba nepoužití filtru může být opět způsobena prostupem frekvencí v pásmu přechodu filtru. V případě Chebysheva filtru vstupuje hry i volba velikosti amplitudy šumu v pásmu propusti.

Na obrázku 12 je porovnání obou metod, kde je pozorovatelné, že metody dávají velmi podobné výsledky.



Obrázek 12 – Porovnání a rozdíl filtrovaných signálů Butterworth – Chebyshev

Z obrázku 12 je patrné, že přes rozdíly v metodách jsou výsledky podobné, liší se v jednotkách procent. Velké rozdíly jsou viditelné na začátku a konci signálu, kde dochází k rušení vlivem synchronizační značky.


6.3.3. LNU

Metoda LNU byla uvažována pro použití pro identifikaci anomálie v signálu. Záměrem bylo naučení metody na signálu (1) a následné použití na signál (2). Předpoklad byl, že změna v signálu proběhne pouze v části pálení a ostatní části zůstanou relativně bez změny, respektive, že změna v signálu bude v oblasti pálení signifikantněji větší než změna v ostatních částech cyklu. Tato skutečnost by se poté měla promítnout na zobrazení chyby metody a tím vykreslit kde dochází k pálení.

V tomto případě je jako velikost vstupního vektoru x volena délka signálu (1). Učení následně probíhá na délce signálu (1) a signál (5) je potom zkoumaný. Zkoumaný celý signál, na nějž je aplikována LNU je potom součet 2 signálů (1) a 1 signálu (5). Tyto signály jsou na začátku upraveny odečtením hodnot středních hodnot pro získání jemnějšího průběhu. Hodnota μ je volena 0,6. Výsledek je vidět na obrázku 13

$$signal(i) = signal(i) - mean(signal(i))/3, \quad (56)$$

$$signal(LNU) = 2 \cdot signal(1) + signal(5). \quad (57)$$



Obrázek 13 – Aplikace LNU na kombinaci signálů (1) a (5)


První graf v obrázku 13 ukazuje závislost vzorku (k) na amplitudě (dB). V grafu jsou vykresleny dvě hodnoty a to změřená (modře) a vypočtená neuronem (zeleně). Druhý graf vykresluje jejich rozdíl.

Výsledky metody nebyly využity z důvodu neprůkaznosti, která je způsobena řadou faktorů. Prvním z nich je podobna signálu, která je odlišná s každou iterací. I pokud by se LNU bylo schopno naučit za 1 dobu délky signálu (1) jeho podobu, signál (5) je natolik odlišný, že by nebylo možné pozorovat změny. Byl zkoušena metoda, kdy pro učicí část bylo použito 5 vzorků (1), ale metodu stejně nebylo možno využít, kvůli velkým rozdílům v signálu. Ty jsou způsobeny celkovou změnou chování motoru. V případě vefuku plynu do motoru dochází ke změně v celém spektru.

Další ideou bylo použití na jeden signál (1) s délkou vektoru x odhadnuto. Odhad by probíhal po větším kroku např. 100 a ve chvíli překročení pálení by v dalším kroku mělo být viditelné. LNU by se totiž učilo na signálu bez anomálie. V dalším kroku by anomálie měla

být patrná. V tomto případě je známo, že začátek pálení je v indexu 300 a jeho doba je 190. Délka vektoru x je tedy volena 500 a je aplikována na signál tvořený ze dvou signálů (1). Koeficient učící rychlosti je volen stejně jako v minulém případě $\mu = 0,6$. Výsledek je ukázán na obrázku 14

$$signal(LNU) = 2 \cdot signal(1). \quad (58)$$



Obrázek 14 – Aplikace LNU na signál (1)

Z obrázku 14 je patrné, že tento přístup je vhodnější, v okolí indexu 2000 až 2300 je vidět větší rozdíl hodnoty predikované neuronem a reálné. V tomto nastavení by nicméně bylo velmi složité odhadnout začátek pálení, a proto ani tato metoda není zvolena.

7. Rozlišení klepání

Vytvořit univerzální algoritmus pro detekci klepání pouze ze zvukového signálu je velmi složité. Problémů je zde několik, kromě již naznačených, je největším z nich rozdílná charakteristika projevu různých motorů. Rozdíly jsou patrné již v provozu motoru v naftovém režimu. Duální provoz tyto rozdíly dále prohlubuje. Tyto rozdíly mohou být způsobeny jak konstrukcí motoru, tak jeho stavem ale i např. okolními podmínkami (typově teplota sacího vzduchu), a dalšími faktory. Cílem je tedy vytvořit algoritmus, který bude dostatečně robustní, a bude mít možnosti parametrizace pro jednoduchou úpravu a přizpůsobení se těmto změnám. Stejně jako u jiných dílčích úloh je na začátku vysvětlení teorie.


Během hledání metody pro rozlišení klepání bylo vybráno množství metod, z nichž ty s relevantními výsledky jsou zde popsány.

7.1. Metodika a testovací signály

Navržené metody jsou voleny na matematickém základu, anebo zkušeností. Ověření jejich použitelnosti je uvedeno na 3 signálech z motoru (6), (7), a (8). Z nichž jeden je při provozu bez klepání a druhý je při provozu motoru s lehkým klepáním a poslední je při provozu s těžkým klepáním.

Signál je oříznut pomocí synchronizační značky tak aby obsahoval pouze jeden cyklus. Signál tedy vždy obsahuje přesně jedno pálení. Pro zpřesnění není pro metody volen celý cyklus, ale pouze vybraný úsek, kdy dochází k pálení, a přidaný přesah, kde je pozorovatelná změna signálu ve spektrogramu. Volba délky je na základě délky a intenzity frekvence ze spektrogramu.

Vybrání úseku je určeno parametry `start_sample` a `length`. Popsaný proces provádí funkce `wav_to_csv_cut(Function_Sound_to_CSV_cut.py)`. Funkce je navržena tak, aby navazovala na první úlohu. Vyhodnocení signálu provedeno v programu `Vyhodnoceni_klepani.py`. Níže je pro ilustraci uveden graf jednoho signálu a jeho úprava.



Obrázek 15 – Ilustrace výběru vyhodnocovaného signálu

První graf na obrázku 15 zobrazuje závislost vzorku (k) na amplitudě (dB) v celém záznamu čtyř cyklů jednoho válce. Druhý graf zobrazuje vybranou část.

7.2. MEL Spektrogram

První metodou, jejíž výstupy jsou využity i v metodách dalších je převedení zvukového záznamu na spektrogram. Tato metoda se využívá i při manuálním vyhodnocení klepání motoru.

Spektrogram je vytvořen za pomoci knihovny Librosa, ta je popsána v [23]. Ta nabízí možnost vytvořit spektrogram ze zvuku za pomoci nadefinování několika parametrů. Parametry, které byly využity při tvorbě spektrogramu jsou popsány níže.

n_fft – délka okna FFT, hop_length – počet vzorků mezi po sobě jdoucími snímky, win_length – každý snímek zvukového záznamu je zpracován funkcí $window()$, délka okna je definována parametrem win_length a následně doplněna nulami tak, aby odpovídala délce n_fft . Platí, že $win_length \leq n_fft$. [23] Parametry jsou voleny empiricky a co nejjemněji při zachování určité výpočetní rychlosti, $n_fft = 1024$, $hop_length = 2$, $win_length = 512$.

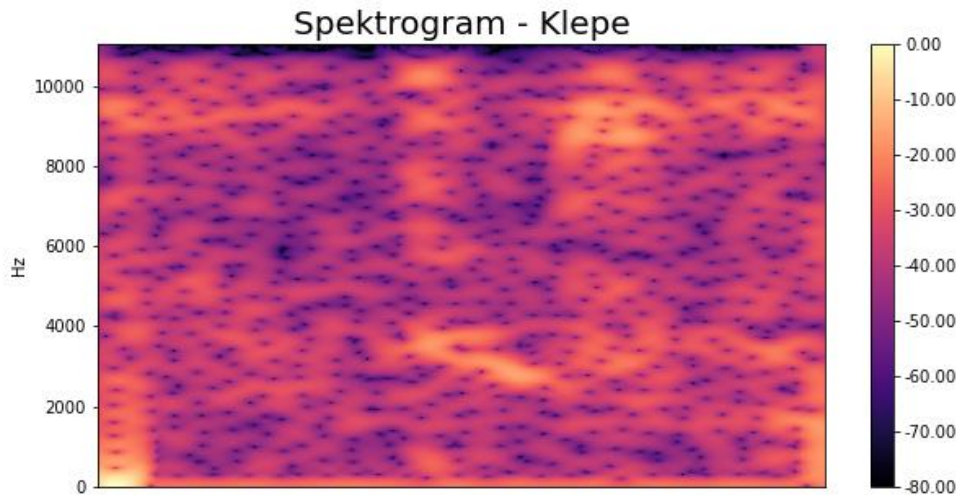
Výstupem ze spektrogramu je vypočtená matice $X(m, k)$ (STFT). Toho je docíleno funkcí $librosa.stft()$, která rozdělí signál do překrývajících se oken, podle definovaných parametrů a vytvoří matici s komplexně sdruženými čísly

$$X(m, k) = \sum_{n=0}^{win_length-1} x[n] \cdot w[n - m \cdot hop_length] \cdot e^{-i2\pi \frac{kn}{n_fft}}, \quad (59)$$

kde $X(m, k)$ je matice STFT, $x[n]$ je n -tý element vstupního signálu, m je index snímku, n je index vzorku uvnitř snímku a k je index koše frekvence.

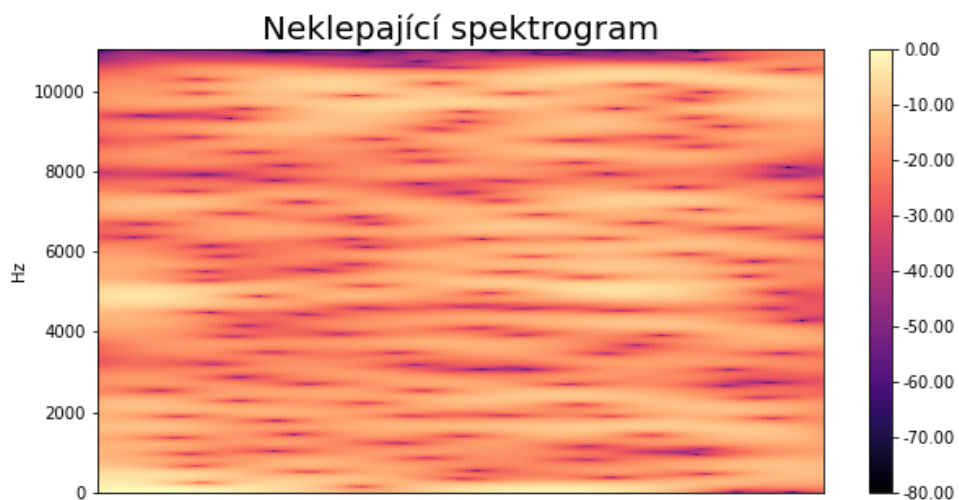
Následně proběhne extrakce reálných složek, výpočet síly, respektive četnosti frekvence v signálu a tvorba spektrogramu. Před vizualizací je spektrogram převeden do logaritmického měřítka a následně zobrazen

$$SG_{dB}(t, f) = 10 \cdot \log_{10} \left(\frac{SG(t, f)}{\max(SG(t, f))} \right). \quad (60)$$

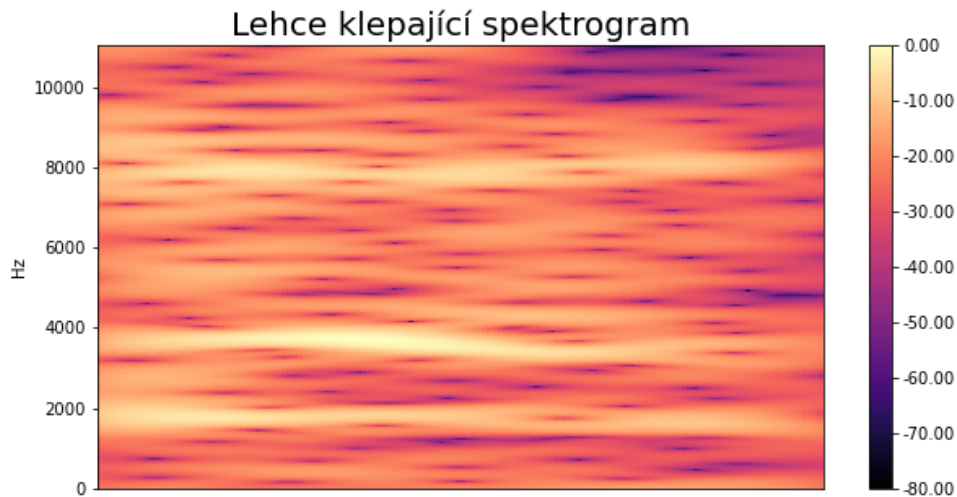


Obrázek 16 – Spektrogram záznamu se silným klepáním, neupravený signál (6)

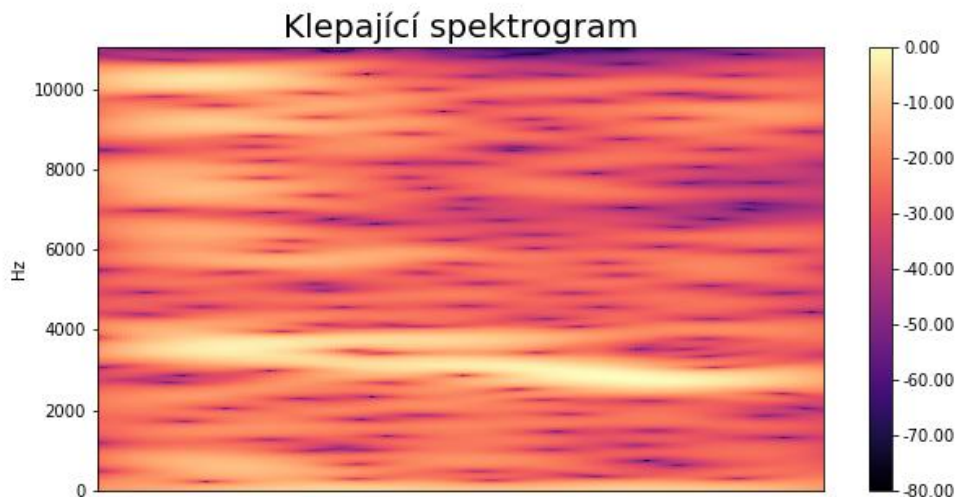
Obrázek 16 ukazuje záznam všech 4 cyklů s viditelným silným klepáním, ve zobrazení spektrogramu.



Obrázek 17 – Spektrogram záznamu bez klepání, upravený signál (8)



Obrázek 18 – Spektrogram záznamu s lehkým klepáním, upravený signál (7)



Obrázek 19 – Spektrogram záznamu se silným klepáním, upravený signál (6)

Obrázky 17 – 19 ukazují 3 stavy provozu v detailu, na vybrané části zvukového záznamu. Na ose x je index (i), na ose y je frekvence a barva zobrazuje četnost frekvence podle měřítka na pravé straně. Vzorky jsou seřazeny od neklepajícího signálu, po signál silně klepající, je možné pozorovat nárůst četnosti v oblasti určené jako klepající.

7.3. PCA

Metoda analýzy hlavních komponent je popsána v teoretické části práce. V této kapitole je vysvětlena aplikace na nahrané signály. Výchozím bodem je předpoklad, že v signálu vzniknou nové dominantní frekvence, které by metoda PCA měla být schopna odhalit a na tomto základě definovat anomálie chování motoru. Mělo by tedy dojít k odhalení klepání

$$\mathbf{covX} = \frac{1}{N} \sum_{i=1}^N (\mathbf{x}_i - \bar{\mathbf{x}}) (\mathbf{x}_i - \bar{\mathbf{x}})^T, \quad (61)$$

$$\mathbf{covX} = \mathbf{X}_{real} \cdot \mathbf{X}_{real}^T, \quad (62)$$

kde \mathbf{covX} je kovarianční matice, \mathbf{X}_{real} je matice reálných složek získaná pomocí STFT. Následně se vypočtou vlastní čísla a vlastní vektory podle [24], [25] za užití rovnic (63) a (64)

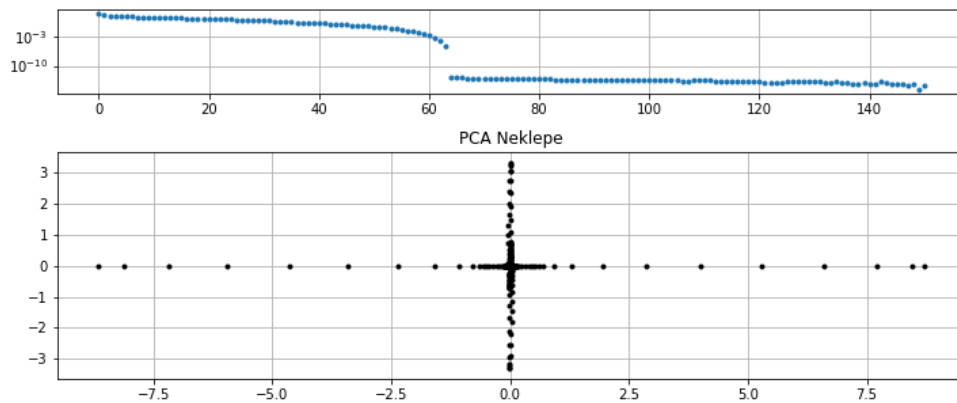
$$\mathbf{covXV} = \mathbf{VD}, \quad (63)$$

kde \mathbf{V} je matice vlastních vektorů a \mathbf{D} je diagonální matice vlastních čísel.

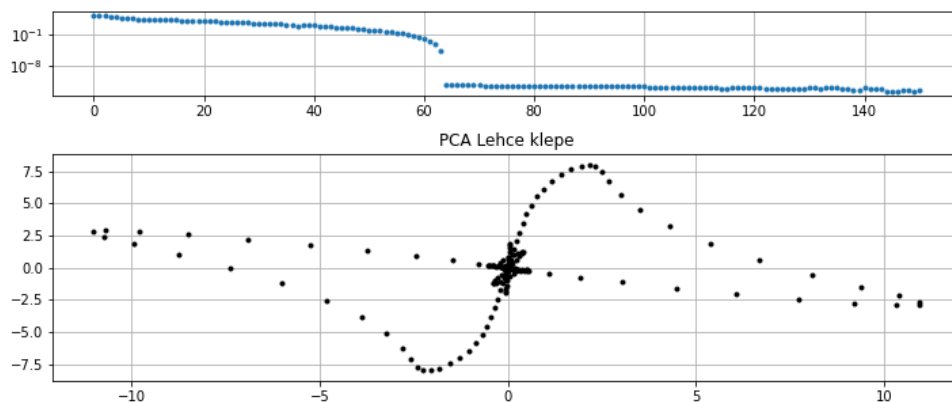
Projekce dat je následně určena volbou počtu hlavních komponent. Testy ukázaly, že první 2 komponenty jsou pro určení klepání nejdůležitější

$$\mathbf{X}_{pca} = \mathbf{covX} \cdot \mathbf{V}_{proj}, \quad (64)$$

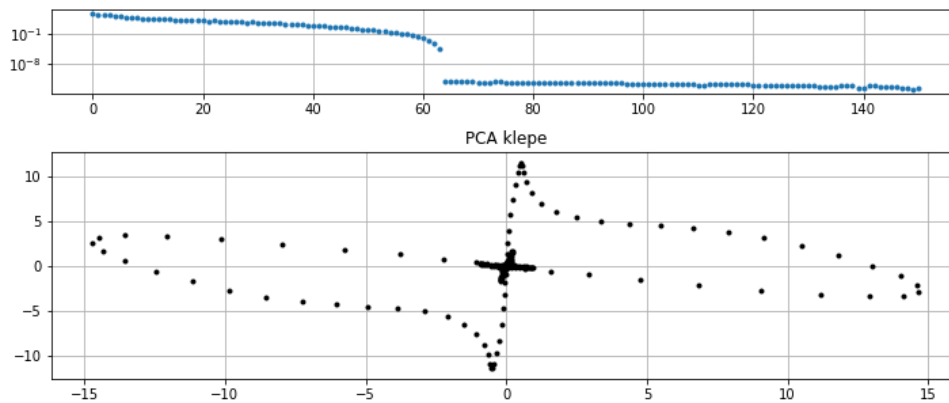
kde \mathbf{X}_{pca} jsou data v redukovaném prostoru a \mathbf{V}_{proj} obsahuje pouze zvolené vlastní vektory, resp. komponenty. Na obrázcích 20-22 jsou pozorovatelné rozdílné výsledky, které metoda PCA dává na signálu z klepajícího válce a na signálu z neklepajícího válce.



Obrázek 20 – PCA neklepajícího signálu



Obrázek 21 – PCA lehce klepajícího signálu



Obrázek 22 – PCA klepajícího signálu


Obrázky 20 až 22 zobrazují tři signály od neklepajícího po silně klepající. Každý obrázek obsahuje dva grafy, kde první zobrazuje významnost hlavní komponenty a druhý zobrazuje data matice X_{real} zobrazené na hlavních komponentách, kdy osa x je první hlavní komponenta a osy y je druhá hlavní komponenta.

7.4. SVD

Singulární rozklad popsán v [14] (Singular Value Decomposition) je další z metod, která vedla k použitelným výsledkům. Metoda stejně jako PCA pracuje s reálnou složkou prvků matice získané z STFT. Matice X_{real} je rozložena na matice U, Σ, V , algoritmu je využita knihovna `sklearn.decomposition`, a její funkce `TruncatedSVD()`, tedy zkrácené SVD, a produktem jsou zkrácené matice $\tilde{U}, \tilde{\Sigma}, \tilde{V}$

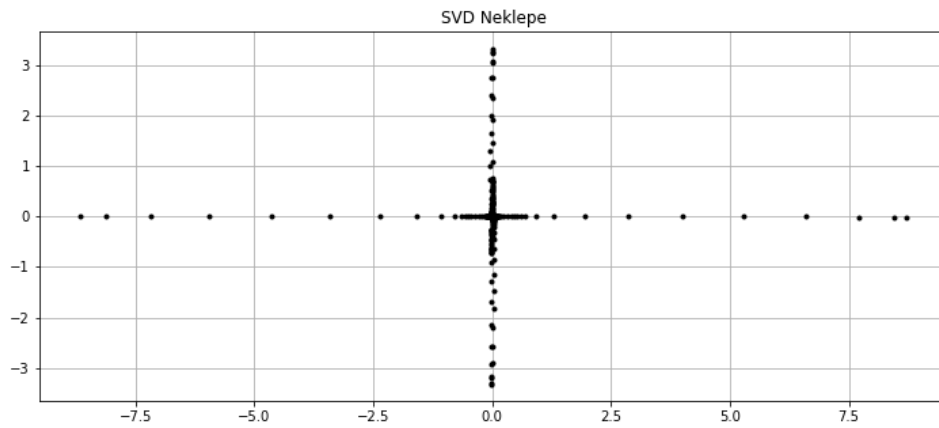
$$X_{real} = \tilde{U} \tilde{\Sigma} \tilde{V}^*, \quad (65)$$

$$X_{svd} = X_{real} \tilde{V}. \quad (66)$$

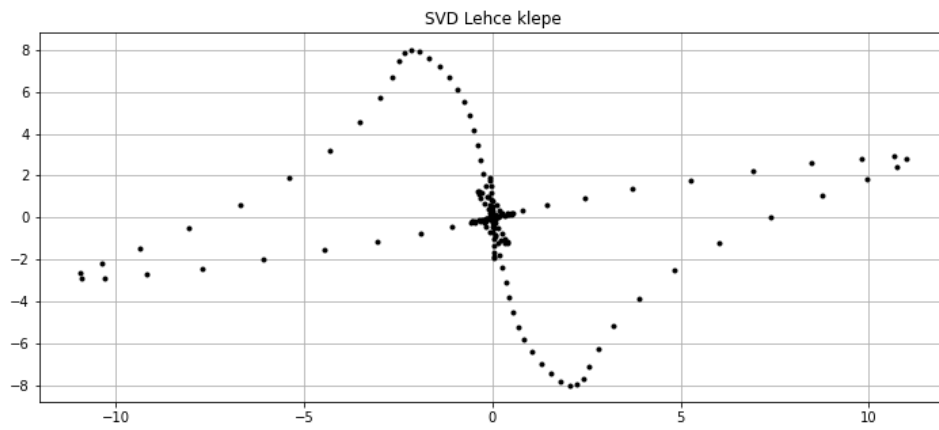


Obrázek 23 – Porovnání SVD a zkráceného SVD [14]

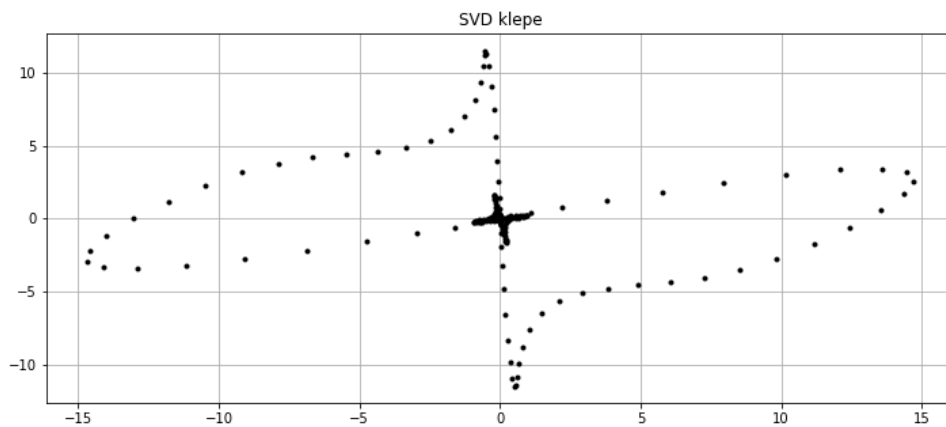
Volba nastavené SVD je podle [26]. V případě použité funkce se definuje počet komponent matice Σ , se kterými se bude pracovat, tedy zkrácená matice $\tilde{\Sigma}$. V tomto případě jsou zvoleny $n_components = 2$, shodně jako v případě PCA, algoritmus vezme první 2 hodnoty z matice Σ , které odpovídají nejvyšším hodnotám. X_{svd} potom promítá data v takto redukovaném prostoru. Každý řádek X_{svd} odpovídá souřadnicím bodu v redukovaném prostoru. Korelační diagram potom vykresluje rozmístění bodů v tomto upraveném prostoru. Osy X a Y reprezentují hlavní komponenty. Parametr $n_iter = 7$, určuje počet iterací náhodného řešitele SVD. Poslední parametr $random_state = 42$, je využit k získání stejných výsledků při různých průbězích programu.



Graf 8 – Korelační diagram SVD neklepajícího signálu



Graf 9 – Korelační diagram SVD lehce klepajícího signálu



Graf 10 – Korelační diagram SVD neklepajícího signálu

Grafy 8-10 zobrazují tři signály od neklepajícího k silně klepajícímu. Grafy zobrazují data matice X_{svd} na redukovaném prostoru dvou komponent získaných z SVD.

7.5. Diskuze vyhodnocení klepání

Grafy PCA i SVD popisují vzdálenost prvků od hlavních komponent, které tvoří osy grafů. Z grafů je patrné, že ve chvíli, kdy je klepání přítomné, se hlavní komponenty změní. Je to dáno tím, že klepáním se zvýší intenzita a četnost určitých frekvencí. Ty do této doby mohly, a s největší pravděpodobností i byly, součástí záznamu, nebyly však tak četné. Tím, že dojde ke změně hlavních komponent, dojde i ke změně vzdálenosti jednotlivých bodů, reprezentujících jednotlivé frekvence. Jejich vzdalování se od hlavních komponent pak lze interpretovat jako vznik anomálie v signálu a tedy klepání.

Tento návrh na identifikaci klepání vychází z odhadu, že při klepání budou vždy dominantní frekvence v okolí vypočtené klepající frekvence. Zde vystává několik potenciálních problémů. Prvním z nich je, pokud bude frekvence klepání podobná frekvenci pálení. Stejně jako u identifikace začátku pálení i zde, bude tato skutečnost znesnadňovat práci se signálem. Řešení by mělo být relativně snadné. Přesto, že pálicí frekvence bude podobná frekvenci klepání, nebude tak intenzivní a hlavní komponenty by měly být určeny jinak při klepajícím a neklepajícím provozu. V tomto případě by měla metoda fungovat, avšak s menšími odchylkami. Proto je nutné sledovat více vzorků a limity nastavovat na základě pozorování.


Dalším problémem při identifikaci klepání mohou být rušivé frekvence. Docházet k nim může v případech, kdy signál bude obsahovat množství rušivých frekvencí, jejichž intenzita bude vysoká a nezávislá na změně paliva. Například pokud bude signál zaznamenávat rušení ve vyšších frekvencích ve všech konfiguracích paliva a jeho intenzita bude vyšší, než intenzita frekvence klepání, budou hlavní komponenty vypočteny stále stejně a nedojde ke změně. Řešením je odfiltrovat tyto frekvence. Zjištění, že je v signálu rušení o velké intenzitě je možné vyčíst ze spektrogramu.

V případě, že budou klepající frekvence mimo ty odhadované, se může stát, že nebude jasné, co se děje. Nicméně algoritmus by měl zachytit zvyšující se frekvenci a odhalit, že dochází k anomálii. Bude totiž stále docházet k nárůstu intenzity určitých frekvencí, a tedy ke změně hlavních komponent.

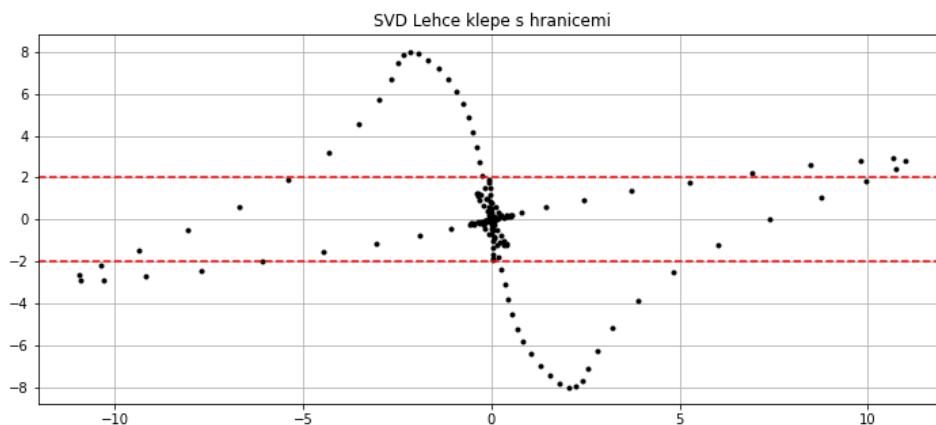
Obě metody jsou velmi úzce závislé na správnosti volby okna pro výpočet, tedy volby, kdy probíhá pálení. V případě že okno vyhodnocení je zvoleno špatně, vstupují do výpočtu nadbytečné frekvence a výsledný výpočet může být nevyhovující, případně zavádějící.

Pro identifikaci klepání je nutné analyzovat všechna dostupná data, v tomto případě jak spektrogram, tak PCA a SVD a hledat odchylky, zároveň je nutné porovnávat různé konfigurace paliva s výchozím naftovým provozem.

V prezentovaném příkladu je patrné, že změnou signálu dochází ke změně hlavních v míře, že se další frekvence vzdalují od hlavních komponent o téměř pětinasobek. Přestože je v názvu grafu i signálu použit termín lehké klepání, jedná se pouze o odlišení vzorků. Veškeré klepání je nebezpečné, a proto jsou hranice nastaveny na dvounásobku naftového provozu. Ideální by bylo nastavit je podle posledního bezpečného provozu.



Graf 11 – PCA s hranicemi



Graf 12 – SVD s hranicemi

Grafy 11 a 12 odpovídají grafům popsaných v kapitolách 7.3 a 7.4 s rozdílem, že jsou doplněny o pomyslnou hranici od kdy je řečeno, že se jedná o klepání. Tato hranice je vhodná pro typ motoru na němž je navržena.

PCA Neklepající		PCA Lehce Klepající		PCA Klepající	
Hlavní komponenta	Hodnota	Hlavní komponenta	Hodnota	Hlavní komponenta	Hodnota
1	582,8581	1	1947,6438	1	3937,3227
2	1332,46	2	1452,5128	2	2534,0788
...		
151	1,64E-15	151	1,86E-14	151	1,91E-14

Tabulka 2 – Hodnoty Hlavních komponent v různých konfiguracích

Z tabulky 2 je patrné, že ve klepajícím vzorku dochází k dosažení klepající frekvence 3,3 kHz i k přesažení. U lehce klepajícího vzorku jsou sice hodnoty pod úrovní klepající


frekvence, nicméně je důležité i porovnání s naftovým provozem (Neklepající vzorek). Zde je patrný velký nárůst, který by měl vést k obezřetnosti.

7.6. Lokalizace anomálie pomocí LNU


Dalším přístupem pro lokalizaci anomálie, a tedy potenciálního klepání je využití LNU. Neuron je v tomto případě natrénován na signálu frekvenčního spektra neklepajícího motoru. Po dokončení trénování jsou uloženy váhy a je použit pro lokalizaci anomálií na zkoumaném signálu.

Velikost vstupního vektoru x je zvolena jako počet záznamů v FFT signálu (1). Učení poté probíhá, dokud není chyba modelu dostatečně malá. V tomto případě je zvoleno 8 cyklů. Signál pro učení je normalizován podle rovnice (67). Obrázky 24 a 25 zobrazují frekvenční spektrum klepajícího a neklepajícího signálu. Obrázek 26 poté zobrazuje učení neuronu

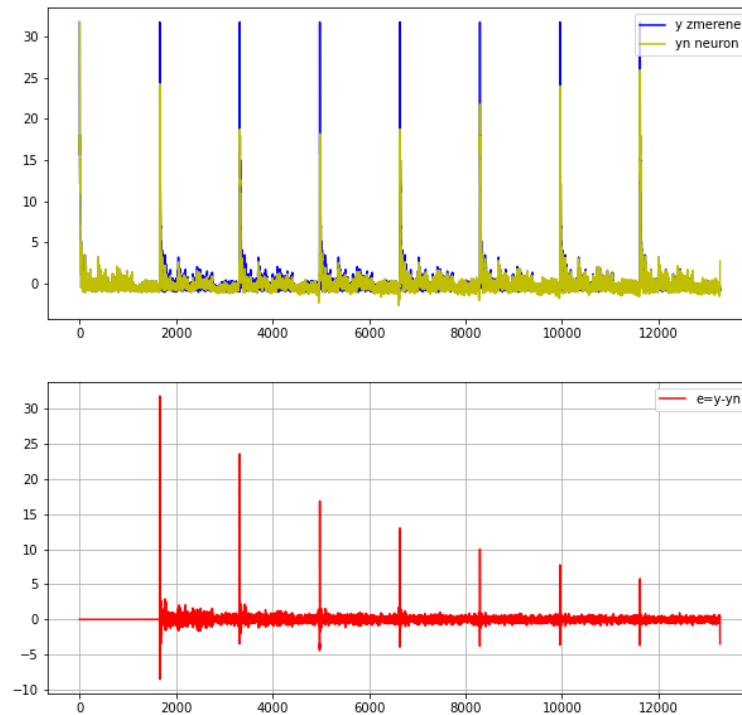
$$signal(FFT_i) = signal(FFT_i) - mean(signal(FFT_i))/3. \quad (67)$$



Obrázek 24 - FFT neklepajícího signálu




Obrázek 25 – FFT klepajícího signálu



Obrázek 26 – Postup učení neuronu

Výhoda využití neuronu je, že se adaptuje na nový signál, tím pádem jsou odhalené odchylky v signálu velké. Takové jsou při hledání klepání klíčové. V případě malé odchylky může jít o změnu chování motoru nikoliv však o klepání. Lokalizace klepání je ukázána na obrázku 27. Hranice je zde zvolena na základě znalosti, že v novém signálu, klepe. Pro použití v praxi by bylo vhodné tuto hranici otestovat na více vzorcích a ověřit.




Obrázek 27 - Detekce anomálie v klepajícím signálu

Obrázek 27 obsahuje tři grafy, kde první zobrazuje závislost frekvence (Hz) na amplitudě (dB) u změřeného signálu a signálu vypočteného za pomoci LNU. Druhý graf zobrazuje průběh chyby změřeného signálu a signálu vypočteného. Poslední graf je přiblížením druhého grafu. V grafech jsou vytyčeny hranice, kde je očekávána klepající frekvence a hranice jejíž překročení signalizuje klepání. Opět platí, že hranice je platná pouze na motoru na němž je navržena.

8. Návrh predikce a rekonstrukce signálu


V této fázi, je známa doba pálení a je připraveno vyhodnocení klepání. Jak již bylo popsáno, motor není výhodné dostávat do oblasti klepání, pokud je to možné, ani na omezený čas. V poslední části je řešena problematika predikce podoby dalšího signálu. V tomto případě je cílem vytvořit odhad, který bude následně použitelný jako vstupní signál pro rozlišení klepání. Vzhledem k tomu, že pro určení klepání je důležitá především frekvence je navržen model, který počítá predikci frekvencí za pomoci modelu ARIMA. Frekvenční spektrum je následně za pomoci inverzní Fourierovy transformace a známého vzorkování převeden na signál v časové oblasti, který může být použit pro vyhodnocení klepání.

Frekvence je určena za využití 2 metod, a to interpolace a modelu ARIMA. První komplikací je fakt, že získaná data jsou z omezeného množství % duálního provozu, v prezentovaném případě (0 %, 20 %, 40 %, 42 %, 43 %), tedy vzorky (1) až (5). Na řadu tedy nelze momentálně nahlížet jako na časovou a ve výchozím bodě nelze aplikovat metodu ARIMA. Na aproximace takovéto řady by bylo v teorii možné využít např. metod interpolace, resp. extrapolace, případně polynomiální extrapolace n-tého řádu. V praxi však tento přístup není použitelný, protože závislost není lineární v celém spektru a nemusí být ani popsitelná jednoduchou křivkou. Průběh frekvencí je viditelný na grafu 13.



Graf 13 – Závislost vybraných frekvencí na % plynu ve směsi

Graf ukazuje, jaká je závislost amplitudy na frekvenci v různých konfiguracích směsi paliv a je z něj patrné, že chování není lineární. Aby bylo možné využít metodu ARIMA, je nutné z naměřených hodnot vytvořit časovou řadu. U vytvoření časové řady došlo ke zjednodušení. Z důvodu časových a ekonomických úspor je možné, že změřených bodů bude v reálném provozu v průběhu ladění substituce pouze omezené množství. Dopočet chybějících bodů je realizován pomocí interpolace. Výsledek je vidět na grafu 14.



Graf 14 – Interpolovaná data pro frekvenci 3600 Hz

Přesnost modelu odhadu dalšího bodu se bude zpřesňovat s počtem naměřených hodnot. Pro ilustraci, je uveden výpočet a volba koeficientů na jedné časové řadě.

Prvním krokem je určení, jestli se jedná o stacionární či nestacionární časovou řadu. Pro výpočet je zvolen ADF test (Augmented Dickey-Fueller) [27], ve výchozí hypotéze tvrdí, že časová řada je nestacionární, pokud je koeficient p nižší než úroveň významnosti (0,05) je hypotéza vyvrácena a jedná se o stacionární řadu.


K tomu je využita knihovna *statsmodels.tsa.stattools*, její popis je v [28]. Výstup je pozorovatelný na obrázku 28, kde je viditelné, že se jedná o nestacionární časovou řadu. V případě, že se jedná o nestacionární řadu je vhodné diferenciovat, standardně se používá 1. nebo 2. řád.

```

time_series_data = pd.read_csv('Interpolovane_frekvence_3600Hz.csv', header=None, squeeze=True)
ADF Statistic: 2.925846007641077
p-value: 1.0
Critical Values: {'1%': -3.6055648906249997, '5%': -2.937069375, '10%': -2.606985625}
  
```


Obrázek 28 – Výstřižek konzole, určení nestacionarity

Dalším krokem je výpočet autokorelace. Její výsledek je následně využit pro identifikaci modelu, resp. jeho části. Cílem, aby byl model funkční, je vidět pozitivní korelaci, pro posledních N vzorků. V tomto případě je jich voleno 10.




Graf 15 – Autokorelace předchozích 10 vzorků

Z grafu 15 je pozorovatelná pozitivní autokorelace se 3 významnými vzorky. Tato hodnota je využita jako první volba pro řád klouzavého průměru. Dalším krokem je poté určení částečné korelace.



Graf 16 – Částečná korelace předchozích 10 vzorků


Z částečné korelace je pozorovatelná opět pozitivní autokorelace, v tomto případě jsou významné 2 prvky. Tato hodnota je volena jako řád autoregrese podle [28]. Výsledný model má tedy podobu ARIMA (2,1,3). V tomto příkladu jsou predikovány 2 hodnoty.



Graf 17 – Předpověď ARIMA (2, 1, 3)

Není, zde uvedeno porovnání predikce s reálnou hodnotou. Je to kvůli tomu, že predikci nejvíce ovlivňují poslední body (43 a 44), které jsou zde změřeny. Pokud by ale byly počítány z interpolovaných hodnot predikce se bude lišit více. Stejný proces by následně byl aplikován na predikci amplitud.

Tento postup by následně byl aplikován na všechny frekvence v signálu a následně je rekonstruován do časové oblasti za pomoci vzorkovací frekvence, ta je použita stejná jako u nahraných signálů.

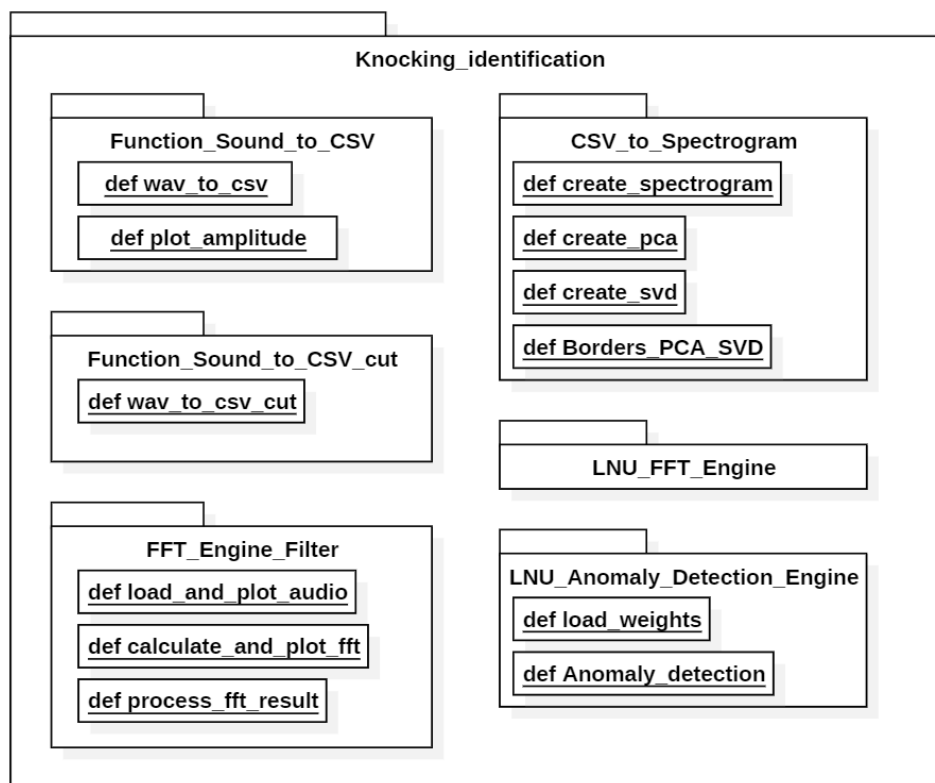


Obrázek 29 – Rekonstrukce jednoduchého signálu

Obrázek 29 popisuje na čtyřech grafech navrženou metodu pro rekonstrukci signálu. Z obrázku 29 je viditelné, že rekonstrukce jednoduchého rušeného signálu funguje s minimální chybou, vzorkovací frekvence je zde použita $s_r = 1000 \text{ Hz}$ a největší měřená frekvence je $f_{max} = 150 \text{ Hz}$.

9. Navržený algoritmus

V programu Python je vytvořena řada knihoven a funkcí jejichž kombinace vytváří nástroj pro zpracování a přípravu dat. Na těchto datech jsou následně provedeny vybrané operace, které vedou k odhalení klepání v signálu. Algoritmus je v současné chvíli navržen pro určitý typ motoru a je parametrizovatelný, tak aby byl snadno přizpůsobitelný pro jiné motory. Seznam knihoven a funkcí je na obrázku 30 a níže v této kapitole. Využité volně dostupné knihovny jsou numpy, pandas, matplotlib, librosa, sklearn a scipy.



Obrázek 30 – Moduly v navrženém algoritmu

Function_Sound_to_CSV

Knihovna obsahuje funkci `wav_to_csv`, která načte nahraný signál z piezoelektrického snímače z motoru. Tento signál ořízne na začátku po prvním signálu ze synchronizační značky, tím je docíleno, že všechny signály mají stejný začátek. Pro správnou funkčnost je nutné znát vzorkování signálu. Funkce toto vzorkování vypočte a vrátí. Toto vzorkování je následně využito pro převod signálu do .csv. Cílem funkce je získat data pro testování a návrh parametrů v další části programu.

Druhá funkce je `plot_amplitude`, která je využita pouze pro vytištění grafu signálu pro ověření, že se jedná o správný signál.

Function_Sound_to_CSV_cut

Tato knihovna obsahuje funkci `wav_to_csv_cut`. Signál nahraný z motoru může obsahovat až několik desítek cyklů. Ty jsou vhodné pro získání většího množství dat pro

testování a validace. V případě, kdy probíhá samotné vyhodnocení, je program zaměřen na jeden konkrétní cyklus, nejprve na celý – sání, komprese, expanze a výfuk. Tento výstup je použit jako vstup pro filtraci a získání vzorku, kde začíná pálení. Dále je funkce využita pro získání pouze části záznamu, kde dochází k pálení, která je využita při vyhodnocení klepání motoru.

FFT_Engine_Filter

Knihovna obsahuje tři funkce, z nichž první je *load_and_plot_audio*, ta je využita pro načtení a vytisknutí hodnot z *wav_to_csv_cut*. Dále funkce *calculate_and_plot_fft* slouží pro vypočtení FFT načteného signálu a jeho vytisknutí. Tento výstup je v první fázi použit k uložení dat o frekvenčním spektru signálu, který bude následně využit pro LNU.

V druhé fázi je tento signál upraven ve funkci *process_fft_result* podle určené hodnoty intervalu frekvence pálení, tak aby odfiltroval ostatní frekvence. Výstupem je graf, ve kterém je vidět počátek pálení. Dále je výstupem graf, který porovnává vstupní signál a rekonstruovaný signál.

Knocking_evaluation

Tato knihovna obsahuje funkci *create_spectrogram*, jejíž vstupem je upravený signál, z funkce *wav_to_csv_cut*, který obsahuje pouze jeden cyklus pálení. Tento signál je převeden na spektrogram a pro kontrolu vytisknut.

Funkce *create_pca* je použita k vypočtení hlavních komponent, jejímu vytištění a dále k vytištění závislosti jednotlivých bodů, reprezentujících dané frekvence od dvou hlavních komponent. Funkce *create_svd* funguje obdobně.

Poslední funkcí je *Borders_PCA_SVD*, která slouží pro definici hranic do kdy není motor v oblasti klepání. Parametry jsou nastaveny na hodnoty 2 a -2. Parametry se mohou v závislosti na chování motoru měnit. V případě, že dojde k případu, kdy je nutné parametry měnit, záleží volba na pozorování motoru v různých konfiguracích. Určení kdy dochází ke klepání lze definovat jako odchylku od naftového provozu a je možnost validovat s funkcí *Anomaly_detection*.

LNU_FFT_engine

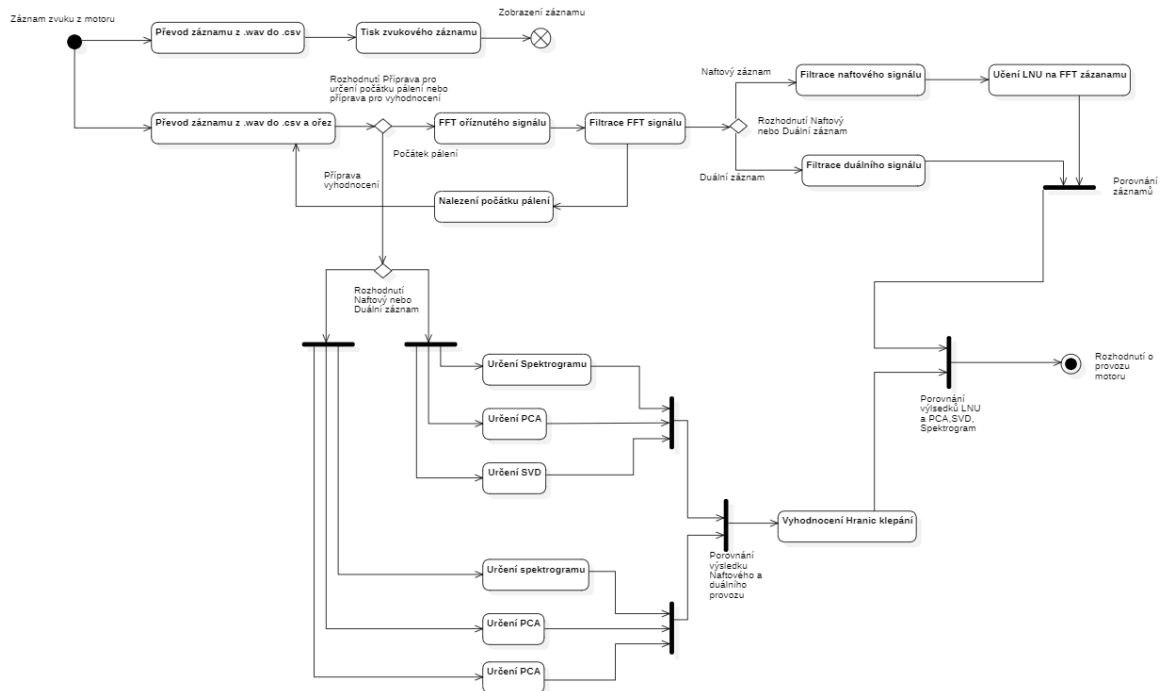
Tato knihovna načítá dříve vytvořený soubor se záznamy frekvenčního spektra z funkce *wav_to_csv_cut*, z první fáze, kdy obsahuje záznam o celém spektru. Tento záznam je získán z naftového provozu. Na něm je natrénován neuron, který bude následně použit pro detekci anomálie na signálu z duálního provozu.

LNU_Anomaly_detection

Knihovna obsahuje funkci *load_weights*, kdy dojde k načtení vypočtených vah z knihovny *LNU_FFT_engine*. Tyto váhy jsou následně využity pro výpočet anomálie v duálním provozu ve funkci *Anomaly_detection*. Knihovna nakonec vrátí graf průběhu

chyby a v případě, že je lokalizována anomálie, vrátí i hlášku o anomálii. Posledním krokem je vyhodnocení výstupu systému technikem.

Návaznost algoritmu je popsána na diagramu aktivit na obrázku 31.




Obrázek 31 – Diagram aktivit

10. Vyhodnocení

V práci je prezentováno množství metod, z nichž pouze některé, byly využity pro navržený algoritmus. V této kapitole je provedeno zhodnocení funkčnosti navržených metod na sadě testovacích vzorků. Testovací vzorky jsou voleny náhodně, aby obsahovaly jak klepající, tak neklepající vzorky, z různých motorů, s různými počátky a délkami pálení. Popis testovacích vzorků a výsledky jsou uvedeny v tabulce 3. Získání výchozích dat k testovacím vzorkům je popsáno na jednom příkladu signálu *Test1* v této kapitole. Testovány jsou metody navržené v algoritmu.

První testovanou hodnotou je počátek pálení, ten slouží k určení počátku klepání. Pro testování jsou známy hodnoty počátku pálení 1862. vzorek a délky pálení 140 vzorků, pro *Test1*. Dalším měřeným parametrem je klepací frekvence ta je u vzorku *Test1* vypočtena z průměru vrtání 159 mm jako 3600 Hz. Poslední veličinou je potom určení, jestli válec klepe, tato veličina je po zjednodušení pozorovatelná z průběhu spektrogramu. U signálu *Test1* je pozorovatelné klepání. Tento signál je následně použit jako vstup do navrženého algoritmu a jsou na něm provedeny popsané operace.

První částí je definice počátku pálení, výsledek je vidět na obrázcích 32 a 33, z kterého je patrné, že počátek pálení je v oblasti na vzorku 1876 a délka je 79 vzorků – rozdíl posledního a prvního vzorku.




Obrázek 32 - Počátek pálení signálu *Test1* pomocí FFT Filtru

```


Reconstructed signal values saved to Test2_knocking.csv
Indices of samples where value > 0.2:
[1876 1877 1889 1890 1902 1903 1955]
  
```

Obrázek 33 – Popis počátku a délky pálení

Další částí je určení doby pálení, v případě, že je pozorovatelná přímo z výchozího signálu, jako zde, je vzata odtud, v opačném případě, je vypočtena podle metod C-window, nebo T-window, popsaných v [22] a následně ověřena porovnáním se spektrogramem. Volba rozsahu a spektrogram jsou vidět na obrázcích 34 a 35.




Obrázek 34 - Originální signál a vybraná část

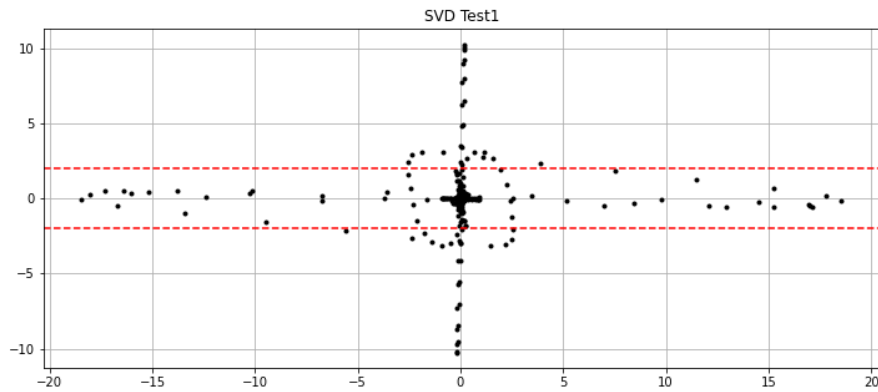


Obrázek 35 - Spektrogram vybrané části

Posledním dílem je určení klepání pomocí PCA a SVD. Metoda LNU je využita pouze v případě, že je k dispozici záznam naftového provozu a je tedy možnost model naučit. Výsledky PCA a SVD jsou na obrázcích 36 a 37. z nich je pozorovatelné, že hranice klepání je překročena. Hranice jsou zvoleny na základě naměřených dat na omezeném množství vzorků, proto je nutné sledovat, jestli jsou v signálu odchylky. Tento postup je aplikován na všechny testované signály, výsledky s grafy jsou dostupné v excelovské sešitu Vzorky_Test



Obrázek 36 - PCA výstup signálu Test1



Obrázek 37 – SVD Výstup signálu Test1

	Vstup	Určeno	Vstup	Určeno	Vstup	Určeno	Vstup	Určeno	
ID	T1		T2		T2		T4		
Název souboru	Test1		Test2		Test3		Test4		
Formát	.wav		.wav		.wav		.wav		
Vrtání [mm]		159		159		159		160	
Klepající frekvence [kHz]		3,6		3,6		3,6		3,6	
Začátek pálení [index]		1862	1876	1750	1772	1315	1366	850	902
Délka pálení [index]		140	79	280	260	158	129	276	124
Klepe	Ano	Ano - PCA	Ano	Mezní - PCA	Ne	Mezní - PCA	Ne	Ne - PCA	
		Ano - SVD		Mezní - SVD		Mezní - SVD		Ne - SVD	

Tabulka 3 – Vyhodnocení testovaných dat

Z tabulky 3 plyne, že metoda pro určení počátku a doby pálení je použitelná, bez větších limitací. V případě, kdy dojde k nepřesnému určení délky pálení, je zde možnost tuto veličinu kontrolovat například metodou C-window, T-window, nebo spektrogramem. Výpočet počátku pálení na testovaných vzorcích funguje. Druhá navržená metoda pro odhalení klepání, funguje s rezervami. Není možné ji v této fázi použít jako samostatné vyhodnocení klepání. Nicméně je využitelná jako pomocný nástroj. Vzhledem k tomu, že cílem nebylo navrhnout samostatný systém vyhodnocení je tato metoda připravena k rozsáhlejším testům a následné implementaci. Poslední část predikce je pouze navržena na simulovaném signálu a je nutno tuto metodu otestovat na reálných vzorcích.

11. Závěr

Problematika klepání motoru je v práci popsána stejně, jako v současné době používané metody jejího vyhodnocování. Vzhledem k povaze používaného systému, tedy snímání zvuku piezoelektrickým snímačem, je v práci prezentován návrh metody postavené na signálu takto získaným. Navržený systém se zabývá třemi hlavními částmi, které je nutné vyřešit pro vyhodnocení klepání. První z nich je identifikace začátku a doby pálení. Druhou částí je rozlišení klepání za pomoci zvukových signálů a znalosti klepající frekvence. V poslední části je následně představen návrh, jak postupovat při predikci signálu další iterace zvýšeného poměru plynu vůči naftě.

V teoretické části práce jsou představeny metody, které jsou v práci dále použity. Jsou zde popsány jejich matematické základy. Jejich aplikace je vysvětlena a prezentována v kapitolách, k nimž se tyto metody vztahují.

Lokalizace a identifikace doby pálení je řešena na začátku práce. Pro vyhodnocení bylo testováno množství metod, mezi nimiž byla filtrace nebo LNU. Jako metoda s nejjednoznačnějšími výstupy byla zvolena metoda za využití FFT analýzy, následně ponechání pouze požadovaných frekvencí a následná aplikace inverzní FFT transformace pro získání signálu pouze s ponechaným frekvenčním pásmem. V tomto signálu je následně možné lokalizovat začátek pálení. V ideálním případě by bylo možné identifikovat i délku pálení, v případě, kdy to možné není je možné využít pomoc spektrogramu, nebo výpočtu.

Rozlišení klepání v případě spolehlivé funkčnosti bude vhodným nástrojem pro optimalizování poměru plynu ku naftě, a tedy ke snižování emisí. Určení klepání je počítáno za pomoci PCA a SVD, kdy jako výchozí bod je vždy brán čistě naftový provoz. Nastavení hranic a správná funkčnost musí být validována s výslednými hodnotami hlavních komponent a spektrogramem.

Návrh predikce je v práci popsán a ukázán na simulovaném signálu. Cílem je odhalit v jakém poměru plynu k naftě dojde ke klepání a vyhnout se tomuto stavu. Zároveň najít stav s největším objemem plynu, který ještě neklepe a zaručuje bezpečný provoz. Tím by bylo docíleno maximálního bezpečného snížení emisí.

Dalšími nezbytnými kroky pro úspěšné nasazení programu jsou nyní otestování navrženého analytického systému na dostatečném množství vzorků a validace jeho funkčnosti. Zejména pak ověření funkčnosti v krajních případech např. pokud je frekvence pálení shodná s frekvencí klepání. Dále aplikace navržené metody pro predikci a stejně jako v minulém kroku její validace. V posledním kroku pro by bylo vhodné vytvořit uživatelsky přívětivé prostředí pro snazší navigaci a práci se systémem.

12. Zdroje

- [1] RITCHIE, Hannah, Pablo ROSADO a Max ROSER. Emissions by sector: where do greenhouse gases come from? *Our World in Data* [online]. 2024 [vid. 2024-01-15]. Dostupné z: <https://ourworldindata.org/emissions-by-sector>
- [2] HEYWOOD, John B. *Internal combustion engine fundamentals*. New York: McGraw-Hill, 1988. McGraw-Hill series in mechanical engineering. ISBN 978-0-07-028637-5.
- [3] ZHEN, Xudong, Yang WANG, Shuaiqing XU, Yongsheng ZHU, Chengjun TAO, Tao XU a Mingzhi SONG. The engine knock analysis – An overview. *Applied Energy* [online]. 2012, **92**, 628–636. ISSN 0306-2619. Dostupné z: doi:10.1016/j.apenergy.2011.11.079
- [4] GRANDIN, Börje a Ingemar DENBRATT. The Effect of Knock on Heat Transfer in SI Engines. In: *SAE 2002 World Congress & Exhibition* [online]. 2002, s. 2002-01–0238 [vid. 2024-01-14]. Dostupné z: doi:10.4271/2002-01-0238
- [5] SHAHLARI, Arsham J. a Jaal GHANDHI. Pressure-Based Knock Measurement Issues. In: *WCXTM 17: SAE World Congress Experience* [online]. 2017, s. 2017-01–0668 [vid. 2024-01-12]. Dostupné z: doi:10.4271/2017-01-0668
- [6] SHAHLARI, Arsham J. a Jaal B. GHANDHI. A Comparison of Engine Knock Metrics. In: *2012 Small Engine Technology Conference & Exhibition* [online]. 2012, s. 2012-32–0007 [vid. 2024-01-12]. Dostupné z: doi:10.4271/2012-32-0007
- [7] SHAHLARI, Arsham J. a Jaal GHANDHI. Pressure-Based Knock Measurement Issues. In: *WCXTM 17: SAE World Congress Experience* [online]. 2017, s. 2017-01–0668 [vid. 2023-07-19]. Dostupné z: doi:10.4271/2017-01-0668
- [8] AKIMOTO, Kenji, Hirotaka KOMATSU a Atsushi KURAUCHI. Development of Pattern Recognition Knock Detection System using Short-time Fourier Transform. *IFAC Proceedings Volumes* [online]. 2013, **46**(21), 366–371. ISSN 14746670. Dostupné z: doi:10.3182/20130904-4-JP-2042.00031
- [9] XU, Wei, Ke-Jun XU, Xiao-Xue YAN, Xin-Long YU, Jian-Ping WU a Wei XIONG. Signal processing method based on energy ratio for detecting leakage of SG using EVFM. *Nuclear Engineering and Technology* [online]. 2020, **52**(8), 1677–1688. ISSN 17385733. Dostupné z: doi:10.1016/j.net.2020.01.023
- [10] *Lecture Notes for EE261 The Fourier Transform and its Applications* [online]. [vid. 2024-01-11]. Dostupné z: <https://see.stanford.edu/materials/Isottaee261/book-fall-07.pdf>
- [11] *numpy.fft.fft — NumPy v1.26 Manual* [online]. [vid. 2024-01-14]. Dostupné z: <https://numpy.org/doc/stable/reference/generated/numpy.fft.fft.html#numpy.fft.fft>

- [12] HÄRDLE, Wolfgang Karl a Léopold SIMAR. *Applied Multivariate Statistical Analysis* [online]. 4th ed. 2015. Berlin, Heidelberg: Springer Berlin Heidelberg : Imprint: Springer, 2015. ISBN 978-3-662-45171-7. Dostupné z: doi:10.1007/978-3-662-45171-7
- [13] PRATS-MONTALBÁN, J.M., A. DE JUAN a A. FERRER. Multivariate image analysis: A review with applications. *Chemometrics and Intelligent Laboratory Systems* [online]. 2011, **107**(1), 1–23. ISSN 01697439. Dostupné z: doi:10.1016/j.chemolab.2011.03.002
- [14] BRUNTON, Steven L. a J. Nathan KUTZ. *Data-Driven Science and Engineering: Machine Learning, Dynamical Systems, and Control* [online]. 1. vyd. B.m.: Cambridge University Press, 2019 [vid. 2024-01-07]. ISBN 978-1-108-38069-0. Dostupné z: doi:10.1017/9781108380690
- [15] HIGHAM, Nicholas J. Computing the Polar Decomposition—with Applications. *SIAM Journal on Scientific and Statistical Computing* [online]. 1986, **7**(4), 1160–1174. ISSN 0196-5204, 2168-3417. Dostupné z: doi:10.1137/0907079
- [16] ELLIS, George. *Control system design guide: a practical guide*. 3. ed. Amsterdam: Elsevier Acad. Press, 2004. ISBN 978-0-12-237461-6.
- [17] ZUMBAHLENAS, Hank a ANALOG DEVICES, INC, ed. *Linear circuit design handbook*. Amsterdam ; Boston: Elsevier/Newnes Press, 2008. ISBN 978-0-7506-8703-4.
- [18] SMITH, Steven W. *The scientist and engineer's guide to digital signal processing*. 1st ed. San Diego, Calif: California Technical Pub, 1997. ISBN 978-0-9660176-3-2.
- [19] Čebyševovy polynomy [online]. [vid. 2024-01-11]. Dostupné z: <http://kfe.fjfi.cvut.cz/~limpouch/numet/aprox/node16.html>
- [20] HUANG, Fuying, Tuanfa QIN, Limei WANG, Haibin WAN a Junyu REN. An ECG Signal Prediction Method Based on ARIMA Model and DWT. In: *2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC): 2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)* [online]. Chengdu, China: IEEE, 2019, s. 1298–1304 [vid. 2024-01-13]. ISBN 978-1-72811-907-6. Dostupné z: doi:10.1109/IAEAC47372.2019.8997620
- [21] BUKOVSKY, Ivo, Gejza DOHNAL, Peter M. BENES, Kei ICHIJI a Noriyasu HOMMA. Letter on Convergence of In-Parameter-Linear Nonlinear Neural Architectures With Gradient Learnings. *IEEE Transactions on Neural Networks and Learning Systems* [online]. 2023, **34**(8), 5189–5192. ISSN 2162-237X, 2162-2388. Dostupné z: doi:10.1109/TNNLS.2021.3123533
- [22] ETTEFAGH, M.M., M.H. SADEGHI, V. PIROUZPANAH a H. ARJMANDI TASH. Knock detection in spark ignition engines by vibration analysis of cylinder block: A parametric modeling approach. *Mechanical Systems and Signal Processing* [online].

2008, **22**(6), 1495–1514. ISSN 08883270. Dostupné
z: doi:10.1016/j.ymsp.2007.11.027

- [23] *librosa.feature.melspectrogram* — *librosa 0.10.1 documentation* [online]. [vid. 2024-01-05]. Dostupné
z: <https://librosa.org/doc/main/generated/librosa.feature.melspectrogram.html>
- [24] *numpy.dot* — *NumPy v1.26 Manual* [online]. [vid. 2024-01-06]. Dostupné
z: <https://numpy.org/doc/stable/reference/generated/numpy.dot.html>
- [25] *numpy.linalg.eig* — *NumPy v1.26 Manual* [online]. [vid. 2024-01-06]. Dostupné
z: <https://numpy.org/doc/stable/reference/generated/numpy.linalg.eig.html>
- [26] *sklearn.decomposition.TruncatedSVD*. *scikit-learn* [online]. [vid. 2024-01-07].
Dostupné z: <https://scikit-learn/stable/modules/generated/sklearn.decomposition.TruncatedSVD.html>
- [27] JOSEF PERKTOLD, SKIPPER SEABOLD, KEVIN SHEPPARD, CHADFULTON, KERBY SHEDDEN, JBROCKMENDEL, J-GRANA6, PETER QUACKENBUSH, VINCENT ARELBUNDOCK, WES MCKINNEY, IAN LANGMORE, BART BAKER, RALF GOMMERS, YOGABONITO, S-SCHERRER, YAUHEN ZHURKO, MATTHEW BRETT, ENRICO GIAMPIERI, YL565, JARROD MILLMAN, PAUL HOBSON, VINCENT, PAMPHILE ROY, TOM AUGSPURGER, TVANZYL, ALEXBRC, TYLER HARTLEY, FERNANDO PEREZ, YUJI TAMIYA a YAROSLAV HALCHENKO. *statsmodels/statsmodels: Release 0.14.1* [online]. B.m.: Zenodo. 14. prosinec 2023 [vid. 2024-01-14]. Dostupné
z: doi:10.5281/ZENODO.593847
- [28] BENVENUTO, Domenico, Marta GIOVANETTI, Lazzaro VASSALLO, Silvia ANGELETTI a Massimo CICOZZI. Application of the ARIMA model on the COVID-2019 epidemic dataset. *Data in Brief* [online]. 2020, **29**, 105340. ISSN 23523409. Dostupné
z: doi:10.1016/j.dib.2020.105340