



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ**
ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

**FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
BIOMEDICAL ENGINEERING**

ADAPTIVNÍ SEGMENTACE EEG SIGNÁLU

ADAPTIVE SEGMENTATION OF EEG SIGNAL

BAKALÁŘSKÁ PRÁCE
BACHELOR'S THESIS

AUTOR PRÁCE
AUTHOR

ANEŽKA OSTRÁ

VEDOUCÍ PRÁCE
SUPERVISOR

ING. VLADIMÍRA KUBICOVÁ

BRNO 2012

Prohlášení

Prohlašuji, že svou bakalářskou práci na téma Adaptivní segmentace EEG signálu jsem vypracoval samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autorka uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením tohoto projektu jsem neporušila autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědoma 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.

V Brně dne 25.5.2012

.....
podpis autora

Poděkování

Děkuji vedoucí bakalářské práce Ing. Vladimíře Kubicové za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé bakalářské práce.

V Brně 25.5.2012

.....
podpis autora

ABSTRAKT:

Tato práce je zaměřena na signál EEG, především na segmentaci signálu a dále také na zpracování signálu, které této segmentaci předchází. Je zde nastíněna problematika stacionarity signálu a vyzdvížena důležitost adaptivní segmentace.

Principy základních metod adaptivní segmentace jsou vysvětleny a dvě popsané metody jsou také dále zpracovány v prostředí Matlab tak, aby byla možná segmentace vybraného kanálu EEG.

Vliv volby parametrů (mezní hodnota segmentace a délka okna) na signál je taktéž názorně ukázán. Mezní hodnota je stanovena pomocí bílého šumu.

KLÍČOVÁ SLOVA:

Elektroencefalograf (EEG), adaptivní segmentace EEG, stacionární signál

ABSTRACT:

This project is aimed at EEG signal, especially at segmentation of signal and next at processing signal, witch this segmentation go before. Problem with signals stacionarity and stress importance of adaptive segmentation are outlined here.

Principle of basic methods of adaptive segmentation are explained and two of them are processed by Matlab to segmentation channel.

Parameters (limiting value and window length) influence segmentation. The limiting value is assessed with help of white noise.

KEY WORDS:

Elektroencefalograf, adaptiv segmentation, stationary signal

BIBLIOGRAFICKÁ CITACE:

OSTRÁ, A. *Adaptivní segmentace EEG signálů*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2012. 46 s., Vedoucí bakalářské práce Ing. Vladimíra Kubicová.

Obsah

1	Úvod.....	1
2	Úvod do problematiky encefalografie.....	2
2.1	Snímání EEG	2
2.2	Vlastnosti signálu EEG a jeho rušení	3
2.2.1	Spontánní potenciály	3
2.2.2	Evokované potenciály	5
2.3	Hlavní artefakty v EEG záznamu	5
2.4	Zpracování signálu EEG.....	6
2.4.1	Předzpracování signálu	6
2.4.2	Analýza EEG.....	7
3	Segmentace EEG	8
3.1	Konstantní segmentace	8
3.2	Adaptivní segmentace - Stacionarita EEG	8
3.2.1	Adaptivní segmentace na základě lineární predikce	9
3.2.2	Adaptivní segmentace na základě autokorelační funkce.....	11
3.2.3	Adaptivní segmentace na základě spektrální difference ve dvou spojených oknech	13
3.2.4	Adaptivní segmentace na základě jednoduché míry difference mezi amplitudami a frekvencemi ve dvou spojených oknech	14
4	Návrh řešení některých metod v programu Matlab	15
4.1	Řešení pomocí jednoduché míry difference mezi amplitudami a frekvencemi ve dvou spojených oknech	15
4.2	Řešení pomocí spektrální difference ve dvou spojených oknech – FFT, PSD	15
4.2.1	Řešení pomocí spektrální difference ve dvou spojených oknech – FFT	16
4.2.2	Řešení pomocí spektrální difference ve dvou spojených oknech – PSD parametrický a neparametrický výpočet	16
5	Volba parametrů pro adaptivní segmentaci	18
5.1	Stanovení délky okna (WL).....	18
5.2	Stanovení meze pro adaptaci pomocí bílého šumu (MEZ)	18

6	Zhodnocení výsledků	20
6.1	Zhodnocení výsledků stanovení mezní hodnoty pomocí bílého šumu.....	20
6.1.1	Stanovení mezní hodnoty - <i>white_noise_for_af.m</i>	21
6.1.2	Stanovení mezní hodnoty - <i>white_noise_for_fft.m</i>	22
6.1.3	Stanovení mezní hodnoty - <i>white_noise_for_pburg.m</i>	23
6.1.4	Stanovení mezní hodnoty - <i>white_noise_for_periodogram.m</i>	24
6.2	Zhodnocení výsledků adaptivní segmentace	24
6.2.1	Adaptivní segmentace – <i>segment_af.m</i>	25
6.2.2	Adaptivní segmentace – <i>segment_fft.m</i>	26
6.2.3	Adaptivní segmentace – <i>segment_pburg.m</i>	27
6.2.4	Adaptivní segmentace – <i>segment_periodogram.m</i>	28
7	Shrnutí.....	29
8	Závěr	30
	Seznam použité literatury.....	31
	Seznam zkratk a symbolů	32
	Přílohy	34
	Elektronické přílohy (CD).....	40

1 Úvod

Encefalografie je důležitá vyšetřovací metoda, sloužící k diagnostice patologických jevů zasahujících mozek. V současné době se metoda EEG čím dál více rozšiřuje do lékařské praxe, zejména v oblasti diagnostiky epilepsie a vyšetření spánkové aktivity, hraje nenahraditelnou roli.

Určení těchto patologických artefaktů v signálu předchází zpracování získaného záznamu signálu EEG a dále jeho segmentace, která rozčlení záznam signálu na stacionární úseky. Lze pak lehce nalézt právě ona patologická místa signálu s přesným určením jejich počátku a konce v čase.

Adaptivní segmentace se setkává s mnoha problémy. Jednotlivé metody využívají různé výpočty, které většinou zavádí menší či větší chybu. Důležitá je také volba parametrů, která je nejednoznačná a u jednotlivých metod se liší.

Tato práce se věnuje nastínění problematiky encefalografie, teorii zpracování EEG a především adaptivní segmentaci v prostředí Matlab. Dále se také snaží najít nějaké zákonitosti stanovení parametrů pro adaptivní segmentaci, aby byla segmentace použitelná i v praxi.

2 Úvod do problematiky encefalografie


Elektroencefalografie (EEG) je metoda umožňující snímání a záznam elektrické aktivity mozku. Snímá se superpozice jednodušších signálů. Původcem EEG signálu je nervová buňka. EEG umožňuje diagnostikovat epilepsii, zranění hlavy, psychické poruchy, neurologické poruchy, poruchy spánkových cyklů,... [1][2]

Záznam elektrické aktivity mozku označujeme jako encefalograf.

2.1 Snímání EEG

Snímání elektrické aktivity je umožněno pomocí elektrod. Používají se elektrody, umístěné na povrchu hlavy, méně často snímáme aktivitu přímo z kůry mozkové pomocí jehlicových elektrod, ale tomuto způsobu snímání se práce nebude věnovat.

Je dán přesný počet a umístění elektrod (Obr. 1). Elektrody jsou umístěny na povrchu hlavy pomocí elektrodové čepice (Obr. 2). Obvykle se používá 19 elektrod, pomocí kterých snímáme signál vůči referenční elektrodě. Kůži je třeba k vyšetření připravit, aby došlo ke snížení odporu na rozhraní elektroda-kůže pod $5\text{ k}\Omega$ k tomu slouží vodivostní gel a poté se zavádí Ag/AgCl elektrody. [1]



Obrázek 1: Elektrodová čepice [13]



Obrázek 2: Elektrody EEG [14]

2.2 Vlastnosti signálu EEG a jeho rušení

EEG signál lze považovat za realizaci náhodného procesu (stochastický proces), jeho vlastnosti lze vypočítat pomocí statistických operací z jedné realizace (ergodický proces) tak, že průměrujeme vzorky v čase. O EEG signálu můžeme dále říct, že je po částech stacionární (kvazistacionární). [8]


2.2.1 Spontánní potenciály

Amplituda signálu se pohybuje od 2 do 100 μV (v epileptických záchvatech až 300 μV). Frekvenční rozsah je 100 Hz a výkonostní maximum je mezi 0,5-30 Hz. Vzorkovací frekvenci f_{vz} volíme od 100 Hz až 256 Hz. [8]

Na záznamu jsou zaznamenávány periodické složky (Obr. 3):


- Alfa vlny s frekvenčním rozsahem 8-13 Hz a amplitudou pod 10 μV . Značí psychický klid se zavřenýma očima, relaxaci.
- Beta vlny s frekvenčním rozsahem 13-22 Hz a amplitudou pod 20 μV . Značí psychickou aktivitu, logicko-analytické myšlení. Při vyšších frekvencích značí stres, podráždění, zlost, napětí...
- Gama vlny s frekvenčním rozsahem 22-30 Hz a amplitudou pod 2 μV . Jsou charakteristické pro vysokou pozornost, soustředění.
- Delta vlny s frekvenčním rozsahem 0,5-4 Hz a amplitudou pod 100 μV . Indikují hluboký spánek, stavy transu či hypnózy. U dospělého člověka jsou v bdělém stavu vždy patologické.

- Theta vlny s frekvenčním rozsahem 4-8 Hz a amplituda pod 100 μV . Indikují spánek, meditaci (hluboké uvolnění). Theta vlny se pojí s inspirací, fantazií, živými vzpomínkami a dalšími stavy, kdy je vědomé myšlení odpojeno.



Obrázek 3: Charakteristické vlny EEG [2]

Dále také záznam ukazuje grafoelementy (Obr. 4) upozorňující na patologické jevy: K-komplex, hroty, ostré vlny, komplexy hrotů a vln, spánková vřetena, vícehrotové úseky, vlny lambda, mí a další. [2][4]



Obrázek 4: Grafoelementy EEG - K-komplex (obrázek a), hroty (obrázek d), ostré vlny (obrázek e a h), komplexy hrotů a vln (obrázek f), spánková vřetena (obrázek g), vícehrotové úseky (obrázek i), vlny lambda (obrázek b), mí (obrázek c)
[2]

2.2.2 Evokované potenciály

Evokované potenciály (EP) jsou bioelektrické projevy mozku jako odpověď na určitý podnět (zvukové, optické,...). Využívá se nejčastěji těchto tří evokovaných potenciálů.

VEP (vizuální evokované potenciály) – Je metoda využívající záblesků stroboskopu. Pacient sleduje šachovnici, měnící světlá pole za tmavé a opačně.

BAEP (sluchové evokované potenciály) – Je metoda, při které jsou pacientovi nasazena sluchátka se záznamem rychle se opakujícím praskáním.

SEP (somatické evokované potenciály) – Je metoda realizovaná pomocí povrchových elektrod, prostřednictvím kterých se provádí stimulace senzitivních vláken periferního nervu. Lze zjistit poškození nervových drah.

Vzorkovací frekvence je EP volena v závislosti na signálu vyšší než u spontánního EEG (tj. nad 256 Hz). Amplituda snímaného signálu se pohybuje od 1 do 20 μV . [1][2][8]

2.3 Hlavní artefakty v EEG záznamu

Záznam signálu ovlivňuje spousta faktorů, které se snažíme eliminovat určitými standardními podmínkami. Pacient sedí uvolněně se zavřenýma očima a pootevřenými ústy, na hlavě má umístěny elektrody vhodné pro snímání biosignálů ve standardizovaném systému 10/20. Přístroj je charakterizován svými parametry – rychlost posunu zaznamenávacího papíru, citlivost přístroje, kmitočtová charakteristika (bývá 0,5 až 110 Hz, přičemž se využívá užitečného pásma do 30-60 Hz), které jsou optimalizovány pro možná co nejlepší záznam signálu. Vyšetření se provádí na přizpůsobených neurologických pracovištích (někdy jsou vybaveny Faradayovými klecemi) a délka vyšetření se pohybuje řádově kolem 10 až 50 minut. [1]

V záznamu EEG se vyskytují nežádoucí artefakty, které zhoršují kvalitu užitečného signálu.

Brum

Sít'ové rušení 50 Hz (v USA 60 Hz) a vyšší harmonické složky. Pro filtraci se používá dolní propust, která propouští frekvence nižší než 50 Hz. [2]

Drift izolinie

Je způsoben elektrochemickými ději na rozhraní elektroda-pokožka - dýchací pohyb, pomalé pohyby. Pro odstranění se používá průměrování signálu, výsledek poté od původního signálu odečítáme. [2]

Pulsové artefakty

Vznikají, je-li elektroda umístěna nad artérií, je třeba elektrodu posunout. [2]

Artefakty EKG


Prosakování EKG signálu. EKG se snímá spolu s EEG a následně se od signálu EEG odečítá. [2]

Artefakty EMG

Rušivý signál myopotenciálů v rozmezí 30 až 50Hz. [2]

Artefakty EOG

Artefakty vzniklé pohyby očí a mrkání. EOG (Obr. 5) je snímáno společně s EEG. Snímaný signál je ve tvaru $x(n) = s(n) + v_0(n)$, kde $s(n)$ signál EEG a $v_0(n)$ je signál EOG nekorelovaný s EEG, proto je možné jej od signálu EEG odečíst. [2]



Obrázek 5: Umístění EOG elektrod
[1]

2.4 Zpracování signálu EEG

Zpracování biosignálů má tři hlavní etapy, které jsou předzpracování signálu, analýzu signálu a rozpoznávání. [8]

Předzpracováním signálu rozumíme filtraci signálu. Signál filtrujeme takovým způsobem, abychom vybraly složky, které přinášejí užitečnou informaci.

Analýza signálu, popisuje signál množinou parametrů a tím také dochází k redukci dat. Tyto parametry jsou zpracovávány v dalších fázích.

Rozpoznávání pracuje s výstupními daty analýzy, signál řadí do tříd pomocí parametrů a poté může lékař provést klasifikaci a rozhodnutí.

2.4.1 Předzpracování signálu

Signál je filtrován antialiasingovým filtrem, kterým je dolní propust s mezní frekvencí $\frac{1}{2}$ vzorkovacího kmitočtu. Jeho realizace musí být analogová, jelikož digitální filtry vyžadují předchozí vzorkování. [8]

Signál EEG je dále navzorkován pomocí A/D převodníku, který převede původně spojitý signál na posloupnost vzorků vybraných s určitým časovým krokem. Následuje kvantizace,

kteřa přiřazuje jednotlivým intervalům vzniklým navzorkováním jedinou diskretní hodnotu. [8]

Při vzorkování, musí být dodržen vzorkovací teorém podle Nyquista $f_{vz} \geq 2f_{max}$. Slovy řečeno vzorkovací frekvence musí být větší nebo rovna dvojnásobku maximální frekvence obsažené ve vzorkovaném signálu. Při nedodržení teorému vzniká v signálu tzv. aliasing, který způsobí nemožnost zpětnou rekonstrukci původního signálu, jelikož dojde k maskování vyšších frekvencí a slévání spekter. [6]

Dále je signál podle potřeby filtrován tak, aby byly výsledkem co nejpřínosnější informace.

2.4.2 Analýza EEG

Analýza na počítačové úrovni má za úkol prezentaci dat v objektivní a přehledné formě, redukci dat, jejich kvantifikaci, hodnocení trendů, normálních či abnormálních úseků, atd. Jednoduše řečeno jde o podporu lékařského hodnocení. [8]

1. Amplitudová analýza – jedná se o statistickém hodnocení amplitud napříč záznamem signálu.
2. Periodová analýza – dělí vlny signálu podle vlnové délky.
3. Časově – frekvenční analýza nestacionárních signálů - U této analýzy nám jde o zjištění spekter signálů z jeho krátkodobých segmentů. K určení těchto spekter slouží krátkodobá Fourierova transformace (STFT⁻¹). Nejprve se signál rozdělí na segmenty o délce N, stanoví se výkonové spektrum z každého segmentu a vloží se do matice, které se zobrazují a dále analyzují. Matice spekter se nazývá spektrogram, na kterém je amplituda spektra vyjádřena jasnem. [4]

Délka okna se musí volit kompromisem, jelikož při velmi dlouhém oknu ztrácíme časové rozlišení a při velmi krátkém oknu zase klesá rozlišení ve frekvenční oblasti.

Metody frekvenční analýzy [8]:

- Neparametrické – signál je zpracován přímo, je možné tyto metody použít okamžitě. Vychází z použití rychlé Fourierovy transformace. Mezi tyto metody patří filtrování, spektrální analýza a korelační analýza.
 - Parametrické – je určen matematický model, pro zpracování signálu a je potřeba odhadnout vyhovující parametry ze zaznamenaných dat. Nejpoužívanější matematické modely jsou autoregresní model (AR), model klouzavých průměrů (MA), autoregresní model klouzavých průměrů (ARMA).
4. Rozpoznávání typických obrazců – rozpoznání charakteristických vln expertem. Výběr vln závisí pouze na jejich tvaru.

3 Segmentace EEG

Frekvenční a amplitudové vlastnosti biologických signálů se v čase mění, říkáme, že jsou nestacionární. Pro určení grafoelementů v signálu je vhodnou metodou rozdělit signál na stacionární úseky. Tuto metodu nazýváme adaptivní segmentace. Výpovědní hodnota ostatních metod je malá, jelikož hranice úseků nemají žádný vztah k charakteru signálu. [8]

3.1 Konstantní segmentace

Konstantní segmentace je nejjednodušší způsob segmentace. Segmentuje signál na části stejné délky (např. dvou sekundové úseky) a nijak se nevztahuje k charakteru signálu. Výsledkem jsou úseky signálů obsahující vlny různých frekvencí a tvarů, které si nejsou podobné. [4]

Vhodnějším nástrojem pro segmentaci je adaptivní segmentace, která odstraňuje nedostatky konstantní segmentace. Počítá s tím, že je signál EEG nestacionární a různými algoritmy vyhledává a segmentuje signál na stacionární úseky, které mohou být dále klasifikovány. [4]

3.2 Adaptivní segmentace - Stacionarita EEG

Stacionární je takový signál, jehož statistické charakteristiky se s časem nemění, tj. střední hodnota a směrodatná odchylka zůstávají stejné. EEG signál je časově proměnný signál, tudíž je nestacionární (za stacionární se berou úseky zhruba 2 s), jelikož jeho amplitudové a frekvenční vlastnosti jsou proměnné.

Pro správné hodnocení EEG signálu je vhodné signál rozdělit na stacionární úseky, které mají různou délku v závislosti na stacionaritě signálu. Tato metoda rozdělení signálu se nazývá adaptivní segmentace. [8]

Metod adaptivní segmentace existuje celá řada. V tabulce (Tab. 1) je přehled základních metod, jejichž principy jsou níže nastíněny. Tabulka také ukazuje, zda je metoda vhodná pro vícekanálovou segmentaci a zpracování signálu on-line. Vícekanálová segmentace je taková segmentace, která je schopna segmentovat najednou více kanálů, aniž by se navzájem ovlivňovali. Takováto segmentace je pro hodnocení EEG signálu přínosnější než segmentace jednakanálová.

Tabulka 1: Přehled metod adaptivní segmentace

	jednokanálová segmentace		vícekanálová segmentace	
	on-line	off-line	on-line	off-line
Adaptivní segmentace na základě lineární predikce	x	x		
Adaptivní segmentace na základě autokorelační funkce	x	x		
Adaptivní segmentace na základě dvou spojených oken			x	x
Adaptivní segmentace na základě dvou spojených oken a jednoduché míry difference			x	x

3.2.1 Adaptivní segmentace na základě lineární predikce

Bodenstein a Praetorius (1977)

Využívá autoregresní model signálu (AR), který popisuje závislost aktuálního vzorku x_n na předchozích hodnotách vzorku. Určení jeho parametrů je lineární úloha.

AR model (Obr. 6) je popsán rovnicí (1) :

$$x(n) + a_1x(n-1) + a_2x(n-2) + \dots + a_px(n-p) = e(n) \quad [3] \quad (1)$$


Z toho plyne:

$$x_n = -\sum_{k=1}^p a_k x_{n-k} + e_n \quad (2)$$

x_n ...aktuální odhadovaný vzorek

a_k ...k-tý koeficient lineárně predikčního filtru (také AR koeficienty), určují se metodou nejmenších čtverců (minimalizace rozptylu e_n)


e_n ...chyba predikce bílý šum (chyba vzniklá při odhadu hodnoty x_n z lineární kombinace p minulých hodnot výstupu v rekurzi (řád modelu)



Obrázek 6: AR model
[3]

Podstata AR modelu vychází z předpokladu, že signál vzniká průchodem bílého šumu lineárním časově inverzním filtrem (Obr. 7). Je-li signál stacionární, dostaneme po průchodu inverzním filtrem bílý šum. [3]


Parametry systému se určují metodou nejmenších čtverců pro minimalizaci chyb predikce.



Obrázek 7: časově inverzní filtr
[3]

Princip (Obr. 8):

- Určí se krátké referenční okno na začátku signálu. Většinou je délka okna kolem jedné sekundy.
- V tomto okně je třeba navrhnout lineárně prediktivní filtr (určit koeficienty tohoto filtru metodou nejmenších čtverců) a užít filtr k němu inverzní, jehož výstupem je chyba predikce.
- Pokud je signál stacionární, bude autokorelační funkce chyby predikce nulová a spektrum e_n bude totožné se spektrem bílého šumu. Když se objeví v signálu nová spektrální složka a LP filtr přestává být adaptován na signál.
- Vyhodnocuje se míra diferencí mezi spektry signálu v referenčním a testovacím oknem pomocí autokorelačních funkcí chyby predikce.
- Signál je kvazi-stacionární, nepřekročí-li difference danou mez. Jestliže se tak stane, umístí se hranice segmentu uprostřed testovacího okna a LP filtr se adaptuje na nový segment a celý proces se opakuje. [8]



Obrázek 8: Adaptivní segmentace na základě lineární predikce [3]

3.2.2 Adaptivní segmentace na základě autokorelační funkce

Michael a Houchin (1979)

Vyplývá z výpočtu difference autokorelace signálu v pevném a pohyblivém okně. Jestliže míra difference překročí určitou hranici, končí stacionární úsek.

Míru difference lze určit dle vztahu (3):

$$DIFF = \sum_{n=0}^{ACFL} \frac{|R_{w_1}(n) - R_{w_2}(n)|}{R_{w_1}(0)R_{w_2}(0)} \quad (3)$$

$ACFL$...počet koeficientů autokorelační funkce

R_w ...autokorelační funkce okna

w_1 ...referenční okno

w_2 ...pohyblivé okno

Vzhledem k určení konce stacionárního úseku v okně není možné používat při on-line vícekanálové segmentaci v reálném čase.

Hodnoty korelační funkce jsou závislé na podobnosti či nepodobnosti obou výchozích signálů při jejich vzájemném posunutí o τ . [5]

Lze vypočítat ze vztahů:

$$R_{xx}(l) = \frac{1}{N-l} \sum_{n=0}^{N-l-1} x(n) \cdot x(n-l), \quad \text{kde } l = 0, 1, \dots, L \quad (4)$$

$$\text{nebo } R_{xx}(n) = FFT^{-1} \{ PSD(k) \} \quad (5)$$


známe-li výkonovou hustotu $PSD(k)$, která je určena vztahem

$$PSD(k) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x(n) \cdot e^{-j2\pi kn} \right|^2 \quad (6)$$

$PSD(k)$ popisuje rozložení hustoty výkonu signálu v závislosti na frekvenci.

Princip (Obr. 9):

- Pevné referenční okno se umístí na začátek signálu a určí se autokorelační funkce (charakteristiky signálu).
- Po signálu klouže pohyblivé testovací okno a průběžně počítá autokorelační funkce signálu.
- Diference autokorelačních funkcí nám ukazuje rozdíly v charakteru signálu referenčního okna a okna testovacího, z čehož vyplývá i odchylka od stacionarity.
- Jakmile difference překročí určitou mez, je stanoven konec stacionárního segmentu, jehož přesná poloha je odhadnuta z průběhu dalšího signálu. Určí se nové testovací okno a proces se opakuje. [8]



Obrázek 9: Adaptivní segmentace na základě autokorelační funkce [3]

3.2.3 Adaptivní segmentace na základě spektrální difference ve dvou spojených oknech

Siline a Skryleve (1984)

Využívá rychlé Fourierovy transformace (FFT). Fourierovu transformaci nelze použít komplexně na celý záznam signálu, jelikož by došlo ke ztrátě důležitých informací, proto je nutné provádět FFT na úrovni oken.

Diskrétní Fourierova transformace

$$X(k) = \sum_{n=0}^{N-1} x(n) \cdot e^{-\frac{j2\pi kn}{N}} \quad (7)$$

je transformací signálu z časové do frekvenční oblasti. Vstupem do DFT je diskrétní navzorkovaný signál a výstupem je diskrétní spektrum tohoto signálu (informace o frekvenčních složkách v něm obsažených).

Aplikací FFT získáme spektra signálů v oknech, určují se difference a hranice stacionarity se umístí do bodu lokálního maxima difference.

$$DIFF = \max \left\{ \frac{1}{2} \left[\frac{X_t(\omega)}{Y_t(\omega)} + \frac{Y_t(\omega)}{X_t(\omega)} \right] - 1 \right\} \quad (8)$$

X_t, Y_t ...spektrální obsah dvou oken vypočítaný pomocí FFT

Metoda je velmi pomalá vzhledem k výpočtům FFT pro každý posun okna. Dochází také k špatnému určování hranic segmentu, jelikož kolem pravých hranic se mohou vyskytovat falešná lokální maxima. [8]

Princip:

- Na signál aplikujeme dvě spojená okna, která kloužou po signále.
 - V oknech se průběžně počítají FFT (spektrální obsah signálu) a určuje se míra difference mezi okny.
 - Hranice stacionárního segmentu je umístěna do místa s lokálním maximem diferencí.
- [8]

3.2.4 Adaptivní segmentace na základě jednoduché míry difference mezi amplitudami a frekvencemi ve dvou spojených oknech

Tato metoda je používána pro on-line zpracování vícekanálových signálů (segmentace jednotlivých kanálů na sobě nejsou závislé).

Metoda vychází z poznatku, že průměrná difference vzorků signálu je přímo úměrná střední frekvenci signálu v daném okně. Z odhadů střední amplitudy a frekvence se určí difference v oknech. [8]

$$A_w = \sum_{i=1}^{wL} |x_i| \quad (9)$$

$$F_w = \sum_{i=1}^{wL} |x_i - x_{i-1}| \quad (10)$$


A_w ...odhad střední amplitudy

F_w ...odhad střední frekvence

wL ...délka okna w

Princip (Obr. 10):

- Na signál aplikujeme dvě spojená okna, která kloužou po signále.
 - V oknech se stanovují odhady střední amplitudy a střední frekvence.
 - Hranice stacionárního segmentu je umístěna do místa s lokálním maximum difference.
- [8]



Obrázek 10: Adaptivní segmentace na základě dvou spojených oken

[3]

4 Návrh řešení některých metod v programu Matlab

Tato bakalářská práce se dále věnuje návrhu řešení adaptivní segmentace vybranými metodami a jejich realizaci v prostředí Matlab.

Informace o používaném signálu

Použitý záznam EEG *pac10.trc* obsahuje 24 kanálů s danou časovou osou délky 1024 vzorků, což odpovídá času 8 s. První kanál GND je zemnicí, kanály 2 až 20 nesou jednotlivé záznamy EEG z různých elektrod, doplňující kanály 21 až 24 nesou záznamy EOG, EMG, ECG a PNG.

Signál je navzorkovaný kmitočtem $F_{vz} = 128 \text{ Hz}$.

4.1 Řešení pomocí jednoduché míry difference mezi amplitudami a frekvencemi ve dvou spojených oknech

Tato metoda je teoreticky popsána v kapitole 3.2.4.

Skript s názvem *segment_af.m* pro řešení této metody pracuje následovně:

1. Načtení signálu a výběr konkrétního kanálu EEG.
2. Nastavení délky oken a mezní hodnotu segmentace – konzultace se skriptem *white_noise_for_af.m*.
3. Načtení dvou spojených oken. Okna kloužou po signálu (postupné načítání jednotlivých vzorků) pomocí *for* cyklu, probíhá výpočet střední amplitudy a frekvence, jejich sumace dle vztahů (9) a (10) a dále difference.

Diference mezi vzorky oken se vypočítá:

$$DIF = k_1 |A_{w1} - A_{w2}| + k_2 |F_{w1} - F_{w2}| \quad (11)$$

k ...váhovací koeficienty

A_w ...střední amplitudy v oknech $W1$ a $W2$

F_w ...střední frekvence v oknech $W1$ a $W2$

Pro zvolení váhovacích koeficientů se udává, že váha pro míru difference frekvenční je sedmkrát vyšší než pro amplitudovou. [9]

4. Stanovení lokálních maxim diferencí a následná aplikace na původní signál EEG.
5. Vykreslení grafů.

4.2 Řešení pomocí spektrální difference ve dvou spojených oknech – FFT, PSD

Tato metoda je řešena třemi algoritmy, které se liší stanovením spektra. Jedna z metod používá výpočet spektra pomocí rychlé Fourierovy transformace v oknech a druhá využívá výpočtu spektrální výkonové hustoty (PSD) signálu.

4.2.1 Řešení pomocí spektrální difference ve dvou spojených oknech – FFT

Tato metoda je teoreticky popsána v kapitole 3.2.3.

Skript s názvem *segment_fft.m* pro řešení této metody pracuje následovně:

1. Načtení signálu a výběr konkrétního kanálu EEG.
2. Nastavení délky oken a mezní hodnotu segmentace – konzultace se skriptem *white_noise_for_fft.m*.
3. Načtení dvou spojených oken. Okna kloužou po signálu (postupné načítání jednotlivých vzorků) pomocí *for* cyklu, probíhá výpočet rychlé Fourierovy transformace (FFT) v jednotlivých oknech a počítá se míra difference podle vzorce (8):

$$DIFF = \max \left\{ \frac{1}{2} \left[\frac{X_t(\varpi)}{Y_t(\varpi)} + \frac{Y_t(\varpi)}{X_t(\varpi)} \right] - 1 \right\}$$

X_t, Y_t ...spektrální obsah dvou oken vypočítaný pomocí FFT

4. Stanovení lokálních maxim diferencí a následná aplikace na původní signál EEG.
5. Vykreslení grafů.

4.2.2 Řešení pomocí spektrální difference ve dvou spojených oknech – PSD parametrický a neparametrický výpočet

Tato metoda je obměnou předcházející metody. Místo FFT používá parametrické a neparametrické stanovení spektrální výkonové hustoty (PSD) v jednotlivých oknech.

Spektrální výkonová hustota (PSD)

Spektrální výkonová hustota je veličina, která ukazuje rozložení energie (hustoty výkon signálu) ve spektru. Jednotkou této veličiny je $\frac{W}{Hz}$.

Pro stanovení PSD se používají parametrické a neparametrické metody. Neparametrické metody vychází z diskretní Fourierovy transformace (např. Schusterův periodogram, Welchova metoda), zatímco parametrické metody počítají s řadou parametrů, které jsou odhadnuty na základě pozorovaných dat (Modely – AR autoregresivní, MA – s klouzavým průměrem, ARMA – autoregresivní s klouzavým průměrem). Parametrické metody nepotřebují dlouhé záznamy, nedochází k prosakování spektra. Výsledky těchto metod bývají mnohem lepší než výsledky metod neparametrických. [8]

Skripty s názvem *segment_pburg.m* a *segment_periodogram.m* pro řešení této metody pracují následovně:

1. Načtení signálu a výběr konkrétního kanálu EEG.
2. Nastavení délky oken a mezní hodnotu segmentace – konzultace se skriptem *white_noise_for_pburg.m* / *white_noise_for_pburg.m*.

3. Načtení dvou spojených oken. Okna kloužou po signálu (postupné načítání jednotlivých vzorků) pomocí *for* cyklu a probíhá výpočet spektrální výkonové hustoty pomocí:

- Funkce v Matlabu *pburg*, která počítá PSD parametrickou Burgovou metodou.
- Funkce v Matlabu *periodogram*, počítá PSD neparametrickou metodou

Míra difference se počítá opět podle vzorce (8).

$$DIFF = \max \left\{ \frac{1}{2} \left[\frac{X_t(\varpi)}{Y_t(\varpi)} + \frac{Y_t(\varpi)}{X_t(\varpi)} \right] - 1 \right\}$$

X_t, Y_t ...spektrální výkonová hustota v oknech

4. Stanovení lokálních maxim diferencí a následná aplikace na původní signál EEG.
5. Vykreslení grafů.

5 Volba parametrů pro adaptivní segmentaci

Výsledky adaptivní segmentace ovlivňují některé parametry, které je třeba vhodně zvolit. Stanovení těchto parametrů je velice složité a ne vždy vyhovuje všem kanálům.

5.1 Stanovení délky okna (WL)

V této bakalářské práci všechny metody adaptivní segmentace využívají dvou spojených oken klouzajících po signálu.

Délka okna (WL) musí být volena kompromisem. Jelikož ovlivňuje časové a frekvenční rozlišení, je délka důležitým vstupním parametrem. Obecně platí, že při kratší délce okna získáme lepší časové rozlišení ovšem na úkor rozlišení frekvenčního, které poklesne. Z toho tedy plyne, čím delší délka okna, tím lepší frekvenční rozlišení. [6]

Všechny skripty pro řešení adaptivní segmentace počítají s délkou okna odpovídající vzorkovací frekvenci, to je 128 vzorků na okno. Dobré výsledky lze získat s doporučenou délkou okna WL 100 až 150.

5.2 Stanovení meze pro adaptaci pomocí bílého šumu (MEZ)

Skripty pro řešení této problematiky *white_noise_for_af.m*, *white_noise_for_pburg.m*, *white_noise_for_fft.m*, *white_noise_for_periodogram.m* řeší stanovení optimální meze pro každou metodu zvlášť.

Rozsah EEG se uvádí 2 až 300 μV , většinou však dosahuje hodnot 2 až max. zhruba 200 (250) μV . Jednotlivé kanály se napětově výrazně liší. Přizpůsobení bílého šumu EEG záznamu je proto složité, není možné segmentovat podle jedné stanovené meze u všech kanálů. Například, kdyby se bílý šum nastavil v rozsahu 2 až 300 μV se střední hodnotou 149 μV , nebylo by možné použít vyhodnocenou mez na kanály s nižším napětovým rozsahem.

Pokusem řešení jednotné mezní hodnoty segmentace bylo zprůměrování všech kanálů EEG, výpočet rozsahu a mediánu a přizpůsobení bílého šumu těmito hodnotám, ale ani toto řešení není optimální a opět se ukázalo, že kanály s nižším napětovým rozsahem nemohou být s touto mezí segmentovány.

Jako nejschůdnějším řešením se ukázalo přizpůsobit bílý šum každému signálu zvlášť, což v tomto případě segmentace signálu off-line není velkým problémem.

Řešení vychází z následujících úvah. Bílý šum je náhodný proces s konstantní výkonovou hustotou na všech kmitočtech, jeho střední hodnota je nulová a spektrum konstantní pro všechny frekvence. Tento signál je stacionární. Tyto předpoklady uvažujeme v ideálním případě. [7]

Ve skriptu se nejprve generuje bílý šum, který se základními matematickými operacemi přiblíží rozsahu signálu EEG, a poté proběhne tento signál naprogramovaným algoritmem pro adaptivní segmentaci. Mez segmentace se snižuje tak dlouho, dokud program nevyhodnotí jeden segment (nebo minimální počet segmentů, je třeba hledat mezní hodnotu, která bude segmentovat zhruba v pěti po sobě jdoucích spuštění programu - volíme kompromis). Tímto se stanoví pomocí teoreticky ryze stacionárního signálu mez pro adaptivní segmentaci EEG signálu nestacionárního.

Takto vyhodnocená mezní hodnota je přibližná (šum přibližně adaptujeme na rozsah kanálu a přibližně stanovujeme mez) a také podle toho se s ní musí pracovat.


6 Zhodnocení výsledků

Tato kapitola se věnuje zhodnocení výsledků jednotlivých programů. Jde především o zhodnocení správného určení mezní hodnoty bílého šumu, čemuž se věnují skripty *white_noise_for_af.m*, *white_noise_for_pburg.m*, *white_noise_for_fft.m*, *white_noise_for_periodogram.m*. Dále pak posouzení samotné adaptivní segmentace stanovené pomocí skriptů *segment_af.m*, *segment_fft.m*, *segment_pburg.m* a *segment_periodogram.m*.

Pro adaptivní segmentaci použitými metodami je stěžejní výpočet míry difference, potažmo maximální míry difference. Nulová hodnota difference nám ukazuje na fakt, že se charakteristika signálu nemění, to znamená, že je signál stacionární. Proto je třeba určit již zmiňovanou mez, abychom stanovili, do jaké hodnoty míry difference bude ještě signál brán jako stacionární, jakmile se tato mez překročí, skončí stacionární úsek.

6.1 Zhodnocení výsledků stanovení mezní hodnoty pomocí bílého šumu

Skripty věnující se této problematice ukazují, že vyhodnocené meze nelze aplikovat u každé metody. Zhodnocení mezních hodnot není vždy jednoduché. Zatím co u některých metod si můžeme směle dovolit vyhodnocené meze použít, přičemž získáme jejich aplikací vyhovující segmentaci, u jiných je třeba meze pro použití ještě snížit. Další podkapitoly ukazují řešení jednotlivých metod s využitím bílého šumu (Obr. 11) a zhodnocení použitelnosti výsledků pro další aplikaci.



Obrázek 11: Bílý šum


6.1.1 Stanovení mezní hodnoty - white_noise_for_af.m

Metoda pomocí jednoduché míry difference mezi amplitudami a frekvencemi (Obr. 12).

Vypočtené difference touto metodou nesou hodnoty řádově v tisících, proto i mez pro segmentaci můžeme očekávat v těchto hodnotách. Od toho se samozřejmě bude odvíjet i přesnost stanovení meze, která se nebude určovat na jednotky, ale postačí řádově v tisících potažmo stovkách.

V tomto případě se ukázalo výhodnějším volit délku okna nízkou (asi 50-60). Snížením délky okna se výsledná mez snížila a stala se tím použitelnější pro segmentaci signálu EEG.

Stanovení optimální meze pomocí bílého šumu není v tomto případě zcela jednoznačné. Stanovená mez se pohybuje zhruba kolem 6000 a ve většině případů je třeba mez pro segmentaci snížit zhruba o 1000 až 2000, aby bylo možné ji použít.




Obrázek 12: Stanovení meze WN kanál 9: WL=50, MEZ=6000

6.1.2 Stanovení mezní hodnoty - white_noise_for_fft.m

Určení mezních hodnot pro metodu využívající spektrální difference FFT (Obr. 13) více méně souhlasí.

Míry diferencí nejsou příliš vysoké (řádově v desítkách) až na občasné vysoké difference, které se skokově liší. Právě kvůli těmto skokům se hůře hodnotí mezní hodnota, třeba volit kompromis.

Vyhodnocené mezní hodnoty se pohybuje většinou v rozmezí 60 až 90. Někdy je třeba mezní hodnoty při aplikaci na EEG signál o hodnotu 10 zvýšit či snížit, aby byla segmentace přijatelnější.




Obrázek 13: Stanovení meze WN kanál 9: WL=50, MEZ=70

6.1.3 Stanovení mezní hodnoty - white_noise_for_pburg.m

Vyhodnocené meze pro metodu s diferencemi PSD vypočítané pomocí parametrické Burgovy metody (Obr. 14) ve většině případů segmentují velice dobře.

Diference se pohybují řádově v jednotkách, vzhledem k těmto velice malým hodnotám difference je těžké úplně přesně stanovit hodnotu dané meze (většinou se pohybuje kolem 2,5). Hodnoty mezí v rozmezí 2 až 3 segmentují téměř všechny kanály s poměrně dobrými výsledky. V některých případech aplikace na EEG signál je možné mez snížit pro lepší segmentaci.




Obrázek 14: Stanovení meze WN kanál 9: WL=Fvz, MEZ=2,5

6.1.4 Stanovení mezní hodnoty - white_noise_for_periodogram.m

Stanovení meze pomocí šumu metodou s diferencí PSD pomocí neparametrické metody periodogramu (Obr. 15) zcela nevyhovuje pro aplikaci na signál EEG.

Diference se pohybují řádově v tisících, avšak některé diference se skokově liší a dosahují hodnot až 10^6 . Z toho důvodu se vyhodnocená mez pohybuje ve vysokých hodnotách přes 100 000 pro diference signálu nepoužitelných.

Takto velké rozdíly diferencí jsou nejspíš způsobeny neparametričností metody stanovení výkonové spektrální hustoty (periodogram).



Obrázek 15: Stanovení meze WN kanál 9: WL=Fvz, MEZ=100 000

6.2 Zhodnocení výsledků adaptivní segmentace

Následující kapitoly ukazují výsledky adaptivní segmentace, snaží se sumovat poznatky o jednotlivých metodách a uvádí charakteristické rysy jednotlivých metod.

V každé podkapitole jsou grafické ukázky segmentace kanálu 9 EEG záznamu danou metodou - další ukázky viz příloha.

6.2.1 Adaptivní segmentace – *segment_af.m*

Diference:


Maxima vyhodnocených diferencí se pohybují v řádu tisíců. V některých kanálech sahají až k hodnotám kolem 16000, v jiných jsou maximální difference nízké, v některých případech nepřesáhnou 4000.

Mezní hodnota:

Mezní hodnoty pro jednotlivé kanály většinou neodpovídají stanoveným mezním hodnotám pomocí bílého šumu *white_noise_for_af.m*, které jsou v rozsahu 4000 až 6000. Pro dosažení vyhovující segmentace je třeba pro aplikaci na EEG signál snížit mez o 1000 až 2000. Stanovená mez (kolem 6000) ve většině kanálů segmentaci provede, avšak počet segmentů je minimální. Získané segmenty jsou příliš dlouhé. Obecně se předpokládá stacionarita segmentů do délky 2 s (tento předpoklad se používá u konstantní segmentace). [3]

Celkové hodnocení:

Adaptivní segmentace s využitím střední frekvence a amplitudy (Obr. 16) se ukázala jako nejjednodušší metoda jak pro vytvoření, tak pro vlastní segmentaci EEG. Využívá jednoduchých algoritmů, je nenáročná a velice rychlá.



Obrázek 16: Adaptivní segmentace kanál 9: WL=Fvz-1, MEZ=5000

Další ukázky kanálů segmentovaných touto metodou viz obrázky příloha (Obr. 20, 24, 28)

6.2.2 Adaptivní segmentace – *segment_fft.m*

Diference:


Diference mají tvar píků, přičemž maximální diference se v kanálech pohybuje kolem 300 až 500. Na obrázku (Obr. 17) lze vidět skokový charakter diferencí.

Mezní hodnota:

Vyhodnocené mezní hodnoty pomocí *white_noise_for_fft.m* jsou přijatelné. Pohybují se v rozsahu zhruba 60-90 a lze je aplikovat na signál v nezměněné podobě, popřípadě hodnoty upravit v rozmezí ± 10 .

Celkové hodnocení:

Metoda je náročná na výpočet, jelikož musí počítat FFT pro každý posun okna a následného výpočtu diference. Metoda je nespolehlivá, produkuje falešná lokální maxima v sousedství skutečných hranic segmentů. [8]



Obrázek 17: Adaptivní segmentace kanál 9: WL=Fvz, MEZ=60

Další ukázky kanálů segmentovaných touto metodou viz obrázky příloha (Obr. 21, 25, 29)

6.2.3 Adaptivní segmentace – *segment_pburg.m*

Diference:


Maximální diference se v kanálech pohybují v rozmezí zhruba 10 až 43. Charakter křivky vypočítaných diferencí je patrný z obrázku (Obr. 18).

Mezní hodnota:

Mezní hodnoty se pohybují v nízkých hodnotách vzhledem k výsledkům stanovení mezní hodnoty *white_noise_for_pburg.m* (2 až 3) a charakteru křivky diferencí. Aplikace mezní hodnoty na signál je možné v nezměněné podobě. V některých kanálech je vhodné mezní hodnotu zvýšit. Segmentace vykazuje nejlepší výsledky v rozmezí mezních hodnot 3 až 5.

Celkové hodnocení:

Vyhodnocení segmentace je pomalejší než u ostatních použitých metod. Segmentace by měla být spolehlivější než při použití výpočtu FFT. Zde se spektrální obsah počítá parametrickou Burgovou metodou stanovení spektrální výkonové hustoty.



Obrázek 18: Adaptivní segmentace kanál 9: WL=Fvz, MEZ=2,5

Další ukázky kanálů segmentovaných touto metodou viz obrázky příloha (Obr. 22, 26, 30)

6.2.4 Adaptivní segmentace – *segment_periodogram.m*

Diference:


Maximální diference sahají k vysokým hodnotám až 10^6 . Na obrázku (Obr. 19) je vidět píkovitý charakter maximálních diferencí.

Mezní hodnota:

Mezní hodnota *white_noise_for_periodogram.m* je pro segmentaci samotného EEG nepoužitelná, je příliš vysoká. Je to dáno velkými rozdíly mezi píky. Použitím mezních hodnot 4000 až 6000 je možné signál segmentovat s uspokojujícím výsledkem.

Celkové hodnocení:

Tato metoda využívá výpočet spektrálního obsahu pomocí metody periodogramu. Tato metoda je neparametrická, což zavádí do segmentace chyby. Na první pohled je patrná úplná odlišnost segmentace s použitím výpočtu PSD pomocí Burgovy metody a metody periodogramu. Dá se předpokládat větší přesnost u Burgovy metody právě kvůli parametrickému charakteru.



Obrázek 19: Adaptivní segmentace kanál 9: WL=Fvz, MEZ=6000

Další ukázky kanálů segmentovaných touto metodou viz obrázky příloha (Obr. 23, 27, 31)

7 Shrnutí

Segmentaci EEG signálu pomocí jednotlivých lze porovnávat z mnoha úhlů pohledu. Tato práce se věnuje dvěma metodám – segmentace využívající odhadu diferencí amplitud a frekvencí a segmentace využívající diferencí spekter FFT (poslední dvě metody jsou alternativou této metody).

Z hlediska jednoduchosti algoritmů výpočtu i programové realizace se jako nejlepší ukázala metoda adaptivní segmentace na základě odhadu amplitudové a frekvenční míry diferencí (*segment_af.m*). Možná chyba této metody je zavedena využíváním odhadu střední amplitudy a frekvence.

Jak už bylo řečeno v kapitole 6.6.2, metoda spektrální difference s využitím FFT je náročná na výpočet a navíc generuje falešná lokální maxima v blízkosti skutečných hranic segmentu. [8]. Jako alternativa této metody pro zlepšení výsledků jsou zavedeny dva další postupy adaptivní segmentace na základě spektrální difference, přičemž zlepšení by mělo přinést použití výpočtů spektrální výkonové hustoty.

Dalo by se říct, že vylepšení přináší metoda využívající parametrického výpočtu PSD (neparametrická metoda periodogramu zavádí další chyby právě svým neparametrickým charakterem).

Podíváme-li se na výsledky segmentace, je patrné, že dvě základní metody se od sebe výsledky do jisté míry liší. Některé hranice mají společné, většina se však liší.

8 Závěr

Tato práce nastínila základní poznatky o EEG signálu a problematiku segmentace nestacionárního EEG signálu.

Pomocí dvou základních metod (segmentace využívající odhadu diferencí amplitud a frekvencí a segmentace využívající diferencí spekter FFT) se spojenými okny a dvou alternativ (segmentace využívající diferencí PSD – periodogram, Burgova metoda) jsem se snažila vytvořit program, který by možná co nejlépe segmentoval EEG signál.

Uvedení teoretických znalostí do praxe se ukázalo velice složité. Jen velmi obtížně je možné stanovit parametry (WL, MEZ), které jsou pro segmentaci stěžejní a významně ovlivňují výsledek segmentace. Veškeré metody a využívané modely zavádí do výpočtů různé chyby a nepřesnosti. I přes snahu objevit způsob, jakým by se dali parametry stanovit (např. stanovení meze pomocí bílého šumu), zůstala tato problematika do jisté míry otázkou kompromisu.

Řešení by se také dalo modifikovat pomocí dvou oken s tím rozdílem, že by jedno bylo nepohybující se na začátku signálu EEG a druhé by klouzalo po signálu. Tato metoda je ovšem zatížena problémem se synchronizací pohybu oken a je pro programové řešení náročnější.

Zavedení těchto metod do praktického využití je zajisté možné, nicméně je třeba znát algoritmy výpočtů, znát také možné chyby, které zavádí a s ohledem na toto všechno tyto metody využívat.

Seznam použité literatury

- [1] KOLÁŘ, Radim. ALDT_T6_EEG: přednáška z předmětu Lékařská diagnostická technika. Dostupné z https://www.vutbr.cz/elearning/file.php/111753/Prednasky/ALDT_T6_EEG.pdf
- [2] KOZUMPLÍK, Jiří. AABS_09_EEG1: přednáška z předmětu Analýza biologických signálů.
- [3] MOHYLOVÁ J., KRAJČA V. Zpracování biologických signálů. Studijní materiály – e-learning. Vysoká škola báňská, Technická Universita Ostrava, 2007. ISBN 978-80-248-1491-9.
- [4] MOHYLOVÁ J., KRAJČA V. Zpracování signálu v lékařství . Žilinská Univerzita v Žiline 2004.
- [5] NEŘIVA, P.: Signály a soustavy I. Skriptum VŠB FEI, 1993, (ISBN 80-7078-196-3)
- [6] JAN, Jiří; KOZUMPLÍK, Jiří; KOLÁŘ, Radim. Číslicové zpracování a analýza signálů: Počítačová cvičení. Brno: VUTUM, 2003. 84 s.
- [7] ŠEBESTA, V., SMÉKAL, Z. Signály a soustavy. Brno: VUT v Brně, 2003. s. 1-165. ISBN: REL117.
- [8] KRAJČA, Vladimír; MOHYLOVÁ, Jitka. Číslicové zpracování neurofyzilogických signálů. [s.l.]: ČVUT, 2011. 168 s. ISBN 978-80-01-04721-7.
- [9] Metody zpracování dlouhodobých záznamů EEG. Lékař a technika. 2008, roč. 38, č. 3, s. 12.
- [10] SANEI, Saeid; CHAMBERS, Jonathon. EEG signal processing. Hoboken, NJ: John Wiley, c2007, 289 s. ISBN 04-700-2581-6.
- [11] JAN, Jiří. Číslicové zpracování a analýza signálů: stručné skriptum. Brno: MJ servis Brno, s.r.o., 2010, 138 s. ISBN 978-80-214-4018-0.
- [12] SÖRNMO, Leif; LAGUNA Pablo. Bioelectrical signal processing in cardiac and neurological applications. Hardback: Elsevier Academic Press, 2005. ISBN 9780124375529.
- [13] Getting Closer to Decoding Brain Activity from EEG. Medgadget [online]. 2004—2011 [cit. 2012-05-10]. Dostupné z: http://medgadget.com/2009/12/getting_closer_to_decoding_brain_activity_from_eeg.html
- [14] Electrode location and recording. Pedagoška fakulteta Univerza v Ljublani [online]. 2010 [cit. 2012-05-10]. Dostupné z: <http://www.pef.uni-lj.si/eprolab/comlab/sttop/sttop-bm/Additional/Electrode%20location%20and%20recording.htm>


Seznam zkratk a symbolů

EEG	Elektroencefalograf
EKG	Elektrokardiograf
EOG	Elektrookulograf
EMG	Elektromyograf
VEP	Vizuální evokované potenciály
BAEP	Sluchové evokované potenciály
SEP	Somatické evokované potenciály
EP	Evokované potenciály
FT	Fourierova transformace
FFT	Rychlá Fourierova transformace
STFT	Krátkodobá Fourierova transformace
AR	Autoregresní model
MA	Model klouzavých průměrů
ARMA	Autoregresní model klouzavých průměrů
LP	Lineárně predikční filtr
DIFF	Diference
f_{vz}	Vzorkovací frekvence
Fvz	Vzorkovací frekvence
f_{max}	Maximální frekvence
a	Koeficient
e	Chyba
x	Vzorek signálu
N	Počet vzorků
n	Číslo vzorku
w	Okno
ACFL	Počet koeficientů autokorelační funkce
X, Y	Spektra signálu
τ	Posun signálu
PSD	Výkonová hustota
A_w	Odhad střední amplitudy

F_w	Odhad střední frekvence
wL	Délka okna L
WL	Délka okna
WN	Bílý šum
k	Váhovací koeficient


Přílohy

Kanál 7: *segment_af.m*




Obrázek 20: Adaptivní segmentace kanál 7: WL=Fvz-1, MEZ=3500

Kanál 7: *segment_fft.m*




Obrázek 21: Adaptivní segmentace kanál 7: WL=Fvz, MEZ=60

Kanál 7: *segment_pburg.m*




Obrázek 22: Adaptivní segmentace kanál 7: WL=Fvz, MEZ=1

Kanál 7: *segment_periodogram.m*




Obrázek 23: Adaptivní segmentace kanál 7: WL=Fvz, MEZ=5000

Kanál 15: *segment_af.m*




Obrázek 24: Adaptivní segmentace kanál 15: WL=Fvz-1, MEZ=4000

Kanál 15: *segment_fft.m*




Obrázek 25: Adaptivní segmentace kanál 15: WL=Fvz, MEZ=90

Kanál 15: segment_pburg.m




Obrázek 26: Adaptivní segmentace kanál 15: WL=Fvz, MEZ=2,5

Kanál 15: segment_periodogram.m




Obrázek 27: Adaptivní segmentace kanál 15: WL=Fvz, MEZ=6000

Kanál 20: segment_af.m




Obrázek 28:Adaptivní segmentace kanál 20: WL=Fvz-1, MEZ=6000

Kanál 20: segment_fft.m




Obrázek 29: Adaptivní segmentace kanál 20: WL=Fvz, MEZ=70

Kanál 20: segment_pburg.m



Obrázek 30: Adaptivní segmentace kanál 20: WL=Fvz, MEZ=3

Kanál 20: segment_periodogram.m



Obrázek 31: Adaptivní segmentace kanál 20: WL=Fvz, MEZ=6000

Elektronické přílohy (CD)

Složky:

Programy_BP – obsahuje:

- záznamy EEG ve formátu .trc a jejich načítání *read_eeg.m*
- programy pro adaptivní segmentaci (Matlab) *segment_af.m*, *segment_fft.m*, *segment_pburg.m* a *segment_periodogram.m*.
- programy pro stanovení meze pomocí bílého šumu (Matlab) *white_noise_for_af.m*, *white_noise_for_pburg.m*, *white_noise_for_fft.m*, *white_noise_for_periodogram.m*

Obrázky_BP – obsahuje použité obrázky (JPEG, PNG, GIF)

Zdroje_BP – obsahuje elektronické podoby některých použitých zdrojů (PDF)

Soubory:

Anezka_Ostra_BP.pdf - elektronická verze bakalářské práce (PDF)

Anezka_Ostra_BP.docx - elektronická verze bakalářské práce (MSWord)