

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

BAKALÁŘSKÁ PRÁCE



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

**FAKULTA ELEKTROTECHNIKY
A KOMUNIKAČNÍCH TECHNOLOGIÍ**

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV TELEKOMUNIKACÍ

DEPARTMENT OF TELECOMMUNICATIONS

**DETEKCE IMPULSNÍHO RUŠENÍ VE ZVUKOVÉM
SIGNÁLU**

IMPULSE NOISE DETECTION IN AUDIO SIGNALS

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Josef Hůla

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Ondřej Mokrý

BRNO 2021

Bakalářská práce

bakalářský studijní program **Audio inženýrství**
specializace Zvuková produkce a nahrávání
Ústav telekomunikací

Student: Josef Hůla

ID: 212557

Ročník: 3

Akademický rok: 2020/21

NÁZEV TÉMATU:

Detekce impulsního rušení ve zvukovém signálu

POKYNY PRO VYPRACOVÁNÍ:

Seznamte se s modely impulsního rušení ve zvukovém signálu. To může být způsobeno např. fyzickým poškozením nosiče (rýhy na gramofonových deskách) nebo může nastat chybou přenosu. Konečně se může jednat o přirozenou, nicméně nežádoucí součást signálu (mlasknutí v řečovém nebo zpěvovém signálu). Rovněž se seznámte s metodami pro detekci takových poruch. Vybrané metody následně implementujte v Matlabu; mimo jiné implementujte metody založené na filtraci horní propustí a na autoregresním modelování signálu. Detekční schopnosti jednotlivých metod porovnejte na simulovaných i skutečných nahrávkách a statisticky vyhodnoťte. Testovací nahrávky částečně dodá vedoucí a spolupracující firma, zbytek si připraví student. Výstupem práce pak bude pro jednotlivé metody vyhodnocení kvality detekce v závislosti na vlastnostech signálu, vlastnostech rušení a na distribuci jeho impulsů.

DOPORUČENÁ LITERATURA:

[1] OUDRE, Laurent. Automatic Detection and Removal of Impulsive Noise in Audio Signals. Image Processing On Line. 2015. Dostupné z: <http://www.ipol.im/pub/art/2015/64/>

[2] GODSILL, Simon J. a Peter J. W. RAYNER. Digital Audio Restoration. 1998. Dostupné z: http://super.tka4.org/materials/lib/Articles-Books/DSP/Noise/digital_audio_restoration.pdf

Termín zadání: 1.2.2021

Termín odevzdání: 31.5.2021

Vedoucí práce: Ing. Ondřej Mokrý

Konzultant: Ing. Jan Kaňka (AUDIFIED s.r.o.)

doc. Ing. Jiří Schimmel, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Práce pojednává o známých metodách detekce impulsního rušení v hudebních nahrávkách. Obsahuje studii o diferenciální, filtrační, autoregresivní a ARMA metodě detekce. Jednotlivé metody jsou prostudovány po teoretické stránce, následně je diskutováno o charakteru detekovaného rušení. Metody jsou implementovány v praxi a jsou mezi sebou srovnány. Za účelem porovnání jsou aplikovány na uměle vytvořené impulsy se známou pozicí a poté i na nahrávky obsahující reálné poškození.

KLÍČOVÁ SLOVA

detekce, impulsní rušení, autoregresivní model, moving-average model, ARMA model, filtrace signálu

ABSTRACT

Study disserts known method of detecting impulsive noise in audiosignal. Differential, filtering, autoregressive and ARMA methods are discussed. First, each method is theoretically examined and the character of impulsive disturbances is presented. Later an implementation of each method is presented and results of their performance is compared. In order to have comparable results, the methods are tested on synthetic impulses with known position and duration and also on recordings containing real impulsive noise.

KEYWORDS

detection, impulsive noise, autoregressive model, moving-average model, ARMA model, filtration of signal

HŮLA, Josef. *Detekce impulsního rušení ve zvukovém signálu*. Brno, 2021, 56 s. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav telekomunikací. Vedoucí práce: Ing. Ondřej Mokrý

PROHLÁŠENÍ

Prohlašuji, že svou bakalářskou práci na téma „Detekce impulsního rušení ve zvukovém signálu“ jsem vypracoval samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno

.....

podpis autora

PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu bakalářské práce panu Ing. Ondřeji Mokrému za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Obsah

Úvod	15
1 Teoretická část	17
1.1 Impulsní rušení	17
1.2 Metody detekce	17
1.3 Diferenční metoda	18
1.4 Filtrování horní propustí	19
1.5 Detekce pomocí autoregresivní metody a metody klouzavého průměru	21
1.5.1 Detekce pomocí ARMA modelování	23
1.5.2 Filtrace detekčního signálu pomocí přizpůsobovacího filtru . .	23
2 Výsledky studentské práce	25
2.1 Testovací nahrávky, charakter impulsů	25
2.2 Programové řešení	27
2.2.1 Nastavení parametrů skriptu a načítání dat	27
2.2.2 Generování umělých impulsů	28
2.3 Diferenční metoda detekce	29
2.4 Detekce pomocí filtrování horní propustí	32
2.5 Detekce pomocí AR modelování signálu	35
2.6 Detekce pomocí ARMA modelování signálu	44
Závěr	47
Literatura	49
Seznam symbolů, veličin a zkratk	53
A Přílohy	55

Seznam obrázků

2.1	Impuls způsobený porušením drážky na vinylové desce	26
2.2	Impuls způsobený nestabilním napájením nebo chybou při převodu .	26
2.3	Impuls způsobený příčnou prasklinou či rýhou na vinylové desce . . .	27
2.4	Grafické zobrazení impulsů obou metod a nepoškozeného signálu s přidáním impulsů	29
2.5	Grafické zobrazení průběhu diferenční metody bez použití RMS filtru	30
2.6	Grafické zobrazení průběhu diferenční metody s použitím RMS filtru šířky 4 vzorky	30
2.7	Grafické zobrazení průběhu diferenční metody	31
2.8	impulses	34
2.9	Grafické zobrazení průběhu filtračních metod na nahrávce klavírního tria	34
2.10	Průběhy detekčního signálu AR metody pro různé hodnoty řádu procesu	36
2.11	Průběhy detekčního signálu AR metody pro různé hodnoty řádu procesu	37
2.12	Grafické zobrazení průběhu autoregresivní metody na uměle vytvoře- ných impulsech	38
2.13	Grafické zobrazení průběhu standardního prahování autoregresivní metody detekce rušení v nahrávce muzikálu	40
2.14	Grafické zobrazení průběhu adaptivního prahování autoregresivní me- tody detekce rušení v nahrávce muzikálu	40
2.15	Grafické zobrazení průběhu jednosměrné autoregresivní detekce ob- ráceného signálu	42
2.16	Grafické zobrazení průběhu obousměrné autoregresivní detekce	43
2.17	Grafické zobrazení obousměrné autoregresivní detekce impulsu	43
2.18	Grafické zobrazení průběhu jednosměrné autoregresivní detekce impulsu	44
2.19	Grafické zobrazení průběhu detekce pomocí ARMA estimace signálu .	45

Úvod

Impulsní rušení je aditivní lokální rušení impulsního charakteru sestávající se z impulsů s různou délkou a intenzitou a s náhodným výskytem [4, 3], nejčastěji způsobené chybami analogového záznamového zařízení či fyzickým poškozením nosiče záznamu signálu nebo elektromagnetickým rušením a atmosférickými jevy v analogové radiokomunikaci [7]. Nejčastěji se s potřebou odstranění tohoto typu rušení setkáme u starých vinylových desek, kde ke vzniku přídatného rušení dochází již při výrobě a nahrávání, nebo opotřebením materiálu opakovaným přehráváním. Projevy tohoto rušení jsou obvykle nazývány praskáním či cvakáním. *Detekce* impulsního rušení je prvním ze dvou kroků při rekonstrukci poškozeného signálu. Druhým krokem je *interpolace*, jinými slovy nahrazení hodnot poškozených vzorků hodnotami co nejbližší odpovídajícími hodnotám signálu původního pomocí vhodného algoritmu. O tomto kroku tato práce nepojednává.

Moderní řešení tohoto problému nabízí i bližší analýzu charakteru rušení [1], kde je rušivý impuls rozdělen na dvě části. V první se nachází impuls samotný, ke kterému dochází v momentě, kdy kupříkladu stylus čtecího ramene gramofonu narazí na nesrovnalost v povrchu media a netrvá déle než 10 ms. Druhá část obsahuje tlumenou pulsní odezvu reprodukčního zařízení na iniciující impuls. Ta má charakter harmonické funkce se snižující se frekvencí i amplitudou a může trvat v nejzávažnějších případech až jednu sekundu. V této práci bude brán potaz na obecnější charakter impulsního rušení.

1 Teoretická část

1.1 Impulsní rušení

Impulsní rušení můžeme rozdělit podle způsobu vzniku do dvou hlavních skupin [3, kapitola 1], a to na rušení vytvořené uměle a rušení vzniklé náhodnými přírodními jevy. První zmíněné je způsobené zařízeními obsaženými v řetězci zpracovávajícím signál. Druhé je přivozeno vlivy přírodních jevů na tento řetězec, jakými jsou atmosférické jevy, sluneční erupce, kosmické záření a mnohé další. Pro syntézu signálů impulsního rušení se používá analogie matematických modelů založených na různých principech [19, 20].

1.2 Metody detekce

Hlavním faktorem při výběru metody detekce je bezpochyby charakter rušivých impulsů. Nejsnadněji detekovatelnými jsou krátké samostatné impulsy s vysokou amplitudou a ostrými hranami. V horších případech jsou naopak delší, mají nižší amplitudu, pomalý náběh a sestup a mají tendenci vyskytovat se ve shlucích, kde může docházet i k překrývání jednotlivých impulsů.

Digitálně zaznamenaná zvuková stopa je obraz akustického tlaku vzduchu $s(t)$, vzorkovaný v periodě T , tudíž dostáváme diskrétní signál $s(nT)$ se vzorkovací frekvencí $f = 1/T$, kde n je celočíselná proměnná udávající pozici v časové řadě. Pro většinu následujících metod můžeme znalost vzorkovací frekvence vypustit a interpretovat nahrávku čistě jako posloupnost hodnot. Pro impulsy jednoduššího charakteru a krátkého trvání v řádu jednotek vzorků je dostačující filtr typu horní propust využívající výpočtu medianu či difference sousedních vzorků [7] s jednoduchým či adaptivním prahováním. Pokud je charakter rušivých impulsů proměnný, zabírá více vzorků než je schopen započítat jednodušší model, blíží se charakteru audiotopy samotné nebo je amplituda impulsů příliš nízká, než aby mohla být spolehlivě detekována, je nutno použít sofistikovanějších technik. Škála možností je vcelku široká, od pokročilejších autoregresivních procesů s fixními či adaptivními parametry, například s adaptivním prahováním [7], a klouzavým průměrem [9], přes detekci pomocí vlnkových transformací [6] nebo s využitím poznatků z oblasti Bayesovské pravděpodobnosti [21] až po detekci s využitím algoritmů neuronových sítí.

Výše zmíněné metody včetně vlnkové transformace vycházejí ze společného základu, jímž je lineární a nelineární predikce, která je produktem matematické analýzy časové řady [23] a matematické analýzy dynamických systémů. Analýza časových řad se využívá již déle než století v mnoha oborech lidské činnosti a jejím významným rysem, kterým se odlišuje od ostatních způsobů analýzy, je konkrétní vztah

mezi jednotlivými body v čase dané řady. Metody analýzy časových řad dělíme do dvou dominantních skupin podle oblasti, ve které analýzu provádíme. První z nich jsou metody ve frekvenční oblasti, jako je například analýza spektrální, pomocí vlnkové transformace nebo diskretní Fourierovy transformace. Analýza v časové oblasti skýtá stochastické metody, například autoregresivní modelování (AR), modelování pomocí klouzavého průměru (MA), integrované modelování (ARIMA), modely využívající modelování pomocí Bayesovské pravděpodobnosti nebo jejich kombinace. Dělení podle oblasti analýzy není jednoznačné, ve většině případů lze daný model použít i pro druhou oblast. Predikce budoucího vývoje je pouze jedno z praktických využití analýzy časové řady, pro naše potřeby je však centrální.

V následujících kapitolách budou stručně popsány vybrané způsoby detekce.

1.3 Diferenční metoda

Mějme sledovaný signál x_n . Metoda vychází z pozorování impulsního rušení jako náhlého zvětšení rozdílu mezi po sobě následujícími vzorky oproti průměrným hodnotám [7]. Úroveň detekčního signálu tedy značí diskretní derivaci pozorovaného signálu. Ta je získána jako podíl rozdílu hodnot po sobě jdoucích vzorků a vzorkovacího intervalu. Výsledek vyjádříme v absolutní hodnotě, aby se nám špičky signálu představující lokaci impulsů soustředily v kladných hodnotách a mohly tak být snadno prahovány:

$$d_n = \frac{|x_{n+1} - x_n|}{\Delta t}. \quad (1.1)$$

Pro vyšší přesnost detekce je vhodné výraz (1.1) aplikovat vícekrát po sobě. Tím získáme výraz

$$d_n = \begin{cases} \frac{\sum_{k=0}^j (-1)^k \binom{j}{k} x_{n-j/2+k}}{(\Delta t)^j} & \text{pro sudá } j, \\ \frac{\sum_{k=0}^j (-1)^k \binom{j}{k} x_{n-(j-1)/2+k}}{(\Delta t)^j} & \text{pro lichá } j, \end{cases} \quad (1.2)$$

Komplexnost výrazu závisí především na vzorkovací frekvenci a charakteru impulsů. Avšak se zvyšující se vzorkovací frekvencí je nutné zvýšit rozlišení detekce.

Jelikož detekční signál sleduje rychlost změny hodnot v pozorovaném signálu, bude se jeho hodnota plovoucího průměru v čase dost měnit. Proto je pro úspěšnou aplikaci této metody nutné využít adaptivního prahování. Toho lze povětšinou efektivně využít i u všech následujících metod. Průměruje hodnoty detekčního signálu v okolí sledovaného vzorku a násobí je vhodnou konstantou míry, kterou je nutno experimentálně určit. Hodnoty prahovacího signálu jsou dány

$$thr_n = \frac{k}{2i+1} \sum_{m=n-i}^{n+i} d_m, \quad (1.3)$$

kde k je konstanta míry nebo také prahovací poměr, d je detekční signál a délka průměrovacího okna je $2i + 1$. Tato metoda je vhodná pro nahrávky hudebních těles, obsahujících perkusivní nástroje. Údery na perkusivní nástroje mohou být v nahrávce zachyceny detekčním signálem a mohou v něm způsobit zvýšenou hladinu šumu. Ta by mohla překročit pevnou hladinu prahování. Adaptivní prahování se snaží tento problém řešit.

Autor článku [7] dále navrhuje před samotnou detekcí upravit signál pomocí kvadratického průměru pozorovaného signálu. První krok detekce tedy vytvoří signál podle vztahu

$$r_n = \sqrt{\frac{1}{2i+1} \sum_{m=n-i}^{n+i} x_m^2}, \quad (1.4)$$

kde $2i + 1$ je šířka průměrování. Následně se na získaném signálu provede výše zmíněná detekce podle vztahu (1.2), kde za pozorovaný signál dosadíme signál po průměrování.

Sám autor však došel k závěru, který v závěru práce i vyjádřil v tabulce porovnávající zmíněné metody, že metoda s použitím kvadratického průměrování signálu nenabízí žádné výrazné zlepšení v detekci oproti samotné derivační metodě, spíše však naopak.

1.4 Filtrování horní propustí

Algoritmus navržený autory [2] realizuje detekci a interpolaci zároveň. Pro úplnost zde bude uveden v celé šíři, avšak při implementaci budeme uvažovat pouze detekční stupeň. Celý algoritmus stojí na filtrování poškozeného signálu horní propustí, úpravě filtrovaného signálu pro lepší prahování a následné filtrování původního signálu filtrem představujícím median, spouštěným přepínacím signálem vzniklým prahováním. Ten tedy provádí průměrování hodnot, jinak řečeno zahlazování špiček, pouze v oblastech, které přepínací signál určí jako poškozené.

Pro představu algoritmu označme vstupní signál x_n a signál výstupní, tedy po výpočtu medianu v oblasti výskytu impulsů, y_n . Filtrování typu horní propust je realizován pomocí diskretní druhé derivace. Ta, jež je navržena autory [2] však úplně neodpovídá definici:

$$d_n = x_{n-1} - 2x_n + x_{n+1}. \quad (1.5)$$

Podle *Verletovy integrace* [25] je druhá derivace série diskretních hodnot v čase dána:

$$\ddot{x}_n = \frac{x_{n-1} - 2x_n + x_{n+1}}{\Delta t^2} = \frac{x_{n-1} - 2x_n + x_{n+1}}{T^2}. \quad (1.6)$$

Jestliže však víme, že vzorkovací perioda je konstantní, můžeme dělitel z výrazu vypustit, aniž bychom pozměnili charakter vzniklého detekčního signálu.

Filtrací jsme získali detekční signál, který je nutné pro snazší detekci nutné upravit tak, aby se pohyboval pouze v kladných hodnotách. Zde se nabízí několik možností. Prvně bychom mohli použít absolutní hodnotu signálu. Tímto postupem bychom získali přesnější lokalizaci počátku impulsu, na druhou stranu by se v intervalu detekce mohla objevit hodnota pod úrovní prahování. Druhá metoda je pro každý vzorek výpočet kvadratického průměru okolních vzorků a vzorku samotného, dále jen RMS:

$$d_{RMS_n} = \sqrt{\left[\frac{1}{M+1} \sum_{j=-M/2}^{M/2} d_{n+j}^2 \right]}, \quad (1.7)$$

kde M je šířka průměrovacího okna. Zde není sice počátek impulsu detekován s takovou přesností, avšak průběh detekce impulsu je souvislý, což je důležitá vlastnost pro správný chod interpolační části algoritmu.

Následuje prahování, které vygeneruje přepínací signál spouštějící regresivní medianový filtr vyhlazující impulsy v poškozeném signálu. Pro tvorbu prahovacího signálu je navržen rekurzivní median filtr jehož funkce je posána následující rovnicí:

$$r_n = \text{med}\{r_{n-k}, r_{n-k+1}, \dots, d_{RMS_n}, d_{RMS_{n+1}}, \dots, d_{RMS_{n+k}}\}, \quad (1.8)$$

kdy šířka okna je $2k+1$. Pro tvorbu efektivního prahovacího signálu je nutné, aby byla šířka okna alespoň dvakrát větší, než je šířka impulsů audiosignálu. Pro snížení výpočetní náročnosti je možné vzorky v okně rekurzivního medianu decimovat.

Přepínací signál g_n je ze signálu d_{RMS_n} a prahovacího signálu r_n vytvořen podle klíče:

$$g_n = \begin{cases} 1 & \text{pokud } z_n > P, \\ 0 & \text{pokud } z_n \leq P, \end{cases} \quad (1.9)$$

kde:

$$z_n = \frac{|d_{RMS_n} - r_n|}{r_n} \quad (1.10)$$

a P je úroveň prahování.

Nakonec je pomocí přepínacího signálu g_n spínán median filtr upravující poškozený signál x_n v místě výskytu impulsu a generující signál upravený y_n :

$$y_n = \begin{cases} s_n & \text{pokud } g_n = 1, \\ x_n & \text{pokud } g_n = 0, \end{cases} \quad (1.11)$$

kde:

$$s_n = \text{med}\{x_{n-k}, x_{n-k+1}, \dots, x_n, x_{n+1}, \dots, x_{n+k}\} \quad (1.12)$$

kde $2k+1$ je šířka okna median filtru.

1.5 Detekce pomocí autoregresivní metody a metody klouzavého průměru

Jedním z hlavních předmětů lineární predikce časově invariantních diskrétních systému je modelování těchto procesů. Základním modelem takového systému je filtr s obecnou přenosovou charakteristikou excitovaný periodickou řadou impulsů nebo náhodným šumovým signálem [23]. Lineární model [23] odvodíme následovně.

Řekněme, že signál s_n je výstupem systému s excitačním vstupem u_n , kdy platí:

$$s_n = - \sum_{k=1}^p a_k \hat{s}_{n-k} + G \sum_{l=0}^q b_l u_{n-l}, \quad b_0 = 1 \quad (1.13)$$

kde $a_k, 1 \leq k \leq p$, $b_l, 1 \leq l \leq q$ a zisk G jsou parametry systému. Výraz říká, že výstup systému s_n je lineární kombinací dřívějších vzorků výstupního signálu a momentálních a dřívějších vzorků vstupního signálu systému [23]. Tento model se nazývá **ARMA**, jelikož obsahuje predikci průběhu jak za pomoci *auto-regresivního* (**AR**), tak *Moving Average* (**MA**) algoritmu, klouzavého průměru. Oba případy budou objasněny dále v textu. Výraz (1.13) lze za použití *transformace Z* převést do frekvenční oblasti

$$H(z) = \frac{S(z)}{U(z)} = G \frac{1 + \sum_{l=1}^q b_l z^{-l}}{1 + \sum_{k=1}^p a_k z^{-k}}, \quad (1.14)$$

kde $S(z)$ je obrazem AR aproximace signálu s_n , představuje nuly přenosové funkce, a $U(z)$ je obrazem aproximace posloupnosti excitačního vstupního signálu u_n , představuje póly přenosové funkce. V odkazovaných literaturách [24, 23] můžeme nalézt drobné nesrovnalosti ve vyjádření vztahu ve frekvenční oblasti, avšak ne takové, aby zásadně měnily význam. Zdroj [24] uvádí nuly přenosové funkce jako $S(z) = \sum_{l=0}^q b_l z^{-l}$, zatímco [23] je značí $S(z) = 1 + \sum_{l=1}^q b_l z^{-l}$. Druhá definice tedy explicitně stanovuje, že první kořen, nezpožděný vzorek excitačního signálu, je roven jedné, zatímco první ponechává váhu prvního pólu na estimaci parametrů. Druhý rozdíl je ve jmenovateli přenosové funkce a spočívá ve znaménkové konvenci. Ve zdroji [23] je suma s kladným znaménkem, zatímco ve zdroji [24] je tomu opačně. Záleží na interpretaci parametrů při jejich estimaci.

Stanovením specifických podmínek pro parametry přenosové funkce získáme dva konkrétní případy tohoto modelu. Prvně položíme $a_k = 0$ pro $1 \leq k \leq p$, čímž získáme přepis pro *Moving Average* model. Ten stanovuje, že výstupní proměnná je lineární kombinací právě sledovaného a minulých vzorků náhodného vstupního signálu. V časové oblasti je obecný přepis MA modelu

$$s_n = \mu + \sum_{l=0}^q b_l u_{n-l}, \quad (1.15)$$

kde μ je střední hodnota řady a q je řád modelu. MA model je narušitel od AR modelu stacionární, jeho střední hodnota a variance se nemění v čase. Tento model je sice v odkazované literatuře uváděn, ale nikde není jeho samostatná aplikace. Mnohem častěji se s ním můžeme setkat v kombinaci s AR procesem. Ani v této práci nebudeme implementovat detekci čistě pomocí MA modelu.

Pokud položíme $b_l = 0$ pro $1 \leq l \leq q$, získáme čistě autoregresivní model. Prvním krokem pro při aplikaci modelu je získání AR parametrů. Tyto parametry jsou stručně řečeno hodnoty, kterými jsou váhovány zpožděné vzorky při regresivním odhadu aktuálního vzorku. Na odhad parametrů existuje mnoho metod. Mezi nej-používanější patří metoda nejmenších čtverců [11, 16], která hledá nejmenší součet čtverců odchylek pro každou kovarianční rovnici, avšak je velmi nepřesná, pokud signál obsahuje bílý šum. Často se také můžeme setkat s odhadem pomocí Yule-Walkerových rovnic [12].

Existují však i kombinace zmíněných metod [13, 14] nebo metody na jiném základu, například metoda nejmenší absolutní odchylky a z ní vyvozující metody, jako generalizovaná metoda absolutní odchylky [15] nebo metoda maximální věrohodnosti [17]. V závislosti na použití parametrů jsou AR modely děleny na časově neměnné, parametry zachovávají v průběhu procesu konstantní hodnoty, a časově proměnné, kdy se hodnoty parametrů průběžně mění v čase.

Pro nepříliš závažně poškozené stopy můžeme uvažovat následující [4]. Mějme sledovaný signál $x_n \in \mathbb{R}^N$, který můžeme vyjádřit jako superpozici signálu bez rušení s_n a rušivého impulsního signálu w_n :

$$x_n = s_n + w_n. \quad (1.16)$$

Z charakteru impulsního rušivého signálu vyplývá, že pokud v nějakém vzorku n není impuls přítomen, nemusíme signál impulsního rušení brát v potaz. To lze vyjádřit pomocí rozepsání rušivého impulsního signálu w_n na součin rušivého signálu v_n a přepínacího procesu i_n

$$w_n = i_n \cdot v_n. \quad (1.17)$$

Cílem AR procesu je s co největší možnou přesností určit hodnoty přepínacího procesu. Toho lze dosáhnout například vhodným prahováním detekčního signálu. Vztah pro detekční signál získáme úpravou základního vztahu pro lokálně časově invariantní autoregresivní proces. Ten vyjadřuje odhadnutou hodnotu aktuálního vzorku jako sumu p součinů předchozích vzorků s_{n-k} s AR parametry a_k

$$s_n = - \sum_{k=1}^p a_k s_{n-k} + e_n. \quad (1.18)$$

Pro přesnější vyjádření je do vztahu přidán člen excitační signál e_n jež vyjadřuje bílý šum s nulovou střední hodnotou.

Pokud impulsní rušení zabírá jen marginální část signálu, dá se předpokládat, že hodnoty AR parametrů signálu bez rušení se nebudou příliš lišit od hodnot parametrů narušeného signálu. Potom můžeme pro sledovaný signál pomocí výrazu (1.16) a (1.18) napsat

$$x_n = - \sum_{k=1}^p a_k s_{n-k} + e_n + w_n, \quad (1.19)$$

a dále rozepsat původní signál v rovnici 1.19 pomocí 1.16, jelikož hodnoty s_n nejsou známy, na

$$x_n = - \sum_{k=1}^p a_k (x_{n-k} - w_{n-k}) + e_n + w_n. \quad (1.20)$$

Nakonec vyvodíme rovnici pro detekční signál jako rozdíl daného vzorku sledovaného signálu a jeho AR odhadu

$$d_n = x_n + \sum_{k=1}^p a_k x_{n-k}, \quad (1.21)$$

a po dosazení rovnice (1.20)

$$d_n = e_n + w_n + \sum_{k=1}^p a_k w_{n-k} \quad (1.22)$$

je zřejmé, že detekční signál vyjadřuje přibližně hledaný impulsní signál.

Jak již bylo zmíněno, tento model se dá s přijatelnými výsledky aplikovat pouze pro impulsní rušení jednoduššího charakteru. To platí především pro rychle po sobě následující impulsy, jejichž vychýlení detekčního signálu se bude propagovat dále, což způsobuje suma v rovnici (1.22).

1.5.1 Detekce pomocí ARMA modelování

Detekce pomocí modelování signálu za pomoci ARMA aproximace je ze zmíněných metod výpočetně nejnáročnější. Reprezentaci signálu můžeme vidět ve výrazu (1.13). AR model je speciální případ modelu ARMA, ten je tedy jeho zobecněním. Jedná se o filtr s nekonečnou impulsní odezvou aplikovaný na sérii vzájemně nezávislých hodnot braných ze stejného rozdělení pravděpodobnosti. Autoři článku [24] shledali detekci pomocí modelování ARMA nízkého řádu za obdobně účinnou jako detekci pomocí AR modelu řádu v řádu desítek.

1.5.2 Filtrace detekčního signálu pomocí přizpůsobovacího filtru

Přizpůsobovací filtry (z anglického *Matched Filter*) jsou filtry využívané za účelem zvýšení odstupu specifického signálu od šumu. Jejich princip se zásadně liší od předchozích. Z pohledu této metody [24] je impulsní rušení považováno za užitečný signál, který se filtr snaží identifikovat. Audiosignál je pak považován za šum, který je nutné potlačit.

2 Výsledky studentské práce

Pro vlastní implementaci probraných řešení byly vybrány následující metody detekce: filtrace signálu filtrem typu horní propust, derivační metoda, jednosměrná a obousměrná detekce autoregresivním modelováním a detekce pomocí ARMA modelování signálu. Za účelem prahování byly aplikovány dvě metody: jednoduché prahování konstantní hodnotou, určenou průměrnou maximální hodnotou detekčního signálu, násobenou volitelnou hodnotou značenou jako prahovací poměr a adaptivní prahování, které vytváří prahovací signál, jehož úroveň je počítána podle průměrné okolní úrovně detekčního signálu (1.3). Hlavním zdrojem při psaní kódu byly články [4, 7, 24, 2]. Za jazyk implementace byl zvolen Matlab. V programu je použito několik komplexnějších funkcí již obsažených ve zmíněném prostředí. Tyto funkce nejsou přímo hlavním objektem zájmu této práce.

Cílem práce je zjistit přesnost těchto metod, jejich nevýhody a slabiny, pozorovat závislost přesnosti výsledku na nastavení parametrů detekčních procesů a hodnotě prahování. Důležitým faktorem při vyhodnocování spolehlivosti procesu je schopnost detekovat více impulsů jdoucích za sebou v těsné návaznosti, jelikož je pravděpodobné, že reálná nahrávka bude tento jev obsahovat.


Nakonec jsou jednotlivé metody detekce aplikovány na nahrávky se skutečným poškozením. Jelikož nejsou známy přesné pozice impulsů, přepínací signály k nahrávkám byly vytvořeny ručně. Počátek impulsu není těžké lokalizovat s dostatečnou přesností. Lokalizace konce impulsu je však téměř nemožná. Pulsní odezva nahrávacího zařízení se projevuje jako vysokofrekvenční harmonické či náhodné kmitání superponované na audiosignál. To lze po počátečním impulsu sledovat, ale jeho energie postupně klesá, až je téměř nerozeznatelné od užitečného signálu. Konce impulsů byly tedy určeny čistě orientačně a výsledky úspěšnosti detekce nahrávek s reálným rušením tudíž nejsou směrodatné, nýbrž pouze orientační.

2.1 Testovací nahrávky, charakter impulsů

K testování uměle generovaných impulsů byla vybrána krátká instrumentální nahrávka bicích, saxofonu a kytary. Nahrávka je vhodná k testování, jelikož bicí a saxofon generují vysoký podíl vyšších harmonických, které zhoršují možnosti detekce impulsů a tudíž na nich lze dobře porovnávat výkon metod. Variance hodnot vzorků v této nahrávce je 0,169.

Dále byly k testování poskytnuty tři nahrávky s reálným rušením. První nahrávka, *capercaille*, je záznamem zpěvu ženského hlasu s ambientním smyčcovým doprovodem. Kromě harmonického rušení, často označovaného jako brum, a šumu


je z poslechu evidentní charakteristický praskot přehrávání vinylové desky. Na prvních 2 sekundách byly ručně označeny i ty nejslabší impulsy. Je však nutno dodat, že tato část je velmi tichá. Díky tomu budeme moci testovat důkladnost jednotlivých metod. Zbytek impulsů v nahrávce byl označen jen zběžně. Variance této nahrávky je $8,184 \cdot 10^{-4}$.



Obr. 2.1: Impuls způsobený porušením drážky na vinylové desce

Ve valné většině případů je amplituda impulsů srovnatelná s amplitudou užitečného signálu. Takovéto impulsy jsou shodné s charakterem popsaným v úvodní kapitole. Detekce v této nahrávce by neměla být obtížná, neboť neobsahuje žádné perkusivní nástroje. Výzvou je však ideální nastavení parametrů detekční metody, jelikož nahrávka obsahuje impulsy s rozdílnou intenzitou a navíc má nízký odstup od šumu, což působí u většiny metod globální zvýšení průměrné hodnoty detekčního signálu.


Dalším předmětem zkoumání je nahrávka tria klavír, housle a cello. Ta obsahuje intenzivní periodické impulsy, nejpravděpodobněji způsobené nestabilním fantomovým napájením kondenzátorového mikrofону nebo A/D převodníkem. Variance této nahrávky je $3,187 \cdot 10^{-4}$.



Obr. 2.2: Impuls způsobený nestabilním napájením nebo chybou při převodu

Impuls je charakteristický svým průběhem. Prvně přijde kladný impuls a přibližně po třiceti vzorcích impuls záporný, po němž však nenásleduje výrazný záchvěv. Díky intenzitě a výraznému impulsu na začátku i konci by neměla být úspěšná detekce problém.

Poslední nahrávka je záznam muzikálu na vinylové desce. Tentokrát se dost pravděpodobně jedná o příčné poškození desky, jak jde poznat z pravidelnosti výskytu impulsu. Variance této nahrávky je $9,9 \cdot 10^{-3}$.



Obr. 2.3: Impuls způsobený příčnou prasklinou či rýhou na vinylové desce

2.2 Programové řešení

2.2.1 Nastavení parametrů skriptu a načítání dat

Skript umožňuje výběr metody detekce z výše zmíněných v kombinaci s vybraným způsobem prahování. Následně si uživatel může zvolit, zda chce, aby skript tiskl průběhy detekcí, průběh původního signálu a signálu s přidaným rušením či rušení samotné. Nakonec musí upřesnit, zda chce zpracovat již poškozené nahrávky, nebo impulsy definovat ručně a přidat je do nepoškozené nahrávky.

V prvním případě je nutné mít před spuštěním skriptu načtený soubor s nahrávkou převedenou do vektorové podoby, informací o vzorkovací frekvenci a s vytvořeným referenčním signálem. Tato data je nutné doplnit do navazující selekce. Dále je možné pro velmi dlouhé stopy nastavit úsek v sekundách, který má být zpracováván a z něj následně vybrat úsek ve vzorcích, který má být zobrazen. V základním nastavení je zpracovávána a zobrazována celá nahrávka. V případě, že chce uživatel do nahrávky představit vlastní impulsy, musí zvolit, kterou nahrávku chce převést, program umí zpracovat pouze monofonní nahrávky. Jako v předchozím případě je možné si zvolit zpracovávanou a zobrazovanou sekci.

Za účelem testování obsahuje skript iterativní cyklus pro generování impulsů s pseudonáhodnými parametry. Nejprve se zvolí počet impulsů, které mají být náhodně rozmístěny v nahrávce. Následně se zvolí průměrná intenzita impulsů, variace intenzity a minimální a maximální délka impulsů. Podle zadaných parametrů jsou do nahrávky přidány impulsy harmonického průběhu. Tento způsob generování impulsů je v práci využit k měření závislosti úspěšnosti detekce na intenzitě impulsního rušení. K porovnání metod slouží statické generování impulsů.


Program zapisuje při každém průběhu skriptu dosažené výsledky do textového souboru **experimental_data.txt**. Každý zápis obsahuje kromě záznamu času spuštění a informaci o použitých datech výčet aplikovaných detekčních metod a jejich přesnost. Ta je vyjádřena třemi hodnotami udanými v procentech, případně v promilích. První, falešná detekce, udává podíl nepoškozených vzorků, které algoritmus označí za poškozené, ze všech nepoškozených vzorků. U tohoto údaje už i jedna promile představuje vcelku vysokou hodnotu, tedy že každý tisíc nepoškozený vzorek byl falešně detekován. To by například u vzorkovací frekvence 44,1 kHz v průměru znamenalo 44 falešných detekcí za sekundu. Druhá hodnota, uniklá detekce, vyjadřuje v procentech podíl nedetekovaných poškozených vzorků ze všech poškozených vzorků. Třetí hodnota, pravdivá detekce, je doplňkem k předchozí, tedy podíl detekovaných poškozených vzorků ze všech poškozených vzorků. Poslední dvě hodnoty určují především, jak přesně dokáže daná metoda odhadnout délku impulsu. Posledním údajem, avšak velmi důležitým, je doba výpočtu. Jelikož nás zajímá konkrétní doba, kterou trvá procesoru zpracovat data zadanými kroky, bylo rozhodnuto pro použití funkce `cputime`, která funguje jako čítač doby běhu procesoru. Doba výpočtu je testována na 50 sekund dlouhé nahrávce *capercaille*. Testování výpočetní náročnosti bylo prováděno na přenosném počítači LENOVO se systémem Windows 10 Pro. Počítač má čtyřjádrový procesor i7-4702MQ 2,20 GHz a 8 GB RAM.

2.2.2 Generování umělých impulsů

Pro potřeby simulace impulsu byly zvoleny dva modely. Oba modely se snaží přiblížit charakteru reálných impulsů. Reálné impulsy začínají prvotní nespojistostí následovanou odeznívající oscilací způsobenou impulsní odezvou zařízení, které snímá daný signál [19]. První model představený v této implementaci vytváří náhodný signál s rovnoměrnou výkonovou spektrální hustotou dělený pořadím vzorku impulsu. Dělení vzorkem impulsu simuluje odeznívající oscilaci. Druhý model funguje na stejném principu, ale náhodný signál je nahrazen harmonickou funkcí [20, 19]:

$$imp_n = I_{max} \cdot \sin\left(2 \cdot \pi \cdot T \cdot \frac{n}{N}\right) \cdot \frac{1}{n}, \quad (2.1)$$

kde I_{max} je amplituda impulsu, T je počet period a N je délka impulsu ve vzorcích. Tento přístup se blíží podobě impulsu způsobeného poškozením vinylové desky 2.1.




Obr. 2.4: Grafické zobrazení impulsů obou metod a nepoškozeného signálu s přidáním impulsů

2.3 Diferenční metoda detekce


U výpočetně nejméně náročného algoritmu se dá očekávat i nejnížší spolehlivost. Jednoduchý diferenční algoritmus prahovaný adaptivně měl u uměle vytvořeného rušení přesnost při prahovacím poměru 6,3 a šířce průměrovacího okna prahování 400 vzorků úspěšnost okolo 7,5 % a falešnou detekci až na 1,7 ‰. Na obrázku 2.6 lze pozorovat, že metoda lépe zachycuje impulsy s náhodným průběhem oproti průběhu harmonickému. U náhodných hodnot bývá rozdíl mezi sousedícími vzorky větší než u harmonického průběhu. Jisté zlepšení přináší zařazení RMS filtru před detekční krok. Tento krok neodpovídá návrhu autorů [7]. Při šířce RMS okna 4 vzorky, okna prahování 150 vzorků a prahovacího poměru 4.6 klesne falešná detekce na jednotky promile a pravdivá detekce se lehce zvedne k devíti procentům. Tato úprava však sebou přináší dřívější detekci, a to o téměř polovinu šířky průměrovacího okna.

Při testování na reálných nahrávkách však metoda vcelku překvapila svými výsledky. Na nahrávce muzikálu byla falešná detekce na 1,7 ‰ a úspěšná na 22 %, na nahrávce klavírního tria 0,8 ‰ a 17 %, na *capercaille* 0,6 ‰ a 21 %. Na obrázku 2.7 můžeme sledovat průběh detekce na prvních dvou sekundách záznamu *capercaille*. Výsledek nelze příliš ovlivnit, jelikož detekční algoritmus nemá žádné vstupní


parametry a jedině, co je možné nastavit, je citlivost prahování. Doba výpočtu pro předem stanovenou nahrávku byla okolo 2,5 sekundy.



Obr. 2.5: Grafické zobrazení průběhu diferenční metody bez použití RMS filtru




Obr. 2.6: Grafické zobrazení průběhu diferenční metody s použitím RMS filtru šířky 4 vzorky



Obr. 2.7: Grafické zobrazení průběhu diferenční metody


Při testování vztahu mezi intenzitou impulsního rušení a úspěšností detekce bylo zjištěno, že zde jistá návaznost je. S rostoucí intenzitou rušení lehce vzrostla hodnota pravdivé detekce, nešlo však o výrazné zlepšení. Při měření bylo využito generování 50 pseudonáhodných impulsů se šířkou 30 až 60 vzorků. V detekčním algoritmu byl použit RMS filtr s šířkou okna 4 vzorky. Adaptivní prahování mělo okno šířky 150 vzorků a prahovací poměr nastaven na 4,8. Záznam měření je dostupný v souboru `experimental_data.txt` na řádcích 23904 až 26250.

Závislost úspěšnosti detekce na intenzitě impulsního rušení



2.4 Detekce pomocí filtrování horní propustí


Tento přístup vychází z předpokladu, že impulsy jsou přítomny ve vyšších frekvenčních pásmech. Při implementaci této metody byly zvoleny dva přístupy. První z nich je popsán v kapitole 1.4. Pro náš účel byla vynechána finální část, kde dochází k opravě poškozeného signálu. Implementovaný algoritmus kopíruje postup popsáný výrazy (1.5) až (1.10). Diferenciacce byla dosažena za pomoci funkce `diff()`, která nám dovoluje určit, o kolikátý stupeň difference se jedná. Detekční signál je tedy získán podle (1.7) a přepínací signál potom podle (1.9). Úroveň difference byla ponechána na stupni 2, jak bylo doporučeno autory [2]. Vyšší úroveň nijak zvlášť nezvyšuje přesnost detekce, nýbrž způsobuje dřívější detekci, což není žádoucí. Podobný důsledek má i zvyšování řádu filtru RMS, který je ideální ponechat kolem hodnoty 4. Řád filtru rekurzivního medianu musí být ponechán tak, aby stíhal sledovat lokální změny charakteru signálu, a zároveň tak, aby ho neovlivňovaly impulsy detekčního signálu, tedy, aby byl alespoň dvakrát delší než předpokládaná délka impulsů. V následujícím měření byla sledována závislost úspěšnosti detekce, hodnota falešné a pravdivé detekce, na hodnotě šířky okna filtru rekurzivního medianu. Ke tvorbě impulsů bylo využito generování 50 pseudonáhodných impulsů intenzity 0,6 a variance intenzity 0,2. Detekční algoritmus stupně difference 2 měl šířku okna RMS filtru 4 vzorky a prahovací poměr 5,4. Záznam měření je dostupný v souboru `experimental_data.txt` na řádcích 27545 až 31849.



Ze závislosti je patrné, že nejlepší poměr falešné a pravdivé detekce je při šířce okna RMF okolo 120 vzorků. Při vyšších hodnotách již zůstává hodnota pravdivé detekce na přibližně na stejné úrovni, zatímco hodnota falešné detekce stoupá. I při vyzkoušení různých nastavení parametrů byla detekce vždy o několik vzorků posunuta.

Dále byl experimentálně proměřen vztah mezi pravdivou detekcí a intenzitou rušení. Do nahrávky bylo náhodně přidáno 50 impulsů s nulovou variancí intenzity a délkou 30 až 60 vzorků. Detekční algoritmus druhého stupně difference s šířkami oken RMS filtru 10 a RMF filtru 120 s prahovacím poměrem 5,4 detekoval impulsy různých intenzit. Záznam měření je dostupný v souboru **experimental_data.txt** na řádcích 32094 až 36959.


Závislost úspěšnosti detekce na intenzitě impulsního rušení




Hodnota pravdivé detekce je tedy evidentně úměrná intenzitě impulsního rušení. Se zvyšující se intenzitou rušení je možné si povšimnout rostoucí hodnoty falešné detekce. To je pravděpodobně způsobeno dřívější detekcí impulsů, která je díky průměrovacím filtrům tím znatelnější, čím intenzivnější je rušení.

V závislosti na parametrech se podíl úspěšné detekce pohyboval od 10 do 20 procent s falešnou detekcí okolo desetiny promile. Při testování na reálné nahrávce muzikálu se falešná detekce zvedla na jednotky promile, což je způsobeno především perkusivními nástroji v první polovině a dechovou sekcí v polovině druhé. Naopak u nahrávky klavírního tria byla detekce velmi úspěšná. Při záběru na detailně označenou část nahrávky *capercaille* bylo dosaženo nulové falešné detekce při velmi úspěšné detekci. Na celé nahrávce se pravdivá detekce pohybovala okolo 30 %. Zvláštností je uniklá detekce mezi vzorky 258974 až 259040. I při různých nastavení ji tato metoda nebyla schopna bezpečně zachytit, ač hned vedlejší impuls o slabší intenzitě zachy-

tila vždy. Doba výpočtu pro předem stanovenou nahrávku byla okolo 8,3 sekundy.



Obr. 2.8: Grafické zobrazení průběhu filtračních metod



Obr. 2.9: Grafické zobrazení průběhu filtračních metod na nahrávce klavírního tria

Druhý přístup spočívá ve filtraci za použití funkce `filter()`. Tato funkce zprostředkuje filtraci signálu filtrem s převodní charakteristikou na základě předaných nul a pólů polynommické převodní funkce. Její navržení bylo následovné. Empiricky byl zvolen filtra typu horní propust druhého či třetího řádu, jehož přenosová funkce

má tvar:

$$H(z) = \frac{b_0 + b_1 z^{-1} + b_2 z^{-2}}{1 + a_1 z^{-1} + a_2 z^{-2}}, \quad (2.2)$$

kde koeficienty jsou dané:

$$\begin{aligned} b_0 &= \frac{Q}{K^2 Q + K + Q} & b_1 &= -\frac{2Q}{K^2 Q + K + Q} & b_2 &= \frac{Q}{K^2 Q + K + Q} \\ a_0 &= 1 & a_1 &= \frac{2Q \cdot (K^2 - 1)}{K^2 Q + K + Q} & a_2 &= \frac{K^2 Q - K + Q}{K^2 Q + K + Q}. \end{aligned}$$

Koeficient K se vypočítá jako $K = \tan(\pi f_c / f_s)$, kde f_c je volitelný mezní kmitočet filtru a f_s je vzorkovací kmitočet filtrované stopy. Činitel jakosti Q je vhodné nastavit v rámci jednotek. Pro naši aplikaci je vhodnější filtr vyšší jakosti. Mezní kmitočet byl empiricky určen na 18,5 kHz. Získaný signál je následně přizpůsoben pro prahování pomocí RMS filtru jako v předchozí aplikaci. Na prahování je použita funkce adaptivního prahování.

Tato metoda má vyšší procento úspěšných detekcí oproti předchozí, jelikož dobře zachycuje oscilační doznívání impulsu, její stinnou stránkou je vyšší procento falešných detekcí, zvláště pak u nahrávek obsahujících perkusivní nástroje a nástroje, jejichž zvuk má vysoký podíl vyšších harmonických. Detekční signál má pak vysokou úroveň šumu, který zamaskuje slabší impulsy. Doba výpočtu pro předem stanovenou nahrávku byla okolo 3,1 sekundy.

2.5 Detekce pomocí AR modelování signálu

K dispozici jsou dvě funkce, obě stojící na AR principu. Funkce mají v sobě za účelem odhadnutí AR parametrů naimplementovány funkce k tomu určené a zároveň můžeme předáním parametru funkce rozhodnout, který model bude na odhad parametrů použit. Na výběr jsou celkem tři možnosti:


- lineární predikce (funkce `lpc()`)
- Yule-Walkerův model (funkce `aryule()`)
- Burgova metoda (funkce `arburg()`).

Funkce pro estimaci parametrů mají dvě hlavní vstupní proměnné, trénovací data, na jejichž základě jsou parametry vypočteny, a řád AR procesu, který stanovuje počet pólů přenosové funkce. Získání parametrů pomocí lineární predikce stojí na principu minimalizace střední hodnoty autokorelační funkce signálu [23]. Toho je dosaženo nejčastěji za pomoci metody nejmenších čtverců. Druhou metodu představili autoři Udney Yule [26] v rámci jeho článku na modelování periodicity výskytu slunečních skvrn a Gilbert Walker [27]. S poslední metodou přišel Jean-Pierre Burg [28].

První z implementovaných detekčních funkcí provádí detekci pouze v jednom směru na základě principu popsaného v 1.5. Druhá funkce, nazvěme ji obousměrnou detekční funkcí, užívá stejného principu jako předchozí, avšak provádí generování detekčního signálu pro oba směry [5]. AR parametry jsou odhadnuty pro oba směry, ač by se neměly příliš lišit. Následně jsou oba detekční signály sečteny a výsledný signál podělen dvěma. Pro prahování detekčního signálu je možné použít obě dříve zmíněné metody prahování.

Na začátek byly porovnány metody estimace parametrů, nebyl však pozorován žádný zásadní rozdíl ve vykreslení průběhů mezi detekčními signály generovanými jednotlivými metodami. Burgova metoda se však od ostatních vymezuje mnohem rychlejším průběhem. Nebyla sice měřena přímo doba estimace, ale doba generování jednosměrného detekčního signálu, která však obsahuje jen dobu vybrané funkce pro estimaci a funkce generování detekčního signálu. Při použití Burgovy metody byla doba výpočtu detekčního signálu poloviční.


Dalším společným parametrem pro obě metody, jednosměrnou i obousměrnou, je řád AR procesu. Podívejme se, jaký důsledek má jeho postupné zvyšování. Estimace parametrů byla provedena pomocí Yule-Walkerových rovnic. Na umělých impulsích jsme postupně provedli detekci řádů procesu 5, 15, 30 a 80.



Obr. 2.10: Průběhy detekčního signálu AR metody pro různé hodnoty řádu procesu

Je evidentní, že se zvyšujícím se řádem procesu se konkretizuje detekce impulsu v celém rozsahu. Při nejnižším řádu zachytí algoritmus jen počáteční impuls. Při zvyšování řádu nad 30 ale není znát výraznější rozdíl. Naopak bylo při opakovaném měření při vysokých hodnotách řádu pozorováno, že detekce je nestálá a často není impuls vůbec zachycen. Toto porovnání bylo provedeno na intenzivním impulsu. Pokud se podíváme na výsledky slabších impulsů v tiché části nahrávky, v našem

případě první dvě sekundy nahrávky *capercaille*, při různých hodnotách řádu autoregresivního procesu, uvidíme následující.




Obr. 2.11: Průběhy detekčního signálu AR metody pro různé hodnoty řádu procesu

Je evidentní, že s rostoucím řádem AR procesu narůstá hladina šumu v detekčním signálu a slabší impulsy jsou tudíž nezachytitelné. Je tedy potřeba zvolit vhodně řád procesu tak, aby byly dostatečně vykresleny silné impulsy a zároveň byly zachyceny i slabší. Experimentálně (`experimental_data.txt` řádek 10384 až 11527) bylo určeno, že ideální hodnota řádu je 8.

Jednosměrná AR detekce

Prvně se blíže podíváme na jednosměrnou AR detekci. V kódu je zapsána implementace jak v časové oblasti, pomocí iteračních cyklů, tak metoda ve frekvenční oblasti za pomoci funkce `filter()`. Výsledky obou postupů jsou naprosto identické, při vyhodnocování byla použita filtrovací metoda.




Obr. 2.12: Grafické zobrazení průběhu autoregresivní metody na uměle vytvořených impulsích


Nejbezpečnější způsob určení pozice silných impulsů bez detekce slabších je pomocí standardního prahování. Pro tento účel je vhodné zvolit prahovací poměr větší než deset, pak by k falešné detekci téměř docházet nemělo, a to ani u nahrávek s perkusivními prvky. Stejně jako v předchozích případech, perkusivní nástroje představují do nahrávky signál příliš podobný šumu, tedy náhodnému signálu. V kontextu detekčního signálu uvažujeme za užitečný signál impulsy a za šum vše ostatní. Při syntéze zvuků takovýchto nástrojů se právě z těchto důvodů používají generátory náhodného signálu. Standardní prahování však nerozezná v detekčním signálu oblast se zvýšeným výskytem šumu od slabšího impulsu.

Pokud bychom chtěli detekovat širší škálu impulsů, je vhodné použít adaptivního prahování. Zde musíme kromě prahovacího poměru nastavit také šířku průměrovacího okna. Experimentálně bylo zjištěno, že šířka okna musí být minimálně dvojnásobná k průměrné šířce impulsu, jinak pravdivá detekce klesá k nule. Naopak vysoké hodnoty průměrovacího okna vedou k falešné detekci v místech, kde se v detekčním signálu nárazově objeví oblast zvýšeného šumu. Proto je v závislosti na vzorkovací frekvenci nejvhodnější volit šířku okna někde mezi 100 až 300 vzorky. Všechny testované nahrávky jsou na vzorkované na nejnižší běžné frekvenci, 44,1 kHz. Volba šířky okna byla provedena následovně. Na nahrávce s umělými impulsy byla při řádu AR procesu 8 a prahovacího poměru 4,8 postupně měněna šířka okna. Měření lze dohledat v souboru **experimental_data.txt** na řádcích 18259 až 22816.


Závislost přesnosti detekce na šířce průměrovacího okna adaptivního prahování



Při hodnotě šířky průměrovacího okna okolo 50 vzorků vychází nejlepší poměr falešné a pravdivé detekce. Počátky všech podstatných impulsů jsou zachyceny. Mohlo by se zdát, že snižování prahovacího poměru při šířce průměrovacího okna 50 vzorků je ideálním přístupem ke zvýšení pravdivé detekce se současně nízkou falešnou detekcí. Avšak experimentálně bylo zjištěno, že snižování poměru vede k znatelnému zvýšení falešné detekce a již ne k tolik viditelnému zvýšení detekce pravdivé. Tudíž, pokud budeme brát 1,0 ‰ jako hraniční hodnotu falešné detekce, ideální hodnota šířky průměrovacího okna bude okolo 170 vzorků. Při standardním prahování s prahovacím poměrem 12 bylo dosaženo nulové falešné detekce a pravdivé detekce okolo 12 %. Při adaptivním prahování šířky okna 150 vzorků a prahovacího poměru 5,2 bylo průměrně dosaženo podobné úrovně pravdivé detekce a od 0,7 ‰ do 1,0 ‰ falešné detekce (`experimental_data.txt` řádek 11871 až 12271).




Obr. 2.13: Grafické zobrazení průběhu standardního prahování autoregresivní metody detekce rušení v nahrávce muzikálu



Obr. 2.14: Grafické zobrazení průběhu adaptivního prahování autoregresivní metody detekce rušení v nahrávce muzikálu

Zajímavý výsledek přineslo měření závislosti hodnoty pravdivé detekce na intenzitě rušení. Náhodně bylo vygenerováno 50 impulsů s nulovou variancí a šířkou 30 až 60 vzorků. Algoritmus autoregresivní detekce s řádem AR procesu 8 byl adaptivně prahovaný s šířkou okna 150 vzorků a prahovacím poměrem 4,8. Měření lze dohledat v souboru `experimental_data.txt` na řádcích 37331 až 41547.

Závislost hodnoty pravdivé detekce na intenzitě impulsního rušení




Intenzita rušení nemá na úspěšnost detekce téměř žádný vliv. Zároveň nebyla během měření pozorována změna falešné detekce, ta se po celou dobu pohybovala okolo 0,8 ‰. Na reálných nahrávkách můžeme pozorovat nespornou výhodu adaptivního prahování. Úroveň prahovacího signálu se mění podle lokální hladiny detekčního signálu a je tak možné detekovat i velmi slabé impulsy. To však neplatí v okolí silnějších impulsů, které logicky hladinu prahování ve svém okolí zvednou. Podobně může dojít k ušlé či méně přesné detekci, pokud je více impulsů ve vzájemné blízkosti. Na obrázku 2.14 je mezi druhým a třetím impulsem krátce zvýšená hladina prahování tak, že u druhého impulsu je detekován pouze počáteční impuls.

Na nahrávce muzikálu měla metoda standardního prahování s poměrem prahování 12 falešnou detekci okolo 0,5 ‰, o desetinu promile více než metoda adaptivní při šířce průměrovacího okna 150 vzorků a prahovacím poměrem mezi 4,8. Obě metody měly při měření podobné výsledky pravdivé detekce, okolo 9 %. U nahrávky klavírního tria jsou impulsy výrazné a slabé nahrávka neobsahuje, což činí adaptivní prahování pro tento účel zbytečné. Standardní dosahuje nulové falešné detekce a adaptivní má kromě falešných detekcí nízké procento pravdivých, jelikož jsou impulsy širší než na předchozích nahrávkách. Doba výpočtu pro předem stanovenou nahrávku byla okolo 1,4 sekundy pro pevné a 3 sekundy pro adaptivní prahování.

Obousměrná AR detekce


Obousměrná detekce pomocí AR modelování se zdá být řešením problému s detekcí impulsu v celé jeho délce, avšak opak je pravdou. Nejen že nepřináší žádné zlepšení, ale snižuje přesnost detekce počátku impulsu. Algoritmus by měl fungovat následovně.

Vezmeme poškozený signál a vytvoříme jeho časově inverzní obraz. Na oba signály, původní a obrácený, aplikujeme detekci impulsů stejně jako v předchozí metodě. Následně obrátíme detekční signál obráceného signálu, čímž získáme detekční signál zpětné detekce. Oba detekční signály sečteme vydělíme dvěma.




Obr. 2.15: Grafické zobrazení průběhu jednosměrné autoregresivní detekce obráceného signálu

Na obrázku 2.15 je průběh jednosměrné autoregresivní detekce na časově obráceném signálu. Je patrné že rušení v tomto směru nabývá na intenzitě postupně, a tak tedy i další odhadované hodnoty mají charakter rušení, a tudíž je rozdíl mezi poškozeným signálem a jeho modelem minimální, prahováním nezachytitelný. Naopak velký rozdíl způsobí přechod z impulsu na nepoškozený signál. Průběh obousměrné detekce pak může vypadat následovně.




Obr. 2.16: Grafické zobrazení průběhu obousměrné autoregresivní detekce

U uměle tvořených impulsů a nahrávek muzikálu a *capercaille* nepřináší tato technika kvůli charakteru impulsů žádné zlepšení detekce. Avšak nahrávka klavírního tria obsahuje impulsy, které mají odlišný charakter. Kromě počátečního impulsu je na konci poškozené oblasti ještě jeden impuls, za kterým je již poškození minimální. Měření (**experimental_data.txt** řádek 13224 až 13464) proběhlo pomocí jednosměrné a obousměrné AR detekce s pevným, standardním prahováním.



Obr. 2.17: Grafické zobrazení obousměrné autoregresivní detekce impulsu




Obr. 2.18: Grafické zobrazení průběhu jednosměrné autoregresivní detekce impulsu

Obousměrná detekce měla sice 0,2 ‰ falešné detekce oproti nulové falešné detekci jednosměrné, ale pravdivou detekci měla více než dvakrát vyšší, okolo 64 %. Doba výpočtu pro předem stanovenou nahrávku byla okolo 2,23 sekundy pro pevné a 4 sekundy pro adaptivní prahování.

2.6 Detekce pomocí ARMA modelování signálu

Poslední implementovaná metoda provádí detekci podle výrazu (1.13). K realizaci byla využita kombinace funkcí `arma()`, `estimate()` a `infer()`. První slouží k vytvoření objektu obsahujícím parametry modelu, mimo jiné řád autoregresivního procesu, řád moving-average procesu a jeho rozdělení, v našem případě standardní Gausovské rozdělení. Následuje estimace signálu pomocí vytvořeného objektu funkcí `estimate()`. Pro odhad parametrů obou procesů využívá lineární predikce, konkrétně metodu nejmenších čtverců. Následně je vyvolán rozdíl mezi sledovaným signálem a jeho estimací, detekční signál.



Obr. 2.19: Grafické zobrazení průběhu detekce pomocí ARMA estimace signálu

Jelikož nastavení tohoto algoritmu obsahuje dost argumentů, nebudou zde podány konkrétní hodnoty, ty je možné dohledat v dokumentu s výsledky měření (`experimentnal_data.txt` na řádcích 13620 až 14278). Při testování na nahrávce s umělými impulsy vycházela lépe metoda pevného prahování s falešnou detekcí okolo poloviny promile a pravdivou detekcí mezi dvaceti až třiceti procenty, někdy i více. Moving-average proces představuje do tvorby detekčního signálu hodně náhodnosti a tudíž se charakter detekčního signálu měnil nejvíce ze všech metod. Adaptivní metoda prahování vycházela na tomto materiálu hůře, jak ve falešné detekci tak v pravdivé. Pro nastavení adaptivního prahování zde platí podobná pravidla jako u autoregresivní metody.

Následující měření jsou zaznamenána v již zmiňovaném dokumentu na řádcích 14312 až 15159. Nastavení AR procesu a prahování byla, kromě poměru pevného prahování, pro jednotlivé nahrávky použita stejná, jako při vyhodnocování AR metody. Díky tomu budeme moci pozorovat přínos MA procesu. Jeho řád je nastaven jako poloviční řádu AR. Na nahrávce klavírního tria se opět jevila jako lepší varianta pevná metoda prahování. U nahrávky muzikálu bylo u standardního prahování dosaženo 8 % pravdivé detekce při 0,3 ‰ falešné detekce, o dvě desetiny promile méně než u AR metody. Adaptivní prahování při stejné úrovni falešné detekce, konkrétně 0,5 ‰, dosáhla 12,5 % pravdivé detekce, oproti AR metodě jde o znatelné zlepšení. U nahrávky *capercaille* bylo při nastavení řádu AR procesu na 4 a řádu MA procesu na 2 dosaženo adaptivním prahováním okna délky 150 vzorků a prahovacího poměru 4,8 falešné detekce 0,4 ‰ a pravdivé detekce 12,5 %.

Tato metoda je ze všech porovnávaných výpočetně nejnáročnější. Porovnávací

nahrávka byla při řádu AR procesu 4 a řádu MA procesu 2 zpracována přibližně za 23 sekund, metoda prahování zde dělala rozdíl necelé sekundy. Výpočetní náročnost, při řádech 8 a 4 dokonce 280 sekund.

Závěr

V práci byly představeny způsoby detekce impulsního rušení v audiosignálu. Nejprve byly testovány na uměle vytvořených impulsech superponovaných na nepoškozenou nahrávku, kde bylo možné přesně měřit přesnost metody. Následně byly metody aplikovány na tři různé nahrávky obsahující reálné impulsní zkreslení. Impulsy v těchto nahrávkách byly označeny ručně s jistou nepřesností.

První představená metoda, metoda diferenční, má vcelku dobré výsledky na reálných nahrávkách ale zároveň vysoké hodnoty falešné detekce. Nedokáže si příliš poradit s nahrávkami perkusivních a žesťových nástrojů. Na druhou stranu je velmi snadno implementovatelná, samotná detekce nemá žádné vstupní parametry, a velmi rychlá. Její vhodnější aplikací je detekce uvedená jako detekce pomocí filtrování horní propustí. V původním dokumentu [2] je filtrování provedeno pomocí difference signálu, podobně jako v předchozí metodě a doplněné o algoritmus upravující detekční signál a vytvářející přepínací signál. Prahování je zde provedeno vlastním způsobem a to pomocí nastavení hodnoty prahování rekursivním medianovým filtrem detekčního signálu. Při implementaci je využita funkce dávající možnost určit stupeň derivace. Testováním však bylo zjištěno, že ideální je druhá difference, jak doporučovali autoři. Tato metoda má lepší výsledky než předchozí, avšak díky svému elementárnímu principu trpí stejnými problémy. Nižší podíl falešné detekce oproti předchozí metodě je vyvážen třikrát vyšší výpočetní náročností. Pro porovnání byla vytvořena metoda filtrující poškozený signál filtrem typu horní propust. Vyfiltrovaný signál je následně upraven RMS filtrem a prahován adaptivním prahováním. Nabízí mnohem flexibilnější nastavení. Její předností oproti předchozímu přístupu je lepší schopnost zachytit oscilační dozívání impulsů s harmonickým průběhem dokmitu. Nedošlo však ke zlepšení podílu falešných detekcí. Na druhou stranu je méně výpočetně náročná. Doposud zmíněné metody jsou výpočetně nenáročné ale jejich úspěšnost je příliš závislá na charakteru zpracovávaného signálu.

Zbylé metody stojí na principu predikce sledovaného signálu. První dvě pomocí autoregresivního modelování, poslední pomocí ARMA modelování. V přechodích aplikacích nebylo vůbec praktické využívat standartního prahování. U těchto metod nezpůsobuje hra perkusivních nástrojů takové změny v úrovni detekčního signálu a také jsou mnohem citlivější na detekci slabých impulsů, jak jsme se přesvědčili při měření závislosti pravdivé detekce jednosměrné autoregresivní metody na intenzitě impulsů. Oproti jednodušším metodám nebyly tyto tolik schopny zachytit celý průběh impulsu včetně oscilačního dokmitu což se projevilo v nižším podílu pravdivé detekce. Obousměrná detekce nebyla u většiny nahrávek lepší než jednosměrná, avšak výrazné zlepšení přinesla při detekování impulsů v nahrávce klavírního tria, kde měly impulsy výrazně odlišný charakter. Výpočetní náročnost prvních dvou me-

tod byla srovnatelná s diferenciálními metodami a spolu s nimi by bylo možné je využít při zpracování audiosignálu v reálném čase. U autoregresivní metody by však nastala potíž s estimací koeficientů. Kvůli výpočtu kovariančních matic výpočetní náročnost narůstá s délkou signálu, a bylo by tudíž potřeba estimovat koeficienty na kratších částech materiálu a postupně je aktualizovat. Nárůst výpočetní náročnosti s délkou materiálu je obzvlášť znát u poslední testované metody. U té by již silně záviselo na hardwaru zařízení. Na druhou stranu je tato metoda velmi flexibilní a množství parametrů ji dovoluje se přizpůsobit různým hudebním žánrům. Oproti čistě autoregresivní metodě vykazuje zlepšení jak v minimalizaci falešné detekce, tak ve zvýšení detekce pravdivé.

Literatura

- [1] H. T. De Carvalho, F. R. Avila and L. W. P. Biscainho, *Bayesian Restoration of Audio Degraded by Low-Frequency Pulses Modeled via Gaussian Process*, IEEE Journal of Selected Topics in Signal Processing, doi: 10.1109/JSTSP.2020.3033410.
- [2] T. Kasparis and J. Lane, *Adaptive scratch noise filtering*, in IEEE Transactions on Consumer Electronics, vol. 39, no. 4, pp. 917-922, Nov. 1993, doi: 10.1109/30.267417.
- [3] David Middleton, *An Introduction to Statistical Communication Theory*, in An Introduction to Statistical Communication Theory: An IEEE Press Classic Reissue, IEEE, 1996, pp.1-1, doi: 10.1109/9780470544112.part1.
- [4] Laurent Oudre, Automatic Detection and Removal of Impulsive Noise in Audio Signals, in Image Processing On Line, 5 (2015), pp. 267–281. <http://dx.doi.org/10.5201/ipol.2015.64>
- [5] M. Niedzwiecki and M. Ciolek, *Elimination of Impulsive Disturbances From Archive Audio Signals Using Bidirectional Processing*, in IEEE Transactions on Audio, Speech, and Language Processing, vol. 21, no. 5, pp. 1046-1059, May 2013, doi: 10.1109/TASL.2013.2244090.
- [6] S. Zoican, *Audio signals noise removal real time system*, 2010 8th International Conference on Communications, Bucharest, 2010, pp. 25-28, doi: 10.1109/ICCOMM.2010.5509098.
- [7] I. Kauppinen, *Methods for detecting impulsive noise in speech and audio signals*, 2002 14th International Conference on Digital Signal Processing Proceedings. DSP 2002 (Cat. No.02TH8628) Santorini, Greece, 2002, pp. 967-970 vol.2, doi: 10.1109/ICDSP.2002.1028251.
- [8] S. Ganapathy, S. Thomas, P. Motlicek and H. Hermansky, *Applications of signal analysis using autoregressive models for amplitude modulation*, 2009 IEEE Workshop on Applications of Signal Processing to Audio and Acoustics, New Paltz, NY, 2009, pp. 341-344, doi: 10.1109/ASPAA.2009.5346495.
- [9] R. Badeau and B. David, *Weighted maximum likelihood autoregressive and moving average spectrum modeling*, 2008 IEEE International Conference on Acoustics, Speech and Signal Processing, Las Vegas, NV, 2008, pp. 3761-3764, doi: 10.1109/ICASSP.2008.4518471.

- [10] C. W. Therrien, *Some observations about centralized linear prediction*, Conference Record of the Thirty-Third Asilomar Conference on Signals, Systems, and Computers (Cat. No.CH37020), Pacific Grove, CA, USA, 1999, pp. 466-469 vol.1, doi: 10.1109/ACSSC.1999.832373.
- [11] G. W. Milne, *Response of the ordinary least squares estimator (OLS) to deterministic and stochastic noise*, IEEE. AFRICON '96, Stellenbosch, South Africa, 1996, pp. 1099-1104 vol.2, doi: 10.1109/FRCON.1996.563053.
- [12] C. E. Davila, *On the noise-compensated Yule-Walker equations*, IEEE Transactions on Signal Processing, vol. 49, no. 6, pp. 1119-1121, June 2001, doi: 10.1109/78.923293.
- [13] A. Mahmoudi and M. Karimi, *Parameter estimation of noisy autoregressive signals*, 2010 18th Iranian Conference on Electrical Engineering, Isfahan, 2010, pp. 145-149, doi: 10.1109/IRANIANCEE.2010.5507084.
- [14] Ning Zhou and J. W. Pierre, *Estimation of autoregressive parameters by the constrained total least square algorithm using a bootstrap method*, (ICASSP '05). IEEE International Conference on Acoustics, Speech, and Signal Processing, 2005., Philadelphia, PA, 2005, pp. iv/417-iv/420 Vol. 4, doi: 10.1109/ICASSP.2005.1416034.
- [15] Y. Xia and M. S. Kamel, *A Generalized Least Absolute Deviation Method for Parameter Estimation of Autoregressive Signals*, in IEEE Transactions on Neural Networks, vol. 19, no. 1, pp. 107-118, Jan. 2008, doi: 10.1109/TNN.2007.902962.
- [16] Z. Mei, Z. Chenghui, Z. Huanshui, C. Peng and Du Yanchun, *Robust Least Square Method and Its Application to Parameter Estimation*, 2007 IEEE International Conference on Automation and Logistics, Jinan, 2007, pp. 1483-1486, doi: 10.1109/ICAL.2007.4338805.
- [17] H. Tong, *Autoregressive model fitting with noisy data by Akaike's information criterion*, IEEE Trans. Inf. Theory, vol. IT-21, no. 4, pp. 476-480, Jul. 1975
- [18] G. Turin, *An introduction to matched filters*, IRE Transactions on Information Theory, vol. 6, no. 3, pp. 311-329, June 1960, doi: 10.1109/TIT.1960.1057571.
- [19] F. R. Avila and L. W. P. Biscainho, *Bayesian Restoration of Audio Signals Degraded by Impulsive Noise Modeled as Individual Pulses*, in IEEE Transactions on Audio, Speech, and Language Processing, vol. 20, no. 9, pp. 2470-2481, Nov. 2012, doi: 10.1109/TASL.2012.2203811.

- [20] S. J. Godsill and P. J. W. Rayner, *Robust noise modelling with application to audio restoration*, 1995 Workshop on Applications of Signal Processing to Audio and Acoustics, New Paltz, NY, USA, 1995, pp. 143-146, doi: 10.1109/ASPAA.1995.482977.
- [21] S. J. Godsill and P. J. W. Rayner, *A Bayesian approach to the restoration of degraded audio signals*, in IEEE Transactions on Speech and Audio Processing, vol. 3, no. 4, pp. 267-278, July 1995, doi: 10.1109/89.397091.
- [22] S. J. Godsill and P. J. W. Rayner, *A Bayesian approach to the detection and correction of error bursts in audio signals*, ICASSP-92: 1992 IEEE International Conference on Acoustics, Speech, and Signal Processing, 1992, pp. 261-264 vol.2, doi: 10.1109/ICASSP.1992.226070.
- [23] J. Makhoul, *Linear prediction: A tutorial review*, in Proceedings of the IEEE, vol. 63, no. 4, pp. 561-580, April 1975, doi: 10.1109/PROC.1975.9792.
- [24] Simon J. Godsill and Peter J.W. Rayner, *Digital Audio Restoration - a statistical model based approach*, September 1998, DOI:10.1007/0-306-47042-x₄.
- [25] Verlet, L., "*Computer "Experiments" on Classical Fluids. I. Thermodynamical Properties of Lennard-Jones Molecules*", *Physical Review*, vol. 159, no. 1, pp. 98-103, 1967. doi:10.1103/PhysRev.159.98.
- [26] Yule, G. Udny *On a Method of Investigating Periodicities in Disturbed Series, with Special Reference to Wolfer's Sunspot Numbers*, 1927, Philosophical Transactions of the Royal Society of London, Ser. A, Vol. 226, 267-298.
- [27] Walker, Gilbert *On Periodicity in Series of Related Terms*, 1931, Proceedings of the Royal Society of London, Ser. A, Vol. 131, 518-532.
- [28] Burg, J. P. *A new analysis technique for time series data*, 1968, In Modern Spectrum Analysis (Edited by D. G. Childers), NATO Advanced Study Institute of Signal Processing with emphasis on Underwater Acoustics. IEEE Press, New York.

Seznam symbolů, veličin a zkratek

AR	autoregresivní model
MA	moving-average model
ARMA	autoregresivní moving-average model
RMS	Kvadratický průměr
$\text{med}\{\}$	median
μ	střední hodnota
x_n	poškozený signál
s_n	užitečný signál
w_n	spínaný impulsní rušivý signál
i_n	přepínací signál
v_n	impulsní rušivý signál
e_n	bílý šum
d_n	detekční signál

A Přílohy

Použitá nahrávky:

Obě nahrávky byly získány z webové stránky:

<https://freesound.org>

Nahrávky jsou pod CC 3.0 licencí, volně k použití, úpravě a distribuci. Zdrojový

kód:

Názvy proměnných jsou ve zdrojovém kóde psány v anglickém jazyce, komentáře jsou v češtině. Kód byl psán v prostředí Matlab verze R2019b.

Kód se sestává z následujících souborů:

- `impulse_detection.m`:
Hlavní skript, ve kterém probíhá načítání audiostopy, generování impulsů, detekce a tisk výsledných průběhů
- `gen_wn_imp.m`:
Funkce na generování impulsu s náhodnými hodnotami
- `gen_harmonic_imp.m`:
Funkce na generování impulsu pomocí harmonické funkce
- `add_impulse.m`:
Funkce na přičtení impulsu do signálu na určitém místě
- `deriv_detection.m`:
Funkce na tvorbu detekčního signálu pomocí diferenciací signálu
- `hp_filter_deriv_detection.m`:
Funkce na tvorbu detekčního i přepínacího signálu pomocí derivační filtrace
- `hp_filter_detection.m`:
Funkce na tvorbu detekčního signálu pomocí filtrace signálu funkcí `filter()`
- `AR_detection.m`:
Funkce na tvorbu jednosměrného detekčního signálu pomocí autoregresivního modelování signálu
- `AR_detection_bidir.m`:
Funkce na tvorbu obousměrného detekčního signálu pomocí autoregresivního modelování signálu
- `ARIMA_detection.m`:
Funkce na naplnění detekčního signálu pomocí ARMA modelování signálu.
- `thresholding.m`:
Funkce na tvorbu přepínacího signálu pomocí pevného prahování
- `adaptive_thresholding.m`:
Funkce na tvorbu přepínacího signálu pomocí adaptivního prahování
- `av_maximum.m`:

Funkce na výpočet průměrné maximální hodnoty signálu

- `experimental_data.txt`

Textový soubor obsahující informace o jednotlivých měření spolu s daty generovanými funkcí `evaluate.m`

- `measures.txt`

Textový soubor obsahující data měření zkoumající důsledky nastavení parametrů

- `measurements.xlsx`

Soubor aplikace excel obsahující data měření staticky zpracovaná tabulkovým editorem