

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

BAKALÁŘSKÁ PRÁCE

Brno, 2020

Matúš Soboňa



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

RESTAURACE POŠKOZENÝCH ZVUKOVÝCH SIGNÁLŮ S VYUŽITÍM AUTOREGRESNÍCH MODELŮ

RESTORATION OF DAMAGED AUDIO SIGNALS USING AUTOREGRESSIVE MODELS

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Matúš Soboňa

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Ondřej Mokrý

BRNO 2020

Bakalářská práce

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

Student: Matuš Soboňa

ID: 203630

Ročník: 3

Akademický rok: 2019/20

NÁZEV TÉMATU:

Restaurace poškozených zvukových signálů s využitím autoregresních modelů

POKYNY PRO VYPRACOVÁNÍ:

Student se seznámí s modely znehodnocení zvukového signálu a s problematikou restaurace zvukových signálů. Podrobněji se zaměří na znehodnocení výpadkem vzorků. Student se seznámí rovněž s konceptem modelování znělých částí signálu jako autoregresního procesu (tj. IIR filtru). Související metody pro doplnění chybějících vzorků poté implementuje v MATLABu a otestuje na simulovaných signálech i reálných nahrávkách, zejména s cílem vzájemného porovnání metod a analýzy jejich závislosti na parametrech. Výstupem práce budou jednak výsledky objektivního srovnávání (SNR, PEMO-Q), jednak subjektivní hodnocení kvality rekonstrukce studentem.

DOPORUČENÁ LITERATURA:

[1] ADLER, Amir, Valentin EMIYA, Maria G. JAFARI, Michael ELAD, Rémi GRIBONVAL a Mark D. PLUMBLEY. Audio Inpainting. IEEE Transactions on Audio, Speech, and Language Processing. 2012. Dostupné z: <http://ieeexplore.ieee.org/document/6020748/>

[2] ETTER, Walter. Restoration of a discrete-time signal segment by interpolation based on the left-sided and right-sided autoregressive parameters. IEEE Transactions on Signal Processing. 1996. Dostupné z: <http://ieeexplore.ieee.org/document/502326/>

Termín zadání: 3.2.2020

Termín odevzdání: 8.6.2020

Vedoucí práce: Ing. Ondřej Mokřý

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

Bakalárska práca sa týka problematiky rekonštrukcie zvukových signálov s využitím autoregresných modelov, ktoré boli poškodené výpadkom vzoriek. Samotná rekonštrukcia je riešená pomocou algoritmov W. Etter a A. Janssen. Tieto algoritmy sú implementované v MATLABe, otestované na simulovaných signáloch a reálnych nahrávkach a následne je porovnaná kvalita rekonštrukcie v závislosti na rôznych parametroch signálu.

KLÚČOVÉ SLOVÁ

audio signál, autoregresný model, doplnenie vzoriek, digitálne spracovanie signálu, extrapolácia, interpolácia.

ABSTRACT

The bachelor thesis deals with the problem of restoring audio signals damaged by sample loss, using autoregressive models. The restoration itself is solved by W. Etter and A. Janssen's algorithms. These algorithms are implemented in MATLAB and tested on artificial signals as well as on real recordings. Algorithms are then compared based on quality of restoration dependent on different parameters of signals.

KEYWORDS

audio signal, autoregressive model, audio inpainting, digital signal processing, extrapolation, interpolation.

SOBOŇA, Matúš. *Restaurace poškozených audiosignálů s využitím autoregresních modelů*. Brno, Rok, 57 s. Bakalárska práca. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav telekomunikací. Vedúci práce: Ing. Ondřej Mokrý,

VYHLÁSENIE

Vyhlasujem, že svoju bakalársku prácu na tému „Restaurovanie poškodených audiosignálov s využitím autoregresných modelů“ som vypracoval samostatne pod vedením vedúceho bakalárskej práce, s využitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na konci práce.

Ako autor uvedenej bakalárskej práce ďalej vyhlasujem, že v súvislosti s vytvorením tejto bakalárskej práce som neporušil autorské práva tretích osôb, najmä som nezasiahol nedovoleným spôsobom do cudzích autorských práv osobnostných a/alebo majetkových a som si plne vedomý následkov porušenia ustanovenia § 11 a nasledujúcich autorského zákona Českej republiky č. 121/2000 Sb., o práve autorskom, o právach súvisiacich s právom autorským a o zmene niektorých zákonov (autorský zákon), v znení neskorších predpisov, vrátane možných trestnoprávných dôsledkov vyplývajúcich z ustanovenia časti druhej, hlavy VI. diel 4 Trestného zákonníka Českej republiky č. 40/2009 Sb.

Brno

.....

podpis autora

POĎAKOVANIE

Rád by som poďakoval vedúcemu bakalárskej práce pánovi Ing. Mokrému O. za odborné vedenie, konzultáciu, rady a návrhy k práci a taktiež veľkú trpezlivosť.

Obsah

1	Úvod	15
2	Značenie	17
2.1	Označenie pôvodného poškodeného signálu	17
2.2	Označenie zrekonštruovaného signálu	18
2.3	Popis a značenie autoregresného modelu	18
2.4	Autokorelačná funkcia a Yule–Walkerove rovnice	19
2.5	Definícia odstavu signálu od šumu	19
3	Doplňovanie chýbajúcich vzoriek audiosignálu	21
3.1	Bližší popis problému	21
3.2	Extrapolácia/Interpolácia signálu	21
3.2.1	Extrapolácia signálu podľa algoritmu W. Ettera	21
3.2.2	Interpolácia signálu podľa algoritmu A. Janssená	23
4	Experimenty spojené s doplnovaním vzoriek	27
4.1	Závislosť kvality rekonštrukcie na parametroch signálu	27
4.1.1	Testovanie signálov sínusového charakteru	27
4.1.2	Testovanie simulovaného AR procesu	33
4.1.3	Testovanie reálnych nahrávok	33
4.2	Testovanie algoritmu A. Janssená	37
4.2.1	Rýchlosť výpočtu algoritmu	37
4.2.2	Kvalita rekonštrukcie a iterácie algoritmu	39
4.2.3	Testovanie Janssenovho algoritmu	39
5	Záver	49
	Literatúra	51
	Zoznam symbolov, veličín a skratiek	53
	Zoznam príloh	55
A	Obsah priloženého .zip súboru	57

Zoznam obrázkov

3.1	Grafická reprezentácia chýbajúceho úseku	21
3.2	Grafická reprezentácia funkcií raised-cosine	22
4.1	Výsledky pre jeden sínusový signál (Etter)	28
4.2	Výsledky pre súčet dvoch sínusových signálov (Etter)	29
4.3	Výsledky pre súčet štyroch sínusových signálov (Etter)	30
4.4	Výsledky pre súčet ôsmich sínusových signálov (Etter)	31
4.5	Výsledky pre súčet šestnástich sínusových signálov (Etter)	32
4.6	Výsledky pre simulovaný AR proces (Etter)	34
4.7	Výsledky pre rekonštrukciu ľudskej reči (Etter)	35
4.8	Výsledky pre rekonštrukciu hudobného diela (Etter)	36
4.9	Výsledky pre rýchlosť výpočtu algoritmu	38
4.10	Kvalita rekonštrukcie a iterácie algoritmu	40
4.11	Výsledky pre jeden sínusový signál (Janssen)	41
4.12	Výsledky pre súčet dvoch sínusových signálov (Janssen)	42
4.13	Výsledky pre súčet štyroch sínusových signálov (Janssen)	43
4.14	Výsledky pre súčet ôsmich sínusových signálov (Janssen)	44
4.15	Výsledky pre súčet šestnástich sínusových signálov (Janssen)	45
4.16	Výsledky pre simulovaný AR proces (Janssen)	46
4.17	Výsledky pre rekonštrukciu ľudskej reči (Janssen)	47
4.18	Výsledky pre rekonštrukciu hudobného diela (Janssen)	48

1 Úvod

V dnešnej digitálnej dobe sa každodenne stretávame s prenosom audio signálov rôznymi médiami.

Tento proces ale nie je dokonalý a veľmi často sa stáva, že je daný signál poškodený a nie je možné ho spracúvať ďalej. Existujú rôzne formy znehodnotenia signálu. Jednou z foriem poškodenia je skreslenie signálu pričítaním náhodného šumu zo zvukového zariadenia alebo hluku prostredia k signálu. Ďalej môže nastať saturácia, teda orezanie špičiek zvukového signálu, ktorá nastáva ak vzorky signálu prekročia dynamický rozsah zvukového zariadenia, ktorý obmedzuje amplitúdu daného signálu. Rekonštrukcie takto poškodených signálov sa v anglickej literatúre označujú ako *denoising* resp. *declipping*. Poslednou veľmi častou formou znehodnotenia signálu je výpadok vzoriek. Riešením tohto znehodnotenia je doplnenie chýbajúcich vzoriek (problematika rekonštrukcie audiosignálu pomocou dopĺňovania chýbajúcich úsekov sa v anglickej literatúre označuje ako *audio inpainting* [4]). Hoci sa touto problematikou zaoberá vedecká komunita od 80. rokov minulého storočia [3], stále vznikajú nové metódy rekonštrukcie poškodených signálov. V tejto práci sa budeme venovať práve dopĺňovaním chýbajúcich vzoriek pomocou algoritmov, ktoré boli uvedené v článkoch [2], [5], [6]. Základom týchto algoritmov je modelovanie poškodeného signálu ako autoregresného procesu. To nám umožňuje predpovedať chýbajúce vzorky na základe predchádzajúcich hodnôt. Tieto algoritmy implementujeme v MATLABe a otestujeme ho na na simulovaných signáloch areálnych nahrávkach.

Riešenie problému bakalárskej práce je uvedené v kapitolách 2 až 4. V druhej kapitole sú uvedené značenia využívané v bakalárskej práci. V kapitole tretej je riešená problematika extrapolácie a interpolácie signálu a taktiež modelovanie signálu ako autoregresného procesu. Následne sú v tejto kapitole uvedené algoritmy, pomocou ktorých je riešené doplnenie chýbajúcich vzoriek. Štvrtá kapitola sa venuje rekonštrukciám konkrétnych signálov pomocou uvedených algoritmov a je v nej vyhodnotená kvalita rekonštrukcie signálov.

2 Značenie

V tejto kapitole definujeme značenie spojené s doplnovaním chýbajúcich vzoriek pomocou autoregresného modelu a taktiež so spracovaním signálov.

2.1 Označenie pôvodného poškodeného signálu

Na to, aby sme mohli úspešne doplniť chýbajúce vzorky, musíme najprv definovať značenie pre signál, u ktorého tento výpadok nastal.

Definícia 1. *Definujme signál $x(i)$:*

$$\{x(1), x(2), x(3) \dots, x(N)\}, \quad (2.1)$$

ktorého M vzoriek

$$\{x(l), x(l+1), \dots, x(l+M-1)\}. \quad (2.2)$$

považujeme za chýbajúce. Tento chýbajúci úsek dĺžky M budeme označovať ako diera.

Definícia 2. *Množiny $T \subset \{1, \dots, N\}$ a $\tilde{T} \subset \{1, \dots, N\}$ budú označovať indexy s chýbajúcimi resp. známymi vzorkami a platí $\{1, \dots, N\} = T \cup \tilde{T}$, T a \tilde{T} sú disjunktné.*

Predikcia poškodených vzoriek bude v algoritme W. Ettera [5] založená na vyčíslení parametrov zo vzoriek, ktoré predchádzajú diere a zo vzoriek, ktoré budú v čase nasledovať po diere. Preto taktiež zavádzame nasledujúce značenie.

Definícia 3. *Označme počet vzoriek ľavého okolia diery ako N_L a počet pravého okolia ako N_R . Signál $x_L(i)$ potom definujeme ako*

$$\{x(l-N_L), \dots, x(l-2), x(l-1)\} \quad (2.3)$$

a signál $x_R(i)$ ako:

$$\{x(l+M), x(l+M+1), \dots, x(l+M+N_R-1)\}. \quad (2.4)$$

Predpokladáme, že okolie diery nepresahuje hranice signálu:

$$(l-N_L \geq 1) \wedge (l+M+N_R \leq N). \quad (2.5)$$

2.2 Označenie zrekonštruovaného signálu

Ďalej označme signál, ktorého chýbajúce vzorky boli doplnené Etterovým algoritmom ako $\hat{x}(i)$.

Časť signálu, ktorého vzorky boli odhadnuté z ľavého okolia diery označme ako $\hat{x}_L(i)$ a časť odhadnutú z pravého okolia ako $\hat{x}_R(i)$.

Na úsekoch $\hat{x}_L(i)$ a $\hat{x}_R(i)$ budeme musieť po doplnení vzoriek vykonať vážený priemer pomocou funkcií, ktoré budeme označovať pre ľavé okolie diery ako $\omega_{L,M}(i)$ a pre pravé okolie diery ako $\omega_{R,M}(i)$. Tieto funkcie splňujú v mieste diery podmienku

$$\omega_{L,M}(i) + \omega_{R,M}(i) = 1, \quad i = 0, \dots, M - 1$$

a sú bližšie definované v sekcii 3.2.1. Vykonaním váženého priemeru následne definujeme signál $\hat{x}(i)$ ako

$$\hat{x}(i) = \omega_{L,M}(i - l) \cdot \hat{x}_L(i) + \omega_{R,M}(i - l) \cdot \hat{x}_R(i), \quad l \leq i < l + M. \quad (2.6)$$

2.3 Popis a značenie autoregresného modelu

V tejto sekcii popíšeme jednotlivé značenie autoregresného modelu (ďalej AR).

Definícia 4. *Autoregresný model signálu $x(i)$ je definovaný ako:*

$$x(i) = \sum_{j=1}^p a(j) \cdot x(i - j) + u(i), \quad p \in \mathbb{N}, a \in \mathbb{R}^p, \quad (2.7)$$

kde p je rád AR modelu, a sú koeficienty AR modelu a $u(i)$ je chýbový člen, ktorý je v spracovaní signálov reprezentovaný bielym šumom.

V kapitole 4 budeme modelovať signál x pomocou koeficientov a , ktoré sú rádu p . Modelovanie signálu ako autoregresného procesu vychádza vlastností AR procesov, ktoré umožňujú veľmi dobrú reprezentáciu harmonického zloženia ľudskej reči a hudobných signálov [9]. Je to práve prítomnosť harmonických zložiek, ktorá nám umožňuje doplniť chýbajúce vzorky s minimálnou odchýlkou.

Ešte predtým než prejdeme k samotnému doplneniu vzoriek, musí daný signál splňovať niekoľko zásadných podmienok.

Chýbajúce vzorky sa musia vyskytovať v krátkych úsekoch, ako to môžeme vidieť na obrázku 3.1 a nebudú náhodne rozmiestnené medzi známymi vzorkami. Signál tiež musí byť modelovateľný ako AR proces konečného rádu a doplnenie vzoriek musí byť vykonané tak, aby zrekonštruovaný signál vyhovoval AR modelu čo najlepšie.

2.4 Autokorelačná funkcia a Yule–Walkerove rovnice

Na výpočet koeficientov autoregresného modelu a využívame v sekcii 3.2.2 vzťahu AR koeficientami signálu a autokorelačnou funkciou, ktorá je definovaná ako:

$$R(\tau) = E[x(i) x(i - \tau)]. \quad (2.8)$$

Úpravou tejto rovnice s využitím definície autoregresného modelu 2.7 získame:

$$\begin{aligned} R(\tau) &= E \left[x(i) \left(\sum_{l=1}^p a(l) x(k - l - \tau) + u(i - \tau) \right) \right] \\ &= - \sum_{l=1}^p a(l) R(\tau - l) + E[x(i) u(i + \tau)]. \end{aligned} \quad (2.9)$$

Z rovníc 2.7 a 2.9 s využitím vlastnosti autokorelačnej funkcie $R(-\tau) = R(\tau)$ nakoniec získame:

$$\begin{bmatrix} \hat{R}(0) & \hat{R}(1) & \cdots & \hat{R}(p-1) \\ \hat{R}(1) & \hat{R}(0) & \cdots & \hat{R}(p-2) \\ \vdots & \vdots & \ddots & \vdots \\ \hat{R}(p-1) & \hat{R}(p-2) & \cdots & \hat{R}(0) \end{bmatrix} \cdot \begin{bmatrix} 1 \\ a_1 \\ \vdots \\ a_p \end{bmatrix} = - \begin{bmatrix} \sigma^2 \\ 0 \\ \vdots \\ 0 \end{bmatrix}. \quad (2.10)$$

Táto sústava rovníc je charakteristická pre autoregresné procesy a nazývame ju Yule–Walkerove rovnice.

2.5 Definícia odstupú signálu od šumu

V tejto sekcii definujeme veličinu odstup signálu od šumu (ďalej SNR), ktorú budeme používať na ohodnotenie kvality rekonštrukcie signálu. SNR je definovaná nasledovne:

$$\text{SNR}(x, \hat{x}) = 10 \cdot \log_{10} \frac{\|x\|_2^2}{\|x - \hat{x}\|_2^2} \quad [\text{dB}].$$

Je nutné poznamenať, že testované signály budú porovnávané len na úseku, ktorý bol poškodený resp. zrekonštruovaný a to kvôli totožnosti signálov mimo tohto úseku. Taktiež vyššia hodnota SNR indikuje presnejšiu rekonštrukciu.


3 Dopĺňovanie chýbajúcich vzoriek audiosig-nálu

Pri riešení tohto problému budeme uvažovať audiosignál, ktorý obsahuje úsek známej pozície, v ktorom nepoznáme hodnoty vzoriek.

Naším cieľom bude následne vyplniť túto dieru vzorkami, ktoré budú čo najvernejšie odpovedať nepoškodenému signálu.

K dosiahnutiu čo najpresnejších výsledkov využijeme dva algoritmy založené na interpolácii resp. extrapolácii poškodeného signálu.

3.1 Bližší popis problému



Obr. 3.1: Grafická reprezentácia chýbajúceho úseku

3.2 Extrapolácia/Interpolácia signálu

V tejto sekcii sa budeme venovať interpolácii a extrapolácii. Tieto matematické modely nám umožňujú odhadnúť hodnoty ľubovoľného rádu čísiel na základe predchádzajúcich dát. Rozdiel medzi nimi je v pozícií hodnôt, pri interpolácii odhadujeme hodnoty, ktoré sa nachádzajú v známom číselnom rozpätí (tj. medzi hodnotami, ktoré sú nám známe) zatiaľ čo pri extrapolácii využívame na odhad dáta, ktoré sa nachádzajú pred alebo za neznámymi hodnotami.

3.2.1 Extrapolácia signálu podľa algoritmu W. Eterra

Je nutné poznamenať, že pri použití extrapolácie musíme počítať s tým, že odchýlka od reálnych dát rastie s dĺžkou extrapolovaného úseku.

Preto budeme pre doplnenie vzoriek kombinovať extrapoláciu signálu z ľavého a pravého okolia diery. Týmto spôsobom docielime toho, že doplnený úsek bude prirodzene nadväzovať na ľavé a pravé okolie diery. Navyše vzorky, ktoré sa nachádzajú v strede diery a sú z hľadiska extrapolácie najďalej „vyhladiť“ pomocou váhovej funkcie v snahe znížiť chybu rekonštrukcie.

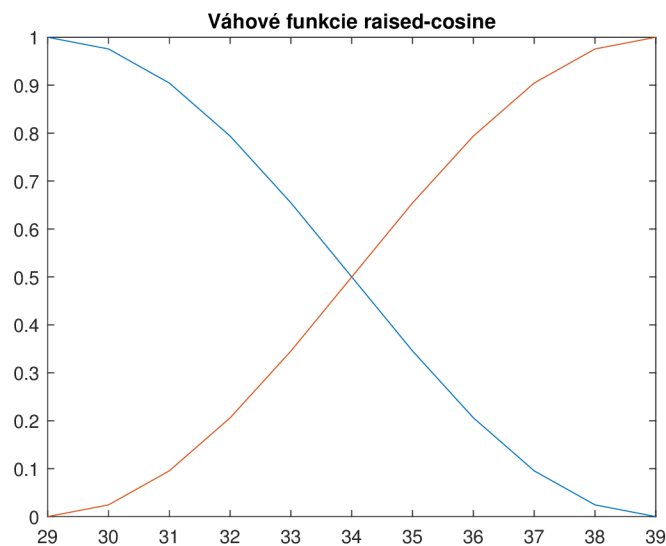
Upresnenie Etterovej metódy

Signálu $x(i)$, ktorý bol definovaný vzťahom 2.2 budeme doplňovať chýbajúce vzorky do diery dĺžky M pomocou vzoriek $x_L(i)$ a $x_R(i)$ z ľavého resp. pravého okolia diery. Týmto postupom sa dopracujeme k signálom $\hat{x}_L(i)$ a $\hat{x}_R(i)$, ktoré sú definované v sekcii 2.2 a ktoré následne vážene spriemerujeme pomocou funkcií $\omega_{L,M}(i)$ resp. $\omega_{R,M}(i)$. V rovnici 2.6 k súčtu využívame vážené funkcie raised cosine, ktoré boli uvedené v článku [5] od W. Etter a sú definované nasledovne:

$$\omega_{L,M}(i) = \begin{cases} \frac{1}{2}(1 - \cos(2\pi\frac{M+i}{2\cdot M})), & \text{ak } 0 \leq i < M \\ 0, & \text{ostatné} \end{cases}$$

a

$$\omega_{R,M}(i) = \begin{cases} \frac{1}{2}(1 - \cos(2\pi\frac{i}{2\cdot M})), & \text{ak } 0 \leq i < M \\ 0, & \text{ostatné.} \end{cases}$$



Obr. 3.2: Grafická reprezentácia funkcií raised-cosine

Týmto spôsobom by sme mali docieľiť rekonštrukciu znehodnoteného signálu s uspokojivou presnosťou. Ďalej sa presunieme k návrhu samotného algoritmu.

Návrh algoritmu

input : časti signálu $x_L(i)$ a $x_R(i)$ z ľavého resp. pravého okolia diery, rád AR procesu p , začiatok a koniec chýbajúceho úseku

output: zrekonštruovaný signál $\hat{x}(i)$

- 1 vypočítaj koeficienty a AR modelu pomocou funkcie **arburg** pre ľavé okolie diery;
- 2 z AR koeficientov a signálu $x_L(i)$ urči pomocou funkcie **filter** počiatkové podmienky zf pre filtráciu;
- 3 odhadni signál $\hat{x}_L(i)$ IIR filtráciou pomocou funkcie **filter**;
- 4 otoč signál $x_R(i)$ funkciou **flip** v zmysle časovej osi;
- 5 vypočítaj koeficienty a AR modelu pre pravé okolie diery ;
- 6 z AR koeficientov a signálu $x_R(i)$ urči počiatkové podmienky zf pre filtráciu;
- 7 odhadni signál $\hat{x}_R(i)$ IIR filtráciou;
- 8 otoč odhadnutý signál $\hat{x}_R(i)$ v zmysle časovej osi;
- 9 vykonaj vážený priemer signálov $\hat{x}_L(i)$ a $\hat{x}_R(i)$ podľa rovnice 2.6;

Algoritmus 1: Algoritmus doplnenia vzoriek podľa W. Ettera

3.2.2 Interpolácia signálu podľa algoritmu A. Janssen

Pri Janssenovom algoritme budeme taktiež pracovať so signálom $x(i)$ (2.2), ktorého chýbajúce vzorky M sú na známej pozícií.

V tomto prípade nebudeme signál $x(i)$ rozdeľovať na ľavú a pravú časť diery a na výpočet koeficientov autoregresného modelu a použijeme vzorky z celého signálu $x(T)$, $x(\tilde{T})$ s obmedzenou dĺžkou kontextu a príslušný rád autoregresného modelu p . Pomocou nepoškodených vzoriek $x(\tilde{T})$, rádu p a koeficientov a následne dopočítame chýbajúce vzorky tak aby čo najlepšie vyhovovali autoregresnému modelu. Týmto spôsobom bude efektívne minimalizovaná podmienka:

$$Q(a, x) = \sum_{k=p+1}^M \left| x(k) + \sum_{l=1}^p a(l) \cdot x(k-l) \right|^2 = \sum_{k=p+1}^M |u(k)|^2. \quad (3.1)$$

Uspokojivé výsledky dosiahneme opakovaním tohto procesu, čo z neho robí iteratívny algoritmus.

Vyčíslenie koeficientov autoregresného modelu

K vyčísleniu koeficientov a použijeme autokorelačnú metódu z článku [6], ktorá využíva vzťah medzi koeficientami autoregresného modelu a autokorelačnou funkciou,

ktorú sme vyjadrili v sekcii 2.4 ako Yule–Walkerove rovnice. Metóda je založená na odhade autokorelačnej funkcie:

$$\hat{R}(\tau) = \frac{1}{M} \sum_{k=\tau+1}^M x(k) \cdot x(k - \tau) \quad (3.2)$$

pomocou, ktorej môžeme upraviť rovnicu 3.1 do maticového tvaru:

$$\begin{bmatrix} \hat{R}(0) & \hat{R}(1) & \cdots & \hat{R}(p-1) \\ \hat{R}(1) & \hat{R}(0) & \cdots & \hat{R}(p-2) \\ \vdots & \vdots & \ddots & \vdots \\ \hat{R}(p-1) & \hat{R}(p-2) & \cdots & \hat{R}(0) \end{bmatrix} \cdot \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix} = - \begin{bmatrix} \hat{R}(1) \\ \hat{R}(2) \\ \vdots \\ \hat{R}(p) \end{bmatrix}. \quad (3.3)$$

Na riešenie tejto sústavy rovníc a následné vyčíslenie koeficientov a použijeme funkciu `aryule`, ktorá je súčasťou Signal Processing Toolbox v MATLABe.

Výčíslenie chýbajúcich vzoriek

Koeficienty autoregresného modelu a použijeme na vyčíslenie chýbajúcich vzoriek tak aby sme minimalizovali podmienku $Q(a, x)$ zo vzťahu (3.1), ktorú môžeme upraviť nasledovne:

$$Q(a, x) = x(T)^\top \mathbf{B} x(T) + 2x(T)^\top \mathbf{d} + \Gamma(x(\tilde{T})), \quad (3.4)$$

kde \mathbf{B} reprezentuje závislosti medzi neznámymi vzorkami, \mathbf{d} spája závislosti známych a neznámych vzoriek a $\Gamma(x(\tilde{T}))$ je člen, ktorý závisí od $x(\tilde{T})$. Riešenie minimalizačnej úlohy (3.4):

$$\mathbf{B} x(T) = -\mathbf{d}. \quad (3.5)$$

Autori Janssen [2] a Oudre [6] uviedli vo svojich článkoch rôzne spôsoby vyčíslenia vektoru a matice \mathbf{d} resp. \mathbf{B} . Jednotlivé rovnice budú z hľadiska rýchlosti výpočtu porovnané v kapitole týkajúcej sa experimentov a na samotné doplnenie vzoriek bude použitá najrýchlejšia metóda. Vektor \mathbf{d} bol definovaný:

$$\forall t \in T \quad d(t) = \sum_{\substack{-p \leq k \leq p \\ t-k \in \tilde{T}}} b(|k|) x(t - k) \quad (3.6)$$

alebo:

$$d = \sum_{-k}^k b(k) x(t(i) - k) \quad (3.7)$$

kde:

$$b_{|k|} = \sum_{j=0}^p a(j) a(j + k) \quad (3.8)$$

a matica \mathbf{B} :

$$\forall (t, t') \in T^2 \quad b_{t,t'} = \begin{cases} \sum_{l=0}^{p-|t-t'|} a(l) a(l + |t - t'|) & \text{ak } 0 \leq |t - t'| \leq p \\ 0, & \text{ostatné} \end{cases} \quad (3.9)$$

alebo:

$$B(a) = A^T A, \quad (3.10)$$

kde A je $t(M) - t(1) + p + 1 \times M$ matica definovaná ako:

$$A(i, j) = a(j, i) = a(t(j) - i - t(1) + p + 1). \quad (3.11)$$

Vyriešením rovnice 3.5 získame hodnoty chýbajúcich vzoriek, ktoré doplníme na známú pozíciu diery a tak zrekonštruujeme poškodený signál. Ďalej sa presunieme na algoritmizáciu popísaného problému.

Algoritmizácia problému

input : signál $x(i)$, rád AR procesu p , začiatok a koniec chýbajúceho úseku

output: zrekonštruovaný signál $\hat{x}(i)$

- 1 vypočítaj koeficienty a AR modelu signálu $x(i)$ pomocou funkcie `aryule`;
- 2 z AR koeficientov vypočítaj hodnoty vektoru a matice \mathbf{d} resp. \mathbf{B} ;
- 3 vyrieš rovnicu 3.5;
- 4 doplň chýbajúce vzorky $x(T)$ na miesto diery;
- 5 kroky 1 až 4 opakuj dokým nie je rekonštrukcia uspojivá

Algoritmus 2: Algoritmus doplnenia vzoriek podľa A. Janssena

4 Experimenty spojené s doplnovaním vzoriek

V tejto kapitole sa budeme venovať testovaniu algoritmov s cieľom dosiahnutia čo najlepších výsledkov pri rekonštrukcii poškodeného signálu.

4.1 Závislosť kvality rekonštrukcie na parametroch signálu


Pred uvedením výsledkov zo samotných experimentov si musíme stanoviť podmienky potrebné k ich prevedeniu, ktoré sa týkajú charakteru testovaných signálov, dĺžky diery a kontextu, z ktorého budú vyčísľované koeficienty a . Postupne budeme testovať doplnenie vzoriek pre rôzne signály, od jednoduchej sínusoidy a simulovaného AR procesu cez signály vytvorené súčtom niekoľkých sínusoid až po rekonštrukciu reálnej nahrávky. Kvalitu rekonštrukcie poškodeného signálu budeme testovať vynesím závislosti pomeru signálu k šumu SNR na veľkosti rádu modelu p , na počte chýbajúcich vzoriek a taktiež na dĺžke kontextu, z ktorej budú koeficienty vyčísľované. Pri metóde A. Janssena navyše vynesieme závislosť SNR na počte iterácií algoritmu. Týmto spôsobom otestujeme oba algoritmy a výsledky následne porovnáme. Všetky testované signály budú dĺžky 264600 vzoriek čo odpovedá dĺžke 6 s pri vzorkovacej frekvencii 44,1 kHz. Dĺžka diery bude premenlivá od 5 ms po 50 ms a jej začiatok sa bude nachádzať na 80000 vzorke. Testovaný rád modelu bude od $p = 1$ po $p = 1000$. Koeficienty AR modelu a budú vyčíslené s využitím kontextu od 23 ms po 113 ms.

4.1.1 Testovanie signálov sínusového charakteru


V tejto časti budeme testovať sínusové signály, vynesieme závislosť SNR na ráde AR modelu p a dĺžke kontextu pre premennú dĺžku diery $M = 5, 15, 25, 30, 40, 50$ ms. Budeme využívať 5 sínusových signálov, ktoré budú postupne naberať na zložitosti tým, že ich vždy sčítame s ďalším sínusoidami.

Jednotlivé vzorky budeme značiť nasledovne:


- (i) $x_1(n) = \sin(\frac{1}{32}\pi n)$,
- (ii) $x_2(n) = x_1(n) + \sin(\frac{1}{16}\pi n)$,
- (iii) $x_3(n) = x_2(n) + \sin(\frac{1}{8}\pi n) + \sin(\frac{5}{16}\pi n)$,
- (iv) $x_4(n) = x_3(n) + \sin(\frac{12}{17}\pi n) + \sin(\frac{9}{16}\pi n) + \sin(\frac{1}{5}\pi n) + \sin(\frac{1}{3}\pi n)$,
- (v) $x_5(n) = x_4(n) + \sin(\frac{1}{32}\pi n) + \sin(\frac{1}{16}\pi n) + \sin(\frac{1}{8}\pi n) + \sin(\frac{44}{77}\pi n) + \sin(\frac{18}{21}\pi n) + \sin(\frac{9}{16}\pi n) + \sin(\frac{5}{51}\pi n) + \sin(\frac{25}{24}\pi n)$.




(a)




(b)




(c)



(d)

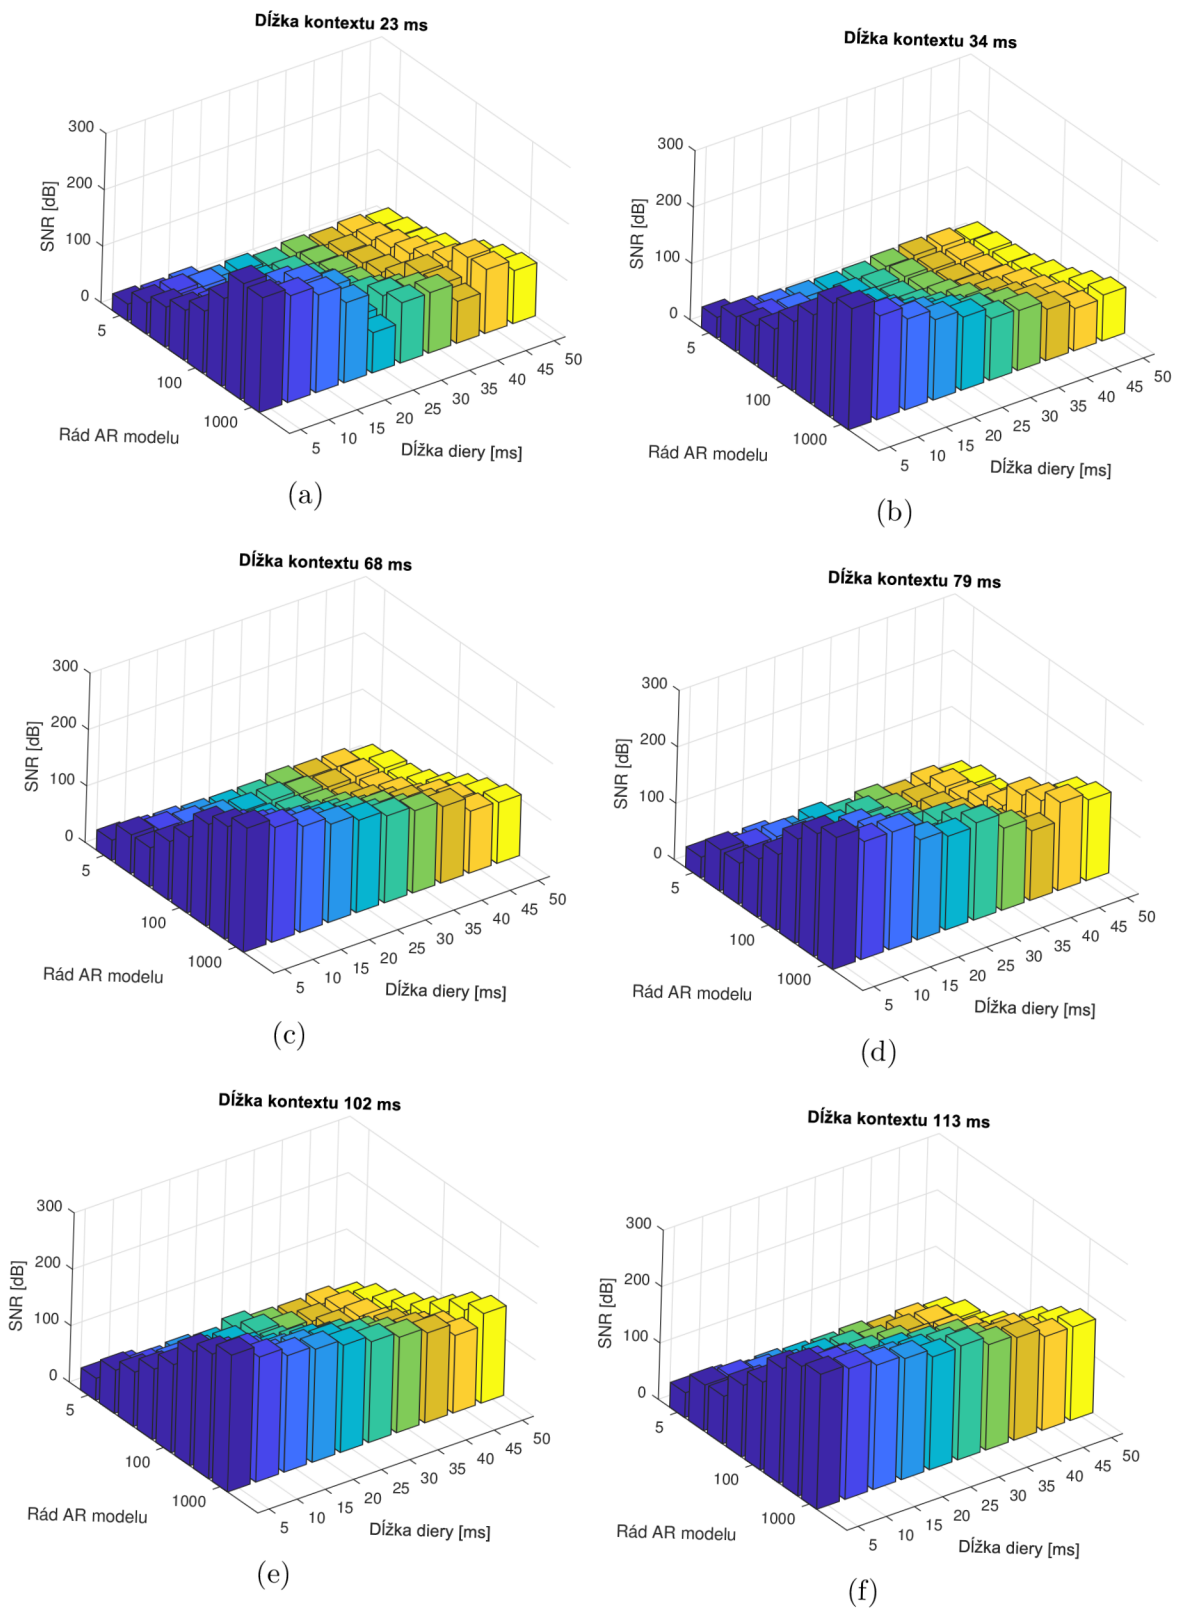


(e)



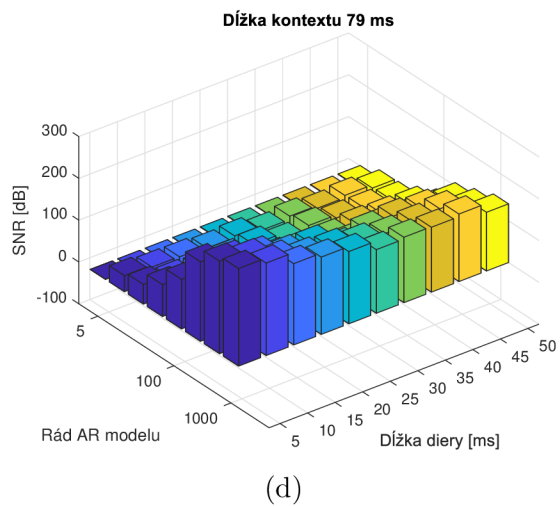





(f)



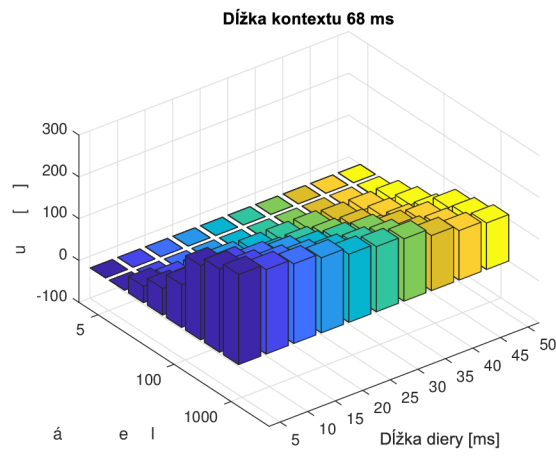
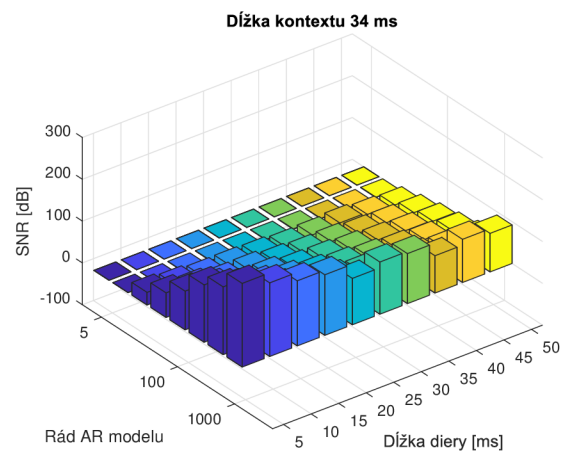
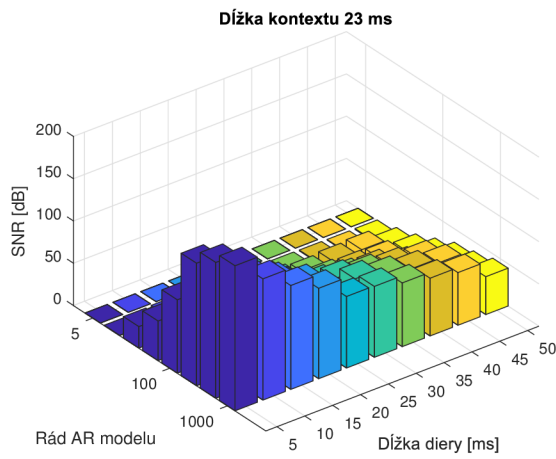
Obr. 4.1: Výsledky pre jeden sínusový signál (Etter)





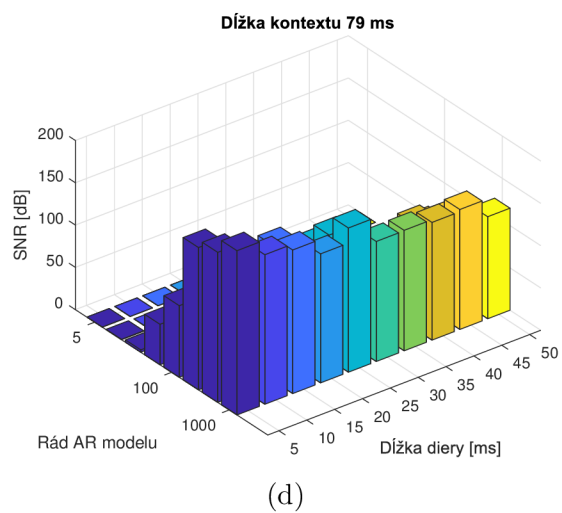
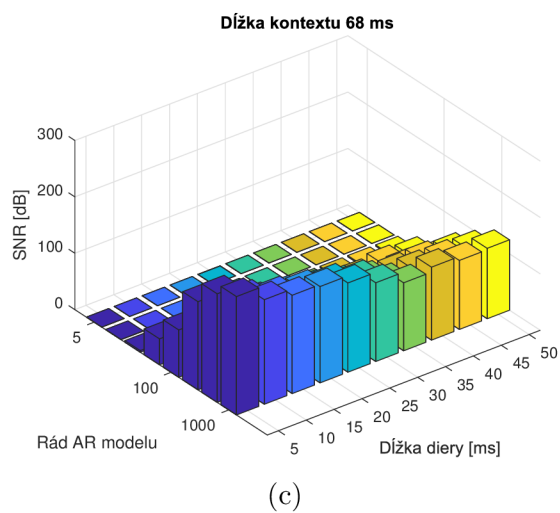


Obr. 4.2: Výsledky pre súčet dvoch sínusových signálov (Etter)



Obr. 4.3: Výsledky pre súčet štyroch sínusových signálov (Etter)



Obr. 4.4: Výsledky pre súčet ôsmich sínusových signálov (Etter)



Obr. 4.5: Výsledky pre súčet šestnástich sínusových signálov (Etter)

Posúdenie experimentov

Z výsledku experimentov je zrejmých niekoľko skutočností. S istotou môžeme povedať, že čím viac nabera signál na zložitosti tým je kvalita rekonštrukcie horšia čo sa odráža na nižšej hodnote SNR. Taktiež môžeme z grafov usúdiť, že kvalita rekonštrukcie je pre toto nastavenie vo väčšine prípadov najlepšia pri hodnote rádu AR modelu $p = 1000$ a pri dĺžke diery 5 ms. Kvalita rekonštrukcie vo všeobecnosti klesá s dĺžkou diery a rastie s rastom AR modelu. Ďalej je z výsledkov zrejmé, že pre zložitejšie signály (v), (iv) je hodnota SNR ≈ 0 pre nízky rád modelu $p < 50$. Z týchto výsledkov môžeme predpokladať, že pre reálne signály sa kvalita rekonštrukcie bude podobáť súčtu šestnástich sínusových signálov (v).

4.1.2 Testovanie simulovaného AR procesu


V tejto sekcii sú na obrázku 4.6 uvedené výsledky experimentov pre simulovaný AR proces 21. rádu.

4.1.3 Testovanie reálnych nahrávok


V tejto sekcii otestujeme kvalitu rekonštrukcie pre signál ľudskej reči [7] a signál hudobného diela [1]. Nahrávky ľudskej reči bola vybraná z databázy WikiCommons pod licenciou Creative Commons Attribution a nahrávka hudby je z verejnej databázy EBUM SQAM. Obe nahrávky sú vo formáte .WAV o vzorkovacej frekvencii 44,1 kHz a pre zjednodušenie boli zredukované na jeden mono kanál. Výsledky sú uvedené na obrázkoch 4.7 resp. 4.8.

Posúdenie experimentov na reálnych nahrávkach


Po vykonaní experimentov sa ukázalo, že nízky rád AR modelu ($p < 100$) nie je postačujúci na uspokojujúcu rekonštrukciu reálnych signálov. Taktiež si môžeme všimnúť, že Etterov algoritmus dosahuje lepšie výsledky rekonštrukcie pre signál ľudskej reči ako signál hudobného diela.




(a)



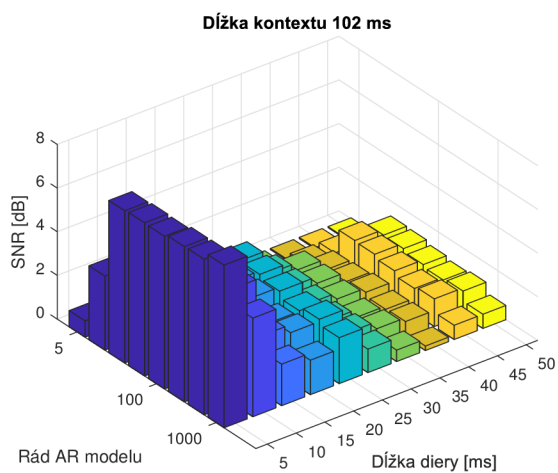
(b)



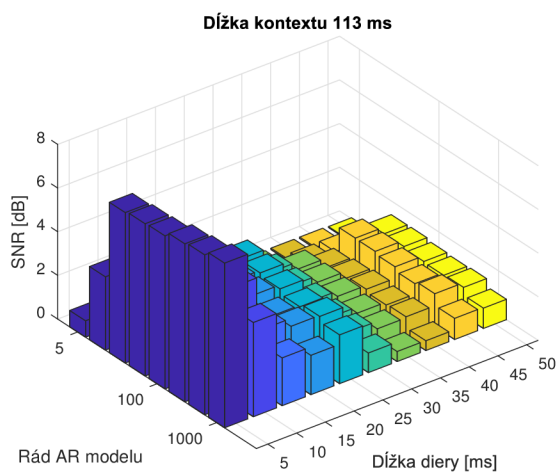
(c)



(d)




(e)




(f)


Obr. 4.6: Výsledky pre simulovaný AR proces (Etter)




(a)




(b)




(c)



(d)




(e)




(f)


Obr. 4.7: Výsledky pre rekonštrukciu ľudskej reči (Etter)




(a)




(b)




(c)



(d)



(e)



(f)

Obr. 4.8: Výsledky pre rekonštrukciu hudobného diela (Etter)

4.2 Testovanie algoritmu A. Janssen

V tejto sekcii budú uvedené všetky experimenty týkajúce sa Janssenovho algoritmu. Najskôr bude porovnaná rýchlosť výpočtu rovnice 3.5 s využitím rozdielnych spôsobov výpočtu vektoru \mathbf{d} a matice \mathbf{B} . Následne vyberieme najrýchlejšiu kombináciu, ktorú potom využijeme na doplnenie vzoriek a experimenty týkajúce sa kvality rekonštrukcie signálu.

4.2.1 Rýchlosť výpočtu algoritmu

Schéma experimentu je nasledovná. Na doplnenie vzoriek sme využili jednoduchý sínusový signál, ku ktorému bol pripočítaný náhodný šum, tento signál bol umelo poškodený a k doplneniu vzoriek boli využité kombinácie rovníc pre výpočet vektoru \mathbf{d} a matice \mathbf{B} . Na výpočet dĺžky výpočtu algoritmu bola použitá funkcia `timeit`. Výstupom experimentu sú grafy závislosti rýchlosti výpočtu algoritmu na počte chýbajúcich vzoriek, type kombinácií a na ráde AR modelu p .


Typy kombinácií:

- 1) rovnice (3.10) + (3.7),
- 2) rovnice (3.9) + (3.7),
- 3) rovnice (3.10) + (3.6),
- 4) rovnice (3.9) + (3.6).

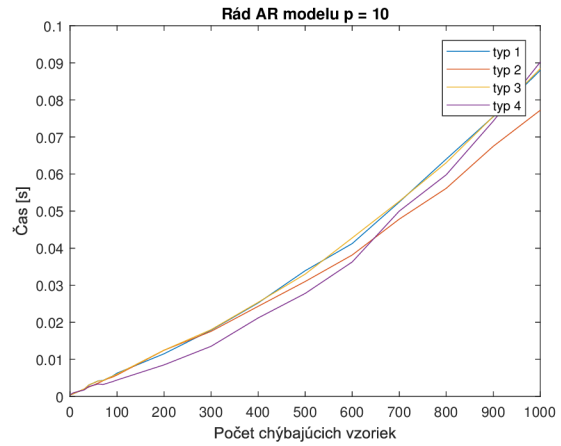
Experiment bol testovaný pre rád modelu $p = [1 : 9, 10 : 10 : 90, 100 : 100 : 1000]$ (jedná sa o zápis v MATLABe). Z dôvodu veľkého množstva grafov budú uvedené len výsledky pre $p = [1, 10, 50, 100, 500, 1000]$.

Posúdenie experimentov


Na grafoch 4.9 môžeme vidieť, že vo väčšine prípadov bola najrýchlejšia kombinácia 4). Táto skutočnosť bola taktiež overená v MATLABe pomocou funkcie `min`. Ďalej sa presunieme na experimenty týkajúce sa samotného doplnenia vzoriek.




(a)



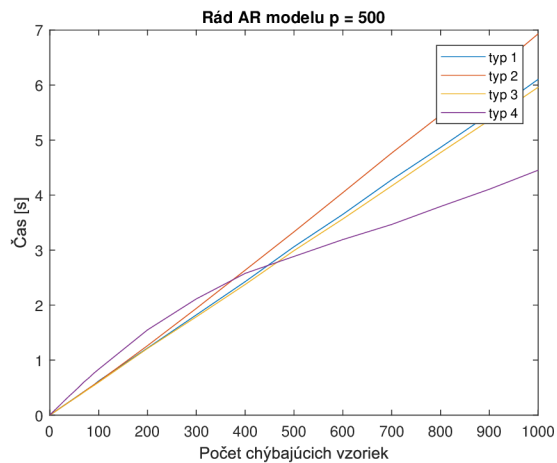
(b)




(c)



(d)



(e)



(f)

Obr. 4.9: Výsledky pre rýchlosť výpočtu algoritmu

4.2.2 Kvalita rekonštrukcie a iterácie algoritmu

Jednou zo základných odlišností medzi jednotlivými algoritmi je že v Janssenovom prípade sa jedná o algoritmus iteračný. V tejto sekcii preto uvedieme závislosť kvality rekonštrukcie na počte iterácií algoritmu. Tento experiment je prevedený na sínusovom signále (v) a kontext výpočtu koeficientov AR modelu je 23 ms. Výsledky sú uvedené na obrázku 4.10.

Vyhodnotenie experimentu


Z výsledkov experimentu môžeme usúdiť, že vo väčšine prípadov nie je po 4. iterácií algoritmu zmena SNR veľmi prudká. Taktiež môžeme povedať, že vyšší počet iterácií neznamená lepšiu kvalitu rekonštrukcie, toto môžeme vidieť na obrázku 4.10e. Na základe týchto výsledkov budú výsledky ďalších experimentov uvedené práve pre 4. iteráciu.

4.2.3 Testovanie Janssenovho algoritmu


V tejto sekcii bude Janssenov algoritmus otestovaný na rôznych signáloch podobne ako v sekciiach 4.1.1, 4.1.2, 4.1.3. Ďalej budú experimenty vyhodnotené a porovnané s výsledkami pre Etterov algoritmus.

Vyhodnotenie testovania Janssenovho algoritmu


Experimenty na sínusových signáloch ukazujú podobné výsledky ako pri Etterovom algoritme, na grafoch môžeme vidieť, že čím väčšia je zložitosť signálu tým vyšší rád AR modelu je nutné použiť aby bola kvalita rekonštrukcie uspokojivá. Taktiež si môžeme všimnúť, že čím je signál zložitejší tým je kvalita rekonštrukcie horšia tzn. SNR je menší. Kvalita rekonštrukcie simulovaného AR procesu bola najlepšia pri dĺžke diery 5 ms, toto je spôsobené náhodnosťou simulovaného AR proces keďže sa jedná o vyfiltrovaný biely šum. Na všetkých testovaných signáloch sa taktiež ukázalo, že dĺžka diery a kontextu súvisia s kvalitou rekonštrukcie. Toto tvrdenie platí obzvlášť pre reálne signály 4.18, 4.17. Pri hudobnom signále 4.18 sa ukázalo, že dĺžka kontextu 23 ms nie je vhodná pre rekonštrukciu keďže aj pri vyššom ráde AR modelu ($p = 1000$) je hodnota $SNR < 0$. Oba algoritmy dosiahli veľmi podobnú kvalitu rekonštrukcie pri reálnych signáloch 4.7, 4.17, 4.8, 4.18 a pri simulovanom AR procese 4.6, 4.16. Rozdiel nastal pri rekonštrukcii sínusových signálov. Na grafoch 4.1, 4.2, 4.11 a 4.12 môžeme vidieť, že Etterov algoritmus dosiahol kvalitnejšiu rekonštrukciu než Janssenov. Naopak pri zložitejších signáloch (iv), (v) nastala kvalitnejšia rekonštrukcia v Janssenovom prípade 4.14, 4.15.




(a) $p=5$ a dĺžka diery =5 ms




(b) $p=50$ a dĺžka diery=20 ms




(c) $p=100$ a dĺžka diery=20 ms



(d) $p=1000$ a dĺžka diery=10 ms




(e) $p=1000$ a dĺžka diery=50 ms




(f) $p=5$ a dĺžka diery=30 ms


Obr. 4.10: Kvalita rekonštrukcie a iterácie algoritmu




(a)




(b)




(c)



(d)




(e)




(f)


Obr. 4.11: Výsledky pre jeden sínusový signál (Janssen)




(a)




(b)




(c)



(d)




(e)




(f)


Obr. 4.12: Výsledky pre súčet dvoch sínusových signálov (Janssen)




(a)




(b)




(c)



(d)




(e)




(f)


Obr. 4.13: Výsledky pre súčet štyroch sínusových signálov (Janssen)




(a)




(b)




(c)



(d)




(e)




(f)


Obr. 4.14: Výsledky pre súčet ôsmich sínusových signálov (Janssen)




(a)




(b)



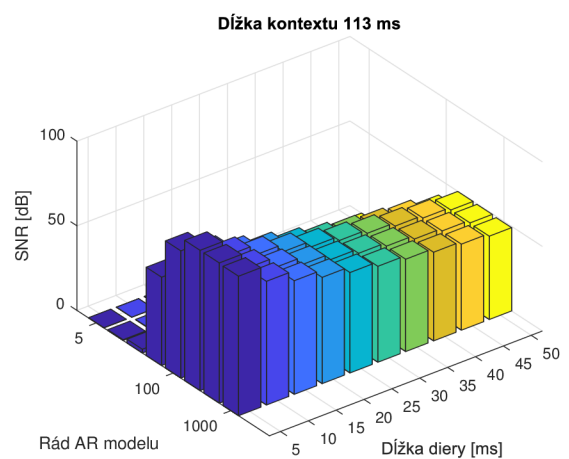
(c)



(d)




(e)




(f)


Obr. 4.15: Výsledky pre súčet šestnástich sínusových signálov (Janssen)




(a)



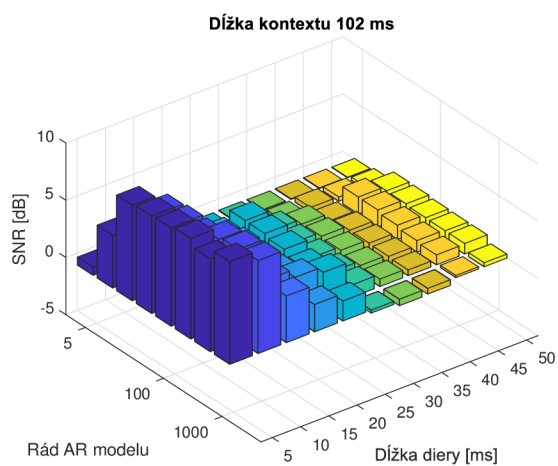
(b)




(c)



(d)




(e)




(f)


Obr. 4.16: Výsledky pre simulovaný AR proces (Janssen)




(a)




(b)




(c)



(d)




(e)




(f)


Obr. 4.17: Výsledky pre rekonštrukciu ľudskej reči (Janssen)




(a)




(b)




(c)



(d)



(e)



(f)

Obr. 4.18: Výsledky pre rekonštrukciu hudobného diela (Janssen)

5 Záver

Cielom bakárskej bolo aplikovať algoritmy W. Ettera a A. Janssena určené na doplnenie vzoriek [5] [2] a otestovať kvalitu rekonštrukcie na reálnych nahrávkach.

V kapitolách 2 a 3 sme stanovili podmienky, ktoré musí poškodený signál spĺňať na to aby mohol byť úspešne zrekonštruovaný. V kapitole 3 sme popísali extrapoláciu a interpoláciu signálu uviedli sme návrh oboch algoritmov pre doplnenie chýbajúcich vzoriek.

Experimenty týkajúce sa rekonštrukcie poškodeného signálu sme popísali v kapitole 4. V prípade Janssenovho algoritmu boli v kapitole 4.2.3 otestované rôzne spôsoby výpočtu chýbajúcich vzoriek a závislosť iterácií algoritmu na kvalitu rekonštrukcie. Výsledky experimentov ukázali niekoľko skutočností, ktoré sa týkajú presnosti rekonštrukcie. Zistili sme, že kvalita doplnenia vzoriek závisí od zložitosti rekonštruovaného signálu a rádu autoregresného modelu tzn. klesá so zložitou signálu a dĺžkou diery, stúpa s dĺžkou kontextu. Závislosť kvality rekonštrukcie na ráde AR modelu sme graficky zobrazili a ukázalo sa, že obe metódy poskytujú uspokojivú rekonštrukciu signálov ak nie je dĺžka diery príliš veľká. Taktiež sme zistili, že vyšší rád AR modelu nie vždy znamená lepšiu rekonštrukciu, keďže testovanie algoritmov vzhľadom na tento parameter neposkytovalo konzistentné výsledky. Na výsledkoch testovania môžeme vidieť, že oba algoritmy dosahujú lepšiu kvalitu rekonštrukcie pre ľudskú reč 4.7, 4.17 než pre hudobný signál 4.8, 4.18.

Literatúra

- [1] EBU SQAM CD. *Sound Quality Assessment Material recordings for subjective tests [online]*. Dostupné z URL: <<https://tech.ebu.ch/publications/sqamcd>>.
- [2] JANSSEN, A., R. VELDHUIS a L. VRIES. Adaptive interpolation of discrete-time signals that can be modeled as autoregressive processes. *IEEE Transactions on Acoustics, Speech, and Signal Processing [online]*. 1986, **34**(2), 317-330 [cit. 2019-11-01]. DOI: 10.1109/TASSP.1986.1164824. ISSN 0096-3518. Dostupné z: <http://ieeexplore.ieee.org/document/1164824/>
- [3] VELDHUIS, R., A. JANSSEN a L. VRIES. Adaptive restoration of unknown samples in certain time-discrete signals. In: *ICASSP '85. IEEE International Conference on Acoustics, Speech, and Signal Processing [online]*. Institute of Electrical and Electronics Engineers, 1985, s. 1013-1016 [cit. 2019-11-09]. DOI: 10.1109/ICASSP.1985.1168128. Dostupné z: <http://ieeexplore.ieee.org/document/1168128/>
- [4] ADLER, Amir, Valentin EMIYA, Maria G. JAFARI, Michael ELAD, Rémi GRIBONVAL a Mark D. PLUMBLEY. Audio Inpainting. *IEEE Transactions on Audio, Speech, and Language Processing [online]*. 2012, **20**(3), 922-932 [cit. 2019-11-09]. DOI: 10.1109/TASL.2011.2168211. ISSN 1558-7916. Dostupné z: <http://ieeexplore.ieee.org/document/6020748/>
- [5] ETTER, W. Restoration of a discrete-time signal segment by interpolation based on the left-sided and right-sided autoregressive parameters. *IEEE Transactions on Signal Processing [online]*. 1996, **44**(5), 1124-1135 [cit. 2019-11-29]. DOI: 10.1109/78.502326. ISSN 1053587X. Dostupné z: <http://ieeexplore.ieee.org/document/502326/>
- [6] OUDRE, L “Interpolation of missing samples in sound signals based on autoregressive modeling,” *Image Processing On Line*, vol. 8, 2018
- [7] ŠABLATURA, J.: *Star Wars - namluvený článek (15. máj 2017) [online]* Dostupné z URL: <https://commons.wikimedia.org/wiki/File:Star_Wars_-_namluvenýčlánek_-_ogg>
- [8] MOKRÝ. O.: *Restaurace poškozených audiosignálů pomocí řídkých reprezentací. Brno, 2017. Bakalářská práce. Vysoké učení technické v Brně. Fakulta strojního inženýrství. Ústav matematiky*. Dostupné na: <<https://www.vutbr.cz/studenti/zav-prace/detail/100257>>

- [9] MOKRÝ. O.: *Moderní metody restaurace poškozených audiosignálů*. Brno, 2019. Diplomová práce. Vysoké učení technické v Brně. Fakulta strojního inženýrství. Ústav matematiky. Dostupné na: <https://www.vutbr.cz/studenti/zav-prace?zp_id=113107>
- [10] KALNÍK. J.: *Moderní metody restaurace audiosignálů*. Brno, 2016. Bakalářská práce. Vysoké učení technické v Brně. Fakulta elektrotechniky a komunikačních technologií. Ústav telekomunikací. Dostupné na: <<https://www.vutbr.cz/studenti/zav-prace/detail/93610>>

Zoznam symbolov, veličín a skratiek

\mathbb{N}, \mathbb{R}	číselné množiny prirodzených, reálnych čísiel
$x(i)$	poškodený signál
M	počet chýbajúcich vzoriek
L	začiatok chýbajúceho úseku, diery
N_L, N_R	počet vzoriek ľavého a pravého okolia diery
$\hat{x}(i)$	zrekonštruovaný signál
$\hat{x}_L(i), \hat{x}_R(i)$	signály, ktorých vzorky boli odhadnuté z ľavého a pravého okolia diery
a	koefficienty autoregresného modelu
p	rád autoregresného modelu
$\omega_{L,M}, \omega_{R,M}$	vážené funkcie
AR	autoregresný model
SNR	odstup signálu od šumu

Zoznam príloh

A Obsah priloženého .zip súboru

57

A Obsah priloženého .zip súboru

Priložený súbor obsahuje zdrojové kódy pre MATLAB, ktoré boli použité na experimenty v kapitole 4. Tieto kódy boli testované vo verzii MATLAB R2017b.

```
/.....koreňový adresár priloženého .zip
├── BP-subory.....kódy pre rekonštrukciu signálu a vynesenie grafov.
│   ├── algW.m
│   ├── Etter-hodnoty.m
│   ├── Etter-hodnoty-script.mlx
│   ├── Etter-vysledky.mat
│   ├── f.wav.....hudobný signál.
│   ├── getbl.m
│   ├── Oudre-Janssen-hodnoty.m
│   ├── Oudre-Janssen-hodnoty-script.m
│   ├── Oudre-Janssen-vysledky-1001.mat
│   ├── speech-samples.wav.....signál ľudskej reči.
│   └── vypC117.m
```