



**ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE**

**FAKULTA ELEKTROTECHNICKÁ**

Katedra radioelektroniky

**Detekce impulzních vad v záznamu zvuku na gramofonových deskách**

**Detection of Impulse Noise in Gramophone Records**

Bakalářská práce

Studijní program: Komunikace, multimédia a elektronika

Studijní obor: Multimediální technika

Vedoucí práce: Ing. František Rund, Ph.D.

**Marek Semanský**

**Praha 2017**



## I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Semanský** Jméno: **Marek** Osobní číslo: **434696**  
Fakulta/ústav: **Fakulta elektrotechnická**  
Zadávající katedra/ústav: **Katedra radioelektroniky**  
Studijní program: **Komunikace, multimédia a elektronika**  
Studijní obor: **Multimediální technika**

## II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

**Detekce impulzních vad v záznamu zvuku na gramofonových deskách**

Název bakalářské práce anglicky:

**Detection of Impulse Noise in Gramophone Records**

Pokyny pro vypracování:

Seznamte se s impulzními vadami mechanického záznamu které vznikají během výrobního procesu. Studujte algoritmy detekce uvedených vad. Metody detekce, implementované v [1], verifikujte na základě poslechových testů slyšitelnosti těchto vad. Navrhněte možná vylepšení jedné z metod, implementujte je a ověřte.

Seznam doporučené literatury:

[1] BOLEK, M. Detekce vad u mechanického záznamu zvuku. Praha: ČVUT 2016. Diplomová práce, ČVUT, Fakulta elektrotechnická, katedra radioelektroniky  
[2] GODSILL, S, RAYNER, P. Digital Audio Restoration. Springer-Verlag, London, 1998.

Jméno a pracoviště vedoucí(ho) bakalářské práce:

**Ing. František Rund Ph.D., katedra radioelektroniky FEL**

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

Datum zadání bakalářské práce: **13.02.2017** Termín odevzdání bakalářské práce: **26.05.2017**

Platnost zadání bakalářské práce: **31.08.2018**

\_\_\_\_\_  
Podpis vedoucí(ho) práce

\_\_\_\_\_  
Podpis vedoucí(ho) ústavu/katedry

\_\_\_\_\_  
Podpis děkana(ky)

## III. PŘEVZETÍ ZADÁNÍ

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

\_\_\_\_\_  
Datum převzetí zadání

\_\_\_\_\_  
Podpis studenta



## Poděkování

Chtěl bych poděkovat svému vedoucímu práce Ing. Františkovi Rundovi, Ph.D., a panu Ing. Václavu Vencovskému, Ph.D., za cenné rady a kritiku při tvorbě této práce.

Děkuji také firmě GZ Media, a.s. za poskytnutí informací a dat potřebných k realizaci této práce.



## Prohlášení

Prohlašuji, že jsem předloženou práci vypracoval samostatně a že jsem uvedl veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

V Praze dne .....

Podpis studenta .....





## Abstrakt

Tato práce se zabývá problematikou detekce impulsních vad u mechanického záznamu zvuku. V práci jsou představeny tři detekční metody, které byly převzaty z diplomové práce Ing. M. Bolka (2016). Jedná se o autoregresivní metodu, rozšíření této metody o matched filtr a metodu vlnkové transformace. Metody jsou aplikovány na poškozené vzorky získané z reálných desek a na vzorky s namodelovanými clicky, které byly vytvořeny v rámci této práce. Součástí práce bylo provedení poslechových testů na testovaných vzorcích z důvodu získání objektivního kritéria pro vyhodnocení výsledků detekce. V této práci je zkoumán vliv jednotlivých parametrů detekčních algoritmů na jejich efektivitu. V závěru je navrženo a implementováno vylepšení jedné z metod, které zaručuje lepší výsledky detekce. Testování detekčních metod provedené v této práci ukazuje, že nejlepší výsledky bylo dosaženo pomocí metody založené na vlnkové transformaci a vyvrací korektnost aplikace detekčních metod popsaných v DP Ing. M. Bolka, kde byly výsledky podstatně horší.

## Klíčová slova

gramofonové desky, impulsní šum, click, autoregrese, vlnková transformace, Matlab

## Abstract

This thesis deals with impulse noise detection in mechanical sound recording. There are three detection methods presented in this paper, which were adopted from M. Bolek's master's thesis (2016). The methods specifically are an autoregressive model, its extension with matched filter and a wavelet transform model. These detection algorithms are applied to a set of corrupted samples retrieved from real gramophone records and a set of samples with modelled impulse degradations. A part of this paper describes subjective listening tests conducted on all the tested samples. Due to these listening tests an objective criteria for evaluating the results was created. This thesis analyses the impact of separate detection method parameters on the effectiveness of the detection. An improvement of one of the methods which provides better efficiency of impulse noise detection is suggested and implemented in the final part. The tests conducted in this paper prove that detection method based on wavelet transform provides the best results. They also disprove the implication correctness of the detection methods presented in Mr. Bolek's thesis, where the detection results were considerably worse.

## Key words

gramophone records, impulse noise, click, autoregression, wavelet transform, Matlab



# Obsah

1 Úvod.....	12
2 Mechanický záznam zvuku.....	13
2.1 Vady gramodesek.....	14
2.1.1 Impulsní vady .....	14
3 Detekce impulsních vad .....	16
3.1 Metoda AR modelu .....	16
3.2 Metoda matched filtru.....	17
3.3 Metoda vlnkové transformace.....	18
4 Zvukové vzorky použité pro testování .....	19
4.3 Subjektivní poslechové testy.....	20
5 Implementace .....	21
6 Testování a výsledky .....	22
6.1 Testování AR modelu .....	24
6.1.1 Experimentální výsledky pro AR model .....	24
6.2 Testování matched filtru .....	28
6.2.1 Experimentální výsledky pro matched filtr .....	28
6.3 Testování metody vlnkové transformace .....	31
6.3.1 Experimentální výsledky pro metodu vlnkové transformace .....	31
6.4 Vyhodnocení výsledků .....	34
7 Vylepšení detekce pomocí vlnkové transformace .....	35
8 Závěr.....	37
Literatura .....	38
Příloha A: Popis funkcí implementovaných v prostředí Matlab .....	39
Příloha B: Obsah přiloženého CD .....	40


# 1 Úvod

Tato práce se věnuje problematice impulsních vad na gramofonových deskách, které se při poslechu projevují nežádoucími lupanci a praskáním. Tyto vady mohou vznikat již při výrobním procesu gramodesek a je velice důležité, aby nevznikaly na všech kopiích, a proto je podstatné je včas detekovat. V praxi se jejich detekce provádí poslechovým testem desek na konci výrobního procesu. Existují však metody jak impulsní šum detekovat pomocí výpočetní techniky, které se využívají například v algoritmech pro opravu poškozených záznamů. Některé z těchto metod byly popsány a implementovány v [1] v prostředí Matlab. Cílem této práce je otestovat tyto metody se zaměřením na slyšitelné impulsní vady, zjistit vliv parametrů jednotlivých metod na jejich výsledky a doporučit možné vylepšení jedné z metod. Dalším cílem je porovnat výsledky s [1] a verifikovat správnou implementaci algoritmů.

Prvním krokem práce je zajištění hudebních vzorků, na kterých budou algoritmy testovány. První sada vzorků je získána z reálných gramodesek poškozených impulsním šumem. Z bezvadných masterů obsahujících hudební záznam byly vystřiženy vzorky druhé sady, do nichž byl namodelován impulsní šum. Druhým krokem je získání objektivního kritéria pro vyhodnocení. Tímto kritériem byly výsledky subjektivních poslechových testů provedených na výše popsaných dvou sadách vzorků, které poskytují informaci o akustickém projevu impulsních vad. Třetím krokem je rozšíření tří detekčních algoritmů převzatých z [1] o algoritmy pro práci s výsledky poslechových testů a vyhodnocení detekce v závislosti na těchto testech. Předposlední kapitolou práce je testování detekčních metod v závislosti na změně jejich parametrů, vyhodnocení výsledků a verifikace implementace metod v [1]. Poslední část se zabývá návrhem a implementací vylepšení jedné z metod.

## 2 Mechanický záznam zvuku

Technologie mechanického záznamu zvuku spočívá v deformaci záznamového materiálu řezacím nožem, který je vychylován ze své osy v závislosti na vstupním signálu – zaznamenávaném zvuku. Signál je přiváděn do elektromechanického měniče, tzv. řezací hlavy, ve které je nůž upevněn. Řezací hlava se může pohybovat kolmo na desku nebo rovnoběžně s deskou. Při kolmém pohybu se jedná o tzv. hloubkový záznam. Při pohybu rovnoběžném s deskou se jedná o stranový záznam. Řezací hlava pro stranový záznam může obsahovat dvě navzájem kolmé cívkky, čímž je umožněno zaznamenávat stereo signál. Princip je zobrazen na obr. 2.1. Řezací nůž se pohybuje po kruhové desce podél jejího kraje a postupně se přibližuje ke středu desky a tak vytvoří spirálovitou drážku. Pravý kanál je zaznamenán na straně drážky blíže k okraji desky.



Obrázek 2.1: Stereofonní záznam zvuku [7]

Takto vyřezané desce se říká master. Master se dříve vyráběl řezáním vyhřívaným nožem do vrstvy laku na desce. Z masteru se následně vytvoří negativ (matrice), který má drážky vystupující. Pro vytvoření matrice se využívá tří kroků galvanického pokovování [6]. Matrice se poté využívá jako razítko, na které se přitiskne vinylová hmota, která má po vylisování podobu finální desky. Nyní se využívá modernější metody Direct Metal Mastering (DMM) [4]. Tato metoda umožňuje řezání diamantovým nožem přímo do kovové vrstvy. Mezi výhody DMM patří např. lepší reprodukce vyšších frekvencí a menší šum v pozadí. Negativ se následně vyrobí pomocí jednoho kroku galvanického pokovování. Galvanické pokovování spočívá v pokrytí matrice vrstvou stříbra (u DMM není třeba), které vytvoří vodivý povrch. Následně se deska vloží do niklové lázně, kde se na stříbro za průchodu elektrického proudu naváže vrstva niklu, které kopíruje master.

Zvuk se z desek snímá pomocí takzvané jehly. Tato jehla se pohybuje v drážce desky, kterou kopíruje a svůj pohyb přenáší do přenosky. Přenoska je měnič, který na svých svorkách vytváří elektrické napětí závislé na výchylce jehly. Nejčastěji funguje na piezoelektrickém, elektrodynamickém nebo elektromagnetickém principu. Stereofonní přenoska ke snímání desky využívá jedné jehly, která řídí dva měniče.

## 2.1 Vady gramodesek

Výroba gramodesek je komplexní záležitost, která vyžaduje preciznost v každém svém kroku. V případě, že jeden krok výroby není proveden dokonale, může to ovlivnit kvalitu jedné desky, ale i stovek desek. Jeden z nejhorších případů je chyba při výrobě masteru nebo negativu. Na kvalitě těchto dvou desek je závislá kvalita stovek až tisíců dalších. Příkladem takové chyby je například poškrábaná matrice. Každá další deska z ní vylisovaná bude kopírovat škrábanec, který se projeví jako akustické rušení.

Vady gramodesek, které mají akustický projev, se dají rozdělit na dvě skupiny. Širokopásmový šum a impulsní šum. Širokopásmový šum se často vyskytuje na celé nahrávce. Nejvíce rušivý je na začátku a konci desky a v místech, kde má zvuk menší amplitudu. V této práci se budu zabývat druhým typem šumu. Impulsní šum, jehož akustický projev se označuje jako „click“, je všeobecně známou vadou gramodesek. Jedná se o krátkodobé, lokální akustické rušení v podobě lupance či praskotu.

### 2.1.1 Impulsní vady

Tato práce se zabývá algoritmy určenými k detekci impulsního šumu. Click je obecně známé akustické rušení, které se projevuje pouze v řádu milisekund. Nedegraduje tedy celou nahrávku, ale jen její krátký úsek. Jednou z vlastností clicků je jejich ploché spektrum. Všechny frekvence jsou ve spektru tedy zastoupeny zhruba rovnoměrně.

Click může vzniknout mnoha způsoby. Typickým důvodem tohoto rušení je škrábanec na desce nebo na její matrici zobrazený na obrázku 2.2. Intenzita praskotu je závislá na hloubce škrábnutí. V případě, že je škrábanec hodně jemný, nemusí mít ani akustický projev. Dalším důvodem vzniku impulsní vady je usazená nečistota v drážce. Nečistota se do drážky může dostat již při výrobě v lisovně. Vinylová hmota poté okopíruje usazeninu a při poslechu se projeví clickem. Příčin je samozřejmě podstatně více. Některé z nich jsou popsány v tabulce 2.1, jejíž obsah byl převzat z materiálů dodaných firmou GZ Media, a.s.

V případě stereofonní gramodesky se ve většině případů projevuje click v obou kanálech. Jeden z mála případů vzniku clicku pouze v jednom kanále je nedolisování desky. Vinylová hmota se na matrici natlačí a obtiskne se. Může se ale stát, že se mezi hmotou a matricí objeví vzduchová bublina nebo se hmota k matrici pořádně nepřitlačí. I touto chybou jsou většinou ovlivněny oba kanály, ačkoliv jeden (většinou levý) výrazně méně. Tento případ je zobrazen na obrázku 2.3.



Obrázek 2.2: Poškrábaná deska [3]



Obrázek 2.3: Příklad nedolisované desky [3]

Tabulka 2.1: Příklady impulsních vad (upraveno z [3])

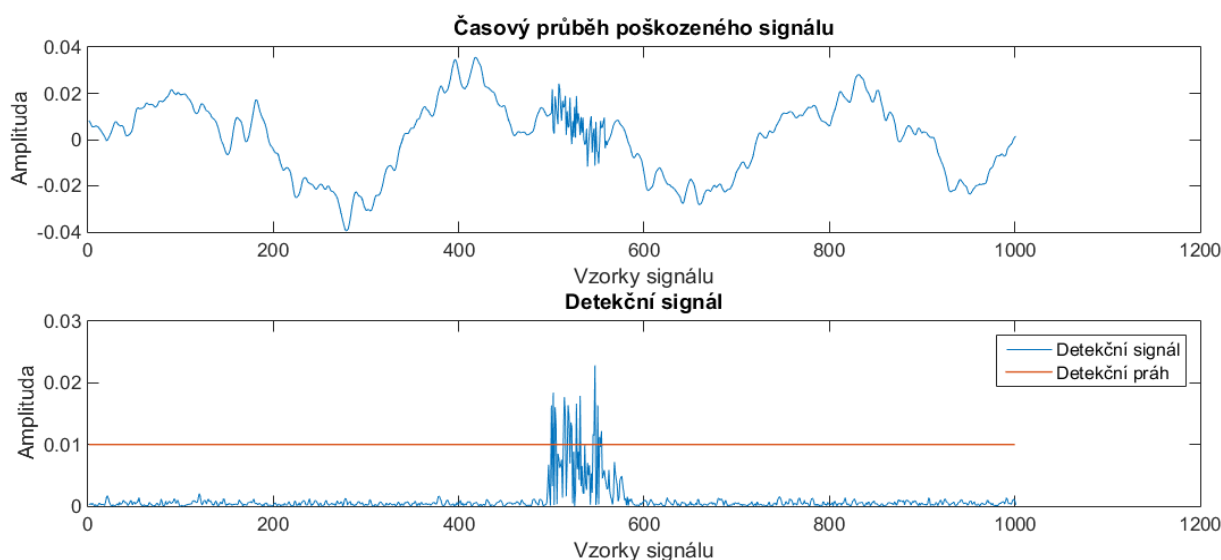
Lupanec/narážka	Obecná porucha, která se projevuje lupancem. Jeho intenzita je různá. Důvodem této poruchy může být: elektrostatický lupanec, nečistota v drážce, prořez, přeskok, škrábanec a dokonce i chyba v podkladu od zákazníka.
Praskot	Posloupnost lupanců s různou intenzitou. Praskot může být způsoben jak poruchami z galvanoplastiky, tak i kvůli poruchám z lisování.
Škrábanec	Na desce můžeme pozorovat čáru (úsečku), která je umístěna přes záznam. Pokud škrábanec zasahuje do dna drážky, tak se může projevit jako lupanec na otáčku. V případě mělkého škrábance (nepoškození drážky), který poškodí pouze zrcátko, se může projevovat jen jako optická vada. Pod mikroskopem pak můžeme pozorovat, jestli je škrábanec na negativu nebo pozitivu. Je velký rozdíl mezi škrábanecem na matrici nebo jen na desce. V případě škrábance na matrici, je touto vadou zatížena veškerá výroba, která byla vyrobena z dané matrice.
Nečistota v drážce	Cizí částice, která je umístěna v drážce. Přenoska do ní narazí a dojde k akustickému projevu. Rozlišujeme dva typy nečistot. První nečistota je taková, která po přehrání přenoskou zmizí. Přenoska jí vytlačí z drážky pryč. Druhý typ nečistoty je takový, že nečistota zůstane v drážce i po přejetí daného místa. Zde se jedná o nečistotu, která je zalisována v drážce.
Škráblá matrice	Při škrábnutí desky můžeme mít štěstí, že se poškodí pouze zrcátko a deska se pak nebude projevovat lupancem na otáčku. U škrábnuté matrice takové štěstí již nemáme. Matrice je totiž negativ a jakýkoliv škrábanec poškodí výstupky, z kterých jsou po vylisování dna drážek. Důsledkem toho pak vznikají různé vady, jako jsou například lupance na otáčku, samostatný lupanec a praskot. Tato vada je způsobena především špatnou manipulací s matricí.
Nedolisy	Tato vada se především projevuje rušivým praskáním v jednom kanálu (v pravém kanálu). Nedolisy jsou fyzicky umístěny v závětrí hran matrice. Ve většině případů je vada umístěna přes několik drážek a praskání tak můžeme slyšet na otáčku. Příčinou je lisování, kde hmota při lisování nedostatečně obteče matrici. Tento problém se obvykle objevuje ke konci stran. Opticky můžeme nedolisy pozorovat jako shluky bílých teček.
Návalky	Návalky vznikají při řezání do lakových fólií a jsou způsobeny: vlastnostmi lakové vrstvy, tvarem řezacího nože, topením (topení by mělo být nastaveno tak, aby byla drážka hladká) a řezací rychlostí. Důsledkem tohoto jevu při řezání dojde při následném procesu k tomu, že výsledné desky mají na okrajích drážky ostré hrany. Když dojde ke kontaktu s rukou nebo jiným tělesem, tak se návalky rozmažou po zrcátku desky a může tak dojít i k znečištění drážky. Tato vada způsobí nesmazatelnou šmouhu na desce. Dále také může způsobit problémy při technologických procesech v galvanoplastice a drobný praskot.
Smeť	Smeť je vada, která ve svém důsledku vzniká již při přípravě na lisování. Lisařka by měla otřít matrici ze zadní strany a zbavit jí veškerých nečistot. Pokud toto neudělá, tak se v průběhu lisování nečistota tlačí na matrici a ta se poškodí (výstupek na matrici), poté je tato vada již na všech deskách. Samozřejmě i může i nastat, že smet se vytvoří i v průběhu lisování, kdy lis nasaje nečistotu a ta se dostane opět pod matrici. Princip je pak stejný. Na desce jí pak můžeme pozorovat jako malý důlek. Smeť se projevuje zvukem, co obsahuje nízké frekvence (bouchání).

### 3 Detekce impulsních vad

Při detekci vad téměř nejde dosáhnout stoprocentní úspěšnosti a je proto důležité volit správný postup detekce. Největším problémem při detekci vad je nedokonalá znalost hledaných vad a jejich rozmanitost, výběr správné metody pro detekci a zvolení správných parametrů této metody. Již existuje několik způsobů detekce vad, které však mají k dokonalosti daleko. Některé z nich pracují v časovém spektru, jiné ve spektru frekvenčním. Všechny způsoby hledají anomálie v signálu (náhlou změnu amplitudy, spektra apod.) k čemuž využívají známých vlastností signálu. Tato práce navazuje na [1] odkud jsou detekční algoritmy tří níže popsaných metod převzaty a kde je i jejich detailní popis. Následující kapitoly stručně shrnují princip detekčních metod a jejich důležité parametry.

#### 3.1 Metoda AR modelu

AR model, neboli autoregresivní model je metoda detekce vad založená na předpovědi amplitudy následujícího vzorku v závislosti na  $p$  předchozích vzorcích [2]. Počet předchozích vzorků  $p$  použitých pro odhad následujícího se nazývá řád predikce. Poškozený signál, ve kterém jsou chyby detekovány lze rozdělit na bezchybný zvukový signál a chybový signál obsahující pouze impulsní rušení. V ideálním případě funguje autoregresivní model jako filtr, který odstraní clicky. AR model totiž dokáže relativně přesně odhadnout následující vzorek, pouze pokud se v něm nevyskytuje nějaký impulsní šum. Toho je využito při hledání clicku. Informaci o poloze nečekaných částí signálu získáme tedy z rozdílu poškozeného signálu a predikovaného signálu. Tomuto rozdílu se říká detekční signál (někdy značeno jako chyba predikce). Tento signál se skládá z náhodného šumu s relativně nízkou amplitudou (z důvodu nedokonalosti predikce) a z impulsního šumu. Pro určení polohy clicku je nutné správně zvolit detekční práh, tedy konstantu  $k$ , kterou se násobí směrodatná odchylka detekčního signálu. Polohu clicků lze zjistit porovnáním detekčního signálu s detekčním prahem. Místa, ve kterých má detekční signál vyšší amplitudu, než je detekční práh označujeme za vadná. Lepších výsledků detekce lze dosáhnout rozdělením signálů na krátké segmenty, které mají v ideálním případě malý dynamický rozsah.

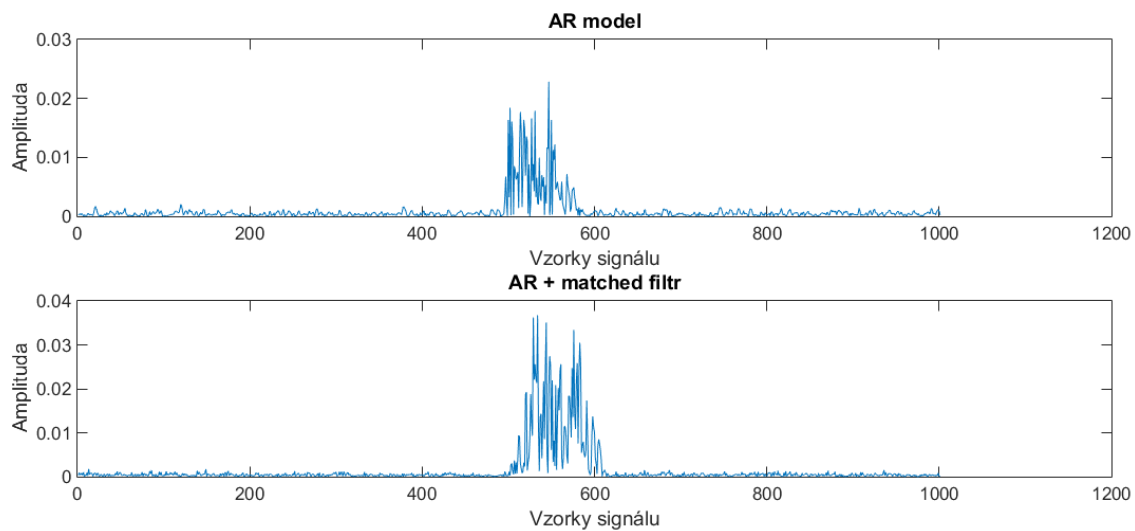


Obrázek 3.1: Poškozený signál (nahore) a detekční signál (dole)



### 3.2 Metoda matched filtru

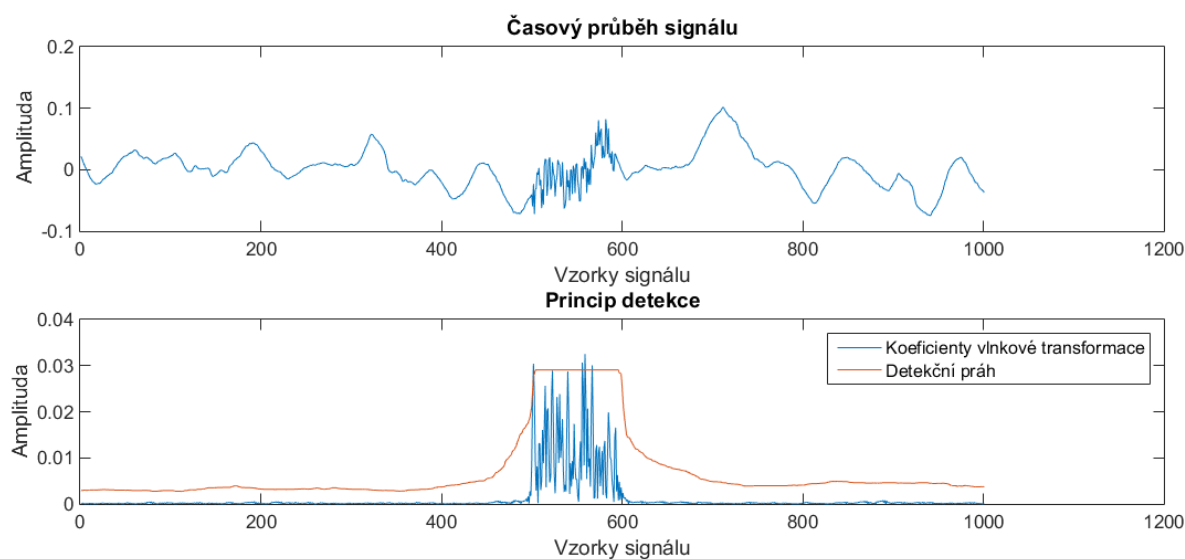
Jednou z metod pro vylepšení autoregresivního modelu je dle [2] použití takzvaného matched filtru. Tento filtr je přizpůsobený (matched) k impulsním vadám a přihlíží k nim jako k signálu samotnému a zbytek dat je vnímán jako širokopásmový šum. Výhodou tohoto filtru je zvýraznění chybných vzorků oproti zbytku signálu. Toho je dosaženo využitím dalšího lineárního filtru, který má obrácenou impulsní odezvu oproti odezvě  $H(z)$  filtru samotného AR modelu. Celý filtr lze dle [2] popsat jako  $H(z)H(z^{-1})$ . Nevýhodou tohoto filtru je ztížené určení polohy impulsní vady. Při rozhodování zda použít samotnou autoregresivní metodu nebo využít přizpůsobeného filtru závisí na dynamickém rozsahu signálu a na amplitudě clicků.



Obrázek 3.2: Porovnání výstupu AR modelu a matched filtru

### 3.3 Metoda vlnkové transformace

Další způsob detekce clicků popsán v [8] je založen na rozkladu signálu pomocí vlnkové transformace. Důležitou vlastností pro tuto metodu je relativně pomalu měnící se spektrální obálka hudebního signálu. Relativně je myšleno oproti clickům. V případě aplikace vlnkové transformace na signál s clicky získáme koeficienty transformace, které se v místech výskytu clicku vyznačují výrazně vyšší amplitudou. K získání informace o poloze clicků je potřeba získat dynamický práh, který se mění v závislosti na hladké obálce koeficientů a zároveň není ovlivněn impulsním šumem. Takový dynamický práh lze získat filtrací vektoru koeficientů vlnkové transformace pomocí mediánového filtru s vhodně zvolenou délkou okna. Dle [8] by měla délka okna  $L_{med}$  splňovat podmínku  $L_{med} > 2K_{max} + 1$ , kde  $K_{max}$  je počet vzorků v nejdelším clicku. Výsledný detekční práh lze získat vynásobením dynamického prahu koeficientů konstantou  $k$ . Důležitým faktorem pro detekci je volba správné vlnky a jejího řádu.



Obrázek 3.3: Časový průběh chybného signálu (nahore) a porovnání koeficientů transformace s detekčním prahem signálu (dole)

## 4 Zvukové vzorky použité pro testování

Jedním z cílů této práce je zjistit vliv jednotlivých parametrů detekčních algoritmů na jejich efektivitu a porovnat výsledky se subjektivními poslechovými testy slyšitelnosti vad. Pro testování byly použity dvě sady devadesáti zvukových vzorků. V této práci se dále pracuje s termíny „první sada“ a „druhá sada“ popřípadě „1. sada“ a „2. sada“ pro označení jednotlivých sad vzorků. První sada byla dodána firmou GZ Media, a.s. Tyto vzorky byly získány z poškozených vinylových desek a digitalizovány do formátu wav. Vzorky obsahují jednu či více impulsních vad. Tyto vady mohou, ale nemusí vytvářet slyšitelné akustické rušení. Každý ze vzorků je dlouhý 800 milisekund, vzorkován frekvencí 44.1 kHz a kvantován 16 bity. Obsah těchto nahrávek jsou hudební i nehupební zvuky (vážná hudba, bubnování, šum apod.). O impulsních vadách v těchto vzorcích nebyly dostupné žádné informace. U některých vzorků se však povedlo lokalizovat click a využít této znalosti při kontrole detekce. Tato kontrola byla implementována ve skriptech `runAnalysisAR_1.m` a `runAnalysisWavelet_1.m`.

Druhá sada vzorků byla vytvořena v rámci této práce. Jedná se o krátké hudební vzorky získané ze tří masterů gramodesek poskytnutých opět firmou GZ Media, a.s. Jelikož se jedná o mastery, je jisté, že se v nich žádné impulsní ani jiné vady nevyskytují. Tyto mastery byly použity jako hudební podklad do kterého bylo možné namodelovat vlastní impulsní vady. Výhodou namodelovaných clicků je známost jejich parametrů. Na rozdíl od první sady vzorků zde známe počet, polohu, amplitudu a délku všech impulsních vad. Jako objektivní kritérium při vyhodnocování výsledků detekčních algoritmů lze tedy použít jak poslechové testy, tak i přesné znalosti vlastností clicků. Tyto vzorky jsou dlouhé 1 sekundu, vzorkovány frekvencí 48 kHz a kvantovány 16 bity.

Tyto tři mastery obsahují nahrávky různých hudebních stylů a nástrojů (bicí, kytary, klávesy apod.). Každý z nich je dlouhý zhruba dvacet minut. V prostředí Matlab byl v rámci této práce navržen algoritmus implementovaný do skriptu `Create_faulty_sounds.m`, který z těchto hudebních souborů náhodně vykrojí úseky o délce 1 sekundy a namodeluje do každého z nich click o náhodné pozici, amplitudě a délce. Podrobný popis tohoto algoritmu je uveden v příloze A. Délka namodelovaných clicků se pohybuje v rozmezí 10 až 100 vzorků. Pro amplitudu byly empiricky zvoleny 4 hladiny (-15dB, -20dB, -25dB, -30dB). Všechny vzorky byly vynásobeny obálkou, která zajistila, že při poslechu nevznikne lupanec na začátku a na konci vzorku z důvodu rychlého nástupu nebo poklesu signálu. Z tohoto důvodu byla pozice clicků omezena na vzorky 1440 až 46560. Amplituda všech vzorků byla normalizována, aby co nejvíce odpovídala první sadě vzorků. Vzorky, které obsahovaly pouze click (byly vystřižené z tiché části mezi písněmi) byly vyměněny za vzorky obsahující hudbu.

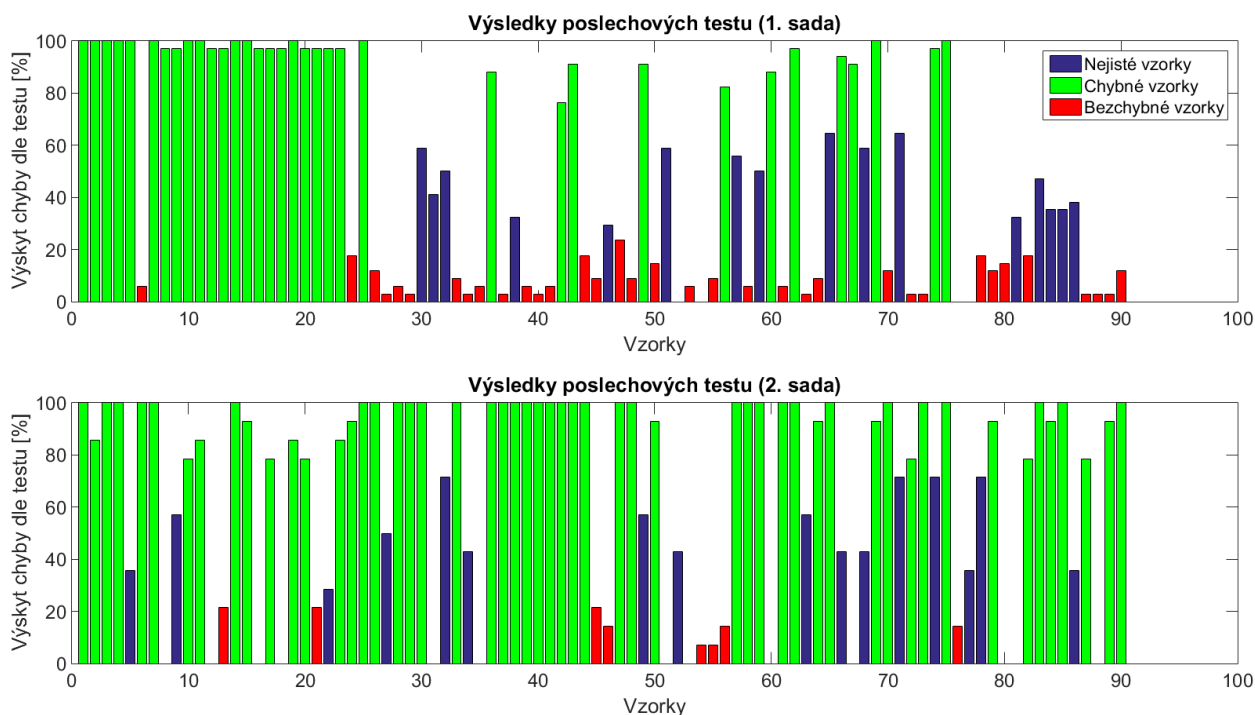
### 4.3 Subjektivní poslechové testy

Subjektivní poslechové testy byly provedeny z důvodu získání objektivního kritéria pro vyhodnocení výsledků detekčních algoritmů. Předpokladem pro získání správných výsledků bylo nutné provést test sluchového ústrojí všech posluchačů. K tomuto účelu byl využit test publikovaný v [11]. Test spočíval v kontrole prahu slyšitelnosti v rozmezí od 250 do 8000 Hz. Veškeré testování probíhalo ve zvukotěsné buňce v laboratoři. Zvuk byl reprodukován pomocí sluchátek Sennheiser HD650. V případě neúspěšného testu sluchu nebyl subjekt puštěn k testům na hudebních vzorcích.

Test první sady vzorků byl proveden již při předchozích studiích a výsledky byly převzaty a využity v této práci. Těchto testů se zúčastnilo sedmáct mužů ve věkovém rozmezí 21 až 47 let (věkový medián 22 let). Každý posluchač provedl testy 2x. Celkem bylo tedy provedeno 34 testů. Testů na druhé sadě se zúčastnilo 14 mužů ve věkovém rozmezí 22 až 33 let s věkovým mediánem 22 let. Na této sadě se testy prováděly pouze jednou.

K testování akustických projevů v jednotlivých vzorcích bylo využito grafického rozhraní prostředí Matlab, které bylo publikováno v [12]. Posluchač měl k dispozici sluchátka, monitor a myš. Po zapnutí testu se automaticky spustil první hudební vzorek. Na monitoru byly zobrazeny tlačítka „Yes“, „No“ a „Repeat“, kterými posluchač mohl označit vzorek za chybný nebo bezchybný, popřípadě si nechat vzorek přehrát vícekrát. Po označení vzorku za chybný nebo bezchybný byla dvě sekundy pauza a následně puštěn další vzorek. Jediná zpětná vazba, kterou posluchač dostal, byl počet poslechnutých vzorků.

Vyhodnocení zda vzorek obsahuje click nebo nikoliv proběhlo v závislosti na procentuálních výsledcích poslechových testů. Jako chybné vzorky jsou považovány ty, které více jak 75 % posluchačů označilo za vadné. Naopak za bezchybné považujeme ty vzorky, které méně než 25 % posluchačů označilo za vadné. Vzorky, které byly v intervalu 25 % až 75 %, byly vyřazeny z testování jednotlivých detekčních algoritmů z důvodu přesnějšího vyhodnocení výsledků (nejisté vzorky).



Obrázek 4.1: Grafické znázornění výsledků poslechových testů na první (nahore) a druhé sadě vzorků (dole)

## 5 Implementace

Veškeré skripty a funkce Matlabu použité v této práci označené indexem 1 slouží k práci s první sadou vzorků a soubory označené indexem 2 slouží k práci s druhou sadou vzorků (s modelovanými clicky). Rozdíly mezi těmito algoritmy jsou výhradně ve vyhodnocení výsledků. K implementaci detekčních algoritmů popsaných v této práci byly použity funkce psané v prostředí Matlabu verze 2013b. Jejich autorem je Ing. Michal Bolek a všechny algoritmy byly publikovány v [1], kde je podrobně popsána jejich implementace. Algoritmy pro vlnkovou transformaci byly upraveny pro přímé vyhodnocení výsledků. Tedy byl do nich vložen kód, který v závislosti na výstupu algoritmů a výsledcích poslechových testů vrací informaci o správnosti detekce. Část kódu, která prováděla detekci clicků, zůstala nezměněna. V případě vlnkové transformace ale probíhá detekce vad pouze v první úrovni rozkladu vlnkové transformace. Bylo tak dosahováno lepších výsledků. Také není využíváno segmentace vzorků, kvůli možnosti vzniku špatných koeficientů v krajních úsecích jednotlivých segmentů. Vlnková transformace využívá FIR filtrů, které automaticky signál segmentují. Konkrétně se jedná o tyto funkce:

- `AR_segment.m`
- `matched_segment.m`
- `vlnkova_segment_1.m`, `vlnkova_segment_2.m`

Z důvodu využití poslechových testů na dvou sadách audio vzorků byly tyto funkce rozšířeny o další skripty a funkce Matlabu, které slouží k načtení a vyhodnocení výsledků poslechových testů, zpracování hudebních vzorků, zavolání funkcí detekčních metod a k následnému vyhodnocení výsledků detekce. Pro podrobný popis těchto kódů viz. příloha A. Jedná se o tyto funkce:

- `runAnalysisAR_1.m`, `runAnalysisAR_2.m`
- `ARmodel_1.m`, `ARmodel_2.m`
- `runAnalysisWavelet_1.m`, `runAnalysisWavelet_2.m`

Prostředí Matlab bylo zvoleno pro implementaci těchto funkcí z důvodu širokého spektra matematických funkcí, možností grafického zpracování výsledků a snadné práce se zvukovými soubory včetně možnosti jejich úprav. Matlab také obsahuje rozšíření Signal Processing Toolbox, které obsahuje mnoho funkcí k analýze a zpracování signálů. Jedná se například o funkce `aryule`, `arburg`, `armcov` apod., které slouží k odhadu koeficientů autoregresivní metody. Dalším rozšířením je Wavelet Toolbox obsahující funkce potřebné k provedení vlnkové transformace (např. `wavedec`, `wrcoef`).

Parametry detekčních metod jsou v kódech Matlabu vyjádřeny pomocí těchto proměnných:

- `Order` – řád predikce AR modelu, řád Daubechiesové vlnky
- `Threshold` – hodnota konstanty  $k$  (úroveň detekčního prahu)
- `LengthSeg` – délka segmentu
- `LengthFilt` – délka okna mediánového filtru

Grafy s výsledky jsou vykreslovány v závislosti na těchto proměnných.

## 6 Testování a výsledky

Snahou testování výše popsaných algoritmů je získat přehled o vlivu hodnot jejich vstupních parametrů na efektivitu detekce impulsních vad a porovnat tyto výsledky z poslechovými testy. Na základě výsledků těchto testů verifikovat či vyvrátit závěry a postupy popsané v [1], kde autor testoval metodu AR modelu a vlnkové transformace podobným způsobem jako zde, ovšem byly vyhodnocovány na základě porovnání s výsledky detekčního softwaru firmy GZ Media, a.s. založeném na porovnání záznamu z gramodesky a z masteru, ze kterého byla vyrobena. Metoda AR modelu s rozšířením matched filtru v [1] testována nebyla. Pro podrobnější popis kritérií pro vyhodnocení viz. [1]. Na rozdíl od [1] byla v této práci vyhodnocena i celková chybovost jednotlivých systémů.

Všechny algoritmy jsou v této práci podrobeny testu na dvou sadách audio vzorků, které byly popsány v kapitole č. 4. Při každém testování je zvoleno několik hodnot jednoho parametru, které jsou následně otestovány. Ostatní parametry detekčních modelů jsou voleny empiricky tak, aby byly výsledky co nejlepší. Výsledky detekce jsou automaticky porovnány s databází výsledků poslechových testů a vyhodnoceny. Výsledky celého testování jsou dány pomocí tří kritérií – procenta nedetekovaných chyb, procenta falešných detekcí a celkové chybovosti.

Pro obě sady audio vzorků se tato kritéria vyhodnocují odlišně. U první sady neznáme počet ani polohu vad (mimo výjimky). Známe pouze výsledky poslechových testů, které říkají, zda je ve vzorku slyšitelné impulsní rušení. Vycházíme tedy z předpokladu, že pokud byl vzorek dle poslechových testů označen za chybný a není v něm testovaným algoritmem detekována chyba, jedná se o nedetekovanou chybu. V případě, že byl vzorek posluchači označen za bezchybný a byla v něm algoritmem detekována chyba, je považována za falešnou detekci. U druhé sady probíhá detekce clicků, jejichž parametry známe. Můžeme tedy detekci vyhodnocovat podrobněji. Z poslechových testů známe informaci o akustickém projevu clicku. Z modelování známe jeho přesnou polohu, délku a amplitudu. V případě, že byl vzorek označen za chybný a algoritmus detekoval chybu v místě clicku, jedná se o správnou detekci. V případě, že detekoval chybu kdekoli jinde, jedná se o falešnou detekci. U druhé sady mohou nastat obě situace najednou. Vyhodnocení výsledků mnou implementované v algoritmech převzatých z [1] je tedy schopné vyhodnotit např. i situace, kdy nebyla detekována slyšitelná chyba v místě jejího výskytu a zároveň se v jiném místě vyskytla falešná detekce. V případě, že byl vzorek posluchači označen za bezchybný a byla v něm detekována chyba, jedná se bez vlivu na polohu detekované chyby o falešnou detekci. Prvním kritériem vyhodnocení je procento nedetekovaných clicků, které je pro obě sady vyhodnoceno stejně a je dáno následující rovnicí:

$$\% \text{ nedetekovaných chyb} = \left(1 - \frac{\text{detekované\_signály}}{\text{chybné\_signály}}\right) * 100, \quad (6.1)$$

kde *detekované\_signály* označují počet vzorků, ve kterých algoritmus našel impulsní šum (v případě druhé sady pouze na správné pozici) a *chybné\_signály* je počet vzorků, které více jak 75 % testujících posluchačů označilo za chybné. Druhým kritériem je procento falešných detekcí, které je vypočteno pro každou sadu vzorků jinak. Pro první sadu je toto kritérium vypočteno pomocí vzorce:

$$\% \text{ falešných detekcí} = \frac{\text{falešné\_detekce}}{\text{bezchybné\_signály}} * 100, \quad (6.2)$$

kde *falešné\_detekce* značí počet signálů, ve kterých byla algoritmem detekována chyba a zároveň je méně než 25 % testujících označilo za chybné. *Bezchybné\_signály* označují počet signálů, které byly pomocí poslechových testů označeny za bezchybné. Jelikož u první sady může falešná detekce nastat jen u vzorků, které poslechové testy určily jako bezchybné, je ve vzorci počítáno pouze s těmito vzorky.

Pro druhou sadu platí tento vzorec:

$$\% \text{ falešných detekcí} = \frac{\text{falešné\_detekce}}{\text{počet\_signálů}} * 100, \quad (6.3)$$

kde *počet\_signálů* je počet testovaných signálů. Jelikož u druhé sady známe pozici modelovaných clicků, můžeme na rozdíl od první sady vyhodnotit případnou falešnou detekci i v signálech, které poslechové testy označily za chybné. Z tohoto důvodu se ve vzorci pro falešné detekce využívá celkového počtu testovaných signálů. Třetím kritériem je celková chybovost algoritmu. U první sady vzorků je možné, aby v jednom audio vzorku byla buď nedetekovaná chyba, nebo falešná detekce. Celková chybovost je tedy součtem prvních dvou kritérií:

$$\text{celková chybovost} = \% \text{ nedetekovaných chyb} + \% \text{ falešných detekcí} \quad (6.4)$$

Pro druhou sadu je vyhodnocení opět odlišné. Zde může nastat případ, že slyšitelná chyba nebyla detekována a zároveň nastala falešná detekce. Celková chybovost je tedy procento vzorků, ve kterých nastal alespoň jeden z těchto dvou případů.


Testované parametry závisí na samotných detekčních metodách a jejich výběr, testování i výsledky jsou popsány v následujících kapitolách. Tyto testy tedy porovnávají výstup algoritmu z Matlabu v závislosti na výsledcích subjektivních poslechových testů. Je tedy předpokladem, že se bude vyskytovat větší množství falešných detekcí a to z důvodu, že testované vzorky často mohou obsahovat vady impulsního charakteru, které nemají pro lidské ucho vnímatelný akustický projev, ale algoritmus je detekuje. Také lze předpokládat, že charakteristiky nedetekovaných chyb a falešných detekcí budou mít se změnou hodnoty určitých vstupních parametrů opačný průběh. Např. se zvyšováním detekčního prahu poroste procento nedetekovaných chyb a naopak poklesne procento falešných detekcí.

## 6.1 Testování AR modelu

Parametry AR modelu, které mohou být důležité pro jeho funkci, jsou tyto: řád AR modelu, práh detekce, a délka segmentu. Schopnost detekovat clicky AR modelem byla proto testována v závislosti na hodnotách těchto parametrů. Testování je vždy zaměřeno pouze na jeden parametr. Ostatní parametry se nemění a byly určeny empiricky z výsledků jiných nezávislých měření, kdy bylo dosaženo nejlepších výsledků. Pro autoregresivní algoritmus byla zvolena délka segmentu 6144, detekční práh 15 a řád predikce 30.

### 6.1.1 Experimentální výsledky pro AR model


Prvním testovaným parametrem je délka segmentu. Test byl proveden pro tyto hodnoty: 256, 512, 1024, 2048, 4096, 6144, 8192, 10240. Z obrázku 6.1, který znázorňuje výsledky testů pro první sadu vzorků, je zřejmé, že je celková chybovost nejnižší pro délku segmentu 2048 vzorků. V tomto případě je procento nedetekovaných chyb 17,65 %, procento falešných detekcí 2,56 % a celková chybovost 20,21 %. Jelikož jde o výsledky v porovnání s poslechovými testy tak je podstatnější získat menší procento nedetekovaných chyb než falešných detekcí. V případě, že posluchač chybu slyšel a algoritmus ji nedetekoval, vzniká výraznější chyba než v případě falešné detekce. Falešné detekce totiž mohou znamenat, že algoritmus správně detekoval chybu, která se na desce vyskytuje, pouze nemá slyšitelný projev např. kvůli maskování. Minimální procento nedetekovaných chyb 11,76 % je pro délku segmentu 6144 vzorků. V tomto případě je procento falešných detekcí 15,38 % a celková chybovost 27,14 %. Tuto hodnotu lze považovat za nejlepší v porovnání s poslechovými testy. Při dalším prodloužení segmentu dochází opět k nárůstu nedetekovaných vad a k poklesu falešných detekcí.



Obrázek 6.1: Výsledky detekce v závislosti na délce segmentu (1. sada)


Výsledky vlivu délky segmentu na druhé sadě jsou znázorněny na obrázku 6.2. Zde je průběh dle očekávání podobný. Počet nedetekovaných chyb klesá až do hodnoty 6144. Při této hodnotě je 28,3 %, falešných detekcí 16,22 % a celková chybovost 35,14 %. Celková chybovost je nejnižší s hodnotou 32,43 % při délce segmentu 8192 vzorků. Stejně jako u první sady vzorků je zde ale zvýšené procento nedetekovaných vad, což je nežádoucí. Nejlepších výsledků je tedy dosaženo při délce segmentu 6144 vzorků.






Obrázek 6.2: Výsledky detekce v závislosti na délce segmentu (2. sada)

Druhým testovaným parametrem je řád predikce, tedy pomocí kolika předchozích vzorků se odhaduje amplituda následujícího. Testované hodnoty jsou 10, 20, 25, 30, 35, 40, 50, 60, 70. Výsledky testů na první sadě jsou graficky zobrazeny na obrázku 6.3. Z tohoto grafu je patrné, že se výsledky příliš nemění. Nejlepších výsledků bylo dosaženo při hodnotách 20 až 40. Nedetekovaných vzorků bylo tedy 11,76 %, falešných detekcí 15,38 % a celková chybovost tedy 27,14 %.




Obrázek 6.3: Výsledky detekce v závislosti na řádu predikce (1. sada)

Obrázek 6.4 potvrzuje minimální vliv tohoto parametru i na druhé sadě vzorků. V tomto případě bylo dosaženo celkové chybovost 32,43 % při řádu predikce 35. Tehdy bylo 26,42 % nedetekovaných chyb a 14,86 % falešných detekcí. Z těchto testů lze usoudit, že volba tohoto parametru není příliš vlivná na výsledky. Jako ideální hodnota pro obě sady vzorků je 35.




Obrázek 6.4: Výsledky detekce v závislosti na řádu predikce (2. sada)

Třetím testovaným parametrem autoregresivního modelu je detekční práh. Přesněji hodnota konstanty  $k$ . Testované hodnoty této konstanty byly 4, 6, 8, 10, 12, 14, 15, 16, 18, 20, 24, 28, 32. Dle teoretického předpokladu lze usoudit, že při nižších hodnotách detekčního prahu se vyskytne velké množství falešných detekcí, jelikož budou brány za chybné i části signálu, které mají menší amplitudu nebo části signálu, kde hrají např. perkusní nástroje. Také lze předpokládat, že nebude docházet k nedetekování slyšitelných chyb. Při zvyšování hodnoty detekčního prahu by tedy mělo klesat procento falešných detekcí a naopak stoupat procento nedetekovaných signálů. Ideální hodnota tohoto parametru by se měla nacházet v okolí průniku křivek těchto dvou kritérií. Teoretický předpoklad je potvrzen z testů na obou sadách vzorků. Obrázky 6.5 a 6.6 znázorňují průběh výsledků testů. V případě první sady bylo dosaženo minimální celkové chybovost 27,14 % s procentem nedetekovaných chyb 11,76 % a procentem falešných detekcí 15,38 % v případě  $k=15$ . U druhé sady je výhodnější volit menší hodnotu konstanty  $k$  než 15 (ideálně 14) z důvodu nižšího procenta nedetekovaných vad i na úkor vyššího procenta celkové detekce.



Obrázek 6.5: Výsledky detekce v závislosti na detekčním prahu (1. sada)



Obrázek 6.6: Výsledky detekce v závislosti na detekčním prahu (2. sada)

Rozšíření Matlabu Signal Processing Toolbox obsahuje navíc k funkci `lpc` ještě několik funkcí pro výpočet koeficientů predikce. Jsou to funkce `arburg`, `arcov`, `armcov` a `aryule`. Funkce `aryule` poskytuje stejné výsledky jako funkce `lpc`. Ostatní funkce dosahují podstatně horších výsledků.

Nejvhodnější hodnoty testovaných parametrů a výsledky detekce na obou sadách vzorků shrnuje tabulka 6.1.

*Tabulka 6.1: Vyhodnocení testů AR modelu*

<b>AR model</b>	<b>1. sada</b>	<b>2. sada</b>
<b>Délka segmentu</b>	6144	6144
<b>Řád predikce</b>	20-40	35
<b>Konstanta <math>k</math> (detekční práh)</b>	15	14
<b>Nedetekovaných chyb</b>	11,76 %	26,42 %
<b>Falešných detekcí</b>	15,38 %	14,86 %
<b>Celková chybovost</b>	27,14 %	32,43 %


Výsledky těchto testů se neshodují s výsledky popsány v [1]. Dle výsledků popsanych autorem je ideální délka segmentu 450 vzorků, řád predikce 30 a detekční práh 11. Je zřejmé, že řád predikce je podobný a lze ho tedy považovat za ideální při vyhodnocování pomocí poslechových testů i pomocí porovnání se záznamem získaným za masteru. Testy prokázaly odlišnou ideální hodnotu detekčního prahu. Tato hodnota se může lišit vzhledem k odlišné celkové úrovni testovaných vzorků a také k poměru amplitudy clicků a signálu. Fakt že v [1] byl na testovaných vzorcích výskyt falešných detekcí 90,3 %, 71 % a 46,5 % napovídá tomu, že je hodnota detekčního prahu 11 příliš nízká. Výsledky testů v obou pracích jasně dokazují, že s vyšším detekčním prahem klesá procento falešných detekcí. Nejvíce se liší ideální hodnota délky segmentu. Nejdelší testovaný segment v [1] měl 1250 vzorků. Nebyly testovány hodnoty v takovém rozsahu jako v této práci. Nelze tedy objektivně říci, zda je délka 450 vzorků špatnou volbou. Dle obrázků 6.1 a 6.2 je ale jasně potvrzeno, že v testech vztažených k poslechovým testům je tato hodnota naprosto nevhodná a je lepší volit segmenty více než 10x delší. Zmíněné zvýšení detekčního prahu s sebou jistě přinese zvýšení procenta nedetekovaných signálů. Lze pouze spekulovat o tom, zda by tento efekt byl vyřešen prodloužením segmentu a celková chybovost by výsledně byla nižší.

## 6.2 Testování matched filtru

Přizpůsobený filtr je pouze rozšíření AR modelu a jsou proto testovány stejné parametry. Díky dalšímu filtru, který je oproti běžnému AR modelu použit, má signál vyšší amplitudu a neočekávané impulsní zvuky (i ty neslyšitelné) jsou mnohem výraznější oproti zbytku signálu. Z toho důvodu lze předpokládat, že bude detekováno více chyb a především vzroste počet falešných detekcí. Ideální hodnota detekční prahu bude oproti AR modelu posunuta výš. Opět byl vždy testován jeden parametr a hodnoty ostatních byly zvoleny ze zkušenost pro dosažení nejlepších výsledků. Délka segmentu 6144 vzorků, řád predikce 30 a detekční práh 35.


### 6.2.1 Experimentální výsledky pro matched filtr

Prvním testovaným parametrem je délka segmentu ve stejném rozsahu hodnot jako u AR modelu. Ihned se potvrzuje teoretický předpoklad o falešných detekcích. Nejnižší celková chybovost je v případě délky segmentu rovné 6144 vzorkům. Tehdy je procento nedetekovaných chyb 17,65 % a falešných detekcí 23,08 %. Celková chybovost je 40,73 %. Oproti samotnému AR modelu jsou všechny výsledky horší.




Obrázek 6.7: Výsledky detekce v závislosti na délce segmentu (1. sada)

Testy na druhé sadě vzorků vykazují ještě horší výsledky. V tomto případě bylo dosaženo nejlepších výsledků při délce segmentu 8192 vzorků. Tehdy byla celková chybovost 71,62 %. Chyba nebyla detekována ve 30,19 % případech a falešná detekce nastala u 55,4 % testovaných vzorků.




Obrázek 6.8: Výsledky detekce v závislosti na délce segmentu (2. sada)

Druhým testovaným parametrem je řád predikce. Stejně jako u samotného AR modelu zde má minimální vliv na výsledky detekce. Důvodem toho je, že je predikce počítána úplně stejným způsobem a pomocí stejných funkcí. Testovány byly hodnoty 10, 20, 25, 30, 35, 40, 50, 60 a 70. Z grafu 6.9 pro první sadu je patrné, že nejlepší výsledek byl dosažen při řádu predikce 30.




Obrázek 6.9: Výsledky detekce v závislosti na řádu predikce (1. sada)

U druhé sady vzorků byly nejlepší výsledky také při hodnotě řádu 30. Jelikož byla tato hodnota zvolena i při testování závislosti délky segmentu, jsou procentuální výsledky stejné. V případě volby hodnoty blízké 30 jsou výsledky nepatrně horší, nicméně při zohlednění výsledků u AR modelu samotného i u použití přizpůsobeného filtru lze konstatovat, že hodnota 30 je nejuniverzálnější a lze ji použít pro různé druhy predikce i vstupních signálů a impulsních vad.




Obrázek 6.10: Výsledky detekce v závislosti na řádu predikce (2. sada)

Testování třetího parametru potvrdilo silný vliv určení detekčního prahu na výsledky detekce. Již z testování tohoto parametru u AR modelu víme, že s jeho změnou lze očekávat prudký nárůst či pokles efektivity detekce. Zde byly testovány tyto hodnoty konstanty  $k$ : 5, 10, 15, 20, 25, 30, 35, 40, 45, 50. Opět by mělo platit, že ideální volba tohoto parametru bude v okolí průniku křivek falešných detekcí a nedetekovaných signálů. Obrázek 6.11 znázorňuje průběh těchto křivek v případě testů na první sadě vzorků. Průběh křivek je podobný jako u samotného AR modelu. Pouze je minimum celkové chybovost posunuto do hodnoty  $k=35$ . U druhé sady vzorků, jejichž výsledky jsou zobrazeny v grafu 6.12, je patrné, že minimální celková chybovost je při hodnotě konstanty  $k=45$ . V tomto případě je ovšem procento nedetekovaných chyb vyšší než procento falešných detekcí. Je tedy výhodnější zvolit práh, kde bude sice celková chybovost vyšší, ale bude méně nedetekovaných chyb. Toto je splněno v případě, že je  $k=35$ . Procentuální výsledky u obou sad jsou shodné s testováním závislosti délky segmentu.



Obrázek 6.11: Výsledky detekce v závislosti na detekčním prahu (1. sada)



Obrázek 6.12: Výsledky detekce v závislosti na detekčním prahu (2. sada)

Tabulka 6.2 shrnuje nejvhodnější volbu hodnot parametrů AR modelu s matched filtrem a výsledky detekcí na obou sadách vzorků.

Tabulka 6.2: Vyhodnocení testů AR modelu s matched filtrem


<b>AR model + matched filtr</b>	<b>1. sada</b>	<b>2. sada</b>
<b>Délka segmentu</b>	6144	8192
<b>Řád predikce</b>	30	30
<b>Konstanta <math>k</math> (detekční práh)</b>	35	35
<b>Nedetekovaných chyb</b>	17,65 %	30,19 %
<b>Falešných detekcí</b>	23,08 %	55,4 %
<b>Celková chybovost</b>	40,73 %	71,62 %

### 6.3 Testování metody vlnkové transformace

Mezi testované parametry vlnkové transformace patří řád vlnky, délka okna mediánového filtru a hodnota konstanty  $k$ . Během testování byla používána vlnka Daubechiesová. Testován byl opět každý parametr postupně. Hodnoty ostatních parametrů byly určeny ze zkušenosti takto: délka okna 150 vzorků, konstanta  $k=25$  a řád Daubechiesové vlnky 30.


#### 6.3.1 Experimentální výsledky pro metodu vlnkové transformace

Prvním testovaným parametrem je délka okna mediánového filtru. Délka okna by teoreticky měla být větší než je délka impulsních vad, ale ne příliš dlouhá. Testované hodnoty byly 100, 125, 150, 175, 200, 225 a 250. Z grafu 6.13 je patrné, že u první sady vzorků bylo nejlepších výsledků dosaženo při délce okna o 150 vzorcích. S rostoucí délkou okna vzniká nárůst falešných detekcí a klesá počet nedetekovaných clicků. Z grafu je ihned poznat, že oproti předchozím dvou metodám jsou procenta chybovosti nižší. Při délce filtru o 150 vzorcích nebylo detekováno 5,88 % chyb a pouze 10,26 % bylo detekováno falešně. Celkem jde o chybovost 16,14 %.



Obrázek 6.13: Výsledky detekce v závislosti na délce okna mediánového filtru (1. sada)


U druhé testované sady je známo, že clicky mají délku 10 až 100 vzorků. Teorie říká, že by měla být délka mediánového filtru ideálně dvojnásobek maximální délky clicků. Z grafu 6.14 je patrné, že tento teoretický předpoklad platí. Při délce mediánového filtru 200 vzorků je celková chybovost nejnižší s hodnotou 14,68 %. Chyba přitom nebyla detekována v 3,77 % případů a ve 12,16 % testovaných vzorků nastala falešná detekce. Ve srovnání s předchozími metodami jde o výrazně lepší výsledky. Z důvodu získání lepších výsledků bude při testování dalších parametrů u druhé sady vzorků použita délka mediánového filtru 200.



Obrázek 6.14: Výsledky detekce v závislosti na délce okna mediánového filtru (2. sada)


Druhým testovaným parametrem je konstanta  $k$ , která spolu s obálkou signálu určuje detekční práh. Byly testovány hodnoty od pěti do padesáti s krokem pět. Z předchozích metod víme, že tento parametr má největší vliv na poměr nedetekovaných chyb a falešných detekcí. Ideální hodnota se nacházela v okolí průniku křivek těchto dvou kritérií. Z obrázku 6.15, který popisují výsledky testů na

první sadě vzorků, je patrné, že nejlepších výsledků bylo dosaženo při hodnotě konstanty  $k=25$ . Výsledky jsou shodné s testem předchozího parametru.




Obrázek 6.15: Výsledky detekce v závislosti na detekčním prahu (1. sada)

Podobných výsledků bylo dosaženo i u druhé sady vzorků. Nejnížší chybovosti bylo dosaženo v případě  $k=25$ . Grafické znázornění výsledků je na obrázku 6.16. Od hodnot konstanty  $k$  30 a výš je procento nedetekovaných chyb větší než procento celkové chybovosti, což není chyba. Je to způsobeno tím, že vyhodnocení nedetekovaných chyb je závislé pouze na vzorcích, které byly označeny za chybné. Procento falešných detekcí a celkové chybovosti je u druhé testované sady počítáno ze všech vzorků. Procentuální výsledky jsou opět shodné s testem předchozího parametru.




Obrázek 6.16: Výsledky detekce v závislosti na detekčním prahu (2. sada)

Třetím testovaným parametrem je řád Daubechiesové vlnky, který ovlivňuje dekompozici signálu a následný výpočet koeficientů vlnkové transformace. Byly testovány tyto hodnoty: 1, 5, 10, 15, 20, 25, 30, 35, 40 a 45. Obrázky 6.17 a 6.18 znázorňují výsledky testů na první a druhé sadě vzorků. Křivky jsou v obou případech nepředvídatelné, ale vždy byly nejlepší výsledky pro hodnotu řádu 30.



Obrázek 6.17: Výsledky detekce v závislosti na řádu Daubechiesové vlnky (1. sada)





Obrázek 6.18: Výsledky detekce v závislosti na řádu Daubechiesové vlnky (2. sada)

V následující tabulce je souhrn ideálních hodnot parametrů detekčního algoritmu využívajícího vlnkové transformace pro obě testované sady.

Tabulka 6.3: Vyhodnocení testů vlnkové transformace

<b>Vlnková transformace</b>	<b>1. sada</b>	<b>2. sada</b>
<b>Délka okna med. filtru</b>	150	200
<b>Hodnota konstanty <math>k</math></b>	25	25
<b>Řád Daubechiesové vlnky</b>	30	30
<b>Nedetekovaných chyb</b>	5,88 %	3,77 %
<b>Falešných detekcí</b>	10,26 %	12,16 %
<b>Celková chybovost</b>	16,14 %	14,68 %

Autor [1] ve své práci označil jako ideální délku okna mediánového filtru 55 vzorků, hodnotu konstanty  $k$  rovnu 8 a řád Daubechiesové vlnky 10. Bohužel v [1] nebyly testovány délky okna mediánové filtru větší než 80 vzorků. Dle [8] by měla délka okna  $L_{med}$  splňovat podmínku  $L_{med} > 2K_{max} + 1$ , kde  $K_{max}$  je počet vzorků v nejdelším clicku. Dle [2] je typická délka impulsního šumu 1-200 vzorků. Nelze tedy předpokládat, že by ideální okno mediánového filtru obsahovalo méně než 80 vzorků. Testy provedené v této práci vyvrací výsledky popsané v [1] a spíše se přiklání k teoretickým předpokladům. Velmi se také liší úroveň detekčního prahu (konstanty  $k$ ). Dle [1] je ideální hodnotou konstanty  $k$  8. Vzhledem k procentuálním výsledkům jeho testů, jež vykazují 99,5 %, 98,8 % a 81,7 % falešných detekcí pro tři testované vzorky lze konstatovat, že tato hodnota také není vhodná. Chybná volba tohoto parametru může být následkem již předtím špatně zvolené délky okna med. filtru. Třetím testovaným parametrem byl řád Daubechiesové vlnky. Autor [1] opět bohužel testoval hodnoty řádu od tří do dvanácti. Ideální řád vlnky je dle jeho testů 10. Dle testů provedených z této práce se nachází ideální hodnota vysoko nad rozsahem hodnot testovaných v [1].

## 6.4 Vyhodnocení výsledků

Testovány byly tři metody detekce impulsních vad. Autoregresivní model, jeho rozšíření o přizpůsobený filtr a metoda využívající vlnkovou transformaci. Tyto metody byly porovnány s výsledky subjektivních poslechových testů na dvou sadách vzorků s reálnými a modelovanými clicky. První ze jmenovaných metod dosáhla celkové chybovosti 27,14 % a 32,43 % na první, respektive druhé sadě vzorků. Tyto výsledky nejsou příliš přívětivé. Důvodem špatných signálů je především nadměrné množství falešných detekcí. Metody detekce signálů využívající lineární predikce jsou v praxi využívány například v radarových systémech. V těchto systémech se pracuje s náhodným šumem, ve kterém se nevyskytují náhlé nárůsty amplitudy způsobené například bicími nástroji nebo jinými perkusemi. Těchto nástrojů je v našich testovaných vzorcích velké množství a často jsou falešně detekovány jako clicky gramofonových desek.

Ještě horší výsledky byly zaznamenány při testování matched filtru. V tomto případě se jedná o stejný princip detekce jako u první metody, pouze je navíc použit filtr s obrácenou impulsní odezvou. Předpokladem bylo, že se v detekčním signálu objeví podstatně větší množství vzorků připomínající click. Bohužel tento fakt se potvrdil a způsobil prudký nárůst falešných detekcí. Celková chybovost pro první sadu byla 40,73 % a pro druhou sadu 71,62 %. Bohužel ve výsledném detekčním signálu nebyl výrazný rozdíl amplitudy mezi místy, kde click opravdu ležel a kde leželo místo falešné detekce. Z toho důvodu nebylo možné potlačit počet falešných detekcí snížením detekčního prahu. Jednou z vlastností, která byla zjištěna u testování autoregresivních metod bylo, že algoritmu špatně detekuje clicky, které jsou na začátku nebo na konci jednotlivých segmentů. Tento problém by bylo možné vyřešit částečným překryvem jednotlivých segmentů. Např. aby segment začínal ve  $\frac{3}{4}$  segmentu předchozího. První i druhá metoda je dle těchto výsledků nevhodná pro detekci v audio signálu, který má velký dynamický rozsah a obsahuje hodně perkusních nástrojů.

Pomocí metody vlnkové transformace byly impulsní vady detekovány poměrně spolehlivě. S průměrnou chybovostí okolo 15 % je zdaleka nejlepší z testovaných metod. V porovnání s předchozími metodami, které měly podstatně horší výsledky u druhé sady testovaných vzorků, má vlnková transformace výsledky u obou sad velice blízké. Tento fakt naznačuje, že je tato metoda vhodná pro detekci clicků v hudbě bez závislosti na parametrech chyb nebo detekovaného signálu. Jediný parametr, jehož ideální hodnota byla odlišná pro dvě sady vzorků, byla délka okna mediánového filtru. To je pravděpodobně způsobeno délkou jednotlivých clicků. Modelované clicky měly maximální délku 100 vzorků a ideální hodnota délky okna filtru bylo 200 vzorků. Vzhledem k ideální hodnotě tohoto parametru u první sady vzorků předpokládáme, že se maximální délka chyb pohybovala okolo 75 vzorků.

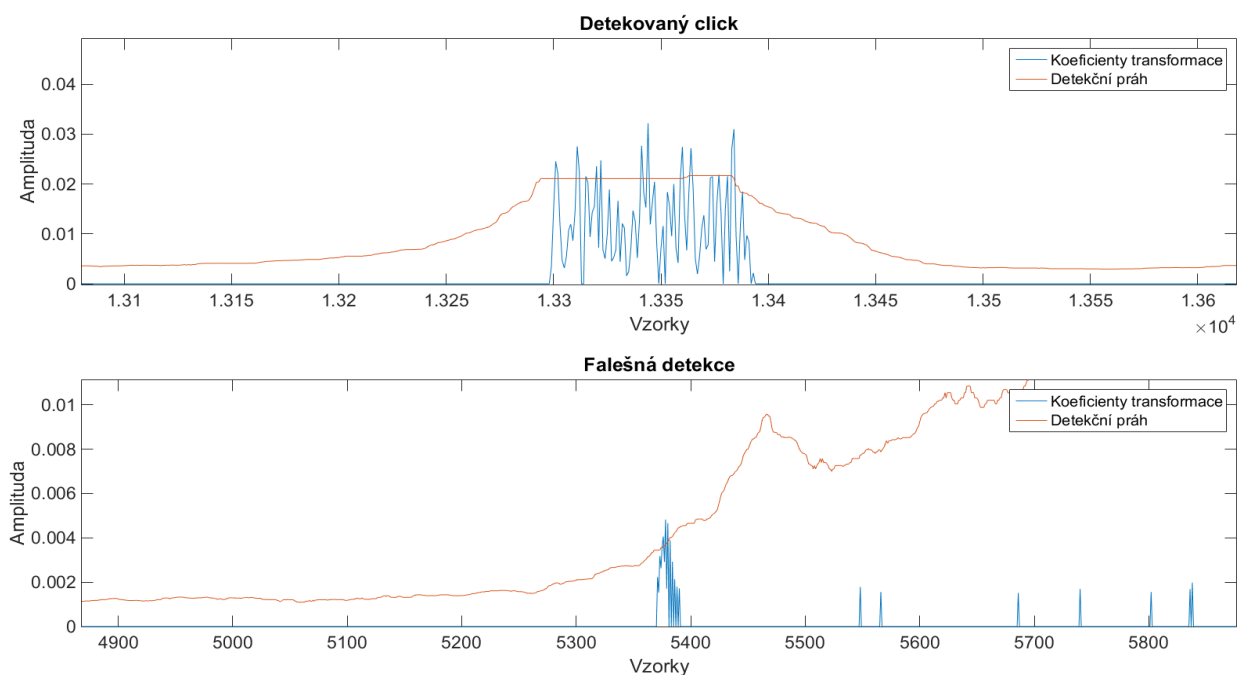
Tabulka 6.4: Souhrn výsledku pro všechny testované metody

1. sada / 2. sada	AR model	Matched filtr	Vlnková transformace
<b>Nedetekovaných chyb</b>	11,76 % / 26,42 %	17,65 % / 30,19 %	5,88 % / 3,77 %
<b>Falešných detekcí</b>	15,38 % / 14,86 %	23,08 % / 55,4 %	10,26 % / 12,16 %
<b>Celková chybovost</b>	27,14 % / 32,43 %	40,73 % / 71,62 %	16,14 % / 14,68 %

Ve srovnání s výsledky popsány v [1] bylo v této práci dosaženo podstatně lepších výsledků detekcí testovaných metod. Parametry, které byly v [1] zvoleny jako ideální se výrazně liší od parametrů zvolených v této práci. V [1] bylo u testovaných metod příliš mnoho falešných detekcí způsobených volbou příliš nízké úrovně detekčního prahu. Tento fakt musel autor řešit ověřovací metodou využívající spektrálních charakteristik clicků. Ve většině případů autor testoval příliš malý rozsah hodnot a nepřišel pro to na fakt, že je lepší volit jiné hodnoty detekčních prahů, délek segmentů a také řádu Daubechiesové vlnky u metody vlnkové transformace.

## 7 Vylepšení detekce pomocí vlnkové transformace

Z předchozí kapitoly je patrné, že pomocí autoregresivní metody lze dosáhnout dobrých výsledků jen těžko. Rozšíření o přizpůsobený filtr způsobilo další zhoršení výsledky při detekci clicků v audio signálu. Jediná metoda, jejíž výsledky jsou nadějně pro praktické využití, je třetí testovaná. Tato metoda sama o sobě bez jakýchkoliv vylepšení přinesla výsledky s celkovou chybovostí okolo 15 %. Podstatná část celkové chybovosti byla způsobena falešnými detekcemi. Je nutné připomenout, že v této práci jde o testování, u jehož vyhodnocení je jako objektivní kritérium využito subjektivních poslechových testů. Je tedy možné, že některé z falešných detekcí jsou detekce clicků, které neměly dostatečně výrazný akustický projev, a testující posluchači je nezaznamenali. Při bližším zkoumání jednotlivých vzorků a průběhu detekce vad bylo zjištěno, že se častěji vyskytují případy falešných detekcí v místě úderu perkusních nástrojů a jiných impulsních zvuků, které jsou chtěnou součástí audio nahrávky. Obrázek 7.1 znázorňuje průběh signálu typickou detekci clicku a falešnou detekci. Znázorněn je případ falešné detekce při nástupu perkusního nástroje. Oproti případu, kdy byl detekován slyšitelný click, je průběh obálky signálu rostoucí. To je způsobeno mediánovým filtrem, který vždy z každého okna vybere mediánovou hodnotu a při perkusi, která nastupuje pomaleji, se obálka zvyšuje se zpožděním a koeficienty transformace překročí její hodnotu. Těchto případů bylo zaznamenáno více.



Obrázek 7.1: Průběh signálu při detekovaném clicku (nahore) a při falešné detekci (dole)

Jako vylepšení této metody bylo navrženo omezení falešných detekcí pro případy, kdy je obálka signálu rostoucí a je detekován click. Po podrobném zkoumání detekovaných clicků a falešných detekcí z předchozích testů bylo zjištěno, že takovýto případ nastává pouze u nástupu perkusních nástrojů. Funkce Matlabu `vlnkova_segment_1` a `vlnkova_segment_2` byly upraveny a bylo do nich implementováno toto vylepšení. Po porovnání amplitud koeficientů a obálky je výsledný signál upraven tak, že místa, která jsou označena za chybná a zároveň v nich má obálka signálu kladný gradient, jsou vynulována a nemohou tedy obsahovat chybu.

S tímto vylepšením byly opět provedeny testy na obou sadách vzorků. Tabulka 7.1 shrnuje výsledky přes a po implementaci tohoto vylepšení. Cílem bylo snížit počet falešných detekcí. Způsob vylepšení mohl ale zapříčinit i vzrůst nedetekovaných signálů. Vzhledem k charakteru správných

detekcí demonstrovánému v obrázku 7.1 by k tomu správně docházet nemělo. Z tabulky výsledků je vidět, že je počet nedetekovaných signálů stejný jako bez tohoto vylepšení. Naopak počet falešných detekcí se snížil dle očekávání. Ze statistik falešných detekcí je evidentní, že toto vylepšení opravdu funguje. V případě první sady se falešné detekce redukovaly na polovinu, což se projevilo jako snížení celkové chybovosti o 5,13 %. U druhé sady se objevilo o 4,05 % falešných detekcí a celková chybovost poklesla o 3,87 %. Tyto výsledky jsou poměrně uspokojující. Vzhledem k již relativně nízké chybovosti nebylo pravděpodobné, že by se chybovost snížila o více než třetinu.

*Tabulka 7.1: Vyhodnocení testů vlnkové transformace s vylepšením*

<b>Bez / s vylepšením</b>	<b>1. sada</b>	<b>2. sada</b>
<b>Nedetekovaných chyb</b>	5,88 % / 5,88 %	3,77 % / 3,77 %
<b>Falešných detekcí</b>	10,26 % / 5,13 %	12,16 % / 8,11 %
<b>Celková chybovost</b>	16,14 % / 11,01 %	14,68 % / 10,81 %

Druhé možné vylepšení spočívá v implikaci prahu minimální amplitudy signálu. Tento práh by omezoval detekci pouze na místa, která jsou pro lidské ucho slyšitelná. Amplituda prahu by se tedy měla odvodit z psychoakustického modelu ucha a z prahu slyšení. Toto vylepšení by tedy mělo zamezit vzniku falešných detekcí v místech, kde má vstupní signál takovou úroveň, která není lidským uchem vnímatelná. Implikace tohoto vylepšení byla provedena na obou sadách vzorků. Bylo testováno více úrovní tohoto prahu, avšak výsledky testování byly negativní a nejsou tedy v této práci podrobněji vyhodnoceny. V případě použití příliš malé úrovně se výsledky nijak neměnily. Tento fakt ukazuje, že se falešné detekce nenachází v místech, která nejsou lidským uchem zaznamenatelná. Při zvyšování úrovně prahu již docházelo k nedetekování clicků při zachování stejného procenta falešných detekcí.

## 8 Závěr

Cílem této práce bylo zkoumat metody detekce impulsních vad u mechanického záznamu zvuku. Teoretická část práce popisuje postupy využívané při výrobě gramofonových desek, popis chyb, které vznikají během výroby i během běžného používání. Dále je v práci popsán teoretický základ, na kterém jsou metody detekce clicků postaveny. Konkrétně byla představena autoregresivní metoda, její rozšíření matched filtrem a vlnková transformace. Popsány byly dvě sady zvukových nahrávek, na kterých testování probíhalo a poslechové testy provedené na těchto nahrávkách za účelem získání objektivní informace použitelné pro vyhodnocení výsledků detekce. V následující kapitole byla zdokumentována implementace těchto metod a funkcí použitých při testování v softwaru Matlab. V předposlední části práce byl popsán způsob vyhodnocení výsledků. Po představení důležitých parametrů jednotlivých detekčních metod byly graficky a číselně popsány výsledky získané porovnáním výstupu detekčního algoritmu a výsledků poslechových testů. Výsledky byly vyhodnoceny pomocí tří parametrů: procenta nedetekovaných chyb, procenta falešných detekcí a celkové procentuální chybovosti. Bylo také provedeno porovnání implementace a výsledků s [1].

Testování metod prokázalo, že v porovnání s poslechovými testy dosáhla nejlepších výsledků detekční metoda využívající vlnkovou transformaci. V nejlepším případě bylo pomocí této metody dosaženo celkové neúspěšnosti 16,14 % na první sadě vzorků a 14,68 % na sadě druhé. Oproti těmto výsledkům zaostávaly ostatní testované metody. Autoregresivní model detekce vykazuje celkovou chybovost 27,14 % na první sadě a 32,43 % na druhé. Nejhůře dopadla metoda AR modelu rozšířená o matched filtr. Tato metoda vykazovala příliš vysoké procento falešných detekcí. Toto procento bylo omezeno zvýšením detekčního prahu, což ale zvýšilo počet nedetekovaných chyb. U první sady vzorků byla chybovost minimálně 40,73 % a u druhé sady 71,62 %. Součástí této práce bylo také vylepšení metody detekce pomocí vlnkové transformace. Toto vylepšení bylo zaměřeno na redukci falešných detekcí. Výsledky detekce po jeho implikaci vykazují chybovost 11,01 % u první respektive 10,81 % u druhé sady. Falešné detekce byly sníženy o 5,13 % a o 4,05 %.

Tyto výsledky jasně naznačují, že pokud by se jednalo o detekci pouze slyšitelných chyb, nejlepší volbou by byla metoda s vlnkovou transformací. Testování prokázalo, že výhodou detekce vlnkovou transformací je její univerzálnost. Na rozdíl od ostatních metod vykazovala velice podobné výsledky pro obě sady vzorků. Ačkoliv měla metoda matched filtru v těchto testech nejhorší výsledky, má nejlepší předpoklady pro detekci vad s minimální amplitudou nebo chyb, které nemají výrazný akustický projev obecně. Nevýhodou metody vlnkové transformace je její výpočetní náročnost. Detekce vad na jedné sadě vzorků pomocí této metody trvala v průměru 55 sekund (při parametrech zvolených dle tabulky 6.3). Oproti tomu metody využívající predikce vynikají rychlostí. Při parametrech zvolených dle tabulky 6.3 trvalo testování jedné sady vzorků pomocí AR modelu i matched filtru v průměru okolo pěti sekund. Autoregresivní metody mají potenciál pro úspěšné detekce v signálech, které nemají tak dynamický průběh jako je průběh signálů hudebních. Z hlediska dalšího vývoje detekčních metod lze vidět velký potenciál ve využití psychoakustických modelů lidského sluchového ústrojí. V případě vlnkové transformace lze uvažovat nad využitím jiného filtru než mediánového pro zkonstruování obálky signálu.

Jedním z cílů bylo verifikovat správnost implementace detekčních metod v [1]. Výsledky testů provedených v této práci jsou v rozporu s výsledky publikovanými Ing. Bolkem. Ačkoliv jsou testy vyhodnocovány podle výsledků poslechových testů, nikoliv podle rozdílů záznamu gramodesky a masteru, ze kterého byl vylisován, jasně prokazují, že volba některých parametrů detekčních metod je v [1] nesprávná. Autor testoval příliš malý rozsah hodnot a svou špatnou volbu musel řešit dalšími metodami ověření detekce. Jediný parametr, jehož ideální volba se v obou testech shodovala, byl řád predikce AR modelu.

## Literatura

- [1] BOLEK, M. Detekce vad u mechanického záznamu zvuku. Praha: ČVUT 2016. Diplomová práce, ČVUT, Fakulta elektrotechnická, katedra radioelektroniky
- [2] GODSILL, S, RAYNER, P. Digital Audio Restoration. Springer-Verlag, London, 1998.
- [3] Interní zdroj firmy GZ Media, a.s.
- [4] DMM Technology [Online], GZVinyl, [vid. 2014], Dostupné z: <http://www.gzvinyl.com/Manufacturing/Mastering/DMM-cutting.aspx>
- [5] OUDRE, L. Automatic Detection and Removal of Impulsive Noise in Audio Signals. Image Processing On Line. 2015, 5, 267-281
- [6] Electroforming [Online], Wikipedia, [vid. 29.12.2015], Dostupné z: <https://en.wikipedia.org/wiki/Electroforming>
- [7] BAŠTA, I. Záznam signálu. Vydavatelství ČVUT, Praha, 1999.
- [8] NONGPIUR, R. C. a SHPAK, D. J. Impulse-noise suppression in speech using the stationary wavelet transform. The Journal of the Acoustical Society of America. 2013, 133(2), 866–879.
- [9] Discrete wavelet transform [Online], Wikipedia, [vid. 27. 11. 2016], Dostupné z: [https://en.wikipedia.org/wiki/Discrete\\_wavelet\\_transform](https://en.wikipedia.org/wiki/Discrete_wavelet_transform)
- [10] RAJMIC, P., KLIMEK, J. Removing crackle from an LP record via wavelet analysis. Proc. of the 7th Int. Conference on Digital Audio Effects (DAFx'04), Naples, Italy, 2004
- [11] VENCOVSKÝ, V., RUND, F. Pure tone audiometer. 20th Annual Conference Proceeding's Technical Computing, 2012
- [12] RUND, F., VENCOVSKÝ, V., BOUŠE, J. Detection of clicks in analog records using peripheral-ear model. Proceedings of the 19th International Conference on Digital Audio Effects (DAFx-16), Brno, Czech Republic, 2016

## Příloha A: Popis funkcí implementovaných v prostředí Matlab

Modelování vlastních clicků do bezchybných nahrávek bylo realizováno ve skriptu `Create_faulty_sounds.m`. Celý proces modelování clicků je vložen do dvou `for` cyklů. V prvním z nich se pouze načítají bezchybné mastery do paměti. V druhém cyklu je nejprve pomocí funkce `rand` vygenerován index, od kterého bude hudební vzorek vystřižen z masteru, index od kterého se bude ve vystřiženém vzorku vyskytovat click a délka clicku. Funkce `rand` zajistila, že je vzorek vystřižen z náhodného místa, click má náhodou pozici a náhodnou délku. Následně je provedeno vystřížení vzorku z masteru. Pro vytvoření chybného signálu je nejprve vytvořen vektor, který měl hodnotu 1 v místech clicku a hodnotu 0 jinde. Tento vektor je vynásoben vektorem náhodných čísel v rozmezí od -1 do 1, které jsou generovány funkcí `rand`. Do vektoru `poznamky` jsou vloženy parametry vygenerovaného clicku. Následně je vektor obsahující chyby vynásoben konstantou, která určí amplitudu clicku. Tato amplituda je pomocí funkce `switch` pravidelně měněna mezi hodnotami -15dB, -20dB, -25dB a -30dB. Dalším krokem je sečtení signálu vystřiženého z masteru a signálu obsahujícího chyby. Důležitým krokem je vytvoření obálky signálu. Náběžná i sestupná hrana jsou generovány pomocí funkce `cos`, jejíž tvar je ideální pro zamezení vzniku slyšitelného lupance na začátku a konci vzorku. Délka obou hran je 30 ms, tedy 1440 vzorků. Po vynásobení signálu obálkou je vzorek uložen do paměti pomocí funkce `audiowrite`. Do názvu každého vzorku je vložena poloha clicku. Toho je později využito ve vyhodnocování výsledků detekce. V posledním kroku je pomocí funkce `xlswrite` uložen vektor `poznamky` do tabulky Excelu. V této tabulce je uložena pozice clicku, jeho délka a amplituda.

Skripty `runAnalysisAR_1.m` a `runAnalysisAR_2.m` jsou volány pro spuštění testů autoregresivního modelu nebo modelu s `matched` filtrem. Po spuštění jsou nejprve načteny výsledky subjektivních testů. Dále jsou uloženy indexy signálů, které byly většinou posluchačů označeny za chybné a bezchybné. Nejisté vzorky nejsou použity. Poté jsou definovány veškeré parametry detekčních algoritmů. Následuje `for` cyklus, který postupně načítá jednotlivé zvukové vzorky a volá funkce `ARmodel_1` a `ARmodel_2` jejichž výstupem je informace o detekovaných chybách a falešných detekcích. Funkce `ARmodel` jsou volány s jinou hodnotou parametru `isClick` v závislosti na chybnosti vstupního signálu. Do proměnné `clickAR` se postupně ukládají výsledky detekcí a jsou vyhodnoceny dle kritérií popsaných v kapitole 6. Výsledné hodnoty chybovosti jsou uloženy to proměnných `ErrorRate`, `FA` a `total`.

Funkce `ARmodel` mají následující strukturu:

```
[ClickDetection] = ARmodel(stim_in, rad, prah1, prah2, LengthSeg, idxLup, idxTolerance, isClick)
```

- `ClickDetection` je výstupní hodnota určující detekování chyby nebo falešnou detekci
- `stim_in` je vstupní signál
- `rad` je hodnota řádu AR modelu
- `prah1` je hodnota nižšího detekčního prahu
- `prah2` je hodnota vyššího detekčního prahu
- `LengthSeg` je hodnota délky segmentů
- `idxLup` je poloha známých impulzních vad
- `idxTolerance` je tolerance polohy známé impulzní vady
- `isClick` je označení zda vstupní signál obsahuje slyšitelnou chybu

Nejprve funkce zjistí na kolik segmentů o délce `LengthSeg` lze vstupní signál rozdělit a vygeneruje prázdný detekční vektor. Následně se ve `for` cyklu, který rozdělí vstupní signál na segmenty, zavolá

funkce `AR_segment` popř. `matched_segment`. Tato funkce se volá jednou pro dopřednou detekci a poté i pro zpětnou detekci. Výsledek obou detekcí je sečten a zapsán do vektoru `detekce_vys`. V poslední fázi se v závislost na parametru `isClick` a na vektoru `detekce_vys` vyhodnotí, zda byla detekována chyba správně a zda nedošlo k falešné detekci. Funkce `ARmodel_1` vrací pouze jednu hodnotu. Funkce `ARmodel_2` vrací vektor dvou hodnot, z nichž první značí, zda byla chyba detekována správně a druhá zda vznikla falešná detekce.

Skripty `runAnalysisWavelet_1.m` a `runAnalysisWavelet_2.m` jsou analogií ke skriptům `runAnalysisAR_1.m` a `runAnalysisAR_2.m`. Tyto skripty se liší pouze v zadaných parametrech – pro AR model a pro vlnkovou transformaci. Skripty pro AR model také nejprve volají funkce `ARmodel`, která vstupní signál segmentuje, poté teprve volá detekční algoritmus a nakonec vyhodnotí výsledky. Funkce pro vlnkovou transformaci volají přímo detekční algoritmus, který obsahuje vyhodnocení výsledků. Z toho plyne, že se vlnková transformace neprovádí po segmentech, ale analyzuje se přímo celý signál.

## Příloha B: Obsah příloženého CD

- `AR_segment.m` – detekce pomocí autoregresivního modelu [1]
- `matched_segment.m` – detekce pomocí AR modelu s matched filtrem [1]
- `vlnkova_segment_1.m` – detekce pomocí vlnkové transformace pro 1. sadu [1]
- `vlnkova_segment_2.m` – detekce pomocí vlnkové transformace pro 2. sadu [1]
- `runAnalysisAR_1.m` – skript pro spuštění detekce AR i matched modelem pro 1. sadu
- `runAnalysisAR_2.m` – skript pro spuštění detekce AR i matched modelem pro 2. sadu
- `runAnalysisWavelet_1.m` – skript pro spuštění detekce vlnkovou transformací pro 1. sadu
- `runAnalysisWavelet_2.m` – skript pro spuštění detekce vlnkovou transformací pro 2. sadu
- `ARmodel_1.m` – skript pro segmentaci a vyhodnocení AR a matched modelu pro 1. sadu
- `ARmodel_2.m` – skript pro segmentaci a vyhodnocení AR a matched modelu pro 2. sadu
- `Create_faulty_sounds.m` – skript pro vytvoření hudebních vzorků s namodelovanými clicky
- `Poznámky.xls` – tabulka Excelu obsahující informace o poloze, amplitudě a délce modelovaných clicků
- `Popisy_priciny_a_projevy_vad.ods` – dokument popisující vady gramofonových desek [3]
- 1. sada – složka obsahující zvukové vzorky použité pro testování [3]
- 2. sada – složka obsahující zvukové vzorky použité pro testování
- `SubjTestResults` – složka obsahující výsledky poslechových testů na první sadě vzorků
- `Subjective_results` – složka obsahující výsledky poslechových testů na druhé sadě vzorků