



**ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE**

---

**Fakulta biomedicínského inženýrství  
Katedra přírodních oborů**

**METODY A PARAMETRY ADAPTIVNÍ SEGMENTACE EEG  
ZÁZNAMŮ**

**METHODS AND PARAMETERS FOR ADAPTIVE SEGMENTATION OF  
EEG RECORDINGS**

Diplomová práce

Studijní program: Biomedicínská a klinická technika

Studijní obor: Přístroje a metody pro biomedicínu

Vedoucí práce: doc. Ing. Vladimír Krajča, CSc.

**Bc. David Kala**

---

**Kladno, červen 2016**

Katedra přírodovědných oborů

Akademický rok: 2015/2016

## Z a d á n í   d i p l o m o v é   p r á c e

Student:                    **Bc. David Kala**  
Studijní obor:            Přístroje a metody pro biomedicínu  
Téma:                        **Metody a parametry adaptivní segmentace EEG záznamů.**  
Téma anglicky:          Methods and parameters for adaptive segmentation of EEG recordings

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

1. Vytvořte software v programovacím prostředí MATLAB pro testování vhodných vybraných segmentačních metod na simulovaném i skutečném EEG signálu.
2. Zaměřte se na adaptivní segmentaci epileptické aktivity v EEG a navrhňte vhodná rozmezí vstupních parametrů pro dosažení optimálních výsledků segmentace.
3. Optimalizujte parametry nejprve pro simulovaný, následně reálný záznam.
4. Diskutujte a ověřte hodnoty vstupních parametrů vhodné pro odlišné typy EEG signálu (epileptický, neonatální, běžná EEG aktivita).

### Seznam odborné literatury:

- [1] H. Hassanpour, M. Shahiri, Adaptive segmentation using wavelet transform, International Conference on Electrical Engineering, ročník , číslo , 2007, 1-5 s., doi:10.1109/ICEE.2007.4287348
- [2] V. Krajca, S. Petranek, I. Patakova, A. Varri, Automatic identification of significant grapholements in multichannel EEG recordings by adaptive segmentation and fuzzy clustering, Int. J. Bio-Med. Comput, ročník 28, číslo 1-2, 1991, 71-89 s.
- [3] R. Agarwal, J. Gotman, Adaptive segmentation of electroencephalographic data using a nonlinear energy operator, IEEE International Symposium on Circuits and Systems (ISCAS'99), ročník 4, číslo , 1999, 199-202 s.

Vedoucí:                    doc. Ing. Vladimír Krajča, CSc.  
Konzultant:                Ing. Hana Schaabová

Zadání platné do:    20.08.2017

.....  
vedoucí katedry / pracoviště

.....  
děkan

V Kladně dne 07.12.2015

*Název práce:*

## **Metody a parametry adaptivní segmentace EEG záznamů**

*Autor:* Bc. David Kala

*Obor:* Přístroje a metody pro biomedicínu

*Druh práce:* Diplomová práce

*Vedoucí práce:* doc. Ing. Vladimír Krajča, CSc.

*Abstrakt:*

Vizuální vyhodnocení EEG záznamu, tak jak se používá v současné lékařské praxi, je časově velmi náročné. Z toho důvodu je snaha o vytvoření automatického systému, který by lékaři práci urychlil. Nezbytným prvním krokem takového systému (z důvodu nestacionarity EEG) je proces adaptivní segmentace (AS) signálu, jehož kvalita se významně podílí na kvalitě celého systému. Právě adaptivní segmentace EEG záznamů a vliv různých vstupních parametrů na výsledek segmentace je předmětem této práce. Byla vytvořena metodika a software v programovém prostředí MATLAB s jejichž pomocí byly porovnány nejznámější současné metody, ze kterých byla pro další testování vybrána Varriho metoda dvou spojených oken (Krajča a kol. 1991). Na té byl následně testován vliv různých vstupních parametrů a jejich konkrétních hodnot na segmentaci umělých (sinusových a autoregresních) dat a rovněž reálných (fyziologických, epileptických a neonatálních) záznamů. Dále zde byly navrženy optimální parametry pro segmentaci reálných klinických záznamů a způsob jejich dalšího doladění. Praktickým výsledkem práce je ucelená metodika a software umožňující porovnání metod AS, testování jejich vstupních parametrů a vliv těchto parametrů na kvalitu segmentace. Teoretickým výsledkem je detailní popis chování adaptivní segmentace v závislosti na použitých parametrech a navržení vhodných rozmezí hodnot těchto parametrů pro dosažení optimálních výsledků při segmentaci klinických EEG záznamů.

*Klíčová slova:* EEG, adaptivní segmentace, optimalizace parametrů

*Title:*

**Methods and parameters for adaptive segmentation of EEG recordings**

*Author:* Bc. David Kala

*Abstract:*

Visual review of long-term EEG recordings, as performed in common medical practice, is strongly time-consuming. Therefore, there is an effort to develop the semi-automatic and automatic systems, which helps physicians to make their work faster and easier. Adaptive segmentation (AS) is an essential first step of such systems and its precision has significant influence to performance of whole system. AS of EEG records and influence of its input parameters to segmentation quality is subject of this diploma thesis. MATLAB software and methodology for comparing of various AS methods was developed in this thesis and Varri's method with two connected windows was selected as most suitable for this. The effect of various input parameters and its values on artificial and real EEG signals segmentation using this method was then tested. Sinusoidal and autoregressive artificial signals and normal, epileptic and neonatal EEG recordings was used for testing. Optimal values of parameters for segmentation of clinical EEG records was specified. The software for methods comparison and for input parameters testing is the practical outcome of this thesis. A detailed study of segmentation performance according to the input parameters is the theoretical outcome of this thesis. Also the ranges of parameters values for optimal segmentation of clinical EEG recordings were established.

*Key words:* EEG, adaptive segmentation, parameters optimization

## **Prohlášení**

Prohlašuji, že jsem svou diplomovou práci s názvem METODY A PARAMETRY ADAPTIVNÍ SEGMENTACE EEG ZÁZNAMŮ vypracoval samostatně a použil k tomu úplný výčet citací použitých pramenů, které uvádím v seznamu přiloženém k diplomové práci.

Nemám závažný důvod proti užití tohoto školního díla ve smyslu §60 Zákona č.121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon).

V Kladně dne .....

.....

Bc. David Kala

## **Poděkování**

Tímto chci poděkovat vedoucímu mé práce, panu doc. Ing. Vladimíru Krajčovi, CSc., za jeho věcné rady a odbornou i pedagogickou pomoc při tvorbě této práce. Dále bych chtěl poděkovat Ing. Haně Schaabové z EEG týmu, za cenné odborné konzultace.

Tato práce byla podpořena grantem studentské grantové soutěže ČVUT v Praze č. SGS15/229/OHK4/3T/17.

# Obsah

Seznam obrázků.....	ix
Seznam použitých symbolů a zkratek.....	xi
Úvod.....	1
Současný stav problematiky .....	4
Cíle práce .....	5
<b>Kapitola 1 Segmentace EEG signálu.....</b>	<b>6</b>
1.1. Fixní segmentace .....	6
1.2. Původní adaptivní segmentace.....	6
1.3. Adaptivní segmentace na základě dvou spojených oken.....	10
1.4. Parametry adaptivní segmentace.....	17
<b>Kapitola 2 Další matematické postupy využitelné u AS .....</b>	<b>20</b>
2.1. Fraktální dimenze .....	20
2.2. Evoluční algoritmy.....	22
<b>Kapitola 3 Software pro testování metod AS.....</b>	<b>24</b>
<b>Kapitola 4 Porovnání současných metod.....</b>	<b>27</b>
4.1. Autoregresní signál pro testování metod.....	28
4.2. Metodika vyhodnocení spolehlivosti .....	29
4.3. Srovnání metod pro kombinaci parametrů WL + DWL .....	31
4.4. Srovnání metod pro kombinaci parametrů WL + STEP .....	32
<b>Kapitola 5 Nově navržené parametry.....</b>	<b>34</b>
5.1. Nové parametry Varriho metody .....	34
<b>Kapitola 6 Segmentace epileptické aktivity.....</b>	<b>38</b>

---

6.1. Epileptická aktivita.....	38
6.2. Simulované epileptické hroty.....	39
6.3. Simulované hroty s autoregresním signálem.....	42
6.4. Testování na simulovaných sinusovkách.....	44
6.5. Reálné EEG záznamy .....	47
6.6. Shrnutí navržených parametrů .....	48
<b>Kapitola 7 Optimalizace parametrů pro reálné záznamy.....</b>	<b>49</b>
<b>Kapitola 8 Segmentace dospělé a neonatální aktivity .....</b>	<b>53</b>
8.1. Segmentace fyziologické aktivity dospělých .....	53
8.2. Segmentace neonatální aktivity .....	54
8.3. Shrnutí navržených hodnot parametrů .....	55
<b>Diskuse.....</b>	<b>57</b>
<b>Závěr .....</b>	<b>61</b>
<b>Reference .....</b>	<b>62</b>



## Seznam obrázků

<b>Obrázek 1.</b> Blokové schéma systému pro automatické rozpoznání grafoelementů.....	1
<b>Obrázek 1.1.</b> Rozdíl mezi fixní a adaptivní segmentací. (Krajča a kol. 2011) .....	7
<b>Obrázek 1.2.</b> Schéma algoritmu AS na základě lineární predikace .....	8
<b>Obrázek 1.3.</b> Schéma metody AS pomocí rozdílu autokorelačních funkcí.....	9
<b>Obrázek 1.4.</b> Obecné schéma metod využívajících dvojici spojených oken.....	10
<b>Obrázek 1.5.</b> Varriho algoritmus (Krajča a kol. 1991) adaptivní segmentace. ....	12
<b>Obrázek 1.6.</b> Ukázka segmentace pomocí NLEO metody .....	13
<b>Obrázek 1.7.</b> Vliv parametrů na energii $G$ funkce (Anisheh a Hassanpour, 2009).....	14
<b>Obrázek 1.8.</b> Ukázka segmentace pomocí změny FD.....	15
<b>Obrázek 1.9.</b> Ukázka segmentace metodou s Kalmanovou filtrací.....	16
<b>Obrázek 1.10.</b> Obecné schéma metody AS využívající dvě spojená okna a vstupní parametry této metody .....	18
<b>Obrázek 1.11.</b> Schéma určení lokálního maxima parametrem DWL.....	19
<b>Obrázek 2.1.</b> Prvních pět iterací vzniku Kochovi sněhové vločky.....	20
<b>Obrázek 2.2.</b> Obecné schéma evolučního algoritmu .....	23
<b>Obrázek 3.1.</b> Modul pro testování parametrů AS .....	24
<b>Obrázek 3.2.</b> Detail panelu pro nastavení hodnot vstupních parametrů .....	25
<b>Obrázek 3.3.</b> Ukázka prostředí pro porovnání metod mezi sebou.....	26
<b>Obrázek 4.1.</b> Vícekanálový autoregresní signál pro testování metod.....	28
<b>Obrázek 4.2.</b> Ukázka výstupu programu pro vyhodnocení metod .....	30
<b>Obrázek 4.3.</b> Přesnost jednotlivých metod v závislosti na zvolené kombinaci vstupních parametrů WL+DWL .....	31
<b>Obrázek 4.4.</b> Přesnost jednotlivých metod v závislosti na zvolené kombinaci vstupních parametrů WL+STEP .....	33
<b>Obrázek 5.1.</b> Ukázka funkční závislosti parametrů DWL a STEP .....	36
<b>Obrázek 5.2.</b> Ukázka segmentace vlivu parametru MSL.....	36
<b>Obrázek 5.3.</b> Vliv parametru zero optimisation (ZO) .....	37

---

<b>Obrázek 6.1.</b> Vliv parametru WL na segmentaci simulovaného hrotu .....	41
<b>Obrázek 6.2.</b> Vliv parametru STEP na segmentaci simulovaného hrotu.....	42
<b>Obrázek 6.3.</b> Segmentace hrotu při zvyšování WL .....	43
<b>Obrázek 6.4.</b> Vliv poměru amplitudy hrot/pozadí na segmentaci. ....	44
<b>Obrázek 6.5.</b> Oscilace na $G$ funkci vzniklé vlivem delšího WL.....	45
<b>Obrázek 6.6.</b> Tři možnosti segmentace nastávající při kombinování WL a STEP .....	46
<b>Obrázek 6.7.</b> Detekce reálného učebnicového EEG záznamu komplexu hrot-vlna....	48
<b>Obrázek 7.1.</b> Tři různé úrovně segmentace .....	50
<b>Obrázek 7.2.</b> Rozdělení signálu na jednotlivé komplexy hrot-vlna .....	51
<b>Obrázek 7.3.</b> Méně citlivá segmentace se sdružením komplexů.....	51
<b>Obrázek 7.4.</b> Nejméně detailní segmentace .....	51
<b>Obrázek 7.5.</b> Obdobná segmentace jiného signálu .....	52
<b>Obrázek 8.1.</b> Ukázka segmentace fyziologické aktivity .....	54
<b>Obrázek 8.2.</b> Segmentace novorozeneckých aktivit typu <i>tracé discontinu</i> .....	55

## Seznam použitých symbolů a zkratek

### Metody adaptivní segmentace

Varri	Varriho metoda (Krajca a kol.)
NEO (NLEO)	Nonlinear energy operator (Gotman)
INLEO	Improved NEO (Hassanpour, Shahiri)
Hass.	Hassanpouriho metoda

### Parametry metod AS

WL (window length)	Délka okna
STEP	Krok algoritmu
DWL (detection window length)	Délka detekčního okna
THR (threshold)	Detekční limit
MSL (minimal segment length)	Nejmenší detekovaný segment
ZO (zero optimization)	Optimalizace k nule
OP (overlapping percentage)	Procento přesahu

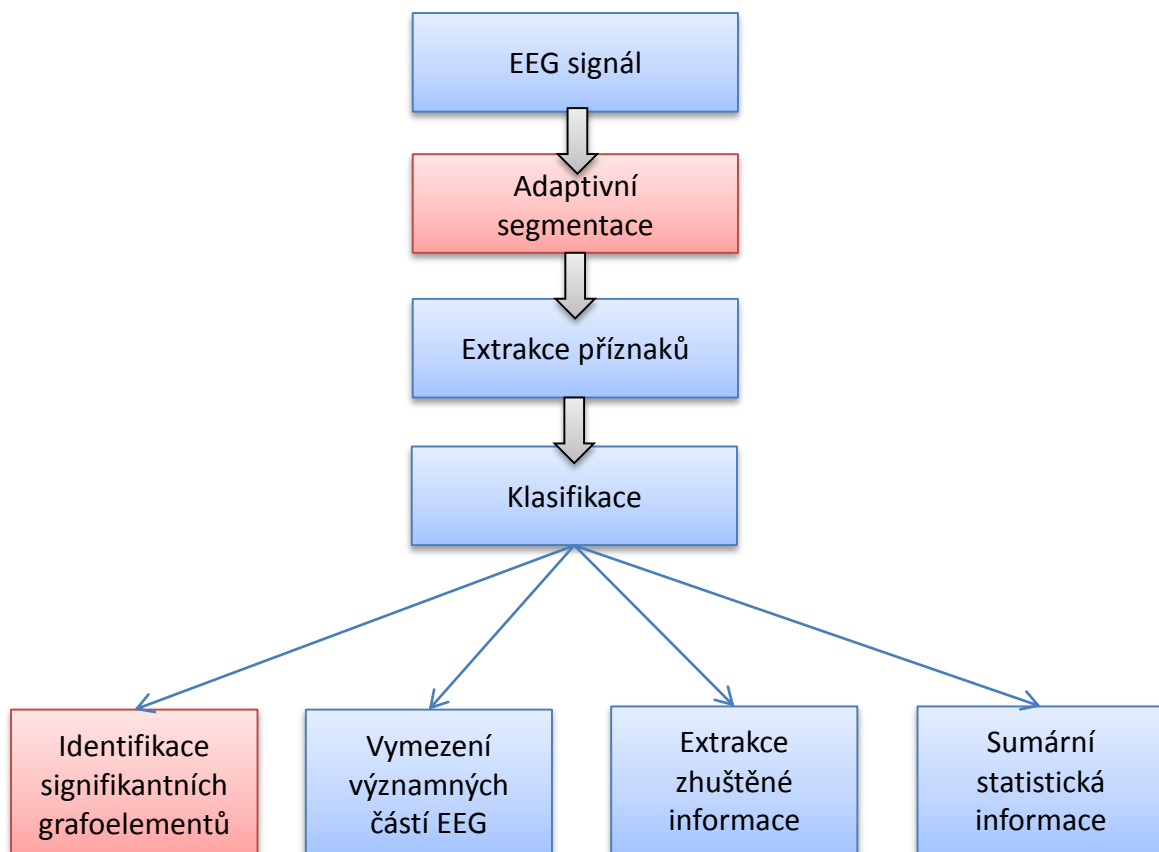
### Další symboly a zkratky

EEG	Elektroencefalogram
AS	Adaptivní segmentace
$G$ funkce ( $Gf$ )	Globální funkce
$R_w$	Autokorelační funkce
$Diff$	Míra rozdílnosti signálu
$W1/ W2$	Referenční/testovací okno
$Adiff/Fdiff$	Amplitudová/frekvenční diference
$\Psi_{kaiser}$	Nelineární energetický operátor
SWT (stationary wavelet transform)	Stacionární vlnková transformace
FD	Fraktální dimenze
$G^l$	$G$ funkce vzniklá použitím daného WL
$E_{G^l}$	Energie $G$ funkce
EA	Evoluční algoritmus
PSO (Particle Swarm Optimization)	EA na principu hejna ptáků
ICA (Imperial Competitive Algorithm)	EA na principu vzniku kolonií
GA	Genetický EA

$d$	Dimenze objektu
$\varepsilon$	Délka úseku křivky
$N(\varepsilon)$	Počet potřebných segmentů o délce $\varepsilon$
$D_b$	<i>Box dimension</i>
$P$	Přesnost metody (koeficient spolehlivosti)
FP	Falešně pozitivní
FN	Falešně negativní
TP	Skutečně pozitivní
N	Maximální počet negativních výsledků
FPR (false positive ratio)	Poměr falešné positivity
AR	Autoregresní
Transient	Významná změna ve stacionaritě signálu
Grafoelement	Úsek signálu mající konkrétní funkční význam

## Úvod

Analýza elektroencefalografických (EEG) záznamů je jedním z nejčastějších úkonů během neurologických vyšetření. Vizuální vyhodnocení záznamu, které se používá v současné lékařské praxi, je časově velmi náročné. Z toho důvodu je snaha o vytvoření systému pro automatické vyhodnocování EEG záznamů (rovněž nazýván systém pro automatické rozpoznání grafoelementů), který by lékaři práci výrazně urychlil a usnadnil. Takovýto systém byl navržen Krajčou a Värrim (1991). Systém EEG záznam zpracovává ve třech postupně navazujících krocích, jak ukazuje Obrázek 1. Nejprve je signál v závislosti na výskytu nestacionarit v EEG záznamu rozdělen na stacionární úseky proměnné délky, dále jsou pro tyto úseky vypočítány příznaky, na jejichž základě je signál (přesněji jeho úseky) v posledním kroku klasifikován do příslušných homogenních tříd a vyhodnocován.



**Obrázek 1.** Blokové schéma systému pro automatické rozpoznání grafoelementů složeného ze tří hlavních kroků: adaptivní segmentace, extrakce příznaků a klasifikace. Systém slouží k usnadnění práce lékařů a ke zkrácení doby potřebné k vyhodnocení EEG záznamu

Tato práce se zabývá prvním krokem takového systému, tedy rozdělením signálu do stacionárních úseků. Důležitost tohoto kroku je dána z podstaty EEG signálu, který je stochastický (náhodný) a obsahuje transienty, jako jsou například epileptické grafoelementy. Stochastické signály nelze popsat matematickou funkcí, proto se u nich používá popis statistickými parametry. Ty jsme však schopni určit pouze u signálů, které jsou stacionární, což EEG signál jako celek bohužel není. Je tedy potřeba rozdělit dlouhý signál na menší segmenty, které stacionární budou, a tudíž půjdou statisticky popsat. K takovému rozdělení se využívá proces zvaný adaptivní segmentace (AS), kterým se budu v této práci dále podrobněji zabývat.

Na kvalitě provedené segmentace, je silně závislá přesnost celého vyhodnocovacího systému, jehož je součástí, proto je pro nás velmi důležité, aby segmentace proběhla co nejlépe. Kvalita jejího provedení se odvíjí od použité metody a konkrétního nastavení jejích vstupních parametrů. Přesné hodnoty těchto vstupních parametrů jsou nastavovány podle specifického charakteru segmentovaného signálu (typ aktivity, frekvence) a rovněž podle konkrétní diagnostické potřeby lékaře.

V této práci se zabývám srovnáním současných metod adaptivní segmentace a vybráním nejlepší metody pro použití v systému automatického rozpoznávání EEG grafoelementů. Dále se zde zabývám popisem vstupních parametrů vybrané metody a vlivem, které mají tyto parametry na výsledek segmentace. Rovněž zde navrhuji některé nové parametry sloužící k zpřesnění metody.

V druhé části práce se zabývám segmentací signálu epileptické aktivity. Tomuto typu aktivity zde věnuji speciální pozornost, jelikož se od běžných fyziologických aktivit velmi liší zejména vyšší frekvencí výskytu sledovaných grafoelementů a přítomností ostrých rychlých hrotů, které se u běžných fyziologických signálů nevyskytují. Kvůli těmto odlišnostem vyžaduje epileptický signál specifické nastavení vstupních parametrů metody AS. V této práci se zabývám nalezením vhodného nastavení metody pro dosažení

optimálních výsledků segmentace. Nakonec ve své práci rovněž navrhuji vhodné parametry pro segmentaci neonatální aktivity a běžné fyziologické aktivity.

**Motivací** k řešení otázky vstupních parametrů je nedostatečná dokumentace k této problematice. Používaných metod je mnoho a ne pro všechny se hodí stejné nastavení. Vliv vstupních parametrů na výsledek segmentace zatím nebyl nikde publikován. Pro lékaře je proto poměrně těžké zvolit správné nastavení používané metody. V běžné praxi lékaři obvykle využívají pouze několik osvědčených kombinací parametrů, čímž přicházejí o možnost přesného ladění metody a dosažení optimálních výsledků i u atypických signálů. Nekvalitní segmentace se následně promítá do horších výsledků celého vyhodnocovacího systému, čímž může značně znesnadnit celou diagnózu pomocí tohoto systému.

**Struktura práce** je tvořena osmi kapitolami. První dvě se zabývají popisem metod adaptivní segmentace a dalších matematických nástrojů při ní používaných. Kapitola 3 se potom zabývá konkrétní implementací metod a popisem použitého softwaru. Výsledky práce jsou rozděleny do kapitol 4-8. Nejprve se zabývám porovnáním současných metod AS a výběrem nejvhodnější z nich pro další použití. Dále v Kapitole 5 popisuje dva nově navržené parametry pro zlepšení výsledků metody. Kapitoly 6 a 7 se zabývají segmentací epileptické EEG aktivity a navržením vhodných hodnot vstupních parametrů segmentační metody pro tento typ signálu. Nakonec v Kapitole 8 srovnávám navržené hodnoty parametrů s parametry vhodnými pro segmentaci fyziologických rytmů a neonatálního signálu typu *tracé discontinu*. Práci uzavírám diskuzí výsledků a závěrem.

## Současný stav problematiky

Adaptivní segmentaci poprvé navrhli Bodenstein a Praetorius (1977). K zachycení změny stacionarity využívali dvojici oken (statické referenční a pohyblivé testovací), v nichž byla stacionarita testována pomocí Wienerova algoritmu lineární predikace. Jednodušší metodu představil Michael (1979). Opět využil dvojici referenční a testovací okno, pouze na místo aplikace Wienerova filtru a výpočtu chyby predikace určoval míru rozdílnosti signálu v těchto oknech pomocí autokorelační funkce. Tuto metodu dále zdokonalili Appel a Brandt (1983, 1984). Novější metodu adaptivní segmentace představil Skrylev (1984), který namísto dvojice referenční a testovací okno využil dvě navzájem spojená okna společně se pohybující po signálu. Touto změnou odstranil desynchronizaci, ke které docházelo u předchozích metod, avšak parametry extrahované z obou oken byly popsány pouze ve frekvenční oblasti pomocí Fourierovy transformace. Proto metodu dále upravili Krajča a Värri (1991). Ti změnu stacionarity určili pomocí jednoduché míry amplitudové a frekvenční difference signálu v jednotlivých oknech. Obdobnou metodu představili později Agarwal a Gotman (1998), kteří namísto jednoduché difference využili nelineární energetický operátor (NEO). Jejich metodu dále zdokonalili Hassanpour a Shahiri (2007). Vylepšená metoda se nazývá INLEO (Improved NEO). Nový přístup představili Anisheh a Hassanpour (2009). Ti ve své metodě určovali změnu stacionarity na základě změny fraktální dimenze (FD) signálu. Pro tuto metodu je zásadní správné nastavení parametrů pro výpočet FD. Optimalizací těchto parametrů pomocí evolučních algoritmů se zabývali (Anisheh a Hassanpour, 2009, 2011). Nejnovější úprava metody byla navržena (Azami a kol., 2013, 2015). Zde byla pro předzpracování signálu využita Kalmanova filtrace a následně opět počítána změna fraktální dimenze. Parametry pro výpočet FD zde byly určovány opět pomocí evolučních algoritmů.



## Cíle práce

Hlavním cílem této práce je poskytnout lékaři jakousi „kuchařku“, podle které by byl schopen snadno nastavit segmentační metodu pro segmentaci běžných EEG záznamů bez hlubších znalostí jejího fungování. Motivací je spleť problémů nastavení vstupních parametrů metod AS a její nedostatečná dokumentace, což z ní dělá těžkopádný nástroj namísto užitečného pomocníka. K dosažení tohoto cíle je zapotřebí splnit následující kroky:

- Prvním důležitým krokem je porovnat současné metody AS a vybrat tu nejvhodnější pro použití v softwaru pro automatickou detekci grafoelementů. K tomu bude zapotřebí vytvořit software umožňující porovnání segmentačních vlastností metod v závislosti na konkrétních hodnotách jejich vstupních parametrů. Abychom otestovali globální chování jednotlivých metod, bude nutné pro každou z nich provést porovnání napříč mnoha kombinacemi vstupních parametrů. Je očekávané, že ne všechny metody budou pro zamýšlený účel vhodné, a to buď z důvodu nízkého rozsahu vhodných parametrů a/nebo vysoké výpočetní náročnosti metody.
- Následně je potřeba otestovat vliv jednotlivých vstupních parametrů na výsledek segmentace pomocí vybrané metody. Testování je záhodno provést nejprve na simulovaných signálech reprezentujících jednotlivé sledované EEG grafoelementy a transienty, až následně na reálných EEG záznamech.
- Posledním krokem práce je navrhnout konkrétní rozmezí vstupních parametrů metody vedoucí ke správné segmentaci různých typů běžně sledovaných klinických EEG záznamů. Takto navržená rozmezí pravděpodobně nebudou platit všeobecně pro všechny záznamy daného typu, proto je rovněž vhodné jednoduše popsat způsob, jakým parametry ladit pro dosažení dobrých výsledků segmentace i u atypických signálů.

# Kapitola 1

## Segmentace EEG signálu

Segmentace EEG signálu je prvním nutným krokem v systému rozpoznávání grafoelementů, jak již bylo řečeno v úvodu. Je motivována korektní extrakcí příznaků z kvazi stacionárních (po částech stacionárních) segmentů. Její nutnost je dána vlastnostmi samotného EEG signálu, který je stochastický (náhodný) a jako takový nemůže být popsán matematickým předpisem. Je tedy potřeba zvolit popis statistický. Abychom tak mohli učinit, musí být popisovaný úsek signálu stacionární, což EEG jakožto biologický signál není - jeho frekvenční a amplitudové vlastnosti se v čase mění (McEwen 1975). Bylo však dokázáno, že EEG signál lze rozdělit na kratší úseky, které již stacionární jsou - je kvazistacionární (po částech stacionární). K takovému rozdělení se využívá operace zvaná adaptivní segmentace. Ta dělí signál buď na úseky o konstantní délce (fixní segmentace), nebo na úseky s proměnlivou délkou (adaptivní segmentace). (Krajča a kol. 2011)


### 1.1. Fixní segmentace

Fixní segmentace je proces rozdělování signál na úseky konstantní délky. Při tomto rozdělení však nemají vzniklé hranice žádný vztah k charakteru signálu. Může tak dojít ke vzniku hybridních úseků, kdy je jeden grafoelement (úsek signálu mající konkrétní funkční význam, např. epileptický hrot) rozdělen do více segmentů, jak ukazuje Obrázek 1.1. Takovýto hybridní nestacionární úsek však nemůže být kvalitně popsán příznaky a tedy ani následně správně klasifikován. Metoda schopná rozdělit signál na úseky proměnné délky podle změny stacionarity se nazývá adaptivní segmentace. (Krajča a kol. 2011)

### 1.2. Původní adaptivní segmentace

Na rozdíl od pevné segmentace, která dělí signál na úseky o konstantní délce, rozděluje adaptivní segmentace signál na různě dlouhé úseky, které však zachovávají stacionaritu.

Takto vniklé úseky potom mohou být správně popsány příznaky a lépe klasifikovány. Rozdíl mezi fixní a adaptivní klasifikací ukazuje Obrázek 1.1. Vybrané metody adaptivní segmentace jsou popsány ve zbytku této kapitoly. Nejprve jsou uvedeny původní, starší metody. Společným problémem těchto metod je jejich **nevhodnost pro multikanálovou segmentaci**. Dochází u nich totiž k desynchronizace během zpětného určování hranice segmentu, což brání v segmentaci několika kanálů najednou. V další části této kapitoly jsou popsány novější metody založené na využití dvou spojených oken. U těchto metod k desynchronizaci nedochází, a tudíž jsou pro multikanálovou segmentaci použitelné.



**Obrázek 1.1.** Rozdíl mezi fixní (nahore) a adaptivní (dole) segmentací. Fixní segmentace může způsobit nesprávné rozdělení grafoelementu do více segmentů bez ohledu na charakter signálu, zatímco adaptivní rozděluje signál na různě dlouhé stacionární úseky (Krajča a kol. 2011)


## Adaptivní segmentace na základě lineární predikace

První metodu adaptivní segmentace představili Bodenstern a Praetorius (1977). K jejímu výpočtu využili Wienerův algoritmus lineární predikace definovaný rovnicí 1.1. Tento algoritmus na EEG použil již Lope de Silva (1975) pro detekci přechodových jevů (grafoelementy odlišné od aktivity pozadí) v signálu.

$$x_n = -\sum_{k=1}^p a_k x_{n-k} + e_n \quad (1.1)$$

$a_k$  jsou koeficienty lineárně predikačního (Wienerova) filtru, který transformuje vstupní posloupnost na posloupnost nekorelovaných hodnot,  $p$  je počet minulých vzorků, ze kterých odhadujeme nové hodnoty  $x_n$  a  $e_n$  je chyba predikace.

Celý algoritmus názorně ukazuje Obrázek 1.2. K určení hranic segmentů se využívají dvě okna. První je nepohyblivé a slouží jako referenční. Uvnitř tohoto okna jsou odhadnuty koeficienty Wienerova filtru. Zbytek signálu prochází druhým, testovacím oknem. Uvnitř tohoto testovacího okna je signál filtrován inverzními filtrem k filtru odhadnutému v referenčním okně a je sledována chyba predikace. Pokud je signál stacionární (filtr zvolený v referenčním okně je adaptovaný i na signál v testovacím okně), je chyba predikace nekorelovaná (její autokorelační funkce je nulová). Pokud ale dojde ke změně stacionarity, filtr přestane být adaptován. Následně je vypočítána autokorelační funkce chyby stacionarity a určeno spektrum v referenčním a testovacím okně. Pokud je rozdíl mezi těmito spektry větší než zvolená hranice, je doprostřed testovacího okna umístěna hranice segmentu. Referenční okno se následně přesune na tento nový segment a algoritmus pokračuje znovu od začátku. (Krajča a kol. 2011)



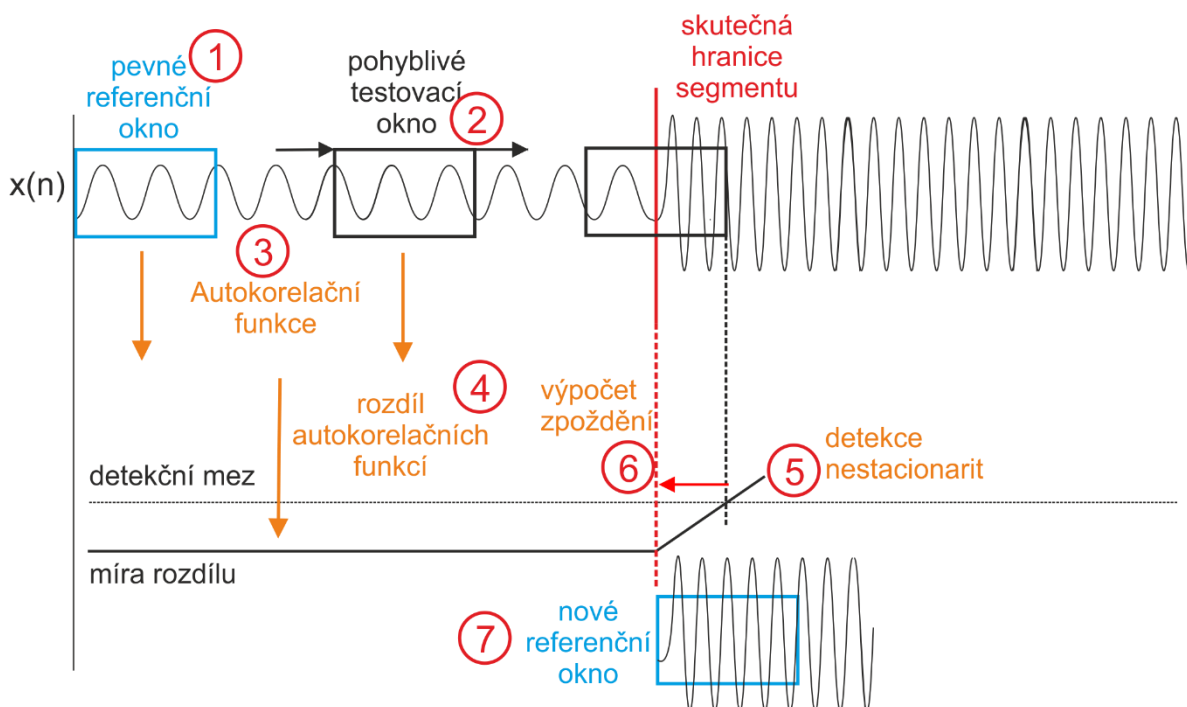
**Obrázek 1.2.** Schéma algoritmu nejstarší metody adaptivní segmentace na základě lineární predikace navržené (Bodenstein a Praetorius, 1977)

## Adaptivní segmentace na základě autokorelační funkce

Jednodušší metodu představil Michael (1979). Opět využívá dvojice referenční a testovací okno, pouze na místo aplikace Wienerova filtru a výpočtu chyby predikace určuje míru rozdílnosti signálu v těchto oknech pomocí autokorelační funkce podle rovnice 1.2.

$$Diff = \sum_{n=0}^{ACFL} \frac{|R_{W1}(n) - R_{W2}(n)|}{R_{W1}(0)R_{W2}(0)} \quad (1.2)$$

$R_w$  jsou autokorelační funkce v referenčním ( $W1$ ) a testovacím ( $W2$ ) okně,  $ACFL$  jsou koeficienty autokorelační funkce. Pokud míra rozdílnosti signálů  $Diff$  překročí nastavenou hranici, identifikujeme toto místo jako změnu stacionarity. Přesná poloha hranice segmentu je následně určena z dalšího průběhu signálu.




**Obrázek 1.3.** Schéma metody adaptivní segmentace pomocí rozdílu autokorelačních funkcí v referenčním a testovacím okně navržené (Michael, 1979)

Předpokládá se zde, že strmost změny parametru  $Diff$  je přímo úměrná poměru obou oken a že k překročení stanovené meze pro detekci dojde o chvíli později, než ke skutečné změně stacionarity v signálu. Toto zpoždění je dopočítáno zpětně. V tomto bodu

algoritmu dochází ke ztrátě synchronizace, a proto metodu vylučuje z použití pro multikanálovou segmentaci. Názorné schéma metody ukazuje Obrázek 1.3. (Krajča a kol. 2011)

Metoda využívající autokorelační funkci byla dále zdokonalena (Appel a Brandt 1983, 1984) modifikací referenčního okna. To zde nezůstává stacionární, ale zvětšuje se s postupem testovacího okna do té doby, než je zaznamenána změna stacionarity. Získává tak maximální informaci o referenčním segmentu.

### 1.3. Adaptivní segmentace na základě dvou spojených oken



**Obrázek 1.4.** Obecné schéma metod využívajících dvojici oken společně klouzajících po signálu. Charakteristická vlastnost se u jednotlivých metod liší. Výsledná diference se někdy nazývá *Totální diference* (Krajča), někdy *G funkce* (Gotman, Hassanpour). Je vidět výrazné zjednodušení oproti předchozím metodám dané zmenšením počtu kroků algoritmu

Ani jedna z předešlých uvedených metod není vhodná pro segmentaci multikanálového signálu z důvodu již zmiňované desynchronizace během zpětného určování zpoždění detekce hranice segmentu. Tento problém vyřešil Skrylev (1984), který poprvé přišel s metodou pracující s dvojicí spojených pohyblivých oken, klouzajících po signálu, kterou následně upravil Varri (1991). Princip této metody spočívá ve společném posuvu obou spojených oken, kdy pro každé okno zvlášť vypočítáváme určitou charakteristickou

vlastnost signálu. Následně určíme diferenci těchto dvou oken, a pokud tato diference překročí stanovenou mez, je v místě spojení oken vyznačena hranice segmentu. Jak je vidět, nevzniká zde žádné zpoždění a tudíž ani nedochází k desynchronizaci jako u předchozích metod. Je tedy možné segmentovat multikanálový signál. Obecné schéma metod využívajících dvě spojená okna ukazuje Obrázek 1.4.

## Adaptivní segmentace na základě jednoduché míry difference


Algoritmů pracujících na principu dvou spojených oken bylo navrženo několik. Hlavní rozdíl mezi nimi je použitá „vlastnost“ signálu, která je v jednotlivých oknech vypočítávána. Nejjednodušší algoritmus byl navržen Krajčou (1991). Jako charakteristická vlastnost se využívá amplitudová a frekvenční difference signálu, které jsou vypočítány dle rovnice 1.3 respektive 1.4. Z těchto diferencí je následně vypočítána takzvaná totální difference (u jiných metod také nazývána Globální funkce,  $Gf$ ) podle vztahu 1.5.

$$Adif = \frac{\sum_{i=1}^N |x_i|}{N} \quad (1.3)$$

$$Fdif = \frac{\sum_{i=1}^N |x_i - x_{i-1}|}{N} \quad (1.4)$$

$$Gf = k_1 \cdot |Adif_L - Adif_R| + k_2 \cdot |Fdif_L - Fdif_R| \quad (1.5)$$

$N$  [vzorky] je délka jednotlivých okének, koeficienty  $L$  a  $R$  značí levé (Left) a pravé (Right) okénko. Koeficienty  $k_1$  a  $k_2$  byly empiricky nastaveny na 1 a 7 a jsou zde z důvodu souměřitelnosti amplitudové a frekvenční difference. Hranice segmentu je umístěna na místo, kde totální difference překročí stanovenou detekční mez. Tento algoritmus využívá velmi jednoduché matematické operace, což ho činí poměrně rychlým a výpočetně jednoduchým. Tento fakt je velkou předností metody a dělá jí vhodnou pro online vyhodnocování EEG záznamů. Ukázka segmentace pomocí tohoto algoritmu (v literatuře uváděného jako Varriho metoda) ukazuje Obrázek 1.5.



**Obrázek 1.5.** Varriho algoritmus (Krajča a kol. 1991) adaptivní segmentace. Nahoře segmentovaný signál, dále amplitudová a frekvenční diference v čase. Dole odpovídající  $G$  funkce v čase

## Adaptivní segmentace metodou NLEO

Agarwal a Gotman (1998) ve své práci využívají rovněž spojená klouzající okna, avšak pro výpočet  $G$  funkce nevyužívají dvou diferencí jako Krajča, ale nelineární energetický operátor NLEO (Nonlinear Energetic Operator) vyvinutý (Kaiser, 1990) vypočítaný podle vztahu 1.6. Tento operátor byl později vylepšen (Plotkin and Swamy, 1992) do formy ukázané vztahem 1.7.  $G$  funkci potom vypočítává obdobně jako Krajča jako diferenci obou oken dle rovnice 1.8. Segmentaci tímto algoritmem demonstruje Obrázek 1.6.

$$\psi_{kaiser}[x(n)] = x^2(n) - x(n-1)x(n-2) \quad (1.6)$$


$$\psi_g[x(n)] = x(n-l)x(n-p) - x(n-q)x(n-s) \quad (1.7)$$

$$l + p = q + s$$

$$G_f(n) = \sum_{m=n-N+1}^n \psi(m) - \sum_{m=n+1}^{n+N} \psi(m) \quad (1.8)$$

$N$ [vzorky] je zde velikost jednotlivých oken.





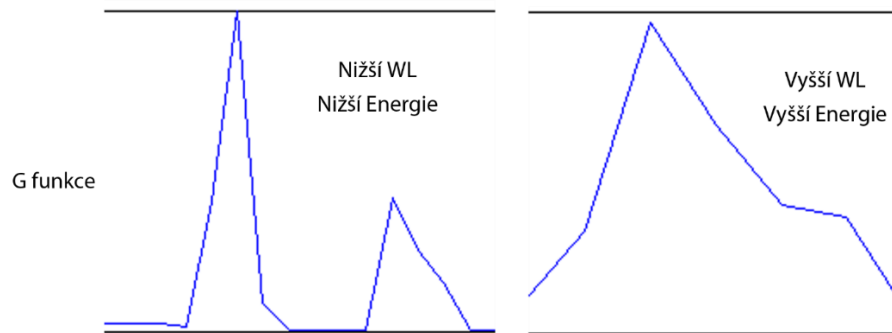
**Obrázek 1.6.** Ukázka segmentace pomocí NLEO metody (Agarwal a Gotman, 1998). Nahoře segmentovaný signál, uprostřed energetický operátor, dole odpovídající  $G$  funkce

Metodu dále vylepšili Hassanpour a Shahiri (2007), kteří před samotným výpočtem NLEO signál upravují pomocí stacionární vlnkové transformace SWT (Stationary Wavelet Transform). Tato metoda je dále známa jako INLEO (Improved NLEO).

## Adaptivní segmentace na základě změny fraktální dimenze

Nový náhled na adaptivní segmentaci přinesli Anisheh a Hassanpour (2009). EEG signál nejprve upravili pomocí vlnkové transformace SWT (Stationary Wavelet Transform). Dále vypočítali fraktální dimenzi FD (Fractal Dimension) signálu pomocí Katzova algoritmu (Katz, 1988) a následně  $G$  funkci jako diferenci fraktální dimenze.

Pro výpočet FD jsou zásadní dva parametry. Délka okna WL (Windows Length) a procento přesahu (Overlapping Percentage) dvou sousedních oken. Další vylepšování metody využívající fraktální dimenzi je založeno na optimalizaci těchto parametrů. Touto problematikou se postupně zabývají (Anisheh a Hassanpour, 2009, 2011).

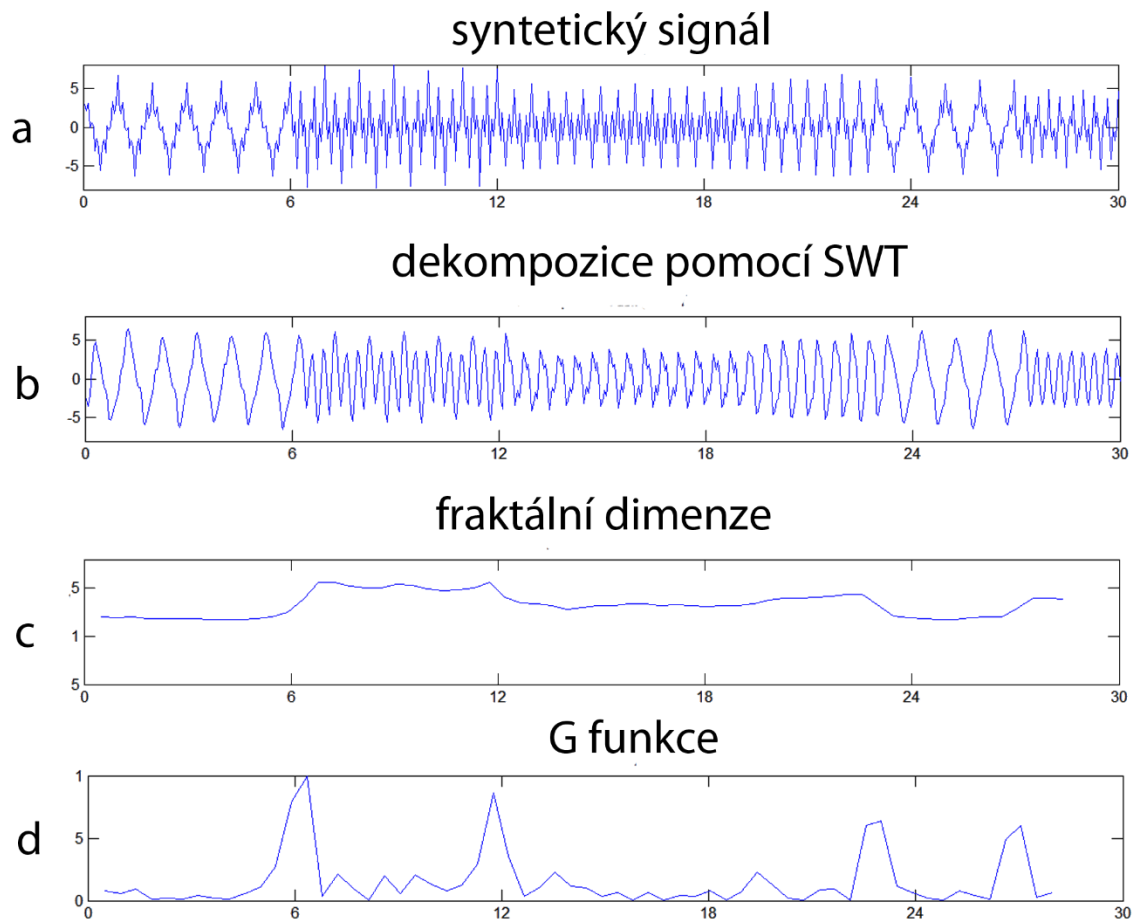


**Obrázek 1.7.**  $G$  funkce vypočítaná z jednoho signálu za použití dvou hodnot parametru WL. Vlevo pro menší hodnotu WL je signál více ostrý, energie (plocha pod křivkou) je menší. Tento tvar  $G$  funkce je vhodnější, jelikož oba hroty jdou od sebe dobře odlišit. Vpravo s použitím méně vhodného většího WL, energie je vyšší, hroty jsou méně ostré a od sebe těžko oddělitelné (Anisheh a Hassanpour, 2009)

Tvar  $G$  funkce se přímo odvíjí od konkrétních použitých hodnot parametrů WL a OP. Při nevhodně zvolených parametrech může mít  $G$  funkce tvar neumožňující správnou detekci změn stacionarity. Obrázek 1.7 ukazuje rozdíl mezi vhodně zvolenou hodnotou WL, kdy tvar následně vypočítané  $G$  funkce umožňuje jasné určení dvou změn stacionarity (hranic segmentů), oproti stavu při zvolení příliš velkého WL, kdy dochází ke splnutí dvou vrcholů v jeden, což znemožňuje správnou segmentaci. V (Anisheh a Hassanpour, 2009) se optimální hodnota parametru WL určuje pomocí energie  $G$  funkce, která je definována podle vztahu 1.9. Je zde deklarováno, že  $G$  funkce má optimální tvar (tedy byly zvoleny optimální parametry WL a OP) pokud je tato energie minimální. V této studii testovali metodu na syntetických datech. Metodu ukazuje Obrázek 1.8.

$$E_{G^l} = \frac{\sum_i |G_i^l|^2}{k} \quad (1.9)$$

$E$  je zjišťovaná energie konkrétní  $G$  funkce  $G^l$  vypočítané s použitím konkrétní hodnoty WL.  $k$  je konstanta normalizace dat z důvodu porovnatelnosti hodnot vzniklých s použitím různých WL a odpovídá délce dané  $G^l$  funkce. (Anisheh a Hassanpour, 2009).




**Obrázek 1.8.** Ukázka segmentace metodou využívající změnu fraktální dimenze. (a) Ukazuje signál synteticky vytvořený složením sinusových signálů. (b) Tento signál rozložený vlnkovou transformací (SWT). (c) Vypočítaná fraktální dimenze s použitím optimálních parametrů  $WL = 1$  s a  $OP = 55\%$ . (d)  $G$  funkce určená jako variace fraktální dimenze. Hranice segmentů definované jako lokální maxima na  $G$  funkci odpovídají hranicím pozorovatelným na syntetickém sinusovém signálu

V (Anisheh a Hassanpour, 2011) využívají opět energetickou funkci definovanou obdobným vztahem jako 1.9. Pro její minimalizování zde využívají evoluční algoritmus PSO (Particle Swarm Optimization). Tento algoritmus napodobuje chování ptáků v hejnu (někdy též rybek, nebo skupiny mravenců) pátrajících po potravě (Eberhart a Kennedy, 1995). Potravou je zde označena funkce, kterou se snažíme minimalizovat popřípadě maximalizovat. Ve zmíněné studii se jedná o hodnotu energie  $G$  funkce.

Další modifikaci provedli (Azami a kol., 2013). Algoritmus určení hranice segmentu je velmi podobný předchozí metodě. Liší se pouze způsobem předzpracování signálu a

evolučním algoritmem použitým pro optimalizaci vstupních parametrů. Azami a kol. využili namísto filtrace signálu pomocí SWT Kalmanovu filtraci. Optimalizaci parametrů pro výpočet fraktální dimenze provedli pomocí dvou evolučních algoritmů, genetického GA a imperialistického ICA (Imperialistic Competitive Algorithm). Metodu s použitím vhodných parametrů ukazuje Obrázek 1.9. Optimalizací parametrů dalšími evolučními algoritmy se dále zabývají (Azami a kol., 2015).



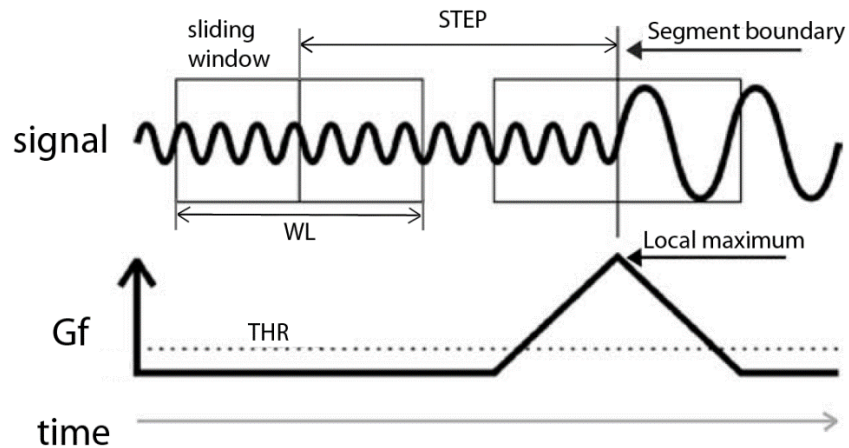
**Obrázek 1.9.** Ukázka segmentace modifikovanou metodou využívající Kalmanovu filtraci a změnu fraktální dimenze. (a) Ukazuje signál synteticky vytvořený složením sinusových signálů. (b) Filtrovaný signál pomocí Kalmanovi filtrace. (c) Vypočítaná fraktální dimenze s použitím optimálních parametrů  $WL=2$  s a  $OP=50\%$ . (d)  $G$  funkce určená jako diference fraktální dimenze

## 1.4. Parametry adaptivní segmentace

Každá z metod pracujících na principu dvou spojených oken uvedená výše pracuje na odlišném principu. Signál je jiným způsobem předzpracováván a  $G$  funkce je počítána na základě jiné matematické vlastnosti signálu. Co mají ale všechny tyto metody společné, jsou vstupní parametry. Těmito parametry se dají metody ladit a primárně na těchto parametrech závisí výsledek segmentace. Jejich správné nastavení je nejenom nutností pro dosažení smysluplné segmentace, ale rovněž se změnou parametrů dá upravit úroveň detailu segmentace. Můžeme tak vytvořit velmi krátké segmenty v případech, kdy lékař potřebuje odlišit samostatné epileptické hroty (tyto úseky mají délku typicky okolo 100 ms), naopak pouhou změnou těchto parametrů jsme schopni segmentovat signál na dlouhé úseky v případech, kdy nás zajímá pouze odlišení epileptické aktivity od aktivity fyziologické (epileptické výboje mají trvání delší jak několik sekund). Tato práce se postupně zabývá vlivem jednotlivých parametrů na výsledek segmentace a následným návrhem konkrétních hodnot parametrů pro dosažení vhodných výsledků segmentace. Tato podkapitola popisuje vstupní parametry použité ve výše uvedených metodách na principu dvou spojených oken. Všechny popisované parametry shrnuje Tabulka 1.1.

**Tabulka 1.1.** Přehled parametrů metod AS pracujících na principu dvou spojených oken

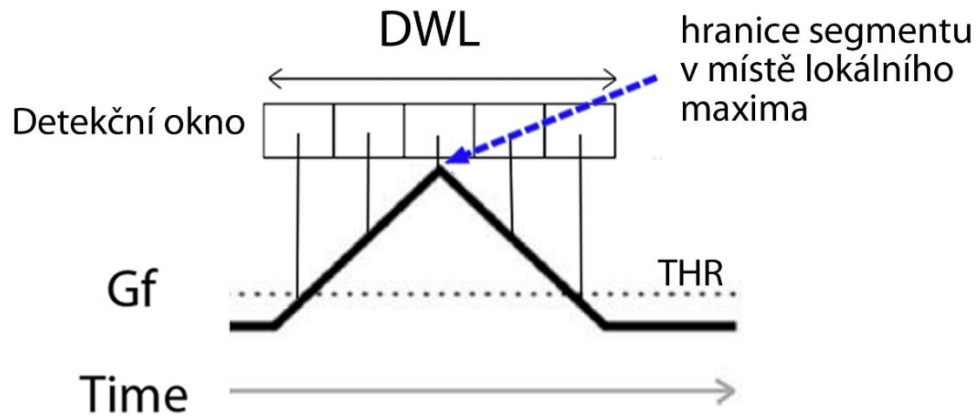
Zkratka	Název	Jednotka	Popis
WL	Window length	s	Délka dvojoka klouzajícího po signálu
STEP	Step	ms	Délka kroku iterace algoritmu (vzdálenost dvou následujících dvojoken)
DWL	Detection window length	ms (vzorek)	Velikost detekčního okna
THR	Threshold	%	Detekční mez



**Obrázek 1.10.** Obecné schéma metody AS využívající dvě spojená okna a vstupní parametry této metody: délka okna  $WL$ , délka kroku  $STEP$  a velikost detekční meze  $THR$

Obrázek 1.10 ukazuje obecné schéma metod AS na principu dvou spojených oken a jejich vstupní parametry. Po signálu se pohybuje klouzající dvojité okénko o délce  $WL$  (window length). V rámci každé poloviny okénka je vypočítána charakteristická vlastnost závisící na konkrétní použité metodě (vlastnosti použité u konkrétních metod jsou popsány v předchozí kapitole). Klouzající okno se po signálu pohybuje s krokem  $STEP$  a v každém místě dojde k vypočítání hodnoty  $G$  funkce podle popsání schématu. Minimální hodnota parametru  $STEP$  je 1 vzorek.

Následně jsou na  $G$  funkci nalezeny vrcholy. Za vrchol je označen bod, který je ve svém okolí nejvyšší a zároveň je  $G$  funkce v jeho okolí z jedné strany rostoucí a z druhé klesající – lokální maxima funkce. Pro definování okolí je použito takzvané D-okno (detection window), které postupně klouže po  $G$  funkci a vyhledává body odpovídající definici vrcholu. Systém detekce demonstruje Obrázek 1.11. Důležitá je zde délka D-okna nazývaná  $DWL$  (detection window length). Minimální možná hodnota tohoto parametru jsou 3 vzorky.



**Obrázek 1.11.** Schéma určení lokálního maxima s použitím parametru DWL definujícím délku detekčního okna

Aby byl nalezený vrchol uznán jako hranice segmentu, musí mít hodnotu vyšší než je nastavený detekční práh. Tento práh je definován parametrem, který se označuje jako THR (threshold). Na obrázcích výše je vidět jako tečkovaná linka. THR zde slouží k eliminaci drobných fluktuací  $G$  funkce. Obecně platí, že pro detekci signálů výrazně se odlišujících od okolí (např. samostatný epileptický hrot), je vhodnější použít THR vyšší. Naopak pro detekci drobnějších změn v signálu je vhodnější THR menší. Tento parametr však nebyl ještě dostatečně prozkoumán a jeho použití je více méně heuristické. V této práci jsem THR nastavoval jako střední hodnotu amplitudy aktuálně zpracovávaného signálu.


## Kapitola 2

### Další matematické postupy využitelné u AS

Tato kapitola krátce popisuje matematické postupy, které se využívají u výše zmíněných metod adaptivní segmentace. Nejprve se zde zabývám výpočtem fraktální dimenze (FD) EEG signálu, na jejímž základě dochází k určení místa změny stacionarity. Dále je popsána základní myšlenka evolučních algoritmů, které se v některých metodách AS využívají pro optimalizaci vstupních parametrů.

#### 2.1. Fraktální dimenze

Fraktální dimenze (FD) je vlastnost objektu používaná ve fraktální geometrii. Tato dimenze udává, jak se mění vzor objektu při změně měřítka, pod kterým tento objekt pozorujeme. Zjednodušeně řečeno udává „složitost“ daného objektu z geometrického hlediska. Někdy se též vysvětluje jako míra zaplnění prostoru naším objektem.



**Obrázek 2.1.** Prvních pět iterací vzniku Kochovi sněhové vločky. Při teoretickém nekonečném počtu iterací je vzdálenost mezi jakýmkoli dvěma body vločky nekonečná. Topologická dimenze tohoto objektu je 1, neboť je složena s čar, které jsou jednodimenzionální. Avšak fraktální dimenze není celé číslo. Přesná hodnota se nachází mezi 1 (nejedná se o jednoduchou přímku) a 2 (nepokrývá celou plochu)



U běžných objektů je tato dimenze intuitivní. Bod má dimenzi nula, přímka jedna, dimenze plochy je dva, krychle tři a objektu  $\mathbb{R}^d$  je  $d$ . Problém nastává u složitějších objektů (fraktálů), u kterých dimenze neodpovídá celému číslu. Příkladem takového fraktálu je „Kochova sněhová vločka“, kterou ukazuje Obrázek 2.1. Vločka vzniká nekonečným opakováním jednoho prvku. Čím detailněji se na ni díváme, tím se jeví její povrch složitější (její povrch je ve skutečnosti nekonečný). (Pollicott, 2005)

Existuje několik definic fraktální dimenze. Nejnázornější je definice za pomoci matematické indukce. Uvažujme, že dimenze 0 odpovídá objektům, které jdou obepnout nekonečně malou koulí, aniž by její povrch proťal hranici definovaného objektu. Potom dimenze  $d$  odpovídá objektům, kdy okraj nekonečně malá koule sestavená kolem každého bodu definované množiny protíná objekt v množině o dimenzi  $d-1$ . V případě přímky tento průsečík tvoří dva body, každý o dimenzi 1 (přímka sama je tedy dvojdimenzionální). V případě roviny je průsečíkem kružnice o dimenzi 2. Touto definicí však dokážeme popsat pouze celočíselné dimenze.

Vhodnější definice je takzvaná „Box dimension“. Uvažujme koule o průměru  $\varepsilon$ , kde  $N(\varepsilon)$  je nejmenší počet takových koulí potřebný k pokrytí objektu. Dimenze je potom určena vztahem 2.1. Aplikujeme tuto metodu na Kochovu vločku. Každý úsek vločky vzniká tak, že původní rovnou přímku rozdělíme na tři stejné díly o délce  $\varepsilon = 1/3$ , přičemž prostřední nahradíme dvěma díly každý rovněž o délce  $1/3$  (toto dobře demonstruje Obrázek 2.1 první iterace). Počet potřebných segmentů je tedy  $N(\varepsilon) = 4$ . Dosazením do vztahu 2.1 potom dostáváme výslednou dimenzi Kochovy vločky  $D_b = 1,26$ . (Falconer, 2003)

$$D_b = \frac{\log N(\varepsilon)}{\log\left(\frac{1}{\varepsilon}\right)} \quad (2.1)$$

Stejného výsledku dosáhneme použitím „Hausdorffovi dimenze“. Máme-li objekt složený ze  $N$  stejných prvků o velikosti  $r$ . Potom platí vztah 2.2, kde  $D$  je hledaná dimenze. Například rozdělíme-li plochu na 4 stejné čtverce, každý o straně  $1/2$ . Potom je dimenze 2.

Zlogaritmováním a upravením vztahu 2.2 dostáváme v tomto případě totožný tvar se vztahem 2.1. (Pollicott, 2005)

$$N = r^D \quad (2.2)$$

Pro výpočet fraktální dimenze časové řady se využívá několik algoritmů. Například Higuchiho, Petrosian, Katzův, Box counting a další. V námi diskutovaných pracích byl využit Katzův algoritmus. Tento algoritmus definuje fraktální dimenzi vztahem 2.3, kde  $L$  je celková délka časové řady a  $d$  je vzdálenost mezi prvním bodem řady a bodem který je od tohoto nejvzdálenější. Aby byl algoritmus nezávislý na použitých jednotkách vzdálenosti, zavádí se takzvaný „yard stick“  $a$  jako průměrná vzdálenost mezi dvěma sousedními body. Potom platí, že celkový počet bodů časové řady  $n = L/a$ . Dosazením do 2.3 a upravením dostáváme výsledný vztah Katzova algoritmu 2.4. (Katz, 1988)

$$FD = \frac{\log L}{\log d} \quad (2.3)$$

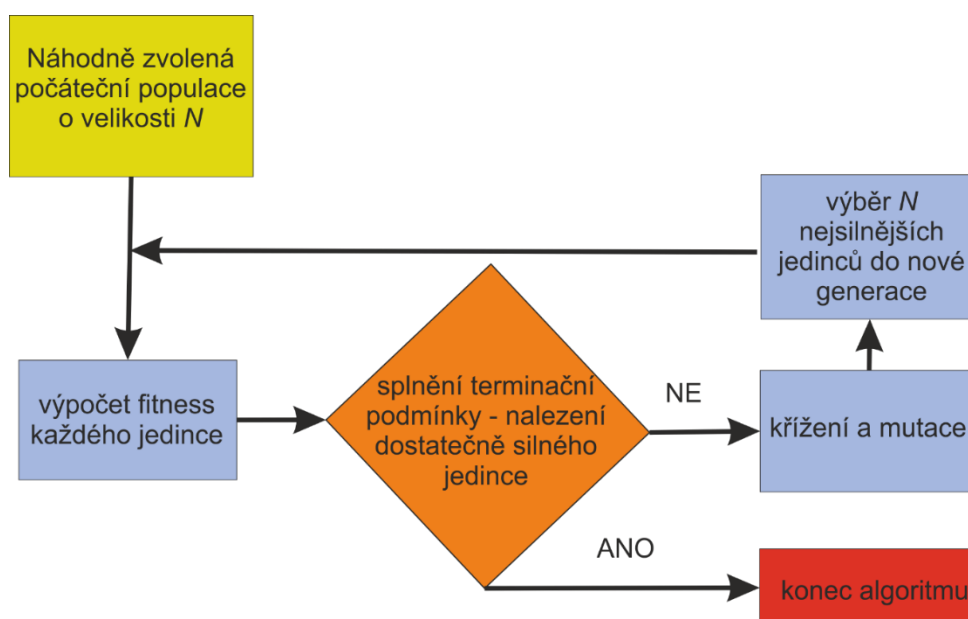
$$FD = \frac{\log n}{\log\left(\frac{d}{L}\right) + \log n} \quad (2.4)$$

## 2.2. Evoluční algoritmy

Evoluční algoritmy patří mezi takzvané optimalizační algoritmy. Snaží se o optimalizace (minimalizaci nebo maximalizaci) předem dané funkce pomocí nastavení jejich vstupních parametrů. Potencionálních aplikací těchto algoritmů je nespočet. V případě adaptivní segmentace se u novějších metod využívají pro optimalizaci vstupních parametrů WL a STEP.

Přestože existuje mnoho různých evolučních algoritmů, základní myšlenka je u všech stejná. V populaci individuálních organismů způsobuje tlak prostředí přírodní selekci, neboli přežití nejsilnějších. Tímto způsobem dochází k celkovému nárůstu „síly“ (označuje se jako fitness) v celé populaci a k evoluci druhu (odtud název evoluční algoritmy). Nová generace jedinců může vznikat dvěma způsoby. Mutací a/nebo křížením. Mutace probíhá

na jednom jedinci, který změní své vlastnosti, čímž vznikne jedinec nový. Křížení se používá u dvou jedinců nazývaných rodiče a výsledkem je jeden nebo více nových jedinců, potomků, přičemž rodičům na rozdíl od mutace zůstávají původní vlastnosti. Nově vzniklí jedinci následně soutěží se starou generací o místo v generaci nové. Do té se dostane pouze omezený počet (daný předem nastavenou velikostí populace) nejlepších jedinců – majících nejlepší hodnotu fitness. Tento proces modifikace vlastností a následného výběru je opakován do té doby, než je nalezen jedinec požadované kvality, nebo je dosažen předem určený počet opakování. Proces zlepšování populace je hnán dvěma základními faktory. První je samotný proces selekce nejlepších jedinců v každé iteraci algoritmu. Druhý je určitý díl náhody, její váha se liší metodu od metody, která působí při tvorbě vlastností nových jedinců (potomků) ať už formou mutace, či křížení. Schéma obecného evolučního algoritmu ukazuje Obrázek 2.2. (Eiben a Smith, 2003)




**Obrázek 2.2.** Obecné schéma evolučního algoritmu. Nejprve je náhodně zvolena počáteční populace (skupina jedinců majících definované vlastnosti/vstupní parametry), u které je následně pro každého člena vypočítána hodnota fitness definovaná testovanou funkcí. Dále algoritmus pokračuje cyklem křížení a mutací za účelem vytvoření nejsilnějšího jedince (s nejlepšími vlastnostmi). Tento cyklus je ukončen buď dosažením maximálního počtu iterací, nebo dosažením dostatečné síly jedince. Výsledkem algoritmu je kombinace nejvhodnějších vlastností/vstupních parametrů pro dosažení optimálního výstupu sledované fitness funkce.

## Kapitola 3

### Software pro testování metod AS

V této kapitole se krátce věnuji samotnému programu, který jsem vytvořil pro porovnávání jednotlivých metod AS (adaptivní segmentace) a testování vlivu jejich vstupních parametrů.

Tato práce volně navazuje na mou bakalářskou práci (Kala, 2014), ve které jsem vytvořil program pro načítání a základní práci s EEG záznamy. V této práci jsem program doplnil několika funkcemi pro adaptivní segmentaci EEG signálu různými metodami a pro porovnání metod navzájem. Veškerou programovací část jsem dělal v programovacím prostředí MATLAB®. Program se spouští skriptem *EEG\_GUI*.



**Obrázek 3.1.** Modul pro testování parametrů AS. Vlevo panely pro ovládání. Shora: panel pro nastavení hodnot vstupních parametrů a hodnoty přepočítané na vzorky, lišta pro výběr segmentační metody, tlačítko pro zahájení segmentace, specifické panely vybrané metody, obecné parametry segmentovaného signálu. Vpravo pole pro zobrazení segmentovaného signálu, charakteristických funkcí dle vybrané metody a  $G$  funkce. Červené tečkované vertikální linky značí jednotlivé hranice

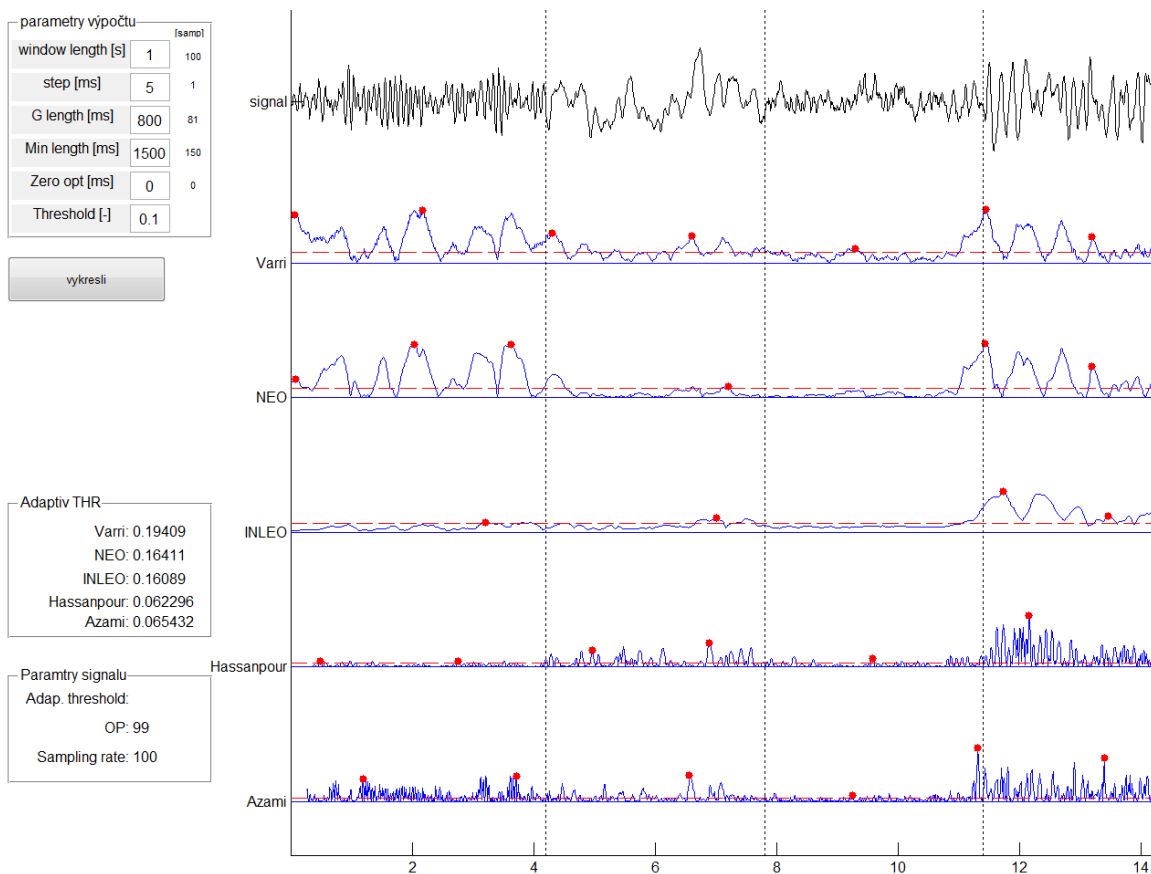
Obrázek 3.1 ukazuje vytvořené prostředí pro testování parametrů segmentačních metod. Toto prostředí je v příloženém kódu vytvářeno skriptem *segmentationM\_GUI* a jednotlivé segmentační metody jsou implementovány pomocí funkce *segmentationM*. Nejdůležitější je zde panel pro nastavení hodnot jednotlivých parametrů, který detailněji ukazuje Obrázek 3.2. Kromě tohoto panelu obsahuje prostředí vyklápěcí lištu pro výběr segmentační metody a parametry aktuálně segmentovaného signálu. Navíc je zde panel pro další parametry a ovládací prvky specifické pro jednotlivé segmentační metody. Tlačítka „Hold“ a „Drop“ zde slouží k uložení a vymazání nalezených hranic. Takto uložené hranice se následně zobrazují společně s nově nalezenými hranicemi. Celé prostředí je velmi jednoduché a jeho ovládání intuitivní.

parametry výpočtu		[samp]
window length [s]	1	128
step [ms]	5	1
G length [ms]	800	103
Min length [ms]	1500	192
Zero opt [ms]	0	0
Threshold [-]	0.2	

**Obrázek 3.2.** Detail panelu pro nastavení hodnot jednotlivých vstupních parametrů metody

Druhým vytvořeným modulem je prostředí pro porovnání segmentací provedených všemi metodami najednou. V příloženém kódu se jedná o funkce *segmentace1\_GUI* a *segmentace1*. Tento nástroj je velmi užitečný potřebujeme-li zaznamenat výsledky více metod pro jednu kombinaci parametrů, jelikož nemusíme neustále přepínat mezi jednotlivými metodami. Modul ukazuje Obrázek 3.3. Panel sloužící pro nastavení jednotlivých parametrů je zde totožný jako v předchozím modulu, pouze parametr THR je zde neaktivní. Místo globálního nastavování THR pro všechny metody je parametr určován adaptivně pro každou metodu zvlášť jako 2/3 střední hodnoty *G* funkce aktuálně zpracovávanému úseku signálu. Hodnoty těchto adaptivních THR parametrů jsou zobrazeny v panelu vlevo uprostřed. V pravé části je opět vidět segmentovaný signál a

následně  $G$  funkce odpovídající jednotlivým segmentačním metodám. Nalezené hranice jsou potom pro každou z metod zobrazeny červenými kruhovými značkami.



**Obrázek 3.3.** Ukázka prostředí pro porovnání metod mezi sebou na simulovaném signálu. Vlevo ovládací panely obdobné předchozímu modulu, Vpravo segmentovaný signál a  $G$  funkce příslušící jednotlivým segmentačním metodám. Červené kruhové značky na  $G$  funkcích značí detekované hranice

## Kapitola 4

### Porovnání současných metod


V této kapitole se budu zabývat srovnáním současných metod uvedených výše v teoretické části. Problematika porovnávání metod adaptivní segmentace má několik úskalí, které jí dělají obtížně uchopitelnou. První a nejdůležitější je fakt, že segmentace EEG signálu je obecně mimetický proces. Tedy proces, který napodobuje práci lékaře. A stejně tak, jako se mohou lišit segmentace provedené dvěma různými lékaři (nebo dokonce jedním lékařem při opakované segmentaci), mohou se i výsledky dvou různých metod AS mírně odlišovat, aniž jsme schopni říct, která z nich je lepší. V této fázi, se do počítačových metod silně promítá subjektivní pohled na problematiku. Každý lékař by signál rozsegmentoval po svém a tudíž nejde přesně definovat, jakou segmentaci považovat za správnou, což velmi znesnadňuje proces vyhodnocení spolehlivosti počítačových metod. K tomu se navíc přidává fakt, že v některých chvílích potřebujeme mírně odlišnou segmentaci než v jiných. Například pokud lékař sleduje pouze přítomnost epileptické aktivity, stačí mu signál rozdělit na tuto aktivitu a ostatní signál. Pokud ho ale zajímá charakter samotné aktivity, je potřeba signál segmentovat mnohem jemněji. Podobných příkladů lze nalézt mnoho, což je další důvod, proč nelze jednoznačně definovat požadovaný výsledek segmentace. Z výše uvedených důvodů je extrémně obtížné, ne-li úplně nemožné vyhodnocovat spolehlivost metody statisticky na reálných záznamech (není možné určit jednoznačný požadovaný výsledek). V této práci jsem metody testoval na uměle vytvořeném autoregresivním signálu (viz níže), u kterého jsou hranice jasně definovány již při jeho vzniku. Opět ale nelze s jistotou říci, že by se signál nedal segmentovat jiným způsobem, který by rovněž dával smysl.

Další komplikace při srovnávání metod je dána použitím odlišných parametrů k ladění metody. Právě tyto vstupní parametry jsou přímo zodpovědné za kvalitu výsledné segmentace. Konkrétně metody Varri, NEO a INLEO popisují ovládání segmentace pomocí kombinace parametrů WL a DWL s krokem STEP=1 vzorek. Zatímco novější

metody (Hassanpour, 2009) a (Azami, 2013) nechávají DWL konstantní a mění WL a STEP. Rovněž pro jednotlivé metody mohou být vhodnější jiné hodnoty parametrů než pro ostatní. V této práci proto testuji jednotlivé metody jak při ovládní pomocí kombinace WL+DWL, tak WL+STEP.

## 4.1. Autoregresní signál pro testování metod

Jak bylo již zmíněno výše, není vhodné používat pro srovnávání metod reálné záznamy, jelikož je u nich problém definovat, jaká segmentace je správná a hlavně která správná není. Proto jsem pro testování vytvořil uměle vytvořený signál vzniklý na základě autoregresního filtru, který je svým charakterem velmi podobný reálnému EEG signálu (Krajča, 1991). Takto vytvořený signál se skládal ze čtyř opakujících se částí o přesně definovaných hranicích. Použité koeficienty AR filtru pro jednotlivé části byly  $(-1.386, 0.81)$ ,  $(-1.736, 0.756)$ ,  $(-1.25, 0.39)$  a  $(-1.692, 0.81)$ . Délka jednotlivých segmentů se pohybuje okolo 3-4 sekund, vzorkovací frekvence 100 Hz. Tento signál byl následně rozložen do více kanálů tak, že byl v každém následném kanálu posunut o 1,5 sekundy oproti kanálu předchozímu. Tímto způsobem bylo zajištěno, že se hranice segmentů v jednotlivých kanálech nenacházejí ve stejném čase. Pomocí tohoto vícekanálového signálu bylo možno testovat schopnost nezávislé multikanálové segmentace. Použitý signál ukazuje Obrázek 4.1.



**Obrázek 4.1.** Vícekanálový autoregresní signál s přesně definovanými hranicemi segmentů pro testování metod. Červené vertikální čáry označují hranice segmentů (místa změny koeficientů autoregresního filtru).



## 4.2. Metodika vyhodnocení spolehlivosti

Pro každou sledovanou kombinaci vstupních parametrů jsem vypočítal faktor spolehlivosti  $P$  (přesnost metody). Tento faktor zahrnuje jak schopnost metody zachytit skutečné hranice autoregresního signálu (tyto hranice byly přesně definovány při tvorbě signálu), tak odolnost metody proti tvorbě falešných hranic mimo skutečné hranice segmentů a byl vypočítán následujícím vztahem 4.1.

$$P = \frac{k \cdot \text{Senzitivita} + l \cdot \text{Rezistence}}{\text{Senzitivita} + \text{Rezistence}} \quad (4.1)$$

Jedná se v podstatě o vážený průměr senzitivity a rezistence metody. Váhy  $k$  a  $l$  byly určeny heuristicky jako 4 a 1. Tyto hodnoty vychází z faktu, že u AS je mnohem důležitější schopnost nalézt skutečné hranice signálu, než se vyhnout falešně pozitivním nálezům. Falešná pozitivita jde totiž na rozdíl od falešné negativity kompenzovat během dalšího zpracování signálu, konkrétně klasifikace. V průběhu klasifikace dochází k zařazení redundantních úseků vzniklých falešně pozitivním určením hranice do jedné společné třídy a následně je s nimi rovněž jako s jednou třídou zacházeno.

$$\text{Senzitivita} = \frac{TP}{TP + FP} \quad (4.2)$$


$$\text{Rezistence} = 1 - FPR \quad (4.3)$$

Pro určení senzitivity a rezistence dle vztahů 4.2 a 4.3 bylo nejprve potřeba pro každou metodu a kombinaci vstupních parametrů spočítat počet falešně pozitivních (FP), negativních (FN) a skutečně pozitivních nálezů (TP). Hodnota skutečně negativních nálezů (TN) v našem případě nelze určit. (Jedná se v podstatě každý vzorek signálu, kde nebyla určena hranice – u spojitého signálu jde TN k nekonečnu). Namísto toho jsem určil nejvyšší množství špatných detekcí ( $N$ ) jako maximální počet nadbytečných detekcí při vyložení přecitlivělé segmentaci).

$$FPR = \frac{FP}{N} \quad (4.4)$$

Vztah 4.4 definuje výpočet  $FPR$  potřebný pro výpočet rezistence.  $FPR$  udává poměr přebytečných hranic k množství takovýchto hranic nalezených při nejhorší, evidentně přecitlivělé segmentaci. Nabývá tedy hodnot v intervalu  $(0, 1)$ . Rezistence metody je potom určena jako doplněk  $FPR$  dle již zmíněného vztahu 4.3.

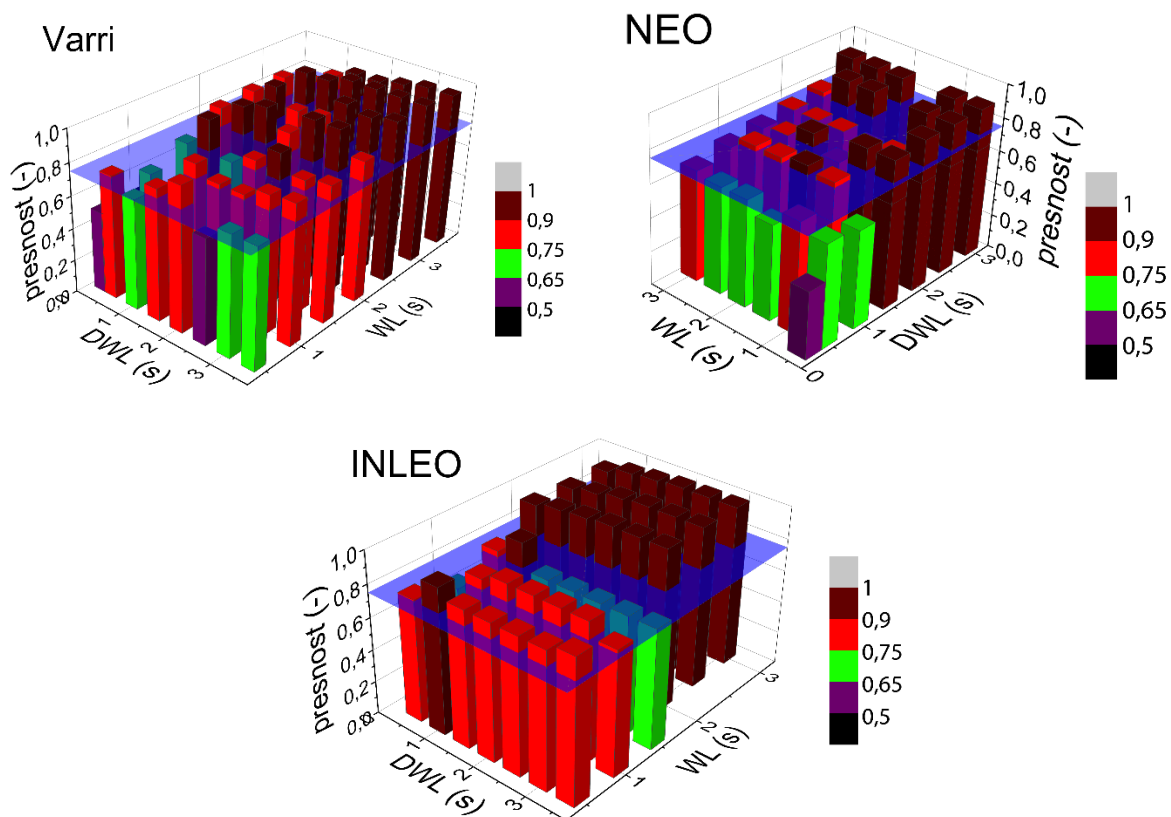
Pro zjištění hodnot  $FP$ ,  $FN$  a  $TP$  jsem vytvořil modul k programu *Prohlížeč EEG* (Kala, 2014), který popisuje Kapitola 3. Pomocí něj jsem načtl předem vytvořený autoregresní signál o přesně definovaných hranicích segmentů, který jsem následně segmentoval paralelně všemi metodami. Ukázkou výstupu z programu zobrazuje Obrázek 4.2.



**Obrázek 4.2.** Ukázkový výstup programu pro vyhodnocení metod. Nahoře segmentovaný signál, dále postupně  $G$  funkce při segmentaci různými metodami (Varri, NEO, INLEO, Hassanpour, Azami). Parametry použité pro tuto segmentaci byly  $WL=2$  s,  $STEP=250$  ms,  $DWL=30$  ms,  $MSL=1500$  ms a  $THR$  byla nastavena adaptivně pro každou z metod zvlášť jako  $2/3$  střední hodnoty aktuálně zpracovávané  $G$  funkce. Červené puntíky na  $G$  funkcích označují detekovaná lokální maxima uznané jako hranice segmentů. Vertikální čárkované linky značí skutečné hranice segmentů. Je vidět, že např. pro Varriho metodu je při této konfiguraci vstupních parametrů  $TP=4$ ,  $FP=3$  a  $FN=1$ . Obdobné určení bylo při srovnávání provedeno pro všechny metody a vybrané kombinace parametrů

### 4.3. Srovnání metod pro kombinaci parametrů WL + DWL

Ladění metody pomocí dvojice parametrů WL (délka okna) a DWL (velikost okénka pro detekci vrcholů  $G$  funkce) bylo navrženo v (Krajča, 1991). Tento způsob ovládání je vhodný pouze pro metody Varri, NEO a INLEO. U novějších metod se tato kombinace nepoužívá, a proto jsem je při srovnávání touto kombinací vynechal. Následující grafy ukazují přesnost jednotlivých metod vypočítanou dle vztahu 4.1 v závislosti na použité kombinaci vstupních parametrů.



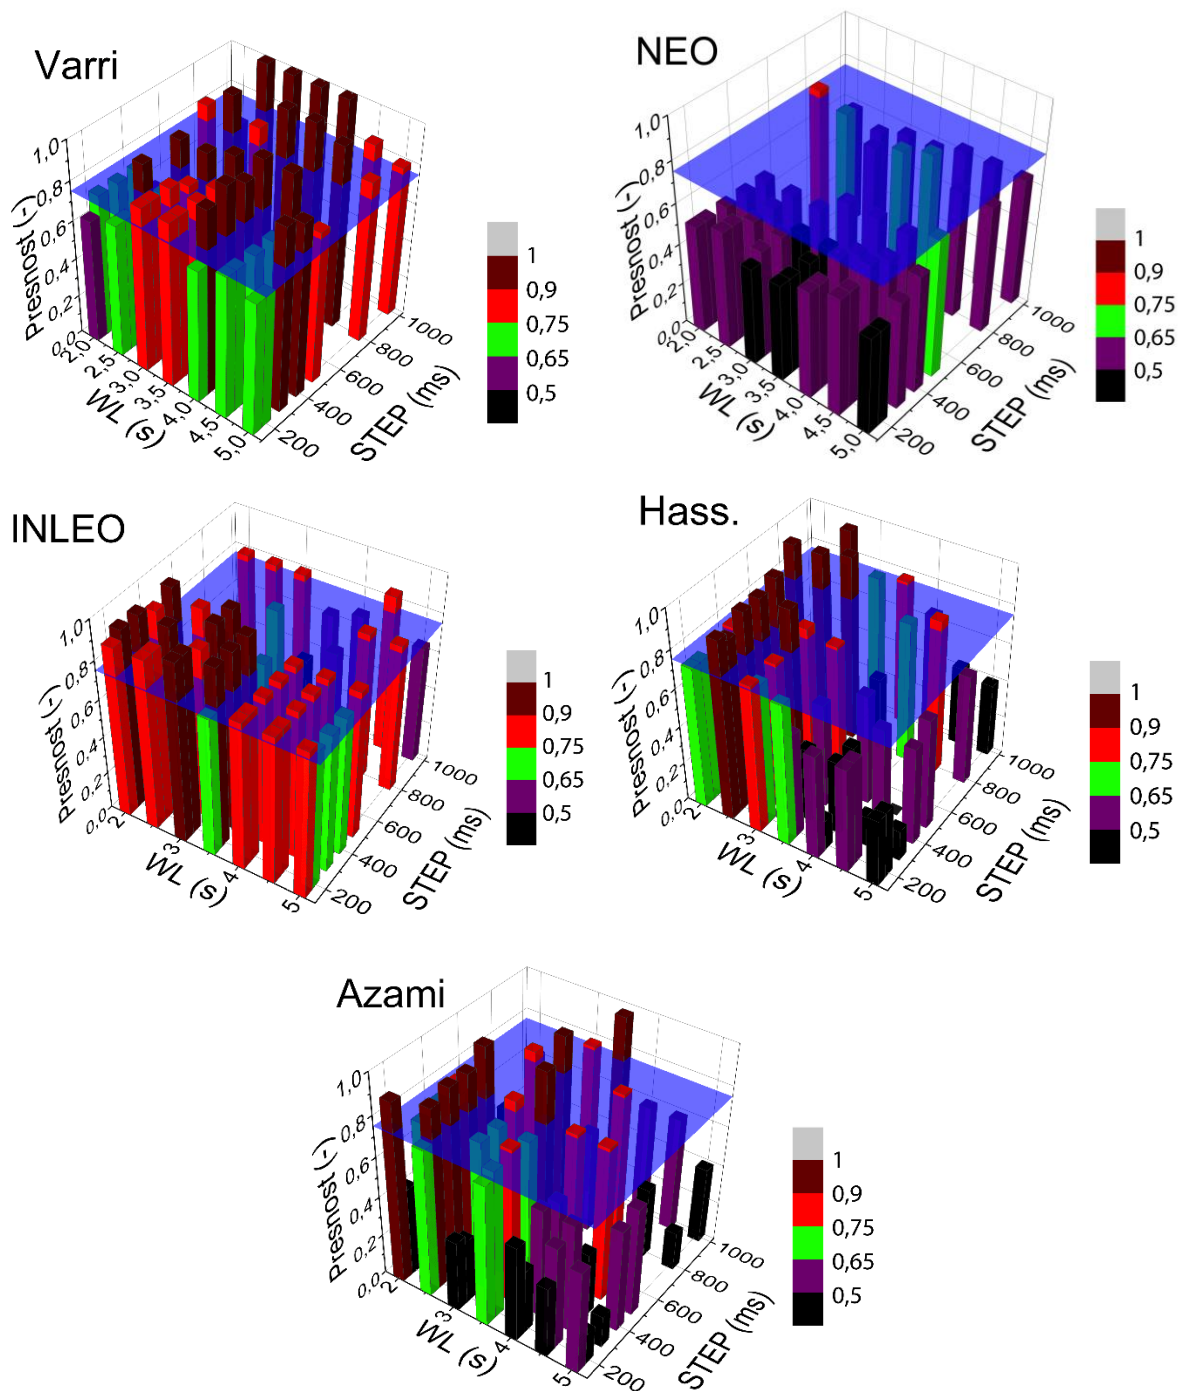
**Obrázek 4.3.** Přesnost jednotlivých metod v závislosti na zvolené kombinaci vstupních parametrů WL+DWL. Modrá plocha označuje hranici 75% přesnost. Osy v podstavě grafu definují hodnoty jednotlivých parametrů DWL a WL, vertikální osa potom míru přesnosti metody v rozmezí  $\langle 0,1 \rangle$ . Přesnost je zároveň zobrazena barevnou škálou

#### 4.4. Srovnání metod pro kombinaci parametrů WL + STEP

Dále jsem testoval přesnost metod při ladění pomocí kombinace parametrů WL (délka okna) a STEP (velikost kroku algoritmu). Toto ovládání bylo navrženo v (Hassanpour, 2009) avšak jde použít i pro starší metody. Přesnost jednotlivých metod graficky znázorňuje Obrázek 4.4.

Z grafů je zjevné, že pro metodu NEO je tato kombinace absolutně nevhodná. Při zvýšení parametru STEP dosahuje metoda žalostných výsledků. Naopak Varriho metoda reaguje na zvyšování STEP výrazným zlepšením přesnosti. V grafu je rovněž dobře pozorovatelný „hřeben“ hodnot se stabilně vysokou přesností při hodnotách WL 3 a 3,5 sekundy. Tyto hodnoty WL vykazovali dobrou přesnost i v předchozí části (Obrázek 4.3). Metoda INLEO na rozdíl od metody Varri snižuje svou přesnost se zvyšující se hodnotou STEP. Nejlepších výsledků tak dosahuje v oblasti nízkých WL i STEP.

Poslední dvě metody, Hassanpour a Azami, se chovají navzájem velmi podobně. Z toho lze soudit, že pro adaptivní segmentaci není příliš velký rozdíl, jestli byl na signál jako předzpracování použit Kalmanův filtr (Hassanpour) nebo vlnková transformace (Azami), jelikož kromě odlišného předzpracování se vlastní algoritmy obou metod téměř neliší. Obě metody jsou velmi nestabilní a obzvláště ve vyšších hodnotách WL dosahují špatných výsledků. Tyto metody však namísto robustnosti spoléhají na zvolení optimálních parametrů pomocí optimalizačních algoritmů. Pokud jsou parametry takto optimalizovány správně, dosahují obě metody výborných výsledků (často až 100%). Použití optimalizace je však činí pomalé a výpočetně velmi náročné a tudíž nevhodné pro online zpracování EEG záznamů.



**Obrázek 4.4.** Přesnost jednotlivých metod v závislosti na zvolené kombinaci vstupních parametrů WL+STEP. Modrá plocha označuje hranici 75% přesnost. Osy v podstavě grafu definují hodnoty jednotlivých parametrů WL a STEP, vertikální osa potom měří přesnosti metody v rozmezí  $<0,1>$ . Přesnost je zároveň zobrazena barevnou škálou

## Kapitola 5

### Nově navržené parametry

Na základě srovnání z předchozí kapitoly jsem jako nejvhodnější metodu pro segmentaci EEG signálu zvolil Varriho metodu dvou spojených oken. Ta prokázala jak dostatečnou přesnost a robustnost, tak i jednoduchost, která jí činí vhodnou pro online použití. Metoda byla již popsána v kapitole 1.3 a její základní parametry v kapitole 1.4. V této kapitole popisují několik nově přidaných parametrů, jejichž správným použitím lze schopnosti metody ještě vylepšit.

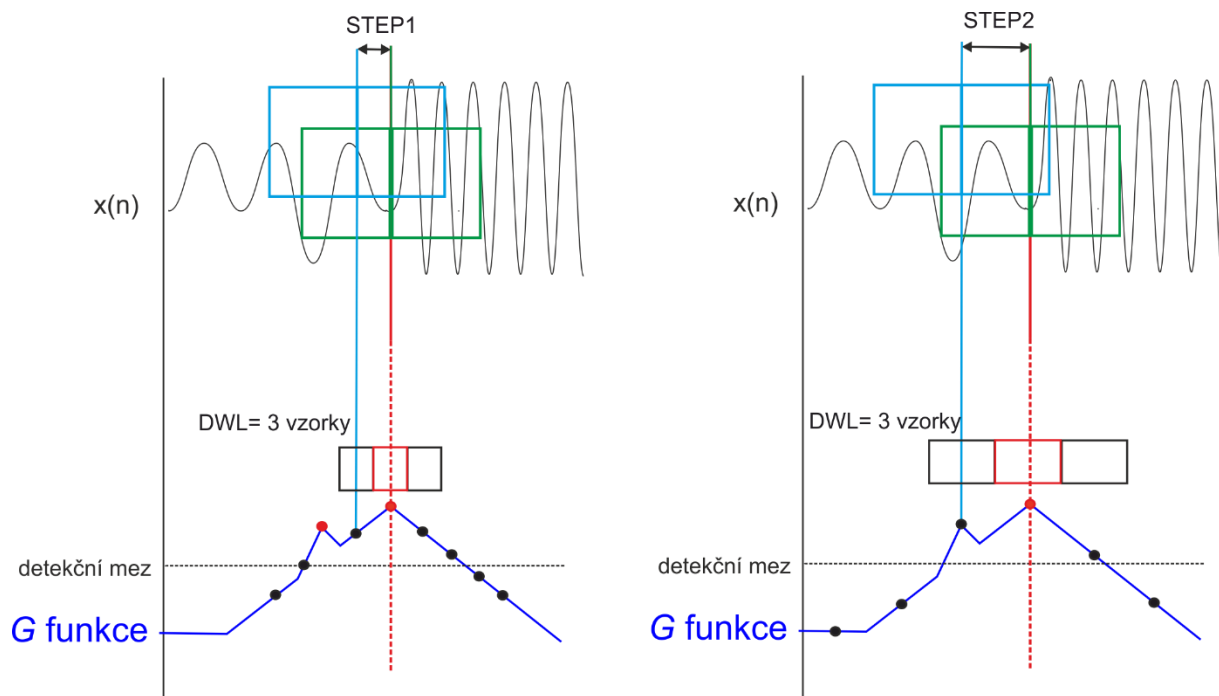
#### 5.1. Nové parametry Varriho metody

Metoda byla navržena Krajčou a Värrim (1991). Princip metody a základní vstupní parametry byl již částečně popsán v úvodní kapitole 1.4. Z důvodu konzistence textu uvádím přehled původních parametrů i zde společně s parametry novými.

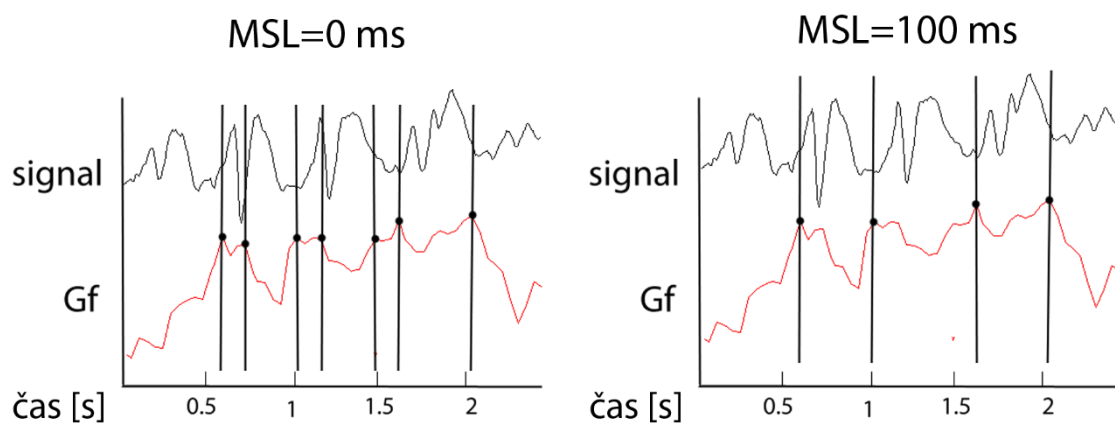
**Tabulka 5.1.** Přehled původních i nových parametrů Varriho metody AS

Zkratka	Název	Jednotka	Popis
WL	Window length	s	Délka dvojoka klouzajícího po signálu
STEP	Step	ms	Délka kroku iterace algoritmu (vzdálenost dvou následujících dvojoken)
DWL	Detection window length	ms (vzorek)	Velikost detekčního okna
THR	Threshold	%	Detekční mez
<b>Nově navržené parametry</b>			
MSL	Minimal segment length	ms	Minimální možná délka detekovaných segmentů
ZO	Zero optimization	ms	Maximální možný posun nalezené hranice během procesu optimalizace

První nový navržený parametr nazývám minimální délku segmentu (MSL). Při použití kratšího WL často dochází k příliš citlivé segmentaci (tedy k vzniku mnoha redundantních segmentů). Tento efekt byl v původní publikaci kompenzován nastavením vyšší hodnoty DWL. Tato kompenzace byla vhodná v případě, kdy jsme k ovládní metody využívali kombinaci parametrů WL+DWL. V případě použití dvojice WL+STEP se však stává nevhodnou, jelikož parametry DWL a STEP se navzájem ovlivňují. Tuto závislost znázorňuje Obrázek 5.1. K pochopení tohoto problému je třeba nejprve zmínit fakt, že ačkoliv jsou parametry definovány v časových jednotkách (z důvodu obecnosti hodnot při různých vzorkovacích frekvencích signálů), při samotném algoritmu AS jsou vnímány jako množství vzorků, na kterých je daná operace prováděna. Vyšší hodnoty STEP potom způsobují, že je vzniklá  $G$  funkce vzorkována s nižší frekvencí (tvořena méně body). Stejně DWL zabírá potom při takovémto STEP delší časový úsek, ve kterém hledá lokální maximum. Některé menší vrcholy tak nemusí být nalezeny a naopak vrcholy, které bychom chtěli potlačit, u menších hodnot STEP potlačeny být nemusí. Z tohoto důvodu jsem definoval parametr MSL, který nahrazuje parametr DWL a zároveň je na hodnotě STEP zcela nezávislý. Rozdíl v segmentaci s použitím parametru MSL a bez jeho použití ukazuje Obrázek 5.2.



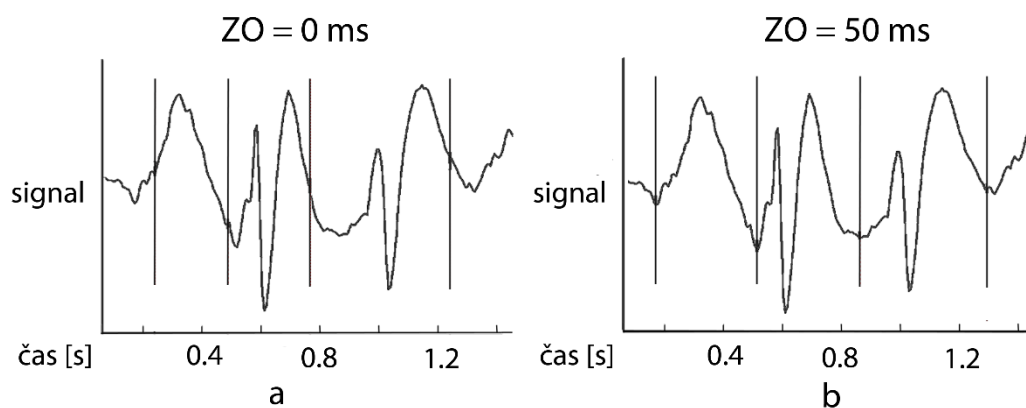
**Obrázek 5.1.** Ukázka funkční závislosti parametrů DWL a STEP. DWL je v obou částech stejné a odpovídá hodnotě 3 vzorky. Vlevo je použit kratší STEP.  $G$  funkce se proto skládá z více vzorků (je vzorkována s vyšší frekvencí) než vpravo, kde je hodnota STEP vyšší. DWL v algoritmu definuje počet vzorků, mezi nimiž je definováno lokální maximum. S vyšším vzorkováním  $G$  funkce vlivem kratší hodnoty STEP vlevo, tak 3vzorkové DWL zabírá kratší časový úsek než vpravo, což vede k jemnější detekci. Modře a zeleně jsou naznačeny dvě po sobě jdoucí pozice dvojokna, černé tečky na  $G$  funkci ukazují body ze kterých je tvořena, červené body jsou body detekované jako lokální maximum a tím určeny jako hranice segmentů



**Obrázek 5.2.** Ukázka segmentace reálného signálu bez použití MSL (vlevo) a s použitím  $MSL = 100$  ms (vpravo). Vlevo můžeme pozorovat velmi citlivou segmentaci projevující se vytvořením příliš krátkých segmentů. Tento efekt je redukován použitím MSL vpravo, kde již dochází ke správnému oddělení epileptických komplexů hrot-vlna. Nahoře je zobrazen signál, dole  $G$  funkce v čase. Vertikální čáry ukazují detekované hranice segmentů



Další přidaný parametr se nazývá Zero Optimization (ZO). Tento parametr určuje velikost okolí kolem nalezené hranice, ve kterém algoritmus vyhledává nejmenší hodnotu, kam následně hranici přesune. Tento proces imituje segmentaci lékařem. Často je totiž hranice Varriho metodou určena uprostřed náběžné nebo sestupné hrany hrotu, zatímco lékař by jí intuitivně posunul na začátek, popřípadě konec hrany (tedy do nejnižší hodnoty). Parametr ZO zajišťuje pro lékaře přirozenější umístění hranic. Použití parametru demonstruje Obrázek 5.3.



**Obrázek 5.3.** Vliv parametru zero optimization (ZO) vlevo bez použití parametru (ZO=0), vpravo ZO=50 ms. Použití parametru vpravo způsobilo mírný posun hranic do vhodnějších pozic, imitující vizuální segmentaci prováděnou lékařem

## Kapitola 6

### Segmentace epileptické aktivity

Jak již bylo řečeno v úvodu, náročnost (hlavně časová) manuálního vyhodnocování EEG záznamů vede ke snaze o vytvoření automatizovaného systému, který by lékaři tuto práci ulehčoval. Součástí tohoto systému je i proces adaptivní segmentace, který původní signál rozdělí na kratší úseky, které jsou lépe matematicky zpracovatelné. Kvalita této segmentace se přímo projevuje v kvalitě výstupu celého systému. Je tedy žádoucí, aby byla segmentace provedena co nejlépe. Kvalita vlastní segmentace se odvíjí od použité metody a konkrétním nastavení jejích vstupních parametrů. Znalost vhodných parametrů je tedy pro správnou segmentaci, a tím i pro kvalitní výsledky automatického rozpoznávání, absolutně nepostradatelná.

Tato kapitola se zabývá vlivem jednotlivých vstupních parametrů na výsledek segmentace epileptických záznamů pomocí Varriho metody dvou spojených oken. Na epileptickou aktivitu se zaměřuji kvůli jejímu zcela odlišnému charakteru oproti ostatním běžným fyziologickým aktivitám (frekvence výskytu sledovaných grafoelementů je zde vyšší a jejich vlastní trvání je výrazně kratší), což nás nutí přistupovat i k její segmentaci odlišným způsobem. Tato kapitola se podrobně zabývá specifickými hodnotami vstupních parametrů Varriho metody AS vhodnými pro segmentování epileptické aktivity.

#### 6.1. Epileptická aktivita

Epilepsie je epizodická neurologická porucha, charakterizována nadměrnou nekontrolovatelnou aktivitou (záchvaty) části nebo celého centrálního nervového systému. Její výskyt je pozorován po celou dobu zaznamenané lidské historie. *„Jedná se o nemoc biologického základu, jejíž příčina je v mozku, nemá tedy nic společného s duševními poruchami a jen výjimečně vede ke snížení inteligence.“* (Matthes, 2003). Podle WHO (World Health Organization) je epilepsie druhým (hned po depresi) nejčastějším onemocněním mozku (Engel, 2008).

V posledním půl století byl v problematice epilepsie učiněn výrazný krok vpřed. Obecný pokrok v neurologických vědách vedl k lepšímu porozumění nemoci a zároveň díky vyvinutí nových léků (antiepileptik) byla výrazně snížena úmrtnost na toto onemocnění (Rho, 2010). Aby mohla být nemoc úspěšně léčena, je potřeba kvalitní diagnostika. Ta je založena na kompetentním klinickém úsudku, přičemž EEG vyšetření přináší k tomuto úsudku nejspeciřtější informace. *„Jde o vystření velmi cenné, v mnohých případech nezastupitelné, je však nutno nálezy správně hodnotit, popisovat a interpretovat. V opačném případě se může cenné využití metody změnit v její nekompetentní zneužití.“* (Hovorka, 2003)

Epileptická aktivita se rozděluje do dvou skupin. Iktální aktivita, odpovídající samotnému záchvatu, se na EEG projevuje rychlými polymorfickými vlnami s proměnlivou amplitudou a frekvencí, mnohočetnými hroty a komplexy hrot-ostrá vlna. Naproti tomu interiktální aktivita obsahuje více osamocených hrotů, ostrých vln a komplexů hrot-vlna. (Tzallas, 2012). Ve své práci se zabývám jak segmentací iktální aktivity, kde je potřeba zejména odlišit tuto aktivitu od okolního neepileptického signálu, tak segmentací osamocených hrotů a komplexů během interiktální aktivity. Zejména pro segmentaci kratších osamocených grafoelementů je potřeba navrhnout specifické hodnoty parametrů abychom byly takto krátké segmenty schopny zachytit, jak zde bude rovněž popsáno.

K zjištění toho, jestli je metoda vůbec schopná segmentovat krátké epileptické grafoelementy a jaké parametry k tomu jsou vhodné, jsem nejprve proces testoval na simulovaných signálech. Konkrétně na simulovaných epileptických hrotech, hrotech s pozadím tvořeným autoregresním šumem a pro simulaci větších změn jsem použil přechod dvou sinusových signálů s různou amplitudou a frekvencí. Tato část práce byla prezentována na studentské konferenci IMBM (Kala, 2015).

## 6.2. Simulované epileptické hroty

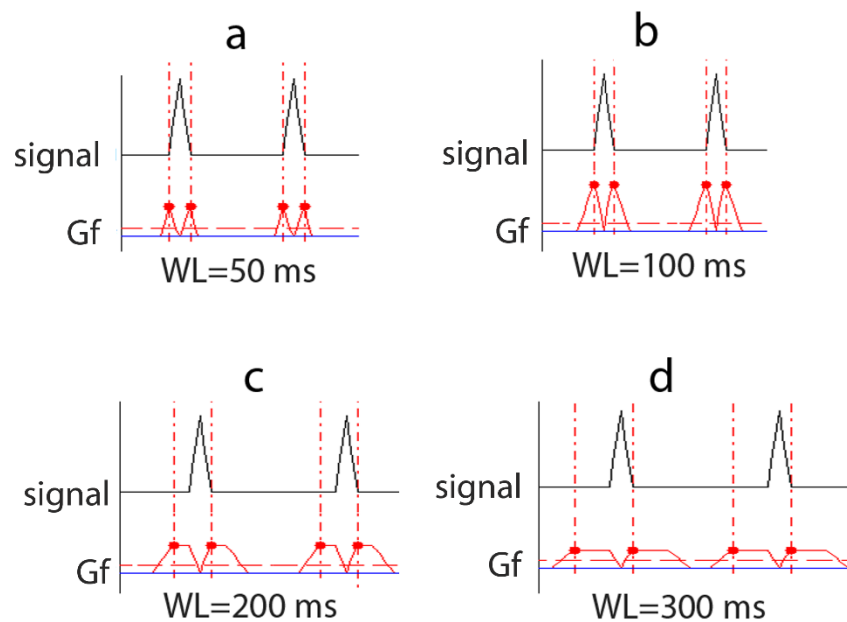
Nejprve jsem segmentační schopnosti testoval na umělých signálech ve tvaru ostré špičky, které mají simulovat krátké osamocené epileptické hroty. Délka takového hrotu se pohybuje okolo 70-100 ms, což se významně liší od běžných segmentů o délce typicky

v jednotkách sekund. Z toho důvodu je potřeba použít zcela jiné hodnoty vstupních parametrů, které zajistí dostatečně citlivou segmentaci. V této části práce byla postupně měněna konfigurace tří parametrů WL, DWL a STEP. Jako standardní detekční limit (THR) byla využita střední hodnota  $G$  funkce. Ve všech testech v této kapitole byl využíván vždy pouze jeden z dvojice parametrů DWL a STEP, zatímco druhý byl nastaven na výchozí (minimální) hodnotu. Bylo tak zabráněno jejich vzájemnému ovlivňování, které bylo popsáno v minulé kapitole. Z toho důvodu nebylo potřeba využít parametr MSL, který by však v případě svého použití plnil stejnou funkci a segmentaci ovlivňoval stejným způsobem jako parametr DWL.

Tabulka 6.1 ukazuje rozpětí parametrů a jim odpovídající segmentační schopnosti při změně WL a následně Tabulka 6.2 při změně STEP. Výsledky rovněž demonstrují Obrázek 6.1 a Obrázek 6.2.

**Tabulka 6.1.** Segmentační vlastnosti při změně WL.  
Pro DWL v rozmezí <30-100>ms a konstantní STEP=10 ms

WL [ms]	Úspěšná Segmentace	WL [ms]	
50	ano	Max. možná	200
100	ano		
150	ano	Normální	100-150
150	ano		
200	ano	Min. možná	50
250	ne		




**Obrázek 6.1.** Vliv parametru WL na segmentaci simulovaného hrotu. Postupné navyšování WL (postupně a-d 50, 100, 200, 300 ms) za konstantního  $DWL=100$  ms a  $STEP=10$  ms vede k roztáhnutí  $G$  funkce a znehodnocení segmentace. Při příliš velkém WL nedokáže algoritmus krátký hrot zachytit

Obrázek 6.1 ukazuje, co se děje s  $G$  funkcí při navyšování WL. Na částech a) a b) WL přibližně odpovídá délce detekovaného hrotu okolo 80 ms, proto má  $G$  funkce rovněž charakter ostrých hrotů s jasným vrcholem. Obrázek 6.1.c ukazuje segmentaci pomocí WL o dvojnásobné délce než délka hrotu. Toto způsobilo rovné plató místo vrcholu na  $G$  funkci, čímž došlo k posunutí hranice dál od patky hrotu. U poslední části (d) ( $W=300$  ms) je tento efekt již natolik závažný, že způsobuje zcela mylnou segmentaci.

**Tabulka 6.2.** Rozpětí STEP vhodného pro segmentaci pro konkrétní WL

WL [ms]	STEP [ms]	
	Max.	Min.
25	25	10
50	35	10
100	40	10
150	45	10
200	40	10
>	-	-
	25	10



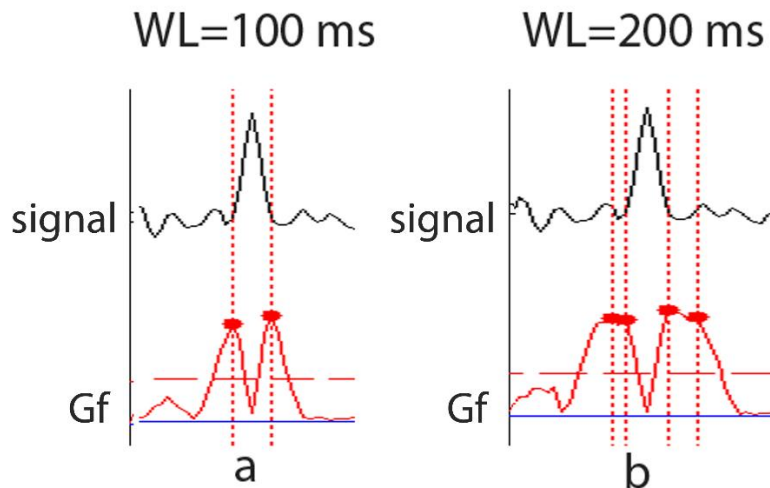
**Obrázek 6.2.** Vliv parametru STEP na segmentaci simulovaného hrotu. Konstantní WL=100 ms, DWL=30 ms a proměnlivý STEP. Vlevo STEP=30; vpravo STEP=50. Zvýšení parametru STEP vede k přehlédnutí některých hranic

Obrázek 6.2 ukazuje rozdílnou detekci při změně hodnoty STEP. Část vlevo ukazuje správnou detekci při WL=100 ms a STEP=30 ms. Naopak v části vpravo došlo k zvýšení STEP na 50 ms, což sice urychlilo výpočetní čas, avšak došlo k přehlédnutí některých hranic.

### 6.3. Simulované hroty s autoregresním signálem

Dále jsem mezi jednotlivé hroty přidal autoregresní signál pro větší podobnost reálnému EEG. Nejprve jsem testoval případ, kdy hroty okolní signál výrazně převyšují (konkrétně mají čtyřnásobnou maximální amplitudu). V tomto případě docházelo podobně jako

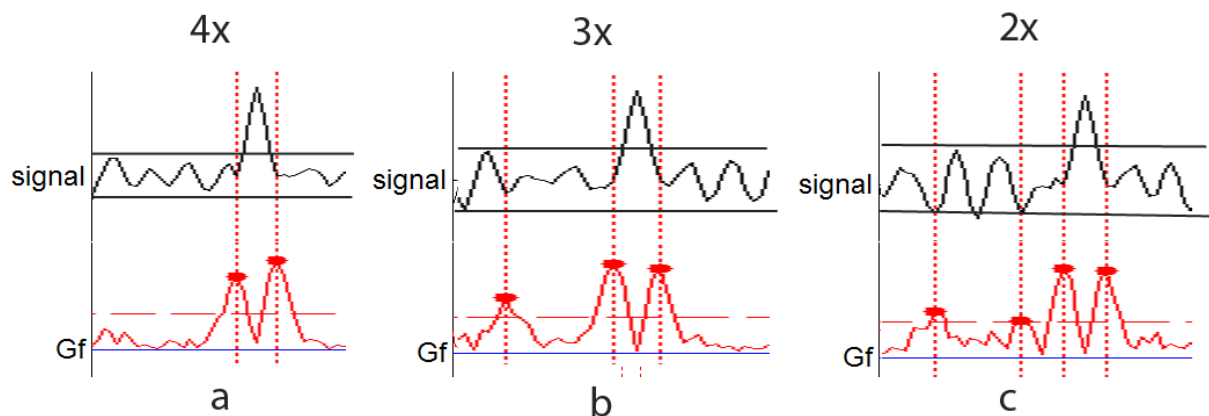
v minulé části k roztažení  $G$  funkce, což v tomto případě způsobilo duplikovanou detekci, jak ukazuje Obrázek 6.3.



**Obrázek 6.3.** Segmentace při zvyšování WL.  $DWL=3$  vzorky,  $STEP=10$  ms. Vlevo  $WL=100$  ms, vpravo  $WL=200$  ms. Dlouhé okno způsobilo roztažení  $G$  funkce a duplikovanou detekci

Stejně jako u špiček bez okolního autoregresního signálu platí, že pro správnou segmentaci je vhodné WL o podobné velikosti jako segmentovaný grafoelement. WL větší jak dvojnásobně způsobuje vícenásobnou detekci. Navyšování WL se dá opět kompenzovat zvyšováním  $DWL$ , ale pouze do té doby, než  $DWL$  dosáhne stejné hodnoty jako je délka nejmenšího detekovaného segmentu. Při překročení této hodnoty již není možné tento segment detekovat.

Epileptický hrot je definován jako ohraničený hrot jasně odlišitelný od pozadí s amplitudou alespoň dvakrát větší než okolní signál. Z tohoto důvodu jsem dále testoval co se děje, blíží-li se poměr hrot/pozadí této hraniční hodnotě dva. Přehledně to ukazuje Obrázek 6.4. Je zde vidět, že čím je amplituda okolního signálu bližší polovině amplitudy hrotu, tím více se promítá do  $G$  funkce a následně může dojít k falešné detekci v místě okolního signálu. Tomuto se dá zamezit nastavením dostatečně vysoké  $THR$ . V případě na obrázku byla využita  $THR = 40\%$  maximální amplitudy  $G$  funkce. Tato hodnota byla přibližně čtyřnásobek střední hodnoty  $G$  funkce. Při takto vysokém  $THR$  však může dojít k potlačení segmentace drobnějších, nebo déle probíhajících změn v signálu.



**Obrázek 6.4.** Vliv poměru amplitudy hrot/pozadí na segmentaci. Čím je poměru menší, tím více se okolní signál promítá do  $G$  funkce a při nízké THR může dojít k falešné detekci. WL=100 ms, STEP=10 ms. THR=40%. Poměr hrot/pozadí postupně (a-c) 4, 3 a 2

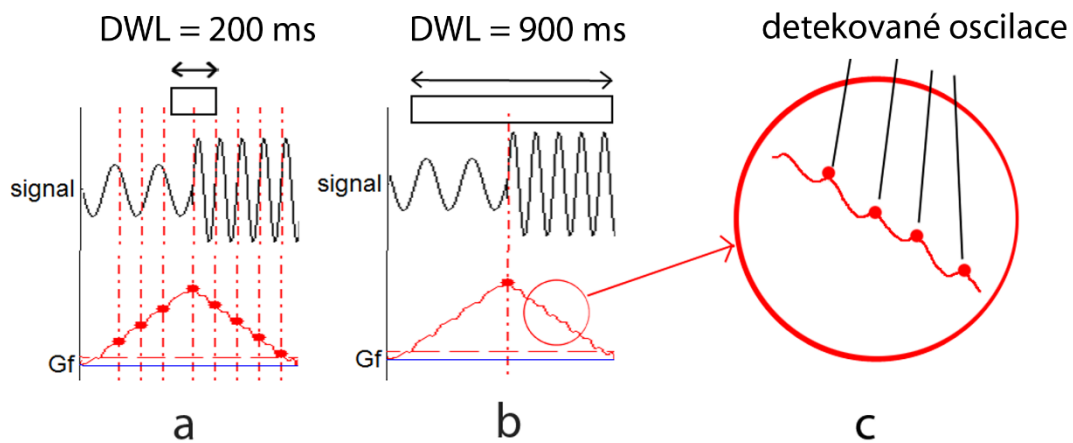
## 6.4. Testování na simulovaných sinusovkách

Dále jsem vytvořil přechod dvou sinusových signálů, které se navzájem liší jak amplitudou, tak frekvencí. Tento přechod má simulovat pomalé změny v signálu. Parametry jsem testoval stejným způsobem jako v předchozí části. Nejprve jsem nechal nejnižší možný STEP (1 vzorek), měnil WL a sledoval minimální hodnotu DWL potřebnou ke správné detekci. Vše demonstruje Tabulka 6.3.

**Tabulka 6.3.** Minimální DWL potřebné pro správnou detekci při daném WL

WL [ms]	<130	130	150	200	250	500	1000	1500	2000	2500	3000
min DWL [ms]	-	50	150	100	200	400	800	1300	1800	2200	2700





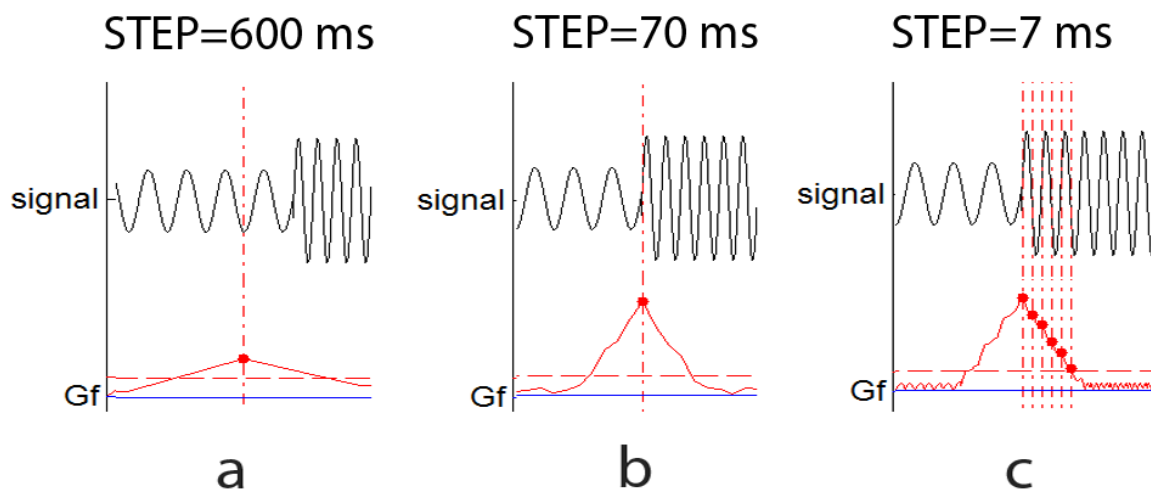
**Obrázek 6.5.** Oscilace na  $G$  funkci vzniklé vlivem delšího WL. Korekce může být provedena pomocí DWL. WL=1000 ms. a) DWL=200 ms; b) DWL=900 ms; c) detail oscilací

Obrázek 6.5 ukazuje důvod, proč je potřeba zvyšování WL (viz Tabulka 6.3) kompenzovat zvyšováním DWL. V části (a) je vidět segmentace pomocí WL=1 s a DWL=200 ms. Délka DWL je v obrázku naznačena cejchovaný obdélníkem. Vyšší WL způsobuje postupné roztahování vrcholu na  $G$  funkci a kromě jednoho ostrého vrcholu, který jsme pozorovali u nižších WL v minulé kapitole (použitých pro detekci ostrého hrotu), se zde objevují menší postranní vrcholky, které jsou při nízkém DWL rovněž zachyceny. Vliv těchto bočních vrcholků (oscilací na  $G$  funkci) může být eliminován zvýšením DWL jak ukazuje Obrázek 6.5.b. Další možností kompenzace je nastavení vysokého THR na hodnoty větší jak 80% maximální amplitudy  $G$  funkce. Tato možnost však není příliš vhodná, jelikož veškeré případné další změny menšího charakteru by byly zanedbány.

Tabulka 6.3 naznačuje, že pokud budeme dostatečně zvyšovat DWL, můžeme libovolně zvyšovat i WL. S každým takovýmto navýšením však ztrácíme rozlišovací schopnost segmentace (nejsme schopni zachytit menší segmenty než DWL). Proto je lepší držet oba parametry v co nejnižších možných hodnotách. Je také třeba uvažovat z jakých prvků je segmentovaný signál složen.

Druhou možností ovládní segmentační metody Varri je deaktivovat DWL (hodnota 3 vzorky) a měnit pouze WL a STEP. Kombinací těchto parametrů lze dosáhnout tří

případů, jak ukazuje Obrázek 6.6. Na všech částech je konstantní  $WL=700$  ms a  $DWL=3$  vzorky, dochází pouze ke změně STEP. V části (b) je nastaven ideální  $STEP=70$  ms, kdy dochází ke správné detekci. Pokud STEP zvýšíme na 600 ms, dojde k roztáhnutí  $G$  funkce a zpožděné, nebo předčasné detekci hranice segmentu (Obrázek 6.6.a). Naopak pokud STEP snížíme na 7 ms (Obrázek 6.6.c) dojde k typické oscilaci, kterou jsem popisoval již dříve a k detekci mnoha falešně pozitivních hranic. Následující Tabulka 6.4 ukazuje rozpětí hodnot, kdy se výsledky segmentace nacházejí mezi těmito extrémny (dochází ke správné segmentaci).



**Obrázek 6.6.** Tři možnosti nastávající při kombinování  $WL$  a  $STEP$ .  $DWL=3$  vzorky,  $WL=700$  ms. a)  $STEP=600$  ms; b)  $STEP=70$  ms; c)  $STEP=7$  ms

Tabulka 6.4 přehledně ukazuje detekční schopnosti a potřebné nastavení metody Varri pro použitý typ signálu. Pokud hodnota  $STEP$  přesáhla odpovídající maximální hodnotu, docházelo ke špatné detekci, pokud naopak klesla pod minimální hodnotu, docházelo k falešným detekcím vlivem oscilací  $G$  funkce. Je vidět, že pro všechna  $WL$  v rozmezí 100 ms-3 s, lze bezpečně použít  $STEP$  u intervalu  $\langle 40, 90 \rangle$  ms, s tím, že čím blíže bude použitá hodnota středu tohoto intervalu, tím větší jistotu správné detekce máme.

**Tabulka 6.4.** Rozmezí parametrů pro správné určení hranic segmentů


WL [ms]	STEP [ms]		WL [ms]	STEP [ms]	
	Max.	Min.		Max.	Min.
100	100	10	900	120	40
150	90	30	1000	110	30
200	160	30	1100	220	20
300	120	30	1200	120	20
400	160	30	1500	170	40
500	150	30	2000	160	40
600	120	40	2500	120	30
700	120	40	3000	120	30
800	170	40	3500	-	-
			optimální	90	40

## 6.5. Reálné EEG záznamy

Epileptický hrot v reálném EEG bývá velmi ojediněle sám, tak jak jsem simuloval v předchozí části. Většinou se objevuje v přítomnosti mnoha dalších hrotů, nebo v komplexu s pomalou vlnou. Obrázek 6.7 ukazuje právě takový komplex hrot vlna. Signál na obrázku je učebnicový příklad. Tento signál neobsahuje žádné artefakty a je minimálně zatížen šumem. V reálné praxi se však podobně „čisté“ záznamy vyskytují málokdy. Rovněž komplexy nejsou obvykle tak snadno odlišitelné jako v toto signálu.

Abych ověřil, jestli chování metody u simulovaných signálů odpovídá chování na reálných signálech, testoval jsem tento reálný signál stejnými parametry jako simulované signály v předchozí části. Obrázek 6.7 ukazuje dva způsoby segmentace komplexu hrot-vlna. Vlevo obrázek ukazuje oddělené pouze hrotů pomocí parametrů  $WL=120$  ms a  $DWL=10$  ms. Tyto parametry odpovídají parametrům navrženým pro segmentaci simulovaných hrotů. Takováto segmentace však nemá z diagnostického hlediska příliš smysl. Abychom byly schopni detekovat celý komplex hrot-vlna, je zapotřebí využít odlišné parametry navržené pro segmentaci skokových změn v signálu, jak ukazuje

Obrázek 6.7 vpravo. Je vidět, že parametry navržené pro segmentaci simulovaných signálů poměrně dobře fungují i na tomto učebnicovém reálném signálu.



**Obrázek 6.7.** Detekce reálného učebnicového EEG záznamu komplexu hrot-vlna. Vlevo detekce pouze samotných hrotů WL=120 ms, DWL=10 ms STEP=10 ms. Vpravo segmentace celého komplexu hrot-vlna WL=1000 ms, DWL=800 ms, STEP=10 ms. Použité parametry odpovídají parametrům navrženým pro simulované signály

## 6.6. Shrnutí navržených parametrů

V této kapitole jsem postupně testoval vliv jednotlivých parametrů na segmentaci epileptických signálů a navrhoval, které hodnoty jsou pro konkrétní signály nejvhodnější. Postupně jsem takto rozebral segmentaci simulovaných epileptických špiček, špiček s přidáním autoregresním signále, pomalejší přechody dvou různých sinusových signálů a nakonec segmentaci učebnicového reálného epileptického signálu s jasně odlišitelnými komplexy. Následující tabulka shrnuje zjištěné hodnoty parametrů vhodné pro tyto úlohy.

**Tabulka 6.5.** Shrnutí navržených rozmezí parametrů vhodných pro segmentaci vybraných signálů

úloha	WL [s]	DWL [ms]	STEP [ms]	MSL [ms]
Osamělé hroty	0,1-0,15	10-50	10-25	<50
Pomalé přechody sinusových signálů	0,5-5 (8)	dle WL: 50-80 % WL	40-120	500-1500

## Kapitola 7

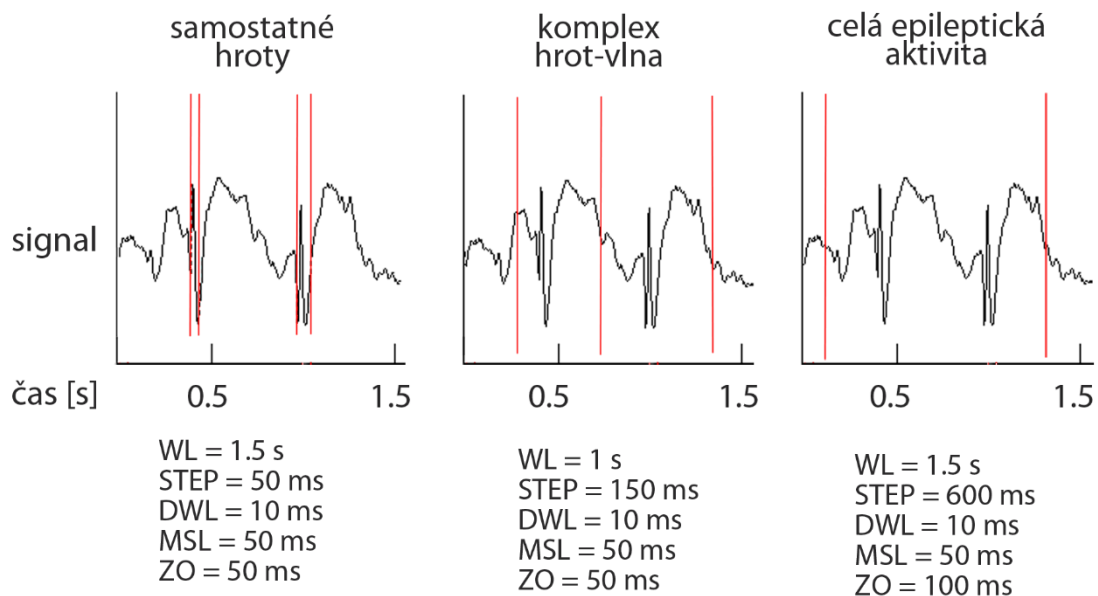
### Optimalizace parametrů pro reálné záznamy

V předchozí kapitole jsem zdokumentoval chování Varriho metody adaptivní segmentace epileptických signálů v závislosti na nastavených vstupních parametrech. Rovněž jsem zde navrhl vhodné parametry pro segmentaci různých umělých signálů simulujících reálné grafoelementy a nakonec tyto parametry ověřil na učebnicovém příkladu reálného EEG záznamu. Reálné záznamy v praxi se však od těchto simulovaných signálů obvykle liší. Často jsou zatíženy šumem a artefakty. Rovněž jednotlivé grafoelementy nebývají tak jasně odlišitelné jako v použitém učebnicovém příkladu (Obrázek 6.7). Tato kapitola se proto zabývá optimalizací již navržených parametrů, pro dosažení kvalitních výsledků u klinických EEG záznamů.

Všechny reálné EEG záznamy použité v této práci byly pořízeny v nemocnici Na Bulovce, Praha, na přístroji BrainQuick firmy Micromed se vzorkovací frekvencí 128 Hz a 12bit AD převodníkem. Data byla při ukládání na disk filtrována pásmovou propustí 0,4-70 Hz. Všichni pacienti před měřením v nemocnici Na Bulovce podepsali informovaný souhlas a jejich data byla anonymizována. Práce byla schválena etickou komisí v roce 2012.

U běžných klinických epileptických EEG záznamů je často obtížné přesně definovat, kde má daná hranice segmentu být umístěna. Vizuální segmentace lékařem je velmi subjektivní problematika a proto je zároveň nesmyslné určit pouze jeden způsob (jednu sadu parametrů) jak signál segmentovat. V této práci se proto zaměřuji na navržení několika různých způsobů segmentace a jim odpovídajících parametrů. Lékař si dle vlastních preferencí popřípadě aktuálního diagnostického účelu vybere, jaká segmentace (zejména úroveň detailu segmentace) je pro něj v daném případě nejvhodnější a dle toho nastaví odpovídající vstupní parametry metody. Cílem této kapitoly je tedy navrhnout několik vhodných sad parametrů AS (a způsob jejich detailnějšího nastavení) z důvodu usnadnění práce lékaři při analýze epileptických EEG záznamů.


Jak již bylo částečně naznačeno v předchozí kapitole, úroveň detailu segmentace lze rozdělit na tři případy, jak ukazuje Obrázek 7.1. První možnost je oddělit pouze epileptické hroty od okolního signálu. Takováto segmentace však nemá z diagnostického hlediska příliš smysl. Druhým způsobem je rozdělit signál na celé epileptické komplexy hrot-vlna. Poslední možností je odlišit pouze aktivitu epileptickou a neepileptickou. Každá z těchto možností vyžaduje mírně odlišný přístup a tudíž použití jiných parametrů. V následující části demonstruji vhodné kombinace parametrů pro reálně využívané segmentační úlohy.




**Obrázek 7.1.** Tři různé úrovně segmentace (pouze samostatné hroty, komplexy hrot-vlna, celá epileptická aktivita) v závislosti na použitých parametrech metody

Obrázky 7.2-7.4 ukazují tři různé úrovně segmentace delší epileptické epizody. Použitý signál je složen z více rychlých epileptických komplexů. Na prvním obrázku byl signál rozdělen na jednotlivé komplexy. Pouze několik velmi podobných komplexů nebylo odděleno ale spojeno do jednoho segmentu. Druhý obrázek zachycuje méně detailní segmentaci docílenou zvýšením parametru WL. Zde je efekt slučování podobných komplexů do jednoho společného segmentu markantnější. Poslední obrázek ukazuje


nejméně detailní segmentaci, během které došlo „pouze“ k oddělení celé epileptické aktivity od okolního signálu.



**Obrázek 7.2.** Rozdělení signálu na jednotlivé komplexy hrot-vlna (nejvyšší detail segmentace). Některé velmi podobné komplexy byly metodou sloučeny do jednoho segmentu




**Obrázek 7.3.** Méně citlivá segmentace dosažená zvýšením WL. Podobné komplexy byly sdruženy dohromady do společných segmentů



**Obrázek 7.4.** Nejméně detailní segmentace oddělila celou epileptickou aktivitu od okolního neepileptického signálu. Snížení citlivosti bylo dosaženo zvýšením parametrů WL a STEP

Obrázek 7.5 ukazuje podobnou segmentaci jako v předchozím případě. Opět jsou zde vidět tři úrovně segmentace. Rozdělení signálu na jednotlivé komplexy, méně detailní rozdělení vyznačující se sloučením podobných komplexů do společných segmentů a oddělení celé epileptické aktivity od okolního signálu. Detailnost segmentace je i zde nepřímě úměrná velikosti použitých parametrů, tedy pro větší hodnoty (zejména WL a STEP) dostáváme méně detailní segmentaci. Na rozdíl od minulého případu je však signál použitý zde složen

z méně rychlých, delších komplexů. Z toho důvodu jsou všechny parametry o něco vyšší. Tento trend platí obecně a to i na druhou stranu. Tedy pro rychlejší signály je třeba volit kratší hodnoty parametrů. Navržené a optimalizované parametry shrnuje Tabulka 7.1.



**Obrázek 7.5.** Obdobná segmentace epileptické epizody třemi způsoby. Zde použitý signál obsahuje celkově pomalejší grafoelementy než v předchozím případě. Použité parametry jsou proto mírně vyšší. Opět ale platí, že se zvyšováním hodnot parametrů se snižuje detail segmentace

**Tabulka 7.1.** Parametry vhodné pro segmentaci epileptické aktivity podle detailnosti segmentace

úloha	WL [s]	DWL [ms]	STEP [ms]	MSL [ms]
Samostatné komplexy	0,5-1	10-50	50	50
Sdružené komplexy	1-1,5	10-50	50-100	50-100
Celá epileptická aktivita	(1) 1,5-3	10-50	150-800	50-500

Pro rychlejší signály (ostřejší grafoelementy, vyšší frekvence) je vhodné volit parametry nižší, naopak pro pomalejší signály parametry vyšší.



## Kapitola 8

### Segmentace dospělé a neonatální aktivity

V předešlých kapitolách jsem se zabýval segmentací epileptických signálů. V této kapitole se krátce zaměřím nejprve na segmentaci běžných fyziologických EEG záznamů dospělých a následně na novorozeneckou aktivitu. Tyto signály se od epileptických liší zejména nižší frekvencí. Rovněž délka segmentů se u těchto signálů ukazuje výrazně vyšší, což plyne z faktu, že zatímco epileptický komplex hrot-vlna má délku obvykle do jedné sekundy, fyziologickou aktivitu obvykle dělíme do úseků výrazně delších. Z toho důvodu jsou parametry použité zde více podobné těm, které byly v minulých kapitolách využity k oddělení celé epileptické aktivity, jak bude dále ukázáno.


#### 8.1. Segmentace fyziologické aktivity dospělých

Běžná fyziologická aktivita dospělých pacientů je obvykle dělena na čtyři základní rytmy. Delta, theta, alpha a beta:

- Delta rytmus se pohybuje v rozmezí 0,5-3,5 Hz a vyznačuje se nejvyšší amplitudou (75-150  $\mu$ V). Jedná se o pomalý rytmus vyskytující se fyziologicky pouze u dětí, popřípadě ve velmi hlubokém spánku u dospělých.
- Theta aktivita se pohybuje mezi 4-7,5 Hz. Fyziologicky je pozorovatelná u dětí v mělkém spánku. U dospělých je vždy patologická.
- Alpha rytmus se pohybuje v rozmezí 8-13,5 Hz s amplitudou nižší než delta (30-100  $\mu$ V). Jedná se o projev klidové mozkové aktivity se zavřenými očima. Při otevření očí dochází k utlumení.
- Beta aktivita má nejvyšší frekvenci 14-30 Hz a zároveň nejnižší amplitudu (do 20  $\mu$ V). Jedná se o projev vědomé mozkové aktivity. Při otevření očí na rozdíl od alpha rytmu nedochází k útlumu. (Penhaker,2004)

Rozlišení těchto pásem hraje klíčovou roli při diagnóze běžného EEG záznamu. Od epileptické aktivity se liší nižší frekvencí jak samotné aktivity, tak i výskytem hranic

segmentů. Z toho důvodu jsou parametry používané pro segmentaci těchto aktivit výrazně vyšší než u aktivity epileptické popsaných v minulých kapitolách. Obrázek 8.1 ukazuje příklad takové segmentace. Dohází zde k segmentaci signálu složeného převážně z alfa aktivity o vyšší amplitudě, která je na krátkou dobu utlumena otevřením očí, kdy místo alfy převažuje beta aktivita. Pro tyto běžné přechody je vhodnější používat původní kombinaci parametrů WL + vyšší DWL s nízkým STEP, jelikož právě na takovouto segmentaci delších úseků byla metoda Varri navržena (původní metoda parametr STEP využívala pouze pro urychlení algoritmu, ne samotné ladění). Segmentaci dalších fyziologických aktivit je analogická s touto ukázkou.




**Obrázek 8.1.** Ukázková segmentace fyziologické aktivity pomocí vyšších hodnot parametrů než byly použity pro segmentaci epilepsie. Záznam zachycuje alfa aktivitu při zavřených očích krátce přerušenu nízkovoltážní beta aktivitou převažující při otevření očí

## 8.2. Segmentace neonatální aktivity

Jedním z častých vyšetření prováděným zejména u předčasně narozených dětí je kontrola správného vývoje mozku. U dětí obvykle do 31. týdne se ukazuje aktivita zvaná *tracé discontinu*. Vykazuje se nízkou aktivitou střídanou občasnými výboji aktivity s výrazně vyšší amplitudou. Opakovaným porovnáváním poměru těchto „aktivních a neaktivních“ fází může lékař monitorovat správnost vývoje mozku pacienta.

Právě tento signál byl v této práci vybrán pro demonstraci využitelnosti popisované metody AS a navržených parametrů pro segmentaci neonatálního záznamu. Při segmentaci *tracé discontinu*, jak již bylo řečeno, je třeba oddělit výboje od zbytku signálu. Nejedná se tedy o oddělení krátkých grafoelementů jako v případě epilepsie, ale o oddělení delších souvislých úseků. Tento problém byl již řešen pro simulované sinusové

signály v kapitole 6.4. Jak zde bylo navrženo, je vhodné použít delší hodnoty WL kompenzované delším DWL popřípadě STEP. Příklad vhodné segmentace na dvou různých neonatálních signálech ukazuje Obrázek 8.2.



**Obrázek 8.2.** Segmentace dvou různých novorozeneckých aktivit typu *tracé discontinu*. Nahoře záznam pacienta s méně vyvinutým mozkem (poměr aktivní/neaktivní fáze je zde menší), dole pacienta s vyvinutějším mozkem. V obou případech byly využity vysoké hodnoty WL i STEP navržené v kapitole 6.4 pro oddělení dvou výrazně se lišících signálů s déle trvajících segmenty

### 8.3. Shrnutí navržených hodnot parametrů

V této kapitole shrnuji rozmezí hodnot parametrů navržená pro všechny typy signálů, kterými se v této práci zabývám. Jak jsem již několikrát zmiňoval, jednotlivé hodnoty nelze generalizovat, stejně jako nejdou generalizovat všechny signály. Vždy je třeba přihlížet k charakteru konkrétního zpracovávaného signálu. Jak již bylo několikrát zmíněno výše, platí pravidlo, že pro pomalejší signály s nižší frekvencí změny stacionarity (popř. výskytu námi sledovaných grafoelementů) je vhodnější volit parametry vyšší a naopak. Tímto způsobem lze zároveň ladit detailnost segmentaci tak, abychom dostali výsledek, který nám nejvíce vyhovuje pro aktuální diagnostickou potřebu.

**Tabulka 8.1.** Shrnutí navržených rozmezí parametrů vhodných pro segmentaci vybraných typů EEG signálů

úloha	WL [s]	DWL [ms]	STEP [ms]	MSL [ms]
Samostatné epileptické komplexy	0,5-1	10-50	50	50
Sdružené epileptické komplexy	1-1,5	10-50	50-100	50-100
Celá epileptická aktivita	(1) 1,5-3	10-50	150-800	50-500
Změny fyziologických rytmů	0,8-5	80% WL	10-50	1000-2000
Neonatální <i>tracé discontinu</i>	3-8	10-50	400-1000	500-1500

## Diskuse

V první fázi své práce jsem se zabýval implementací současných metod zmíněných v kapitole 1 z důvodu jejich testování a následného porovnání. Metody jsem implementoval jako nástavbu na svůj předchozí program *Prohlížeč EEG signálu*, vše v programovém prostředí MATLAB. Samotná implementace byla zdlouhavý proces, jelikož ne všechny metody byly v původních článcích dostatečně popsány. Často zde chyběly důležité detaily, které jsem musel zjišťovat metodou pokus-omyl. Nejčastěji se jednalo o nedostatečné popsání normalizace dat během výpočtu charakteristických funkcí signálu. Znalost normalizace je pro správnou implementaci klíčová zejména u metod využívajících výpočet fraktální dimenze. Způsob normalizace jsem tak v případě těchto metod (Hassanpour, Azami) musel odhadovat z ukázek segmentace simulovaných signálů v jednotlivých článcích, přičemž tyto signály rovněž nebyly vždy plně dokumentovány. Nikde například nebyla zmíněna vzorkovací frekvence těchto signálů, jejíž odlišné nastavení od hodnot použitých v originále následně ovlivňovalo výsledek vlnkové transformace během předzpracování signálu. Z toho důvodu byla přesná replikace metod obtížná.

Pro samotné porovnání jsem vytvořil dvě nové funkce do svého programu. První, sloužící k testování vlivu vstupních parametrů na výsledek segmentace pomocí předtím naimplementovaných metod a druhou pro porovnávání výsledků jednotlivých metod mezi sebou. Jak popisuje Kapitola 4, srovnání metod bylo provedeno na simulovaném autoregresním signálu, u něhož byly správné pozice hranic segmentů přesně známy. Simulovaný signál jsem použil z důvodu obtížné uchopitelnosti kvantifikace segmentačních vlastností metod na reálných EEG záznamech. Ze mnou provedeného porovnání vyšly nejlépe metody INLEO a Varri, které dosahovaly vysokých přesností a zároveň vykazovaly největší robustnost (rozsah použitelných hodnot jednotlivých parametrů). Metoda NEO se ukázala jako nejméně spolehlivá a to jak vlivem nízké robustnosti tak i z důvodu nedostatečné přesnosti při vyladění parametrů. Novější metody

Hassanpour a Azami prokázaly vysokou vzájemnou korelaci. Tento fakt si zdůvodňují velmi podobnou stavbou vlastního algoritmu obou metod, kdy jediným významným rozdílem mezi nimi je použitý způsob předzpracování. Zatímco Hassanpour využívá stacionární vlnkovou transformaci, Azami filtruje signál Kalmanovým filtrem.

Co se segmentačních vlastností týče, v mém testování novější metody Hassanpour a Azami neprokázaly dostatečnou robustnost – nebylo možné nalézt větší spojitou oblast hodnot parametrů, ve které by metody dosahovaly stabilně kvalitních výsledků. Obě tyto metody vyžadují pro každý konkrétní segmentovaný signál nové, přesné nastavení parametrů. Pokud bylo toto specifické nastavení zajištěno, dosahovaly velmi vysokých přesností (často až 100%), avšak takovýchto „správných“ kombinací parametrů bylo v porovnání s ostatními metodami velmi málo. Určení vhodných hodnot parametrů je v původních článcích řešeno pomocí optimalizačních algoritmů (Hassanpour využívá PSO, Azami GA a ICA) jak popisuje Kapitola 1. Tyto algoritmy jsou sice schopny při správné implementaci nastavit parametry tak, abychom dosáhli kvalitní segmentace, avšak toto nastavování musí být prováděno pro každý signál zvlášť (což u dlouhodobých záznamů znamená měnit nastavení při každé výraznější změně charakteru signálu). S přihlédnutím k dlouhé výpočetní době vlastní optimalizace je tento způsob naprosto nevhodný pro online zpracování záznamu a použití u dlouhodobých signálů je rovněž velmi diskutabilní.

Porovná-li mnou získané výsledky spolehlivosti těchto dvou nových metod s články, ve kterých byly metody prezentovány, je s podivem, že mé výsledky jsou přesně opačné než v případě zmíněných článků, kde metody Varri a INLEO nedosahují zdaleka tak dobrých výsledků jako představované metody nové. Důvod tohoto rozporu je těžké určit, jelikož ve zmíněných článcích není o způsobu vyhodnocování řečeno zcela nic. Tento nedostatek je dle mého názoru zcela kruciólní, jelikož definování správných pozic umístění hranice segmentu, podle kterých je metoda následně vyhodnocena, je u reálných signálů (na kterých byly metody údajně testovány) velmi těžko uchopitelný problém, bez jehož přesného popisu je vlastní vyhodnocení víceméně subjektivní.

Na základě výše zmíněných faktů, kterými se hlouběji zabývá Kapitola 4, jsem pro další použití vybral metodu Varri, jelikož prokázala dostatečnou robustnost, přesnost a zároveň výpočetní jednoduchost. Pro její další zpřesnění jsem navrhl nové dva parametry (Kapitola 5). Tyto parametry nejsou pro chod metody zásadní, avšak jejich správným nastavením se dá výsledek segmentace vylepšit tak, aby co nejvěrněji napodoboval segmentaci prováděnou lékaři. Rovněž se tyto parametry hodí při segmentaci některých abnormálních signálů, které jsou pomocí běžného nastavení metody segmentovatelné pouze obtížně.

Kapitola 6 popisuje segmentaci epileptické aktivity a vliv jednotlivých parametrů na její kvalitu. Epileptické aktivitě ve své práci věnuji speciální pozornost ze dvou důvodů. Prvním je vysoký diagnostický přínos EEG vyšetření při podezření na epilepsii (i s příchodem nových zobrazovacích metod je EEG vyšetření stále primárním způsobem stanovení epilepsie). Druhým důvodem je velká odlišnost epileptického signálu a ostatních běžných EEG signálů. Epileptický signál má obvykle mnohem vyšší kadenci sledovaných grafoelementů. Navíc mají tyto grafoelementy obvykle výrazně kratší dobu trvání oproti jiným typům signálu. Z těchto důvodů je třeba k segmentaci epileptických záznamů použít zcela odlišné nastavení metody adaptivní segmentace, kterým se v této práci zabývám.

Nejprve jsem tedy na simulovaných datech testoval vliv parametrů na výsledek segmentace, na jehož základě jsem následně navrhl některá vhodná rozmezí jednotlivých parametrů pro segmentaci konkrétních fenoménů. K tomu jsem využil nejprve jednoduché krátké špičky simulující epileptické hroty, ke kterým jsem následně přidal autoregresní signál. Postupně jsem měnil vzájemný poměr hrot : okolní signál, abych otestoval schopnost metody zachytit i méně výrazné hroty. Následně jsem se zabýval přechodem dvou sinusových signálů o rozdílné amplitudě i frekvenci. Tato segmentace měla simulovat pomalejší přechody signálu, což jsem následně využil například u segmentace neonatálních záznamů, jak budu popisovat níže. Nakonec této části jsem navržené parametry testoval na učebnicovém reálném epileptickém EEG signálu obsahujícím pomalé, snadno rozlišitelné komplexy hrot-vlna.

V následující části jsem navržené a otestované parametry aplikoval na reálné epileptické EEG záznamy méně učebnicového stylu. Zde jsem narazil na zásadní problém diskutovaný již při testování metod (Kapitola 4), a to obtížnost exaktního definování hranice segmentu u reálných dat. Narážíme zde totiž na fakt, že segmentace EEG signálu je mimetický proces (napodobující práci lékaře) a jako takový zahrnuje notnou dávku subjektivity. Obvykle tedy nejde definitivně říci, která segmentace je špatná a která dobrá. Namísto definování procentuální „spolehlivosti“ jednotlivých kombinací parametrů, které jsem měl původně v úmyslu vytvořit, jsem ze zmíněného důvodu pouze definoval tři odlišné způsoby (detaily) segmentace EEG aktivity a parametry k tomu vhodné. Nejdetailnějším způsobem segmentace je rozdělení signálu na jednotlivé komplexy. Při méně detailní segmentaci jsou podobné komplexy sdruženy dohromady a nejhrubším způsobem je oddělení celé epileptické aktivity od okolního neepileptického signálu. Každý z těchto způsobů má svá diagnostická využití a jejich variací lze správně segmentovat i atypický signál.

Pro jednotlivé tři typy segmentace zmíněné výše jsem navrhl rozsahy parametrů, tak aby bylo použití metody pro lékaře co nejsnadnější a co nejméně musel jednotlivé hodnoty přenastavovat. Přesto se však ručnímu ladění parametrů, zejména u méně typických signálů, zatím nedá vyhnout. Metoda je stále pouze semiautonomní a stále vyžaduje dozor lékaře. Její hlavní přínos je v této fázi pouze usnadnění práce lékaři, ne jeho úplné nahrazení. Další pokrok v tomto směru by mohl být uskutečněn pomocí učících se algoritmů, kterým by byla nejprve předložena zkušební data pro naučení, a algoritmus by následně parametry mohl ladit sám bez lékařovy supervize.

V poslední části své práce (Kapitola 8) jsem se krátce zabýval segmentací běžné fyziologické aktivity a následně neonatálními záznamy typu *tracé discontinu*. Demonstraval jsem zde použitelnost metody Varri i pro jiné než epileptické signály a diskutoval rozdílnost použitých parametrů. Ty musely nabývat pro tyto signály výrazně vyšších hodnot (podobné hodnoty jsem navrhl pro segmentaci pomalých přechodů sinusových signálů výše) z důvodu pomalejšího charakteru signálu a méně častým změnám stacionarity.



## Závěr

Přínos této práce je jak v teoretické, tak v praktické rovině.

**Praktickým výsledkem** mé práce je software umožňující adaptivní segmentaci EEG záznamů pomocí několika nejznámějších metod (Varri, NEO, INLEO, Hassanpour, Azami). Software umožňuje snadné nastavování vstupních parametrů a poskytuje široký prostor pro testování samotných metod. Dále nabízí možnost přehledného porovnání výsledků jednotlivých metod mezi sebou. Program umožňující adaptivní segmentaci EEG signálu je prvním krokem k vytvoření nástroje pro automatické vyhodnocování EEG záznamů. Takovýto nástroj by významně ulehčil práci lékařů a zkrátil celkovou dobu potřebnou k stanovení diagnózy pomocí analýzy EEG záznamů.

**Teoretickým výsledkem** je podrobný popis problematiky nastavení vhodných vstupních parametrů metod AS pro dosažení požadovaných výsledků. Zmapoval jsem vliv jednotlivých parametrů na segmentaci nejprve simulovaných signálů a následně na segmentaci epileptických, neonatálních a dospělých fyziologických EEG záznamů pomocí Varriho metody dvou spojených oken. Dále jsem navrhl vhodná rozmezí hodnot jednotlivých parametrů a způsob jejich detailního doladění pro dosažení optimálních výsledků segmentace zmíněných typů signálů. Pomocí těchto navržených hodnot a jednoduchých informací o jejich ladění je lékař schopen EEG signál velmi snadno segmentovat a to i bez hlubších znalostí samotné segmentační metody. Navíc jsem vytvořil dva nové parametry, které kvalitu segmentace ještě dále zlepšují a její výsledek dělají pro lékaře přirozenější.

Cíl ulehčit lékařům práci a popsat zatím nedostatečně zdokumentovaný vliv jednotlivých parametrů na výsledek segmentace stejně jako ostatní cíle definované v zadání práce byly bez výjimky splněny.

---

## Reference

1. Agarwal, R., Gotman, J., Flanagan, D., Rosenblatt, B., 1998. Automatic EEG analysis during long-term monitoring in the ICU. *Electroencephalography and Clinical Neurophysiology* 107, 44–58. doi:10.1016/S0013-4694(98)00009-1
2. Anisheh, S. M, Hassanpour, H, 2009. Adaptive segmentation with optimal window length scheme using fractal dimension and wavelet transform. *International Journal of Engineering*, 257–268.
3. Anisheh, S.M., Hassanpour, H., 2011. Designing an adaptive approach for segmenting non-stationary signals. *International Journal of Electronics* 98, 1091–1102. doi:10.1080/00207217.2011.560559
4. Appel, U., Brandt, A.V., 1983. Adaptive sequential segmentation of piecewise stationary time series. *Information Sciences* 29, 27–56. doi:10.1016/0020-0255(83)90008-7.
5. Azami, H., Hassanpour, H., Escudero, J., Sanei, S., 2015. An intelligent approach for variable size segmentation of non-stationary signals. *Journal of Advanced Research* 6, 687–698. doi:10.1016/j.jare.2014.03.004
6. Brandt, A.V., Appel, U., 1984. A comparative study of three sequential time series segmentation algorithms. *Signal Processing*, 45–60.
7. Eberhart, R., Kennedy, J., 1995. A new optimizer using particle swarm theory. *IEEE*, pp. 39–43. doi:10.1109/MHS.1995.494215
8. Eiben, A.E., Smith, J.E., 2003. *Introduction to Evolutionary Computing*, Natural Computing Series. Springer Berlin Heidelberg, Berlin, Heidelberg.
9. Engel, J., Pedley, T.A. (Eds.), 2008. *Epilepsy: a comprehensive textbook*, 2nd ed. ed. Wolters Kluwer Health/Lippincott Williams & Wilkins, Philadelphia.
10. Falconer, K.J., 2003. *Fractal geometry: mathematical foundations and applications*, 2nd ed. Wiley, Chichester, England.

11. Hassanpour, H, Shahiri, M, 2007. Adaptive segmentation using wavelet transform, in: Institute of Electrical and Electronics Engineers, University of Engineering and Technology (Eds.), . Presented at the International Conference on Electrical Engineering: [ICEE '07], 11-12 April, IEEE Service Center, Lahore, Pakistan, pp. 365–369.
12. Hovorka, J., 2003. Klinická elektroencefalografie: základy klasifikace a interpretace. Maxdorf, Praha.
13. Kaiser, J.F., 1990. On a simple algorithm to calculate the “energy” of a signal. IEEE, pp. 381–384. doi:10.1109/ICASSP.1990.115702
14. Kala, D. 2014. Digital EEG signal analysis and display of results. Kladno. Bakalářská práce. České vysoké učení technické v Praze, Fakulta biomedicínského inženýrství.
15. Kala, D., 2015. The application of adaptive segmentation for EEG epileptic grapho-elements detection, in: Instruments and Methods for Biology and Medicine 2015. Presented at the Conf. Instruments and methods for biology and medicine 2015, Czech Technical University in Prague, Kladno, pp. 24–27.
16. Katz, M.J., 1988. Fractals and the analysis of waveforms. Computers in Biology and Medicine 18, 145–156. doi:10.1016/0010-4825(88)90041-8
17. Krajča, V., Petránek, S., Patáková, I., Värri, A., 1991. Automatic identification of significant graphoelements in multichannel EEG recordings by adaptive segmentation and fuzzy clustering. International Journal of Bio-Medical Computing 28, 71–89. doi:10.1016/0020-7101(91)90028-D
18. Krajča, V., Mohylová, J., České vysoké učení technické v Praze, Fakulta biomedicínského inženýrství, 2011. Číslicové zpracování neurofyziologických signálů. České vysoké učení technické, V Praze.
19. Lopes da Silva, F. H, Dijk, A, Smits, H., 1977. Detection of nonstationarities in EEG's using the autoregressive model-An application to EEG's of epileptics. CEAN: Computerized EEG Analysis, 180–199.
20. Matthes, A., Schneble, H., 2003. Co bychom měli vědět o epilepsii. Praha: Desetin. Dostupné z: <http://www.desetin.cz/index/php/article/detail/3582>.
21. McEwen, J. A. 1975. Modelling the stationarity and Gaussianity of spontaneous electroencephalographic activity. IEEE Trans. Biomed.Eng., BME-22, 299-305.

22. Michael, D., Houchin, J., 1979. Automatic EEG analysis: A segmentation procedure based on the autocorrelation function. *Electroencephalography and Clinical Neurophysiology* 46, 232–235. doi:10.1016/0013-4694(79)90075-0
23. Nieminen, A., Neuvo, Y., Jantti, V., Hakkinen, V., n.d. An approach to adaptive segmentation of EEG. *Uppsala journal of medical sciences* 1986, 50–50.
24. Penhaker, M., 2004. *Lékařské diagnostické přístroje: učební texty*, Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, Fakulta elektrotechniky a informatiky
25. Plotkin, E. I, Swamy, M. N. S., n.d. Nonlinear signal processing based on parameter invariant moving average modeling. Presented at the CCECE 21, Toronto (Canada), p. TM3.11.1.–TM3.11.4.
26. Pollicott, M., 2005. *Lectures on fractals and dimension theory*.
27. Praetorius, H., Bodenstein, G., Creutzfeldt, O., 1977. Adaptive segmentation of EEG records: a new approach to automatic EEG analysis. *Electroencephalography and Clinical Neurophysiology* 42, 84–94. doi:10.1016/0013-4694(77)90153-5
28. Rho, J.M., Sankar, R., Stafstrom, C.E., 2010. *Epilepsy mechanisms, models, and translational perspectives*. CRC Press, Boca Raton, FL.
29. Skrylev, K. M, Silin. D. Y. 1986. A method of analysis of abrupt changes in the EEG rhythm. *Fisiol Chelovek (Human Physiology)*, 333–336
30. Tzallas, A., Tsipouras, M., Tsalikakis, D., Karvounis, E., Astrakas, L., Konitsiotis, S., Tzaphlidou, M., 2012. Automated Epileptic Seizure Detection Methods: A Review Study, in: Stevanovic, D. (Ed.), *Epilepsy - Histological, Electroencephalographic and Psychological Aspects*. InTech.