


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

AUTOMATICKÁ SEGMENTACE DAT EEG

AUTOMATED EEG DATA SEGMENTATION

BAKALÁŘSKÁ PRÁCE
BACHELOR'S THESIS


AUTOR PRÁCE
AUTHOR

ONDŘEJ KRUPKA

VEDOUcí PRÁCE
SUPERVISOR

Ing. KAREL BUBNÍK

BRNO 2013



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav biomedicínského inženýrství

Bakalářská práce

bakalářský studijní obor

Biomedicínská technika a bioinformatika

Student: Ondřej Krupka

ID: 137253

Ročník: 3

Akademický rok: 2012/2013

NÁZEV TÉMATU:

Automatická segmentace dat EEG

POKYNY PRO VYPRACOVÁNÍ:

1) Proved'te literární rešerši v oblasti automatické segmentace dat EEG. Popište jednotlivé metody a proved'te jejich vzájemné srovnání. 2) Z popsáných metod vyberte dvě metody, u nichž navrhnete algoritmus řešení v programovém prostředí MatLab. 3) Realizujte vybrané metody v programovém prostředí MatLab. 4) Ověřte funkčnost metod na dodaných záznamech EEG. 5) Vzájemně porovnejte výsledky obou zvolených metod.

DOPORUČENÁ LITERATURA:

[1] SAID, Sanei, J.A. Chambers. EEG signal processing. England: John Wiley & Sons Ltd, 2007. ISBN 04-700-2581-6.

[2] JAN, Jiří. Číslicová filtrace a analýza signálů. Brno: VUT IUM, 2002. 2. upravené a rozšířené vydání, 427 s. ISBN 80-214-2911-9.

Termín zadání: 11.2.2013

Termín odevzdání: 31.5.2013

Vedoucí práce: Ing. Karel Bubník

Konzultanti bakalářské práce:

prof. Ing. Ivo Provazník, Ph.D.

Předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

Abstrakt

Tato bakalářská práce se zabývá EEG signálem, jeho vlastnostmi, použitím a způsoby zpracování. Prvním úkolem je seznámení s různými metodami automatické segmentace dat EEG signálu. Dále je předmětem realizace některých metod v programu MATLAB, ověření jejich funkčnosti a vzájemné porovnání výsledků segmentace.

Klíčová slova

Elektroencefalografie (EEG), segmentace signálu

Abstract

This bachelor's thesis deals with EEG signal, its properties, usage and its processing methods. The main task is introduction with different methods of automatic EEG data segmentation. Furthermore the subject of this project is realization of some methods in MATLAB software, verification of functionality and mutual comparison of segmentation results.

Keywords

Electroencephalography (EEG), signal segmentation

Bibliografická citace:

KRUPKA, O. AUTOMATICKÁ SEGMENTACE DAT EEG. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií. Ústav biomedicínského inženýrství, 2013. 51s. Bakalářská práce. Vedoucí práce: Ing. Karel Bubník.

Prohlášení:

Prohlašuji, že svoji bakalářskou práci na téma AUTOMATICKÁ SEGMENTACE DAT EEG 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 autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této 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 části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009Sb.

V Brně dne 28. 5. 2013

.....

Poděkování:

Děkuji vedoucímu bakalářské práce Ing. Karlu Bubníkovi za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé bakalářské práce.

V Brně dne 28. 5. 2013

.....

Obsah

Obsah.....	vi
Seznam obrázků	viii
Seznam tabulek	ix
1 Úvod	1
2 Elektroencefalografie	2
2.1 Snímání EEG.....	2
2.1.1 Elektrody.....	2
2.1.2 Metodika snímání.....	3
2.2 EEG signál	5
2.2.1 Základní struktura EEG	6
2.2.2 Spontánní potenciál – základní aktivita.....	6
2.2.3 Grafoelementy.....	6
2.2.4 Evokovaný potenciál.....	7
2.2.5 Artefakty.....	7
2.3 Zpracování EEG signálu.....	8
2.3.1 Předzpracování.....	8
2.3.2 Analýza	9
2.3.3 Klasifikace	10
3 Segmentace signálu.....	11
3.1 Konstantní Segmentace.....	12
3.2 Adaptivní segmentace	12
3.2.1 Adaptivní segmentace pomocí lineární predikce	12
3.2.2 Adaptivní segmentace pomocí autokorelační funkce	14
3.2.3 Adaptivní segmentace pomocí míry difference odhadnuté z FFT	15
3.2.4 Adaptivní segmentace pomocí míry difference střední amplitudy a frekvence	16
3.2.5 Další metody adaptivních segmentací.....	17
4 Programová realizace	18
4.1 Referenční signál	18
4.1.1 Měření	18
4.1.2 Předzpracování signálu.....	19
4.2 Vypracování adaptivní segmentace pomocí míry difference střední amplitudy a frekvence	20
4.3 Vypracování adaptivní segmentace pomocí míry difference odhadnuté z FFT	21

4.4	Vypracování adaptivní segmentace pomocí autokorelační funkce.....	21
4.5	Nastavení parametrů segmentace	22
4.5.1	Nastavení délky okna.....	22
4.5.2	Nastavení prahu detekce.....	22
5	Srovnání výsledků detekce	24
5.1	Výsledky detekce <i>eeg_seg_af.m</i>	24
5.2	Výsledky detekce <i>eeg_seg_fft.m</i>	25
5.3	Výsledky detekce <i>eeg_seg_kor.m</i>	26
5.4	Vzájemné porovnání.....	28
5.5	Srovnání náročnosti výpočtu	30
6	Závěr	33
	Seznam použité literatury	34
	Seznam zkratk.....	35
A.	Obrázková příloha	36
B.	Obsah CD	42

Seznam obrázků

Obrázek 2.1: Standardní schéma umístění povrchových elektrod.....	2
Obrázek 2.2: Referenční zapojení elektrod	4
Obrázek 2.3: Bipolární zapojení elektrod	4
Obrázek 2.4: Zprůměrněné zapojení elektrod	5
Obrázek 2.5: Systém zpracování signálu, pracující v reálném čase.....	8
Obrázek 2.6: Kvantovaný signál	9
Obrázek 3.1: EEG signál obsahující preiktální, iktální a postiktální segmenty	11
Obrázek 3.2: Princip segmentace EEG signálu pomocí lineární predikce	13
Obrázek 3.3: Princip segmentace EEG signálu pomocí autokorelační funkce	14
Obrázek 3.4: Ukázka použití míry difference. a – EEG signál, b – vypočtená míra difference signálu	15
Obrázek 3.5: Segmentace pomocí míry difference střední amplitudy a frekvence.	17
Obrázek 4.1: Reálné segmenty.....	19
Obrázek 4.2: Signál před a po filtraci	20
Obrázek 5.1: Výsledky segmentace <i>eeg_seg_af.m</i>	24
Obrázek 5.2: Výsledky segmentace <i>eeg_seg_fft.m</i>	26
Obrázek 5.3: Výsledky segmentace <i>eeg_seg_kor.m</i>	27
Obrázek 5.4: Porovnání jednotlivých metod, kanál 11. Shora - a) Střední amplituda a frekvence b) FFT c) Autokorelační funkce.....	28
Obrázek 5.5: : Porovnání jednotlivých metod, kanál 17. Shora - a) Střední amplituda a frekvence b) FFT c) Autokorelační funkce	29
Obrázek 5.6: Porovnání jednotlivých metod na alternativním signálu. Shora - a) Střední amplituda a frekvence b) FFT c) Autokorelační funkce	30
Obrázek 5.7: Závislost délky výpočtu na počtu vzorků signálu EEG.....	31
Obrázek A.1:Výsledek segmentace <i>eeg_seg_af.m</i> , okno=128, prah=0,1	36
Obrázek A.2:Výsledek segmentace <i>eeg_seg_fft.m</i> , okno=128, prah=0,05.....	37
Obrázek A.3:Výsledek segmentace <i>eeg_seg_akor.m</i> , okno=128, prah=8e13	38
Obrázek A.4:Výsledek segmentace <i>eeg_seg_af_signal1.m</i> , okno=128, prah=0,1	39
Obrázek A.5:Výsledek segmentace <i>eeg_seg_fft_signal1.m</i> , okno=128, prah=0,1	40
Obrázek A.6:Výsledek segmentace <i>eeg_seg_kor_signal1.m</i> , okno=128, prah=2e11	41

Seznam tabulek

Tabulka 2.1: Rozdělení EEG vln	6
Tabulka 5.1: Závislost délky výpočtu na počtu vzorků signálu EEG.....	31

1 Úvod

Mozek, jakožto nejkomplexnější struktura v lidském těle, slouží jako řídicí centrum nervové soustavy. Odpovídá za funkce organismu a to od základních životních funkcí, až po abstraktní myšlení. V mozku jsou obrovskou rychlostí, nepřetržitě přenášeny informace skrze elektrické impulsy a to i při spánku. Proto je velice důležité mozek zkoumat z lékařského hlediska a předcházet, či léčit onemocnění poškozující právě mozek. Jednou z nejdůležitějších metod vyšetření mozku je Elektroencefalografie.

Pro diagnostiku je důležité signál zpracovat, mimo jiné jej segmentovat na stacionární úseky, které slouží k identifikaci jednotlivých mozkových aktivit a patologických jevů.

Tato práce pojednává o problematice encefalografie, zpracování a především o segmentaci dat EEG. Teoreticky popisuje jednotlivé metody segmentace, následně je realizován výběr několika metod pro vypracování v prostředí MATLAB.

Cílem práce je porovnání jednotlivých metod segmentace z hlediska účinnosti a náročnosti výpočtu, který souvisí s aplikací metod v klinické praxi.

2 Elektroencefalografie

Elektroencefalografie (EEG) je neinvazivní diagnostická metoda, zaznamenávající elektrickou aktivitu mozku. Pomocí povrchových elektrod jsou měřeny změny polarizací neuronů v čase, které vznikly na základě kontinuální aktivity vzrušivých membrán na synapsích. Jsou vytvářeny dipóly, pomocí kladných a záporných nábojů, které jsou kolmé k povrchu mozku [9].

Z průběhů snímané elektrické aktivity lze posuzovat funkční stav jednotlivých částí mozku. Proto je elektroencefalografie jednou ze základních diagnostických metod [2].

Především je snímána aktivita povrchových struktur, výchylka takového signálu je řádově v desítkách μV [5].


Zdrojem EEG signálu jsou z větší části excitační postsympatické potenciály a inhibiční postsympatické potenciály, neboli EPSP a IPSP, a z menší části akční potenciály, které jsou méně časté s mnohem kratší dobou trvání, ale zato mají větší výchylku [5].

2.1 Snímání EEG

Výsledný signál vzniká superpozicí jednotlivých kanálů, snímáný záznam se jmenuje elektroencefalogram. Elektroencefalogram může být zobrazen na display nebo na papír [9].

2.1.1 Elektrody

Pro snímání elektrické aktivity mozku se používají nejčastěji povrchové elektrody umístěné na hlavě pacienta. Počet použitých elektrod závisí na množství snímaných kanálů elektroencefalografu a způsobu snímání. Elektrody jsou na pacienta umísťovány dle standardního schématu (Obrázek 2.1) [1] [2].



Obrázek 2.1: Standardní schéma umístění povrchových elektrod

Jiným příkladem snímání je elektrokortikografie, kde elektrody jsou umístěny přímo na povrchu mozku při neurochirurgickém zákroku [2].

2.1.2 Metodika snímání

Běžně se pro měření elektroencefalografu používá 19 elektrod, kterých je 8 párových a 3 vertexové (nepárové). Elektrody jsou rozloženy tak, že v každé pomyslné linii jsou vzdáleny 10-20-20-20-20-10% z celkové délky, toto rozmístění se označuje jako systém 10/20 [9].

Pozice elektrod jsou označovány podle jejich umístění (viz Obrázek 2.1) [5]:


- **F**rontální
- **C**entrální
- **P**arietální
- **T**emporální
- **O**kcipitální
- **A**urikulární

Ve speciálních případech jdou použít i jiné systémy zapojení. Například systém 10/10 s dvojnásobným počtem elektrod, který se používá v epileptologii. Dále redukovaný počet 10 elektrod používaný u velmi malých kojenců s rozložením 20/40 [9].

Pro registraci bioelektrické aktivity potřebujeme dvě elektrody připojené na dva vstupy diferenčního zesilovače jednoho EEG signálu. Tato základní jednotka se nazývá **svod**. Výše zmíněné elektrody se nazývají **explorační** a **referenční** a jsou zapojeny na 1., respektive 2. vstup diferenčního zesilovače. Při měření můžeme použít více způsobů uspořádání použitých svodů:


- Referenční (unipolární)
- Bipolární
- Zdrojové

Prvním způsobem uspořádání je referenční, neboli unipolární zapojení, u kterého jsou explorační elektrody zapojeny proti společné referenční elektrodě (Obrázek 2.2) [5].




Obrázek 2.2: Referenční zapojení elektrod

Další metoda zapojení je bipolární, kde jsou elektrody sekvenčně zapojeny do řady – jedna elektroda je zároveň zapojena na 2. vstup předchozího kanálu a na 1. vstup kanálu následujícího. Elektroda se uplatňuje jako explorační a referenční současně. Metoda má velkou výhodu v možnosti přesné lokalizace ložiska a dobrého zobrazení místních rozdílů ve výchylce (Obrázek 2.3) [5].



Obrázek 2.3: Bipolární zapojení elektrod

Třetí způsob zapojení je tzv. zprůměrněný režim, který využívá indiferentní elektrodu (Obrázek 2.4) [5] [10].



Obrázek 2.4: Zprůměrněné zapojení elektrod

Čtvrtým způsobem zapojení se nazývá zdrojové zapojení. Ve zdrojovém zapojení je pro každou elektrodu vypočtena zvláštní reference, na základě matematické transformace. Dochází k porovnání aktivit každé elektrody s váženým průměrem voltáží ostatních elektrod [9].

Provádí se korekce váhovaným součtem potenciálů ze sousedních elektrod, např.

$$V = V_0 - (V_1 + V_2 + V_3 + V_4)/4, \quad (2.1)$$

kde dochází k potlačení zdroje mimo oblast elektrod 1-4 [5].

2.2 EEG signál

V šedé kůře mozkové můžeme pozorovat tři typy potenciálů. Na těle neuronu, nebo na axonu, vznikají **jednotkové** potenciály, mají velice krátké trvání (v řádech milisekund). Delší jsou **synaptické** potenciály, s trváním 15 – 40ms. Poslední jsou **dendritické** potenciály, které mají komplexní tvar s trváním až 100ms [10].

Elektroencefalograf vzniká nejvíce z dendritických a synaptických potenciálů na povrchu kortexu. Vzniká tedy součinností neuronů z thalamu a kortexu, kde thalamus funguje jako generátor rytmů [10].

2.2.1 Základní struktura EEG

Křivka elektroencefalografu se skládá z několika prvků. Prvním jsou **rytmy**, což jsou nejjednodušší komponenty, na které lze křivku rozložit. Další částí EEG signálu je **základní aktivita**, neboli je převažující aktivita registrovaná po většinu doby snímání na určitém místě. Poslední složkou EEG signálu jsou **grafoelementy** (nazývané také jako tranzienty), vzniklé jako rytmy nápadně vystupující ze základní aktivity. Dělí se na jednotlivé grafoelementy, nebo na komplexy dvou a více grafoelementů se společným výskytem [9].

2.2.2 Spontánní potenciál – základní aktivita

V EEG signálu můžeme rozlišit několik základních elektroencefalografických rytmů, neboli vln (Tabulka 2.1) [5].

Tabulka 2.1: Rozdělení EEG vln

Rytmus	Frekvence [Hz]	Maximální amplituda [μ V]	Výskyt
Delta	do 4	100	U novorozenců normální, u dospělých v bdělém stavu patologický
Theta	4-8	150	Při usínání, přechází v delta rytmus
Alfa	8-13	50	Klid se zavřenými očima
Beta	13-30	30	Zvýšená pozornost
Sigma	kolem 14	40	3. spánkové stadium
Mí	7-11	50	Častý u psychicky narušených jedinců

Při popisování EEG křivky nás zajímá:

- Frekvence – výskyt rytmů za jednotku času
- Výchylka – výstupní voltáž v jednotkách μ V
- Morfologie – monomorfní, polymorfní, bifázický, trifázický
- Výskyt v prostoru – lokalizace rytmů
- Výskyt v čase – kontinuální, periodická atd.
- Synchronie – současný výskyt určité aktivity
- Symetrie – výskyt aktivit nad oběma polovinami hlavy
- Reaktivita – reakce např. při stimulacích, kapitola 2.2.3

2.2.3 Grafoelementy

Grafoelementy jsou části signálu, obvykle vázané na patologické jevy, například na epilepsii. Patří mezi ně například komplex SW, který je tvořen komplexem hrot – pomalá vlna, dále SSS vlny, které indikují epilepsii, dalšími jsou K-komplex, vlny lambda apod [5] [9].

2.2.4 Evokovaný potenciál

Evokované potenciály jsou významné změny v neuronové aktivitě a tím i v EEG signálu. Tyto změny jsou vyvolány vnější stimulací. Důležité jsou reakce a jejich rozdíly u zdravých a nemocných subjektů. Evokované potenciály mají malou výchylku (jednotkách μV) a proto nemusí být v EEG signálu detekovány. Kvůli této skutečnosti se používá kumulačních technik pro získání přesných tvarů.

Pro stimulace využíváme zvukové nebo světelné podněty [4].

2.2.5 Artefakty

Na kvalitu snímání působí několik rušivých elementů, které se snažíme co nejlépe eliminovat např. podmínkami při měření, kdy pacient sedí uvolněně se zavřenýma očima a pootevřenými ústy [4].

Artefakty jsou signály, které nejsou projevem mozkové činnosti. Při měření EEG se s nimi téměř vždy setkáváme. Bývá však snaha tyto artefakty maximálně potlačit.

Mezi nejvýznamnější artefakty patří [5]:

Brum – rušení ze sítě (50Hz) a jeho vyšší harmonické složky, projevuje se při vysokém kožním odporu, či nedokonalém uzemnění EEG přístroje, nebo pacienta. Pro filtraci brumu se používají úzkopásmové FIR filtry s lineární fázovou charakteristikou.

Drift – vliv elektrochemických dějů na rozhraní elektroda-pokožka, dýchací pohyby, pomalé pohyby. Vznikají změnou impedance elektrod a kožního pocení (změna vodivosti kůže). Vlivem pocení může vzniknout i solný můstek, který dokáže snížit výchylku signálu.

Elektrodové artefakty – porucha elektrody, pomalé, vyšší výchylky, obdélníkový tvar.

Pulsové artefakty – pokud je elektroda umístěna nad arterií, nutno změnit umístění. Projevují se periodicky, ostré nebo tvaru trojúhelníku. Perioda ve shodě se srdečním tepem.

Artefakty EKG – způsobuje výskyt hrotů v období komplexu QRS, více výrazné při použití kardiostimulátoru. Dále evokované odpovědi v intervalu T-P. Pro odstranění rušení nebo se současně s EEG snímá i EKG a výsledný signál vzniká odečtením těchto dvou signálů.

Artefakty EOG - pohyby očí a mrkání. Navrhují se adaptivní filtry pro potlačení EOG, nebo se pro odstranění rušení používá stejná metoda jako u rušení pomocí EKG signálu.

Artefakty EMG - vysokofrekvenční (30-50Hz). Mají krátké trvání, ostré vlny. Používá se filtrace dolní propustí, kde je potřeba správně zvolit mezní frekvenci aby nedošlo ke zkreslení ostrých vln a hrotů.

Dentální artefakty – u osob s výplněmi zubů vyrobených z vodivých materiálů.

Jazykové artefakty – jazyk se chová jako dipól. Pohyb jazyka způsobuje pomalé a dlouhé vlny.

Obecně se pro odstranění rušení může použít lineární filtrace (drift, brum). Pro jiné typy rušení můžeme například použít průměrování, adaptivní filtraci, současné měření a následný odečet signálů, nebo i kumulační metody.

2.3 Zpracování EEG signálu

Zpracování EEG signálů můžeme rozdělit na hlavní 3 etapy [3] [7]:

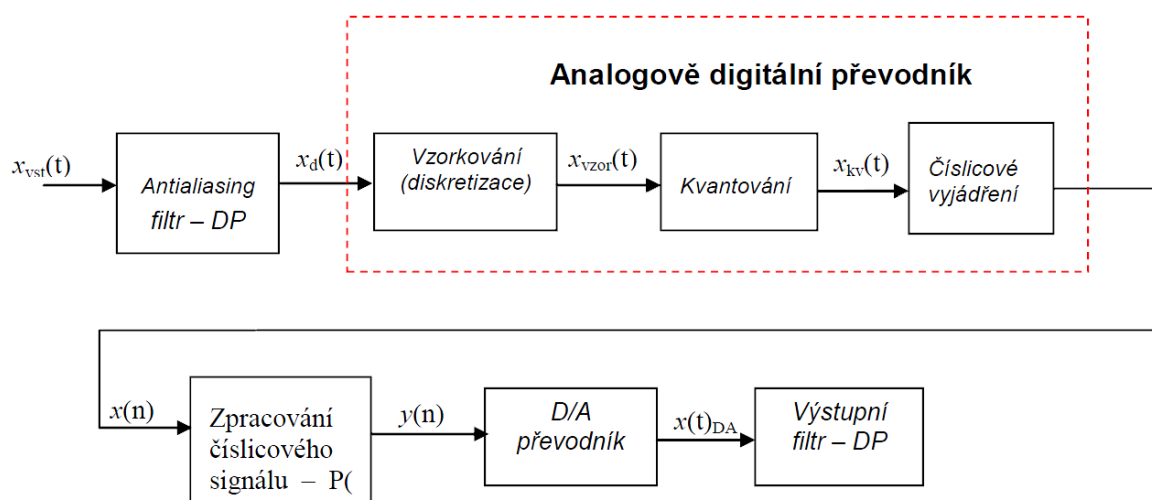
- Předzpracování
- Analýza
- Rozpoznávání a klasifikace

Předzpracování znamená odstranění nežádoucích artefaktů a rušení ze signálu. V podstatě ze signálu vybíráme užitečné složky.

Následuje analýza signálu, ta popisuje signál množinou parametrů. Například spektrální analýza, kde se k rozboru signálu používá rychlá Fourierova transformace. Transformace signálu do frekvenční oblasti umožní stanovení množství a pozici rytmů v jednotlivých frekvenčních pásmech a určení frekvence, která je nejvíce zastoupena v signálu.

Rozpoznávání značí práci s výstupními daty analýzy, kde dochází ke třídění signálu na základě určitých příznaků do klasifikačních tříd. Dále přichází na řadu samotná klasifikace lékařem a jeho rozhodnutí, či diagnóza.

2.3.1 Předzpracování



Obrázek 2.5: Systém zpracování signálu, pracující v reálném čase

Nejprve je signál filtrován pomocí antialiasingového filtru (Obrázek 2.5) [8], který má za úkol filtrovat ze signálu vyšší frekvence než je jedna polovina vzorkovací frekvence.


Aliasing se projevuje překrývání spekter a díky tomu dochází ke ztrátě informace. Tento filtr je realizován analogovou dolní propustí, digitální filtr vyžaduje předchozí vzorkování [8] [12].

Potom je signál přiveden na vstup analogově digitálního převodníku, který převádí spojitý signál na posloupnost vzorků signálu v pravidelných intervalech (vzorkovací frekvence). Vzorkovací frekvence musí dodržovat Nyquistův teorém:

$$f_{vz} \geq 2 \cdot f_{max}, \quad (2.2)$$

kde f_{max} je nejvyšší frekvence, vyskytující se v signálu. Velikost f_{vz} musíme vhodně volit, protože při příliš malé hodnotě vzniká aliasing a při příliš velké vzrůstá velmi výrazně požadavek na paměť počítače.

Výchyly vzorků jsou dále kvantovány do zvolených úrovní (Obrázek 2.6). Tyto úrovně se potom vyjádří v například dvojkové číselné soustavě. Použitá číselná soustava určuje, do kolika úrovní může být signál kvantován. Například 4 bitový převodník má rozsah čísel 0- 15, tudíž hodnota výchyly může být vyjádřena číslem od -7 do +8 [8].



Obrázek 2.6: Kvantovaný signál

2.3.2 Analýza

Pro analýzu signálu využíváme spektrální analýzy signálu, neboť v signálu posuzujeme frekvenční složky, které jsou v něm obsaženy. Frekvenční analýzu můžeme rozdělit na dvě kategorie:

- Neparametrické metody
- Parametrické metody

Neparametrické metody mohou zpracovávat jakýkoli signál, na signál nejsou kladeny žádné speciální požadavky. Signál je tedy zpracováván přímo. Mezi tyto metody patří například spektrální analýza a korelační analýza [8].

Při použití **parametrických** metod musíme stanovit řadu parametrů, aby signál vyhovoval matematickému modelu zpracování. Odhadujeme tedy tyto parametry ze zaznamenaných dat a provádíme jejich analýzu. Mezi modely dat můžeme zařadit například autoregresivní model, model klouzavých průměrů a jejich kombinaci: autoregresivní model klouzavých průměrů [8].

2.3.3 Klasifikace


Klasifikací rozumíme segmentaci EEG signálu, ten můžeme rozdělit například na jednotlivé vlny, komplexy vln, či detekci spánkových fází, epileptických aktivit apod. Následuje shluková analýza, například využitá pro detekci grafoelementů a jejich klasifikaci. Dále prezentace výsledků (identifikace grafoelementů, vymezení významných částí EEG, sumární informace statistika apod.).

3 Segmentace signálu

Při zpracování EEG signálu je často nutné rozdělit signál na jednotlivé segmenty s podobnými charakteristikami, které jsou hodnotné pro lékaře a pro posouzení neurofyziology. V každém segmentu se předpokládá statistická stálost, obvykle s podobnými časovými a frekvenčními statistikami. Například EEG signál nasnímaný u pacienta s epilepsií můžeme rozdělit do 3 segmentů [11]:

- Preiktální
- Iktální
- Postiktální

Každý segment má jiné trvání. Na (Obrázek 3.1) je EEG signál se všemi třemi výše zmíněnými segmenty. Tyto části můžeme segmentovat pomocí tzv. adaptivní segmentace, viz kapitola 3.2.



Obrázek 3.1: EEG signál obsahující preiktální, iktální a postiktální segmenty

Známe dva typy segmentace:

- Konstantní segmentace, stejná délka segmentu
- Adaptivní segmentace, proměnná délka segmentu

3.1 Konstantní Segmentace

Nejjednodušší způsob segmentace, signál je rozdělen na stejně velké segmenty, které jsou nezávislé na charakteru signálu. Získáme tedy pouze části signálů obsahující různé prvky, které si nejsou podobné. Výhodou je hlavně jednoduchost provedení.

3.2 Adaptivní segmentace

Užitečnější metodou je adaptivní segmentace, ta zohledňuje, že EEG signál je nestacionární. Stacionarita signálu znamená, že jeho statistické charakteristiky se časově nemění, neboli střední hodnota a směrodatná odchylka jsou v čase stejné. To však neplatí pro signál EEG, u něj dochází v průběhu času ke změnám jeho amplitudových a frekvenčních vlastností. Dokonce se v něm vyskytují tzv. *hybridní segmenty*, které obsahují například směs vln různých tvarů a frekvencí. Signál je tedy *kvazistacionární* (stacionární po částech). Metody segmentace obecně vyžadují detekci nestacionarit (změn stacionarit) a odhad přesného časového okamžiku změny [7].

Adaptivní segmentace tedy signál segmentuje na stacionární úseky proměnné délky, které mohou dále zjednodušit klasifikaci signálu [7].

Pro adaptivní segmentaci můžeme použít více metod, já si však pro svoji práci vybral několik z nich, kterým budu věnovat následující kapitoly.

3.2.1 Adaptivní segmentace pomocí lineární predikce

Metoda lineární predikce vychází z autoregresivního (AR) modelu signálu [8]. Určení parametrů AR modelu je lineární úloha, AR model si můžeme popsat rovnicí:

$$x(n) + a_1x(n-1) + a_2x(n-2) + \dots + a_px(n-p) = e(n). \quad (3.1)$$

Pro konstrukci AR modelu využijeme IIR filtr pouze s póly, kde p představuje počet minulých hodnot výstupu přivedených na vstup. Vycházíme z předpokladu, že signál vznikl průchodem bílého šumu přes lineární časově neměnný filtr. Musíme si určit koeficienty tohoto filtru, a to ze vzorků signálu. Získáme je tak, že kvadrát amplitudové frekvenční charakteristiky filtru aproximujeme skutečnou spektrální hustotou signálu. Tyto parametry tedy získáme metodou nejmenších čtverců, pro potlačení chyby predikce.

Poté, když signál přivedeme na inverzní filtr k tomu, jehož koeficienty jsme určili, bude za předpokladu, že je tato část stacionární, na výstupu filtru bílý šum a jeho autokorelace bude nulová [8].


Samotná lineární predikce vychází z diferenční rovnice AR modelu:

$$x_n = - \sum_{k=1}^p a_k x_{k-n} + e_n, \quad (3.2)$$

kde a_0 až a_p představují Wienerův filtr, který transformuje vstupní posloupnost do posloupnosti náhodných veličin. e_n je chyba predikce, které se dopouštíme při odhadu hodnoty x_n z lineární kombinace minulých vzorků.

Princip segmentace EEG signálu pomocí lineární predikce je (Obrázek 3.2):

1. Na začátek signálu je umístěno referenční okno, které zůstává v jednom místě signálu. Délka okna se volí nejčastěji 1s.
2. Navrhne lineárně prediktivní (LP) Wienerův filtr, jehož koeficienty určíme metodou nejmenších čtverců, při návrhu použijeme signál z referenčního okna.
3. Signál přivedeme na vstup inverzního filtru, k tomu, který jsme určili v minulém kroku.
4. Sledujeme výstup tohoto filtru. Je-li signál stacionární, bude autokorelační funkce nulová a spektrum chyby predikce bude totožná se spektrem bílého šumu.
5. Vyhodnocujeme míru difference mezi spektry referenčního a zkoumaného vzorku signálu pomocí autokorelační funkce chyby predikce.
6. Jestliže difference překročí určitou mez, posune se referenční okno doprostřed testovacího okna a LP filtr se znovu adaptuje na nový referenční signál a proces pokračuje od začátku.



Obrázek 3.2: Princip segmentace EEG signálu pomocí lineární predikce

Při použití lineární predikce je nutné správné stanovení řádu modelu p , protože pokud je řád nízký, je spektrální výkonová hustota příliš vyhlazena. Při vysokém řádu se ve spektru mohou vyskytnout chybné vrcholy výkonové hustoty, ovšem s nižší amplitudou [3].

Pro určení optimálního řádu AR modelu bylo stanoveno několik kritérií, která se zakládají na potlačení chyby predikce. Tyto kritéria se počítají po každém kroku predikce [7].

3.2.2 Adaptivní segmentace pomocí autokorelační funkce

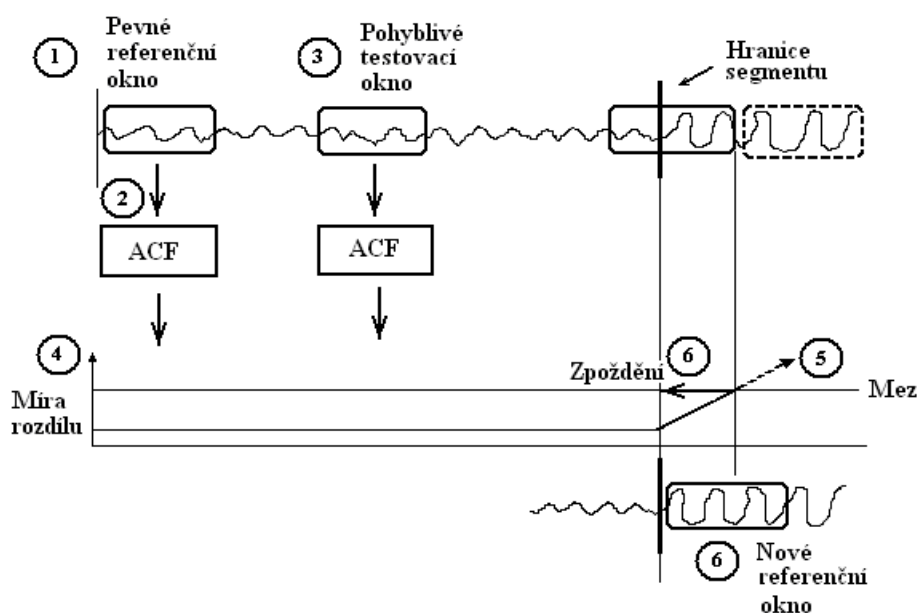
Adaptivní segmentace pomocí autokorelační funkce je metoda velmi podobná metodě lineární predikce. Avšak se zde počítá přímo autokorelace signálů ve dvou oknech a nepoužívá se LP filtr s výpočtem chyby predikce. Určuje se tedy míra difference [6]:

$$DIF = \frac{\sum_{n=0}^{N-1} (r_{ref}(n) - r_{test}(n))^2}{r_{ref}(0)r_{test}(0)}, \quad (3.3)$$

N je počet koeficientů autokorelační funkce, r_{ref} je autokorelační funkce referenčního okna a r_{test} je autokorelační funkce testovacího okna.


Princip segmentace EEG signálu pomocí autokorelační funkce je (Obrázek 3.3):

1. Na začátek segmentu umístíme referenční okno, provedeme odhad autokorelace r_{ref} .
2. Po signálu postupuje testovací okno a v každém místě je průběžně odhadována autokorelace r_{test} .
3. Určíme míru difference, neboli odchylku od stacionarity, podle vztahu (3.3).
4. Pokud DIF překročí určitou mez, ukončí se stacionární segment.
5. Určení nového segmentu a skok na první krok.



Obrázek 3.3: Princip segmentace EEG signálu pomocí autokorelační funkce

Na (Obrázek 3.4) [6] můžeme vidět EEG signál, který následně projde výše zmíněným postupem. Výsledné píky představují velikost míry difference mezi okny.



Obrázek 3.4: Ukázka použití míry difference. a – EEG signál, b – vypočtená míra difference signálu

Tyto první 2 metody mají nevýhodu v tom, že nejsou vhodné pro nezávislou segmentaci vícekanálového záznamu současně, což je nepoužitelné pro vícekanálovou segmentaci v reálném čase. Důvodem je ztráta synchronizace pohybu oken ve více kanálech při umístění referenčního okna na nový začátek, kde v jednom kanálu se umístí nové okno a ve druhém může ještě určitý časový úsek zůstat na stejném místě. Řešení nabízí například použití dvou spojených oken, které se po signálu pohybují současně.

3.2.3 Adaptivní segmentace pomocí míry difference odhadnuté z FFT

Pokud analyzujeme signál, jehož charakter se v čase rychle mění, musíme při analýze uvažovat o frekvenčním obsahu krátkých signálových úseků, musíme tedy použít koncept tzv. krátkodobých spekter [3]. Pro tuto segmentaci využíváme rychlou Furierovu transformaci (FFT). Tu však nelze použít na celý záznam signálu, proto ji využijeme pouze v určitých časových úsecích (v oknech).

Nejprve si definujeme diskrétní Furierovu transformaci (DFT), ze které vychází algoritmy výpočtu FFT:

$$X(k) = \sum_{n=0}^{N-1} x(n) \cdot e^{-\frac{j2\pi kn}{N}}. \quad (3.4)$$

DFT transformuje signál z časové do frekvenční oblasti. Do tohoto výpočtu přivedeme diskrétní navzorkovaný signál (viz kapitola 2.3.1), po průchodu signálu DFT je výstupem diskrétní spektrum, ovšem informace o frekvenčních složkách v něm nejsou zahrnuty [12].

Po aplikaci FFT získáme spektra signálů v námi určených oknech a jako míru difference určujeme rozdíl těchto spektrálních obsahů oken, který je ovšem počítán pro každý posun oken z FFT:

$$DIF = \max_{\omega} \left\{ \frac{1}{2} \left[\frac{X_t(\omega)}{Y_t(\omega)} + \frac{Y_t(\omega)}{X_t(\omega)} \right] - 1 \right\}, \quad (3.5)$$

X_t a Y_t jsou spektrální obsahy dvou spojených oken.

Princip segmentace EEG signálu pomocí míry difference odhadnuté z FFT:

1. Po signálu kloužou dvě spojená okna.
2. Z rozdílu charakteru obou signálů v obou oknech se pomocí FFT určí míra difference (neboli odchylka od stacionarity).
3. Hranice segmenů jsou umístěny do míst lokálních maxim diferencí.

Nevýhoda metody je, že je náročná na počet jednotlivých výpočtů FFT, kde musíme počítat FFT pro každý posun oken. Dále není příliš přesná, protože vykazuje falešná maxima diferencí v sousedství skutečných hranic segmentů. Odhad spektra je také dále nutné vyhlazovat.

3.2.4 Adaptivní segmentace pomocí míry difference střední amplitudy a frekvence

Pojem amplituda signálu se používá v souvislosti s periodickými signály. V případě EEG signálu je vhodné mluvit o okamžité výchylce. Reálně touto metodou počítáme střední výchylku signálu, ale pro konzistenci s názvem metody použijeme termín amplituda.

Poslední metoda je obdobná předchozím segmentačním metodám, s tím rozdílem, že je založena na určování míry difference pomocí střední amplitudy a střední frekvence [7].


Stanovuje tedy míru difference ve dvou spojených oknech, pomocí triviálních odhadů amplitudové a frekvenční difference, vycházejících z odhadu střední amplitudy A_W a střední frekvence F_W v oknech $W1$ a $W2$:

$$A_W = \sum_{i=1}^{WL} |x_i|, \quad (3.6)$$

$$F_W = \sum_{i=1}^{WL} |x_i - x_{i-1}|. \quad (3.7)$$

Průměrná difference vzorků signálu je přímo úměrná střední frekvenci signálu v daném okně. Míra difference je kombinací obou částí, vynásobené váhami, které byly získány experimentálně (udává se, že váha frekvenční difference je sedmkrát větší než váha amplitudového odhadu).

Na hranicích segmentů dostaneme lokální maximum, které pokud překročí zadanou mez, označí reálnou hranici zkoumaného segmentu (Obrázek 3.5).



Obrázek 3.5: Segmentace pomocí míry difference střední amplitudy a frekvence.

Díky nenáročnosti výpočtů je tato metoda vhodná k online zpracování EEG signálu, a to i ve více kanálech. Z principu postupuje segmentace v každém kanálu nezávisle.

3.2.5 Další metody adaptivních segmentací

Pokud se věnujeme metodám adaptivní segmentace, hodilo by se zmínit také jiné metody, které jsou založené na detekcích nestacionarit určených z míry diferencí mezi referenčním a testovacím oknem.

První metodou může být například adaptivní segmentace s narůstajícím a pevným oknem. Vychází z metody, která využívá autokorelační funkce, je však výpočetně náročnější. Zakládá se na rostoucím referenčním okně, které uchovává během růstu čím dál více informací o signálu. Velikost testovacího okna se nemění.

Referenční okno roste, dokud není detekována nestacionarita. Poté se znovu adaptuje na nový začátek signálu. Změna stacionarity je tedy určena z odhadu predikční chyby tří oken: rostoucího, pevného testovacího a složeného z obou oken [7].

Další metodou je adaptivní segmentace EEG s CUSUM. Technika CUSUM je kumulovaný součet, díky čemuž je možné použít statistický test z něj vycházející. Kumulace se opět uskutečňuje pomocí rostoucího referenčního a klouzajícího testovacího okna. Pro určení parametrů se užívá AR model.

4 Programová realizace

Pro programovou realizaci v prostředí MATLAB jsem si vybral 3 metody segmentace signálu EEG:

- Adaptivní segmentace pomocí míry difference střední amplitudy a frekvence
- Adaptivní segmentace pomocí míry difference odhadnuté z FFT
- Adaptivní segmentace pomocí autokorelační funkce

Tyto metody budou následně srovnány z hlediska účinnosti detekce a náročnosti výpočtu na referenčním signálu a následně na signálu z databáze www.physionet.org.

Tento výběr jsem učinil z důvodu různorodosti metod a dobré dostupnosti v literatuře, viz [6] [7]. První dvě metody se zakládají na výpočtu difference ve dvou spojených oknech. U první metody dochází k výpočtu difference na základě amplitudy (výchylky) a frekvence obsažené v obou oknech. U druhé metody je difference vypočtena na základě spektrálních vlastností signálu.

Třetí metoda je odlišná tím, že odhad difference je realizován v jednom statickém (referenčním) okně a v jednom klouzavém (testovacím) okně. Míra difference se zakládá na výpočtu autokorelace a vzájemném porovnání obsahu obou oken.

4.1 Referenční signál


Jako vstupní signál pro automatickou segmentaci EEG byl použit signál změřený v laboratořích, na Ústavu biomedicínského inženýrství VUT v Brně, pomocí přístroje *TruScan 32™* od výrobce *Alien Technik*. Při měření subjekt vykonával určité úkony, které by se měly projevit změnou charakteru signálu EEG, kterou mohu následně použít pro konečnou segmentaci signálu. Pro čtení ze souboru jsem použil skript *read_alien.m*.

4.1.1 Měření

Při měření subjekt vykonával následné úkony (časy jsou přibližné):

- 30s otevřené oči
- 30s zavřené oči
- 30s otevřené oči
- 30s počítání
- 15s zavřené oči
- Pauza
- 30s zavřené oči
- 30s vymýšlení slov
- 30s otevřené oči

Výsledný signál s vyznačenými reálnými segmenty je vyobrazen na (Obrázek 4.1).



Obrázek 4.1: Reálné segmenty


4.1.2 Předzpracování signálu

Jelikož se v signálu vyskytovalo velmi výrazné rušení (Obrázek 4.2) jak síťovým kmitočtem (brum), tak kolísáním nulové linie (drift), bylo nutné signál nejprve filtrovat. Pro filtraci je použit skript *filter_eeg.m*, ve kterém jsou použity dva FIR filtry za sebou. Jeden propouští v signálu pouze nižší frekvence než je stanovená mez - filtr typu dolní propust' a druhý propouští pouze vyšší frekvence – filtr typu horní propust'.

Tyto dva filtry můžeme považovat za pásmovou propust' s nastavenými parametry:

- Dolní mez: 0,5Hz
- Horní mez: 45Hz
- Řád filtru: 300

Výsledek filtrace je patrný z (Obrázek 4.2):



Obrázek 4.2: Signál před a po filtraci

4.2 Vypracování adaptivní segmentace pomocí míry difference střední amplitudy a frekvence

Tato metoda vychází z odhadu difference ze střední amplitudy a frekvence. K výpočtu dochází ve dvou spojených oknech, procházejících po signálu. Metoda je teoreticky vysvětlena v kapitole 3.2.4.

Výpočet je realizován skriptem *eeg_seg_af.m*, jehož algoritmus funguje tímto způsobem:

1. Načtení signálu pomocí *read_alien.m*
2. Filtrace signálu skriptem *filter_eeg.m*
3. Načtení proměnných
4. Výpočet střední amplitudy a frekvence ve dvou spojených oknech, klouzajících po signálu pomocí cyklu *for*, podle rovnic (3.6), (3.7) a následný výpočet difference:

$$difference = |A1 - A2| + 7 * |F1 - F2| \quad (4.1)$$

kde rozdíl frekvencí má sedmkrát větší váhu, než rozdíl amplitud. $A1$, $A2$ jsou střední amplitudy a $F1$, $F2$ jsou střední frekvence v oknech 1 a 2 [7].

5. Aplikace prahu a určení lokálních maxim
6. Vykreslení:
 - a. Původní signál s reálnými komplexy
 - b. Difference s aplikovaným prahem
 - c. Původní signál s původními a detekovanými segmenty

4.3 Vypracování adaptivní segmentace pomocí míry difference odhadnuté z FFT

Adaptivní segmentace pomocí míry difference odhadnuté z FFT je obdobná metoda, kdy jsou využity opět 2 spojená okna, klouzající po signálu společně. Teoretický rozbor metody se nachází v kapitole 3.2.3.

Segmentaci touto metodou vykonává skript *eeg_seg_fft.m*:

1. Načtení signálu pomocí *read_alien.m*
2. Filtrace signálu skriptem *filter_eeg.m*
3. Načtení proměnných
4. Výpočet rychlé Fourierovy transformace v oknech 1 a 2, které pomocí *for* cyklu kloužou po signálu a následný výpočet difference dle vztahu (3.5)
5. Aplikace prahu a určení lokálních maxim
6. Vykreslení:
 - a. Původní signál s reálnými komplexy
 - b. Difference s aplikovaným prahem
 - c. Původní signál s původními a detekovanými segmenty

4.4 Vypracování adaptivní segmentace pomocí autokorelační funkce

Adaptivní segmentace pomocí autokorelační funkce je metoda odlišná od předchozích v tom, že po signálu klouže pouze jedno testovací okno a druhé referenční je statické. Referenční okno se posune pouze v případě překročení prahu u hodnoty difference. Více v kapitole 3.2.2.

Segmentaci touto metodou vykonává skript *eeg_seg_kor.m*:

1. Načtení signálu pomocí *read_alien.m*
2. Filtrace signálu skriptem *filter_eeg.m*
3. Načtení proměnných
4. V cyklu *while* dochází k výpočtu autokorelací obou oken, referenční okno je umístěno na začátek signálu, testovací okno klouže po signálu a probíhá výpočet difference dle vzorce (3.3), který bylo nutné upravit na následující tvar:

$$DIF = \sum_{n=0}^{N-1} (r_{ref}(n) - r_{test}(n))^2 \quad (4.2)$$

5. Průběžně je aplikována mez. Při jejím překročení se referenční okno posune na začátek nového segmentu a výpočet difference pokračuje.
6. Aplikace prahu a určení lokálních maxim
7. Vykreslení:
 - d. Původní signál s reálnými komplexy
 - e. Difference s aplikovaným prahem

f. Původní signál s původními a detekovanými segmenty

Modifikace vzorce (3.3) byla nutná kvůli zlepšení výsledků detekce, kdy vzorec s dělitelem (použitým pro normalizaci výsledků) vykazoval o několik tříd horší výsledky detekce. Toto bylo způsobeno prvními hodnotami autokorelace oken $r_{\text{ref}}(0)$ a $r_{\text{test}}(0)$, které v mém případě neměly hlubší souvislost s analyzovaným signálem a v důsledku toho skript nefungoval jak měl.

4.5 Nastavení parametrů segmentace

Pro správnou detekci hranic segmentu je velice důležité nastavení parametrů. Těmito parametry jsou délka okna a práh detekce. Stanovení parametrů záleží na konkrétním signálu, konkrétním kanálu v signálu a také na metodě segmentace. Např. u stejné metody může difference dosahovat v různých kanálech diametrálně odlišných hodnot. Proto nemusí jednou zadaný práh vyhovovat v jiném kanálu, natož potom v jiném signálu.

4.5.1 Nastavení délky okna

Nastavení délky okna má vliv na časové a frekvenční rozlišení detekce, je tedy nutné brát v úvahu charakter signálu. Obecně platí, že s délkou okna roste frekvenční rozlišení, ale časové rozlišení klesá a naopak.

To znamená, že pro signál, ve kterém dochází k pomalým změnám, či změnám s dlouhým časovým odstupem, je vhodné použít delší okno – citlivější detekce. Naopak u dynamických signálů s mnoha časovými změnami krátce po sobě, musíme použít kratší okno za cenu horší detekce.

Dále také délka okna ovlivňuje náročnost výpočtu a tedy i čas, který je nutný pro výpočet segmentace. Více v kapitole 5.5.

I když jsou mnou zvolené metody velmi odlišné, dá se pro relativně dobrou detekci na referenčním signálu zvolit délka okna například na 128 vzorků, což odpovídá hodnotě vzorkovací frekvence a tedy i 1s signálu.

U referenčního signálu, u něhož víme, že změny by se měly odehrávat po každých 30 sekundách, můžeme teoreticky okno několikanásobně zvýšit. V tomto případě se ale velmi zvyšuje náročnost výpočtu a i detekce dosahuje horších výsledků. Toto může být zapříčiněno například artefakty v signálu (mrkání, pohybové artefakty apod. – kapitola 2.2.5).

4.5.2 Nastavení prahu detekce

Nastavení prahu detekce výrazně ovlivňuje detekční účinnost jednotlivých metod. Při vysokém prahu nemusí skript detekovat všechny žádoucí píky difference a při příliš nízkém prahu detekuje i falešné špičky a zapíše nepravdivé konce segmentů.

U prvních dvou metod, které pracují se dvěma spojenými okny je práh nastaven jako:

$$\text{práh} = x * \max(\text{difference}), \quad (4.3)$$

kde

$$x \in (0; 1 >. \quad (4.4)$$

Tuto variantu můžeme použít, protože ve skriptu nejdříve vypočítáme celou diferenci v cyklu *for* a potom aplikujeme práh. U metody *odhadu difference pomocí autokorelační funkce* musíme aplikovat práh přímo v cyklu *while*, kdy je vypočítávána difference. Kvůli tomu musíme určit práh předem, před výpočtem difference.

U metody *segmentace pomocí míry difference střední amplitudy a frekvence* je práh nastaven na $x=0,2$. U metody segmentace pomocí míry difference odhadnuté z FFT je práh nastaven na $x=0,1$. A u metody segmentace pomocí autokorelační funkce je práh nastaven na $8 \cdot 10^{13}$.

Platí ale, že maximální hodnota difference je závislá na charakteru signálu a může se měnit i se změnou kanálu. Proto je žádoucí případně změnit práh dle potřeby.


5 Srovnání výsledků detekce

V této kapitole budou srovnány detekční schopnosti jednotlivých metod adaptivní segmentace na referenčním signálu a na signálu získaného z databáze www.physionet.org.

Následně bude srovnána náročnost výpočtu jednotlivých metod pomocí MATLAB funkce *Run and Time*.

5.1 Výsledky detekce *eeg_seg_af.m*

Výsledky segmentace pomocí míry difference střední amplitudy a frekvence jsou na (Obrázek 5.1).



Obrázek 5.1: Výsledky segmentace *eeg_seg_af.m*

Nastavení parametrů:

- Kanál 11 (Elektroda C4)
- Délka okna = 128
- Práh detekce = $0,2 * \text{maximum difference}$

V prvním okně je původní filtrovaný signál s vyznačenými reálnými segmenty (červeně). Ve druhém okně je míra difference vypočtená dle vzorců (3.6), (3.7) a (4.1). Na míru difference je aplikován práh (černě). Ve třetím okně je vykreslen původní filtrovaný signál s reálnými segmenty (červeně) a s detekovanými segmenty (černě).

Z uvedeného obrázku je patrné, že došlo k úspěšné detekci ve čtyřech segmentech. Jeden segment byl detekován chybně. Čtyři segmenty nebyly detekovány vůbec (2 segmenty kolem 160 sekund nejsou reálnými segmenty, pouze pauzami v měření).

Při změně velikosti okna na 50 vzorků a snížení prahu na 0,15 dosáhneme lepšího výsledku s detekcí pěti segmentů. Avšak u těchto parametrů se zhoršuje detekce v jiných kanálech (falešná detekce, či snížení míry difference v okolí reálného segmentu).

5.2 Výsledky detekce *eeg_seg_fft.m*

Výsledky segmentace pomocí míry difference odhadnuté z FFT jsou na (Obrázek 5.2).


Nastavení parametrů:

- Kanál 11 (Elektroda C4)
- Délka okna = 128
- Práh detekce = $0,1 * \text{maximum difference}$

Průběh zobrazení je totožný s předchozí metodou v kapitole 5.1. Pro výpočet míry difference je použit vztah (3.5).

V tomto případě byla segmentace úspěšná ve čtyřech segmentech, avšak vykazuje více falešných hranic segmentů. U první detekované hranice segmentu je poloha přibližně o 4 sekund (500 vzorků) zpožděna za reálným segmentem. V tomto případě nemusí být chyba na straně metody, aktivita *alfa* se mohla projevit až po určitém čase po zavření očí.

Při změně kanálu je nutná úprava parametrů, skript najde v tomto případě větší počet falešných segmentů, nebo detekce úplně selhává. Při zkrácení okna se zvýší počet falešně rozpoznaných segmentů bez zvýšení segmentů detekovaných správně. Při zvětšení okna se snižuje detekce celkově.



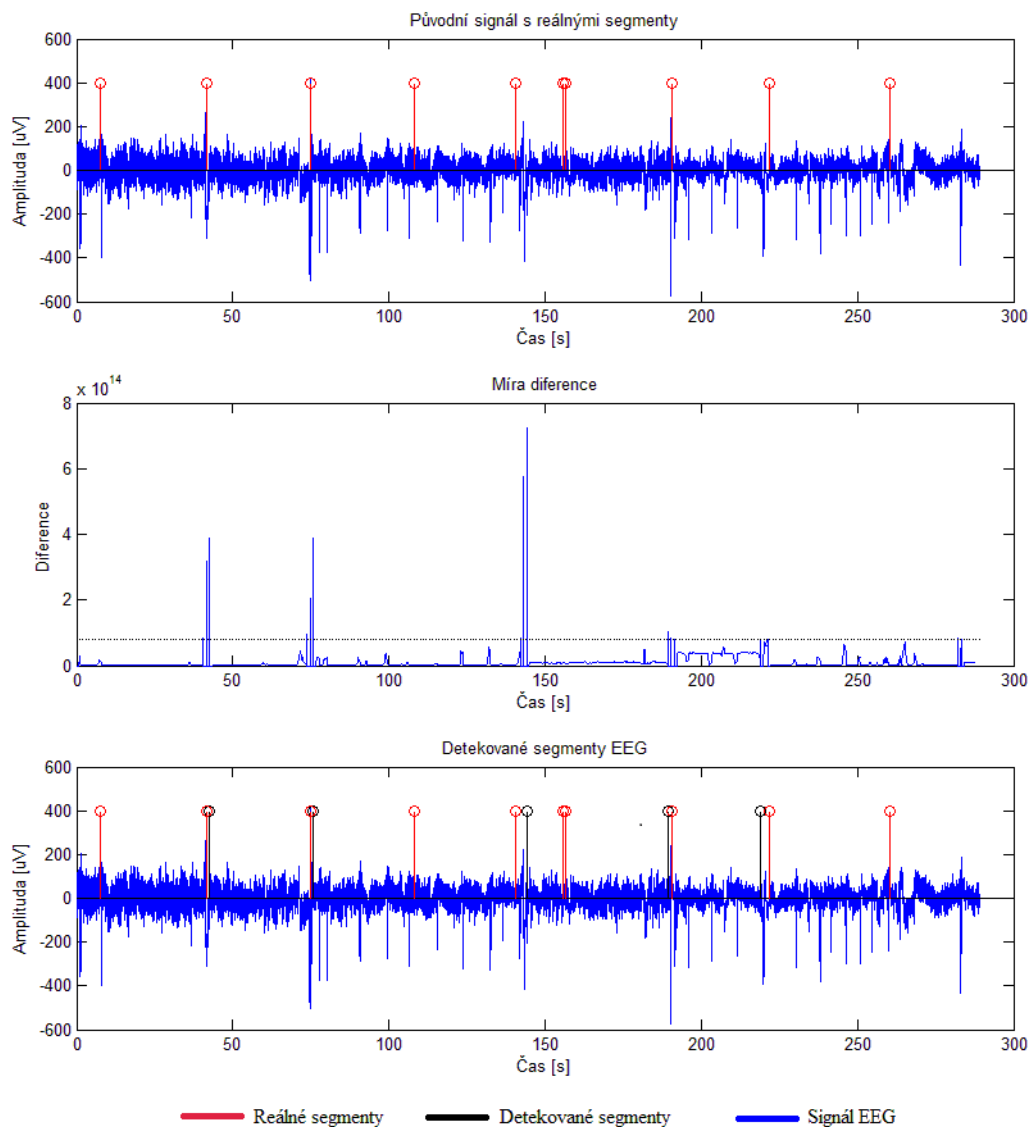
Obrázek 5.2: Výsledky segmentace *eeg_seg_fft.m*

5.3 Výsledky detekce *eeg_seg_kor.m*

Výsledky segmentace pomocí autokorelační funkce jsou na (Obrázek 5.3).

Nastavení parametrů:

- Kanál 11 (Elektroda C4)
- Délka okna = 128
- Práh detekce = $8 \cdot 10^{13}$



Obrázek 5.3: Výsledky segmentace eeg_seg_kor.m

Z hlediska úspěšnosti detekce vykazuje tato metoda obdobné výsledky, jako metody předchozí. Bylo detekováno celkem pět reálných segmentů bez falešných hranic segmentů. Tři segmenty detekovány nebyly. V okolí času 140s (18000 vzorků) je segment posunut, opět můžeme hovořit o zpoždění nástupu aktivity *alfa*.


Při nepatrném zvětšení či zmenšení okna se detekce příliš nemění, v případě zmenšení je detekováno o jeden segment méně. U zvětšení je detekován o jeden správný segment více, avšak dochází k posunu značek detekce vůči reálným hranicím segmentů.

Při změně analyzovaného kanálu je nutné přenastavit velikost prahu, protože dochází k velkým změnám ve velikosti difference a to v jednotkách řádů. Toto je velká nevýhoda

metody, je nutné nejprve nechat metodu signál analyzovat a poté nastavit práh segmentace podle velikosti difference.

5.4 Vzájemné porovnání


Vzájemné porovnání metod segmentace v kanálu 11 je na (Obrázek 5.4). Metody dosahují podobných výsledků. Správně byly detekovány čtyři segmenty v prvních dvou případech, ve třetím případě bylo detekováno segmentů pět.



Obrázek 5.4: Porovnání jednotlivých metod, kanál 11. Shora - a) Střední amplituda a frekvence b) FFT c) Autokorelační funkce

V kanálu 17 (Obrázek 5.5) první metoda detekovala šest hranic segmentů, některé jsou však posunuty oproti reálným polohám. Druhá metoda správně označila pět hranic segmentů, některé posunuté a navíc detekovala větší množství falešných hranic segmentů. Poslední metoda správně označila pouze 4 správné segmenty.


Při změně kanálu bylo nutné upravit práh detekce u všech tří metod. Velikost okna zůstala na 128. Průběhy diferencí v kanálu 17 jsou přiloženy v (Obrázková příloha).



Obrázek 5.5: : Porovnání jednotlivých metod, kanál 17. Shora - a) Střední amplituda a frekvence b) FFT c) Autokorelační funkce

Při použití jiného než referenčního signálu můžeme pozorovat, jaké segmenty metody detekují i bez znalosti poloh reálných segmentů signálu. Ve všech případech dochází k velkým odlišnostem v detekcích. Pouze několik málo hranic segmentů je detekováno ve více případech (Obrázek 5.6). Jednotlivé průběhy diferencí jsou přiloženy v (Obrázková příloha).

Potvrzuje se tedy fakt, že účinnost metody nesouvisí pouze s nastavenými parametry, ale se samotným charakterem analyzovaného signálu.



Obrázek 5.6: Porovnání jednotlivých metod na alternativním signálu. Shora - a) Střední amplituda a frekvence b) FFT c) Autokorelační funkce

5.5 Srovnání náročnosti výpočtu

Srovnání náročnosti výpočtu původně není součástí zadání bakalářské práce, ale bezpochyby jde o velice důležitý parametr jednotlivých metod například při využití těchto metod v klinické praxi.


Menší náročnost výpočtu je žádoucí především při zpracování signálu v reálném čase, dále při zpracování dlouhých úseků dat, zpracování signálů na serveru apod.

Pro zjištění náročnosti výpočtu metod segmentace byla použita funkce Run and Time v programu MATLAB. Skripty byly testovány na počítači se čtyřjádrovým procesorem, taktovaným na 3,2GHz a pevným diskem s rychlostí 7200 otáček/min. Při výpočtech byla operační paměť s taktom 1333MHz využita pouze z části, MATLAB si při použití signálu dlouhého 100 000 vzorků se vzorkovací frekvencí 256Hz zabral zhruba 400 MB.

Naměřené hodnoty (Tabulka 5.1) a graf závislosti délky výpočtu (Obrázek 5.7) ukazují, že metodou, která je nejméně náročná na výpočet je, *Adaptivní segmentace pomocí míry difference odhadnuté z FFT*. Naopak *Adaptivní segmentace pomocí autokorelační funkce* je výpočetně nejvíce náročná.

Tabulka 5.1: Závislost délky výpočtu na počtu vzorků signálu EEG

Počet vzorků	Čas výpočtu [s]		
	eeg_seg_af.m	eeg_seg_fft.m	eeg_seg_kor.m
10 000	5,395	2,785	6,740
20 000	8,503	3,951	11,181
30 000	12,260	5,203	16,616
40 000	15,603	6,467	22,219
50 000	19,189	7,746	27,162
60 000	23,230	8,997	32,626
70 000	26,682	10,247	38,393
80 000	30,564	11,531	43,688
90 000	34,126	12,768	48,878
100 000	38,301	14,124	54,540



Obrázek 5.7: Závislost délky výpočtu na počtu vzorků signálu EEG

Při výpočtu *Adaptivní segmentace pomocí autokorelační funkce* je potřeba nejvíce času pro výpočty jednotlivých autokorelací funkcí *xcorr*, které je nutné provést při každém posunu okna. Samotný výpočet skriptu (výpočet difference, aplikace prahu a vykreslení) zabere přibližně pětinu času.

Adaptivní segmentace pomocí míry difference střední amplitudy a frekvence se ukázala jako středně výpočetně náročná metoda a nejvíce času zabere vypočítat skript jako takový.

Toto je způsobeno nutností výpočtu střední amplitudy a frekvence v obou oknech po každém posunu okna o jeden vzorek.

Adaptivní segmentace pomocí míry difference odhadnuté z FFT je poněkud překvapivě nejméně náročná metoda a to i přes výpočet Rychlé Fourierovy transformace v obou oknech po každém posunu okna o jeden vzorek. V tomto případě opět zabere nejvíce času výpočet samotného skriptu.

Z hlediska využití při *online* zpracování není z metod vhodná ani jedna. U zpracování EEG v reálném čase musíme segmentovat všech 19 kanálů EEG současně a tedy vynásobit změřený čas segmentací počtem kanálů. Výsledky segmentování pouze jednoho kanálu nemusí platit pro kanály ostatní, kdy některé typy aktivity se mohou projevat pouze v určitých místech lebky.

V případě segmentace v reálném čase všechny tři metody nevyhovují a u nejméně náročné metody *Adaptivní segmentace pomocí míry difference odhadnuté z FFT* při použití 10 000 vzorků v 19 kanálech dochází ke zpoždění okolo 14 sekund.

Limitujícím faktorem *online* segmentace je také použitý hardware. Rychlost výpočtu ovlivňuje takt procesoru, který udává počet zpracovaných instrukcí za sekundu. Množství otáček za sekundu u pevného disku ovlivňuje čtecí a zapisovací rychlost disku a tudíž i rychlost načítání dat. Velikost operační paměti určuje počet vzorků signálu, který můžeme zpracovávat bez zpomalení výpočtu.

6 Závěr

Z uvedených grafů můžeme říci, že výsledky metod adaptivní segmentace jsou velmi odlišné a záleží nejen na nastavených parametrech, ale také na charakteru zpracovávaného signálu.

Na referenčním signálu vykazovala nejlepší výsledky detekce metoda *Adaptivní segmentace pomocí míry difference střední amplitudy a frekvence*, která správně označila většinu reálných segmentů. Metoda *Adaptivní segmentace pomocí míry difference odhadnuté z FFT* dosáhla podobných výsledků, ale označila i větší množství segmentů falešných. *Adaptivní segmentace pomocí autokorelační funkce* se potýká s problémem nastavení správného prahu segmentace, její detekční účinnost je také o něco horší ve srovnání s ostatními metodami.

Obecně úspěšnost detekce ve velké míře závisí na nastavených parametrech jednotlivých metod. Nastavení parametrů je otázkou kompromisů, kde při nastavení okna volíme mezi časovým a frekvenčním rozlišením. Při nastavení prahu je nutné rozlišit, zda jsou vrcholy v průběhu difference reálnými, či pouze falešně indikovanými hranicemi segmentů.

Realizace do klinické praxe je u těchto metod možná u *offline* zpracování, je ale zapotřebí počítat s nevýhodami těchto metod, jako jsou nedetekované, či falešně detekované segmenty a nutnost přenastavení prahu při změně kanálu. U *online* zpracování nejsou metody použitelné kvůli náročnosti výpočtu, kde by při vícekanálovém zpracování docházelo ke zpožděním. Metoda *Adaptivní segmentace pomocí autokorelační funkce* nemůže být použita k *online* bez ohledu na čas zpracování a to díky ztrátě synchronizace pohybu oken.

Zlepšení může být realizováno například v podobě adaptabilního prahu (platí především pro metodu *Adaptivní segmentace pomocí autokorelační funkce*), detekce falešně označených segmentů, nebo použitím jiných metod segmentace.

Seznam použité literatury

[1] CEPEK, Jan. Brain computer interface[online]. Bionics semestral work. České Vysoké učení Technické. Praha: 2004. Dostupné na

<http://gerstner.felk.cvut.cz/biolab/bionika2004/cepek/bci.html>

[2] HRAZDIRA, Ivo; MORNSTEIN, Vojtěch. Lékařská biofyzika a přístrojová technika. 1. vydání. Brno: Neptun, 2001. ISBN 80-902896-1-4.

[3] JAN, Jiří. Číslicová filtrace, analýza a restaurace signálů. VUT Brno, 1997, (ISBN 80-214-0816-2)

[4] KOLÁŘ, Radim. Elektroencefalografie. [online] Přednáška z předmětu Lékařská diagnostická technika. Vysoké Učení Technické. Brno: 2012. Dostupné na https://www.vutbr.cz/elearning/file.php/123624/Prednasky/ALDT_T6_EEG.pdf

[5] KOZUMPLÍK, Jiří. AABS_09_EEG1: přednáška z předmětu Analýza biologických signálů.

[6] KOZUMPLÍK, Jiří. AABS_09_EEG2: přednáška z předmětu Analýza biologických signálů.

[7] KRAJČA, Vladimír; MOHYLOVÁ, Jitka. Číslicové zpracování neurofyzilogických signálů: ČVUT, 2011. 168 s. ISBN 978-80-01-04721-7.

[8] MOHYLOVÁ, Jitka; KRAJČA, Vladimír, ZPRACOVÁNÍ BIOLOGICKÝCH SIGNÁLŮ, učební text, Vysoká škola báňská – Technická univerzita Ostrava, Ostrava: 2007

[9] POKORNÝ, Jan. Elektroencefalografie [online]. Dostupné na <http://fbmi.cvut.cz/files/nodes/657/public/EEG.pdf>

[10] POLANSKÝ, Štěpán. Zpracování elektroencefalografických signálů[online]. Diplomová práce. Vysoké Učení Technické. Brno: 2011. Dostupné na http://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=37132

[11] SANEI, Saeid; CHAMBERS, J.A., EEG Signal Processing, Cardiff university, UK, 2007

[12] VÍTEK, Martin. Vzorkování, aliasing, spektrum signálu [online]. Studijní text cvičení z předmětu Číslicové zpracování signálů a obrazů. Vysoké Učení Technické. Brno: 2010. Dostupné na


https://www.vutbr.cz/elearning/file.php/123627/cviceni/AZSO_cviceni_01_vzorkovani.pdf

Seznam zkratek

EEG	Elektroencefalografie
EPSP	Excitační postsympatické potenciály
IPSP	Inhibiční postsympatické potenciály
FIR	Finite impulse response
EKG	Elektrokardiogram
EOG	Elektrookulogram
EMG	Elektromyogram
f_{vz}	Vzorkovací frekvence
f_{max}	Maximální frekvence
AR model	Autoregresivní model
IIR	Infinite impulse response
a	Koeficient
e	Chyba
LP	Lineárně prediktivní
p	Řád modelu
x	Vzorek signálu
N	Počet vzorků
n	Číslo vzorku
DIF	Diference
FFT	Rychlá Fourierova transformace
DFT	Diskrétní Fourierova transformace
A_w	Odhad střední amplitudy
F_w	Odhad střední frekvence
CUSUM	Cumulative sum control chart


A. Obrázková příloha

Kanál 17: *eeg_seg_af.m*




Obrázek A.1: Výsledek segmentace *eeg_seg_af.m*, okno=128, prah=0,1

Kanál 17: *eeg_seg_fft.m*




Obrázek A.2: Výsledek segmentace *eeg_seg_fft.m*, okno=128, prah=0,05

Kanál 17: *eeg_seg_kor.m*




Obrázek A.3: Výsledek segmentace *eeg_seg_akor.m*, okno=128, prah=8e13

Signál1, kanál 11: *eeg_seg_af_signal1.m*




Obrázek A.4: Výsledek segmentace *eeg_seg_af_signal1.m*, okno=128, prah=0,1

Signál1, kanál 11: *eeg_seg_fft_signal1.m*



Obrázek A.5: Výsledek segmentace *eeg_seg_fft_signal1.m*, okno=128, prah=0,1

Signál1, kanál 11: *eeg_seg_kor_signal1.m*



Obrázek A.6: Výsledek segmentace *eeg_seg_kor_signal1.m*, okno=128, prah=2e11

B. Obsah CD

Složky:

Programy_BP – obsahuje:

- *read_alien.m* – načtení souboru *signal.dat*
- *filter_eeg.m* – filtrace signálu *signal.dat*
- *filter_eeg.m_signal1* – načtení a filtrace signálu *signal1.mat*
- *eeg_seg_af.m* - Adaptivní segmentace pomocí míry difference střední amplitudy a frekvence
- *eeg_seg_fft.m* - Adaptivní segmentace pomocí míry difference odhadnuté z FFT
- *eeg_seg_kor.m* - Adaptivní segmentace pomocí autokorelační funkce
- *eeg_seg_af_signal1.m* - Adaptivní segmentace pomocí míry difference střední amplitudy a frekvence pro použití *signal1.mat*
- *eeg_seg_fft_signal1.m* - Adaptivní segmentace pomocí míry difference odhadnuté z FFT pro použití *signal1.mat*
- *eeg_seg_kor_signal1.m* - Adaptivní segmentace pomocí autokorelační funkce pro použití *signal1.mat*

Obrázky_BP – obsahuje použité obrázky

Soubory:

ondrej_krupka_BP.pdf – elektronická verze bakalářské práce (PDF)

ondrej_krupka_manual_ke_skriptum.pdf – Manuál k přiloženým skriptům