



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA STROJNÍHO INŽENÝRSTVÍ

FACULTY OF MECHANICAL ENGINEERING

ÚSTAV MECHANIKY TĚLES, MECHATRONIKY A BIOMECHANIKY

INSTITUTE OF SOLID MECHANICS, MECHATRONICS AND BIOMECHANICS

AUTOMATICKÁ DETEKCE ZLOMENÍ NÁSTROJE PŘI DĚROVÁNÍ PLECHŮ

AUTOMATIC DETECTION OF TOOL FRACTURE IN METAL SHEET PUNCHING

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Jan Kluz

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Martin Brabc

BRNO 2022

Zadání bakalářské práce

Ústav:	Ústav mechaniky těles, mechatroniky a biomechaniky
Student:	Jan Kluz
Studijní program:	Aplikované vědy v inženýrství
Studijní obor:	Mechatronika
Vedoucí práce:	Ing. Martin Brabc
Akademický rok:	2021/22

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

Automatická detekce zlomení nástroje při děrování plechů

Stručná charakteristika problematiky úkolu:

V duchu aktuálních trendů v oblasti prediktivní údržby a automatizace v průmyslu obecně se tato práce bude zabývat rozpoznáním zvuků, které při práci vydává stroj pro děrování plechů. Předpoklad je, že z těchto zvuků bude možné rozpoznat degradaci a následně zlomení nástroje. Smyslem této práce je tedy detekovat závadu, zastavit stroj a upozornit obsluhu o nutnosti servisního zásahu.

Cíle bakalářské práce:

- 1) Proveďte rešerši podobných průmyslových aplikací v oblasti prediktivní údržby.
- 2) Měřením získejte testovací sérii zvuků, u kterých je známo kdy došlo k poškození.
- 3) Navrhněte klasifikační algoritmus pro rozpoznání hrozící nebo nastalé závady. Preferujte exaktní metody před strojovým učením.
- 4) Implementujte navržený algoritmus na vhodný HW a realizujte signálové propojení se strojem tak aby bylo možné jej zastavit.
- 5) Validujte funkci navrženého algoritmu.

Seznam doporučené literatury:

NELLES, Oliver. Nonlinear system identification: from classical approaches to neural networks and fuzzy models. Berlin: Springer, 2011. ISBN 978-364-2086-748.

LJUNG, Lennart. System identification: theory for the user. 2nd ed. Upper Saddle River, NJ: Prentice Hall PTR, 1999. ISBN 978-0136566953.

NOSKIEVIČ, Petr. Modelování a identifikace systémů. Ostrava: Montanex, 1999. ISBN 80-722-50-0-2.

Termín odevzdání bakalářské práce je stanoven časovým plánem akademického roku 2021/22

V Brně, dne

L. S.

prof. Ing. Jindřich Petruška, CSc.
ředitel ústavu

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

ABSTRAKT

Tato bakalářská práce se zabývá návrhem a následnou implementací systému automatické detekce zlomení razníku při procesu děrování plechů razníkem o malých rozměrech (0.5 x 12 mm). Navrhovaný systém má význam pro výrazné ulehčení práce operátora, zrychlení procesu výroby a rovněž šetření finančních prostředků firmy. V první části práce je předvedena řešená problematika. Následuje stručný teoretický úvod do oblasti digitálního zpracování signálu. V další části jsou prezentovány metody vyvinuté za účelem detekce signálu zlomení včetně pomocných algoritmů. Jedná se o metodu frekvenčních špiček, frekvenčních pásem, autokorelace, metody frekvenční korelace, klasifikaci strojovým učením včetně hlubokého strojového učení. Z použitých metod dosáhla nejlepších výsledků metoda hlubokého strojového učení neuronové sítě. Pro účely návrhu klasifikačního systému byly použity charakteristiky z časové a frekvenční oblasti. Je popsána rovněž možnost prediktivní údržby nástroje včetně řešerše této oblasti v moderním průmyslu. Prezentovány jsou pak dosažené výsledky a jejich stručné zhodnocení. V poslední části se nachází popis procesu implementace celého systému do realtime podoby a jeho propojení s děrovacím lisem pomocí mikrokontroléru *Arduino Uno* a vytvořeného vstupně-výstupního signálového obvodu. Navrhovaný systém se povedlo sestavit, otestovat a uvést do zkušebního provozu.

Klíčová slova

Digitální zpracování signálů, strojové učení, realtime systém, stavové diagramy, prediktivní údržba, *Arduino Uno*

ABSTRACT

This Bachelor thesis deals with the design and subsequent implementation of the realtime fault detection system during the sheet metal punching process with a tool of small dimensions (0.5 × 12 mm). The proposed system is important for significant ease of the operator's work, acceleration of the process of production, as well as saving of the company finance budget. The first part of this thesis deals with the theoretical background of the studied issue. The following part is a brief theoretical introduction to the field of digital signal processing. The next chapter presents methods developed for fault signals detection including speed enhancing and data flow reducing algorithms. The main examined methods were: frequency peaks, frequency bands, autocorrelation, frequency correlation methods and machine learning including deep machine learning. Deep machine learning of the neural network achieved the best results overall. Features from time and frequency domain were used for purposes of creating the classification model using machine learning. The possibility of developing the predictive maintenance system is also described, including research of this area in a modern industry. Subsequently, the achieved results and their evaluation are presented. The end of this thesis is dedicated to the description of the implementation of classification system into realtime form and connecting this system to the punching press computer using *Arduino Uno* microcontroller and basic signal control electronics. The proposed system has been successfully assembled, tested and put into on-site testing.

Key words

Digital signal processing, machine learning, realtime system, flowcharts, predictive maintenance, *Arduino Uno*

BIBLIOGRAFICKÁ CITACE

KLUZ, Jan. *Automatická detekce zlomení nástroje při děrování plechů*. Brno, 2022. Dostupné také z: <https://www.vutbr.cz/studenti/zav-prace/detail/140249>. Bakalářská práce. Vysoké učení technické v Brně, Fakulta strojního inženýrství, Ústav mechaniky těles, mechatroniky a biomechaniky. Vedoucí práce Martin Brablc.

PROHLÁŠENÍ

Prohlašuji, že jsem bakalářskou práci na téma **Automatické detekce zlomení nástroje při děrování plechů** vypracoval samostatně s použitím odborné literatury a pramenů, uvedených v seznamu, který tvoří přílohu této práce.

.....
Datum

.....
Jméno a příjmení

PODĚKOVÁNÍ

V první řadě bych chtěl poděkovat Ing. Martinu Brablcovi za odborné vedení, cenné připomínky a rady, které mi poskytl během vypracování závěrečné práce. Rovněž velice děkuji firmě AlamakPres, sdružení za poskytnutí zázemí pro tvorbu práce. Závěrem bych chtěl poděkovat rodině za jejich podporu během studia.

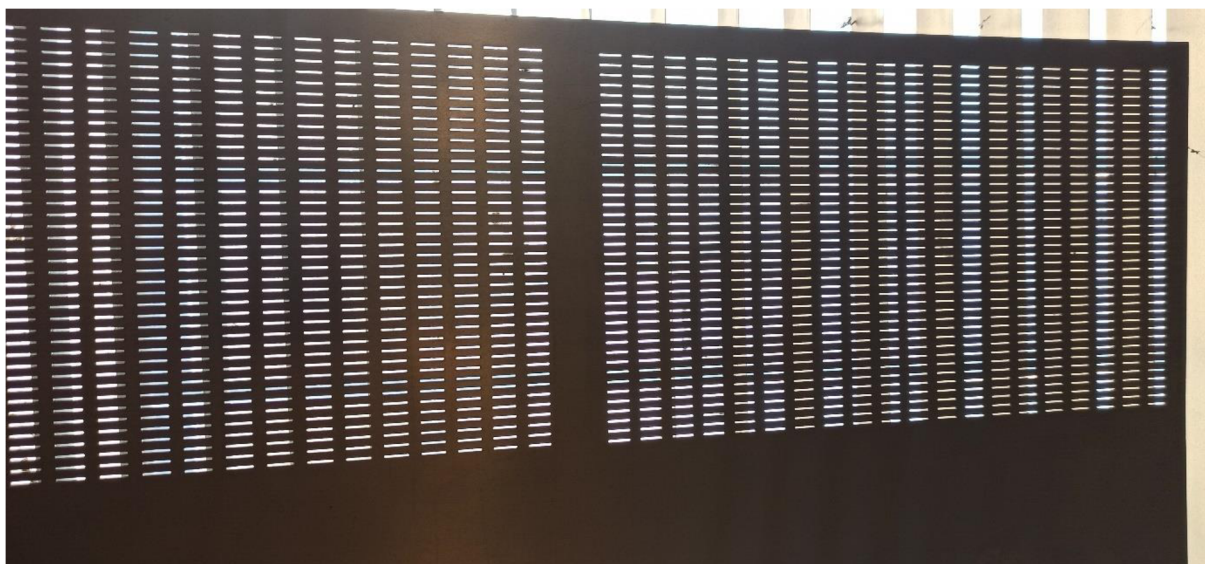
1. ÚVOD	11
1.1. Motivace k návrhu klasifikačního systému	11
1.2. Stručná ukázka zázemí děrovacího lisu LDR 25	13
1.3. Požadavky na klasifikační systém	14
2. TEORETICKÉ ZÁKLADY	15
2.1. Koncept digitálního zpracování signálů	15
2.1.1. Lineární prostor	15
2.1.2. Delta funkce, impulsní odezva	16
2.1.3. Časová vs. frekvenční oblast	17
2.1.4. Konvoluce	17
2.1.5. FFT	18
2.2. Limity DSP	18
3. ZÍSKÁNÍ VSTUPNÍCH DAT	19
3.1. Možnosti indikace zlomení	19
3.1.1. Detekce akustických vln	19
3.1.2. Možnosti využití jiných prostředků propagace signálů	19
3.2. Použité metody pro úpravu získaných signálů	20
3.2.1. Dvoustupňová analýza lokálního rozptylu	20
3.2.2. Multiplexe signálů	23
3.3. Ukázka signálů zlomení	24
3.3.1. Zlomení při přejezdu	24
3.3.2. Zlomení při úderu	25
4. VYTVOŘENÍ METODY KLASIFIKACE ZÁVADY	27
4.1. Algoritmy vylepšující kvalitu vstupních dat	27
4.1.1. Filtrace časové oblasti	27
4.1.2. Redukce šířky dat frekvenčního spektra	27
4.2. Zlomení při přejezdu	29
4.2.1. Metody vyhodnocení časové oblasti	29
4.2.2. Metody vyhodnocení frekvenční oblasti	29
4.2.3. Klasifikace strojovým učením	35
4.2.4. Klasifikace hlubokým strojovým učením	36
4.3. Odhad zbytkové životnosti razníku	37
4.3.1. Korelace průměru bufferu FIFO s následujícím signálem ve frekvenční oblasti	37
4.3.2. Párování korelace FFT	38
4.3.3. Další možné způsoby RUL odhadu	39
4.4. Podobné aplikace prediktivní údržby v průmyslu	40

5. VÝSLEDKY APLIKACE KLASIFIKAČNÍCH METOD	40
5.1. Detailní popis účinnosti jednotlivých metod	40
5.1.1. Metody vyhodnocení časové oblasti.....	40
5.1.2. Metody vyhodnocení frekvenční oblasti.....	41
5.1.3. Klasifikace strojovým učením	43
5.2. Odhad zbytkové životnosti razníku	46
5.3. Stručné porovnání metod	47
5.3.1. Zlomení razníku.....	47
5.3.2. Odhad zbytkové životnosti razníku.....	48
6. IMPLEMENTACE KLASIFIKAČNÍHO SYSTÉMU V REALTIME.....	49
6.1. Real-time algoritmus v Matlabu©	49
6.2. Vytvoření filtru	49
6.3. Ukázka vyfiltrovaných signálů	51
6.4. Sestavení funkce vracející charakteristiky signálu	51
6.5. Natrénování vhodného klasifikačního modelu	52
6.6. Výstup z počítače do reálného světa.....	52
6.7. Propojení Arduina s děrovacím lisem.....	53
6.8. Vyladění algoritmu	55
7. ZÁVĚR.....	59
7.1. Úroveň splnění jednotlivých cílů bakalářské práce	59
7.2. Přijmutí systému personálem firmy	59
7.3. Možnosti dalšího vylepšení klasifikační metody.....	59
7.4. Možné oblasti dalšího využití výstupů bakalářské práce	60
SEZNAM POUŽITÝCH ZDROJŮ	61
SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK.....	63
SEZNAM OBRÁZKŮ	64
SEZNAM TABULEK.....	66

1. ÚVOD


1.1. Motivace k návrhu klasifikačního systému

V kovoobráběcím průmyslu může docházet k závadám na mechanických zařízeních, které mají často stochastický charakter, a není možno je jednoduše predikovat. Takovéto závady mohou klást velké nároky na obsluhu a způsobovat nemalé provozní, finanční a časové zátěže. Předmětem této práce je návrh a realizace vyhotovení automatického zabezpečovacího systému umožňujícího včasné vyhodnocení závady a usnadnění její predikce. Systém schopný automatické detekce zlomení razníku vychází z reálného provozu ve firmě *AlamakPres, sdružení*. Zde je provozován děrovací lis *LDR 25 TGRJ* sloužící k děrování plechů. Pro speciální účely dané výrobními požadavky (hořákové trubice) je použit žáruvzdorný nerezový plech 17 255 s vysokou houževnatostí.




Obr. 1: Fotografie děrovaného plechu

V jednom děrovaném výrobku je celkem 720 děr. Pro účely děrování byl ve firmě speciálně vyvinut nástroj obsahující 4 razníky. Takové uspořádání redukuje nutný počet úderů k výrobě jednoho výrobku na 180. Razníky jsou vyrobeny z materiálu 19 800 a jsou zakaleny na tvrdost 60 HRC. Při děrování do odolného žáruvzdorného nerezového plechu může dojít k ulomení části razníku. Ten se pak vzpříčí v matici, nebo jeho úlomky zůstanou ležet na její střížné hraně. V takovém případě musí operátor neprodleně vypnout chod stroje. V opačném případě může při dalším úderu dojít ke zlomení celého razníku, nebo k poškození střížné hrany matrice. Následkem toho musí operátor matici přebrousit, aby byla znovu použitelná. Takový úkon nezbytně naruší chod výroby, časový harmonogram a přináší finanční ztráty.



Obr. 2: Fotografie děrovacího nástroje, nepoškozené a poškozené střížné hrany matrice

Zlomení razníku má stochastický charakter. V některých případech má razník životnost až několik dní, v opačném případě může dojít k jeho zlomení po několika úderech od jeho prvotního osazení. Charakter poškození razníku se často různí. Může dojít k odlomení pouze špičky, nebo naopak jeho podstatné části.



Obr. 3: Fotografie ulomených špiček razníků (vlevo – pravý je nový); kotevního kroužku s usazenými razníky

Důvodem pro vytvoření systému schopného klasifikace zlomení a následného vypnutí stroje je následující příklad:


Při zakázce 1000 ks děrovaných hořákových plechů musí operátor vykonat 1000×180 úderů a zároveň kontinuálně dohlížet na správnost chodu lisu a vyhodnocovat případné zlomení razníku. Při daném počtu opakování to znamená 180 000 úderů s možností selhání. Časový úhrn této operace činí zhruba 40 hodin čistého času této činnosti operátora.

Navrhovaný systém slouží k výraznému odlehčení práce operátora. V současnosti je k děrování používán program zahrnující drobné prodlevy mezi jednotlivými údery sloužící k reakci operátora na případné zlomení razníku. Systém by měl být schopen tyto prodlevy

eliminovat a zrychlit chod provozu zhruba o třetinu. Rovněž umožní snížit náklady nutné k výrobě nových matic.

1.2. Stručná ukázka zázemí děrovacího lisu LDR 25

LDR 25 TGRJ je děrovací lis vyrobený v roce 1986. Tyto lisy vyráběla firma *Metalpres* v Zastávce u Brna. Přesnost polohování jsou 0,004 mm a děrovací sílu 500 kN. Lisem je možné děrovat materiál o tloušťce < 6 mm. Řídicí systém je plně programovatelný s možností exportu a importu programů do centrálního počítače. Operační systém je v případě výpadku možno nahrát z děrného pásku.



Obr. 4: Fotografie zázemí děrovacího lisu LDR 25 TGRJ – Nahoře řídicí počítač, dole lis

1.3. Požadavky na klasifikační systém

Ke zlomení razníku může dojít jak při samotném úderu, tak při následném přejezdu na novou polohu úderu. Zlomení při úderu je operátorem málokdy rozpoznatelné. Zlomení při přejezdu je naopak zřetelné. Je tedy nutné vyhodnocovat signál zlomení při úderu a přejíždění samostatně. Při úderu postačuje signál vyhodnotit jednotlivě, při přejezdu kontinuálně. Obecným požadavkem na navrhovaný systém je schopnost detekce zlomení a vypnutí stroje před dalším úderem. Žádoucím reakčním časem vyhodnocení signálu a následného vypnutí stroje je 50–250 ms. Ze své podstaty se jedná o tvrdý realtime systém. V případě nezvládnutí rozpoznání zlomení razníku před dalším úderem se ztrácí jeho použitelnost.

Vzhledem k užívání v reálném provozu je systém opatřen uživatelsky přívětivým a ergonomicky vyhovujícím rozhraním při současném zachování plné funkčnosti. Rovněž umožňuje libovolné pozastavení činnosti. Sada bezpečnostních prvků zamezuje uvedení lisu v činnost bez splnění kontrol při startu podmíněných připojením systému na výstupní jednotku, nízkou rychlostí chodu (zahlcení) a podobně.

2. TEORETICKÉ ZÁKLADY

2.1. Koncept digitálního zpracování signálů

Navrhovaný systém využívá metod digitálního zpracování signálů (*Digital Signal Processing, DSP*). Jedná se o oblast aplikované matematiky, s jejíž pomocí je za využití poznatků o spojitéch signálech v lineárním prostoru možné provádět podrobné analýzy signálu, jeho úpravy, nebo další operace [2, 13].

Implementované algoritmy DSP pracují s diskrétními signály. Důvodem je omezená velikost paměti RAM a AD převodníku pracujícího na konkrétní vzorkovací frekvenci. Oblast DSP nabízí možnosti jinak velice těžko realizovatelné. V této podkapitole bude nastíněn stručný přehled základních algoritmů DSP použitých v rámci této bakalářské práce.


DSP metody použité v rámci této bakalářské práce využívají následující komponenty:

- lineární prostor,
- impulzní odezvu,
- časovou a frekvenční oblast,
- konvoluci a
- FFT (*Fast Fourier Transformation*).

2.1.1. Lineární prostor


Předpokladem správné funkčnosti algoritmů DSP je jejich definování v lineárním prostoru. Matematický model lineárního prostoru musí splňovat 4 následující charakteristiky:

- homogenitu,
- aditivitu,
- podmínku sinusové odezvy a
- fázovou invarianci [13].



Obr. 5: Homogenita (vlevo), aditivita (vpravo) [13]

Díky existenci lineárních systémů ve velké míře v přírodě je možné aproximovat například fyzikální děje (proud odporem, mechaniku těles a podobně) a řešit tak požadované úlohy.




Obr. 6: Porovnání lineárních a nelineárních systémů (vlevo je B-H křivka magnetického obvodu, vpravo jsou lineární modely pružin) [13]

2.1.2. Delta funkce, impulsní odezva

Základem pro pochopení podstaty DSP je delta funkce. Jedná se o diskretní signál mající první vzorek o normalizované velikosti 1 a ve druhém vzorku velikost 0. V podstatě jde o jednotkový Diracův impuls [13]. Přivedení toho impulsu na vstup systému vytvoří impulsní odezvu.

V případě přivedení impulsu o odlišné velikosti na vstup systému (např. 0,5) bude mít výsledná impulsní odezva poloviční velikosti vzorků, protože se jedná o lineární systém.



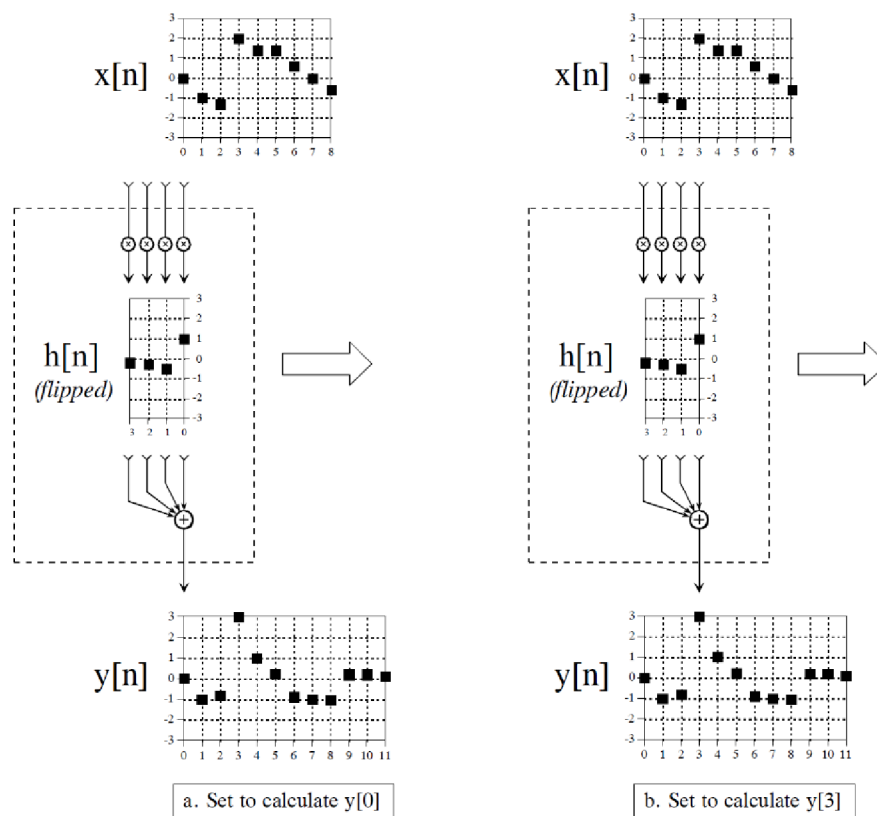
Obr. 7: Delta funkce a impulsní odezva [13]

2.1.3. Časová vs. frekvenční oblast

Na signál je obecně možné nahlížet jako na amplitudu určité veličiny v čase, nebo jako součet harmonických funkcí, které jsou po sečtení ekvivalentní signálu v čase [3]. Oba tyto náhledy na signál jsou plně zaměnitelné a správné. Každý popisuje signál z jiného úhlu pohledu. Tyto dva přístupy je možné oboustranně konvertovat díky algoritmu FFT, který je popsán v následující části. Rozhodnutí, jestli pro daný účel vyhovuje víc časová, nebo frekvenční oblast, záleží od typu aplikace. Klasifikační systém vytvořený v rámci této práce využívá časovou i frekvenční oblast.

2.1.4. Konvoluce

Konvoluce je popis vlivu signálu akční veličiny na odezvu systému. Díky této metodě je možné modelovat charakteristickou impulzní akustickou odezvu reálného prostoru po přivedení jednotkového skoku o určité frekvenci. Zpětně je možné získat i tvar signálu ze znalosti impulzní odezvy daného prostoru. Je možné odfiltrovat vliv okolního prostoru na zvukový signál. Tento proces se nazývá dekonvoluce. V diskrétní podobě představuje operace konvolvování dvou signálů složení vážených vstupů konvolvovaného signálu jednoho přes druhý. Signál, přes který se provádí konvoluce, je ale invertován v čase.



Obr. 8: Algoritmus diskrétní konvoluce [13]

Konvoluce diskrétních signálů je popsána následující rovnicí:

$$y[i] = \sum_{j=0}^{M-1} h[j] \cdot x[i - j] \quad (1)$$

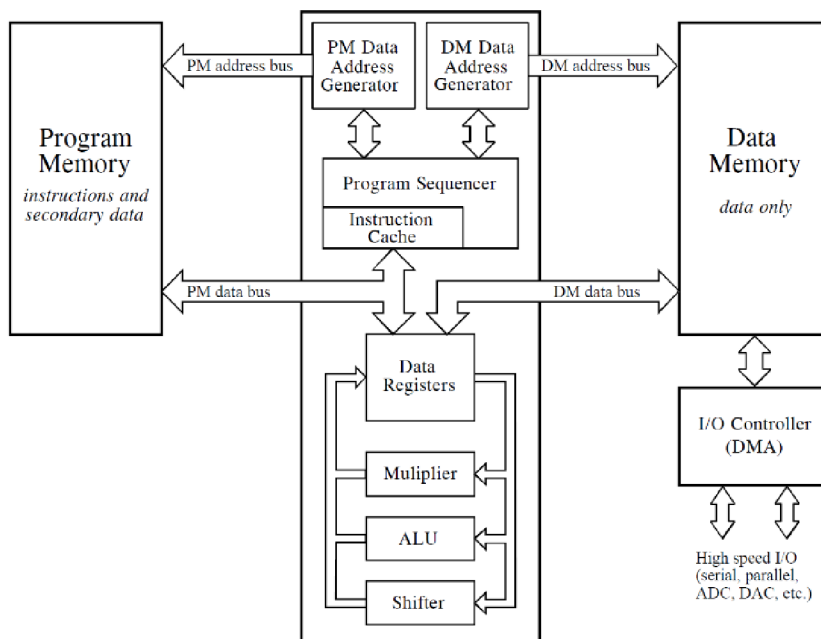
Konvoluci je možné provádět jak v časové, tak ve frekvenční oblasti. Konvoluce ve frekvenční oblasti představuje součin jednotlivých frekvencí konvolovaných signálů, dekonvoluce pak podíl těchto frekvenčních spekter. Rozdíl mezi konvolucí v časové a frekvenční oblasti se zvětšuje přibližně logaritmičticky podle počtu vzorků filtrovaného signálu. Konvoluce ve frekvenční oblasti je tedy daleko rychlejší, než v časové. Algoritmus, který se běžně implementuje, je tedy konverze signálů do frekvenční oblasti, následnou konvoluce vynásobením frekvenčních spekter a zpětná konverze do časové oblasti pomocí IFFT (inverzní FFT) [13].

2.1.5. FFT

Algoritmus FFT (*Fast Fourier Transform*) je metoda efektivního počítání diskrétní Fourierovy transformace (DFT). DFT transformuje signál z časové oblasti do komplexní spojité rozložené frekvenční oblasti – speciální případ spojité Fourierovy transformace. Při použití DFT k transformaci signálu je délka trvání závislá kvadraticky na počtu vzorků, při použití FFT je závislá lineárně-logaritmičticky. Existuje celá řada modifikací této metody. Základní algoritmus je založen na faktorizaci a binární reprezentaci čísel [2, 13].

2.2. Limity DSP

Možnosti využití DSP algoritmů v reálném světě mají určitá omezení. Těmi jsou kromě úrovně kvality vstupních periférií především rychlost procesoru a dostupná velikost paměti RAM. Dalším problémem je datová propustnost mezi jednotlivými perifériemi nebo nutnost dvojnásobné vzorkovací frekvence AD převodníku, než jaká je vlastní požadovaná frekvence (podle Nyquistova teorému) [8, 9]. Zpracování dat procesorem je možné velmi výrazně vylepšit použitím speciální architektury vnitřního uspořádání procesoru zvané DSP architektura. Jde o zřetěžené paralelní zpracování signálů [13].



Obr. 9: Modelové schéma typického DSP procesoru [13]

DSP architektura může být až desetkrát rychlejší ve vykonávání DSP algoritmů než obyčejný mikroprocesor, který nemá implementované DSP instrukce.

3. ZÍSKÁNÍ VSTUPNÍCH DAT

3.1. Možnosti indikace zlomení

První krok provedený při navrhování klasifikačního systému bylo zamyšlení se nad možnostmi digitalizace signálů zlomení.

3.1.1. Detekce akustických vln

Pro detekci signálů zlomení byl z důvodu jednoduchosti a kompaktnosti zvolen mikrofon. Zlomení je možné mikrofonem detekovat v dostatečně velké rozlišitelnosti a intenzitě. Navíc se velice jednoduše uvádí do provozu z důvodu masivního využití jako běžné periferie k počítači. Konkrétní mikrofon použitý pro digitalizaci zvuku je *Connect II[®] CI-481* s externí zvukovou kartou *AXAGON[®] ADA-17*.



Obr. 10: Fotografie použitého mikrofonu a zvukové karty; převzato z www.czc.cz

3.1.2. Možnosti využití jiných prostředků propagace signálů

Pomocí snímání akustických vln je možné detekovat zlomení pouze v daném okamžiku zlomení – při zanedbání speciálních technik, které navíc nejsou snadno realizovatelné. Například buzení razníku vnějším zdrojem vibrací a sledování mikrofonem jeho odezvy – zlomený razník bude mít z důvodu změny vlastní frekvence kmitání jinou odezvu než nepoškozený. Tato metoda není realizovatelná z důvodu nepodstatných amplitud buzeného razníku vzhledem k okolním strojním součástem. Další věc je způsob, jakým by toto buzení mohlo být realizováno. V nástroji pro toto není místo a patrně by se rozkmital celý nástroj. Mikrofonem je tedy možné kontrolovat razník pouze nepřímo a pouze v jednom krátkém časovém okamžiku při zlomení a krátce po něm.

Pro účel přímého snímání stavu razníku by byla vhodná například kamera. Kameru ovšem není možné použít z důvodu způsobu konstrukce nástroje. Razník není při přejíždění děrovaného materiálu viditelný, je zcela skrytý v nástroji.

Jako další možný způsob digitalizace dat se jeví použití tenzometru. Mohl by být osazen dovnitř nástroje (snímání při úderu), nebo na spodní část matrice (snímání při přejíždění). Tenzometrem by mělo být možné detekovat vibrace přenášené ocelovými částmi stroje. Teoreticky by mohl být tenzometr citlivější než mikrofon. Nicméně nebyl zvolen z důvodu

složitější digitalizace dat z výstupu. Navíc by výsledek nemusel mít větší přínos, než použití mikrofon. V lisu je totiž většina součástí spojená přímým kontaktem ocel – ocel. To způsobuje, že stroj jako celek se chová jako soustava, kterým se mohou volně přenášet všechny možné kmity pocházející od valivého nebo kluzného tření, motorů nebo syčení stlačeného vzduchu až po vnější vlivy. Toto by mohlo vlastní zvuky zlomení nástroje učinit nepodstatnými vzhledem k rušení. Nástroj ani matici není z různých důvodů možné od zbytku stroje odizolovat vibračně nevodivou vrstvou.

3.2. Použité metody pro úpravu získaných signálů

Metody aplikované úpravy signálů byly vytvořeny za korekce signálu požadovaným způsobem. Jedná se o metody využívající ke své funkci různé statistické metriky, matematický aparát lineárních systémů, algoritmů DSP a další.

3.2.1. Dvoustupňová analýza lokálního rozptylu

Tato metoda byla vytvořena za účelem rozpoznání jednotlivých signálů v záznamu obsahujícím šum. Metoda je schopna efektivně a s vysokou spolehlivostí provést separaci záznamu na jednotlivé zvuky. Ty je možné následně vyexportovat. Příklad: záznam *OK22.wav* má délku trvání 53 minut. V tomto záznamu je neznámý počet úderů. Údery nelze brát jako ekvidistantně rozložené v čase. Tyto jednotlivé údery je potřeba oddělit a vyexportovat jako samostatné signály. Toto je možné provést relativně rychle a jednoduše dvoustupňovou analýzou lokálního rozptylu. Její podstata spočívá v základní statistické charakteristice vektoru hodnot - rozptylu. Rozptyl statistického souboru dat je možné interpretovat jako výkyvy hodnot od střední hodnoty. Čím víc jsou data vzdálená od průměru, tím větší mají rozptyl.

Vstupem do metody je signál získaný křížovou korelací testovaného signálu s testovacím signálem, jímž je exportovaný signál. Je známo, že v místě největší špičky křížové korelace začíná hledaný signál. V tomto místě se nachází odpovídající vzorek, kde součet vážených vstupů od jednotlivých vzorků nejvíce odpovídá vzorovému signálu. Podstata metody je následující: vytvoří se buffer typu first-in-first-out (FIFO). Do tohoto bufferu se načte následující vzorek ze vstupního signálu křížové korelace a předposlední vzorek se stane posledním. Buffer postupuje vstupním signálem. Po každé jeho aktualizaci se vypočítá jeho rozptyl. Tento vypočítaný rozptyl se stane další hodnotou „signálu lokálního rozptylu“ majícího stejnou délku jako vstupní vektor křížové korelace. V podstatě se jedná o vyfiltrovanou hodnotu rozptylu posledních n -vzorků. V případě, že rozptyl ve vstupním signálu křížové korelace začne vykazovat zvýšené oscilace, zvětší se i hodnota lokálního rozptylu. Jakmile se oscilace zmenší, zmenší se lokální rozptyl.

V dalším kroku se vytvoří maska, obsahující oblasti s exportovanými signály. Vzorky masky, kterým odpovídá lokální rozptyl s hodnotou menší než prahovou, budou nulové. V případě hodnot větších než prahových bude vzorek masky nenulovým číslem. Tím dojde k vytvoření logického signálu. V místech, kde je hodnota masky větší než nula, se nachází hledaný signál. V místech, kde je hodnota masky lokálního rozptylu nulová, se hledaný signál nenachází. V takovém případě se jedná o rušení nebo šum. Funkce následně prohledá všechny oblasti masky, ve kterých je nenulová hodnota, a vrátí počet a indexy jednotlivých špiček vstupního signálu křížové korelace. Tento algoritmus je jednostupňovou analýzou lokálního rozptylu. Daným postupem lze vytrždit a následně vyexportovat jednotlivé signály jako samostatné zvuky ze záznamu neobsahujícího šum. V případě záznamu s větším výskytem šumu je tato metoda nepoužitelná. Problematickým je fakt, kdy lokální rozptyl může v určitém bodě začít oscilovat a tím se dostat pod prahovou hodnotu a vytvořit u masky duplicitní nenulové hodnoty. Tento problém lze částečně vyřešit zabudováním určité hystereze. Další


možností je přidání předřadného stupně za účelem filtrace vstupního signálu křížové korelace. První stupeň analýzy vyhodnotí vstupní signál lokálního rozptylu v místech. Tam, kde je hodnota menší než prahová, se u vzorků vstupního signálu křížové korelace nastaví nuly. Druhý stupeň je proveden identicky jako v případě jednostupňové analýzy.

Toto je princip funkce metody dvoustupňové analýzy lokálního rozptylu, která byla napsána speciálně pro účely bakalářské práce. Tuto metodu je dále možné optimalizovat pro rychlejší běh algoritmu. Funkce nemusí procházet jednotlivé vzorky, ale může přeskakovat o určitý počet vzorků. Při testování měl skok o hodnotě 200 vzorků identické výsledky jako skok o velikosti jednoho vzorku. Další možnou optimalizací je procházení nenulových hodnot masky pouze do určitého indexu. Napsaná funkce pracovala velice dobře při následujících nastavených parametrech:

Tab. 1: Vhodné parametry funkce peaks

Parametr	Nastavená hodnota	
	První stupeň	Druhý stupeň
Šířka bufferu	38	45
Signálový skok	200	350
Prahová hodnota	2000	1

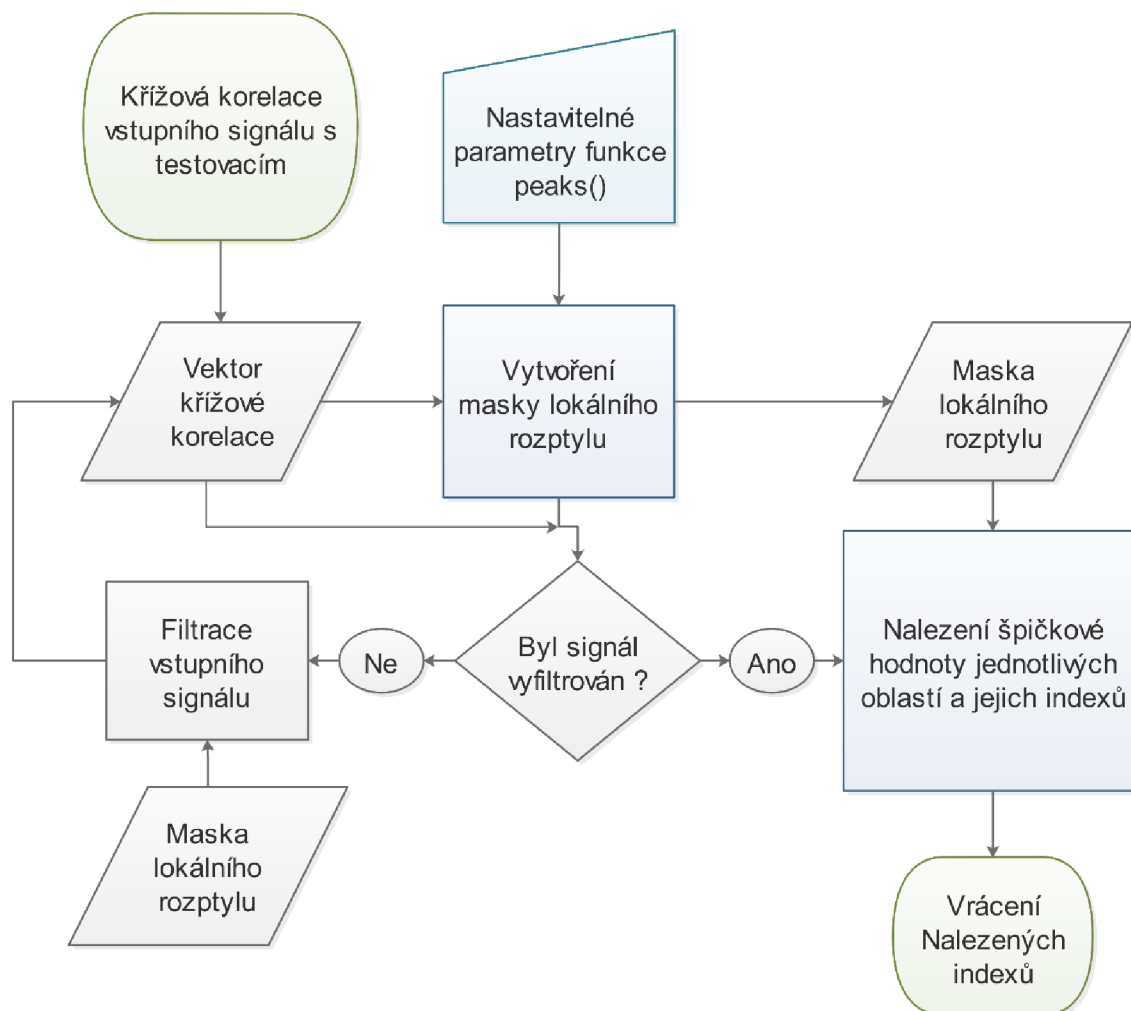
Tyto parametry byly laděny iteračně do doby, než funkce poskytovala optimální výsledky. Implementovaná podoba této funkce v *Matlabu*[©] je schopná na procesoru *Intel Core i-7 9600U* zpracovat jednu hodinu vektoru křížové korelace za 1,753 vteřiny se směrodatnou odchylkou 104 ms. Měření bylo provedeno pro 100 iterací. Při výstupní kontrole bylo ze získaných 11708 záznamů bez zlomení razníku při úderu (= OK zvuk) chybně vyexportovaných 7¹.



Obr. 11: Graf vizualizované podoby výsledků dvoustupňové analýzy lokálního rozptylu

¹ Pro výstupní kontrolu byla napsána funkce, která vyexportované signály zobrazovala na monitoru v pravidelných intervalech. V případě nalezení špatně vyexportovaného signálu byl jeho index zapsán do tabulky.

Výsledný vektor hodnot je převzorkován. Pro vykreslování signálu je použit každý n -tý (100 vzorků) vzorek ze vstupního signálu. V případě, kdy signál má milion vzorků v grafu, bude vykresleno jenom 10 000 hodnot. V grafu budou zachovány dostatečné informace o výstupu z funkce a proces vykreslování bude řádově urychlen.



Obr. 12: Stavový diagram dvoustupňové analýzy lokálního rozptylu

3.2.2. Multiplexe signálů

Metoda multiplexe signálů dokáže sloučit n -signálů do jednoho. Jedná se způsob například superponování signálu vyexportovaného zlomení na záznam rušení k účelům otestování kvality výsledného klasifikačního algoritmu. Při aplikaci poznatků o DSP jako o lineárním systému na dva různé signály, které je zapotřebí „smíchat“ dohromady, se tedy postupuje následovně: signály se k sobě jednoduše přičtou; v případě, že výsledný signál má hodnotu větší, než 1, je možné signál normalizovat. Toto se provede tak, že se zjistí nejvyšší hodnota vzorku ve výsledném součtu signálů. Amplitudy všech vzorků se pak takto zjištěnou hodnotou vydělí. Tímto vznikne normalizovaný součet dvou signálů.

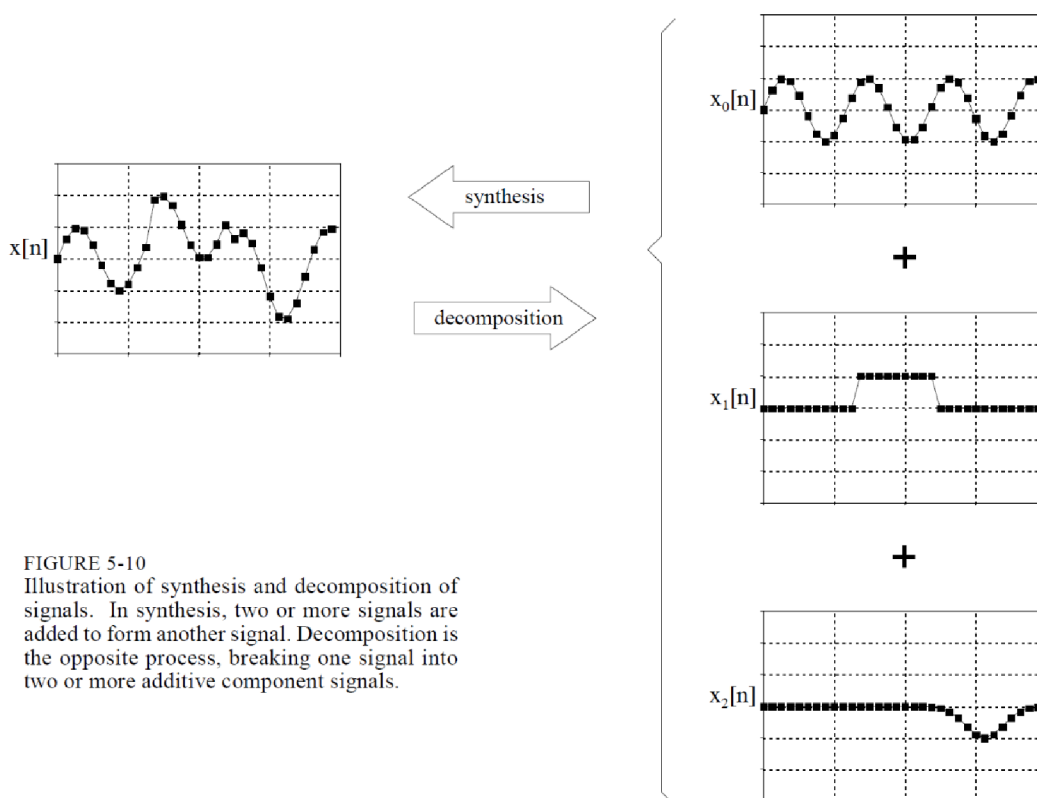


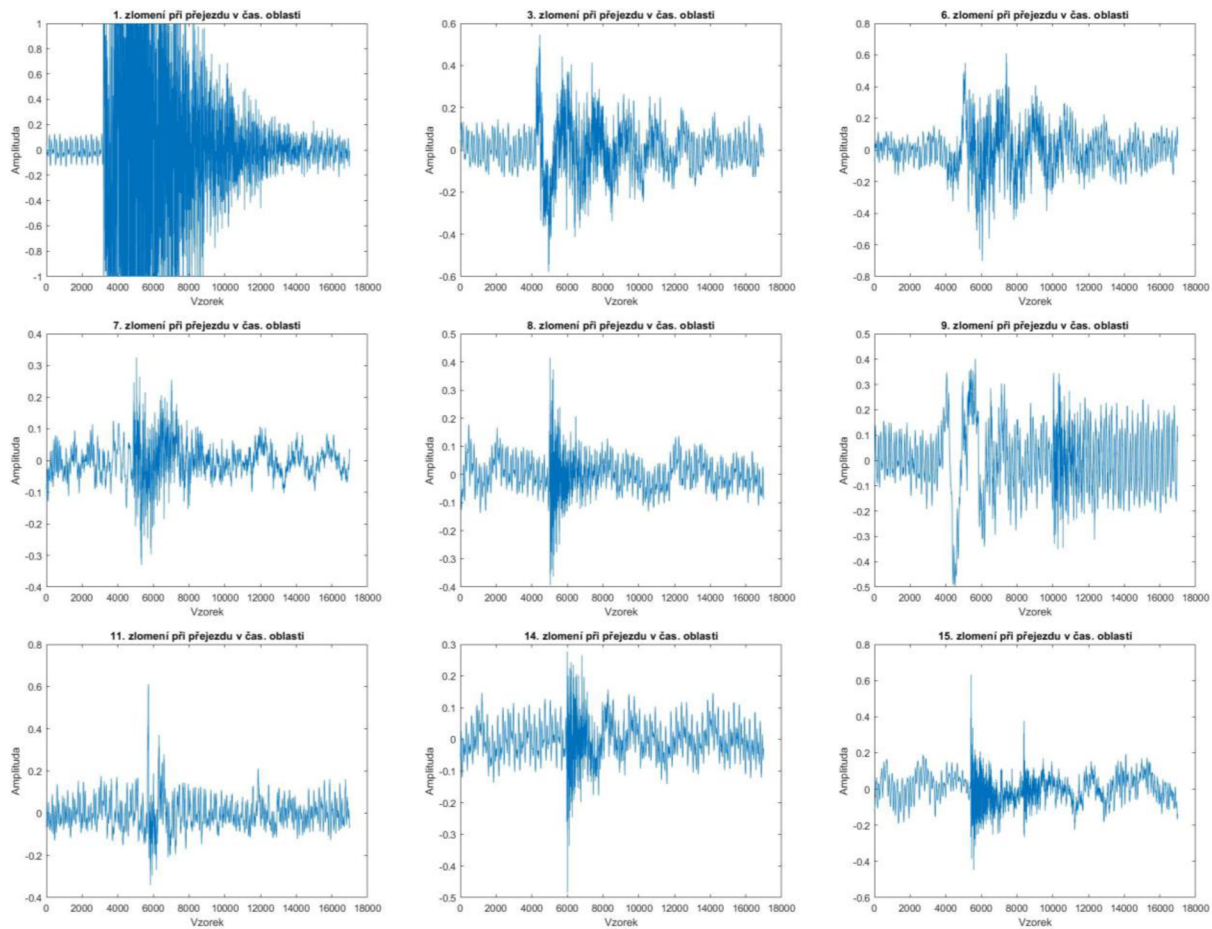
FIGURE 5-10
Illustration of synthesis and decomposition of signals. In synthesis, two or more signals are added to form another signal. Decomposition is the opposite process, breaking one signal into two or more additive component signals.

Obr. 13: Multiplexe signálů [13]


3.3. Ukázka signálů zlomení

Celkem bylo nahráno 9 hodin záznamu. Z tohoto počtu bylo vyexportováno celkem 11 701 OK úderů, 25 záznamů se zlomením razníku při úderu (= NOK úderů), 15 zlomení při přejezdu a 211 pozadí při přejezdu. Do pozadí se promítá především polohování pojezdu stolu a PWM ovládání motorů. Dále byla pořízena jedna hodina záznamu běžného zvuku na pozadí, šum (hudba) a doprovodné dílenské zvuky.

3.3.1. Zlomení při přejezdu




Obr. 14: Grafy zlomení při přejezdění v časové oblasti

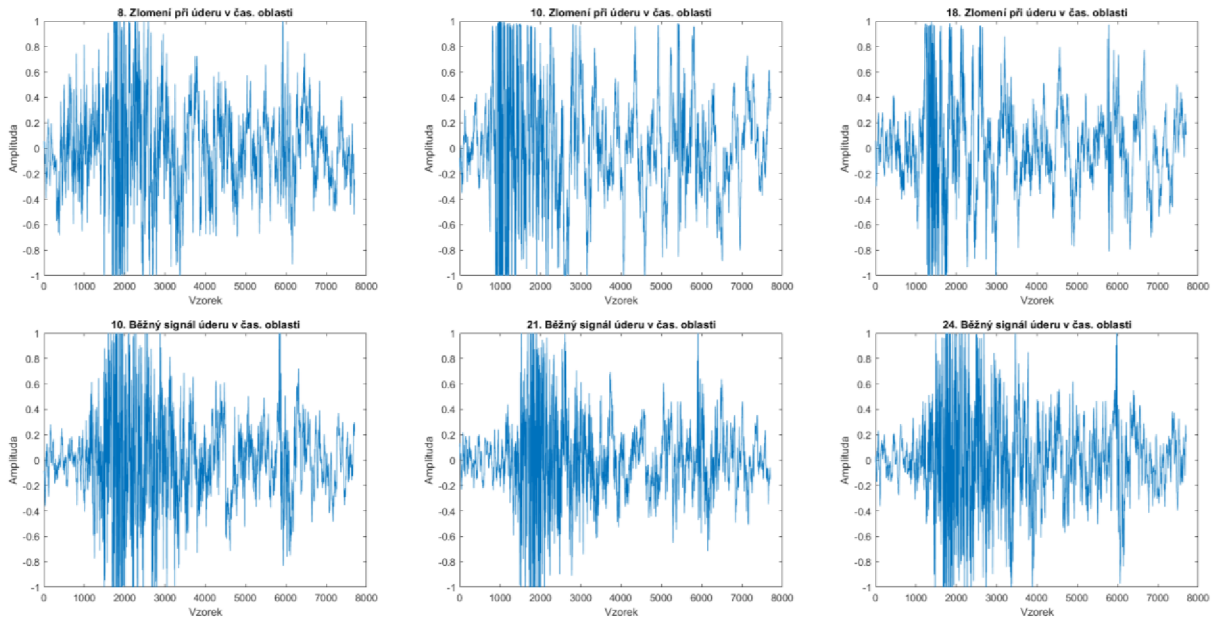


Obr. 15: Grafy zlomení při přejíždění ve frekvenční oblasti

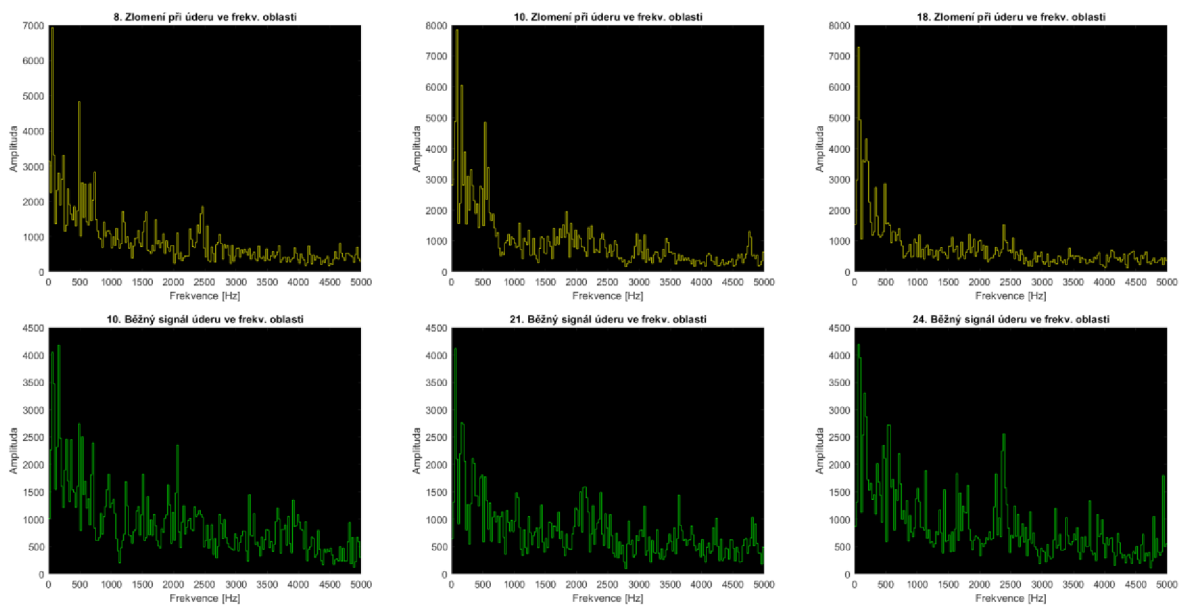
3.3.2. Zlomení při úderu



Obr. 16: Srovnání průběhu OK, NOK a úderu naprázdno v časové oblasti



Obr. 17: Srovnání průběhu (střední části signálů) OK a NOK úderu v časové oblasti



Obr. 18: Ukázka výše uvedených grafů OK a NOK úderů ve frekvenční oblasti

Je důležitý pouze zvuk uprostřed, jiné zvuky působí jako rušení. Jak je možné vidět z pořizovaných záznamů, je signál zlomení daleko lépe rozpoznatelný pouhým okem v časové i frekvenční oblasti, než signál při úderu. Jeho odlišení od signálu při úderu by tedy mělo být daleko lépe realizovatelné.

4. VYTVOŘENÍ METODY KLASIFIKACE ZÁVADY

Dalším stupněm vývoje klasifikačního systému byl návrh jádra systému – metody umožňující rozlišení signálů zlomení od signálů pozadí.

4.1. Algoritmy vylepšující kvalitu vstupních dat

Následující metody spadají do oblasti aplikované úpravy signálů popsané výše. Tyto algoritmy byly v různých stupních implementovány k vylepšení rozlišitelnosti některých metod nebo pro zlepšení datového toku a výkonnosti při běhu výsledné funkce v reálném čase.

4.1.1. Filtrace časové oblasti

Jelikož ve výsledné podobě systému je mnoho charakteristik signálu získáváno z časové oblasti, velmi pomůže, když se ze signálu odstraní zvuky, které se běžně vyskytují na pozadí. Jde hlavně o PWM signál motorů, polohování stolu a další podobné zvuky, které působí jako rušení. Toto je možné realizovat filtrem. Filtraci časové oblasti je možné provádět kontinuálně přes konvoluci a to buď v časové oblasti, nebo ve frekvenční. Filtrů existuje nepřeberné množství. Základní dělení filtrů je na filtry pro frekvenční a časovou oblast. Filtry pro frekvenční oblast jsou filtry s konečnou odezvou v čase (FIR) a nekonečnou, neboli filtry rekurzivní (IIR) [13]. Filtrem pro časovou oblast je například vážený průměr. Tento filtr je schopen vyčistit signál od vysokofrekvenčního rušení, zavádí ale značný fázový posun signálu. Filtrace signálu je nástroj, kterým jde signál „vyčistit“ od rušení, které by jinak mohlo negativně ovlivnit funkčnost algoritmu.

U filtrů jsou dále důležité jejich parametry, jakým způsobem ovlivňují filtrovaný signál. A to jak ve frekvenční, tak v časové oblasti. Mezi základní parametry v časové oblasti patří odezva na jednotkový skok, velikost překmitu a ovlivnění fáze. Frekvenčními parametry jsou strmost filtrovaného pásma, útlum a zákmity na hranicích pásem [13]. Signál vyhodnocovaný až po jeho zachycení (tzn. nevyhodnocovaný průběžně), je možné jednoduše vyfiltrovat převedením do frekvenční oblasti, vynásobením obdélníkovým oknem a provedením inverzního FFT. Tento způsob je ideální filtrace nijak neovlivňující fázi signálu. Má nekonečně velký útlum, nekonečně velkou strmost a nulový překmit na hranicích frekvenčních pásem. Signál filtrovaný průběžně musí být ale filtrován konvolucí.

4.1.2. Redukce šířky dat frekvenčního spektra


Metoda spočívá v transformaci FFT do frekvenčních pásem. Jde v podstatě o integraci FFT křivky po pásmech. Toto má značný dopad na velikost datového toku. Ten se výrazně zmenší a výsledná funkce se tak urychlí. Navíc tato metoda zavádí určitou schopnost průměrování frekvencí, což může být užitečné při kolísání frekvencí. Konkrétní frekvenční špička může například změnou teploty nějakého kondenzátoru změnit svoji frekvenci o několik hertzů, ale intenzita v daném frekvenčním pásmu zůstane stejná. To ve výsledku znamená větší odolnost algoritmu ke změně počátečních podmínek. Funkce integrující plochu pod FFT byla realizována pomocí trapézové metody. Tato metoda má pro daný účel dostatečně velkou numerickou přesnost.

$$P_{\text{freq band}} = \int_{f_{\min}}^{f_{\lim}} \text{FFT}_{\text{in_sig}(f)} df = \frac{h}{2} \cdot \left[\text{FFT}_{\text{in_sig}(f_{\min})} + 2 \cdot \sum_{i=1}^{i=n-1} \text{FFT}_{\text{in_sig}(f_{\min+i \cdot h})} + \text{FFT}_{\text{in_sig}(f_{\lim})} \right] \quad (2)$$

kde h je šířka diskretizovaného pásma:

$$h = \frac{f_{\lim} - f_{\min}}{n} \quad (3)$$

a n je počet hodnot vstupního signálu FFT, které připadají na jedno pásmo. Tyto vzorky jsou rozděleny ekvidistantně.



Obr. 19: Ukázka binování

Ve funkci je dále zabudován mechanismus, který umožňuje integrovat pouze žádaná frekvenční pásma. Implementovaná funkce je schopná integrovat kompletní FFT mající 8 500 vzorků za $437 \mu\text{s}$ se směrodatnou odchylkou 206 ms na procesoru *Intel Core i-7 9600U*. Tento čas byl získán provedením 10 000 iterací.

4.2. Zlomení při přejezdu

4.2.1. Metody vyhodnocení časové oblasti

Jelikož časová oblast může být plnohodnotným obrazem určité informace, byla vynaložena snaha vytvořit algoritmus schopný rozlišit signál zlomení od signálu pozadí podle tvaru signálu v časové oblasti.

Statistické zpracování signálu v časové oblasti

Tato metoda spočívá v nalezení určité statistické metriky nebo souboru metrik schopného odlišit zlomení od pozadí. Toto může být například velká derivace amplitudy v kombinaci s velkým rozptylem a špičatostí. V případě, že razník praskne, je vidět, že se u průběhu signálu dočasně zvětší amplituda, která se pak zase vrátí na svou původní hodnotu. Tato metoda by fungovala ve 100 % případů. Má ale značnou nevýhodu. Schopnost rozpoznat výraznou změnu signálu v časové oblasti s sebou nese i problém, kdy by systém vypínal chod stroje vždy při sebemenším zakmitání zvuku. Systém musí vypnout chod stroje při velmi specifickém signálu zlomení a nereagovat na okolní zvuky. Nastavit tento systém manuálně pouze na základě odhadu tak, aby spolehlivě fungoval, je časově a fyzicky náročné.

Tato metoda tedy nebyla realizována jako samostatný algoritmus. Existuje ale prostředek, kterým by bylo možné najít sub-optimální nastavení jednotlivých statistických charakteristik – klasifikace strojovým učení. Tato metoda je popsána v podkapitole 2.3 této práce a využívá ke své funkci právě značnou část statistických metrik získaných z časové oblasti.

Autokorelace

Metoda autokorelace signálu určuje, jak velkou intenzitou je zastoupen testovací signál v testovaném. Výsledek je přímo číselný. Jedná se o metodu podobnou křížové korelaci. Je založena na konvoluci. Jediný rozdíl oproti konvolučnímu algoritmu je, že signál, přes který se konvolvuje, není invertován v čase. Je používána například v radarových systémech k detekci příchozího signálu, který byl zpětně vyslán anténou [13]. Tento signál je možné detekovat s rozlišením o velikosti jednotek vzorkovací frekvence. Toto byl první navržený algoritmus. Jeho podstata spočívá v nalezení signálu vzniklého při zlomení. Lze to provést jednoduchým zprůměrováním vzorků v časové oblasti za předpokladu identické fáze signálu a jeho časové invariance. Tímto signálem se pak bude periodicky vyhodnocovat autokorelace s postupně aktualizovaným FIFO bufferem se zaznamenanými daty z mikrofону. V případě, že bude rozpoznána zvýšená autokorelace signálu zlomení v bufferu, stav bude vyhodnocen jako zlomení a vypne se chod stroje.

4.2.2. Metody vyhodnocení frekvenční oblasti

Frekvenční oblast je ekvivalentním obrazem signálu v časové oblasti. Je v ní zahrnuto obrovské množství informací o signálu. Další metody byly tedy zaměřeny na využití těchto informací uložených ve frekvenční oblasti.

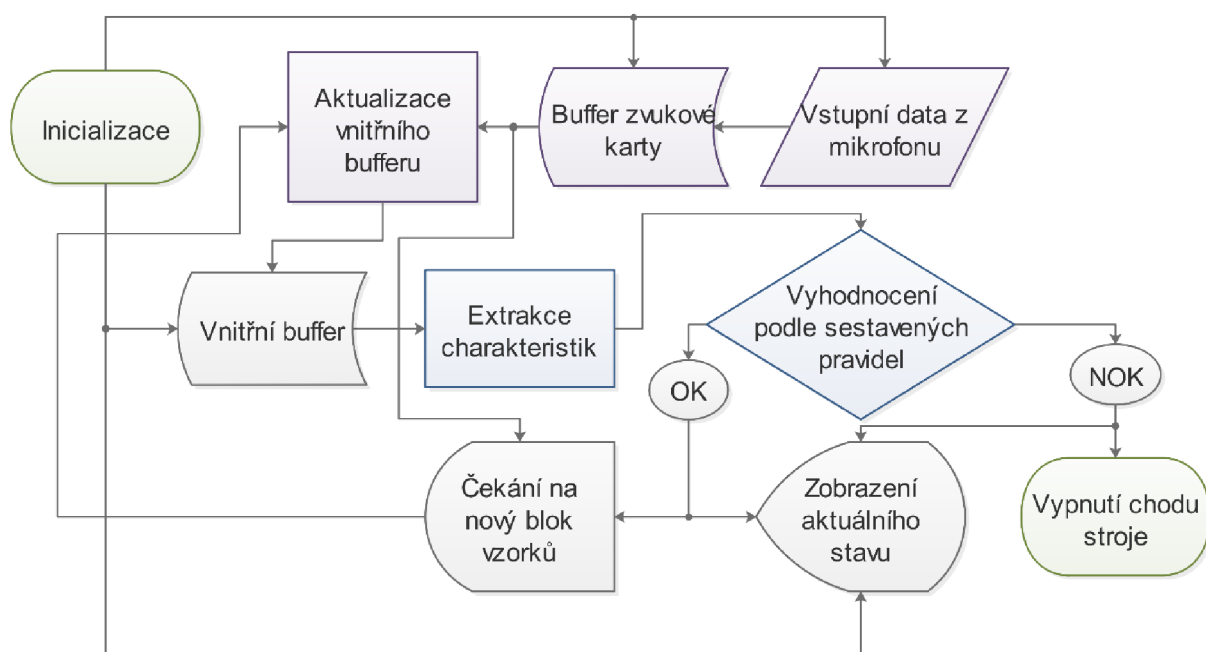
Vyhodnocení frekvenční oblasti statistickými metodami

Na frekvenční oblast je stejně jako na časovou oblast možné aplikovat statistické metriky. Je třeba mít na paměti, že signál není na sobě úplně stejně závislý, jako jsou v časové oblasti

závislé vzorky. Frekvenční oblast postrádá dynamiku časové oblasti. Nicméně při pohledu na FFT grafy zlomení je možné zjistit určité makroskopické tvary, které v signálech pozadí nemusí být přítomny. Nabízí se proto myšlenka vyhodnocovat frekvenční oblast některými vybranými statistickými metrikami. Ne všechny metriky mají ve frekvenční oblasti svůj význam, ale jak bylo prokázáno v praktické části, některé vylepšují klasifikační schopnost systému při realtime provozu. Průměr FFT například význam mít nebude, ale špičatost, efektivní hodnota nebo směrodatná odchylka svůj určitý význam mít mohou.

Kvantitativní charakteristiky FFT

Zde byla zkoumána možnost rozpoznání zlomení dle určitých konkrétních špiček ve frekvenční oblasti, které vydá razník při zlomení. Bylo zjištěno, že signály zlomení jsou velice variabilní, co se frekvenční oblasti týče a není možné to tímto způsobem spolehlivě detekovat. Šlo by teoreticky jednotlivé signály zlomení spárovat podle vlastního zvuku a ty pak vyhodnotit samostatně, ale tento přístup neposkytuje záruku, že se neobjeví nový tvar signálu zlomení, pro který nebude vyhodnocena sada frekvenčních špiček a systém tak nebude schopen detekce tohoto nového zvuku. Dále není možné zaručit, že rozříděné signály budou mít opravdu podobné frekvenční špičky. Tuto metodu je dále možné rozšířit o možnost sbínavání frekvenčních pásem. Tato metoda zaručí „zprůměrování“ frekvenčních pásem a byla popsána výše. Určitým způsobem snižuje rozlišovací úroveň frekvenční oblasti a je pak možné s větší efektivitou sledovat intenzitu jednotlivých pásem. Což u pouhé FFT nemusí být tak zřetelné, jako u sbínavané FFT. Existují další kvantitativní charakteristiky frekvenční oblasti, které ale nebyly v této bakalářské práci zkoumány. Jedná se o charakteristiky jako například spektrální entropie, spektrální špičatost, harmonický poměr, MFCC (mel-frequency cepstral coefficients), GTCC (gammatone cepstral coefficients) a podobné [5]. Tyto charakteristiky jsou ovšem vektory, nejedná se o skaláry.



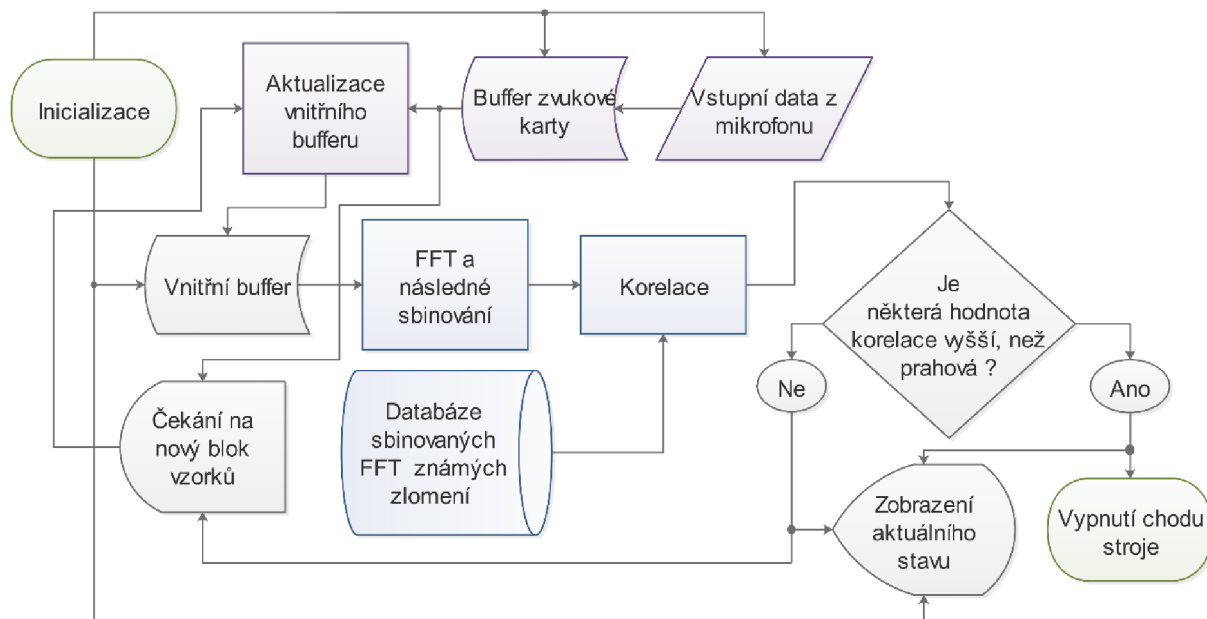
Obr. 20: Stavový diagram algoritmu kvantitativních charakteristik

Korelace databáze vektorů FFT

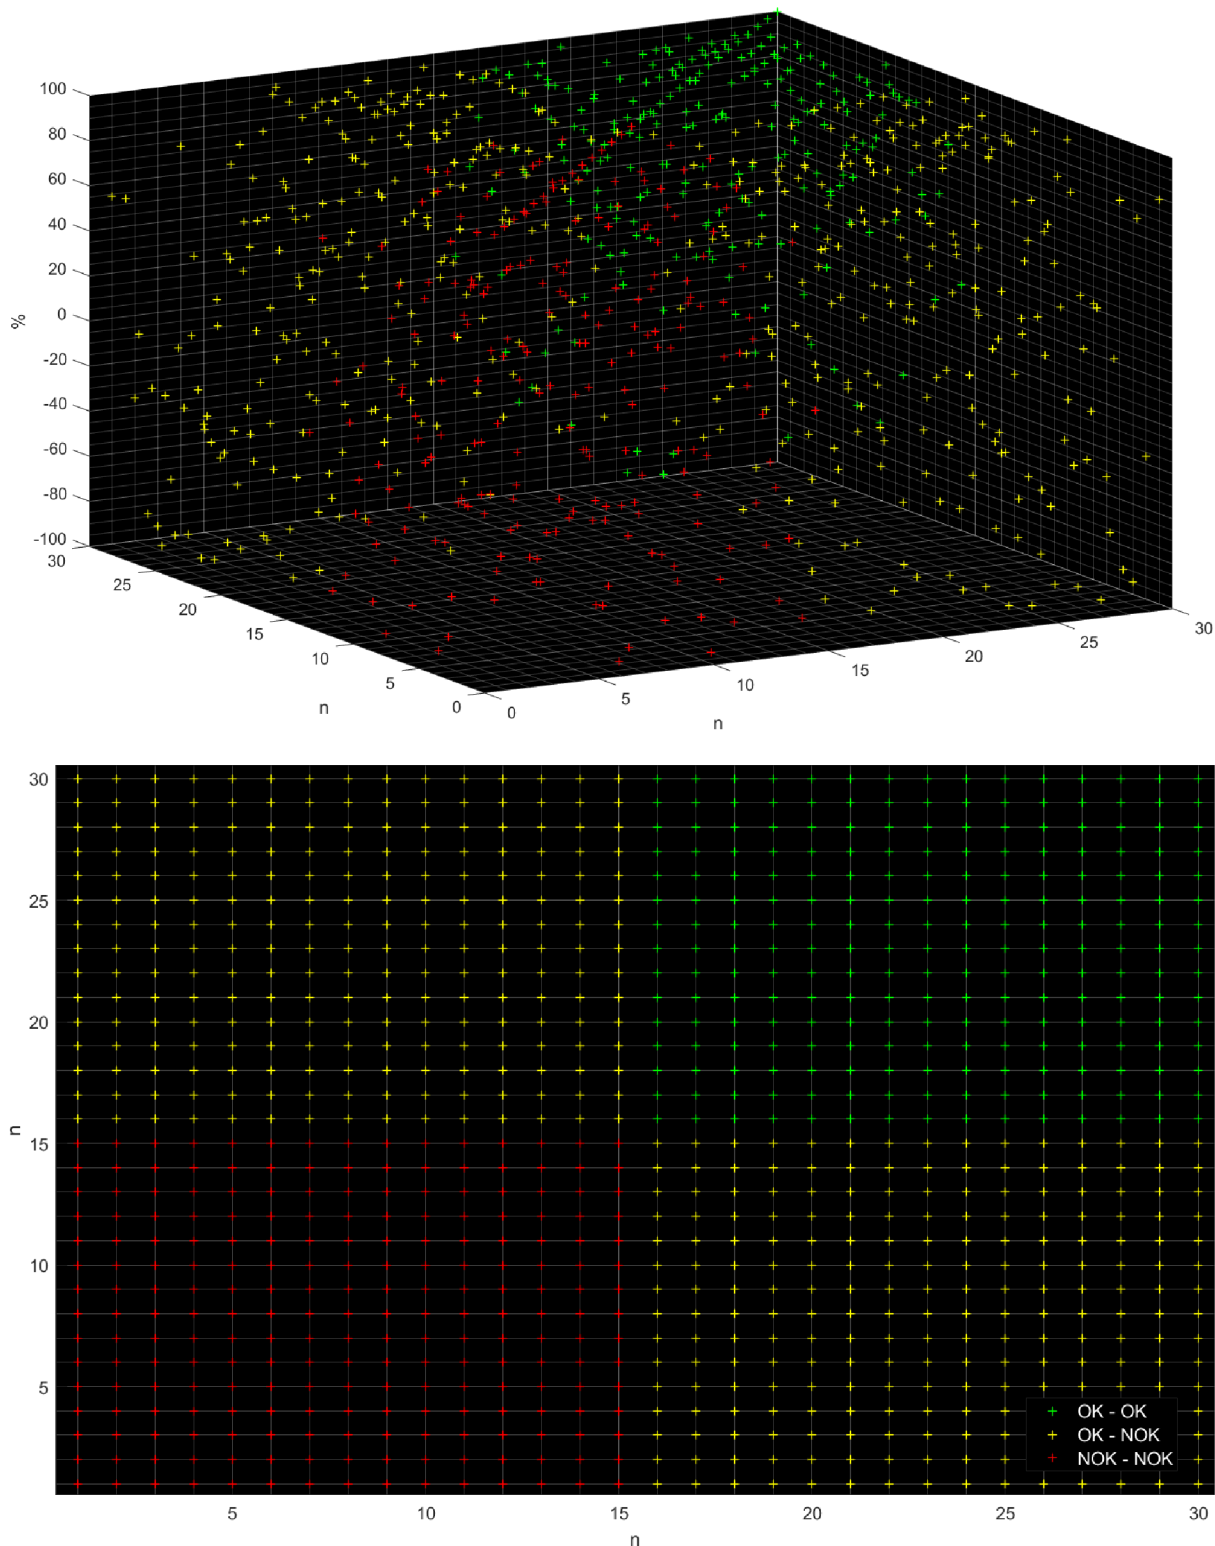
Další metodou, která byla realizována a implementována do realtime podoby, byla frekvenční korelace. Jde o metodu korelace FFT signálu z bufferu se sadou FFT zlomení. Korelace je postup umožňující ověřit podmíněnou závislost dvou sad statistických souborů. Číselnou kvantifikaci korelace je možné spočítat vzorcem:

$$\rho_{x,y} = \frac{\frac{1}{n} \cdot \sum_{i=1}^n (x_i \cdot y_i - \bar{x} \cdot \bar{y})}{S_x \cdot S_y} \quad (4)$$

Podstatou této metody je vytvoření určité prahové hodnoty korelace pro každé známé FFT zlomení, při jejímž překročení se stav vyhodnotí jako zlomení. Metoda předpokládá, že přichází zvuk zlomení bude mít větší korelaci, než prahovou korelaci s již zaznamenaným signálem zlomení. Pro to, aby tato metoda fungovala dobře, je nutné, aby bylo vzorků zlomení co nejvíce. Potom je možné s vysokou pravděpodobností konstatovat, že nově pořízený signál zlomení bude rozpoznán jako zlomení a systém vypne chod děrovacího lisu. Tato metoda má velkou nevýhodu v datovém toku a výpočtovém čase. Je tomu tak z důvodu prováděné korelace pro každý signál zvlášť. Jedná se o korelaci souboru hodnot o 8 501 prvcích pro signál o délce 17 000 vzorků. V případě, že je k dispozici 15 zlomení, půjde tedy celkem o provedení 15 korelací pro tyto soubory dat. Schopnost uplatnění v realtime tedy klesá s počtem vzorových signálů zlomení. Tento problém by bylo možné vylepšit vytvořením speciální funkce provádějící korelaci pro n souborů se sbínanou FFT z bufferu současně, což by značně urychlilo výpočetní čas funkce. Vybrání prahových korelačních hodnot pro jednotlivé signály bylo provedeno jednoduchým offsetem korelační úrovně pro jednotlivé vzorové signály zlomení se signálem pozadí. Pro tyto korelační úrovně by bylo nutné vymyslet propracovanější statistickou metodu offsetu pro lepší funkci metody.




Obř. 21: Stavový diagram algoritmu korelace databáze vektorů FFT



Obr. 23: Grafy frekvenční korelace – prostorový náhled, pohled shora pro korelační intenzitu v pásmu 315-322 Hz

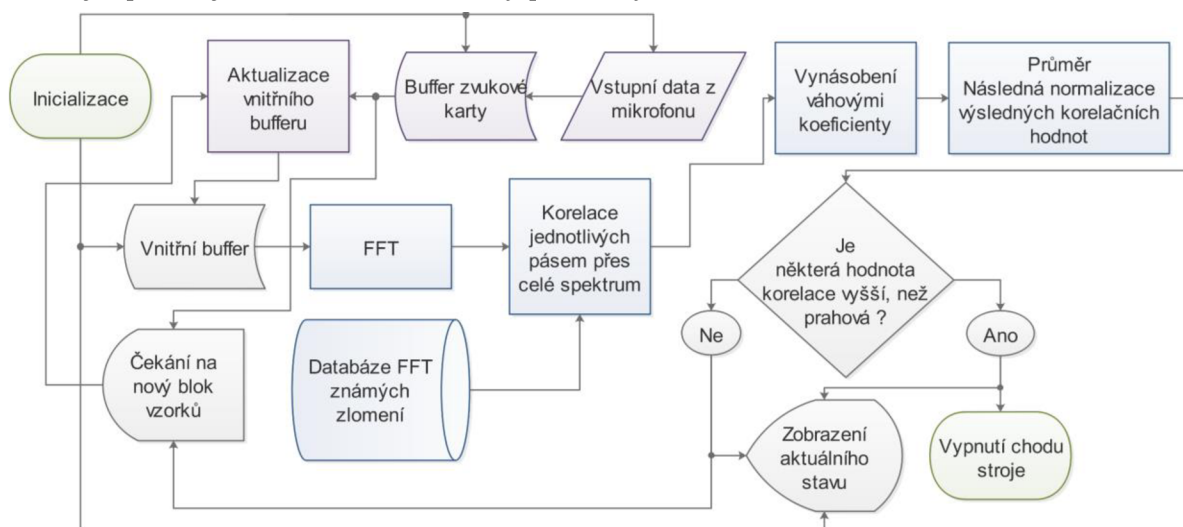
Toto je pouze získání vstupních dat. Pro další zpracování se provede statistické vyhodnocení intenzity v jednotlivých pásmech jak silnou korelaci má signál zlomení a signál pozadí v tom daném pásmu. Předpoklad je, že tam, kde mají silnou korelaci signály zlomení vzájemně mezi sebou a signály pozadí slabou, tam bude určité frekvenční pásmo, které bude mít pro výslednou

hodnotu korelace daleko větší váhu, než tam, kde mají zlomení slabou korelaci a pozadí silnou. Nebo také oblast se silnou vzájemnou korelací mezi signály pozadí a zlomení. V této oblasti se může právě nacházet určité rušení, které je obsaženo jak v signálu zlomení, tak i v pozadí (např. PWM signál motorů). V této práci bylo přistoupeno k získání jednotlivých vah průměrování jednotlivých korelací, čímž se výsledný čtyřdimenzionální prostor redukoval na dvojdimenzionální prostor.



Obr. 24: Průměr korelací jednotlivých tříd napříč frekvenčním spektrem rozděleným do pásem

Tyto hodnoty jsou pouze korelace jednotlivých tříd v konkrétních pásmech. Pro získání vlastních váhových koeficientů pro účely vážené korelace je třeba tyto hodnoty převést do absolutní hodnoty a připočítat hodnotu 1 ke každé hodnotě. Tento způsob získání váhových koeficientů je jednoduchým lineárním offsetem, který zajistí, že budou všechny váhové koeficienty větší než jedna a nebudou tak snižovat hodnotu výsledné korelace. Tyto hodnoty je možné již použít jako váhové koeficienty pro účely vážené frekvenční korelace.

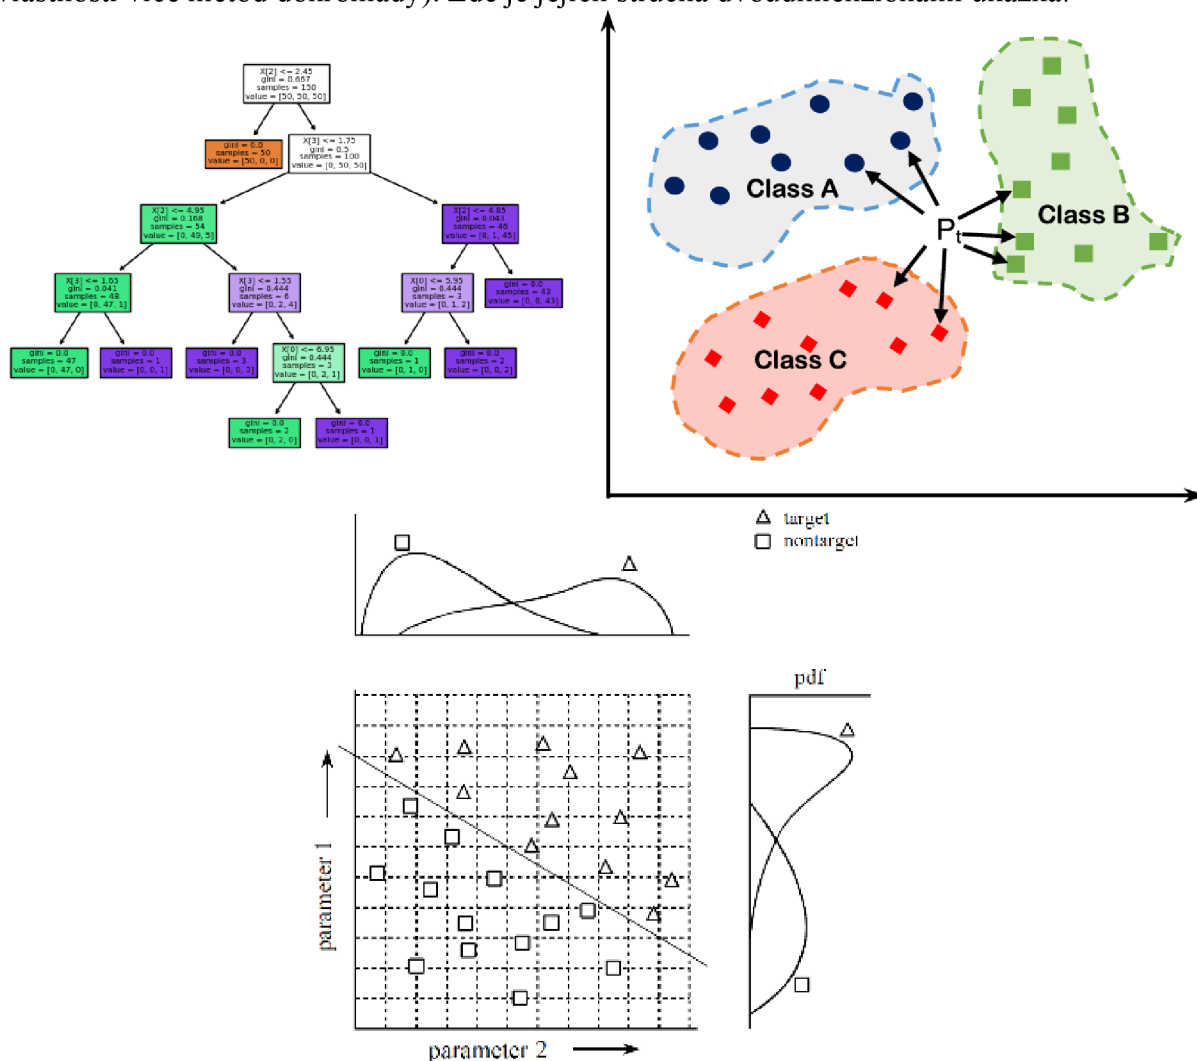


Obr. 25: Stavový diagram algoritmu vážené korelace databáze vektorů FFT

Výsledky souboru korelace zlomení s pozadím by se dalo využít pro zlepšení vstupních dat do korelace zahrnutím pouze pásma nad určitou prahovou hodnotou korelace s vynecháním pásem se silnou korelací signálu zlomení s pozadím.

4.2.3. Klasifikace strojovým učením

Klasifikace strojovým učením je metodou navrženou přesně pro sestavení modelu vhodného klasifikátoru. Jedná se v podstatě o algoritmus schopný strojově statistickými metodami vybrat konkrétní parametry daného trénovaného modelu. Těchto klasifikačních modelů existuje nespočet. Jde například o SVM (*Support Vector Machines*), KNN (*Algoritmus k-nejbližších sousedů*), rozhodovací stromy nebo ensemble (klasifikátory kombinující vlastnosti více metod dohromady). Zde je jejich stručná dvoudimenzionální ukázka:



Obr. 26: Ukázka klasifikačních algoritmů – rozhodovacího stromu, KNN a lineárního SVM; převzato z www.scikit-learn.org.

Každý z těchto modelů je přesně matematicky popsán. Vstupem do klasifikátoru je obecně n -rozměrný prostor určitých charakteristik dané entity. Tyto charakteristiky jsou skaláry, popřípadě komplexní čísla, nebo se může jednat také o složitější matematické konstrukce². Při trénování zvolené klasifikační metody jde pak většinou o nalezení určité nadroviny tohoto hyperprostoru, ve které lze statistickými metodami ze známých velikostí jednotlivých charakteristik zkoumaných entit vytvořit určité oblasti. Klasifikace nové entity pak probíhá tak, že do klasifikačního modelu přijdou n -rozměrná data, následně se vyhodnotí oblasti, které tyto entity zaujímají a podle toho se jedná buď o pozitivní, nebo negativní třídu – v případě binárního klasifikátoru³.

Výslednou klasifikační schopnost daného modelu je dále třeba validovat. Toto se může provést otestováním klasifikační schopnosti na entitách, které nebyly použity pro trénování klasifikačního modelu. Celkem je možné pro binární klasifikátor získat čtyři možné výsledky. Kladně pozitivní, falešně pozitivní, kladně negativní a falešně negativní výsledek. Přičemž váhu jednotlivých možných klasifikačních výsledků je možné nastavit. Způsob tohoto nastavení záleží na typu uplatnění. Je možné dodat, že zvolení správné úrovně klasifikační schopnosti je nelehký úkol, nad kterým je možné strávit spoustu času. Obecně existují dva možné způsoby trénování klasifikačního modelu. Jde o trénování s učitelem (*supervised*) a bez učitele (*unsupervised*). Trénování s učitelem funguje na principu sady známých vstupů a výstupů entit. Na vstupy se namapuje klasifikační model, který nejlépe odpovídá výstupům. Oproti tomu trénování modelu bez učitele je stav, kdy jsou známy pouze vstupy a výstupy už nikoli. Model tedy provede určité spárování vstupních entit podle jejich charakteristik do určitých oblastí.

Tato metoda má oproti jiným metodám prezentovaným v této práci výhodu, že dokáže implementovat prakticky všechny metody do jedné a vyhodnotit tak signál komplexně, namísto sledování pouze jedné nebo více charakteristik.

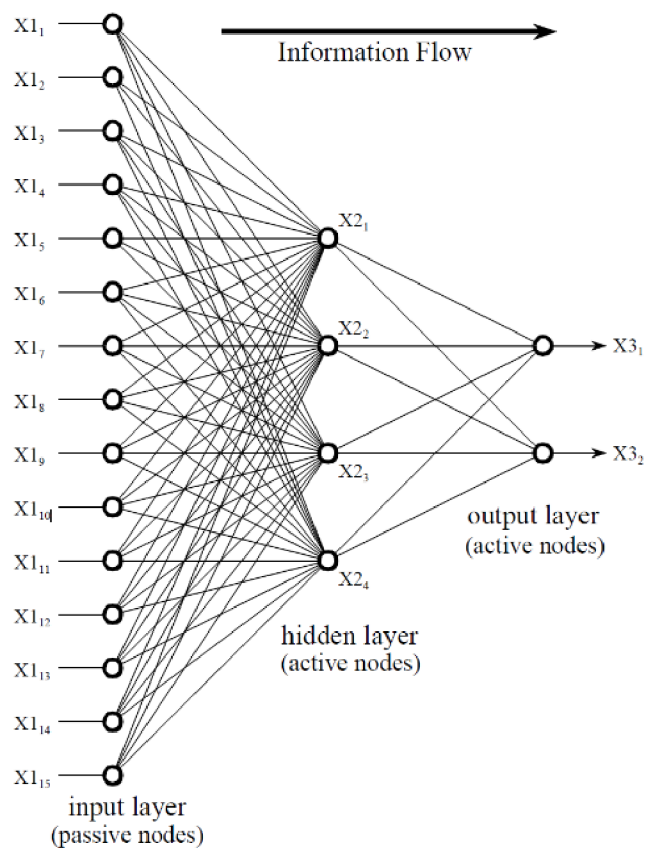
4.2.4. Klasifikace hlubokým strojovým učením

Tato oblast aplikované informatiky a matematiky je podoblastí klasifikace strojovým učením. Oproti předem definovaným hyperprostorovým modelům se jedná o tvorbu a následné trénování umělých neuronových sítí. Jejich princip fungování lze popsat na Obr. 27.

Na druhou stranu skutečná funkce je z matematického hlediska velmi obtížně popsatelná, ba prakticky nepopsatelná. Tato metoda je silně nelineární a vyžaduje obrovské množství dat pro kvalitní natrénování. Jejím prostřednictvím lze získat klasifikační schopnosti, které mohou být u běžných klasifikačních metod pracujících s lineárními bázovými funkcemi nedosažitelné.

² Z podstaty tomu nic nebrání, ale je třeba se zamyslet, jestli opravdu daný problém nejde řešit rozdělením do jednodušších částí.

³ Obecně je možné sestavit klasifikátor s n rozhodovacími stavů.



Obr. 27: Typické uspořádání neuronové sítě [13]

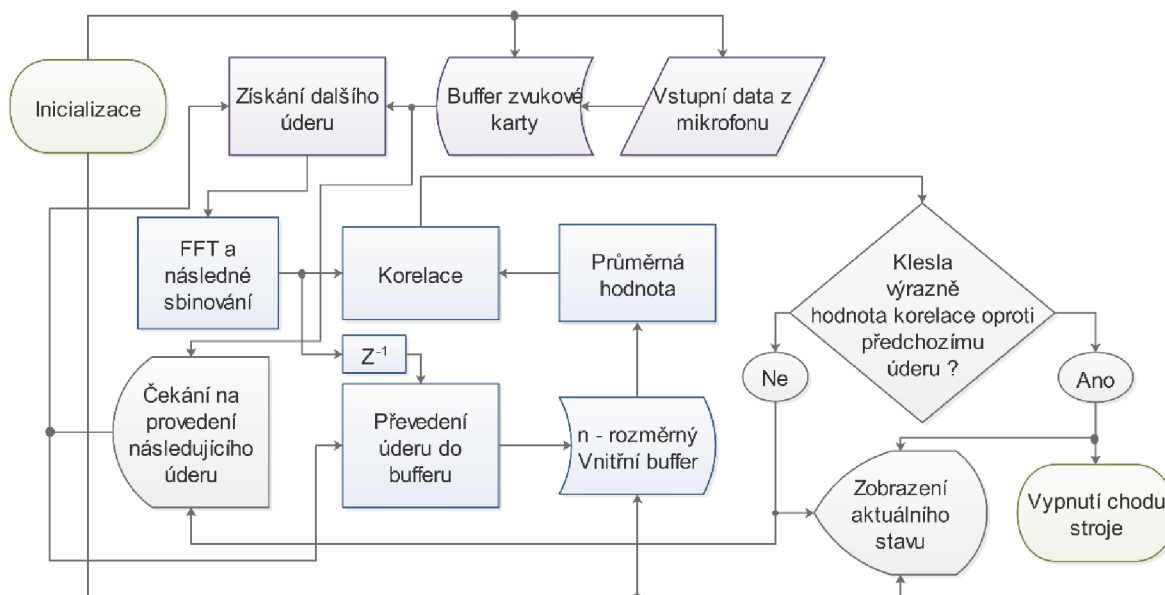
4.3. Odhad zbytkové životnosti razníku

Další oblastí, na kterou byla zaměřena bakalářská práce, je oblast možné predikce zlomení razníku (*RUL – remaining useful life*). V této aplikaci nastává problém, že vlastní signál děrujícího razníku je zanedbatelný vzhledem k okolním signálům a je tak velmi těžké detekovat možné změny jeho tvaru. Dalším problémem je fakt, že se v nástroji nachází celkem čtyři razníky. V případě jednoho problematického razníku ze čtyř mohou být tedy metody vyhodnocující nepatrné změny neúčinné až nefunkční. Byly tedy vytvořeny následující metody:

4.3.1. Korelace průměru bufferu FIFO s následujícím signálem ve frekvenční oblasti

První metodou, která v části RUL odhadu nástroje byla zkoumána, je postupná korelace FFT signálů úderů s průměrem předchozích FFT úderů. Podstata této metody je taková, že se vytvoří FIFO buffer s FFT n předchozích signálů. Statisticky se bude vyhodnocovat jejich průměr a v případě, že klesne korelace dalšího úderu pod určitou hodnotu, bude vyhodnoceno zlomení. Tato metoda je funkční za předpokladu časové invariance signálu úderu a za předpokladu, že je vlastní signál razníku zanedbatelný vzhledem k jiným signálům, které se vyskytují během chodu stroje. Dalším problémem je signál vytvářený plechem. Ten totiž během děrování přejíždí, jeho těžiště se posouvá, s tím i jeho vlastní frekvence kmitání. Operátor navíc musí s plechem během děrování občas různě manipulovat. Plech se při úderu vždy rozkmitá,

tím vytvoří dosti intenzivní vysoce variabilní signál, není ho možné jednoduše obyčejným filtrem odfiltrovat⁴ a snižuje tak navíc rozpoznatelnost vlastních zvuků razníků.

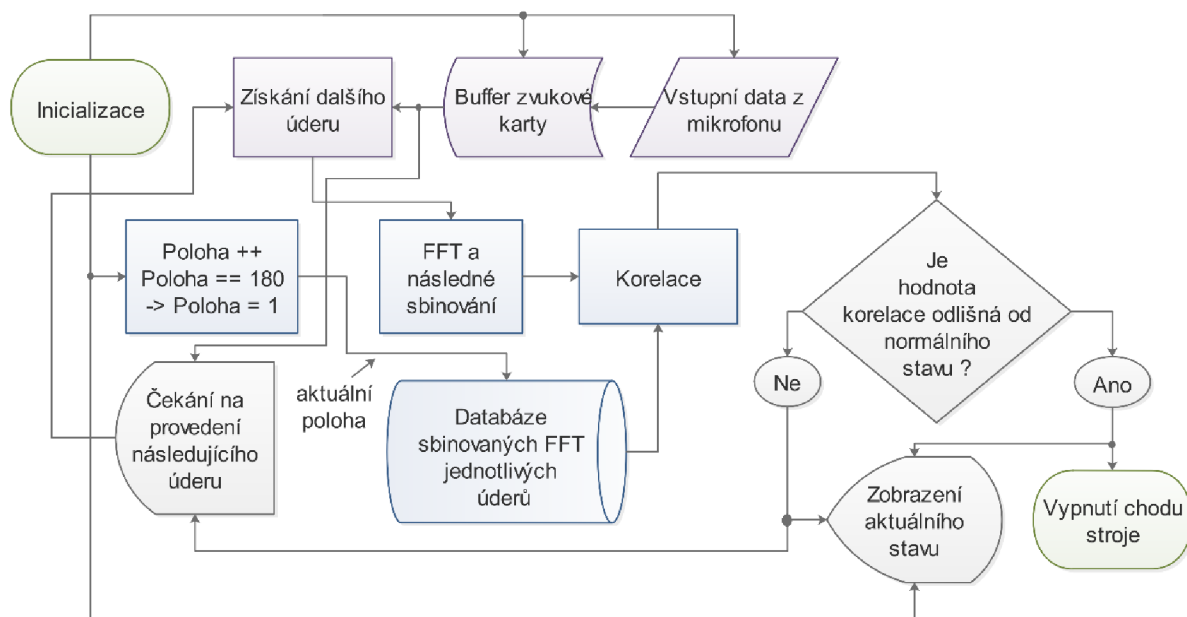


Obr. 28: Stavový diagram algoritmu frekvenční korelace průměru bufferu FIFO s následujícím úderem

4.3.2. Párování korelace FFT

Tato metoda byla vyvinuta jako vylepšená varianta metody předchozí. Má za cíl určitým způsobem eliminovat zvuky generované přejíždějícím plechem při úderech. Její princip spočívá ve vytvoření databáze zvuků jednotlivých po sobě jdoucích úderů na plechu. Korelace na další úder se pak provede s dalším v řadě následujícím úderem. Tuto metodu je dále možno vylepšit způsobem, kdy se pro každý úder vytvoří vlastní pásmovou zádrž, která zadrží vlastní frekvence plechu a signály na pozadí. Signál razníku by pak měl být teoreticky zřetelnější. Obě tyto metody (4.3.1. a 4.3.2.) jsou velice náchylné na vnější rušení. Mohly by fungovat za předpokladu přítomnosti pouze žádoucích signálů (razník a běžné pozadí), což v průmyslové oblasti nemůže nastat.

⁴ Nabízí se možnost použití adaptivního filtrování



Obr. 29: Stavový diagram algoritmu párované frekvenční korelace FFT

4.3.3. Další možné způsoby RUL odhadu

Jedna z možností je predikce zlomení posunutím určitých frekvenčních špiček na frekvenční ose několik úderů před zlomením. Metoda byla záhy vyloučena, protože FFT jednotlivých úderů je velice variabilní a posun ve frekvencích není možné detekovat. Pro účely testování této metody byl vytvořen soubor deseti sad po deseti úderech před zlomením razníku. Postupně byla zkoumána sbívaná FFT jednotlivých signálů umožňující zřetelnou detekci frekvenčního posunu v určitém frekvenčním pásmu přímo na monitoru. Takový frekvenční posun nebyl nikdy detekován. Navíc jsou v nástroji celkem čtyři razníky, což znamená, že při posunu frekvence u jednoho razníku by intenzita původní frekvence mohla klesnout jen nepatrně a posunutá frekvence by tak mohla mít pouze minoritní intenzitu. Během testování metody byla napsána i funkce podobná binování, která ovšem signál nesčítala, ale počítala rozptyl ve frekvenčním pásmu. Rovněž při tomto postupu nebyl detekován žádný záchytný bod, který by bylo možné použít pro odhad zbytkové životnosti razníků. Současně byla porovnávána FFT několika úderů těsně před zlomením a náhodně vybraným OK úderem, kdy nedošlo ke zlomení razníku při dalších 2 000 úderech.

Další metodou použitelnou pro odhad zbytkové životnosti razníku je klasifikace strojovým učením včetně hlubokého strojového učení. Tato metoda by mohla přinést určité výsledky, nebyla ale realizována z důvodu předpokladu malé pravděpodobnosti úspěchu a hlavně faktu, že i detekce zlomení při úderu během obyčejných metod klasifikace je efektivní maximálně ve zhruba 10 vzorcích z celkového počtu 24. Výsledný algoritmus pro RUL odhad by tedy nemusel pracovat ideálně a mohl by mylně hlásit závadu, což je nežádoucí.

4.4. Podobné aplikace prediktivní údržby v průmyslu

V rámci bakalářské práce byly v oblasti možné predikce zlomení zkoumány způsoby prediktivní údržby nástrojů děrovacích lisů používaných v průmyslu. Souhrnnou rešerší této problematiky vytvořili např. Voss [15] či Badgujar et al. [1]. Bylo zjištěno, že tato oblast je prozkoumána do takové míry, že lze poměrně dobře detekovat blížící se konec životnosti razníku. Je předpoklad, že při blížícím se konci životnosti razníku, začne docházet k tvorbě otřepů v dírách následkem opotřebení matrice a razníku. Ubhayaratne et al. [14] ve své práci potvrdili, že existuje silná korelace mezi stavem opotřebení nástroje a zvukovým signálem generovaným při stříhu. Pro účely predikce stavu nástroje byly testovány různé senzory. Kromě detekce signálů pomocí mikrofону bylo rovněž testováno využití děrovací síly, signálu silového napětí nástroje, akustické emise a detekce vibrací [1, 16]. Bylo dokázáno, že při děrování tupým nástrojem, kdy dochází k otěru děrovaných hran děr o samotný razník (tzv. galling), jsou zvětšeny statistické metriky, jako je RMS nebo špičková hodnota amplitudy signálu [12]. Kromě výše zmíněného, bylo zjištěno, že zvýšený otěr nástroje je doprovázen zvýšením energie v určitém frekvenčním pásmu [10, 11]. Klesající životnost razníku byla rovněž detekována pomocí frekvenčního posunu [12]. Autoři Shanbhag et al. [12] popsali metodu estimace průměrné frekvence (mean frequency estimate). Předmětem zkoumání mnoha autorů byly časově-frekvenční vlnkové transformace získaných signálů [1, 12, 14, 16]. V publikovaných pracích byla testována možnost vytvoření modelu logistické regrese s různými konfidenčními intervaly se vstupními charakteristikami získanými jak z časové, tak z frekvenční oblasti [16]. Rovněž bylo zjištěno, že existuje komerční řešení umožňující vytvoření systému prediktivní údržby pro predikci stavu nástroje, jako například: *Autoform DieAdviser^{plus}* [4].

5. VÝSLEDKY APLIKACE KLASIFIKAČNÍCH METOD

V této kapitole jsou prezentovány dosažené výsledky při použití jednotlivých algoritmů. Podkapitoly 5.1 a 5.2 prezentují detailní popis jejich funkce v grafech včetně popisu důvodu odlišného chování od očekávaného. Podkapitola 5.3 prezentuje výsledky všech použitých metod v tabulce včetně trvání výpočetního času.

5.1. Detailní popis účinnosti jednotlivých metod

5.1.1. Metody vyhodnocení časové oblasti

Autokorelace

První věc uskutečněná během realizace této metody bylo vytvoření průměrných zvuků úderu naprázdno s nástrojem, kdy se nic nestalo a rovněž s nástrojem, kdy se zlomil razník. Následně bylo potřeba odečíst od OK a NOK úderů průměrný signál úderu naprázdno, čímž se získal zprůměrovaný signál OK a NOK úderu – pouze signál samotného nástroje při děrování včetně zvuku razníku. Takto získaný signál byl následně odečten od NOK úderu, při kterém razník prasknul. Tímto se měl získat zvuk, který vydá průměrné zlomení. S těmito dvěma zvuky se měla následně provádět autokorelace. V případě, že by se snížila hodnota autokorelace na OK úder a zvýšila na NOK úder, mělo být vyhodnoceno zlomení. Měly být nalezeny číselné prahy pro OK a NOK signály, při kterých bude stroj vypnut. Už při získávání samotného zvuku při úderu naprázdno ale tato metoda přestala fungovat. Nahrané zvuky nejsou fázově identické. I vlastní signály úderu naprázdno mají drobné rozdíly, nejsou dva údery, které by byly

identické. Tato metoda je tedy nefunkční a není ji možné použít pro účely detekce zlomení razníku při úderu.

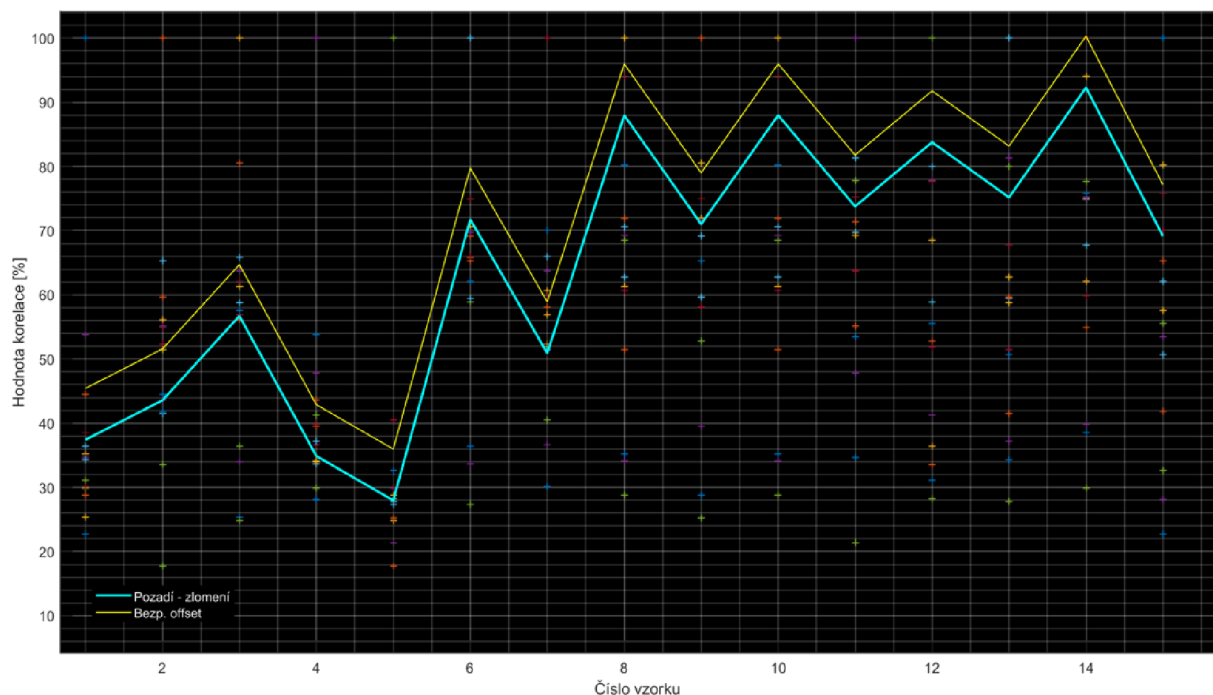
5.1.2. Metody vyhodnocení frekvenční oblasti

Kvantitativní charakteristiky FFT

Tato metoda byla nepoužitelná, protože systém nevykazoval frekvenční stabilitu na určité konkrétní frekvenci nebo ve frekvenčním pásmu, tudíž není možné použít pouze frekvenční špičky jako indikátor zlomení. Bylo ale zjištěno, že systém při zlomení vykazuje větší intenzitu v nižších frekvencích, než ve vyšších. Signál zlomení při přejezdu je ale aktivní i v oblasti nad 10 kHz. Toto bylo zjištěno při aplikaci vysokopásmové propusti na signály zlomení (frekvence nad 10 kHz). I po odfiltrování frekvencí pod 10 kHz byla většina zlomení slyšet.

Korelace databáze vektorů FFT

Tato metoda byla realizována do finální podoby v *Simulinku*. Byla vytvořena *m-funkce*, která prováděla korelaci *FFT* pro jednotlivé signály zlomení s aktuálním signálem z bufferu. Kromě toho, že tato metoda byla velice pomalá⁵ měla i velmi neuspokojivé výsledky. Dokázala sice rozpoznat 4 signály zlomení, které nebyly v databázi, a odfiltrovat pozadí, které nebylo nastaveno pro velikost offsetu, ale další zvuky přítomné při realtime provozu byly chybně interpretovány jako zlomení⁶. Nefunkčnost metody byla velmi pravděpodobně zapříčiněna použitím jiného mikrofону, než jakým byla vstupní data nahrána. Mikrofon sloužící k nahrání měl totiž poměrně velké tlumení šumu, na rozdíl od signálu z mikrofónu webkamery⁷.



Obr. 30: Graf korelace všech zlomení navzájem

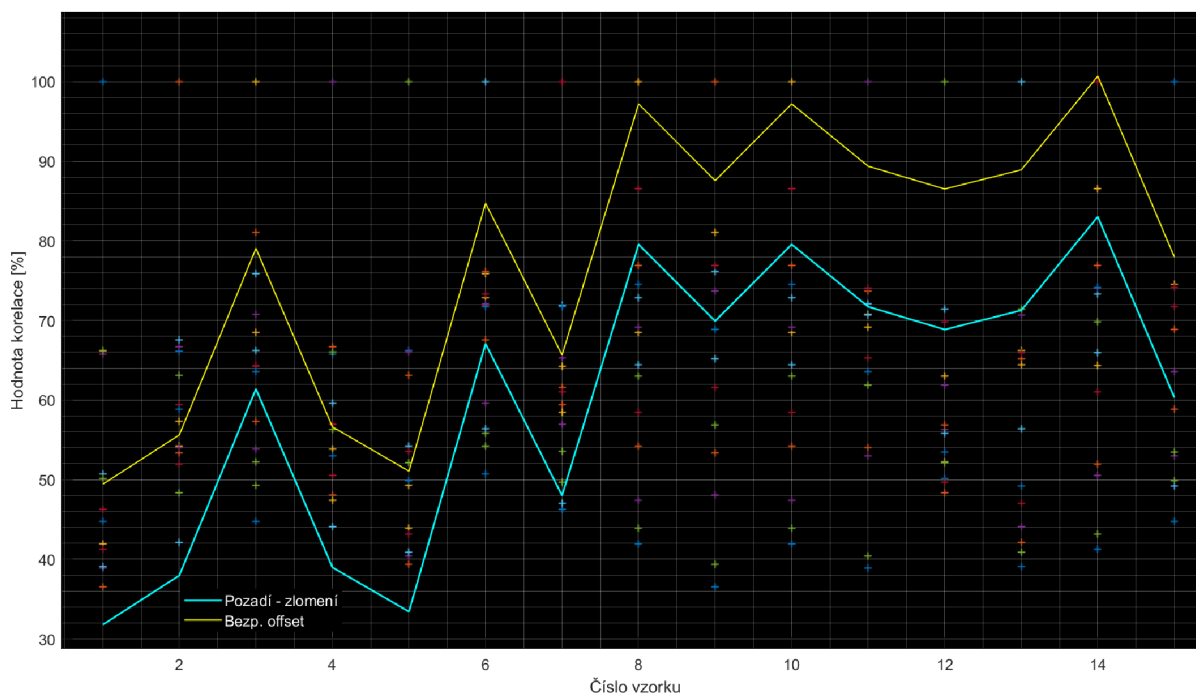
⁵ Zapříčiněno pravděpodobně způsobem realizace.

⁶ Mluvené slovo, poklepání o stůl.

⁷ Funkčnost metody by značně vylepšilo použití filtrace

Vylepšená korelace databáze vektorů FFT

Použití této metody mělo velice znatelný vliv na rozpoznávací schopnost výsledného algoritmu:




Obr. 31: Graf vylepšené korelace všech zlomení navzájem

Tuto metodu by bylo možné vylepšit použitím obdélníkového filtru pro získání nezarušeného signálu.

Vážená korelace databáze vektorů FFT

Tato metoda byla plně otestována se zjištěním, že je nepoužitelná z důvodu dlouhého času trvání výpočtu. Korelace pro každý 80 ms vzorek na procesoru *Intel Core i-7 9600U* se vstupním signálem trvá 14,6 ms pro signál zlomení při přejezdu. Při počtu 15 vzorků to je tedy víc než 200 ms. Což není dostatečně krátká výpočetní doba a tato metoda je rovněž nepoužitelná. Má ovšem daleko lepší výsledky než obyčejná frekvenční korelace:



Obr. 32: Graf vážené korelace všech zlomení navzájem

5.1.3. Klasifikace strojovým učení

Pro výsledný klasifikační model bylo tedy zvoleno strojové učení předdefinovaných modelů. Tato možnost je k dispozici ve velmi pohodlné, rychlé a jednoduché formě díky softwarovému balíku *Matlab*[®]. V tomto softwaru existuje možnost přidání dodatečné softwarové komponenty *Statistics and machine learning toolbox*. V tomto toolboxu je aplikace *Classification learner*, která obsahuje předdefinované klasifikační modely. Tyto modely pak dokáže natrénovat, a to včetně následné validace. Tato aplikace obsahuje celkem 7 různých modelů ve 23 různých variantách (verze 12.1). Navíc u většiny modelů existuje možnost využití optimalizace⁸ [6]. Dále k těmto možnostem existuje navíc možnost natrénování předtrénovaných neuronových sítí. U těchto neuronových sítí jde navíc nastavovat způsob aktivace neuronů (Tanh, Sigmoida, ReLU, nebo bez aktivace) a taky jde nastavit topologii sítě (max 3 úrovně vrstev a plně nastavitelný počet neuronů v nich).

Trénování těchto modelů probíhá formou trénování s učitelem. V rámci bakalářské práce byla obšírně zkoumána možnost použití různých modelů SVM, KNN, Ensemble a podobně. Byly natrénovány všechny dostupné modely, byly vyzkoušeny různé váhy u nastavitelné váhové matice (nastavovala se zvýšená váha u klasifikace zlomení jako OK zvuku). Výsledkem je, že nejlepším modelem bylo obecně SVM a RUSboost ensemble⁹. Tyto modely už ale při realtime validaci nebyly tak úspěšné, jako na grafu validace v *Classification learner*. Byla proto vyzkoušena možnost natrénování neuronové sítě. Výsledná neuronová síť má konkrétně dvě vrstvy, z čehož první má 53 neuronů, druhá 5. Tyto počty byly ověřeny jako suboptimální,

⁸ V aplikaci *ClassificationLearner* jde nastavit Bayesovou optimalizaci, mřížkové hledání a genetický algoritmus

⁹ RUSboost je ensemble model, který redukuje nerovnováhu u vstupních dat tím, že náhodně vybere vzorky z dat, kterých je řádově víc, než jiných

protože mají daleko lepší výsledky, než kdyby první vrstva měla 54, nebo 52 a druhá 4 nebo 6. Tato neuronová síť má daleko lepší parametry při realtime provozu než blízké jiné.

Výběr klasifikačního modelu byl velmi ovlivněn i výpočetním časem modelu. V tomto ohledu neuronová síť výrazně převyšuje většinu jiných modelů, výpočet trvá přibližně 12 ms. Optimalizované modely vykazovaly výpočetní čas někdy delší než 40 ms. Proto je použití klasifikačního modelu neuronové sítě vhodnou variantou pro daný účel. Vhodnost neuronové sítě je také dána vysokou variabilitou vstupních dat, kterých je navíc málo. Jde o nepoměr 5 175 signálů pozadí k 15 signálům zlomení. Pro účely trénování modelu byly využity všechny dostupné vzorky zlomení. Validován byl až výsledný klasifikační model při realtime funkci. Kdyby bylo dostupných více signálů pozadí, mohly by lineární modely fungovat daleko lépe. Neuronová síť by na druhou stranu mohla být na tom dokonce řádově lépe. Celkový čas věnovaný tvorbě klasifikačního modelu mohl být odhadem kolem 40 hodin čistého času. Byla vyzkoušena i možnost PCA (Analýza hlavních komponent). S výsledkem, že použití této metody pro redukci vstupních dat má za výsledek jenom zhoršení klasifikační metody, nikdy nebylo pozorováno zlepšení klasifikace natrénovaného modelu při použití PCA.

Tab. 2: Přehled vybraných charakteristik zahrnutých do klasifikačního modelu

Charakteristika	Stručný popis	Vzorec
Časová oblast		
Clearance faktor	Tato charakteristika má špičkovou hodnotu u nových ložisek a klesá s jejich snižující se životností	$x_{\text{clear_f}} = \frac{x_{\text{peak}}}{\left(\frac{1}{N} \sum_{i=1}^N \sqrt{ x_i }\right)^2}$
Činitel výkyvu	Poruchy se projevují nejprve v podobě změn ve špičkách signálů předtím, než se projeví v energii signálu reprezentovanou efektivní hodnotou	$x_{\text{crest_f}} = \frac{x_{\text{peak}}}{\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}}$
Impulse faktor	Porovnání výšky špičky k průměrné hodnotě	$x_{i_f} = \frac{x_{\text{peak}}}{\frac{1}{N} \sum_{i=1}^N x_i }$
Koeficient špičatosti	Vytváření poruch se může projevit vytvářením lokálních špiček	$x_{\text{kurt}} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{\left[\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2\right]^2}$
Průměrná hodnota	V případě některých aplikací se může porucha projevit zvýšením střední hodnoty	$x_{\text{mean}} = \frac{1}{N} \sum_{i=1}^N x_i$
Špičková hodnota	Velikost špičkové hodnoty signálů může vypovídat o poruše	$x_{\text{peak}} = \max(x)$
Efektivní hodnota	Jedná se o metriku vypovídající o velikosti energie digitalizovaného signálu	$x_{\text{RMS}} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
SINAD	Poměr signálu k šumu a zkreslení	$x_{\text{SINAD}} = \frac{P_{\text{signal}} + P_{\text{noise}} + P_{\text{distortion}}}{P_{\text{noise}} + P_{\text{distortion}}}$

SNR	Poměr signálu k šumu	$x_{\text{SNR}} = \frac{P_{\text{signal}}}{P_{\text{noise}}}$
THD	Celkové harmonické zkreslení; Jedná se o metriku kvantifikující harmonické zkreslení přítomné ve vstupním signálu; Čím nižší je tato metrika, tím kvalitnější je digitalizovaný signál	$x_{\text{SNR}} = \frac{\sum P_{\text{harmonic frequencies of } n+1 \text{ order}}}{P_{\text{first order harmonic frequency}}}$
Faktor tvaru	Faktor tvaru je závislý na tvaru signálu, přičemž je nezávislý na dimenzi signálu	$x_{\text{s}_f} = \frac{x_{\text{rms}}}{\frac{1}{N} \sum_{i=1}^N x_i }$
Koeficient šikmosti	Popisuje asymetrii signálu	$x_{\text{skew}} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{\left[\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \right]^{3/2}}$
Směrodatná odchylka	Jedná se o metriku popisující výkyvy od střední hodnoty	$x_{\text{s}_f} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$
Frekvenční oblast		
Clearance faktor	Jde o odhad výběru konkrétních charakteristik, jelikož popisují vektor hodnot určitým způsobem s ohledem k vektoru jako k celku a ne pouze k jedné hodnotě.	
Efektivní hodnota		
Šikmost		
Směrodatná odchylka		
Intenzita frekvenčních pásem	79 frekvenčních pásem pro signál při přejíždění po 9 Hz a 53 pro úder po 25 Hz. Signál je rozdělen do těchto pásem s ohledem na velikost vektoru po provedení FFT. Požadavkem byla korelace alespoň pěti hodnot, proto není možné provádět například binování po pásmu 1 hertzu (bez použití složitějších metod (lineární aproximace a podobně)). Tyto konkrétní frekvenční špičky byly vybrány pomocí výsledků vážené korelace.	

[7]

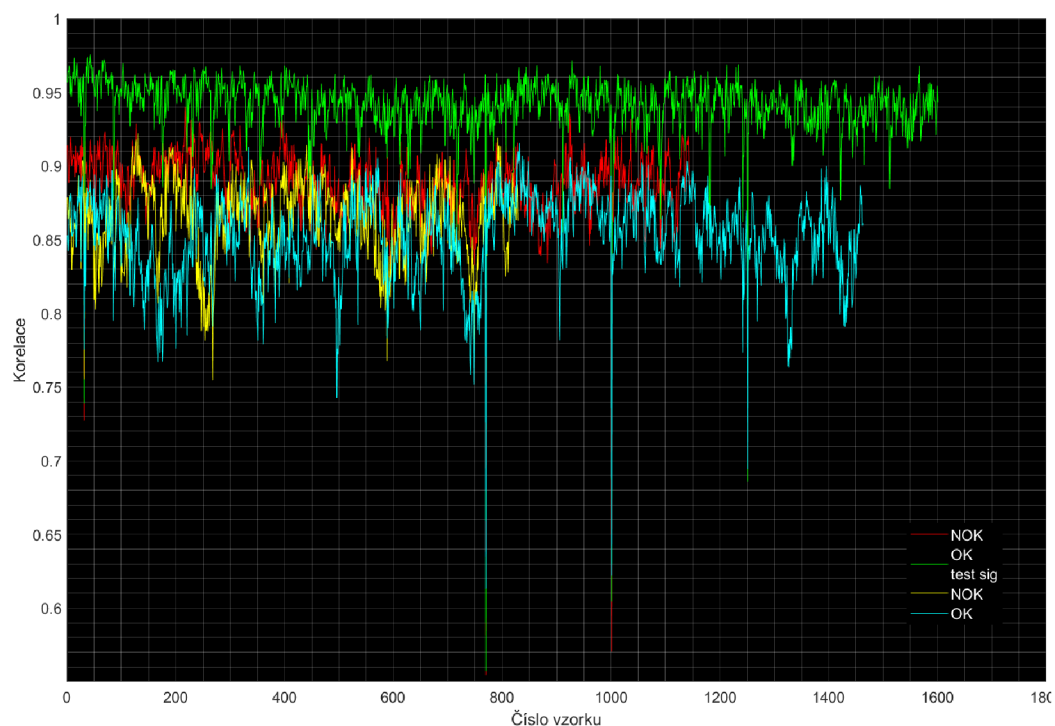
5.2. Odhad zbytkové životnosti razníku

Metoda korelace bufferu FIFO s následujícím signálem ve frekvenční oblasti byla vyhodnocena jako nefunkční. Nelze ji použít pro odhad zbytkové životnosti razníku (viz. Obr. 33).



Obr. 33: Graf frekvenční korelace průměru bufferu FIFO s následujícím úderem

Metoda párované korelace FFT je rovněž nepoužitelná pro odhad zbytkové životnosti razníku.



Obr. 34: Graf frekvenční korelace průměru bufferu FIFO s následujícím úderem

5.3. Stručné porovnání metod

5.3.1. Zlomení razníku

Níže uvedená tabulka č. 3 prezentuje efektivitu a výpočetní náročnost jednotlivých výše uvedených metod. Všechny uvedené metody byly do určitého stupně testovány. Ověření výpočetního času bylo provedeno na procesoru *Intel Core i7-9600U* pro 10 000 iterací a signál čítající 17 640 vzorků.

Tab. 3: Srovnání klasifikačních metod zlomení

Metoda	Výsledek	Poznámka	Výpočetní čas	Směrodatná odchylka
Kvantitativní charakteristiky FFT	Funguje	Nepraktická	11,7 μ s	13,7 μ s
Subtrakce signálů s následnou autokorelací	Nefunguje	Časová i frekvenční oblast	5,80 ms	0,80 ms
Kvantitativní charakteristiky frekvenční oblasti	Nefunguje	Vysoká variabilita FFT	247 μ s	70 μ s
Intenzita frekvenčních oblastí - binning	Nefunguje	Vysoká variabilita FFT	693 μ s	206 μ s
Korelace databáze vektorů FFT	Funguje částečně	Realizovaná v Simulinku	68,9 μ s / vzorek	17,2 μ s / vzorek
Vylepšená korelace databáze vektorů FFT	Funkční, částečně použitelná, nutné vhodně nastavit	Výrazně lepší chování než „základní“ verze realizovaná v Simulinku	68,0 μ s / vzorek	16,0 μ s / vzorek
Vážená korelace databáze vektorů FFT	Teoreticky funkční, nepoužitelná	Dlouhý čas výpočtu	14,6 ms / vzorek	0,94 ms / vzorek
Klasifikace strojovým učením	Vyhovuje, funkční	Zvolena neuronová síť jako výsledný klasifikační model	20,8 ms	3,1 ms

5.3.2. Odhad zbytkové životnosti razníku

Tab. 4: Srovnání zkoušených a navržených metod prediktivní údržby

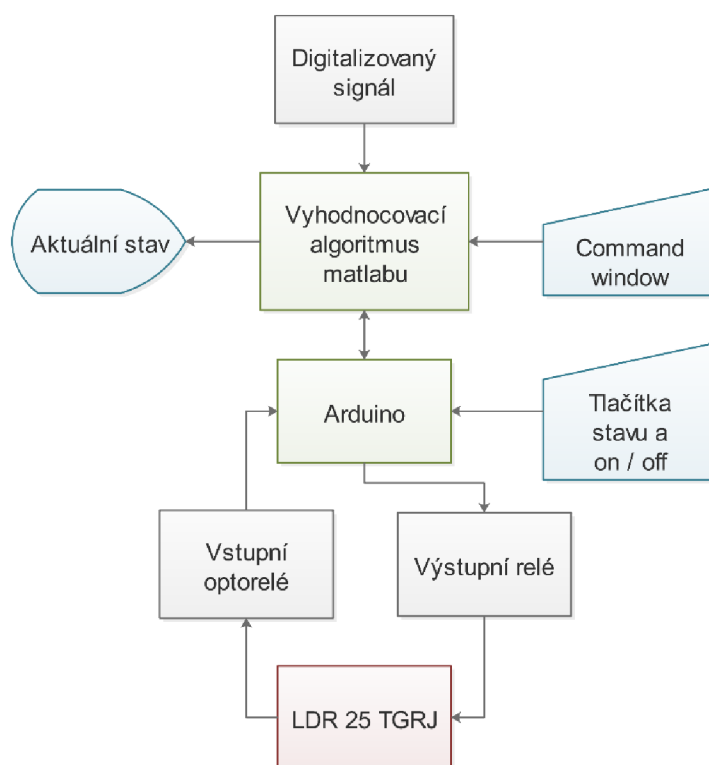
Metoda	Výsledek	Poznámka
Korelace bufferu FIFO s následujícím signálem ve frekvenční oblasti	Nefunguje	
Párovaná korelace FFT	Nefunguje	
Klasifikace strojovým učením	Nehodnoceno	Pravděpodobně by nevedla k produktivním výsledkům (z výše uvedených důvodů)

6. IMPLEMENTACE KLASIFIKAČNÍHO SYSTÉMU V REALTIME

Jako poslední byla v bakalářské práci provedena implementace systému do realtime podoby.

6.1. Real-time algoritmus v Matlabu[©]

Pro implementaci výsledného systému bylo zvoleno prostředí *Matlab*[©]. K této volbě bylo přistoupeno z časových důvodů a rovněž kvůli možnosti vygenerovat C++ kód přímo z *Matlabu*[©]. Pro realtime digitalizaci zvuku byl využit Audio toolbox poskytující *audioDeviceReader*, který vrací počet n vzorků z bufferu zvukové karty. Navržen a implementován byl následující algoritmus:




Obr. 35: Stavový diagram algoritmu klasifikačního systému – obecně


6.2. Vytvoření filtru

Filtr je základní součástí algoritmu implementovaného v realtime. Filtr byl vytvořen samostatně pro zlomení při přejezdu a zlomení při úderu. Byl zvolen *FIR* filtr typu equiripple, který má v realizované podobě po částech lineární fázi. Filtr pro zlomení při přejezdu má 7 528 vzorků, filtr pro zlomení při úderu má 10 000 vzorků. Filtrují se signály, které mají 17 640 vzorků (zlomení při přejezdu) a 17 700 vzorků (zlomení při úderu). Informace o možném filtrování vynásobením obdélníkovým oknem ve frekvenční oblasti byla zjištěna až po kompletním vytvoření filtrů. Filtrace byla ponechána ve své podobě. Kompletní předělání do ideální filtrace by nemuselo přinést velké zlepšení. Samotné filtrování filtrem equiripple, který má útlum -25 dB, se jeví jako dostatečné. Pro filtraci byla využita funkce *Matlabu*[©] *fftfilt*(filtrační_koeficienty, filtrovaný_signál). Tato funkce provádí filtraci konvolucí ve frekvenční oblasti a její provedení trvá cca 1ms. Tato doba je přijatelná. Filtrovaná pásma byla

zjištěna způsobem postupného zobrazování FFT pozadí na monitoru. Při identifikaci zvýšené intenzity určité frekvence byla tato frekvence zapsána do tabulky. Takto bylo analyzováno celé využitelné spektrum: 0–20 kHz. Bylo zjištěno, že mikrofon funguje akceptovatelně do 20 kHz, pak nastává vysoký útlum. Pásmo 20–22,05 kHz je tedy nevyužitelné.




Obr. 36: Frekvenční a fázová odezva FIR filtru pro signál přejíždění




Obr. 37: Frekvenční a fázová odezva FIR filtru pro signál úderu

6.3. Ukázka vyfiltrovaných signálů

Níže je ukázka vyfiltrovaných signálu zlomení při přejezdu a úderu vytvořenými filtry:



Obr. 38: Filtrované signály zlomení při přejíždění



Obr. 39: Filtrované signály zlomení při úderu

6.4. Sestavení funkce vracející charakteristiky signálu

Funkce vracející charakteristiky signálů je jednou z hlavních součástí celého systému. Tato funkce byla tvořena postupně. Nejprve byla vygenerována funkce z *diagnosticFeatureDesigneru*, která vracela charakteristiky z časové oblasti signálu. Tato funkce nebyla ideální z důvodu neoptimálně generovaného kódu. Funkce pro průměr vstupního souboru dat se v ní počítala cca 14 krát. Pro soubor, který má 14 112 vzorků (zlomení při přejezdu) se tedy neprovede výpočet pouze pro 14 112 vzorků, ale celkem pro 197 568 vzorků, což je v realtime systému nevhodné. Jedná se o funkci *mean()*, ve vygenerované funkci se ale počítalo vícekrát několik dalších podobných charakteristik. Důležitá část této funkce byla tedy vyextrahována do samostatné funkce, která byla následně přepsána tak, aby se tyto charakteristiky počítaly pouze jednou. Optimalizace proběhla i do další úrovně. U speciálních charakteristik jako je THD (*Total Harmonic Distortion*), *kurtosis* a *SINAD* se počítá uvnitř těchto funkcí vždy periodogram a vždy se generuje Kaiserův filtr pro vstupní filtraci signálu. Ve funkci extrahující charakteristiky se tyto tři funkce volají. Jádra těchto funkcí byla vyextrahována do samostatných funkcí, do kterých vstupuje periodogram a Kaiserův filtr. V konečném důsledku se tedy nepočítají tři periodogramy, ale pouze jeden. Vstupní filtr byl zaveden jako proměnná typu *persistent*, která se vygeneruje jednou při prvním zavolání funkce a následně zůstane v paměti. Optimalizovány byly i další funkce, například funkce *mean*. Při jejím otevření totiž lze zjistit, že čítá 200 řádků. Z toho důvodu byla napsána nová funkce *mean*, která má pouze jeden řádek. Toto bylo provedeno i pro další dvě funkce, které šly jednoduše optimalizovat.

Dále byla vylepšena funkce binující plochu pod FFT křivkou tak, že počítá pouze žádaná pásma. Ve výsledku tedy výpočet optimalizované funkce počítající 13 charakteristik z časové oblasti a 215 frekvenčních pásem¹⁰ trvá 8,2 ms se směrodatnou odchylkou 1,3 ms, oproti původnímu času 17,5 ms neoptimalizované verze se směrodatnou odchylkou 2,1 ms. Finální funkce, která navíc počítá statistické charakteristiky z frekvenční oblasti a vytvoří tabulku obsahující všechny vypočítané charakteristiky pro klasifikační model, trvá 11 ms se směrodatnou odchylkou 10 ms. Všechny testy funkcí byly provedeny pro 10 000 iterací na procesoru *Intel Core i7-9600U*. Do funkce byly zahrnuty všechny lineární charakteristiky nabízené aplikací *diagnosticFeatureDesigner*, dále čtyři statistické charakteristiky z frekvenční oblasti a celkem 79 frekvenčních oblastí. Tyto oblasti byly vybrány z výsledků vážené frekvenční korelace. Jde o pásma, ve kterých mají mezi sebou větší korelaci signály zlomení se signály zlomení a zároveň menší korelaci s pozadím. Pásma, ve kterých je korelace zlomení se zlomením stejná jako s pozadím, jsou vynechána. Jedná se totiž o nedůležitá frekvenční pásma. Pro výběr hodnot vstupního vektoru korelačních pásem do binovací funkce byl napsán skript automaticky generující vektor požadovaných korelačních pásem podle zadaných prahových hodnot. V důsledku je tedy celkem využito 79 frekvenčních pásem z 2 223 možných. Výsledná funkce extrahující charakteristiky ze vstupního signálu byla validována s kladným výsledkem. Vrací totožné hodnoty jako neoptimalizovaná verze. Vytvoření této funkce bylo dalším krokem v této práci. Jejím prostřednictvím byla získána vstupní data do aplikace pro trénování klasifikačních modelů *classificationLearner*.

6.5. Natrénování vhodného klasifikačního modelu

Jak již bylo zmíněno výše, pro výsledný klasifikační model byla využita neuronová síť složená ze dvou vrstev. První vrstva obsahuje 49 a druhá 5 neuronů. Uvedené počty neuronů mají velice dobré výsledky, blízké počty uvedeným hodnotám až tak dobré výsledky nemají. Jedná se tedy o jedno z možných suboptimálních nastavení. Trénování klasifikační metody probíhalo tak, že se natrénoval klasifikátor, který byl následně vyexportován do *workspace*. Klasifikátor byl dále validován pomocí stejného mikrofonu, který byl použit pro účely bakalářské práce. Pro validaci byly použity zvuky připomínající signál zlomení¹¹. Výsledný klasifikátor má rovněž velmi dobrou „imunitu“ vůči pozadí. Je schopen rozlišit zvuky vyskytující se v běžném provozu od zlomení zakaleného razníku současně. To znamená, že výsledný klasifikátor je využitelný pro nasazení v průmyslové aplikaci.

6.6. Výstup z počítače do reálného světa

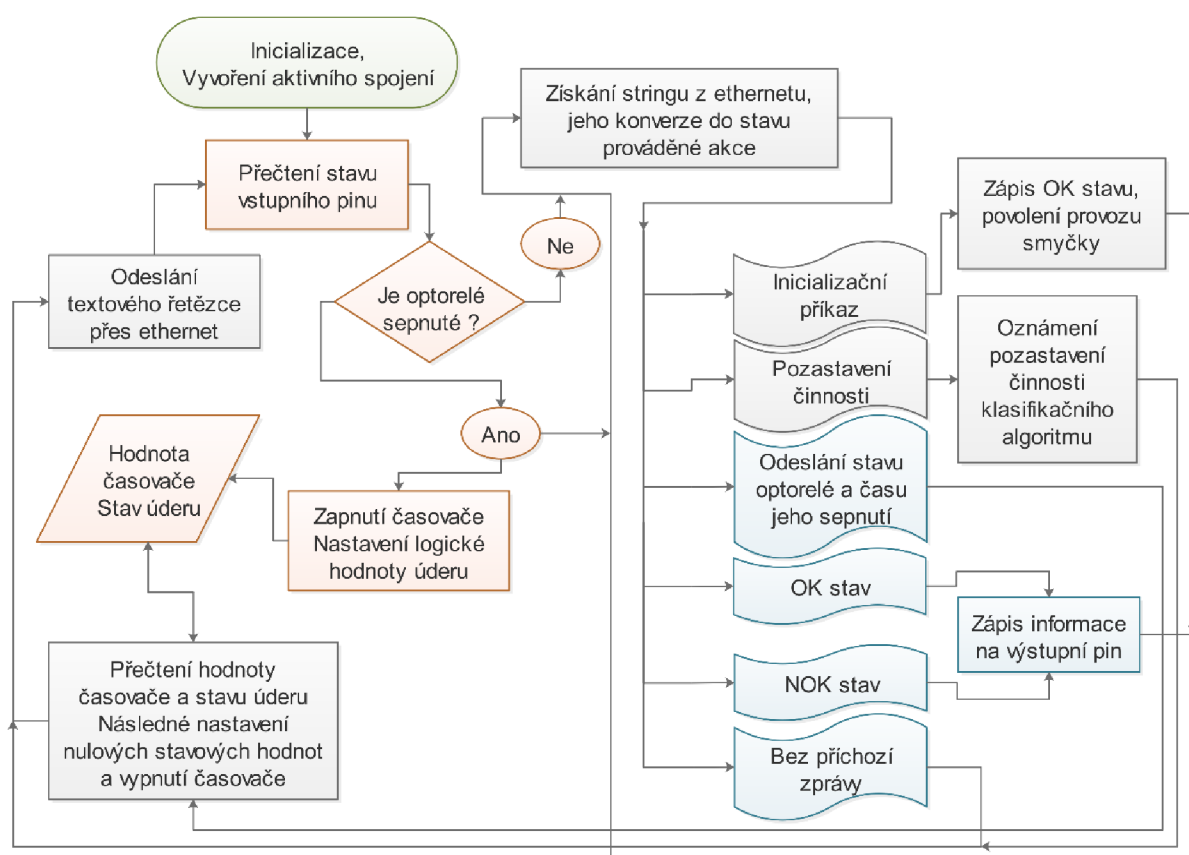
Dalším krokem bylo získat binární výstup z počítače do děrovacího lisu. Pro tyto účely byla vedoucím práce poskytnuta řídicí jednotka *CRiO 9053* s měřicí kartou od *National Instruments*® *NI 9041*. Během realizace propojení s *Matlabem*® bylo zjištěno, že dokumentace k tomuto přístroji neobsahuje dostatečný počet informací potřebných k jeho zprovoznění¹². Nebylo tedy možné v řídicí jednotce z *Matlabu*® zapnout nebo vypnout logický výstup nebo přečíst úroveň signálu ve vstupu. Toto by bylo možné zjistit reverzním inženýrstvím například pomocí programového nástroje *Wireshark*, jenž by zachytil textový řetězec odeslaný do řídicí

¹⁰Pro účely testování bylo zvoleno sbinování 215 frekvenčních pásem

¹¹Např. zlomení zakaleného kolíku nebo razníku ve svěráku

¹²Oficiální dokumentace k tomuto přístroji čítá 50 stránek, popsány jsou pouze splňované standardy a jak s přístrojem zacházet. Není popsán komunikační protokol, jednotka jede pouze s vhodnými programy (více viz www.ni.com)

jednotky při nastavení logického výstupu. Z uvedených důvodů a také z důvodu vysokých nákladů na zakoupení řídicí jednotky bylo zvoleno jiné řešení, tj. *Arduino*. Bylo zakoupeno *Arduino Uno s Ethernet Shieldem* a napsán programový kód umožňující komunikaci přes *TCP/IP* rozhraní v podobě stringů. *Arduino* má v sobě rovněž zabudovaný časovač umožňující zjištění času, kdy byl na vstup přiveden logický signál. Zjištění přesného času je nutné z důvodu způsobu realizace propojení s *Matlabem*[®]. Ten postupuje sekvenčně a není doporučeno v něm používat přerušení pro realtime provoz. *Matlab*[®] odešle požadavek s aktuálním stavem vyhodnocení signálu z bufferu jako textový řetězec, *Arduino* požadavek vyhodnotí a odešle stav pinu včetně hodnoty v timeru formou stringu. Textový řetězec odeslaný z *Arduina* je dále zpracován v *Matlabu*[®]. Připojení přes ethernet bylo zvoleno z důvodu velké odolnosti ethernetu vůči rušení a možnosti spojení s jednotkou na vzdálenost až 100 m. Použití USB spojení by bylo možné spolehlivě využívat na vzdálenost maximálně několik metrů, což není vyhovující. Takové spojení by navíc bylo méně odolné vůči rušení, které se při chodu stroje v určité míře vyskytuje.




Obr. 40: Stavový diagram algoritmu vnitřního programu *Arduina*

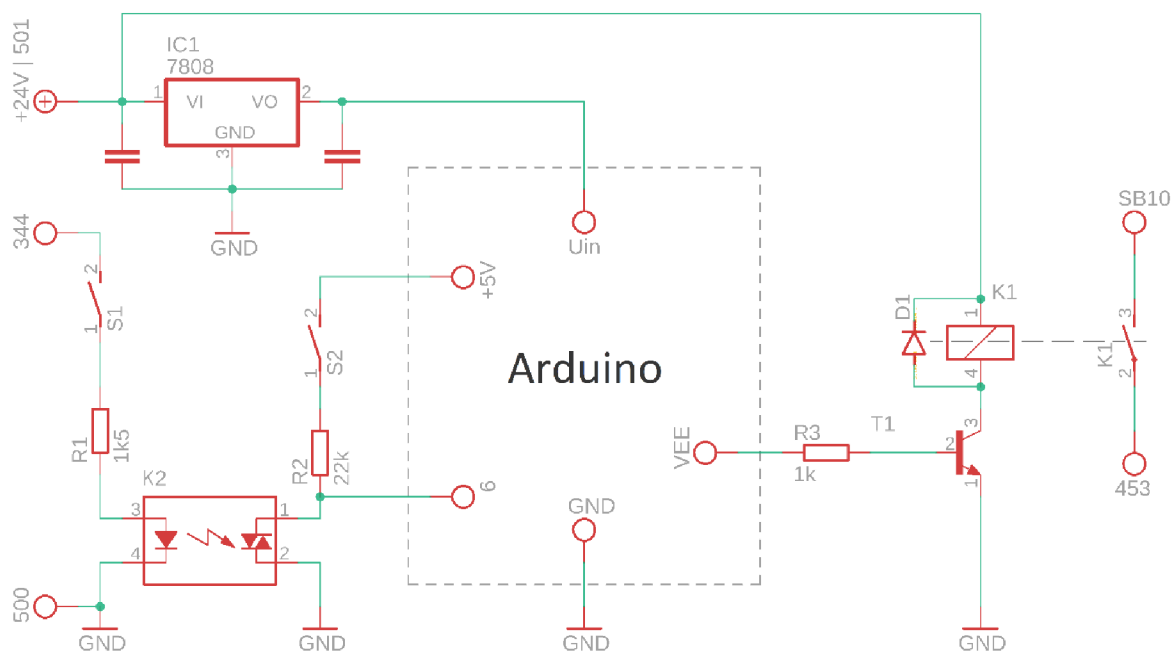
6.7. Propojení *Arduina* s děrovacím lisem

Použitý *Arduino Uno* má na výstupu logickou napětíovou úroveň +5 V. Řídicí počítač děrovacího lisu používá napětíové úrovně 24 V u výstupů na aktuátory a senzory. Bylo proto potřeba spojit *Arduino* s děrovacím lisem. Propojení bylo realizováno pomocí optorelé ze strany děrovacího lisu a obyčejného relé ze strany *Arduina*. Signálový výstup z *Arduina* je vzhledem k vysokému zapínacímu proudu relé posílen tranzistorem. Dále je použita demagnetizační dioda pro zabránění vzniku napětíových špiček. Do vstupního optorelé je přiveden signál z horní úvratě beranu děrovacího lisu. Použití relé a optorelé k oddělení napětíových úrovní má výhodu galvanického oddělení systémů od sebe navzájem. Ze strany děrovacího lisu je žádoucí

použit optorelé z důvodu vysokého počtu spínacích cyklů. Obyčejné relé je nevyhovující z důvodu podstatně menší životnosti. Na následujících obrázcích je možné vidět způsob realizace propojení *Arduina* s děrovacím lisem včetně schémat zapojení relé a optorelé:



Obr. 41: Zapojení *Arduina* a jeho uložení do boxu




Obr. 42: Schéma zapojení optorelé a relé a jejich připojení k *Arduinu*

Pro okamžité vypnutí je signál z výstupního relé přiveden na vstup od úpinek děrovacího lisu. Tento registr je systémovým bezpečnostním prvkem, který při náhodném výpadku přítlačné síly u úpinek vypne chod programu¹³

6.8. Vyladění algoritmu

Po připojení systému k děrovacímu stroji bylo možné přistoupit k finální fázi bakalářské práce – vyladění klasifikačního systému. Vyladění proběhlo následovně. Bylo nutné zajistit, aby do klasifikátoru pro zlomení při úderu vstupovala pouze důležitá část signálu úderu a do klasifikátoru pro zlomení při přejezdu pouze signál na pozadí, a to ihned po skončení signálu úderu. Kdyby došlo k nechtěnému posunu, systém by se mohl stát nepředvídatelný, mohl by vypnout. Pro tuto synchronizaci byl nahrán signál v bufferu současně s logickou úrovní vstupu z *Arduina*. *Arduino* umí vrátit i čas, kdy došlo k nastavení vstupu do logické jedničky na hodnotu 16 μ s, což je méně, než vzorkovací frekvence zvuku z mikrofonu, která má 22,5 μ s.

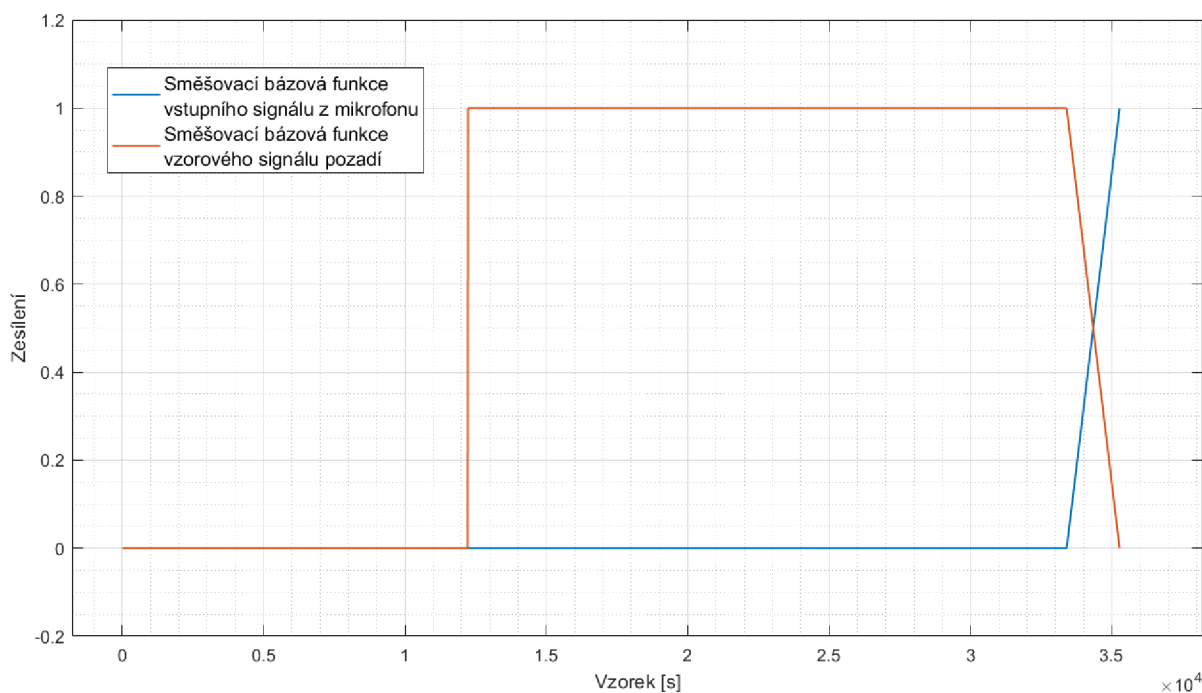


Obr. 43: Synchronizace signálu úderu z optorelé a digitalizovaného signálu z mikrofonu

Bylo tedy zjištěno, že signál přicházející z *Arduina* je velmi nepřesný co se týče synchronizace se zvukem získaným z mikrofonu. Pro účely synchronizace byla použita metoda autokorelace pro první polovinu OK úderu. Dále byl napsán cyklus *while*, který přidává do bufferu bloky až do té doby, než má signál úderů dostatečný počet vzorků a může být vyřiznut zesynchronizovaný střední část úderu a následně klasifikován. Použití této metody má překvapivý výsledek. Algoritmus je schopen synchronizovat správně úder i při velmi hlasitých rušivých vlivech. Dále byl nalezen vzorek odpovídající návratu stavu úderu do přejezdu na

¹³ V děrovacím lisu existuje takových bezpečnostních prvků několik, jedná se například o aretaci nástrojové lišty (nastavení úhlového natočení karuselu), dojetí na některý z dorazů nebo rovněž podtlak v přívodu stlačeného vzduchu

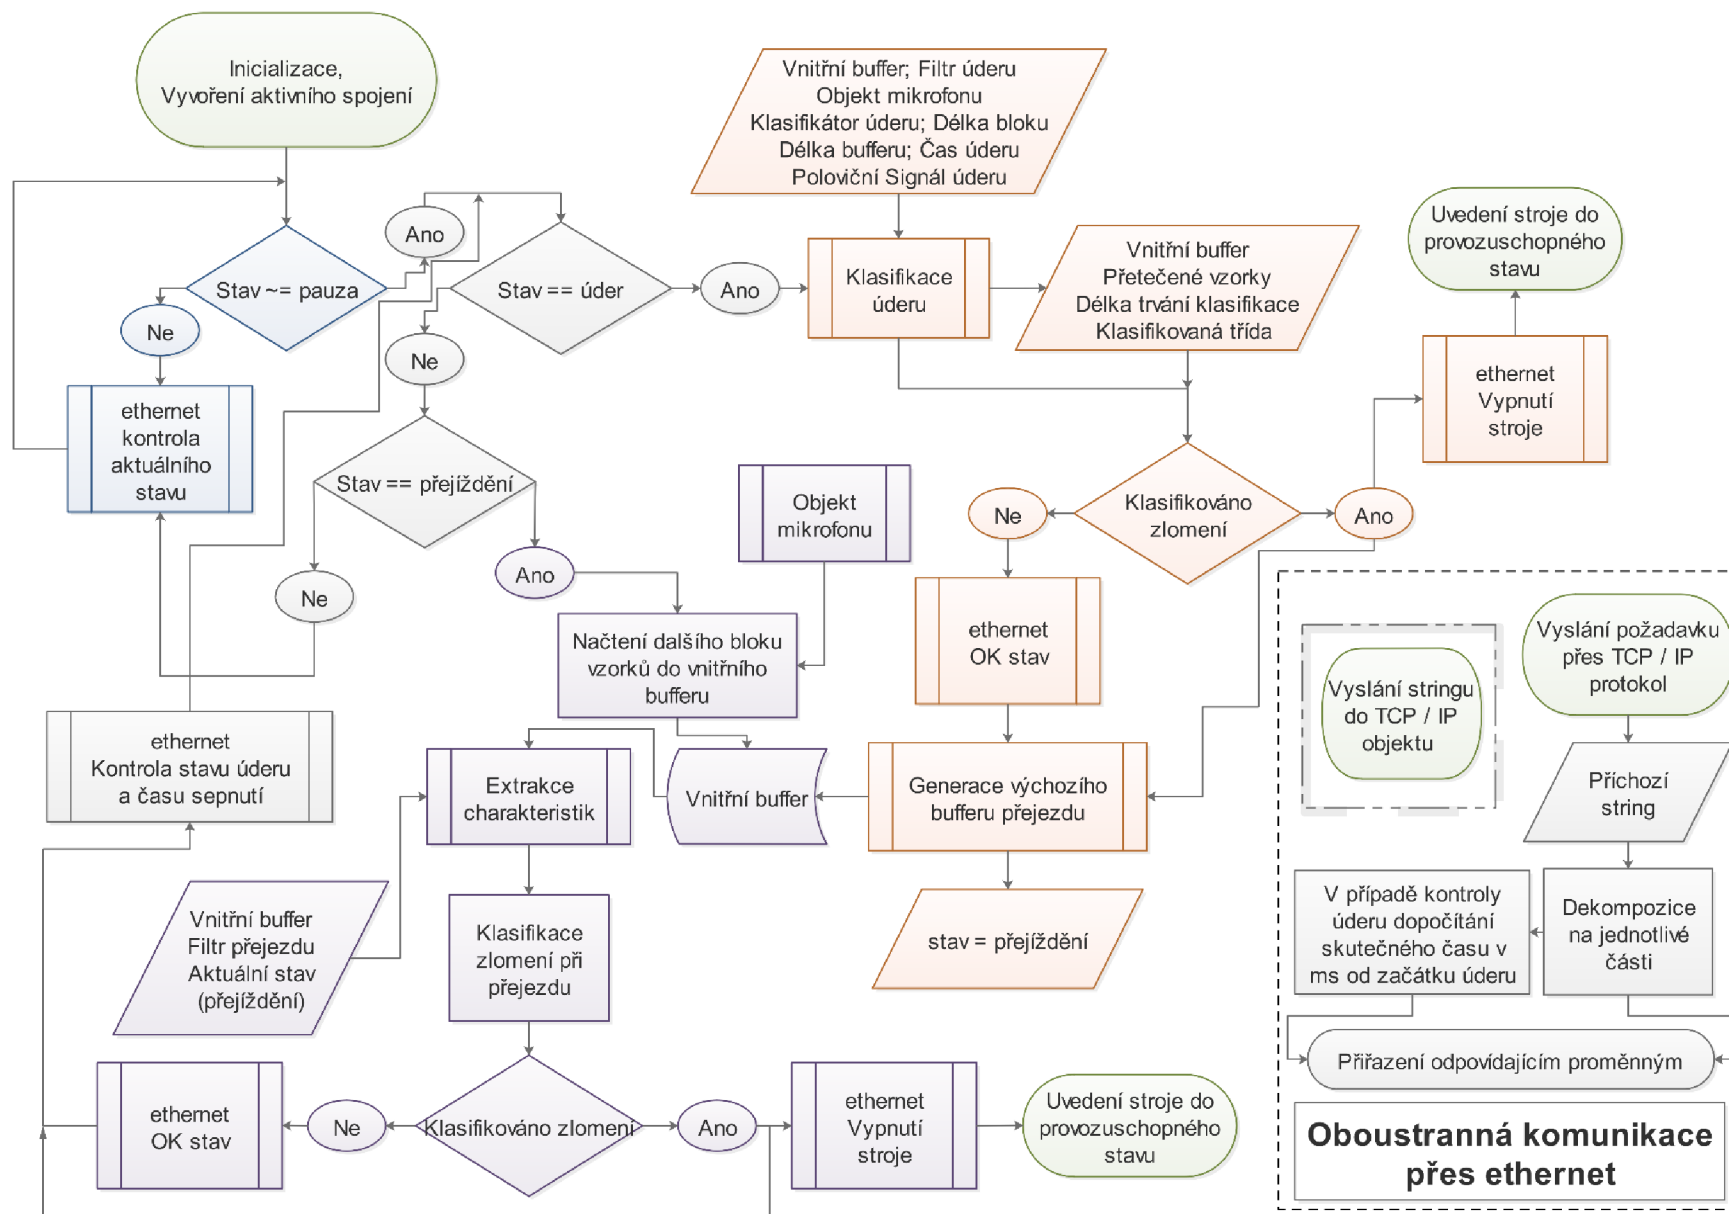
novou pozici. Zde se vyskytl problém. Jakmile se začne aktualizovat buffer novými vzorky při přejezdu, tak se v prvních pěti cyklech (300 ms) objeví v bufferu nulové bloky. Toto představuje velký problém, protože se jedná o nedefinovaný stav klasifikátoru. Klasifikátor byl totiž trénován se signály, které vykazovaly nenulové hodnoty vzorků¹⁴ Tento problém byl vyřešen následovně. Do vstupního bufferu se nahraje signál z určitého pozadí, který postupně přejde v nový signál z mikrofonu. Toto bylo realizováno vynásobením počtem n -posledních vzorků z bufferu arbitrárními bázovými koeficienty. Tyto vektory je možné vidět na následujících grafech:



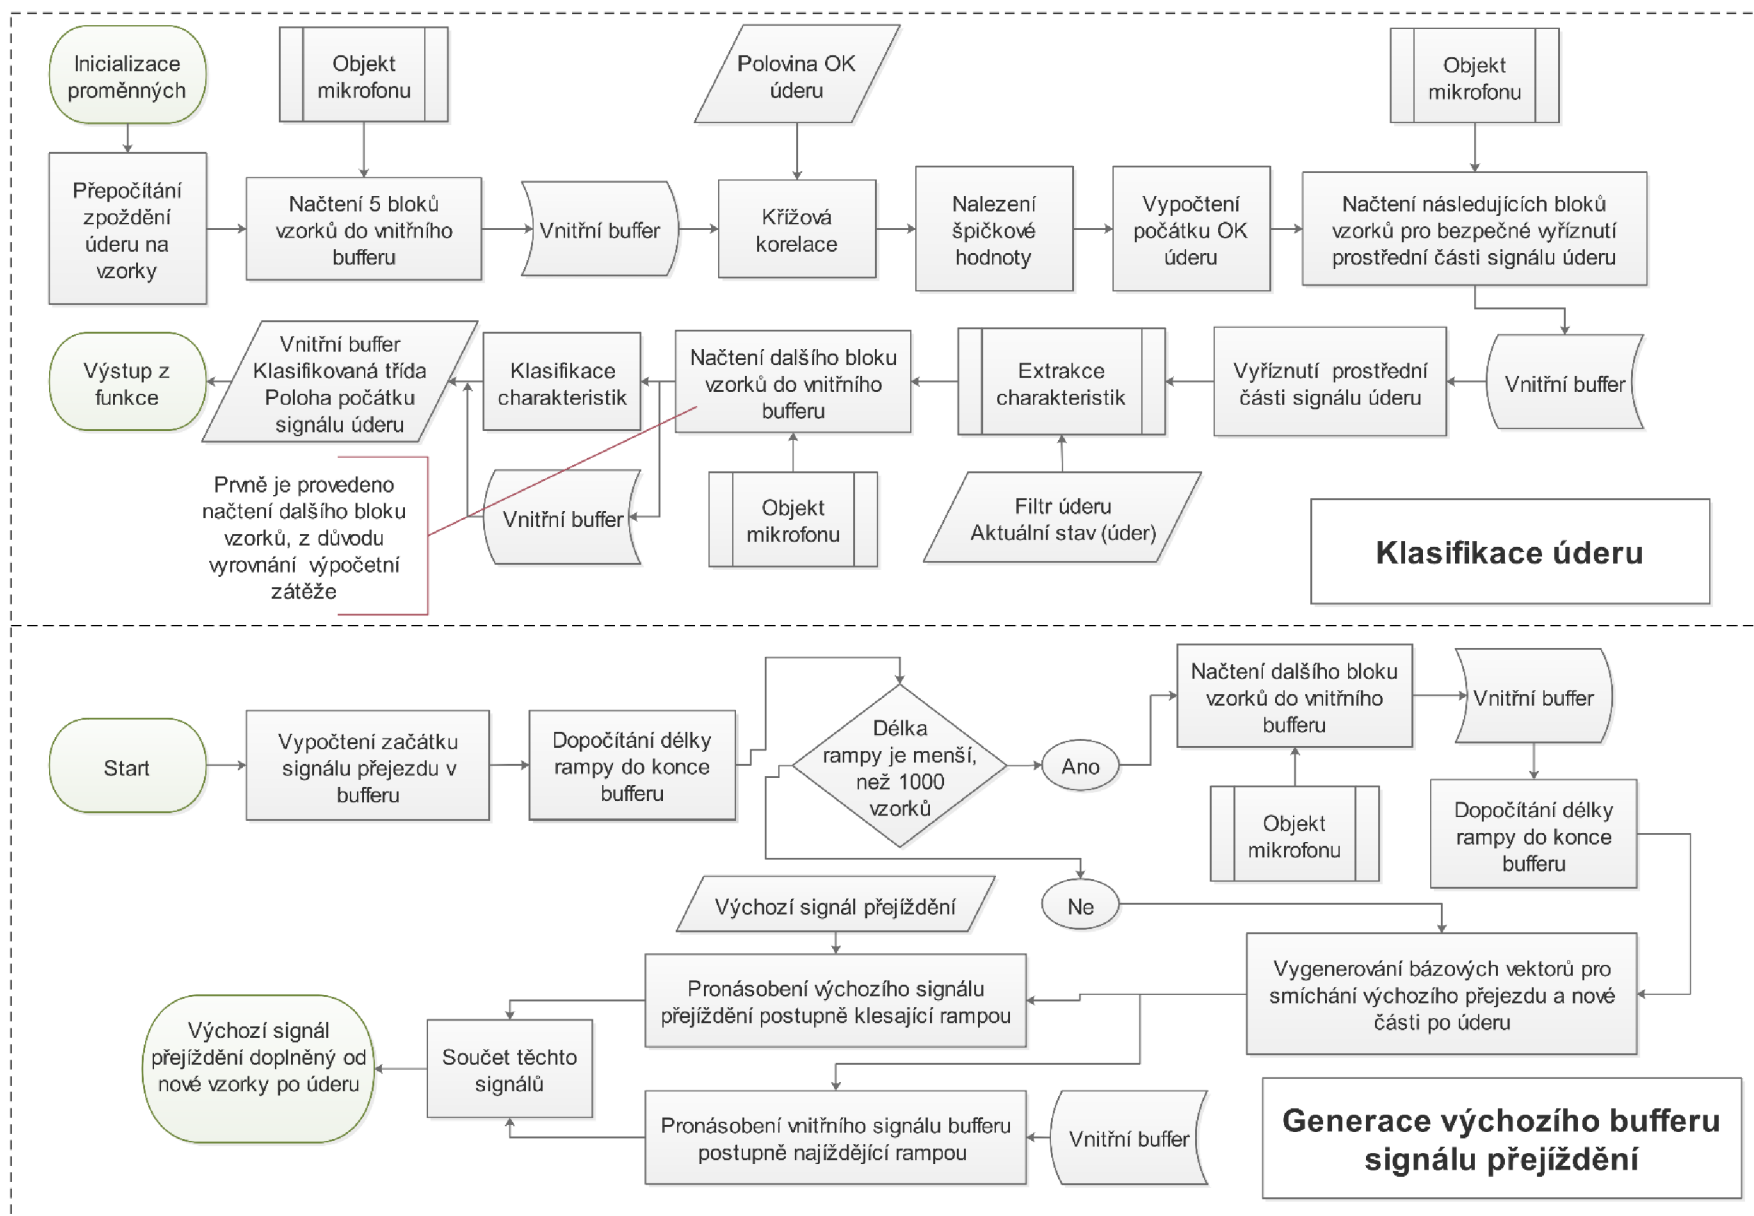
Obr. 44: Arbitrární bázové funkce sloužící pro hladké směšování signálů vzorového signálu a nově přichozícího signálu

Hodnota délky rampy byla zvolena na minimálně 1000 vzorků. Toto je programově ošetřeno a nikdy nemůže dojít ke stavu, kdy bude délka rampy kratší než 1000 vzorků. Délka rampy je navíc dynamická. Maximální možná délka rampy může být rovna délce bloku (3 528 vzorků). U překrytí signálu jde v podstatě o zamezení skokové změny hodnoty vzorků signálu doprovázené charakteristickým prasknutím. Další věcí vyžadující změnu byl možný příchod několika počátečních vzorků úderů do klasifikátoru přejezdu v posledním cyklu před přepnutím do klasifikace úderu. Což je nepřijatelné. Opět jde o nedefinovaný stav. Toto je způsobeno možným drobným zpožděním přerušení z *Arduina* (v řádu desítek ms) vzhledem k detekovanému signálu z mikrofonu. Tento problém byl vyřešen vynecháním posledního bloku v bufferu. Vstupní signál do funkce vyhodnocující vstupní signál se posunul o jeden blok v bufferu. Tímto je zaručeno, že do klasifikátorů přijdou správná data.

¹⁴ Jedná se o to, že vzorky po vynulování bufferu po úderu mají všechny nulovou hodnotu



Obr. 45: Stavový diagram hlavního algoritmu běžícího v *Matlabu*®



Obr. 46: Detailní popis vnitřní funkce klasifikace úderu a procesu generace výchozího bufferu signálu přejíždění

7. ZÁVĚR

7.1. Úroveň splnění jednotlivých cílů bakalářské práce

Systém jako celek byl úspěšně navržen, realizován a otestován s pozitivním výsledkem. Nicméně pro lepší klasifikační schopnosti systému je vyžadováno více signálů zlomení, neboť 15 signálů zlomení není dostatečné množství pro spolehlivé natrénování klasifikačního systému. Správné natrénování je možné jen v případě velkého rozdílu v určité charakteristice signálů zlomení oproti pozadí. Rozdíl signálu zlomení a pozadí není dostatečný.

7.2. Přijetí systému personálem firmy

Firma *AlamakPres, sdružení* má klasifikační systém k dispozici zhruba 3 týdny. V současné době probíhá jeho testování při nástřihu perforace planžet určených k výrobě plynových hořáků. Zařízení je testováno v běžně používaném rychlostním módu. Během testování došlo ke zlomení 3 kusů obdélníkových razníků o velikosti 0,5×6,0 mm. Klasifikátor ve všech případech rozpoznal zlomení a přerušil běh programu. Zařízení se doposud jeví jako přínosné z důvodů menších nákladů na zhotovení střížníků a matic, zkrácení výrobního času děrovaných plechů a zjednodušení práce obsluhy lisu. Klasifikátor bude postupně zkoušen při vyšších rychlostech posuvu a pokud se osvědčí, bude využíván ve výrobním procesu.

7.3. Možnosti dalšího vylepšení klasifikační metody

Tento klasifikační systém vyvinutý v rámci plnění cílů bakalářské má velký potenciál a lze jej dále zdokonalovat. První věcí vedoucí k případnému zlepšení je získání většího počtu zvuků zlomení při přejezdu. Toto je naprosto klíčové pro správnou funkci systému, kdy dosavadních 15 vzorků je nedostatečných. Toto by bylo možné provést zaznamenáním zvuků získaných podobnými mechanizmy jako při zlomení u přejíždění. Tato možnost byla zjištěna až při validaci umělým lámáním razníků a jiných zakalených předmětů ve svěráku. Z tohoto důvodu toto nebylo realizováno rychleji. Další možností je zavedení dalších obsáhlejších charakteristik ze signálu. Jde například o různé nelineární charakteristiky z časové oblasti (např. korelační dimenze, Lyapunov exponent a podobné), které ale nebyly do vlastní funkce extrahující charakteristiky zahrnuty vzhledem k dlouhému výpočetnímu času¹⁵. Dále by bylo vhodné zařadit charakteristiky z frekvenční oblasti¹⁶. Zahrnutí těchto charakteristik do systému by mělo pravděpodobně kladný vliv na klasifikační schopnost výsledného klasifikátoru. Popřípadě by bylo možné na tyto vektorové charakteristiky aplikovat algoritmus, který byl aplikován i u získání jednotlivých vah frekvenčních pásem vážené frekvenční korelace. To umožní identifikovat přesná pásma z těch vektorových charakteristik, kde korelace daného zlomení s databází ostatních zlomení je větší, než korelace zlomení s pozadím. Získané oblasti by bylo možné následně sbíhat a dodat klasifikačnímu systému jako jednu hodnotu. Toto je nutné ovšem ověřit. Další možností zlepšení klasifikačního systému je využití hlubokého strojového učení. Tato oblast skýtá určitý potenciál pro zlepšení funkce klasifikačního systému.

¹⁵ Doba potřebná k vypočítání Lyapunovova exponentu trvá na procesoru *Intel Core i-7 9600U* pro signál dlouhý 14 412 vzorků kolem 40 vteřin

¹⁶ Jedná se o charakteristiky typu spektrální entropie, spektrální špičatost, harmonický poměr, MFCC, GTCC a podobné. Těchto charakteristik ve frekvenční oblasti existuje velké množství

7.4. Možné oblasti dalšího využití výstupů bakalářské práce

Bakalářská práce byla zaměřena speciálně na klasifikaci signálů zlomení. Použité postupy a techniky jsou ovšem natolik univerzální a obecné, že použité algoritmy jde aplikovat na klasifikaci velké oblasti signálů. Může to být například:

- opotřebení ložisek, řetězů, převodovek a jiných strojních součástí,
- kontrola správného mazání,
- nahrazení stávajících senzorů jednodušším systémem,
- kontrola stavu konstrukcí,
- kontrola provozu strojů obecně, a jiné.

SEZNAM POUŽITÝCH ZDROJŮ

- [1] BADGUJAR, Tushar Y., K.R. BHAVSAR a Vijaykumar WANI. *Acoustic Based Condition Monitoring of Stamping Process: A Review* [online]. 2017 [cit. 2022-05-16]. Dostupné z: https://www.researchgate.net/publication/321168867_Acoustic_Based_Condition_Monitoring_of_Stamping_Process_A_Review
- [2] IFEACHOR, Emmanuel C. a Barrie W. JERVIS. *Digital signal processing: a practical approach*. 2nd ed. Harlow: Prentice-Hall, c2002. ISBN isbn0-201-59619-9.
- [3] JAN, Jiří. *Číslíková filtrace, analýza a restaurace signálů*. Brno: Vysoké učení technické, 1997. ISBN isbn80-214-0816-2.
- [4] LÁSZLÓ, Noémi a Mária MAROS. Determination of Optimal Wear Concept of Sheet Metal Forming Tools Using the Autoform Dieadviser Modul. In: *The publications of the MultiScience - XXXI. MicroCAD International Scientific Conference* [online]. University of Miskolc, 2017, 2017, s. - [cit. 2022-05-16]. ISBN 9789633581322. Dostupné z: doi:10.26649/musci.2017.081
- [5] *MathWorks® Help Center: audioFeatureExtractor* [online]. 2022 [cit. 2022-05-16]. Dostupné z: <https://www.mathworks.com/help/audio/ref/audiofeatureextractor.html>
- [6] *MathWorks® Help Center: Choose Classifier Options* [online]. 2022 [cit. 2022-05-16]. Dostupné z: <https://www.mathworks.com/help/audio/ref/audiofeatureextractor.html>
- [7] *MathWorks® Help Center: Signal Features* [online]. 2022 [cit. 2022-05-16]. Dostupné z: <https://www.mathworks.com/help/audio/ref/audiofeatureextractor.html>
- [8] NYQUIST, H. Certain Factors Affecting Telegraph Speed 1. *Bell System Technical Journal* [online]. 1924, 3(2), 324-346 [cit. 2022-05-16]. ISSN 00058580. Dostupné z: doi:10.1002/j.1538-7305.1924.tb01361.x
- [9] NYQUIST, H. Certain Topics in Telegraph Transmission Theory. *Transactions of the American Institute of Electrical Engineers* [online]. 1928, 47(2), 617-644 [cit. 2022-05-16]. ISSN 0096-3860. Dostupné z: doi:10.1109/T-AIEE.1928.5055024
- [10] SARI, D.Y., B.T. LIN, T.L. WU, P.J. CHEN a C.W. CHANG. *Investigation on sound signal emitted by punching process for punch failure monitoring* [online]. Kaohsiung, Taiwan, 4 [cit. 2022-05-16]. Dostupné z: https://www.researchgate.net/publication/318899510_Investigation_on_sound_signal_emitted_by_punching_process_for_punch_failure_monitoring

- [11] SARI, Delima Yanti, Tsung-Liang WU a Bor-Tsuen LIN. Study of sound signal for online monitoring in the micro-piercing process. *The International Journal of Advanced Manufacturing Technology* [online]. 2018, 97(1-4), 697-710 [cit. 2022-05-16]. ISSN 0268-3768. Dostupné z: doi:10.1007/s00170-018-1970-5
- [12] SHANBHAG, Vignesh V., Bernard F. ROLFE, Narayanan ARUNACHALAM a Michael P. PEREIRA. Investigating galling wear behaviour in sheet metal stamping using acoustic emissions. *Wear* [online]. 2018, 414-415, 31-42 [cit. 2022-05-16]. ISSN 00431648. Dostupné z: doi:10.1016/j.wear.2018.07.003
- [13] SMITH, W. Steven. *Digital signal processing: scientist and engineer's guide*. California: California Technical Publishing, 1997. ISBN 0966017633.
- [14] UBHAYARATNE, Indivarie, Michael P. PEREIRA, Yong XIANG a Bernard F. ROLFE. Audio signal analysis for tool wear monitoring in sheet metal stamping. *Mechanical Systems and Signal Processing* [online]. 2017, 85, 809-826 [cit. 2022-05-16]. ISSN 08883270. Dostupné z: doi:10.1016/j.ymssp.2016.09.014
- [15] VOSS, Brendan. *Galling wear detection and measurement in sheet metal forming*. Austrálie, 2018. Dizertační práce. Australian National University. Vedoucí práce Matt Doolan.
- [16] WU, Tsung-Liang, Delima Yanti SARI, Bor-Tsuen LIN a Chia-Wei CHANG. Monitoring of punch failure in micro-piercing process based on vibratory signal and logistic regression. *The International Journal of Advanced Manufacturing Technology* [online]. 2017, 93(5-8), 2447-2458 [cit. 2022-05-16]. ISSN 0268-3768. Dostupné z: doi:10.1007/s00170-017-0701-7

SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

A/D	analogově digitální převodník
DFT	diskrétní Fourierova transformace
DSP	Digital Signal Processing
FFT	Rychlá Fourierova transformace (Fast Fourier Transformation)
FIFO	first-in-first-out (buffer)
FIR	filtr s konečnou impulzní odezvou (Finite impulse response)
GTCC	Gammatone cepstral coefficients
HRC	Hardness Rockwell C
Hz	Hertz
IFFT	Inverzní rychlá Fourierova transformace (Inverse fast Fourier Transformation)
IIR	filtr s nekonečnou impulzní odezvou (Infinite impulse response)
kHz	kilohertz
ks	kus
kN	kiloNewton
KNN	Algoritmus k-nejbližších sousedů
MFCC	Mel-frequency cepstrum coefficients
m	metr
mm	milimetr
ms	milisekunda
μs	mikrosekunda
např.	například
NOK	not okay úder
OK	okay úder
PCA	Principal Component Analysis
PWM	pulzně šířková modulace
RAM	Random-access memory
RUL	Remaining useful life
SINAD	Signal-to-noise and distortion ratio
SNR	Signal-to-noise ratio
SVM	Support Vector Machine
TCP/IP	Transmission Control Protocol/Internet Protocol
THD	Total harmonic distortion
USB	Universal Serial Bus
V	Volt

SEZNAM OBRÁZKŮ

- Obr. 1:** Fotografie děrovaného plechu
- Obr. 2:** Fotografie děrovacího nástroje, nepoškozené a poškozené střížné hrany matrice
- Obr. 3:** Fotografie ulomených špiček razníků (vlevo – pravý je nový); kotevního kroužku s usazenými razníky
- Obr. 4:** Fotografie zázemí děrovacího lisu LDR 25 TGRJ – Nahoře řídicí počítač, dole lis
- Obr. 5:** Homogenita (vlevo), aditivita (vpravo)
- Obr. 6:** Porovnání lineárních a nelineárních systémů (vlevo je B-H křivka magnetického obvodu, vpravo jsou lineární modely pružin)
- Obr. 7:** Delta funkce a impulsní odezva
- Obr. 8:** Algoritmus diskrétní konvoluce
- Obr. 9:** Modelové schéma typického DSP procesoru
- Obr. 10:** Fotografie použitého mikrofonu a zvukové karty
- Obr. 11:** Graf vizualizované podoby výsledků dvoustupňové analýzy lokálního rozptylu
- Obr. 12:** Stavový diagram dvoustupňové analýzy lokálního rozptylu
- Obr. 13:** Multiplexe signálů
- Obr. 14:** Grafy zlomení při přejíždění v časové oblasti
- Obr. 15:** Grafy zlomení při přejíždění ve frekvenční oblasti
- Obr. 16:** Srovnání průběhu OK, NOK a úderu naprázdno v časové oblasti
- Obr. 17:** Srovnání průběhu (střední části signálů) OK a NOK úderu v časové oblasti
- Obr. 18:** Ukázka výše uvedených grafů OK a NOK úderů ve frekvenční oblasti
- Obr. 19:** Ukázka binování
- Obr. 20:** Stavový diagram algoritmu kvantitativních charakteristik
- Obr. 21:** Stavový diagram algoritmu korelace databáze vektorů FFT
- Obr. 22:** Stavový diagram algoritmu vylepšené korelace databáze vektorů FFT
- Obr. 23:** Grafy frekvenční korelace – prostorový náhled, pohled shora pro korelační intenzitu v pásmu 315-322 Hz
- Obr. 24:** Průměr korelací jednotlivých tříd napříč frekvenčními spektrem rozděleným do pásem
- Obr. 25:** Stavový diagram algoritmu vážené korelace databáze vektorů FFT
- Obr. 26:** Ukázka klasifikačních algoritmů – rozhodovacího stromu, KNN a lineárního SVM
- Obr. 27:** Typické uspořádání neuronové sítě
- Obr. 28:** Stavový diagram algoritmu frekvenční korelace průměru bufferu FIFO s následujícím úderem
- Obr. 29:** Stavový diagram algoritmu párované frekvenční korelace FFT
- Obr. 30:** Graf korelace všech zlomení navzájem
- Obr. 31:** Graf vylepšené korelace všech zlomení navzájem
- Obr. 32:** Graf vážené korelace všech zlomení navzájem
- Obr. 33:** Graf frekvenční korelace průměru bufferu FIFO s následujícím úderem
- Obr. 34:** Graf frekvenční korelace průměru bufferu FIFO s následujícím úderem
- Obr. 35:** Stavový diagram algoritmu klasifikačního systému – obecně
- Obr. 36:** Frekvenční a fázová odezva FIR filtru pro signál přejíždění
- Obr. 37:** Frekvenční a fázová odezva FIR filtru pro signál úderu
- Obr. 38:** Filtrované signály zlomení při přejíždění
- Obr. 39:** Filtrované signály zlomení při úderu
- Obr. 40:** Stavový diagram algoritmu vnitřního programu *Arduina*
- Obr. 41:** Zapojení *Arduina* a jeho uložení do boxu
- Obr. 42:** Schéma zapojení optorelé a relé a jejich připojení k *Arduinu*
- Obr. 43:** Synchronizace signálu úderu z optorelé a digitalizovaného signálu z mikrofonu

Obr. 44: Arbitrární bázové funkce sloužící pro hladké směšování signálů vzorového signálu a nově přichozího signálu

Obr. 45: Stavový diagram hlavního algoritmu běžícího v *Matlabu*®

Obr. 46: Detailní popis vnitřní funkce klasifikace úderu a procesu generace výchozího bufferu signálu přejíždění

SEZNAM TABULEK

Tab. 1: Vhodné parametry funkce peaks

Tab. 2: Přehled vybraných charakteristik zahrnutých do klasifikačního modelu

Tab. 3: Srovnání klasifikačních metod zlomení

Tab. 4: Srovnání zkoušených a navržených metod prediktivní údržby