



TECHNICKÁ UNIVERZITA V LIBERCI
Fakulta mechatroniky, informatiky
a mezioborových studií ■

Robustní metoda pro potlačování akustické odezvy

Diplomová práce

M13000197

Studijní program: N2612 – Elektrotechnika a informatika

Studijní obor: 1802T007 – Informační technologie

Autor práce: **Bc. Michael Müller**

Vedoucí práce: doc. Ing. Zbyněk Koldovský, Ph.D.





TECHNICAL UNIVERSITY OF LIBEREC
Faculty of Mechatronics, Informatics
and Interdisciplinary Studies ■

Robust method for acoustic echo cancellation

Diploma thesis

M13000197

Study programme: N2612 – Electrical Engineering and Informatics

Study branch: 1802T007 – Information technology

Author: **Bc. Michael Müller**

Supervisor: doc. Ing. Zbyněk Koldovský, Ph.D.



ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: Bc. Michael Müller
Osobní číslo: M13000197
Studijní program: N2612 Elektrotechnika a informatika
Studijní obor: Informační technologie
Název tématu: Robustní metoda pro potlačování akustické odezvy
Zadávající katedra: Ústav informačních technologií a elektroniky

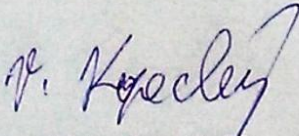
Z á s a d y p r o v y p r a c o v á n í :

1. Nastudujte metodu pro potlačování akustické odezvy pomocí částečně slepé separace. Metodu otestujte v režimu cross-talku, kdy je výpočet přenosové funkce akustické odezvy rušen uživatelem. Metody porovnejte s jinými existujícími metodami (LMS, RLS, Kalman).
2. Modifikujte metodu pro výpočet řídké (aproximace) impulzní odezvy. Optimalizujte váhovací funkci, která ovlivňuje (ne)nulovost koeficientů výsledné impulzní odezvy.
3. Navrženou metodu otestujte na simulovaných datech s umělou a reálnou impulzní odezvou různé délky.

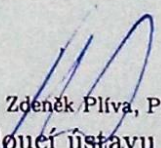
Rozsah grafických prací: Dle potřeby dokumentace
Rozsah pracovní zprávy: cca 40 až 50 stran
Forma zpracování diplomové práce: tištěná/elektronická
Seznam odborné literatury:

- [1] I. Tashev, "Sound Capture and Processing" Practical Approaches", Wiley, 2008.
- [2] A. Hyvärinen, J. Karhunen, and E. Oja, Independent Component Analysis, Wiley-Interscience, New York, 2001.
- [3] Z. Koldovský, J. Málek, M. Müller, and P. Tichavský, "On Semi-Blind Estimation of Echo Paths During Double-Talk Based on Nonstationarity," Proc. of the 14th International Workshop on Acoustic Signal Enhancement (IWAENC 2014), pp. 199-203, Antibes ? Juan les Pins, France, Sept. 2014.

Vedoucí diplomové práce: **doc. Ing. Zbyněk Koldovský, Ph.D.**
Ústav informačních technologií a elektroniky
Konzultant diplomové práce: **Ing. Jiří Málek, Ph.D.**
Ústav informačních technologií a elektroniky
Datum zadání diplomové práce: **12. září 2014**
Termín odevzdání diplomové práce: **15. května 2015**


prof. Ing. Václav Kopecký, CSc.
děkan




prof. Ing. Zdeněk Plíva, Ph.D.
vedoucí ústavu

V Liberci dne 12. září 2014

Prohlášení

Byl jsem seznámen s tím, že na mou diplomovou práci se plně vztahuje zákon č. 121/2000 Sb., o právu autorském, zejména § 60 – školní dílo.

Beru na vědomí, že Technická univerzita v Liberci (TUL) nezasahuje do mých autorských práv užitím mé diplomové práce pro vnitřní potřebu TUL.

Užiji-li diplomovou práci nebo poskytnu-li licenci k jejímu využití, jsem si vědom povinnosti informovat o této skutečnosti TUL; v tomto případě má TUL právo ode mne požadovat úhradu nákladů, které vynaložila na vytvoření díla, až do jejich skutečné výše.

Diplomovou práci jsem vypracoval samostatně s použitím uvedené literatury a na základě konzultací s vedoucím mé diplomové práce a konzultantem.

Současně čestně prohlašuji, že tištěná verze práce se shoduje s elektronickou verzí, vloženou do IS STAG.

Datum: 15. 5. 2015

Podpis: *Mu'lik*

Poděkování

Rád bych poděkoval vedoucímu práce doc. Ing. Zbyňku Koldovskému, Ph.D. za cenné rady při vytváření diplomové práce. Dále bych rád poděkoval svým rodičům a přítelkyni, kteří mě drželi nad vodou v těžkých chvílích a povzbuzovali až do konce. v neposlední řadě bych rád poděkoval doc. RNDr. Pavlu Satrapovi, Ph.D za zpracování L^AT_EX šablony, kterou jsem využil při vytváření této zprávy.

Práce byla podpořena Grantovou agenturou ČR, projekt č. 14-11898S.

Abstrakt

V této práci je popsán problém potlačování akustické odezvy. Dále je zde vysvětleno, co je akustická impulsní odezva a řídká impulsní odezva. Pro potlačování akustické metody jsou zde vysvětleny některé metody, které se tímto problémem zabývají. Tyto metody jsou porovnány při aktivitě rušení i cílového signálu. Pro výpočet řídké impulsní odezvy musela být navržena úprava metody SBAEC a následně porovnána s jinými metodami ve zlepšení při odhadu řídkých impulsních odezev.

Klíčová slova

signál, filtr, potlačování rušení, řídká impulsní odezva

Abstract

In this thesis is described problem of Acoustic Echo Cancellation. Further is explained, what is the acoustic impulse response and sparse impulse response. For AEC are explained some of the methods, which solves this problem. These methods are compared when the double-talk is active. For estimate the sparse impulse response had to be proposed modification of SBAEC method and then it was compared with other methods in estimation of sparse impulse responses.

Keywords

signal, filter, echo cancellation, sparse impulse response

Obsah

Seznam zkratek	11
Úvod	12
2 Potlačování akustické odezvy	13
3 Impulsní odezva	17
3.1 Akustická impulsní odezva	17
3.2 Řídká impulsní odezva	18
4 Metody pro výpočet impulsní odezvy	20
4.1 LMS	22
4.1.1 Neadaptivní	22
4.1.2 Adaptivní	23
4.2 RLS	24
4.3 Kalmanův filtr	28
4.4 Částečně slepý odhad akustické cesty, když je aktivní cílový signál . .	32
4.5 Guntherův odhad	35
5 Porovnání metod v režimu cross-talku	37
6 Úprava pro výpočet řídké impulsní odezvy	41
6.1 Úprava	41
6.2 Váhovací funkce	43
7 Porovnání metod v režimu cross-talku pro výpočet řídkých im- pulsní odezev	45
Závěr	50

Literatura	51
Obsah přiloženého CD	53

Seznam obrázků

2.1	Zobrazení vzniku zarušení v signálu	14
3.1	Vznik akustické impulsní odezvy	17
3.2	Řídká impulsní odezva	18
5.1	Vliv vstupního SNR na ERLE	38
5.2	Vliv délky filtru na ERLE	39
5.3	Vliv parametru T60 na ERLE	40
7.1	Vliv vstupního SNR na ERLE	46
7.2	Vliv délky odhadované impulsní odezvy na ERLE	47
7.3	Vliv původní délky impulsní odezvy na ERLE	48
7.4	Vliv směru příhodu signálu na ERLE	49

Seznam zkratek

LMS	Least Mean Square
RLS	Recursive Least Square
SNR	Signal to Noise Ratio
ERLE	Echo Reduce Loss Enhancement
RIR	Room Impulse Response
AEC	Acoustic Echo Cancellation
SBAEC	Semi Blind Acoustic Echo Cancellation

Úvod

Tato práce se zabývá metodami pro potlačování husté i řídké akustické odezvy při aktivitě rušení i cílového signálu. v kapitole *Potlačování akustické odezvy* je vysvětleno jak vzniká zarušený signál, ze kterého následně odstraňujeme rušení pomocí odhadnuté impulsní odezvy. v další kapitole je vysvětleno co je to impulsní odezva, jak vzniká i to proč se zabývat potlačováním právě řídkých akustických odezev, které se v reálném světě téměř nevyskytují.

Ve 4. kapitole jsou popsány jednotlivé metody, které jsem musel nastudovat a posléze naprogramovat v programu Matlab. Mezi tyto metody jsou zařazeny blokové i adaptivní. v kapitole *Porovnání metod v režimu cross-talku* jsem provedl porovnání jednotlivých metod, kdy jsem u každého testu měnil jeden parametr a zjišťoval jaký vliv to má na potlačení rušení. v 6. kapitole s názvem *Úprava pro výpočet řídké impulsní odezvy* je popsána úprava metody SBAEC tak, aby byla schopna odhadnout i řídké impulsní odezvy s využitím algoritmů ℓ_1 -Homotopy, SpaRSA a návrhem jednoduché váhovací funkce pro určení řídkosti odhadu.

V poslední kapitole je otestováno to, jak dobře metody odhadují respektive potlačují rušení ovlivněné řídkou impulsní odezvy. Předpokládáno je zlepšení hlavně metody SBAEC, protože pro tu byla určena úprava z předchozí kapitoly.


2 Potlačování akustické odezvy

Potlačování akustické odezvy (AEC) je v oblasti zpracování signálů jedna z nejzajímavějších oblastí. Původní nápad této úlohy pochází z 60. let a může být považován za opravdový milník v telekomunikačních systémech. AEC je využíván v případech, kdy je cílový signál $s(n)$ zarušen jiným signálem označeným $r(n)$, který je změněn impulsní odezvou $a(n)$. Zarušený signál $x(n)$ má potom tvar

$$x(n) = s(n) + \{a * r\}(n), \quad (2.1)$$

kde $*$ značí konvoluci, $s(n)$ je cílový signál a echo je tvaru $\{a * r\}(n)$, což je zarušení v signálu. Echo je tedy tvořeno z $r(n)$, kterému se také říká referenční signál. Referenční signál může být získán přímo u svého zdroje vyvedením linky. Druhou částí echa je impulsní odezva $a(n)$, kterou je referenční signál změněn při své cestě mezi zdrojem a snímacím zařízením.

Jako příklad AEC může být situace použití handsfree v automobilu, kdy signál od prvního účastníka hovoru vycházející z reproduktoru mobilního telefonu druhého účastníka je změněn akustickou cestou mezi reproduktorem a mikrofonem a zaruší tak signál od mluvčího, který je snímán mikrofonem na telefonu a odeslán zpět prvnímu účastníku hovoru viz. obrázek 2.1. Toto způsobuje snížení kvality hovoru. Proto se zde potlačuje signál, který je změněn akustickou cestou a sečten s cílovým signálem.



Obrázek 2.1: Zobrazení vzniku zarušení v signálu

Potlačování odezvy existují dva druhy, Network Echo Cancellation (potlačování odezvy v síťových signálech) a Acoustic Echo Cancellation (potlačování odezvy v akustických signálech), oba jsou založeny na základním principu odhadnutí impulsní odezvy, která může být označena jako filtr, jehož výstupem je pak kopie echa. To je dále odečteno od zarušeného signálu. Hlavním rozdílem mezi potlačováním rušení v síťových a akustických signálech je to jak v nich rušení vzniká. v síťových signálech je to nevyvážené propojení mezi dvou vodičovými a čtyřvodičovými okruhy, z čehož vzniká rušení, zatímco v akustické rušení vzniká v důsledku akustické cesty mezi reproduktorem a mikrofonem.

Aby mohlo být potlačeno echo v signálu potřebujeme znát referenční signál. Ten známe, protože jsme schopni ho získat přímo ze svého zdroje, jak bylo zmíněno výše. Z referenčního signálu jsme schopni odhadnout impulsní odezvu $\hat{a}(n)$. Odhadnutá impulsní odezva $\hat{a}(n)$ by měla být v ideálním případě stejná jako původní impulsní odezva. Můžeme tedy změnit referenční signál odhadnutou impulsní odezvou $\hat{a}(n)$ a odečíst ho od referenčního signálu změněného původní impulsní odezvou. Pokud toto učiníme, získáme z rovnice č. 2.1, že $x(n) = s(n)$ a můžeme $x(n)$ označit jako odhadnutý cílový signál $\hat{s}(n)$

$$\hat{s}(n) = s(n) + \{(a - \hat{a}) * r\}(n). \quad (2.2)$$

Ale my cílový signál $s(n)$ nemáme k dispozici, ale známe zarušený signál $x(n)$, musíme z něj tedy $\hat{s}(n)$ odhadnout. Pokud tedy do rovnice č. 2.1 dosadíme $\hat{a}(n)$ a vyjádříme si cílový signál $s(n)$, o kterém z rovnice č. 2.2 víme, že odpovídá $\hat{s}(n)$. Dostaneme tedy

$$\hat{s}(n) = x(n) - \{\hat{a} * r\}(n). \quad (2.3)$$

Odhadovaná impulsní odezva může být různé délky. Tím může dojít k různě silnému potlačení echa v signálu. Účinnost filtrů různých délek je závislá na tom jakou délku měla původní impulsní odezva.

Jestliže není aktivní cílový signál, pak se filtr odhaduje snadno, protože zarušený signál odpovídá referenčnímu změněnému impulsní odezvu.

$$x(n) = \{a * r\}(n), \quad (2.4)$$

Takže potřebujeme minimalizovat vzdálenost mezi odhadovanou a původní impulsní odezvou

$$\min_{\hat{a}} \sum_{n=1}^N |x(n) - \{\hat{a} * r\}(n)|^2, \quad (2.5)$$

kde po dosazení rovnice č. 2.4 dostaneme

$$\min_{\hat{a}} \sum_{n=1}^N |\{a * r\}(n) - \{\hat{a} * r\}(n)|^2 = \min_{\hat{a}} \sum_{n=1}^N |\{(a - \hat{a}) * r\}(n)|^2. \quad (2.6)$$

Nyní se minimalizuje vzdálenost mezi $a(n)$ a $\hat{a}(n)$, kde ideálně dostaneme hodnotu 0. Zatímco v případě cross-talku je cílový signál aktivní a proto musíme minimalizovat následující

$$\min_{\hat{a}} \sum_{n=1}^N |s(n) + \{a * r\}(n) - \{\hat{a} * r\}(n)|^2 = \min_{\hat{a}} \sum_{n=1}^N |s(n) + \{(a - \hat{a}) * r\}(n)|^2, \quad (2.7)$$

kde po roznásobení dostaneme kritéria pro minimalizaci dvě

$$\min_{\hat{a}} \sum_{n=1}^N |s(n)|^2 + 2|\{(a - \hat{a}) * r\}(n)s(n)| + |(\{(a - \hat{a}) * r\}(n))^2|. \quad (2.8)$$

Tím nám vznikne část $s(n)^2$, která je brána pouze jako konstanta. Dále $2\{(a - \hat{a}) * r\}(n)s(n)$, což je vzájemná kovariance. Tato vzájemná kovariance je ta část, která odhad při cross-talku komplikuje. Kdyby tato část byla pouze konstanta, tak by se jednalo o stejný případ jako, když cross-talk není aktivní. Ale vzhledem k tomu, že je tato část závislá na čase, tak se musí minimalizovat v každém časovém okamžiku. Poslední část $(\{(a - \hat{a}) * r\}(n))^2$, která je stejná jako v případě, kdy není cross-talk aktivní. Cross-talkem nazýváme situace, kdy například do promluvy jednoho

mluvčího, začne v pozadí hovořit další mluvčí. Jde tedy obecně o to, že je jeden signál zarušen jiným signálem. Problémem cross-talku se zabývá i tato práce.

Pokud jsou filtry počítány adaptivně ze signálu, který obsahuje cross-talk, dochází u algoritmů jako je Least Mean Square (LMS) k nesprávnému výpočtu impulsní odezvy, když je aktivní mluvčí jehož promluvu chceme získat.

V některých případech nejsou známy žádné informace o signálech, ze kterých se zarušený signál skládá ani o zarušeném signálu, nebo o typu zarušení, metody použité pro potlačení či separaci některých signálů se nazývají jako slepé (blind). Právě proto, že je snaha potlačit zarušení bez jakékoliv informace. v případě cross-talku, který je zmiňován v této práci je znám referenční signál, jež lze využít pro výpočet impulsní odezvy. Metody pro řešení tohoto typu úloh jsou nazývány jako částečně slepé (semi-blind), jelikož je znám některý ze signálů s jehož pomocí se filtr pro odstranění zarušení odhadne.


Filtry pro AEC můžeme počítat přes celý signál nebo po blocích. Takto spočítaný filtr, se pak aplikuje buď na celý signál, nebo na ten blok, pro který byl spočítán. Dále lze počítat filtr v reálném čase, čili pro každý nový vzorek signálu (záleží na velikosti kroku) se přepočítá filtr. Tím postupně konverguje k řešení. Pokud je cílový signál $s(n)$ aktivní, potom adaptivní metody jako je LMS nebo Recursive Least Square (RLS) selhávají tak, že špatně konvergují a nejde tedy správně potlačit echo, nebo se potlačí i část signálu, který chceme získat.

3 Impulsní odezva

Jednotkový impuls je krátký signál. v časové oblasti je to Diracova delta funkce $\delta(t)$, zatímco v diskretní oblasti jde o Kroneckerovu delta funkci $\delta(n)$. Impulsní odezva je definována jako výstup systému, na jehož vstup je aplikován jednotkový puls.

3.1 Akustická impulsní odezva

Akustická impulsní odezva je taková impulsní odezva, která změní vyslaný signál ze zdroje. AEC tedy vzniká cestou mezi zdrojem a přijímačem signálu. Signál šířící se od zdroje ke snímači je postupně změněn odrazy v místnosti. Je tedy změněn akustickou odezvou místnosti viz. obr. 3.1. Akustická impulsní odezva je závislá na prostředí, tzn. na velikosti místnosti, teplotě, vlhkosti, materiálech atd. Na přijímači je tedy signál, který je změněný akustickou impulsní odezvou. Odezva bývá zpravidla velice hustá a dlouhá, tím se komplikuje její odhad.



Obrázek 3.1: Vznik akustické impulsní odezvy


Signál, který je ovlivněný akustickou impulsní odezvou můžeme zapsat ve tvaru

$$x(n) = \sum_{i=0}^{N-1} a_n \cdot r(n-i). \quad (3.1)$$

Jako příklad si můžeme vzpomenout na situaci, kdy přednášející hovoří v místnosti a to, jak ho slyšíme, je ovlivněno právě akustickou impulsní odezvou. s jinou akustickou odezvou ho uslyší lidé v předních řadách a jinak zase ti v zadních.

3.2 Řídká impulsní odezva

Impulsní odezva obsahující vysoké množství po sobě jdoucích nulových koeficientů vyskytujících se na více místech celé impulsní odezvy se nazývá řídká. Taková impulsní odezva se vyskytuje například v mobilních sítích, kde vlivem kódování, přetěžování a zpožděním přenosu vznikají prodlevy čímž se v impulsní odezvě objevují neaktivní úseky obsahující koeficienty rovné nule. To pak tvoří impulsní odezvu řídkou.



Obrázek 3.2: Řídká impulsní odezva

Algoritmy pro výpočet řídkých impulsních odezev, jsou ve většině případů upravené již existující algoritmy pro výpočet impulsních odezev. Jeden z prvních al-

goritmu pro výpočet řídké impulsní odezvy je Proportionate Normalized Least Mean Square (PNLMS), kde je každý koeficient aktualizován v závislosti na kroku úměrnému magnitudě počítaných hodnot filtru. [6]

Hlavní motivací toho, proč se zabývat řídkými impulsními odezvami, je zabývat se jimi v akustických signálech. v akustických signálech není impulsní odezva úplně řídká, ale jen přibližně. To znamená, že koeficienty jsou velmi blízké nule, potom lze takový případ aproximovat na případ s řídkou impulsní odezvou. Následně mohou být aplikovány metody pro výpočet řídkých impulsních odezev i na akustické signály, které nemají impulsní odezvu zcela řídkou. Je sice ztracena určitá přesnost, než kdybychom odhadli přímo hustou impulsní odezvou, ale řídkou impulsní odezvou, jsme schopni odhadnout dobře. Takže ve výsledku může být řídký odhad lepší než odhad klasické husté impulsní odezvy.

4 Metody pro výpočet impulsní odezvy

Abychom dosáhli požadovaného filtru, který nám potlačí nechtěný signál, musí být použita jedna z metod pro výpočet, respektive odhad filtru. Metody jsou blokové nebo adaptivní.

Blokové metody se nejvíce hodí na offline zpracování, čili pokud máme nějaký záznam, kde si můžeme spočítat filtr přes celý signál nebo po blocích. Pokud bychom počítali filtr po blocích, dala by se tato metoda použít i na online zpracování tak, že bychom využili bufferu a vždy vypočítali filtr jen pro část signálu. Do této kategorie spadá metoda Least Mean Square.

Pro zpracování v reálném čase se ovšem mnohem více hodí adaptivní metody pro výpočet filtru. Další důvod pro využití adaptivních metod je, když se impulsní odezva mění v průběhu signálu. Výhoda je v postupném výpočtu filtru, to znamená, že pro každý nový vzorek můžeme vypočítat nový filtr. Nemusíme však počítat filtr od začátku, stačí, když aktualizujeme filtr stávající. Adaptivní metody musí mít definovány inicializační hodnoty některých parametrů. Tyto hodnoty budou popsány u jednotlivých metod. Sem patří metoda Adaptivní LMS a Recursive Least Square.

Cílem metod pro výpočet filtrů je minimalizovat chybu, které se dopouštíme, chceme-li získat signál $r(n)$ ze vstupního signálu $x(n)$. Signál $r(n)$ by měl být co nejvíce podobný výstupnímu, nebo-li zpracovanému signálu $y(n)$. Tuto chybu budeme definovat jako

$$e(n) = r(n) - y(n). \quad (4.1)$$

Filtr, který budou jednotlivé metody hledat bude typu FIR a délky L . Jeho impulsní odezva bude označována $\hat{a}(n)$. Můžeme tedy zapsat vztah mezi vstupním signálem

$x(n)$ a výstupním signálem $y(n)$ jako

$$y(n) = \sum_{i=0}^{N-1} a(i)x(n-i). \quad (4.2)$$

Jsou-li zavedeny vektory

$$\mathbf{x}_n = \begin{bmatrix} x(n) \\ x(n-1) \\ \vdots \\ x(n-L) \end{bmatrix} \quad \mathbf{a} = \begin{bmatrix} a(0) \\ a(1) \\ \vdots \\ a(L) \end{bmatrix}, \quad (4.3)$$

potom můžeme vztah č. 4.2 zapsat jako

$$y(n) = \mathbf{a}^T \mathbf{x}_n. \quad (4.4)$$

Filtry, které následující metody odhadují, jsou navrženy tak, aby nějakým způsobem minimalizovaly kvadrát chyby $e(n)$. Musí se tedy zavést kritérium, které je funkcí \mathbf{a} (funkcí L proměnných $a(i)$) a je rovno kvadrátu chyby v časový okamžik n

$$J_n(\mathbf{a}) = e(n)^2. \quad (4.5)$$

Gradient $J_n(\mathbf{a})$, nebo-li vektor parciálních derivací podle \mathbf{a} , může být zapsán vektorově

$$\nabla J_n(\mathbf{a}) = -2\mathbf{x}_n r(n) + 2\mathbf{x}_n \mathbf{x}_n^T \mathbf{a}. \quad (4.6)$$

Zde může být zavedeno značení

$$\mathbf{R}_n = \mathbf{x}_n \mathbf{x}_n^T \quad (4.7)$$

$$\mathbf{p}_n = \mathbf{x}_n r(n), \quad (4.8)$$

pak můžeme gradient zapsat jako

$$\nabla J_n(\mathbf{a}) = -2\mathbf{p}_n + 2\mathbf{x}_n \mathbf{R}_n \mathbf{a}. \quad (4.9)$$

4.1 LMS

4.1.1 Neadaptivní

LMS (Least Mean Square) je metoda pro výpočet filtru z celého signálu, nebo můžeme filtr počítat v několika časových úsecích, čili po blocích. Filtrem tedy minimalizujeme průměrnou hodnotu kritéria $J_n(\mathbf{a})$ na určitém úseku $n = n_1, \dots, n_2$

$$J_{n_1, n_2}(\mathbf{a}) = \frac{1}{n_2 - n_1 + 1} \sum_{n=n_1}^{n_2} e(n)^2 \quad (4.10)$$

Pro jednoduchost můžeme počítat s celým úsekem dat $n = 1, \dots, N$

$$J(\mathbf{a}) = \frac{1}{N} \sum_{n=1}^N e(n)^2. \quad (4.11)$$

Derivace je lineární operace, takže gradient $J(\mathbf{a})$ je roven průměru gradientů $J_n(\mathbf{a})$ a platí

$$\nabla J(\mathbf{a}) = -2\mathbf{p} + 2\mathbf{R}\mathbf{a}, \quad (4.12)$$

kde

$$\mathbf{R} = \frac{1}{N} \sum_{n=1}^N \mathbf{x}_n \mathbf{x}_n^T \quad (4.13)$$

$$\mathbf{p} = \frac{1}{N} \sum_{n=1}^N \mathbf{x}_n r(n), \quad (4.14)$$

Matici \mathbf{R} je tedy vzájemná kovariance. Matici \mathbf{R} můžeme pojmenovat také jako Toeplitzovskou. Lze ji zapsat jako součin matic \mathbf{X} a \mathbf{X}^T tedy:

$$\mathbf{R} = \frac{1}{N} \mathbf{X}\mathbf{X}^T, \quad (4.15)$$

kde matice \mathbf{X} vypadá následovně

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}[1] & \mathbf{x}[2] & \cdots & \mathbf{x}[N] & 0 & \cdots & 0 \\ 0 & \mathbf{x}[1] & \cdots & \mathbf{x}[N-1] & \mathbf{x}[N] & \cdots & 0 \\ \vdots & & \ddots & & & \vdots & \\ 0 & \cdots & \cdots & \mathbf{x}[N-L] & \mathbf{x}[N-L+1] & \cdots & 0 \end{bmatrix}. \quad (4.16)$$

Vektor \mathbf{p} vznikl cross-kovariancí matice \mathbf{X} se signálem, který je označen $r(n)$.

$$\mathbf{p} = \frac{1}{N} \mathbf{X} r(n). \quad (4.17)$$

Položíme-li nyní gradient roven nule $\nabla J(\mathbf{a}) = 0$ dostaneme vzorec pro výpočet LMS filtru

$$\mathbf{a} = \mathbf{R}^{-1} \mathbf{p}. \quad (4.18)$$

Pokud bychom chtěli odhadovat filtr adaptivně mohli bychom počítat LMS po jednotlivých blocích. Potom mohou vznikat dva problémy. Prvním problémem je, že nemusí existovat inverzní matice \mathbf{R} a druhým problémem, jsou náhlé změny. Čím menší je interval tím větší je pravděpodobnost, že nebude existovat inverzní matice a změny budou větší.

4.1.2 Adaptivní

Adaptivní LMS je navrženo tak, aby byla minimalizována aktuální chyba v čase n . To znamená, že se podle toho musí změnit i \mathbf{a}_n . v tomto případě nemůžeme minimalizování vyřešit jednoduchým položením gradientu rovný nule $J_n(\mathbf{a})$, jelikož \mathbf{R}_n nemá inverzi. Adaptivní LMS proto používá pro úpravu \mathbf{a} metodu největšího spádu

$$\mathbf{a}_n = \mathbf{a}_{n-1} - \mu \nabla J_n(\mathbf{a}), \quad (4.19)$$

kde μ značí délku kroku. Dosazením dostaneme krok

$$\mathbf{a}_n = \mathbf{a}_{n-1} - \mu \mathbf{x}_n e(n). \quad (4.20)$$

Metoda největšího spádu je iterační metoda pro hledání minima funkce. Prove-

dením jedné iterace, tak zmenšíme chybu $J_n(\mathbf{a})$. v další iteraci je tedy hodnota chyby jiná. Pokud provedeme další iteraci, chybu opět zmenšíme atd. Tímto se nám filtr adaptuje po celou dobu adaptace. Důležité je správně zvolit krok μ . To ovšem není tak jednoduché. Je-li zvolen krok moc malý, filtr se neadaptuje dostatečně rychle a nekonverguje do požadované hodnoty. Je-li krok zase moc velký, dojde k divergenci a filtr nefunguje správně.

4.2 RLS

Recursive Least Square minimalizuje v každém časovém okamžiku kritérium

$$J_{n,\lambda}(\mathbf{a}_n) = \sum_{k=1}^n \lambda^{n-k} e_n(k)^2, \quad (4.21)$$

kde λ je od 0 do 1. Pokud je $\lambda = 0$, tak je kritérium rovno pouze kvadrátu aktuální chyby. Na druhou stranu pokud by $\lambda = 1$, pak má každá chyba váhu 1. λ tedy ovlivňuje paměť kritéria. Chybový signál $e(n)$ je definován jako

$$e_n(k) = r(k) - \mathbf{a}_n^T \mathbf{x}_k. \quad (4.22)$$

Minimalizaci kritéria $J_{n,\lambda}(\mathbf{a}_n)$, lze provést stejně jako u LMS filtru, tedy položením gradientu $J_{n,\lambda}(\mathbf{a}_n)$ rovno nule. Výsledkem je tzv. normálová rovnice

$$\boldsymbol{\phi}_n \mathbf{a}_n = \mathbf{z}_n, \quad (4.23)$$

kde

$$\boldsymbol{\phi}_n = \sum_{k=1}^n \lambda^{n-k} \mathbf{x}_k \mathbf{x}_k^T \quad (4.24)$$

$$\mathbf{z}_n = \sum_{k=1}^n \lambda^{n-k} \mathbf{x}_k r(k). \quad (4.25)$$

Matice $\boldsymbol{\phi}_n$ a vektor \mathbf{z}_n jsou obdobou matice \mathbf{R}_n a vektoru \mathbf{p}_n .

Rekuzivní výpočet ϕ_n a \mathbf{z}_n

Pokud budeme řešit normálovou rovnici přímým způsobem v každý časový okamžik musíme počítat matici ϕ_n její inverzi a vektor \mathbf{z}_n . To je výpočetně velmi náročné. Můžeme využít toho jaké kritérium zde uvažujeme a můžeme tak dosáhnout výrazných úspor. Úspory spočívají v tom, že využijeme hodnoty, které jsme už počítali v předchozích krocích. Můžeme tak odvodit rekuzivní vztahy

$$\phi_n = \lambda\phi_{n-1} + \mathbf{x}_n\mathbf{x}_n^T \quad (4.26)$$

$$\mathbf{z}_n = \lambda\mathbf{z}_{n-1} + \mathbf{x}_nr(n). \quad (4.27)$$

K výpočtu least-square odhadu (filtru) $\hat{\mathbf{a}}_n$ musíme určit inverzní matici ke korelační matici ϕ_n . To v praxi znamená, že tyto operace můžou být značně časově náročné, zejména pokud je velikost matice ϕ_n vysoká. Také bychom chtěli aby least-square odhad $\hat{\mathbf{a}}_n$ byl počítán rekuzivně pro $n = 1, 2, \dots, \infty$. Můžeme tyto dva problémy spojit dohromady pomocí Lemma o inverzní matici, které je popsáno v následující podkapitole.

Lemma o inverzní matici

Nechť \mathbf{A} je matice velikosti $M \times M$ dána vztahem

$$\mathbf{a} = \mathbf{B}^{-1} + \mathbf{C}\mathbf{D}^{-1}\mathbf{C}^T, \quad (4.28)$$

potom inverze matice \mathbf{A} je rovna

$$\mathbf{A}^{-1} = \mathbf{B} - \mathbf{B}\mathbf{C}(\mathbf{D} + \mathbf{C}^T\mathbf{B}\mathbf{C})^{-1}\mathbf{C}^T\mathbf{B}. \quad (4.29)$$

Dokázat toto Lemma lze jednoduchým vynásobením rovnic č. 4.28 a 4.29 čímž vznikne identická matice.

Algoritmus výpočtu RLS

U naší korelační matice ϕ_n předpokládáme, že je nesingulární a má inverzi. Můžeme tedy aplikovat Lemma o inverzní matici, nejdříve však musíme správně označit jednotlivé části z rovnice č. 4.26:

$$\begin{aligned}
\mathbf{a} &= \phi_n \\
\mathbf{B}^{-1} &= \lambda \phi_{n-1} \\
\mathbf{C} &= \mathbf{x}_n \\
\mathbf{D} &= 1
\end{aligned} \tag{4.30}$$

Pokud toto dosadíme do rovnice č. 4.29, dostaneme následující vzorec pro rekurzivní výpočet inverzní matice ϕ_n^{-1}

$$\phi_n^{-1} = \lambda^{-1} \phi_{n-1}^{-1} - \frac{\lambda^{-1} \phi_{n-1}^{-1} \mathbf{x}_n \mathbf{x}_n^T \phi_{n-1}^{-1}}{1 + \lambda^{-1} \phi_{n-1}^{-1} \mathbf{x}_n \mathbf{x}_n^T}. \tag{4.31}$$

Pro zjednodušení si definujeme následující substituce

$$\mathbf{P}_n = \phi_n^{-1} \tag{4.32}$$

$$\mathbf{k}_n = \frac{\lambda^{-1} \mathbf{P}_{n-1} \mathbf{x}_n}{1 + \lambda^{-1} \mathbf{x}_n^T \mathbf{P}_{n-1} \mathbf{x}_n}. \tag{4.33}$$

S těmito definicemi můžeme přepsat rovnici č. 4.31 takto:

$$\mathbf{P}_n = \lambda^{-1} \mathbf{P}_{n-1} - \lambda^{-1} \mathbf{k}_n \mathbf{x}_n^T \mathbf{P}_{n-1}. \tag{4.34}$$

Matici \mathbf{P}_n můžeme označit jako inverzní korelační matici a vektor \mathbf{k}_n získáme tak, že \mathbf{k}_n z rovnice č. 4.33 upravíme na:

$$\mathbf{k}_n = (\lambda^{-1} \mathbf{P}_{n-1} - \lambda^{-1} \mathbf{k}_n \mathbf{x}_n^T \mathbf{P}_{n-1}) \mathbf{x}_n, \tag{4.35}$$

kde obsah kulatých závorek je stejný jako samotné \mathbf{P}_n proto můžeme do této rovnice dosadit a získáme

$$\mathbf{k}_n = \mathbf{P}_n \mathbf{x}_n, \tag{4.36}$$

pokud za \mathbf{P}_n dosadíme zpátky ϕ_n^{-1} dostaneme definici vektoru \mathbf{k}_n

$$\mathbf{k}_n = \phi_n^{-1} \mathbf{x}_n, \tag{4.37}$$

Jinými slovy vektor \mathbf{k}_n je definován jako transformace vektoru \mathbf{x}_n pomocí inverzní korelační matice ϕ_n .

Update odhadnutého filtru

Nyní můžeme zapsat rovnice pro update filtru \mathbf{a} , ke které dojdeme pomocí rovnic č. 4.27 a 4.32:

$$\begin{aligned}\mathbf{a}_n &= \phi_n^{-1} \mathbf{z}_n \\ &= \mathbf{P}_n \mathbf{z}_n \\ &= \lambda \mathbf{P}_n \mathbf{z}_{n-1} + \mathbf{P}_n \mathbf{x}_n r(n).\end{aligned}\tag{4.38}$$

Dosazením rovnice č. 4.34 pouze za první \mathbf{P}_n na pravé straně rovnice č. 4.38, dostaneme

$$\begin{aligned}\mathbf{a}_n &= \mathbf{P}_{n-1} \mathbf{z}_{n-1} - \mathbf{k}_n \mathbf{x}_n^T \mathbf{P}_{n-1} \mathbf{z}_{n-1} + \mathbf{P}_n \mathbf{x}_n r(n) \\ &= \phi^{-1} \mathbf{z}_{n-1} - \mathbf{k}_n \mathbf{x}_n^T \phi^{-1} \mathbf{z}_{n-1} + \mathbf{P}_n \mathbf{x}_n r(n) \\ &= \mathbf{a}_{n-1} - \mathbf{k}_n \mathbf{x}_n^T \mathbf{a}_{n-1} + \mathbf{P}_n \mathbf{x}_n r(n).\end{aligned}\tag{4.39}$$

Nakonec využijeme toho, že $\mathbf{P}_n \mathbf{x}_n$ je stejné jako vektor \mathbf{k}_n v rovnici č. 4.36 a dostaneme vztah pro rekurzivní výpočet pro update filtru:

$$\begin{aligned}\mathbf{a}_n &= \mathbf{a}_{n-1} + \mathbf{k}_n (r(n) - \mathbf{x}_n^T \mathbf{a}_{n-1}) \\ &= \mathbf{a}_{n-1} + \mathbf{k}_n \xi(n).\end{aligned}\tag{4.40}$$

Zde,

$$\xi(n) = r(n) - \mathbf{x}_n^T \mathbf{a}_{n-1}\tag{4.41}$$

je chyba odhadu. Vnitřní část $\mathbf{a}_{n-1}^T \mathbf{x}_n$ zobrazuje odhad odezvy $r(n)$ založené na starém odhadu filtru, který byl vytvořen v čase $n - 1$.

Ještě je potřeba nastavit inicializační data, před tím než začneme signál touto metodou zpracovávat. v tomto případě si připravíme \mathbf{a}_0 stejně jako u adaptivní LMS

tak, že ho po celé délce vyplníme nulami. Dále si potřebujeme inicializovat matici \mathbf{P}_0 , to uděláme tak, že vynásobíme identickou matici \mathbf{I} hodnotou δ^{-1} . Kde δ je kladná konstanta.

$$\mathbf{a}_0 = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}, \quad \mathbf{P}_0 = \delta \mathbf{I}, \quad (4.42)$$

Pro výpočet další adaptace filtru už není potřeba počítat inverzní matici v každém kroku adaptace. v kapitole o LMS je zmíněno, že nemusí existovat inverze pro matici \mathbf{R} , je-li spočtena z příliš krátkého úseku dat. Toto platí i pro matici ϕ_n . Ta je počítána z krátkého úseku je-li λ blízká nule. Proto musí být λ zvolena dostatečně velká. Výhodou RLS je, že může být inicializován libovolnou regulární maticí. Čímž se vyřeší problém, krátkého úseku dat pro výpočet ϕ_n při spuštění algoritmu. [1]

4.3 Kalmanův filtr

Kalmanův filtr je metoda pro výpočet filtrů založená na Bayesovském přístupu. Algoritmus odhaduje několik neznámých proměnných z řady pozorování zarušeného signálu v průběhu času. Tento algoritmus postupně poskytuje optimální odhad těchto proměnných.

V kontextu s potlačováním rušení má signál z mikrofону v diskretním čase tvar

$$x(n) = \mathbf{r}_n^T \mathbf{a} + v(n) = y(n) + v(n), \quad (4.43)$$

kde

$$\mathbf{r}_n^T = [r(n) \quad r(n-1) \quad \cdots \quad r(n-L+1)]^T \quad (4.44)$$

je vektor obsahující L posledních vzorků z referenčního signálu $r(n)$.

$$\mathbf{a} = [a_0 \quad a_1 \quad \cdots \quad a_{L-1}]^T \quad (4.45)$$

je impulsní odezva systému délky L , která má být odhadnuta a $v(n)$ je stacionární bílý Gaussovský šum. Signál $y(n)$ je echo, které má být potlačeno filtrem $\hat{\mathbf{a}}$.

Nyní je systém pro odhad impulsní odezvy chápán jako stavová rovnice a echo signál jako část nepozorovatelných proměnných. s ohledem na P posledních vzorků signálu z mikrofonu, může být rovnice č. 4.43 zapsána jako

$$\begin{aligned}\mathbf{x}_n &= [x(n) \quad x(n-1) \quad \cdots \quad x(n-P+1)]^T \\ &= \mathbf{y}_n + \mathbf{v}_n,\end{aligned}\tag{4.46}$$

kde

$$\mathbf{y}_n = \mathbf{X}_n^T \mathbf{a}_n\tag{4.47}$$

je vektor echa o délce P ,

$$\mathbf{X}_n = [\mathbf{r}_n \quad \mathbf{r}_{n-1} \quad \cdots \quad \mathbf{r}_{n-P+1}]^T\tag{4.48}$$

je vstupní matice o velikosti $L \times P$. Vektor šumu \mathbf{v}_n je definován obdobně jako \mathbf{x}_n . v tomto kontextu je \mathbf{X}_n^T matice měření a $r(n)$ je považován za deterministický. Potom je výraz č. 4.46 nazýván pozorovací rovnicí. Předpokládáme, že \mathbf{a}_n je náhodný vektor, který vychází ze zjednodušeného Markovova modelu

$$\mathbf{a}_n = \mathbf{a}_{n-1} + \mathbf{w}_n,\tag{4.49}$$

kde \mathbf{w}_n je vektor bílého Gausovského šumu, který není korelovaný s \mathbf{a}_{n-1} a s \mathbf{v}_n . Korelační matice k \mathbf{w}_n je předpokládána jako $\mathbf{R}_n^w = \sigma_w^2(n) \mathbf{I}_L$, kde \mathbf{I}_L je $L \times L$ identická matice. Variance $\sigma_w^2(n)$ zachycuje nesrovnalosti v \mathbf{a}_n . Výraz č. 4.49 je nazván stavovou rovnicí.

Nyní může být problém echo cancellation popsán následovně

$$\mathbf{a}_n = \mathbf{a}_{n-1} + \mathbf{w}_n\tag{4.50}$$

$$\mathbf{x}_n = \mathbf{X}_n^T \mathbf{a}_n + \mathbf{v}_n,\tag{4.51}$$

cílem je najít optimální rekurzivní odhad \mathbf{a}_n označený $\hat{\mathbf{a}}_n$. v souvislosti s echo cancellation $\sigma_w^2(n)$ hraje vysokou roli ve výkonnosti odhadu.

Na základě uvedeného modelu může být odvozen Kalmanův filtr. v souvislosti

s lineárním sekvenčním Bayesovským přístupem je optimální vztah pro výpočet vektoru $\hat{\mathbf{a}}_n$ tvaru

$$\begin{aligned}\hat{\mathbf{a}}_n &= \hat{\mathbf{a}}_{n-1} + \mathbf{K}_n[\mathbf{x}_n - \mathbf{X}_n^T \hat{\mathbf{a}}_{n-1}] \\ &= \hat{\mathbf{a}}_{n-1} + \mathbf{K}_n \mathbf{e}_n,\end{aligned}\tag{4.52}$$

kde \mathbf{K}_n je Kalmanova matice a

$$\begin{aligned}\mathbf{e}_n &= \mathbf{x}_n - \hat{\mathbf{y}}_n \\ &= \mathbf{x}_n - \mathbf{X}_n^T \hat{\mathbf{a}}_{n-1}\end{aligned}\tag{4.53}$$

je počáteční chybový signál mezi signálem z mikrofonu a odhadem echo signálu. Konečný chybový signál je definován jako

$$\begin{aligned}\boldsymbol{\epsilon}_n &= \mathbf{x}_n - \mathbf{X}_n^T \hat{\mathbf{a}}_n \\ &= \mathbf{X}_n^T \boldsymbol{\mu}_n + \mathbf{s}_n,\end{aligned}\tag{4.54}$$

kde

$$\boldsymbol{\mu}_n = \mathbf{a}_n - \hat{\mathbf{a}}_n\tag{4.55}$$

je stav výpočetní chyby nebo konečné odchylky. Korelační matice pro $\boldsymbol{\mu}(n)$ je

$$\mathbf{R}_n^\mu = E[\boldsymbol{\mu}_n \boldsymbol{\mu}_n^T].\tag{4.56}$$

Definována může být i počáteční odchylka jako

$$\begin{aligned}\mathbf{m}_n &= \mathbf{a}_n - \hat{\mathbf{a}}_{n-1} \\ &= \boldsymbol{\mu}_{n-1} + \mathbf{w}_n,\end{aligned}\tag{4.57}$$

jejíž korelační matice lze zapsat jako vztah

$$\begin{aligned}\mathbf{R}_n^m &= E[\mathbf{m}_n \mathbf{m}_n^T] \\ &= \mathbf{R}_{n-1}^\mu + \sigma_w^2(n) \mathbf{I}_L.\end{aligned}\quad (4.58)$$

Prvotní odhad se změní na prvotní chybový signál

$$\mathbf{e}_n = \mathbf{X}_n^T \mathbf{m}_n + \mathbf{v}_n. \quad (4.59)$$

Kalmanova matice je získána minimalizováním kritéria

$$J_n = \frac{1}{L} \text{tr}[\mathbf{R}_n^\mu] \quad (4.60)$$

s ohledem na \mathbf{K}_n , které najdeme

$$\mathbf{K}_n = \mathbf{R}_n^m \mathbf{X}_n [\mathbf{X}_n^T \mathbf{R}_n^m \mathbf{X}_n + \sigma_v^2 \mathbf{I}_P]^{-1}, \quad (4.61)$$

kde \mathbf{I}_P je $P \times P$ identická matice a

$$\mathbf{R}_n^m = [\mathbf{I}_L - \mathbf{K}_n \mathbf{X}_n^T] \mathbf{R}_n^m. \quad (4.62)$$

Následující rovnice shrnují výpočet Kalmanova filtru:

$$\begin{aligned}\mathbf{R}_n^m &= \mathbf{R}_{n-1}^\mu + \sigma_v^2 \mathbf{I}_L, \\ \mathbf{R}_n^e &= \mathbf{X}_n^T \mathbf{R}_n^m \mathbf{X}_n + \sigma_v^2 \mathbf{I}_P, \\ \mathbf{K}_n &= \mathbf{R}_n^m \mathbf{X}_n (\mathbf{R}_n^e)^{-1}, \\ \mathbf{e}_n &= \mathbf{x}_n \mathbf{X}_n^T \hat{\mathbf{a}}_{n-1}, \\ \hat{\mathbf{a}}_n &= \hat{\mathbf{a}}_{n-1} + \mathbf{K}_n \mathbf{e}_n, \\ \mathbf{R}_n^\mu &= [\mathbf{I}_L - \mathbf{K}_n \mathbf{X}_n^T] \mathbf{R}_n^m.\end{aligned}\quad (4.63)$$

Pro výpočet Kalmanova filtru je nutné nastavit inicializační hodnoty výpočtu.

Tyto hodnoty jsou následující, $\mathbf{R}_0^\mu = \epsilon \mathbf{I}_L$, kde za ϵ se zvolí malá kladná konstanta a

$$\hat{\mathbf{a}}_0 = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}. \quad (4.64)$$

Více informací o Kalmanovu filtru se lze dočíst v [3].

4.4 Částečně slepý odhad akustické cesty, když je aktivní cílový signál

Tato metoda byla navržena na Technické univerzitě v Liberci. Je to metoda určená pro potlačování ruchu v signálu, zejména pokud je v signálu vedle akustického echa aktivní i cílový signál. Metoda je zaměřena na částečně slepé výpočty impulsní odezvy. Dále bude označována zkratkou SBAEC (Semi Blind Acoustic Echo Cancellation).

Předpokládá se, že impulsní odezva a_n se nemění v čase a má konečnou délku L . Rovnice č. 2.1 lze zapsat vektorovým zápisem

$$x(n) = s(n) + \mathbf{a}^T \mathbf{r}_n, \quad (4.65)$$

kde $\mathbf{r}_n = [r(n), r(n-1), \dots, r(n-L+1)]^T$ a $\mathbf{a} = [a(1), \dots, a(L)]^T$. Problém odhadu \mathbf{a} je formulován pomocí okamžitého modelu míšení

$$\mathbf{y}_n = \mathbf{A} \mathbf{u}_n, \quad (4.66)$$

kde $\mathbf{y}_n = [\mathbf{r}^T x(n)]^T$, $\mathbf{u}_n = [\mathbf{r}^T s(n)]^T$ a

$$\mathbf{a} = \begin{pmatrix} \mathbf{I}_L & \mathbf{0}_{L \times 1} \\ \mathbf{a}^T & 1 \end{pmatrix} \quad (4.67)$$

je $(L+1) \times (L+1)$ čtvercová matice, \mathbf{I}_L a $\mathbf{0}_{L \times 1}$ označují identickou matici a nulový vektor stejné velikosti. v tomto případě má \mathbf{u}_n dvě nezávislé komponenty \mathbf{r}_n a $s(n)$, kde jedna z nich, \mathbf{r}_n , je multidimenzionální. \mathbf{A} je částečně známá, proto odhad její neznámé části \mathbf{a} z \mathbf{y}_n nazýváme jako částečně slepý odhad.

Blokový výpočet stacionárního Gaussovského modelu signálu je vážen, což bylo prokázáno jako vhodné pro slepou separaci signálů. To znamená, že hodnoty $\mathbf{u}_n, n = 1, \dots, N$ jsou předpokládány jako nezávislé a stejně rozvržené. Gaussovské vektory mají kovarianci $\mathbb{R}_{\mathbf{u},n}$, kde kovariance je konstantní přes bloky délky N_b . Předpokládáme že $M = N/N_b$ je celé číslo odpovídající počtu bloků. Věrohodnostní funkce sledovaných signálů $\mathbf{y}_n, n = 1, \dots, N$ tak zní

$$p(\mathbf{y}|\mathbf{a}) = \prod_{k=1}^M (2\pi \det \mathbb{R}_{\mathbf{y},k})^{-N_b/2} \times \exp \left\{ -\frac{1}{2} \sum_{n=(k-1)N_b+1}^{kN_b} \mathbf{y}_n^T \mathbb{R}_{\mathbf{y},k}^{-1} \mathbf{y}_n \right\}, \quad (4.68)$$

kde $\mathbb{R}_{\mathbf{y},k}$ je kovarianční matice \mathbf{y}_n uvnitř k -tého bloku. Pro zjednodušení, bude vynechán index bloku k ze značení kovariance.

Struktura kovariací

V souvislosti se vztahem č. 4.66 $\mathbb{R}_{\mathbf{y}} = \mathbf{A} \mathbb{R}_{\mathbf{u}} \mathbf{A}^T$ kde $\mathbb{R}_{\mathbf{u}}$ je kovarianční matice \mathbf{u}_n , která má strukturu

$$\mathbb{R}_{\mathbf{u}} = \begin{bmatrix} \mathbb{R}_{\mathbf{r}} & 0_{L \times 1} \\ \mathbf{0}_{L \times 1}^T & r_s \end{bmatrix}, \quad (4.69)$$

kde $\mathbb{R}_{\mathbf{r}}$ značí $L \times L$ kovarianční matici \mathbf{r}_n a r_s je variance $s(n)$. Proto

$$\mathbb{R}_{\mathbf{y}} = \begin{bmatrix} \mathbb{R}_{\mathbf{r}} & \mathbb{R}_{\mathbf{r}} \mathbf{a} \\ \mathbf{a}^T \mathbb{R}_{\mathbf{r}} & \mathbf{a}^T \mathbb{R}_{\mathbf{r}} \mathbf{a} + r_s \end{bmatrix}. \quad (4.70)$$

Odhad $\mathbb{R}_{\mathbf{y}}$ je dán vztahem

$$\mathbb{R}_{\mathbf{y}} = \frac{1}{N_b} \sum_n \mathbf{y}_n \mathbf{y}_n^T, \quad (4.71)$$

kde součet pokračuje přes odpovídající bloky. Strukturu $\mathbb{R}_{\mathbf{y}}$ pak lze parametrizovat jako

$$\mathbb{R}_{\mathbf{y}} = \begin{bmatrix} \mathbb{R}_{\mathbf{r}} & \mathbf{r}_{rx} \\ \mathbf{r}_{rx}^T & r_x \end{bmatrix}. \quad (4.72)$$

Předpokládané odhady

Z [4] byla odvozena přibližná záporná logaritmická věrohodnostní funkce

$$-\log p(\mathbf{y}|\mathbf{a}) \approx \frac{N_b}{4} \langle \text{tr}(\mathbf{R}_y^{-1} \Delta \mathbf{R}_y \mathbf{R}_y^{-1} \Delta \mathbf{R}_y) \rangle_M + c, \quad (4.73)$$

kde c značí konstantu, $\text{tr}(\cdot)$ označuje stopu argumentu, $\langle \cdot \rangle_M$ značí průměrovací operátor a $\Delta \mathbf{R}_y = \mathbb{R}_y - \mathbf{R}_y$. Z tohoto může být odvozen vzorec pro odhad impulsní odezvy $\hat{\mathbf{a}}$ pomocí minimalizace kritéria

$$Q(\mathbf{a}) = \langle \text{tr}(\mathbf{Q}_k^{-1} \Delta \mathbf{R}_y \mathbf{Q}_k^{-1} \Delta \mathbf{R}_y) \rangle_M, \quad (4.74)$$

kde $\mathbf{Q}_k = \mathbf{R}_y + \epsilon_k \mathbf{I}_{L+1}$ jsou regulární matice a ϵ_k je malé kladné číslo. Pro zjednodušení se předpokládá, že parametry \mathbb{R}_r a r_s splňují $\mathbb{R}_r = \mathbf{R}_r$ a $r_s = r_x - \mathbf{a}^T \mathbb{R}_r \mathbf{a}$. Z čehož vyplyne následující

$$\Delta \mathbf{R}_y = \begin{bmatrix} 0 & \mathbf{R}_r \mathbf{a} - \mathbf{r}_{rx} \\ \mathbf{a}^T \mathbf{R}_r - \mathbf{r}_{rx}^T & 0 \end{bmatrix} \quad (4.75)$$

a $Q(\mathbf{a})$ se stane kvadratickou funkcí v \mathbf{a}

$$\mathbf{Q}_k^{-1} = \begin{bmatrix} (\mathbf{R}_r + \epsilon_k \mathbf{I}_L)^{-1} + \kappa_k^{-1} \mathbf{z}_k \mathbf{z}_k^T & (-\kappa_k^{-1} \mathbf{z}_k) \\ -\kappa_k^{-1} \mathbf{z}_k^T & -\kappa_k^{-1} \end{bmatrix} \quad (4.76)$$

a

$$\mathbf{Q}_k^{-1} \Delta \mathbf{R}_y = \begin{bmatrix} -\kappa_k^{-1} \mathbf{z}_k \mathbf{b}_k^T \mathbf{R}_r & (\mathbf{I}_L + -\kappa_k^{-1} \mathbf{z}_k \mathbf{r}_{rx}^T) \mathbf{b}_k \\ -\kappa_k^{-1} \mathbf{b}_k^T \mathbf{R}_r & -\kappa_k^{-1} \mathbf{r}_{rx}^T \mathbf{b}_k \end{bmatrix}, \quad (4.77)$$

kde

$$\mathbf{z}_k = (\mathbf{R}_r + \epsilon_k \mathbf{I}_L)^{-1} \mathbf{r}_{rx}, \quad (4.78)$$

$$\kappa_k = \epsilon_k + r_x - \mathbf{z}_k^T \mathbf{r}_{rx}, \quad (4.79)$$

$$\mathbf{b}_k = \mathbf{a} - \mathbf{z}_k. \quad (4.80)$$

Zde je nutné poznamenat, že \mathbf{z}_k je odhad odezvy \mathbf{a} pomocí LMS s využitím pouze k -tého bloku dat. Vložení matice 4.77 do rovnice 4.74, dojde ke zjednodušení $Q(\mathbf{a})$

na

$$Q(\mathbf{a}) = 2 \langle \kappa_k^{-1} \mathbf{b}_k^T (\mathbf{R}_r + 2\kappa_k^{-1} \mathbf{r}_{rx} \mathbf{r}_{rx}^T) \mathbf{b}_k \rangle_M. \quad (4.81)$$

Batch-offline odhad

Vezmeme-li gradient rovnice 4.81

$$\frac{\partial}{\partial \mathbf{a}} Q(\mathbf{a}) = 4 \langle \kappa_k^{-1} \mathbf{b}_k^T (\mathbf{R}_r + 2\kappa_k^{-1} \mathbf{r}_{rx} \mathbf{r}_{rx}^T) \mathbf{b}_k \rangle_M. \quad (4.82)$$

a položíme ho rovný nule, dostaneme tak první iteraci našeho odhadu

$$\mathbf{B} = \langle \kappa_k^{-1} (\mathbf{R}_r + 2\kappa_k^{-1} \mathbf{r}_{rx} \mathbf{r}_{rx}^T) \mathbf{b}_k \rangle_M, \quad (4.83)$$

$$\mathbf{q} = \langle \kappa_k^{-2} (r_x + \mathbf{z}_k^T \mathbf{r}_{rx}) \mathbf{r}_{rx} \rangle_M, \quad (4.84)$$

$$\hat{\mathbf{a}} = \mathbf{B}^{-1} \mathbf{q}. \quad (4.85)$$

V dalších iteracích jen napočítáme matici \mathbf{B} a vektor \mathbf{q}

$$\mathbf{B} = \mathbf{B} + \langle \kappa_k^{-1} (\mathbf{R}_r + 2\kappa_k^{-1} \mathbf{r}_{rx} \mathbf{r}_{rx}^T) \mathbf{b}_k \rangle_M, \quad (4.86)$$

$$\mathbf{q} = \mathbf{q} + \langle \kappa_k^{-2} (r_x + \mathbf{z}_k^T \mathbf{r}_{rx}) \mathbf{r}_{rx} \rangle_M, \quad (4.87)$$

$$\hat{\mathbf{a}} = \mathbf{B}^{-1} \mathbf{q}. \quad (4.88)$$

a nahradíme $z_k = \hat{\mathbf{a}}$. [4] [5]

4.5 Guntherův odhad

Guntherův odhad je založen na maximálně věrohodném odhadu. Začíná inicializací hodnoty \mathbf{a} a každá iterace je provedena následovně

$$a_k = \mathbf{a}^T \mathbf{R}_r \mathbf{a} - 2\mathbf{a}^T \mathbf{r}_{rx} + r_x \quad (4.89)$$

$$\mathbf{B} = \langle a_k^{-1} \mathbf{R}_r \rangle_M, \quad \mathbf{q} = \langle a_k^{-1} \mathbf{r}_{rx} \rangle_M \quad (4.90)$$

$$\hat{\mathbf{a}} = \mathbf{B}^{-1} \mathbf{q}. \quad (4.91)$$

Aby metoda zkonvergovala do výsledné impulsní odezvy, tak to obvykle vyžaduje 2 až 5 iterací.

5 Porovnání metod v režimu cross-talku

Pro jednotlivé experimenty v této části je využita nahrávka promluvy muže a ženy z TIMIT [7], kteří reprezentují signály $s(n)$ a $r(n)$. Oba signály jsou délky 8,3 s a jsou využity pro simulaci double-talku. Vzorovací frekvence nahrávek je 16 kHz. Dále byl použit RIR generátor, což je generátor pro generování impulsní odezvy místnosti $a(n)$. Ve všech experimentech je v generátoru nastaven rozměr místnosti na $(5 \times 7 \times 3)$ m. Délka $a(n)$ je řízena skrz parametr doby odrazu T60, který je nastaven na 200 ms. Mikrofon je umístěn na pozici $[0.5 \ 0.10 \ 1]$ m v místnosti. Reprodukční se nachází na pozici $[1.5 \ 0.15 \ 1]$ m. Pro zhodnocení jednotlivých experimentů bylo použito Echo Return Loss Enhancement (ERLE).

V následujících experimentech budou porovnány metody LMS, RLS, Kalmanův filtr a SBAEC. Metody se zde porovnávají blokové a adaptivní, proto budou porovnány vždy kompletně odhadnuté impulsní odezvy. To znamená, že u adaptivních metod to bude impulsní odezva, která je získána adaptací přes celý signál. U blokových to bude odhad napočítaný přes všechny bloky.

ERLE


ERLE (Echo return loss enhancement) v našem případě určuje o kolik dB došlo k potlačení echa v zarušeném signálu. Čím je větší hodnota ERLE, tím je lepší odhad odezvy a naopak. Na hodnotu ERLE má vliv i signál samotný, hlavně jeho SNR, tedy poměr mezi hledaným signálem a echem. ERLE se v následujících experimentech počítá podle vzorce

$$ERLE = 10 \log_{10} \frac{\mathbf{a}_L^T \mathbf{S} \mathbf{a}_L}{(\mathbf{a}_L^T - \hat{\mathbf{a}})^T \mathbf{S} (\mathbf{a}_L - \hat{\mathbf{a}})}, \quad (5.1)$$

kde \mathbf{a}_L je prvních L vzorků původní impulsní odezvy. L je délka odhadované odezvy, která je označena $\hat{\mathbf{a}}$ a matice \mathbf{S} je Toeplitzovská matice vytvořená z autokorelační matice obsahující vzájemné korelace jednotlivých bloků referenčního signálu.

Vliv vstupního SNR na ERLE

Jako první způsob pro porovnání jednotlivých metod je postupné zvyšování vstupního SNR a vyhodnocení pomocí ERLE. Protože se jedná o experiment, kdy je aktivní jak cílový signál tak i echo. Žena reprezentuje chtěný signál a muž šum. Postupným zvyšováním SNR od -10 dB do 10 dB se mění míra zastoupení signálu, který chceme odstranit v zarušeném signálu, přičemž -10 dB je více zastoupený referenční signál, 0 db je 50 % z obou signálů a při 10 dB je méně zastoupený referenční signál. Délka filtru $\hat{a}(n)$, který je odhadován, je nastavena na 300 vzorků.




Obrázek 5.1: Vliv vstupního SNR na ERLE

Ve výsledku je vidět, že každá metoda se vzrůstajícím SNR méně potlačuje nechtěný signál, protože je v zarušeném signálu méně zastoupený a metody ho odhadují s většími obtížemi. Metoda SBAEC zůstává zhruba stejně účinná pro všechna vstupní SNR zatímco metody LMS a RLS postupně potlačují méně. a metoda Kalmanův filtr s větším vstupním SNR už nic nepotlačuje a selhává. Všechny metody lépe pracují pokud je v zarušeném signálu ve větší míře zastoupený ten signál, který je potřeba potlačit. Pokud je SNR vysoké a tedy echo slabé, potom je každé drobné

zlepšení dobré, protože potlačit slabé echo je těžké. Jak se SNR postupně zvyšuje, filtry spočítané metodami začínají být méně účinné. Zejména Kalmanův filtr.

Vliv délky odhadovaného filtru na ERLE

V dalším experimentu byla proměnným parametrem délka odhadované impulsní odezvy $\hat{a}(n)$. SNR (poměr signálu a šumu) bylo nastaveno na hodnotu -5dB. Jednotlivé délky filtru $\hat{a}(n)$ byly nastaveny od 150 do 550 vzorků vždy po 100 vzorcích. Výsledky budou opět vyhodnoceny pomocí ERLE.




Obrázek 5.2: Vliv délky filtru na ERLE

Na výsledném grafu tohoto experimentu je vidět, že SBAEC a RLS, daleko lépe potlačují nechtěný signál, pokud je spočítaný filtr dlouhý kolem 350 vzorků. LMS je jen o trošku horší než RLS. Poslední testovaný je Kalmanův filtr, který je opět nejhorší ze všech testovaných a od délky filtru 350 vzorků se drží míra potlačení na stejné úrovni.

Vliv délky generované impulsní odezvy na ERLE

Posledním experimentem v této části je porovnání vlivu parametru T_{60} , který určuje dobu odrazu impulsní odezvy (délku impulsní odezvy) na jednotlivé metody. Hlavním rozdílem od předchozího experimentu je, že zde měníme parametr určující délku skutečné impulsní odezvy, kdežto v předchozím experimentu se měnila délka odhadované impulsní odezvy. Vyhodnocení tohoto experimentu bude opět pomocí ERLE. Délka počítaného filtru $\hat{a}(n)$ je nastavena na 100 vzorků. Vstupní poměr signálu a echa byl nastaven na -5 dB.



Obrázek 5.3: Vliv parametru T_{60} na ERLE

Ve výsledku posledního experimentu je vidět, že SBAEC, ze všech metod potlačuje rušení při všech testovaných hodnotách parametru T_{60} nejlépe. Stejně tak metoda RLS. Na Kalmanův filtr má zvyšování hodnoty parametru T_{60} největší vliv a postupným zvyšováním délky vygenerovaného filtru je jeho ERLE nižší.

6 Úprava pro výpočet řídké impulsní odezvy

Pokud chceme zpřesnit odhad řídkých impulsních odezev, musíme upravit jednu z metod. Pro úpravu byla vybrána metoda SBAEC. Pokud se zpřesní výpočet řídkých odezev, tak se zlepší i potlačení rušení, které je takovou odezvou změněné. Můžeme také aproximovat husté impulsní odezvy. Bude tak ztracena určitá přesnost výpočtu, ale odhadnout řídkou impulsní odezvu budeme moci velice dobře. Ve výsledku tedy může být odhad řídké impulsní odezvy přesnější a lepší než odhad husté impulsní odezvy.

V této kapitole budou popsány jednotlivé kroky úpravy metody SBAEC pro výpočet řídkých impulsních odezev.

6.1 Úprava

Nejprve upravíme rovnici č. 4.81. Chceme najít kvadratické kritérium v následujícím tvaru, které má minimum ve stejném bodě jako 4.81

$$\|\mathbf{A}\mathbf{a} - \mathbf{b}\|_2^2, \quad (6.1)$$

roznásobením je získán vztah

$$\|\mathbf{A}\mathbf{a} - \mathbf{b}\|_2^2 = \mathbf{a}^T \mathbf{A}^T \mathbf{A} \mathbf{a} - 2\mathbf{b}^T \mathbf{A} \mathbf{a} + \mathbf{b} \mathbf{b}^T. \quad (6.2)$$

Kritérium Q chceme zapsat ve stejném tvaru jako 6.2. To je možné tak

$$Q(\mathbf{a}) = \mathbf{a}^T \mathbf{G} \mathbf{a} + \mathbf{g}^T \mathbf{a} + c, \quad (6.3)$$

kde

$$\mathbf{G} = \mathbf{A}^T \mathbf{A}, \quad (6.4)$$

$$\mathbf{g} = -2\mathbf{b}^T \mathbf{A}. \quad (6.5)$$

a c je konstanta, na které nám nezáleží, protože neovlivňuje pozici minima. Nyní můžeme tyto kroky aplikovat na 4.81 s tím, že si zvolíme substituci

$$\mathbf{T} = (\mathbf{R}_r + 2\kappa_k^{-1} \mathbf{r}_{rx} \mathbf{r}_{rx}^T) \quad (6.6)$$

a za \mathbf{b}_k dosadíme 4.80. Výsledný vztah je tak zjednodušen

$$Q(\mathbf{a}) = 2\langle \kappa_k^{-1} (\mathbf{a} - \mathbf{z}_k)^T \mathbf{T} (\mathbf{a} - \mathbf{z}_k) \rangle_M. \quad (6.7)$$

Pokud je tento vztah roznásoben je získán tvar

$$Q(\mathbf{a}) = 2\mathbf{a}^T \langle \mathbf{T} \kappa_k^{-1} \rangle_M \mathbf{a} - 2\mathbf{a} \langle 2\mathbf{T} \kappa_k^{-1} \mathbf{z}_k \rangle_M + 2\langle \mathbf{z}_k^T \mathbf{T} \mathbf{z}_k \kappa_k^{-1} \rangle_M. \quad (6.8)$$

Nyní již máme rovnici ve tvaru jako 6.3 a můžeme zapsat, že

$$\mathbf{G} = \langle \mathbf{T} \kappa_k^{-1} \rangle_M = \langle (\mathbf{R}_r + 2\kappa_k^{-1} \mathbf{r}_{rx} \mathbf{r}_{rx}^T) \kappa_k^{-1} \rangle_M, \quad (6.9)$$

$$\mathbf{g} = \langle 2\mathbf{T} \kappa_k^{-1} \mathbf{z}_k \rangle_M = \langle 2(\mathbf{R}_r + 2\kappa_k^{-1} \mathbf{r}_{rx} \mathbf{r}_{rx}^T) \kappa_k^{-1} \mathbf{z}_k \rangle_M. \quad (6.10)$$

Vzhledem k tomu, že \mathbf{G} je symetrická a pozitivně semidefinitní matice, tak je možné získat matici a pomocí pravidla

$$\mathbf{G} = \mathbf{U} \mathbf{V} \mathbf{U}^T = \mathbf{U} \sqrt{\mathbf{V}} \sqrt{\mathbf{V}} \mathbf{U}^T, \quad (6.11)$$

kde \mathbf{U} je matice jejíž sloupcové vektory značí jednotlivé vlastní vektory a \mathbf{V} je diagonální matice vlastních čísel matice \mathbf{G} . Dále na základě vzorce č. 6.4 může být zapsáno, že

$$\mathbf{a} = \sqrt{\mathbf{V}} \mathbf{U}^T. \quad (6.12)$$

A vektor \mathbf{b} lze vypočítat ze vztahu

$$\mathbf{b} = (-2\mathbf{A}^T)^{-1}\mathbf{g}. \quad (6.13)$$

Pro výpočet řídké impulsní odezvy je ke vzorci č. 6.1 přičtena ℓ_1 norma, která má definici

$$\|x\|_1 = \sum_i |x_i|. \quad (6.14)$$

Vznikne tak vzorec, který může být později minimalizován

$$\|\mathbf{A}\mathbf{a} - \mathbf{b}\|_2^2 + \tau\|\mathbf{a}\|_1, \quad (6.15)$$

kde τ určuje míru řídkosti. τ může být nastaveno pro celou impulsní odezvu stejné a nebo může být pomocí váhovací funkce nastaveno pro každý koeficient filtru jiné. K tomu může být využita jednoduchá váhovací funkce, která bude popsána níže. Pokud je τ nastaveno na nízkou hodnotu, poté filtr vychází s více nulovými koeficienty a nebo naopak. Při použití váhovací funkce bude řídkost impulsní odezvy určena lépe.

Nyní můžeme využít některý z algoritmů pro minimalizaci ℓ_1 normy. Algoritmy, které jsou použity v této práci:

- ℓ_1 -Homotopy,
- SpaRSA.

Jelikož Guntherův algoritmus také počítá v každé iteraci matici \mathbf{B} a vektor \mathbf{q} , tak bychom z nich mohli vyjádřit matici \mathbf{A} a vektor \mathbf{b} a dosadit do dvou zmiňovaných algoritmů ℓ_1 -Homotopy a SpaRSA. v následující kapitole bude porovnáno zda se zlepší i tato metoda.

6.2 Váhovací funkce

Při využití algoritmu ℓ_1 -Homotopy můžeme nastavit jednotlivé hodnoty τ pro každý vzorek spočtené impulsní odezvy. To je vyřešeno jednoduchým for cyklem, který prochází impulsní odezvu. Na základě určené hranice, která je označena K , se nastaví τ pro daný vzorek buď na 0.3, nebo na 1.

Algoritmus 1 Váhová funkce

```
1: for  $i = 1$  až délka(a) do  
2:   if  $a_i \geq K$  then  
3:      $w_i = 0.1$   
4:   else  
5:      $w_i = 1$   
6:   end if  
7: end for
```

7 Porovnání metod v režimu cross-talku pro výpočet řídkých impulsní odezev

Pro experimenty s reálnými impulsními odezvami, byly využity impulsní odezvy z databáze od profesora Sharona Gannota z Bar-Ilan University [8]. Opět byla použita nahrávka promluvy muže a ženy z TIMIT [7].

Pro jednotlivé experimenty v následující části byly vybrány impulsní odezvy, kde byl mluvčí vzdálený 2 m od mikrofonu s proměnnou délkou a směry, ze kterých hlas mluvčího přicházel. Dále z těchto odezev byly vytvořeny řídké impulsní odezvy podle pravidla


$$|\mathbf{a}_i| \leq \varepsilon \rightarrow \mathbf{a}_i = 0, \quad (7.1)$$

kde ε je malé kladné číslo určující mez řídkosti. Takto upravené metody byly potom využity k vytvoření zarušeného signálu.

Vliv vstupního SNR na ERLE

První experiment se týká poměru signálu a rušení, kdy zvyšováním SNR je méně slyšet rušení a je tedy obtížněji odhadnutelná jeho impulsní odezva. Pro tento experiment byla zvolena impulsní odezva, kde byl mluvčí reprezentující echo vzdálený 2 m od mikrofonu a hovořil z úhlu 0° , byl tedy přímo před mikrofonem. Hodnota parametru T60, který určuje délku skutečné odezvy byla nastavena na 160 ms. Délka odhadované impulsní odezvy byla nastavena na délku 600 vzorků.

Výsledek tohoto experimentu je vidět na obrázku č. 7.1, kde postupným zvyšováním SNR klesá míra potlačení u všech způsobů odhadu. Řídké odhady upravené metody SBAEC jsou vždy o pár dB lepší v potlačení rušení. U řídkého odhadu pomocí Guntherovy metody se s vyšším SNR potlačení rušení téměř nezvyší.




Obrázek 7.1: Vliv vstupního SNR na ERLE

Vliv délky odhadované impulsní odezvy na ERLE

Druhý experiment je zaměřený na proměnnou hodnotu délky odhadovaného filtru. Zvolená impulsní odezva zůstala stejná a jednotlivá nastavení také. SNR bylo nastaveno na 5 dB. Ve výsledném zarušeném signálu, je tedy slabší rušení.

Na výsledném grafu, který je v obrázku č. 7.2 můžeme vidět, že se potlačení mírně zmenší s delší odhadnutou odezvou až na odhad upravené metody SBAEC a vyhodnocení řídkosti pomocí knihovny SpaRSA.




Obrázek 7.2: Vliv délky odhadované impulsní odezvy na ERLE

Vliv skutečné délky impulsní odezvy na ERLE

Třetím experimentem je zjištění vlivu skutečné délky odezvy, která je určena parametrem T_{60} . Pro tento experiment byly zvoleny tři impulsní odezvy z databáze, všechny jsou se stejným úhlem 0° a vzdáleností od mikrofonu 2 m. Parametry T_{60} jsou 160 ms, 360 ms a 610 ms. SNR se kvůli tomuto proměnnému parametru trochu mění, ale zůstává na hodnotách kolem 6dB.

Z výsledků na obrázku č. 7.3 lze vyčíst, že řídký odhad upravené metody je na tom znovu nejlépe a vliv na jednotlivé metody výpočtu má změna parametru T_{60} dosti podobný. U jediného odhadu SBAEC s pomocí knihovny SpaRSA je při delší skutečné odezvě větší pokles. Toto může být zapříčiněno tím, že tato knihovna nemá možnost volby parametru τ pro každý vzorek odezvy.

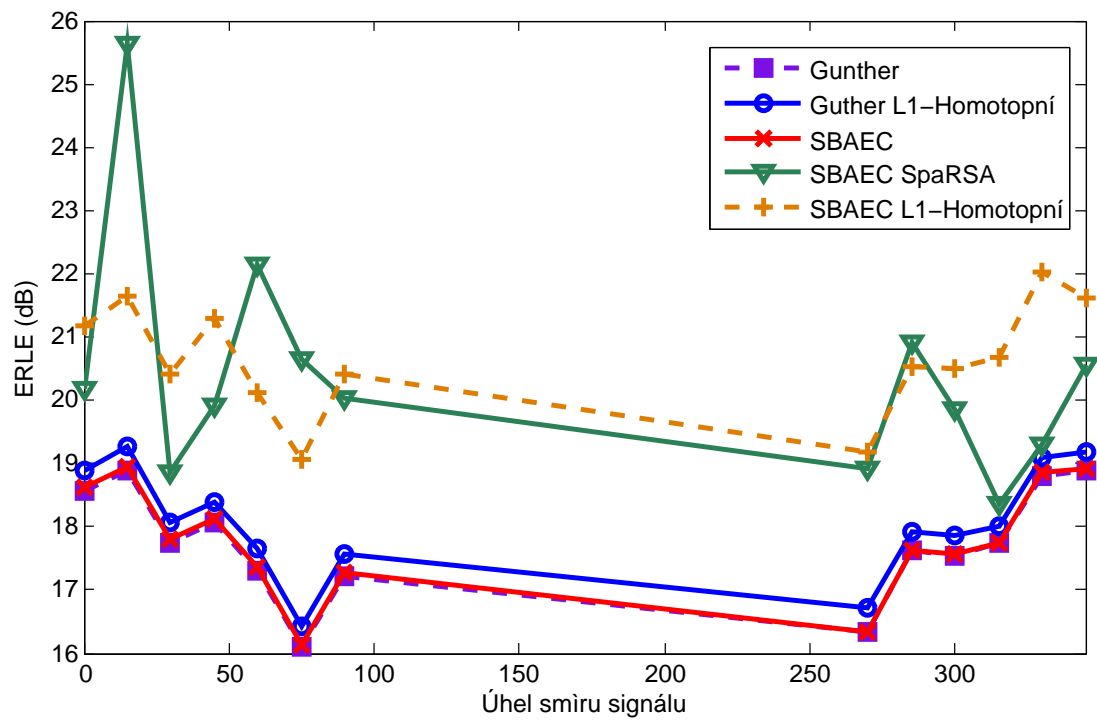


Obrázek 7.3: Vliv původní délky impulsní odezvy na ERLE

Vliv úhlu šíření signálu k mikrofonu na ERLE

V posledním experimentu se zjišťuje jaký bude mít vliv na výpočet změna směru příchodu signálu. Jednotlivé úhly jsou dány od 0° do 90° vždy po 15° a od 270° do 345° . Je tedy otestováno 13 různých impulsních odezev. Skutečná délka impulsní odezvy, byla nastavena na 160 ms a vzdálenost mluvčího od mikrofonu 2 m. SNR bylo díky použití více impulsních odezev mezi 6 dB a 9 dB.

Ve výsledku můžeme vidět, že směr nemá skoro žádný vliv na odhady. Kromě odhadu SBAEC SpaRSA u kterého by se pro menší výkyvy mohlo nastavit pro jednotlivé impulsní odezvy, vždy jiný parametr τ .



Obrázek 7.4: Vliv směru příhodu signálu na ERLE

Závěr

Mými úkoly bylo nastudovat metody pro potlačování akustické odezvy zejména SBAEC. Tyto metody jsou v práci popsány, aby si je čtenář mohl zkusit naprogramovat. Následně jsem tyto metody naprogramoval v programovacím jazyce matlab a porovnal je mezi sebou. Potvrdily se mé předpoklady, že metoda SBAEC bude potlačovat nejlépe hlavně při vysokém SNR, kdy je rušení v signálu obsaženo méně a je špatně potlačitelné.

V další části bylo úkolem modifikovat metodu SBAEC, aby byla schopna přesněji odhadnout řídkou impulsní odezvu. K tomuto účelu byl vybrán způsob, kdy její kvadratické kritérium bylo potřeba dostat do tvaru $\|\mathbf{a} - \mathbf{b}\|_2^2$ a přidat k němu minimalizaci ℓ_1 normy. Následně jsem využil algoritmy ℓ_1 -Homotopy a SpARSA pro určení řídkosti.

Poslední částí bylo otestování míry potlačení při různých proměnných parametrech. Porovnával jsem zároveň metody SBAEC a Guntherovu metodu v neupraveném a upraveném stavu. Podle předpokladů většinou nejlépe vycházela metoda SBAEC, když byl použit algoritmus ℓ_1 -Homotopy pro určení řídkosti. Největší vliv měla na výsledky hodnota SNR. Při hodnotě SNR 10dB (více echa v zarušeném signálu) bylo zlepšení při odhadu řídké odezvy až 2dB.

Literatura

- [1] HAYKIN, Simon *Adaptive filter theory*. 4th ed. Upper Saddle River: Prentice Hall, 2002, 920 s. ISBN 01-309-0126-1.
- [2] E. Lehmann and A. Johansson, „Prediction of energy decay in room impulse responses simulated with an image-source model“, *Journal of the Acoustical Society of America*, vol. 124, no. 1, pp. 269–277, July 2008.
- [3] C. Paleologu, J. Benesty and S. Ciochina, „Study of the General Kalman Filter for Echo Cancellation“, *IEEE Transactions on Audio, Speech, and Language Processing*, vol. 21, no. 8, August 2013.
- [4] P. Tichavský and Z. Koldovský, „Weight adjusted tensor method for blind separation of underdetermined mixtures of nonstationary sources“, *IEEE Transactions on Sig. Proc.*, vol. 59, no. 3, pp. 1037–1047, March 2011.
- [5] Z. Koldovský, J. Málek, M. Müller a P. Tichavský, „On semi-blind estimation of echo paths during double-talk based on nonstationarity“, *International Workshop on Acoustic Signal Enhancement (IWAENC)*, pp. 198 - 202, September 2014
- [6] CONSTANTIN PALEOLOGU, Jacob Benesty. Sparse adaptive filters for echo cancellation. San Rafael, Calif.: Morgan & Claypool, 2010. ISBN 9781598293067.
- [7] J. S. Garofolo, et al., „TIMIT Acoustic-Phonetic Continuous Speech Corpus“, Linguistic Data Consortium, Philadelphia, 1993.
- [8] E. Hadad, F. Heese, P. Vary, and S. Gannot, „Multichannel audio database in various acoustic environments“, International Workshop on Acoustic Signal Enhancement 2014 (IWAENC 2014), Antibes, France, Sept. 2014.

- [9] Stephen J. Wright, Robert D. Nowak, Senior Member, IEEE, and Mário A. T. Figueiredo, Senior Member, IEEE, „Sparse Reconstruction by Separable Approximation“, *IEEE Transactions on Signal Processing*, vol. 57, no. 7, July 2009

Obsah přiloženého CD

- dokumentace
- experimenty metod v režimu cross-talk
- experimenty pro porovnání zlepšení výpočtu řídkých odezev