

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ
ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING


ADAPTIVNÍ FILTRACE EKG SIGNÁLŮ

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE
AUTHOR


Bc. ZDENĚK NEJEZCHLEBA

BRNO 2011



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ**

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

ADAPTIVNÍ FILTRACE EKG SIGNÁLŮ

ADAPTIVE FILTERING OF ECG SIGNALS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR


Bc. ZDENĚK NEJEZCHLEBA

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. LUKÁŠ SMITAL

BRNO 2011



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav biomedicínského inženýrství

Diplomová práce

magisterský navazující studijní obor
Biomedicínské a ekologické inženýrství

Student: Bc. Zdeněk Nejezchleba

ID: 74886

Ročník: 2

Akademický rok: 2010/2011

NÁZEV TÉMATU:

Adaptivní filtrace EKG signálů

POKYNY PRO VYPRACOVÁNÍ:

Navrhněte a realizujte v programovém prostředí Matlab metody pro potlačení síťového rušení v signálech EKG s využitím adaptivních filtrů. Zaměřte se především na lineární metody. Zhodnoťte (podle SNR) úspěšnost navržených adaptivních filtrů pro elektrokardiogramy uměle rušené síťovým kmitočtem. Dále srovnajte s výsledky dosaženými odlišnými metodami, např. s lineární úzkopásmovou filtrací.

DOPORUČENÁ LITERATURA:

[1] JAN, J. Číslíková filtrace, analýza a restaurace signálů. VUT v Brně, nakl. VUTIUM, 2002.

[2] ZAKNICH, A. Principles of Adaptive Filters and Self-learning Systems. London : Springer-Verlag, 2005. 386 s. ISBN 1-85233-984-5.

Termín zadání: 15.10.2010

Termín odevzdání: 20.5.2011

Vedoucí práce: Ing. Lukáš Smital

prof. Ing. Ivo Provazník, Ph.D.

Předseda oborové rady

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové 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

Cílem práce bylo vyzkoušet metody potlačování 50 Hz brumu adaptivní filtrací. Při použití obecného adaptivního schématu a schématu pro potlačení deterministického brumu. V práci je teoretické odvození adaptivního algoritmu a několik příkladů modelace v programu MATLAB.

KLÍČOVÁ SLOVA

EKG, Adaptivní filtr, odstranění brumu, šum, LMS, MATLAB

ABSTRACT

The aim was to test the methods for suppression 50 Hz noise with adaptive filtering. When using the general scheme of adaptive and deterministic scheme to suppress hum. The work is a theoretical derivation of adaptive algorithms and some examples of modeling in MATLAB.

KEYWORDS

EKG, adaptive filtering, LMS algorithm, MATLAB, noise filtering

NEJEZCHLEBA, Zdeněk *ADAPTIVNÍ FILTRACE EKG SIGNÁLŮ* : diplomová práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2011. 48 s. Vedoucí práce byl Ing. Lukáš Smital

PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma „ADAPTIVNÍ FILTRACE EKG SIGNÁLŮ “ jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

Brno

.....

(podpis autora)

Děkuji vedoucímu diplomové práce Ing. Lukáši Smitalovi za pedagogické vedení mé diplomové práce.

V Brně dne 20. května 2011

OBSAH

Úvod	11
1 Teoretický úvod	13
1.1 STRUČNÝ POPIS SIGNÁLU EKG	13
1.2 ZÁKLADNÍ ZNALOSTI O ADAPTIVNÍCH FILTRECH	15
1.3 TEORETICKÉ ODVOZENÍ ADAPTAČNÍHO MECHANIZMU	17
1.4 MODIFIKACE ADAPTAČNÍCH ALGORITMŮ	18
1.4.1 Sign-Error Algoritmus	18
1.4.2 Sign-Data Algoritmus	19
1.4.3 Sign-Sign Algoritmus	19
1.4.4 LMS-Newton Algoritmus	19
1.5 ZÁKLADNÍ ADAPTAČNÍ SCHÉMATA	20
1.6 MODIFIKA PRO POTLAČENÍ DETERMINISTICKÉHO BRUMU	20
1.7 GENETICKÝ ALGORITMUS	21
1.7.1 Obecné schéma genetického algoritmu	22
2 MODELACE	24
2.1 DEFINICE VSTUPŮ	24
2.1.1 Obecné adaptační schéma a obecný algoritmus	26
2.1.2 Obecné adaptační schéma a algoritmus signum data	28
2.1.3 Obecné adaptační schéma a algoritmus signum error	30
2.1.4 Obecné adaptační schéma a algoritmus signum signum	32
2.1.5 Obecné adaptační schéma a Newtonův algoritmus	34
2.1.6 Brumové adaptační schéma a obecný algoritmus	36
2.1.7 Brumové adaptační schéma a algoritmus signum data	38
2.1.8 Brumové adaptační schéma a algoritmus signum error	40
2.1.9 Brumové adaptační schéma a algoritmus signum signum	42
3 Závěr	44
Literatura	46
Seznam symbolů, veličin a zkratk	47
A Ovládání M-file souborů v prostředí MATLAB	48

SEZNAM OBRÁZKŮ

1.1	Charakteristický průběh signálu EKG s popisem jednotlivých segmentů.	14
1.2	Autoregresní model klouzavých součtů.	15
1.3	Model klouzavých součtů.	16
1.4	Metoda nejstrmějšího spádu.	17
1.5	Základní schéma adaptace.	20
1.6	Modifikované schéma adaptace.	20
2.1	Vstupní signály.	24
2.2	Zašumněný signál.	25
2.3	Zašumněný signál šumem s amplitudovou modulací.	25
2.4	Vyfiltrovaný signál při použití obecného schématu a obecného adaptačního algoritmu - první signál. Tab 2.1	27
2.5	Vyfiltrovaný signál při použití obecného schématu a obecného adaptačního algoritmu - druhý signál. Tab 2.1	27
2.6	Vyfiltrovaný signál při použití obecného schématu a algoritmu signum data - první signál. Tab 2.1	28
2.7	Vyfiltrovaný signál při použití obecného schématu a algoritmu signum data - druhý signál. Tab 2.2	29
2.8	Vyfiltrovaný signál při použití obecného schématu a algoritmu signum error - první signál. Tab 2.3	31
2.9	Vyfiltrovaný signál při použití obecného schématu a algoritmu signum error - druhý signál. Tab 2.3	31
2.10	Vyfiltrovaný signál při použití obecného schématu a algoritmu signum signum - první signál. Tab 2.4	32
2.11	Vyfiltrovaný signál při použití obecného schématu a algoritmu signum signum - druhý signál. Tab 2.4	33
2.12	Vyfiltrovaný signál při použití obecného schématu a Newtonova algoritmu - první signál. Tab 2.5	34
2.13	Vyfiltrovaný signál při použití obecného schématu a Newtonova algoritmu - druhý signál. Tab 2.5	35
2.14	Vyfiltrovaný signál při použití brumového schématu a obecného adaptačního algoritmu - první signál. Tab 2.6	37
2.15	Vyfiltrovaný signál při použití brumového schématu a obecného adaptačního algoritmu - druhý signál. Tab 2.6	37
2.16	Vyfiltrovaný signál při použití brumového schématu a algoritmu signum data při použití nejlepšího filtru z tabulky. Tab 2.7	39
2.17	Vyfiltrovaný signál při použití brumového schématu a algoritmu signum error - první signál. Tab 2.8	41

2.18	Vyfiltrovaný signál při použití brumového schématu a algoritmu signum error - druhý signál. Tab 2.8	41
2.19	Vyfiltrovaný signál při použití brumového schématu a algoritmu signum signum - první signál. Tab 2.9	43
2.20	Vyfiltrovaný signál při použití brumového schématu a algoritmu signum signum - druhý signál. Tab 2.9	43

SEZNAM TABULEK

2.1	Úspěšnost vyfiltrování signálu při použití obecného schématu a obecného adaptačního algoritmu	26
2.2	Úspěšnost vyfiltrování signálu při použití obecného schématu a algoritmu signum data	28
2.3	Úspěšnost vyfiltrování signálu při použití obecného schématu a algoritmu signum error	30
2.4	Úspěšnost vyfiltrování signálu při použití obecného schématu a algoritmu signum signum	32
2.5	Úspěšnost vyfiltrování signálu při použití obecného schématu a Newtonova algoritmu	34
2.6	Úspěšnost vyfiltrování signálu při použití brumového schématu a obecného algoritmu	36
2.7	Úspěšnost vyfiltrování signálu při použití brumového schématu algoritmu signum data	38
2.8	Úspěšnost vyfiltrování signálu při použití brumového schématu algoritmu signum error	40
2.9	Úspěšnost vyfiltrování signálu při použití brumového schématu algoritmu signum signum	42
3.1	Úspěšnost vyfiltrování signálu při změně vlastností šumu	44

ÚVOD

Adaptivní filtrace představuje efektivní způsob potlačení parazitního signálu v užitečném signálu (např. elektrokardiografický signál EKG, apod.). Adaptivní filtry lze s úspěchem použít tam kde rušení s časem mění svoje parametry nebo jeho parametry předem neznáme. V takovém případě pak nelze navrhnout potřebný či optimální filtr, který je obvykle lineární.

Metody adaptivní filtrace se využívají v lékařství díky rozvoji digitalizace. Prostřednictvím analýzy EKG signálu lze diagnostikovat řadu nemocí. Data získaná z Holterovského vyšetření, z klidového EKG a zátěžového vyšetření slouží ke zjištění srdečních arytmí, srdeční ischemie, infarktu, atd.

Data zaznamenaná z povrchu těla pacienta jsou však často kontaminována šumem. Mezi základní typy šumu patří následující.

- Kolísání nulové linie (drift) – je způsobeno elektrochemickými ději na rozhraní elektroda – kůže. Jedná se o náhodné rušení, dechové a obecně pohyby pacienta.
- Síťové rušení (brum) – je zapříčiněno indukci harmonického signálu z elektrovodné sítě. V České republice se jedná o kmitočet 50 Hz, v některých jiných zemích jde o kmitočet 60 Hz. Cílem této práce je odstranění tohoto typu šumu.
- Myopotenciály – je napětí vznikající při činnosti svalů. Projevuje se ve všech částech užitečného spektra EKG signálu. Rušení myopotenciály je typické pro zátěžové EKG.

Existují systémy, které se snaží síťové rušení účinně potlačit. Většina z nich jsou lineární filtry kvůli jejich relativně snadnému návrhu a zejména jednoduché implementaci. Současné systémy také využívají nelineární systémy, adaptivní systémy a v poslední době umělé neuronové sítě. V této práci se budeme zabývat metodou adaptivní filtrace s použitím obecného a brumového schématu s různými variantami algoritmů. Jedná se o sestavení rychlého algoritmu, který potlačí rušení v EKG signálu. V této práci je použit výhradně algoritmus LMS, který je méně výpočetně náročný. Snahou bude najít filtry s optimální kvalitou filtrace.

Jako adaptivní filtr se často využívá lineární filtr s konečnou impulsovou odezvou (FIR), jehož koeficienty jsou průběžně měněny adaptivním algoritmem. Ten monitoruje vlastnosti vstupního a výstupního signálu z filtru a z vypočteného chybového signálu se snaží optimálně nastavit koeficienty filtru tak, aby chybový signál byl co nejmenší.

Vzledem k efektivitě vyhledávání optimálních parametrů filtru nelze použít metodu vyzkoušení všech filtrů z určitého rozsahu, ať už rychlosti učení tak délky impulzní charakteristiky. Proto jsou pro nalezení vhodného filtru použity genetické algoritmy.

1 TEORETICKÝ ÚVOD


1.1 STRUČNÝ POPIS SIGNÁLU EKG

Elektrokardiogram (EKG) je grafický záznam srdečních potenciálů snímaných z povrchu těla nebo ze srdečních dutin. Stah svalových buněk počíná elektrickou změnou zvanou depolarizace. EKG snímané z povrchu těla zaznamenává depolarizaci všech jednotlivých buněk srdečního svalu. Tvar EKG vln závisí na sekvenci iontových změn, které depolarizaci působí a na způsobu jak se tyto šíří srdcem. Je-li jednotlivá svalová buňka v klidu, její povrch je nabit pozitivně a vnitřek negativně. Rozdíl potenciálů na membráně je okolo -90mV . Elektrický podnět způsobí rychlý tok Na^+ z extracelulární tekutiny do buňky, čímž se vnitřek buňky stává oproti okolí pozitivním. Membránový potenciál rychle dosáhne $+30\text{mV}$. Počáteční proud sodíkových iontů rychle ustává a je následován pomalým vstupem dalších Na^+ iontů. V tomto stadiu se také pohybují relativně pomalu do svalové buňky kalciové ionty. Společný vstup těchto dvou iontů směřuje k tomu, aby se membránový potenciál stal ještě více pozitivní. Avšak toto je vyváženo únikem kalciového iontu z buňky ven.

Elektrickým výsledkem těchto pozdějších toků iontů je, že membránový potenciál svalové buňky se udržuje okolo nuly asi po 200ms a potom nastane repolarizační fáze, při níž klesá membránový potenciál na klidových -90mV .

Když povrch jedné srdeční buňky změní polaritu z pozitivní na negativní, vznikne proud pozitivních iontů z extracelulární tekutiny z přilehlých buněk k depolarizované. Tento iontový pohyb spustí depolarizaci v klidových buňkách. Depolarizace se tedy šíří jako postupující vlna z buňky, která byla jako první depolarizována. Povrchový elektrokardiogram zaznamená tuto vlnu depolarizace; jelikož buňky myokardu jsou depolarizované, EKG zaznamená změnu elektrické aktivity na povrchu těla, ale když srdeční buňky jsou úplně depolarizované se stálým membránovým potenciálem rovným nule, EKG se vrátí k základní nulové linii.

Během repolarizace vzniká druhá elektrická vlna na tělesném povrchu a EKG zaznamená další odklon, kterým je vlna T. Charakteristický průběh signálu EKG. viz obr 1.1



Obr. 1.1: Charakteristický průběh signálu EKG s popisem jednotlivých segmentů.

- Vlna P - zobrazuje postup aktivace síní
- interval PQ (PRinterval) - doba převodu aktivace ze síní na komory
- komplex QRS_D - projev aktivace komor, tvar dán postupem aktivace v srdci (depolarizace)
- segment ST_D - doba, kdy jsou komory aktivovány (plató akčního potenciálu)
- vlna T - repolarizace začínající u buněk, které byly aktivovány jako poslední (největší akční potenciál), a proto má vlna T stejnou polaritu jako největší výchylka komplexu QRS


1.2 ZÁKLADNÍ ZNALOSTI O ADAPTIVNÍCH FILTRECH

Adaptivní filtry svou podstatou vyplňují místo. Klasický přístup k filtraci vyžaduje velké znalosti o chování systému, jakož i jeho charakteru, a to jak z pohledu užitečného signálu tak i nechtěné složky. Tyto znalosti je možné zjistit u stacionárních procesů.

V případě aplikace filtru v neznámém nebo v čase se měnícím prostředí je předběžná identifikace nemožná. Cílem je vytvořit filtr adaptivní, který je schopen se v dané aplikaci sám modifikovat, a to tak aby odhady veličin se co nejvíce blížili skutečné hodnotě. [1], V principu je pak možné také očekávat, že filtr bude s určitou rychlostí schopen reagovat i na změny tohoto prostředí a tedy zpracovávat i signály, generované nestacionárními procesy, aniž by časově proměnné parametry těchto procesů byly předem známy.“ Daní za schopnost adaptace na časově variantní druh signálu je nutnost přivádět filtru dodatečnou informaci v podobě tzv „trénovacího signálu“ jako druhý vstup filtru. Tento trénovací signál musí úzce souviset s požadovaným signálem, v nejjednodušším případě přímo požadovaný výstup, nebo tato souvislost musí nastávat mezi trénovacím signálem a signálem parazitním, který chceme filtrem odfiltrout.


Na první pohled může být závažnější potřeba filtrovat signál jehož požadovaný výstup známe s dostatečnou přesností. Toto však můžeme používat periodicky k naučení adaptivního filtru k odstranění zkreslení přenosovou cestou, typicky mobilní sítě.

Adaptivní filtry dělíme podle impulsní charakteristiky na filtry s nekonečnou charakteristikou(IIR) a s konečnou charakteristikou(FIR)



Obr. 1.2: Autoregresní model klouzavých součtů.

Obecnější jsou typu ARMA 1.2 (Autoregressive moving average process), IIR filtry, jejichž nevýhodou je nutnost kontrolovat stabilitu filtru v každém kroku adaptace, a v případě nestability učinit kroky potřebné ke stabilizaci.



Obr. 1.3: Model klouzavých součtů.

V této práci se bude dále zabývat filtry typu MA 1.2 , FIR, které jsou z podstaty věci vždy stabilní. Filtry typu MA se dělí v základu na filtry RLS a LMS, Filtry typu RLS se v této práci také nebudeme zabývat.

1.3 TEORETICKÉ ODVOZENÍ ADAPTAČNÍHO MECHANIZMU

Least-mean-squares algoritmus publikovali v roce 1959 pánové Widrow a Hoff. Jedná se o algoritmus minimalizující kvadratickou odchylku funkce.

Algoritmus LMS je jedním z nejpoužívanějších algoritmů v adaptivní filtraci a to z několika důvodů. Mezi hlavní příčinu tohoto patří nízká výpočetní náročnost, jednoznačná konvergence ve stacionárním prostředí a stabilní chování při výpočtu s konečnou přesností.


Střední kvadratická odchylka ε_n^2 je definována jako

$$\varepsilon_n^2 = \mathbb{E} \{ (x_n - \hat{x}_n)^2 \} \quad (1.1)$$

V případě FIR filtru s konečným počtem koeficientů $n = 0, 1, 2, \dots, N$

$$\varepsilon_n^2 = \mathbb{E} \left\{ \left(x_n - \sum_{i=0}^N h_i x_{(n-i)} \right)^2 \right\} \quad (1.2)$$

Koeficienty $h(i)$ hledáme jako minimum ε_n^2 metodou největšího spádu. Pro jednoduchost použijeme filtr o jednom koeficientu, označíme ho jako $t = h(0)$. Střední kvadratická odchylka je funkcí $f(t)$ proměnné t s minimumem s t_{min} viz obr 1.3



Obr. 1.4: Metoda nejstrmějšího spádu.

K minimumu t_{min} se blížíme iteračním vztahem

$$t_{n+1} = t_n - \mu f'(t_n) \quad (1.3)$$

$$t_{n+1} = t_n - (1 - 2\mu)(t_n - t_{min}) \quad (1.4)$$

Kde t_n je počáteční hodnota, f' je derivace funkce v bodě a konvergenčním μ určujeme rychlost konvergence. Jako takový musí být tento parametr nenulový a kladný. Pokud jej zvolíme příliš malý, řešení konverguje pomalu, pokud jej zvolíme přespříliš velký řešení diverguje.

V případě nahrazení t vektorem \mathbf{W} dostáváme vztah

$$\mathbf{W}_{n+1} = \mathbf{W}_n - \mu \nabla (\varepsilon_n^2) \quad (1.5)$$

Symbol ∇ označuje operátor gradientu. Ten můžeme psát jako

$$\begin{aligned} \nabla (\varepsilon_n^2) &= \left[\frac{\partial e^2(n)}{\partial W_k(0)} \frac{\partial e^2(n)}{\partial W_k(1)} \cdots \frac{\partial e^2(n)}{\partial W_k(M-1)} \right]^T = \\ &= -2e(k) \left[\frac{\partial e(n)}{\partial W_k(0)} \frac{\partial e(n)}{\partial W_k(1)} \cdots \frac{\partial e(n)}{\partial W_k(M-1)} \right]^T = -2e(k) \mathbf{x}(n-k) \end{aligned} \quad (1.6)$$

Čímž dostáváme finální podobu adaptačního algoritmu

$$\mathbf{W}_{k+1} = \mathbf{W}_k + 2\mu e(k) \mathbf{x}_k \quad (1.7)$$

1.4 MODIFIKACE ADAPTAČNÍCH ALGORITMŮ

Mezi základní modifikace patří použití funkce signum, jejíž výhodou je zrychlení strojového výpočtu. Dochází sice k snížení rychlosti konvergence ovšem toto nemusí být problém při filtraci v reálném čase. [2]

1.4.1 Sign-Error Algoritmus

Tato modifikace obecného adaptivního algoritmu vychází z myšlenky kvantifikovat chybu. Nejjednodušší kvantifikací je

$$\begin{aligned} \text{sign}(e) &= \begin{cases} 1, & x > 0 \\ 0, & e = 0 \\ -1, & e < 0 \end{cases} \\ \mathbf{W}_{k+1} &= \mathbf{W}_k + 2\mu \text{sign}[e(k)] \mathbf{x}_k \end{aligned} \quad (1.8)$$

1.4.2 Sign-Data Algoritmus

Modifikace předchozího. Funkce signum není použita na chybu, ale na prvek vstupního vektoru.

$$\text{sign}(x) = \begin{cases} 1, & x > 0 \\ 0, & x = 0 \\ -1, & x < 0 \end{cases}$$

$$\mathbf{W}_{k+1} = \mathbf{W}_k + 2\mu e(k) \text{sign}[\mathbf{x}_k] \quad (1.9)$$

1.4.3 Sign-Sign Algoritmus

Jedná se o kombinaci předchozích algoritmů. Výpočetně nejméně náročný, ovšem má také malou rychlost konvergence. [6]

$$\mathbf{W}_{k+1} = \mathbf{W}_k + 2\mu \text{sign}[e(k)] \text{sign}[\mathbf{x}_k] \quad (1.10)$$

1.4.4 LMS-Newton Algoritmus

Uvedený algoritmus si klade za cíl odstranění pomalé konvergence LMS algoritmů v případě korelace vstupních signálů. Daní za to je větší výpočetní náročnost.

$$\mathbf{W}_{k+1} = \mathbf{W}_k + 2\mu e_k \hat{\mathbf{R}}_k^{-1} \mathbf{x}_k \quad (1.11)$$

kde $\hat{\mathbf{R}}_k^{-1}$ je v nultém kroku $\hat{\mathbf{R}}_0^{-1} = a\mathbf{I}$, kde konstanta a je malé, kladné číslo.


$$\hat{\mathbf{R}}_k^{-1} = \frac{1}{1-\alpha} \left[\hat{\mathbf{R}}_{k-1}^{-1} - \frac{\hat{\mathbf{R}}_{k-1}^{-1} \mathbf{x}_k \mathbf{x}_k^T \hat{\mathbf{R}}_{k-1}^{-1}}{\frac{1-\alpha}{\alpha} \mathbf{x}_k^T \hat{\mathbf{R}}_{k-1}^{-1} \mathbf{x}_k} \right] \quad (1.12)$$

Newtonův algoritmus je matematicky identický k RLS algoritmu pokud je $2\mu = \alpha$. Ačkoliv se zmiňují, že RLS nebude v této práci zmiňováno, je třeba uvést alespoň základy.

RLS je základním představitelem druhé třídy adaptivních algoritmů. Základním rozdílem proti rodině LMS algoritmů je vlastní statistické pojetí. Zde se pracuje s průměrnými hodnotami veličin počítanými z časových vývoji namísto vzorkových průměrů počítaných z několika realizací stejného náhodného procesu. Struktura filtru zůstává stejná jako u LMS algoritmů, jen adaptivní proces je odlišný, vzhledem

k použití průměrů. Z toho rovněž plyne větší výpočetní náročnost než u LMS algoritmů.


1.5 ZÁKLADNÍ ADAPTAČNÍ SCHÉMATA



Obr. 1.5: Základní schéma adaptace.

Kde y je vstupní signál zkreslený průchodem neznámým prostředím, x je trénovací signál, e odchylka odhadovaného signálu a vstupního signálu a nakonec \hat{x} jenž představuje odhad signálu.

1.6 MODIFIKA PRO POTLAČENÍ DETERMINISTICKÉHO BRUMU



Obr. 1.6: Modifikované schéma adaptace.

Význam znaků odpovídá dříve uvedenému. Tato metoda je rozdílná v tom že jako trénovací signál používá dva harmonické signály s fázovým posunutím 90° (typicky \sin a \cos). Výsledný průběh získáme jako

$$\begin{aligned}
X_k &= W_1 \cos(\omega kT - \varphi) + W_2 \cos(\omega kT - \varphi - \frac{\pi}{2}) \\
X_k &= \frac{1}{2} \sqrt{W_1^2 + W_2^2} \cos(\omega kT - \varphi - \arctan \frac{W_2}{W_1})
\end{aligned} \tag{1.13}$$

Jak je patrné lze vhodným složením obou prŮbŮhŮ dostat výsledný prŮbŮh o libovolné amplitudě a fázi.

1.7 GENETICKÝ ALGORITMUS

Genetické algoritmy (GA) se inspirovaly myšlenkou Darwinovy teorie přirozeného výběru a genetikou – dědičnost, mutace, přirozený výběr a křížení.

Nejdůležitější osobností se stal John Holland, který obor založil. Který vydal v roce 1975 zásadní knihu *Adaptace v přirozeném a umělém prostředí* (v originále *Adaptation in Natural and Artificial Systems*). V roce 1992 byly genetické algoritmy (GA) použity na vývoj samostatných programů řešící s větším stupněm volnosti zadaný problém, kde kromě řešení byl znám i jeho postup. Tato metoda se nazývá "genetické programování".

Genetický algoritmus je heuristický postup, který se snaží aplikovat principy evoluce a s jejich pomocí nalézt řešení složitých problémů, pro které neexistuje použitelný exaktní algoritmus.

Princip práce genetického algoritmu je postupná tvorba generací různých řešení daného problému. Při řešení se uchovává tzv. populace, jejíž každý jedinec představuje jedno řešení daného problému. Jak populace probíhá evolucí, řešení se zlepšují. Tradičně je řešení reprezentováno binárními čísly, řetězci nul a jedniček, nicméně používají se i jiné reprezentace (jako v našem případě použití pole o třech prvcích). Typicky je na začátku simulace (v první generaci) populace složena z naprosto náhodných členů. V přechodu do nové generace je pro každého jedince spočtena tzv. fitness funkce, která vyjadřuje kvalitu řešení reprezentovaného tímto jedincem. Podle této kvality jsou stochasticky vybráni jedinci, kteří jsou modifikováni (pomocí mutací a křížení), čímž vznikne nová populace. Tento postup se opakuje, čímž se kvalita řešení v populaci postupně vylepšuje. Algoritmus se obvykle zastaví při

dosažení postačující kvality řešení, případně po předem dané době.

1.7.1 Obecné schéma genetického algoritmu

Cyklus genetického algoritmu se skládá z následujících kroků.

- (Inicializace) Vytvoř nultou populaci (obvykle složenou z náhodně vygenerovaných jedinců).
- Výpočti zdatnost těchto nových jedinců (fitness funkce).
- (Začátek cyklu) Pomocí určité výběrové metody (zpravidla zčásti náhodné) vyber z populace několik jedinců s vysokou zdatností.
- Z vybraných jedinců vygeneruj nové použitím následujících metod (operátorů), čímž vznikne další generace:
 - křížení - „prohod“ části několika jedinců mezi sebou,
 - mutace - náhodně změň část jedince,
 - reprodukce - kopíruj jedince beze změny,
- Výpočti zdatnost těchto nových jedinců.
- (Konec cyklu) Pokud není splněna zastavovací podmínka, tak pokračuj od bodu 3.
- (Konec algoritmu) Jedinec s nejvyšší zdatností je hlavním výstupem algoritmu a reprezentuje nejlepší nalezené řešení.

Metody reprodukce

Metody reprodukce jsou tři Turnaj, Vážená Ruleta a speciální pozici má Elitářství.

Turnaj

Turnaj je v poslední době nejvíce používanou technikou v aplikacích GA. Hlavním důvodem je jednoduchost implementace při zachování kvality selekčního tlaku.

Z populace jsou vybírání jednotlivci a ti se podrobují „souboji o přežití“, který spočívá v tom, že jedinec z největší fitness funkcí přežívá a postupuje do dalšího kola. Tím se splňuje náš základní předpoklad, aby přežívali jedinci z vyšší kvalitou, ale jedinci vstupující do souboje jsou vybírání náhodně, což zaručuje různost populace.

Výhoda je při této metodě zřejmá. Do následující generace s velkou pravděpodobností postupují jen silní jedinci.

Vážená Ruleta

Každý jedinec zabírá na pomyslné kružnici procentuálně takovou plochu jakou představuje jeho kvalita, čím kvalitnější tím větší plocha. Pak dochází náhodně k výběru jedinců, čím větší plocha tím větší pravděpodobnost výběru.

Nevýhodou je, že při jednom silném jedinci a zbytku populace slabé dochází s velkou pravděpodobností k výběru pouze silného jedince a hrozí uváznutí v lokálním maximu.

Elitářství


Předešlé techniky obecně nezaručují postup nejlepšího jedince do nové generace. Zvláště v malých populacích je tato ztráta vnímána velmi negativně. Experimenty prokázaly, že ztráta nejlepších jedinců může být opakována a znovuvytvoření jedince není automatické.

Elitářství je jednoduchá technika, kterou vybíráme určitý (velmi malý, většinou pouze jeden) počet nejlepších jedinců a ti se nepodrobují selekčnímu tlaku, ale postupují do nové generace přímo.

2 MODELACE

2.1 DEFINICE VSTUPŮ

Modelování bylo prováděno v programu Matlab, jako signály byly použity záznamy EKG z databáze CSE [8] cse28v3 a cse28ii, jedná se o signály ze dvou různých svodů. Viz 2.1




Obr. 2.1: Vstupní signály.


Zarušení 50 Hz brumem bylo zajištěno numerickým přidáním funkce sinus viz obr 2.1 a 2.1. Jeho úroveň budeme porovnávat přes SNR dle vzorce 2.1

$$SNR = 10 \log \frac{\sum s_n^2}{\sum (y_n - s_n)^2} \quad (2.1)$$

Samotné vyhledávání vhodného filtru je řešeno genetickými algoritmy. Metodika je taková, že každý jedinec v generaci je jednou realizací filtru. V jeho jednotlivých genomech jsou zakódovány vlastnosti filtru a to rychlost učení a délka impulzní charakteristiky filtru. Po prvotní generaci náhodné generace dojde k vyčíslení plochy mezi obdrženým průběhem a průběhem signálu který předem známe. Tato plocha slouží jako hodnotící kritérium kvality jedince potažmo filtru. Do další generace pak postupují dva různí jedinci s nejlepší kvalitou rekonstrukce, následujících 30% následujícího pokolení je vybráno soubojem. Zbývající jedinci jsou nakříženi z předchozí populace. V následujícím kroku je proveden mutace. Z mutace je vynechán nejlepší jedinec.



Obr. 2.2: Zašumněný signál.



Obr. 2.3: Zašumněný signál šumem s amplitudovou modulací.

Hodnoty filtrů jsou generovány náhodně z následujících intervalů.

- Základ rychlosti učení je v intervalu $\langle 0, 100 \rangle$
- Exponent rychlosti učení leží v intervalu $\langle -1, 1 \rangle$
- Délka impulzní charakteristiky leží v intervalu $\langle 1, 1800 \rangle$


2.1.1 Obecné adaptační schéma a obecný algoritmus

Vstupní úroveň SNR je $1,1302 \text{ dB}$. Po spuštění vyhledávání vhodného filtru jsme obdržely následující vhodné filtry.


Rychlost učení	Délka filtru	SNR_1 [dB]	SNR_2 [dB]
179E-06	30	47,5949	48,7164
175E-06	30	47,5832	48,4426
155E-06	39	47,2316	48,9831
155E-06	41	47,0598	49,0019
303E-06	18	47,0485	47,5543
469E-06	12	46,9723	47,8411
469E-06	18	45,1610	46,7034

Tab. 2.1: Úspěšnost vyfiltrování signálu při použití obecného schématu a obecného adaptačního algoritmu

Výstupní poměr SNR byl počítám až po uplynutí přechodných dějů, čili až od dvoutisícího vzorku.



Obr. 2.4: Vyfiltrovaný signál při použití obecného schématu a obecného adaptačního algoritmu - první signál. Tab 2.1



Obr. 2.5: Vyfiltrovaný signál při použití obecného schématu a obecného adaptačního algoritmu - druhý signál. Tab 2.1


2.1.2 Obecné adaptační schéma a algoritmus signum data

Vstupní úroveň SNR je 1,1302 dB. Po spuštění vyhledávání vhodného filtru jsme obdržely následující vhodné filtry.

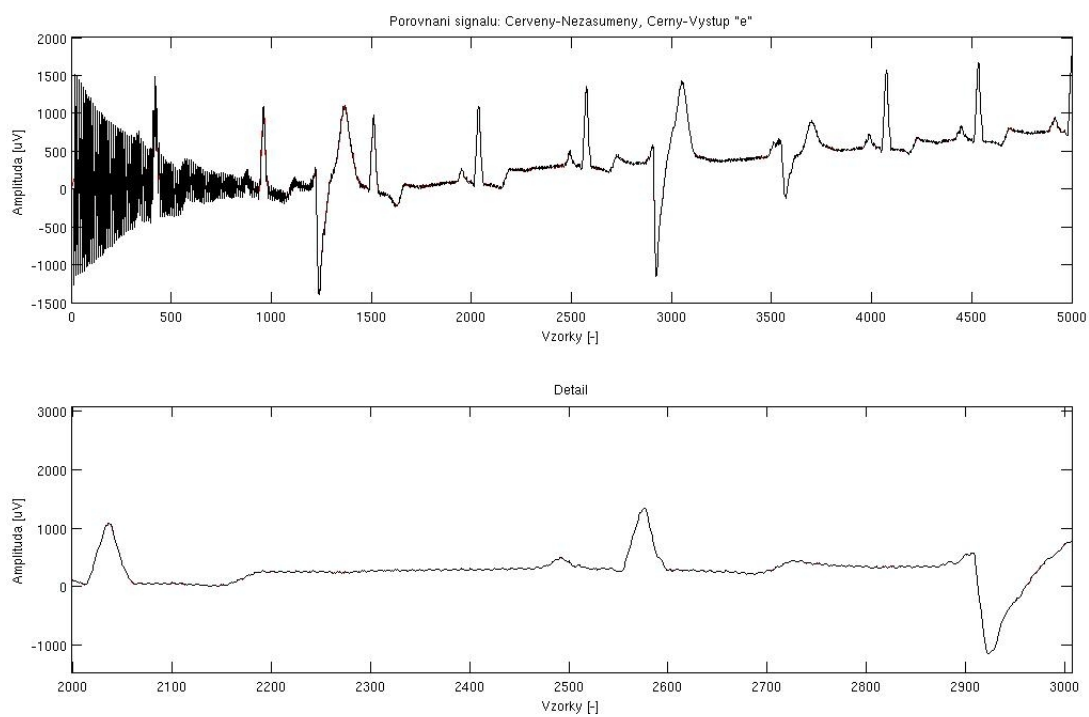
Rychlost učení	Délka filtru	SNR_1 [dB]	SNR_2 [dB]
295,845E-06	15	47,9525	50,5298
221,546E-06	21	47,8351	51,0126
360,974E-06	10	47,7990	45,9554
221,546E-06	15	46,4482	42,7993
295,845E-06	21	45,9925	49,2588

Tab. 2.2: Úspěšnost vyfiltrování signálu při použití obecného schématu a algoritmu signum data

Výstupní poměr SNR byl počítám až po uplynutí přechodných dějů, čili až od dvoutisícího vzorku.



Obr. 2.6: Vyfiltrováný signál při použití obecného schématu a algoritmu signum data - první signál. Tab 2.1



Obr. 2.7: Vyfiltrovaný signál při použití obecného schématu a algoritmu signum data - druhý signál. Tab 2.2


2.1.3 Obecné adaptační schéma a algoritmus signum error

Vstupní úroveň SNR je 1,1302 dB. Po spuštění vyhledávání vhodného filtru jsme obdržely následující vhodné filtry.


Rychlost učení	Délka filtru	SNR_1 [dB]	SNR_2 [dB]
1,4020	6	33,3071	26,7464
256,292E-03	37	33,0377	27,0814
258,838E-03	37	33,0254	26,5613
427,358E-03	21	33,0023	29,0348
397,812E-03	21	32,9340	28,9979
513,853E-03	19	32,8976	27,6308
390,425E-03	21	32,8174	27,3105
475,834E-03	19	32,7689	28,2504
98,134E-03	113	32,6298	26,9752
540,264E-03	17	32,6207	29,1327
416,655E-03	21	32,5751	28,0427
282,795E-03	37	32,4924	27,4055
2,0210	5	32,4288	26,0560

Tab. 2.3: Úspěšnost vyfiltrování signálu při použití obecného schématu a algoritmu signum error

Výstupní poměr SNR byl počítám až po uplynutí přechodných dějů, čili až od dvoutisícího vzorku.



Obr. 2.8: Vyfiltrovaný signál při použití obecného schématu a algoritmu signum error - první signál. Tab 2.3



Obr. 2.9: Vyfiltrovaný signál při použití obecného schématu a algoritmu signum error - druhý signál. Tab 2.3


2.1.4 Obecné adaptační schéma a algoritmus signum signum

Vstupní úroveň SNR je 1,1302 dB. Po spuštění vyhledávání vhodného filtru jsme obdržely následující vhodné filtry.


Rychlost učení	Délka filtru	SNR_1 [dB]	SNR_2 [dB]
140,322E-03	50	33,5588	29,2465
206,490E-03	32	33,6379	28,6253
669,419E-03	10	33,4480	27,7710
1,467E+00	5	33,3439	27,3201

Tab. 2.4: Úspěšnost vyfiltrování signálu při použití obecného schématu a algoritmu signum signum

Výstupní poměr SNR byl počítán až po uplynutí přechodných dějů, čili až od dvoutisícího vzorku.



Obr. 2.10: Vyfiltrovaný signál při použití obecného schématu a algoritmu signum signum - první signál. Tab 2.4



Obr. 2.11: Vyfiltrovaný signál při použití obecného schématu a algoritmu signum signum - druhý signál. Tab 2.4


2.1.5 Obecné adaptační schéma a Newtonův algoritmus

Vstupní úroveň SNR je 1,1302 dB. Po spuštění vyhledávání vhodného filtru jsme obdržely následující vhodné filtry.


Rychlost učení	Délka filtru	SNR_1 [dB]	SNR_2 [dB]
1,562E-03	2	47,4905	49,4289
1,217E-03	2	46,1842	44,2738
3,177E-03	2	43,0741	44,5510
3,386E-03	2	42,6088	44,0170
4,393E-03	2	40,6710	41,8227

Tab. 2.5: Úspěšnost vyfiltrování signálu při použití obecného schématu a Newtonova algoritmu

Výstupní poměr SNR byl počítán až po uplynutí přechodných dějů, čili až od dvoutisícího vzorku.



Obr. 2.12: Vyfiltrováný signál při použití obecného schématu a Newtonova algoritmu - první signál. Tab 2.5



Obr. 2.13: Vyfiltrovaný signál při použití obecného schématu a Newtonova algoritmu - druhý signál. Tab 2.5


2.1.6 Brumové adaptační schéma a obecný algoritmus

Vstupní úroveň SNR je 1,1302 dB. Po spuštění vyhledávání vhodného filtru jsme obdržely následující vhodné filtry.


Rychlost učení	Délka filtru	SNR_1 [dB]	SNR_2 [dB]
1,313E-03	2	47,6658	48,6625
120,652E-06	22	47,6148	48,6315
405,413E-06	7	47,5557	49,2351
67,450E-06	39	47,5496	48,3736
62,499E-06	45	47,5098	49,0131
2,900E-03	1	47,4952	49,2930
242,836E-06	10	47,3819	47,0556
159,383E-06	15	47,2417	46,5696
52,781E-06	45	46,9998	45,9518
159,383E-06	22	46,4787	48,3527
2,196E-03	1	46,3424	44,1023
129,952E-06	29	46,0057	47,7952

Tab. 2.6: Úspěšnost vyfiltrování signálu při použití brumového schématu a obecného algoritmu

Výstupní poměr SNR byl počítán až po uplynutí přechodných dějů, čili až od dvoutisícího vzorku.



Obr. 2.14: Vyfiltrovaný signál při použití brumového schématu a obecného adaptačního algoritmu - první signál. Tab 2.6



Obr. 2.15: Vyfiltrovaný signál při použití brumového schématu a obecného adaptačního algoritmu - druhý signál. Tab 2.6

2.1.7 Brumové adaptační schéma a algoritmus signum data


Vstupní úroveň SNR je 1,1302 dB. Po spuštění vyhledávání vhodného filtru jsme obdržely následující vhodné filtry.

Rychlost učení	Délka filtru	SNR[dB]
4,16724E-13	168	1,3432
1,81907E-07	47	1,3432
2,528	35	1,3432
3,30242E-10	21	1,3432
0,035933	209	1,3432
0,015275	665	1,3432
0,012353	209	1,3432
40,329	45	1,3432
0,015275	665	1,3432
0,101601	1773	1,3432
0,012353	209	1,3432
0,101601	1773	1,3432
0,079933	45	1,3432
9,328	48	1,3432
0,168611	98	1,3432
0,399997	844	1,3432
1,253	1714	1,3432
1,253	2	1,3432
0,015275	665	1,3432
4,799	21	1,3432
0,012353	209	1,3432
0,241338	1773	1,3432

Tab. 2.7: Úspěšnost vyfiltrování signálu při použití brumového schématu algoritmu signum data

Výstupní poměr SNR byl počítán až po uplynutí přechodných dějů, čili až od dvoutisícího vzorku.

Jak je patrné filtrování brumovým adaptačním schématem s využitím algoritmu signum data není moc vhodné, dochází sice k potlačení brumu, ale ne na použitelnou úroveň. Z tohoto důvodu nebyly nalezené filtry použity na druhý signál.



Obr. 2.16: Vyfiltrovaný signál při použití brumového schématu a algoritmu signum data při použití nejlepšího filtru z tabulky. Tab 2.7


2.1.8 Brumové adaptační schéma a algoritmus signum error

Vstupní úroveň SNR je 1,1302 dB. Po spuštění vyhledávání vhodného filtru jsme obdržely následující vhodné filtry.


Rychlost učení	Délka filtru	SNR_1 [dB]	SNR_2 [dB]
406,699E-03	21	30,8888	26,1236
85,706E-03	96	30,8274	27,9194
389,000E-03	21	30,8140	25,5175
932,892E-03	8	30,7234	24,1185
203,013E-03	42	30,6289	26,2334
311,653E-03	29	30,5918	26,8725
233,508E-03	37	30,4684	25,2140
538,406E-03	15	30,3945	26,2700

Tab. 2.8: Úspěšnost vyfiltrování signálu při použití brumového schématu algoritmu signum error

Výstupní poměr SNR byl počítán až po uplynutí přechodných dějů, čili až od dvoutisícího vzorku.



Obr. 2.17: Vyfiltrovaný signál při použití brumového schématu a algoritmu signum error - první signál. Tab 2.8



Obr. 2.18: Vyfiltrovaný signál při použití brumového schématu a algoritmu signum error - druhý signál. Tab 2.8


2.1.9 Brumové adaptační schéma a algoritmus signum signum

Vstupní úroveň SNR je 1,1302 dB. Po spuštění vyhledávání vhodného filtru jsme obdržely následující vhodné filtry.


Rychlost učení	Délka filtru	SNR_1 [dB]	SNR_2 [dB]
1,283	4	32,2456	27,6850
573,432E-03	9	31,8424	26,9798
1,302	4	31,8369	24,1037
544,939E-03	9	31,7034	27,2713
570,389E-03	9	31,6995	25,7786
194,087E-03	32	31,5725	28,0527
593,254E-03	9	31,5053	26,5119
197,151E-03	32	31,4319	24,7727
785,828E-03	8	31,2538	27,4824
778,894E-03	8	30,8191	28,2235
194,865E-03	28	30,7201	27,2078

Tab. 2.9: Úspěšnost vyfiltrování signálu při použití brumového schématu algoritmu signum signum

Výstupní poměr SNR byl počítán až po uplynutí přechodných dějů, čili až od dvoutisícího vzorku.



Obr. 2.19: Vyfiltrovaný signál při použití brumového schématu a algoritmu `signum` - první signál. Tab 2.9



Obr. 2.20: Vyfiltrovaný signál při použití brumového schématu a algoritmu `signum` - druhý signál. Tab 2.9

3 ZÁVĚR

Pro srovnání byla filtrace realizována také pásmovou zářdí 48 Hz až 52 Hz, pro kterou vychází vhodné filtry s délkou impulsní charakteristiky v rozmezí 376 až 800 vzorků. Přičemž nejlepšího poměru signál/šum dosahuje filtr s délkou impulsní charakteristiky 434 při poměru SNR 44,4450 *dB*. Zatímco při zářdí 45-55 Hz je maximální SNR "jen" 40,5426 při délce impulsní charakteristiky 174 vzorků.

Z tohoto důvodu jsou považovány za vhodné filtry jen filtry se SNR větším než 45 *dB*. Toto kritérium splňují při použití obecného adaptačního schématu tyto algoritmy:

- Obecný algoritmus,
- Algoritmus signum data,
- Newtonův algoritmus,

a pro brumové schéma pouze obecný adaptační algoritmus.

V následující tabulce je porovnání kvality filtrace při použití amplitudově modulovaného šumu viz obr 2.1 a při odchylce frekvence na 45 Hz.

1. Vstupní SNR při amplitudové modulaci je 10 *dB*.
2. Vstupní SNR při šumu na jiné frekvenci je 1.1302 *dB*.

Metodika	Rychlost učení	Délka filtru	SNR_{AM} [dB]	SNR_{Mimo_f} [dB]
Obecný-Obecný	179E-06	30	15,7832	45,7435
Obecný-Obecný	175E-06	30	15,7325	45,6216
Obecný-signData	295,845E-06	15	14,3170	46,8009
Obecný-signData	221,546E-06	21	14,3170	46,6900
Obecný-Newton	1,562E-03	2	13,4827	16,0913
Obecný-Newton	1,217E-03	2	13,1578	13,7797
Brum-Obecný	1,313E-03	2	14,1661	47,0315
Brum-Obecný	120,652E-06	22	14,1209	47,6805

Tab. 3.1: Úspěšnost vyfiltrování signálu při změně vlastností šumu

Závěrem lze říct, že nalezené filtry lze s úspěchem použít pro odfiltrování šumu z EKG signálu a to i v případě rozdílných frekvencí v rámci tolerance 10% což je dalece za udávaným rozptylem síťových 50 Hz +4/ - 6 %.[9] V případě, že se amplituda šumu mění pomalu a pozvolně lze říct, že je filtrace úspěšná. Toto již ovšem neplatí pro výrazně se měnící amplitudu síťového rušení kdy filtry nevykazují

schopnost potlačit šum v rozumné a použitelné míře. Také se dá říci, že kvantifikační modifikace adaptivního filtru jsou pro filtraci EKG signálu obecně nevhodné.

LITERATURA

- [1] JAN J. *Číslíková filtrace, analýza a restaurace signálů* VUTIUM 2002. ISBN - 80-214-1558-4
- [2] DINIZ P. *Adaptive Filtering - Algorithms and Practical Implementation* Springer Thirt Edition. ISBN - 978-0-387-31274-3
- [3] ZAPLATÍLEK K.,DOŇAR B. *Matlab začínáme se signály* BEN 2006. ISBN - 80-7300-200-0
- [4] KAY S. M. *Intuitive Probability and Random Processes Using MatLab* Springer 2006. ISBN - 0-387-24158-2
- [5] Mathews V. J.,Cho S. H. *Improved convergence analysis of stochastic gradient adaptive filters using the sign algorithm* IEEE Trans. on Acoust., Speech, and Signal Processing, vol. 38, 1987
- [6] Mathews V. J. *Performance analysis of adaptive filters equipped with dual sign algorithm* IEEE Trans. on Signal Processing, vol. 39, 1991
- [7] ŠMÍD K. *Adaptivní filtrace biologických signálů* Diplomová práce VUT Brno 2008
- [8] Databáze signálů <<http://www.physionet.org>>. K 20.3.2010
- [9] Vlastnosti sítě <<http://www.eon.cz/cs/info/parameters.shtml>>. K 15.5.2011
- [10] Přednášky z předmětu Bionika <<https://www.vutbr.cz/studium/ects-katalog/detail-predmetu?apid=98802>>.

SEZNAM SYMBOLŮ, VELIČIN A ZKRATEK

FIR	Finite impulse response - Filtr s konečnou impulsní charakteristikou
IIR	Infinite impulse response - Filtr s nekonečnou impulsní charakteristikou
LMS	Least mean squares - Algoritmus minimalizace
RLS	Recursive least squares - Algoritmus minimalizace
EKG	Electrocardiogram - Elektrokardiogram
QRS	Komplex QRS neboli komorový komplex
ε_n^2	Střední kvadratická odchylka
x	Vstup
\hat{x}	Optimální odhad vstupu
e	Chyba
μ	Rychlost učení
f_{vz}	vzorkovací kmitočet
SNR_1	Poměr SNR při filtraci signálu cse28ii
SNR_2	Poměr SNR při filtraci signálu cse28v3

A OVLÁDÁNÍ M-FILE SOUBORŮ V PROSTŘEDÍ MATLAB

Základem je `Gen_alg.m`. V tomto scriptu jsou definovány vstupní parametry a na jeho konci je zakomentovaná část pro vykreslení průběhu při filtraci nejvhodnějším nalezeným filtrem.

Výběr adaptačního schématu se provádí prostým odkomentováním vhodného řádku ve scriptu `gen_kvalita.m`.

Dále je třeba ve scriptech `ada_brum.m` a `ada_fil.m` nastavit odkomentováním požadovaný adaptační algoritmus.