



ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

FAKULTA BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

Katedra biomedicínské techniky

**Detekce svalového artefaktu v EEG záznamech pomocí časově-
frekvenční analýzy**

**Detection of muscle artifact in EEG recordings using time-
frequency analysis**

Bakalářská práce

Studijní program: Biomedicínská a klinická technika

Studijní obor: Biomedicínský technik

Vedoucí práce: Ing. Jan Štrobl

Kladno 2021



ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

FAKULTA BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

Katedra biomedicínské techniky

Veranika Tuzankina



ZADÁNÍ BAKALÁŘSKÉ PRÁCE

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Tuzankina** Jméno: **Veranika** Osobní číslo: **482916**
Fakulta: **Fakulta biomedicínského inženýrství**
Garantující katedra: **Katedra biomedicínské techniky**
Studijní program: **Biomedicínská a klinická technika**
Studijní obor: **Biomedicínský technik**

II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

Detekce svalového artefaktu v EEG záznamech pomocí časově-frekvenční analýzy

Název bakalářské práce anglicky:

Detection of muscle artifact in EEG recordings using time-frequency analysis

Pokyny pro vypracování:

Analyzujte možnost využití časově frekvenční analýzy pro identifikaci svalových artefaktů v EEG záznamech. Implementujte v programovém prostředí MATLAB vhodnou metodu časově-frekvenční analýzy s adekvátně zvolenými parametry. Na základě implementované metody vytvořte metodiku vhodnou pro identifikaci svalových artefaktů. Aplikujte vytvořenou metodiku na reálné EEG záznamy. Navrhněte a následně realizujte statistickou analýzu správnosti detekce svalových artefaktů pomocí Vámi vytvořené metodiky.

Seznam doporučené literatury:

- [1] Mike X. Cohen, Analyzing Neural Time Series Data: Theory and Practice, ed. 1, The MIT Press, 2014, ISBN 978-0-262-01987-3
- [2] Krajča V., Mohylová J., Číslíkové zpracování neurofyziologických signálů, ed. Fakulta biomedicínského inženýrství, ČVUT Praha, 2011, ISBN 978-80-01-04721-7
- [3] Vinay K. Ingle, John G. Proakis, Digital signal processing using MATLAB, ed. Third edition, CENGAGE Learning, 2012, ISBN 978-1-111-42737-5

Jméno a příjmení vedoucí(ho) bakalářské práce:

Ing. Jan Štrobl

Jméno a příjmení konzultanta(ky) bakalářské práce:

Ing. Marek Piorecký, Ph.D.

Datum zadání bakalářské práce: **15.02.2021**

Platnost zadání bakalářské práce: **18.09.2022**


.....
doc. Ing. Martin Rožánek, Ph.D.
podpis vedoucí(ho) katedry


.....
prof. MUDr. Jozef Rosina, Ph.D., MBA
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Student(ka) bere na vědomí, že je povinnen(a) vypracovat bakalářskou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v bakalářské práci.

07.04.2021
Datum převzetí zadání


Podpis studenta(ky)

PROHLÁŠENÍ

Prohlašuji, že jsem bakalářskou práci s názvem „Detekce svalového artefaktu v EEG záznamech pomocí časově-frekvenční analýzy“ vypracovala samostatně a použila k tomu úplný výčet citací použitých pramenů, které uvádím v seznamu přiloženém k bakalářské 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), ve znění pozdějších předpisů.

V Kladně dne 12.05.2021

.....

Veranika Tuzankina

PODĚKOVÁNÍ

Ráda bych poděkovala především vedoucímu mé bakalářské práce Ing. Janu Štroblovi za velkou trpělivost, zodpovědnost a čas věnovaný konzultacím při přípravě této práce. Dále bych ráda poděkovala zaměstnancům Národního ústavu duševního zdraví za naměření a vyhodnocení EEG záznamu, které jsem ve své práci používala.

ABSTRAKT

Detekce svalového artefaktu v EEG záznamech pomocí časově-frekvenční analýzy:

Elektroencefalografie (EEG) je standardní neinvazivní zobrazovací metoda, která vytváří záznam elektrických potenciálů mozku. EEG je často kontaminován signály, mající svůj zdroj mimo mozek měřeného subjektu, například svalovými artefakty. Svalové artefakty překrývají fyziologickou složku EEG signálu a činí interpretaci EEG signálu komplikovanou. Tato práce je zaměřena na analýzu možnosti využití časově-frekvenční analýzy pro identifikaci svalových artefaktů v EEG záznamech. Prvním cílem této práce je analyzovat metody transformace EEG signálu do komplexního prostoru a následný získ časově-frekvenční analýzy. Dvě vybrané metody: Krátkodobá Fourierova transformace a Vlnková transformace byly aplikovány na vytvořený simulovaný EEG záznam v programovém prostředí MATLAB. Nastavením různých hodnot parametrů pro každou metodu byly získány spektrogramy. Ze dvou analyzovaných metod bylo lepší výsledků dosaženo pomocí metody STFT s nastavením č. 1. Na základě metody STFT s nastavením č. 1 byla vytvořena metodika, za použití reálných testovacích EEG dat, pro detekci svalových artefaktů v EEG signálu. Pro statistické vyhodnocení mnou navržené metodiky byla navržena a realizována statistická analýza správnosti detekce svalových artefaktů na reálných EEG datech pro validaci. Tato analýza využívala výpočet senzitivity a specifity. Navržená metodika se porovnávala s daty, která obsahovala EEG záznam s úseky, které všichni experti označili jako segment s artefakty a záznam s úseky, které označil alespoň jeden expert. Hodnocením mnou navržené metodiky, pomocí záznamu s úseky, které všichni experti ohodnotili jako segmenty s artefakty, kde byl výskyt artefaktu jistý, bylo docíleno průměrné senzitivity 72 % a průměrné specifity 84 %.

Klíčová slova

EEG, časově-frekvenční analýza, Krátkodobá Fourierova transformace, detekce svalových artefaktů, výkonové spektrum.

ABSTRACT

Detection of muscle artifact in EEG recordings using time-frequency analysis:

Electroencephalography (EEG) is a standard non-invasive imaging method that records the electrical potentials of the brain. EEG is often contaminated with signals that originate outside the subject's brain, such as muscle artifacts. Muscle artifacts overlap the physiological component of the EEG signal and make the interpretation of the EEG signal complicated. This work is focused on the analysis of the possibility of using time-frequency analysis to identify muscle artifacts in EEG recordings. The first goal of this work is to analyze the methods of transformation of the EEG signal into a complex space and the subsequent gain of time-frequency analysis. Two selected methods: Short-term Fourier transform and Wavelet transform were applied to the created simulated EEG record in the MATLAB programming environment. Spectrograms were obtained by setting different parameter values for each method. From the two analyzed methods, better results were achieved using the STFT method with setting No. 1. Based on the STFT method with setting No. 1, a methodology was created, using real test EEG data, for the detection of muscle artifacts in the EEG signal. For the statistical evaluation of the methodology proposed by me, a statistical analysis of the accuracy of the detection of muscle artifacts on real EEG data for validation was designed and implemented. This analysis used the calculation of sensitivity and specificity. The proposed methodology was compared with data that contained an EEG record with sections that all experts identified as a segment with artifacts and a record with sections identified by at least one expert. When evaluating my initial proposed methodology (using signal with segments), which experts were evaluating as segments with artifacts, where presence of artifact was precise, the average sensitivity of 72 % and average specificity of 84 % were reached.

Keywords

EEG, time-frequency analysis, Short-term Fourier transform, detection of muscle artifacts, power spectrum.

Obsah

Seznam symbolů a zkratk	9
Seznam obrázků	10
Seznam tabulek	12
1 Úvod	13
2 Přehled současného stavu	15
2.1 EEG rytmy.....	15
2.1.1 Artefakty.....	15
2.2 Časově-frekvenční analýza.....	17
2.2.1 Krátkodobá Fourierova transformace.....	19
2.2.2 Vlnková transformace.....	20
3 Cíle práce	22
4 Metody	23
4.1 Použitá data.....	23
4.1.1 Simulovaná data.....	23
4.1.2 Reálná data.....	25
4.2 Předzpracování dat.....	26
4.3 Výběr metody časově-frekvenční analýzy.....	26
4.3.1 Krátkodobá Fourierova transformace.....	26
4.3.2 Vlnková transformace.....	28
4.3.3 Vizualizace časově-frekvenční analýzy.....	30
4.4 Detekce svalového artefaktu.....	30
4.5 Statistické vyhodnocení.....	32
5 Výsledky	35
5.1 Výběr metody časově-frekvenční analýzy.....	35
5.2 Nastavení hranice pro detekci svalového artefaktu.....	39
5.3 Vyhodnocení metodiky detekce svalového artefaktu.....	40
6 Diskuse	42
6.1 Výběr metody časově-frekvenční analýzy.....	42
6.2 Detekce svalových artefaktů.....	43
6.3 Metodika detekce svalových artefaktů.....	43

7 Závěr	45
Seznam použité literatury	46
Příloha A: Obsah přiložených souborů	49

Seznam symbolů a zkratek

Seznam symbolů

Symbol	Jednotka	Význam
A	V	Amplituda
f	Hz	Frekvence
π		Ludolfovo číslo
t	s	Čas
θ	°	Fázový posun
j		Imaginární jednotka
$x[n]$		Zkoumaný signál
$w[n]$		Okénková funkce
ψ		Vlnka
s		Měřítka vlnky
τ	s	Aktuální čas, ve kterém se vlnka vyskytuje

Seznam zkratek

Zkratka	Význam
EEG	Elektroencefalografie
STFT	Krátkodobá Fourierova transformace (<i>Short-time Fourier transform</i>)
EKG	Elektrokardiografie
EOG	Elektrookulografie
EMG	Elektromyografie
MATLAB	Matrix Laboration
BSS	Separace slepých zdrojů (<i>Blind source separation</i>)
MMG	Mechanomyografie
NUDZ	Národní ústav duševního zdraví
ASSR	Zvukové stimulace (<i>Auditory steady state response</i>)
FFT	Rychlá Fourierova transformace (<i>Fast Fourier transform</i>)
cfg.foi	Frekvenční krok
cfg.toi	Časový krok
cfg.t_ftimwin	Krok časového okna
cfg.width	Šířka vlnky
ROC	Receiver Operating Characteristics
TP	Správně pozitivní (<i>True Positive</i>)
TN	Správně negativní (<i>True Negative</i>)
FP	Falešně pozitivní (<i>False Positive</i>)
FN	Falešně negativní (<i>False Negative</i>)
SE	Senzitivita
SP	Specifita

Seznam obrázků

1. Obrázek 2.1: a) Ukázka pěti normálních mozkových rytmů: alfa (8–13 Hz), beta (13–30 Hz), theta (4–7 Hz), delta (< 3,5 Hz), gama (30–100 Hz). b) Ukázka tří různých druhů biologických artefaktů: oční artefakt (EOG), svalový artefakt (EMG) a srdeční aktivita (EKG). Převzato z [2]. 16
2. Obrázek 2.2: Příklad signálu ve všech třech doménách (obrázek vlevo): časové (Time), frekvenční (Frequency) a prostorové (Space). Obrázek vpravo ukazuje příklad zobrazení signálu ve frekvenčním řezu. Na ose y je výkon signálu (Power), a na ose x je frekvence signálu (Frequency) Převzato z [1]. 17
3. Obrázek 2.3: Příklad signálu ve všech třech doménách (obrázek vlevo): časové (Time), frekvenční (Frequency) a prostorové (Space). Obrázek vpravo ukazuje příklad zobrazení signálu v časovém řezu. Na ose y je výkon signálu (Power), a na ose x je čas (Time). Převzato z [1]. 17
4. Obrázek 2.4: Příklad signálu ve všech třech doménách (obrázek vlevo): časové (Time), frekvenční (Frequency) a prostorové (Space). Obrázek vpravo ukazuje příklad grafického zobrazení, kde barva grafu (osa z nebo hloubka) reprezentuje výkon. Převzato z [1]. 18
5. Obrázek 2.5: Příklad signálu ve všech třech doménách (obrázek vlevo): časové (Time), frekvenční (Frequency) a prostorové (Space). Obrázek vpravo ukazuje příklad časově-frekvenčního zobrazení, kde barva grafu (osa z nebo hloubka) reprezentuje výkon. Na ose y je frekvence signálu (Frequency), a na ose x je čas (Time) Převzato z [1]. 18
6. Obrázek 2.6: Ukázka Morletovy vlnky. Na ose x je čas (Time) na ose y je amplituda (Amplitude). Převzato z [1]. 20
7. Obrázek 4.1: Celý simulovaný EEG signál. 24
8. Obrázek 4.2: Úsek simulovaného EEG signálu 1–3 s. 25
9. Obrázek 4.3: Reprezentace principu STFT. Na ose y je amplituda (Amplitude) a na ose x je čas (Time). Na obrázku je vidět posouvání (Shift) okna (Window) po celé délce signálu. Převzato a upraveno z [31]. 27
10. Obrázek 4.4: Reprezentace principu Vlnkové transformace. Na ose y je frekvence (Frequency) a na ose x je čas (Time). Červeně je označen EEG signál, modře je označena vlnka. Na obrázku je vidět posouvání vlnky (Shift) po celé délce signálu. Převzato a upraveno z [30]. 29
11. Obrázek 4.5: Grafická reprezentace STFT využívané v metodě detekce svalového artefaktu. STFT je zde aplikována na testovací EEG záznam, žlutá část reprezentuje

segmenty, které by následně měly být detekovány jako svalový artefakt. Spektrogram byl vytvořen z prvního kanálu.	31
12. Obrázek 4.6: Příklad zprůměrovaného výkonového spektra EEG signálu z prvního kanálu, zpracovaného pomocí Krátkodobé Fourierovy transformace.	32
13. Obrázek 5.1: Celý simulovaný EEG signál.	35
14. Obrázek 5.2: Časově-frekvenční analýza simulovaného EEG signálu po STFT s použitým nastavením č.1 , s frekvenčním krokem 0,1 Hz, časovým krokem po 0,2 s a nastaveným parametrem délky okna 0,6 s.	36
15. Obrázek 5.3: Časově-frekvenční analýza simulovaného EEG signálu po STFT s použitým nastavením č. 2 , s frekvenčním krokem 0,1 Hz, časovým krokem po 0,2 s a nastaveným parametrem délky okna 0,2 s.	36
16. Obrázek 5.4: Časově-frekvenční analýza simulovaného EEG signálu po STFT s použitým nastavením č. 3 , s frekvenčním krokem 0,001 Hz, časovým krokem po 3 s a nastaveným parametrem délky okna 3 s.	37
17. Obrázek 5.5: Časově-frekvenční analýza simulovaného EEG signálu po Vlnkové transformaci s použitým nastavením č. 1 , s časovým krokem po 5 s a nastaveným parametrem šířky vlnky 3.	37
18. Obrázek 5.6: Časově-frekvenční analýza simulovaného EEG signálu po Vlnkové transformaci s použitým nastavením č. 2 , s časovým krokem po 7 s a nastaveným parametrem šířky vlnky 5.	38
19. Obrázek 5.7: Časově-frekvenční analýza simulovaného EEG signálu po Vlnkové transformaci s použitým nastavením č. 3 , s časovým krokem po 9 s a nastaveným parametrem šířky vlnky 8.	38
20. Obrázek 5.8: ROC křivka, spočítaná pro různé hodnoty prahu. Červený bod reprezentuje optimální nastavení hodnoty prahu $0,35 \mu V^2/Hz$, kde senzitivita má hodnotu 92,6 % a specifita má hodnotu 86,5 %. Na ose x je 1-Specifita, na ose y je Senzitivita.	39
21. Obrázek 5.9: Detekce svalových artefaktů v záznamu z 200. kanálu mnou navrženou metodikou na reálných testovacích EEG datech.	40

Seznam tabulek

1. Tabulka 4.1: Charakteristiky simulovaného EEG signálu.....	24
2. Tabulka 4.2: Nastavené parametry pro testované varianty STFT.	28
3. Tabulka 4.3: Nastavené parametry pro testované varianty Vlnkové transformace. .	30
4. Tabulka 5.1: Statistické hodnocení reálného EEG záznamu s označenými úseky svalových artefaktů, na kterých se shodlo všech 5 expertů. Tabulka obsahuje senzitivitu a specificitu jednotlivých úseků a jejich průměrné hodnoty.	40
5. Tabulka 5.2: Statistické hodnocení reálného EEG záznamu s označenými úseky svalových artefaktů, které identifikoval alespoň jeden expert z 5. Tabulka obsahuje senzitivitu a specificitu jednotlivých úseků a jejich průměrné hodnoty.	41

1 Úvod

Elektroencefalografie (EEG) je záznam popisující časové změny elektrického potenciálu, způsobeného mozkovou aktivitou [1]. EEG se široce používá v neurovědě, kognitivní psychologii a dalších vědních oborech. EEG se používá k diagnostice různých stavů mozku, jako je zkoumání epileptické aktivity, poruch spánku nebo neurologických dysfunkcí [2]. EEG signál je považován za kvazistacionární (stacionární po částech) [3]. Z důvodu nestacionární povahy EEG záznamu je obtížné jeho vyhodnocení.

EEG je standardní neinvazivní metodou funkčního vyšetření elektrické aktivity centrálního nervového systému. Sumační signály z neuronů jsou snímány elektrodami z povrchu skalpu. Sumační potenciál vychází z celého orgánu. Výsledný biosignál je aritmetickým součtem signálů jednotlivých buněk [1]. Obvykle tento součet ovlivňují i signály vycházející z buněk jiných orgánů. Výsledkem je přítomnost různých biologických artefaktů v EEG záznamu. Artefaktem nazýváme signál, který nepochází z mozku. Svalový artefakt je elektrická aktivita svalů, která téměř vždy kontaminuje EEG záznam. Pro analýzu EEG záznamu je potřebné artefakty detekovat a případně odstranit. Může být obtížné přesně lokalizovat oscilační aktivity svalových artefaktů v časové a frekvenční oblasti [1].

Biologické signály jako EEG jsou často analyzovány v časové a frekvenční doméně. Existuje několik metod, pomocí kterých je možné transformovat signál do komplexního prostoru. Mezi takové metody patří například Fourierova transformace a Vlnková transformace. Speciálním případem Fourierovy transformace je krátkodobá Fourierova transformace (STFT). V rámci této práce jsou zvolené dvě metody transformace EEG signálu: Krátkodobá Fourierova transformace a Vlnková transformace. U STFT a Vlnkové transformaci se hledá kompromis mezi rozlišením v časové a frekvenční oblasti. Použitím vhodných parametrů nastavení obou metod lze dosáhnout optimálního rozlišení jak v časové, tak ve frekvenční oblasti. Výsledkem STFT a Vlnkové transformace je analytický signál. Jeho spektrální charakteristiku lze využít k detekci svalových artefaktů v EEG záznamu.

Výběrem vhodné metody lze získat časově-frekvenční analýzu signálu. U implementované metody nastavit vhodné parametry pro přesnější rozlišení jak v časové, tak ve frekvenční oblasti. Na základě implementované metody vytvořit metodiku vhodnou pro identifikaci svalových artefaktů. Aplikovat vytvořenou metodiku na reálné EEG záznamy. Navrhnout a následně realizovat statistickou analýzu správnosti detekce svalových artefaktů pomocí mnou vytvořené metodiky.

Tato práce je zaměřena na analýzu možnosti využití časově-frekvenční analýzy pro identifikaci svalových artefaktů v EEG záznamech. Cílem této práce je navrhnout metodu

k detekci svalového artefaktu v EEG signálu na základě vhodně zvolené metody transformace.

2 Přehled současného stavu

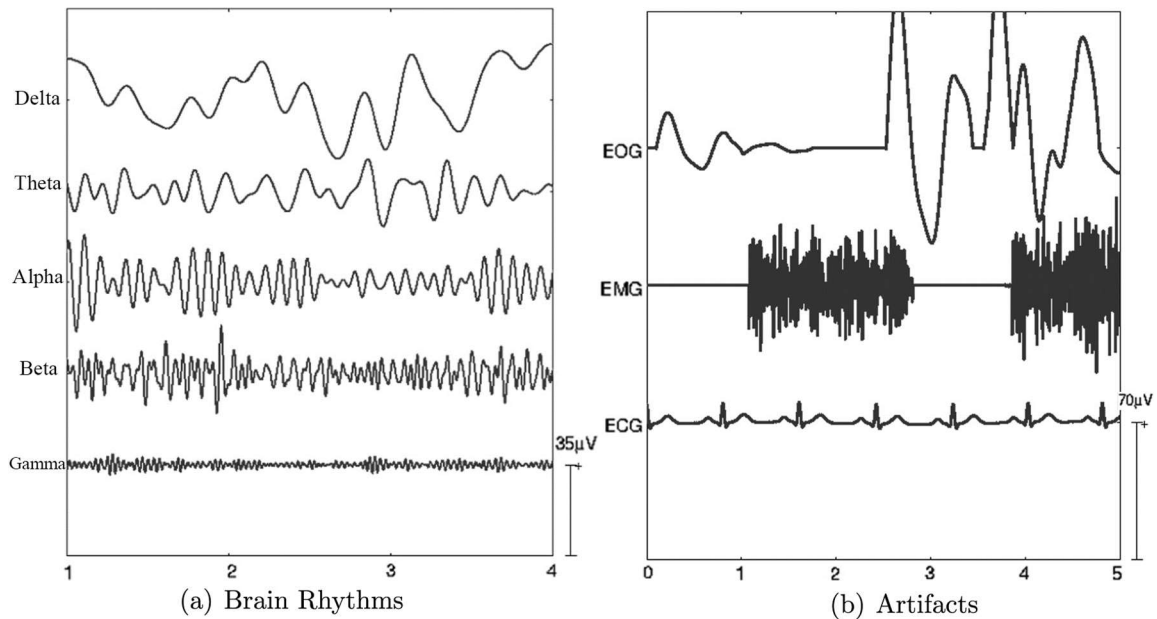
Elektroencefalografie (EEG) je standardní neinvazivní zobrazovací metoda, která vytváří záznam elektrických potenciálů mozku. EEG analýza se používá jako nástroj pro lékařskou diagnostiku různých onemocnění souvisejících s mozkem, jako je epilepsie, demence, mozkové poruchy, jako je stress a další mozková onemocnění [4]. K identifikaci těchto nervových poruch se provádí zpracování EEG signálu. Časově-frekvenční analýza poskytuje správnou vizualizaci EEG signálu k extrakci různých frekvenčních rytmů [4].

2.1 EEG rytmy

Amplituda EEG signálu se pohybuje mezi 10 a 100 μV a frekvence EEG signálu je v rozmezí 1 až 150 Hz [4]. Frekvenční složky lze oddělit prostřednictvím technik zpracování signálu. Rytmy EEG jsou seskupeny do pásem. Rytmická aktivita mozku obsahuje více frekvenčních pásem současně, které se liší svoji amplitudou a frekvencí. Frekvenční pásma mozkového rytmu obsahují alfa, beta, theta, delta a gama aktivity (viz Obrázek 2.1) [1]. Alfa aktivita se vyskytuje u zdravého dospělého jedince při bdění, relaxaci a zavřených očích v okcipitální a parietální oblasti [4]. Alfa aktivita je charakteristická frekvenčním rozsahem 8–13 Hz a amplitudou 20–200 μV . Beta aktivita se vyskytuje u dospělých při bdění a motorickém klidu ve frontální oblasti. Beta aktivita se charakterizuje frekvenčním rozsahem 13–30 Hz a amplitudou 5–10 μV [4]. Theta aktivita se vyskytuje při spánku u dospělých a u dětí v temporální a parietální oblasti. Theta aktivita je charakteristická frekvenčním rozsahem 4–7 Hz a amplitudou 5–10 μV [4]. Delta aktivita se vyskytuje při hlubokém spánku u novorozenců v okcipitální oblasti a při vážných mozkových poruchách u dospělých ve frontální oblasti. Delta aktivita je charakteristická frekvenčním pásmem do 3,5 Hz a amplitudou 20–200 μV . Gama aktivita se vyskytuje při krátkodobé paměti v precentrální oblasti. Pro gama aktivitu je charakteristické frekvenční pásmo 30–100 Hz [4].

2.1.1 Artefakty

EEG je často kontaminován signály, majícími svůj zdroj mimo mozek měřeného subjektu. Signály, které nepocházejí z mozku, se nazývají artefakty [5]. Artefakty jsou téměř vždy součástí EEG záznamu [5]. Vysokofrekvenční nervová aktivita se zcela překrývá se spektrální šířkou pásma svalové aktivity ($\sim 20\text{--}300$ Hz) [5]. Artefakty se dělí na biologické a technické. Nejčastějšími typy biologických artefaktů jsou: EOG artefakty (pohyby očí, očních víček), EKG artefakty (elektrická aktivita srdce) a svalové artefakty (viz Obrázek 2.1).



Obrázek 2.1: a) Ukázka pěti normálních mozkových rytmů: alfa (8–13 Hz), beta (13–30 Hz), theta (4–7 Hz), delta (< 3,5 Hz), gama (30–100 Hz). b) Ukázka tří různých druhů biologických artefaktů: oční artefakt (EOG), svalový artefakt (EMG) a srdeční aktivita (EKG). Převzato a upraveno z [2].

Dolní mezní frekvence aktivity svalových artefaktů je kolem 15 Hz, zatímco horní mezní hodnota aktivity je nad 100 Hz, ačkoli frekvenční pásmo artefaktů se liší podle typu svalu a typu kontrakce [5]. Maximální výkon žvýkacích svalů je ve frekvenčním pásmu kolem 50–60 Hz, pokud jde o frekvenci čelních svalů, které řídí pohyby obočí, dosahuje jejich výkon maxima ve frekvenčním pásmu 30–40 Hz [5]. Nejčastějšími typy technických artefaktů jsou například síťový šum (50 Hz) nebo špatné zapojení elektrod.

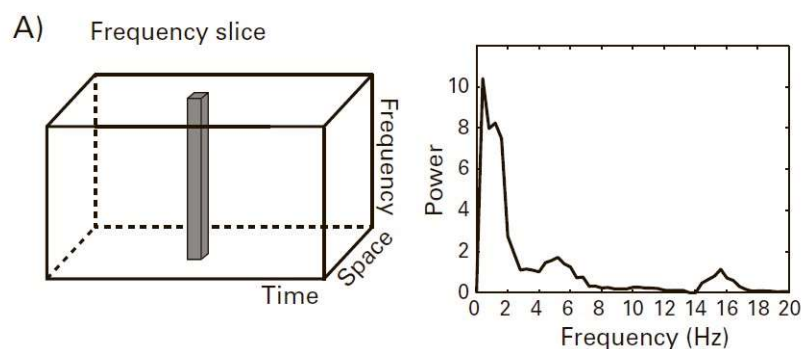
Artefakty snižují kvalitu EEG signálu a potlačují jeho charakteristiku. Zatímco technické artefakty a artefakty EKG a EOG lze poměrně účinně detekovat a odstranit pomocí adaptivních filtrů a technik separace slepých zdrojů (BSS – Blind source separation), artefakt vyvolaný svalovou aktivitou (např. kousání, žvýkání a zamračení) je zvláště obtížné detekovat a potlačit [6]. Hlavní důvod spočívá v tom, že EMG artefakt má vyšší amplitudu (ve srovnání s fyziologickou složkou EEG signálu) a širokou spektrální distribuci [6]. Svalový artefakt snižuje kvalitu všech EEG pásem, zejména se značně překrývá s beta aktivitou v rozmezí 13–30 Hz [2]. Svalové artefakty překrývají fyziologickou složku EEG signálu a činí interpretaci EEG signálu komplikovanou nebo dokonce nemožnou [6]. Důsledkem mohou být zhoršené výsledky zpracování signálu EEG, jako je například analýza mozkové konektivity.

Existuje značné množství metod, které se snaží detekovat, odstranit nebo do určité míry potlačit svalové artefakty. Pomocí detekce úseku EEG signálu, kde je přítomen svalový artefakt, lze tento segment odstranit a následně analyzovat pouze záznam mozkové aktivity. K detekci svalového artefaktu lze využít jeho vysoké amplitudy (nad 20 Hz).

2.2 Časově-frekvenční analýza

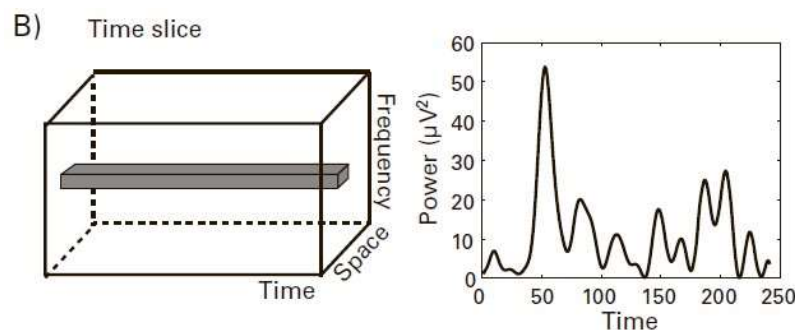
Analýza signálu je proces získávání informací obsažených v signálu [7]. Analýza stacionárních signálu je triviální a může být jednoduše reprezentována v časové nebo frekvenční doméně [4]. EEG je však nestacionární signál a k jeho zpracování se používá mimo jiné časově-frekvenční analýza.

Výsledky časově-frekvenční analýzy jsou reprezentovány v trojrozměrném prostoru, kde rozměry jsou frekvence, čas a prostor. Frekvenční řez (viz Obrázek 2.2) reprezentuje spektrální výkon (energii v každém frekvenčním pásmu na ose y) jako funkci frekvence (osa x), která se mění v čase. Čas se v takovém zobrazení “ztrácí”, v tom smyslu, že není možné určit, zda a jak se frekvenční charakteristiky v průběhu času mění [1]. Popis signálu ve frekvenční oblasti se zaměřuje na posouzení celkového charakteru signálu v celém jeho časovém rozsahu [8]. V takovém případě hovoříme o frekvenční analýze.




Obrázek 2.2: Příklad signálu ve všech třech doménách (obrázek vlevo): časové (Time), frekvenční (Frequency) a prostorové (Space). Obrázek vpravo ukazuje příklad zobrazení signálu ve frekvenčním řezu. Na ose y je výkon signálu (Power), na ose x pak frekvence signálu (Frequency). Převzato z [1].

Časový řez (viz Obrázek 2.3), reprezentuje jedno frekvenční pásmo a jeho průběh v čase. Popisem signálu v časové oblasti je možné určovat okamžité hodnoty signálu v konkrétních časech a jejich trendech [1].



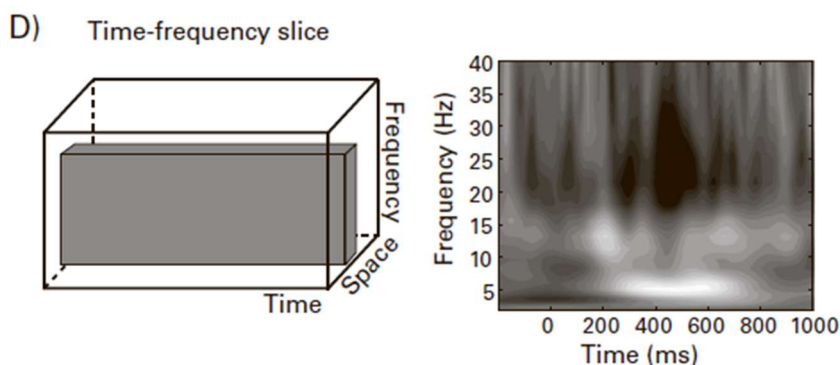
Obrázek 2.3: Příklad signálu ve všech třech doménách (obrázek vlevo): časové (Time), frekvenční (Frequency) a prostorové (Space). Obrázek vpravo ukazuje příklad zobrazení signálu v časovém řezu. Na ose y je výkon signálu (Power), na ose x pak čas (Time). Převzato z [1].

Prostorový řez (viz Obrázek 2.4), reprezentuje data v jednom časově-frekvenčním bodě nebo v průměru přes několik vedlejších časově-frekvenčních bodů. Prostorový řez umožňuje vizualizaci topografického rozložení dat a usnadňuje topografickou lokalizaci [1].



Obrázek 2.4: Příklad signálu ve všech třech doménách (obrázek vlevo): časové (Time), frekvenční (Frequency) a prostorové (Space). Obrázek vpravo ukazuje příklad grafického zobrazení, kde barva grafu (osa z nebo hloubka) reprezentuje výkon. Převzato z [1].

V časově-frekvenčním řezu (viz Obrázek 2.5), lze nakonec data zobrazit v časově-frekvenčním grafu, kde na ose x je čas a na ose y je frekvence. Barva grafu (osa z nebo hloubka) reprezentuje některé charakteristiky dat, jako je výkon, fázové shlukování, konektivita nebo korelační koeficient [1].



Obrázek 2.5: Příklad signálu ve všech třech doménách (obrázek vlevo): časové (Time), frekvenční (Frequency) a prostorové (Space). Obrázek vpravo ukazuje příklad časově-frekvenčního zobrazení, kde barva grafu (osa z nebo hloubka) reprezentuje výkon. Na ose y je frekvence signálu (Frequency), na ose x pak čas (Time). Převzato z [1].

Výhodou kombinace časové a frekvenční analýzy je možnost určení okamžité frekvence. Analytické parametry umožňují zvolit lepší přesnost v jedné oblasti (časové nebo frekvenční) na úkor horší přesnosti v druhé oblasti [1]. Existuje několik prací, které provádějí srovnání metod klasifikace EMG signálů, viz studie [9]. Z navržených 37 metod ukazovala ve studii nejlepší výkon frekvenční informační metoda v časové doméně [9]. Potvrzuje to účinnost časově-frekvenční analýzy a důvod použití této metody pro detekci svalových artefaktů.

Pro vizualizaci časově-frekvenční analýzy se používá spektrogram, který poskytuje informace o výkonu jednotlivých komponent signálu a rozložení frekvence v čase [10]. Existují dva hlavní problémy spektrogramu: je obtížné nebo není možné zvolit optimální délku okna pro datové segmenty, které obsahují několik různých funkcí. Existuje zde časově-frekvenční kompromis: zlepšení rozlišení nižších frekvencí na úkor zkrácení délky dat. Existující časově-frekvenční kompromis byl přirovnán k principu nejistoty, kde součin frekvenčního rozlišení (vyjádřený jako šířka pásma) a času, musí být větší než určité minimum [11]:

$$BT \geq \frac{1}{4\pi}, \quad (2.1)$$

kde B je šířka pásma, T je čas a π je Ludolfovo číslo.

Hlavní motivací celé práce je navrhnout takovou metodu, která by usnadnila hodnocení a zpracování EEG signálů. Následně popsat efektivitu navržené metody a její možné využití v budoucnu. Metoda detekce artefaktů na základě časově-frekvenční analýzy by měla pomoci řadě studií, které se zabývají zkoumáním různých aktivit mozku. Vzhledem k tomu, že některé mozkové aktivity mohou být překrývány artefakty, zkoumání určitých částí mozkových aktivit je omezeno.

Pro programovací prostředí MATLAB existuje několik sad nástrojů (toolbox) vhodných pro aplikování časově-frekvenční analýzy, které usnadňují zpracování biomedicínských signálů. V této práci byl k analýze metod transformace EEG signálu použit FieldTrip toolbox [12].

2.2.1 Krátkodobá Fourierova transformace

Řada studií [11, 13, 14, 15] používá Krátkodobou Fourierovou transformaci pro zpracování nestacionárních EMG signálu. STFT je výpočetně efektivní a poskytuje spolehlivé časově-frekvenční grafy pro pomalu se měnící signály [11]. Metody založené na STFT předpokládají, že je signál na krátkých úsecích stacionární [14]. STFT používá časová okna (krátké segmenty dat). Délka okna pro výpočet spektra signálu určí rozlišení v časové a frekvenční oblasti. Čím je okno delší, tím je lepší rozlišení ve frekvenční oblasti a horší v časové, protože delší okno zachytí víc frekvenčních složek na větším časovém úseku. Naopak kratší časové okno není schopné zachytit větší množství frekvenčních složek na malém časovém úseku. Při nastavování parametrů časového okna proto vzniká kompromis mezi rozlišením v časové a frekvenční oblasti [17]. Metoda STFT vytváří časově-frekvenční mapu, ze které je možné získat časový průběh výkonu určité frekvence nebo výkonové spektrum v určitém čase [1].

Pro volbu vhodných parametrů nastavení STFT k detekci svalových artefaktů bylo využito několika studií [17, 18], které používají metodu STFT k analýze EMG záznamu. Studie [17] se věnuje zpracování EMG signálů v časově-frekvenční oblasti za použití STFT a Vlnkové transformace. Účelem studie bylo zkoumat mechanomyografické


(MMG) a elektromyografické (EMG) odpovědi v časově-frekvenční oblasti. Hlavním zjištěním bylo, že STFT a Vlnková transformace vytvářely podobné časové a frekvenční reprezentace pro sledování změn frekvencí MMG a EMG. Z toho plyne vhodnost použití těchto dvou metod k detekci svalových artefaktů i pro tuto práci. Studie [18] se věnuje analýze časově-frekvenční koherence mezi EEG a EMG aktivitami v trvání únavy, za použití metody STFT a koherenční analýzy. Hlavní zjištění práce bylo, že STFT a koherenční analýza poskytují užitečné výsledky pro současné EEG a EMG záznamy. Z toho rovněž plyne vhodnost použití metody STFT k detekci svalových artefaktů i pro tuto práci.

Časové a frekvenční rozlišení vždy zaleží na nastavení parametrů a konkrétním signálu, pro který je daná metoda použita. Obecně je velmi obtížné určit, které parametry nastavení jsou vhodné pro časově-frekvenční analýzu [14].

2.2.2 Vlnková transformace

Druhá často používaná metoda pro časově-frekvenční analýzu EEG signálu je Vlnková transformace. Podobně jako STFT, Vlnková transformace předpokládá stacionaritu EEG signálu na krátkých úsecích a reprezentaci signálu jako součet sinusu a kosinusu o příslušné amplitudě a frekvenci. Základem této transformace je vlnka. Podobně jako změna parametrů okna u metody STFT, změna délky vlnky a její pozice v čase určí rozlišení v časové a frekvenční oblasti [14]. Existuje velké množství různých typu vlnek. Ne všechny vlnky však jsou užitečné pro časově-frekvenční analýzu dat EEG. Nejpoužívanější u EEG signálu je Morletova vlnka (viz Obrázek 2.6). Morletova vlnka představuje sinusovou vlnu, která se zužuje k nule směrem k oběma koncům. Díky takovému tvaru Morletova vlnka poskytuje rovnováhu mezi časovým a frekvenčním rozlišením bez artefaktů, způsobených hranami posouvací vlnky. Morletova vlnka je užitečná pro lokalizaci změn frekvenčních charakteristik v čase [1].

Aby bylo možné z EEG signálu extrahovat informace o frekvencích v určitém čase, musí být data vynásobena sinusovou vlnkou. Bez vynásobení výsledek vlnkové transformace reprezentuje průběh frekvencí na celé časové řadě [1].



Obrázek 2.6: Ukázka Morletovy vlnky. Na ose x je čas (Time), na ose y pak amplituda (Amplitude). Převzato z [1].

Pro volbu vhodných parametrů nastavení Vlnkové transformace k detekci svalových artefaktů bylo vycházeno z několika studií [19, 20]. Časové a frekvenční rozlišení metody zaleží na volbě vlky a nalezení jejích vhodných parametrů.

3 Cíle práce

Cílem této práce je analyzovat možnost využití časově-frekvenční analýzy pro identifikaci svalových artefaktů v EEG záznamech. Vybrat vhodnou metodu časově-frekvenční analýzy s vhodně zvolenými parametry a implementovat ji v programovém prostředí MATLAB. Následně vytvořit simulovaný EEG signál pro otestování a vyhodnocení metod transformace časové frekvenční analýzy. Na základě vybrané metody časově-frekvenční analýzy vytvořit metodiku vhodnou pro identifikaci svalových artefaktů.

Dalším cílem je aplikovat vytvořenou metodiku na reálné EEG záznamy. Posledním cílem je navrhnout a následně realizovat statistickou analýzu správnosti detekce svalových artefaktů pomocí mnou vytvořené metodiky.

4 Metody

V této kapitole jsou popsány metody, které jsem využívala k zpracování EEG signálu. EEG signál je stacionární po částech, proto pro detekci svalových artefaktů bylo zapotřebí zvolit vhodnou metodu k jeho zpracování [3]. Při použití metod časově-frekvenční analýzy je důležité zvolit optimální nastavení parametrů. Zvolené parametry okna u Krátkodobé Fourierovy transformace jsou popsány v kapitole 4.3.1 a parametry vlnky u Vlnkové transformace jsou popsány v kapitole 4.3.2. Abych zajistila funkčnost metod byl použit simulovaný EEG signál, který je popsán v kapitole 4.1.1. Následně byl navržen algoritmus pro detekci svalových artefaktů na základě jedné metody, která vykazovala nejlepší výsledky. Vlastní detekční algoritmus je popsán v kapitole 4.4, kde byla využita reálná testovací EEG data k nastavení prahové hodnoty výkonu. Pro statistické vyhodnocení efektivity metody byla využita reálná data pro validaci, zpracována pěti experty.

4.1 Použitá data

4.1.1 Simulovaná data

Simulovaný EEG signál byl vytvořen pro zajištění funkčnosti metod. Pro volbu vhodné metody časově-frekvenční analýzy k odstranění svalového artefaktu v reálných záznamech jsem nejdříve všechny metody aplikovala na simulovaný EEG signál, kde jsem přesně věděla charakteristiky analyzovaného signálu (viz Tabulka 4.1).

EEG je po částech stacionární signál, proto bylo vytvořeno několik časových úseků různé délky, obsahujících různé frekvenční složky, aby výsledná simulace aproximovala reálný EEG záznam. Simulovaný signál byl vytvořen součtem sinusových vln o různých frekvencích a s proměnnou délkou časových úseků. Sinusové vlny lze matematicky popsat pomocí následujícího vzorce:

$$A \sin(2\pi f t + \theta), \quad (4.1)$$

kde A je amplituda sinusové vlny, π je Ludolfovo číslo, f je frekvence sinusové vlny, t je čas a θ je fázový posun [1].

Zvolené hodnoty frekvenčních složek odpovídaly rozmezí skutečných frekvenčních pásem EEG záznamu. V simulovaném signálu se vyskytovaly následující aktivity: alfa (9, 10, 12 Hz), beta (20, 25, 30 Hz), delta (3, 5 Hz) a theta (2, 5 Hz). Použita vzorkovací frekvence byla 1000 Hz. Celková délka simulovaného signálu byla 80 sekund. Simulovaný signál byl složen z úseků, majících rozdílné časy, rozdílný počet frekvencí a rozdílný součet sinusových vln (někdy byla jen jedna, někdy i tři). Vytvořený signál se nejvíce přibližoval reálnému nestacionárnímu EEG signálu, kde se různé frekvence mezi


sebou překrývají a mění s časem. Výsledný simulovaný EEG signál byl následně shrnut do jedné programové funkce v prostředí Matlab.

V tabulce 4.1 jsou uvedené charakteristiky simulovaného EEG signálu: frekvence, které se vyskytují v jednotlivých úsecích, jejich čas a doba trvání.

Tabulka 4.1: Charakteristiky simulovaného EEG signálu.

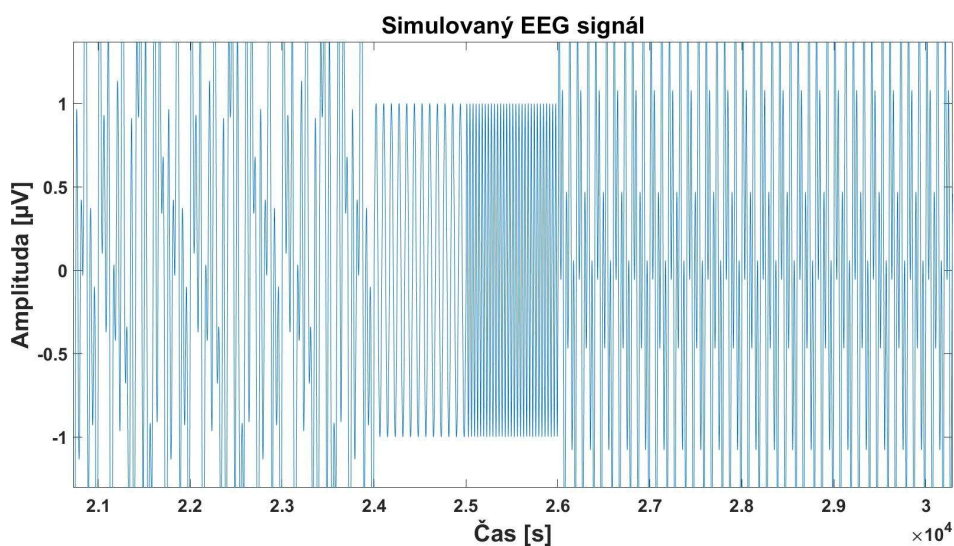
Úsek	Frekvence (Hz)	Čas (s)	Doba trvání (s)
1	10, 30, 3, 2	0–15	15
2	12, 20, 5, 2	15–24	9
3	12	24–25	1
4	30	25–26	1
5	10, 25	26–36	10
6	10, 5	36–46	10
7	9, 20, 5	46–49	3
8	10, 2	49–59	10
9	25, 5	59–69	10
10	12	69–70	1
11	10, 25, 5	70–80	10

Na obrázku 4.1 je uveden simulovaný EEG signál délkou 80 sekund. Použita vzorkovací frekvence byla 1000 Hz.



Obrázek 4.1: Celý simulovaný EEG signál.

Na obrázku 4.2 je uveden úsek simulovaného signálu 1–3 s.



Obrázek 4.2: Úsek simulovaného EEG signálu 1–3 s.

4.1.2 Reálná data

V této práci jsem používala 2 druhy reálných dat: testovací a validační. Testovací data obsahovala záznam s velkým množstvím výrazných artefaktů hodnocený jedním expertem. Tento typ dat jsem používala pro nastavení prahové hodnoty výkonu v detekčním algoritmu (viz kapitola 4.4). Validační data obsahovala 10 záznamů hodnocených pěti experty, kde se svalový artefakt vyskytuje stejně často, jako v běžném EEG záznamu. Tato data byla použita pro statistické vyhodnocení mnou navržené metodiky (viz kapitola 4.5).

K získání testovacích dat pro tuto práci bylo provedeno měření v Národním ústavu duševního zdraví (NUDZ). Měření probíhalo ve Faradayové kleci pomocí přístroje EGI Net Amps 400, jednalo se o hdEEG s 256 kanály. Vzorkovací frekvence snímaného signálu byla 1000 Hz. Pro referenční signály byly použity elektrody umístěné na mastoidech. Měření bylo schváleno etickou komisí NUDZ a subjekt podepsal informovaný souhlas. Subjekt měl po dobu nahrávání náhodně zatnout čelist, mračit se či provádět oba úkony zároveň. Tyto tři úkony subjekt prováděl náhodně, aniž by nad nimi uvažoval a mezi nimi byly časové úseky, kdy byl subjekt v klidu. Data byla nahrávána na pozadí ASSR (auditory steady state response) zvukové stimulace. Stimulace probíhala zvukem o frekvenci 40 Hz. Pro potřeby porovnání efektivity metody, byla provedena identifikace svalových artefaktů expertem. Expert měl nejdříve za úkol hledat svalové artefakty v celém EEG signálu a následně identifikovat EEG kanály, ve kterých se svalový artefakt vyskytoval.

Druhá sada dat byla použita pro validaci. K získání validačních dat pro tuto práci bylo provedeno opět měření ASSR stimulace. Subjekt ovšem tentokrát nevytvářel

záměrně svalový artefakt. Jednalo se o běžný EEG experiment, kde se svalové artefakty vyskytovaly v obdobném množství, jako se budou vyskytovat i v budoucích EEG záznamech, pro jejichž čištění by měla být metoda využívána. Měření bylo schváleno etickou komisí NUDZ a každý subjekt podepsal informovaný souhlas. Subjekt byl po dobu nahrávání v klidu. Svalový artefakt se vyskytoval jenom v kanálech blízkých zdroji artefaktu. Záznamy z elektrod umístěných ve frontální a temporální oblasti jsou s větší pravděpodobností kontaminovány svalovým artefaktem. Pro porovnání efektivity metody byla provedena identifikace svalového artefaktu experty. Data hodnotilo 5 různých expertů. Pro vyhodnocení se vytvořená metoda porovnávala s úseky, které identifikovali všichni experti jako svalový artefakt a s úseky, které vyhodnotil alespoň jeden expert jako svalový artefakt. Pro EEG záznam, kde svalový artefakt detekovali všichni experti, jsou charakteristické výraznější artefakty a menší chybovost experta. Pro EEG záznam, kde svalový artefakt detekoval alespoň jeden expert, jsou charakteristické méně výrazné artefakty a větší chybovost experta.

4.2 Předzpracování dat

Následné předzpracování signálů probíhalo v programovém prostředí MATLAB [21] (verze 9.7.0.1296695) s použitím toolbox FieldTrip [12].

Pro správné výstupy a statistické vyhodnocení je nutným předpokladem kvalitní předzpracování dat. Pokud je signál zatížen síťovým rušením, je obtížně detekovat svalové artefakty, což může výrazně zkreslit výsledné hodnocení navržené metody. Důvodem je překrývající se spektrum výskytu svalového artefaktu a síťového šumu, proto byl síťový šum odfiltrován při předzpracování dat. Pro odstranění síťového šumu jsem použila dftf filtr, který využívá Diskrétní Fourierovy transformace.

Po filtraci EEG signálů na začátku a na konci zbývaly vrcholy, které jsou velmi ostré a také obsahují vysokofrekvenční složky. Pro zlepšení výstupu signálu byly nevhodné úseky záznamu odstraněny.

Posledním krokem předzpracování signálu bylo posunutí střední hodnoty signálu na nulu a odstranění fluktuace použitím funkce detrend.

4.3 Výběr metody časově-frekvenční analýzy

Tato kapitola popisuje metody časově-frekvenční analýzy, ze kterých byla vybírána metoda vhodná pro detekci svalových artefaktů. Použitím různých nastavení parametrů na simulovaných datech jsem ověřila vhodné nastavení těchto metod.

4.3.1 Krátkodobá Fourierova transformace

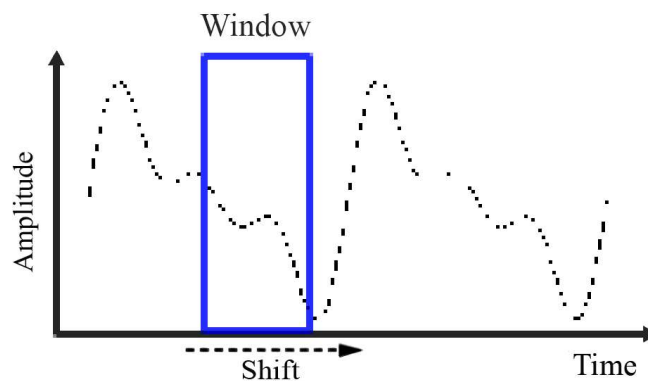
Krátkodobá Fourierova transformace je metoda časově-frekvenční analýzy signálu. Metoda vychází z algoritmu Rychlé Fourierovy transformace (FFT) a spočívá v rozdělení

zkoumaného signálu na úseky, které jsou vynásobeny okénkovou funkcí [22]. Následně je (z vynásobených segmentů, pomocí FFT) spočítáno spektrum. Frekvenční spektra segmentů jsou nakonec poskládána za sebe, čímž se získá průběh frekvenčních komponent v čase, který se nazývá spektrogram [22]. Nejdůležitějšími parametry jsou u STFT délka a typ časového okna. Čím je delší časové okno, tím je lepší frekvenční rozlišení, ale horší časové. Naopak, čím je časové okno kratší, tím je lepší časové rozlišení a horší frekvenční. Na výsledné spektrum má také vliv typ zvoleného časového okna. Aby nedocházelo k tzv. průsaku spekter (spectral leakage), který vznikne vlivem konvoluce spektra zkoumaného signálu se spektrem časového okna části signálu (časové okno obsahuje neceločíselné násobky periody vstupního signálu) [1, 8]. STFT pro diskrétní signál je definována následovně: [8]

$$STFT(t, \omega) = \sum_{n=-\infty}^{\infty} x[n]w[n - m]e^{-j\omega n} , \quad (4.2)$$

kde $x[n]$ je zkoumaný signál, $w[n]$ je okénková funkce a t je délka časového okna, j je imaginární jednotka.

Okénková funkce se pohybuje po celé délce signálu a rozděljuje ho na určité úseky, na které se aplikuje FFT (viz obr. Obrázek 4.3). Následně jsou získána spektra jednotlivých časových úseků.



Obrázek 4.3: Reprezentace principu STFT. Na ose y je amplituda (Amplitude), na ose x pak čas (Time). Na obrázku je vidět posouvání (Shift) okna (Window) po celé délce signálu. Převzato a upraveno z [23].

Existuje několik typů okénkových funkcí, nepoužívanější jsou obdélníkové, Hammingovo, Hanningovo, trojúhelníkové a Blackmanovo okno. K získání časově-frekvenční analýzy bylo zvoleno Hanningovo okno. Tento typ okna se používá na EEG i v jiných studiích s EEG signálem [24, 4]. Je to sinusové okno, které na začátku a na konci časového segmentu tlumí data úplně na nulu a veškerá váha je soustředěna uprostřed daného časového úseku [1, 8]. Hanningovo okno je definováno vztahem: [25]

$$w(n) = 0,5 \left(1 - \cos \left(2\pi \frac{n}{N} \right) \right), \text{ pro } 0 \leq n \leq N, \quad (4.3)$$

kde N je počet vzorků v okně, n je počet vzorků v analyzovaném segmentu.

Časově-frekvenční analýza byla získána pomocí funkce `ft_freqanalysis` z toolboxu `FieldTrip`. Funkce používá posuvné časové okno, pro které se vypočítávají komplexní koeficienty pro danou frekvenci. Pro volbu vhodných parametrů nastavení STFT jsem vycházela z několika studií [17, 18], které používají metodu STFT k analýze EMG signálu (viz kapitola 2.5 [17], kapitola preprocessing [18]). Dle empirického testování (viz Tabulka 4.2) jsem v této práci zvolila parametry následovně:

- `cfg.foi`, sledované frekvence pro testování na simulovaném signálu byly nastaveny v rozmezí 1–40 Hz v krocích nastavených dle tabulky 4.2. Při zmenšení frekvenčního kroku dojde k lepšímu frekvenčnímu rozlišení na úkor mimo jiné doby výpočtu.
- `cfg.toi`, časový interval zájmu. Tento vektor určuje střední časy pro časová okna, pro která by se měly vypočítat hodnoty výkonu. Například nastavení `cfg.toi = 1:2:78` vede k hodnotám výkonu od 1 do 78 s v krocích po 2 s. Příliš jemné časové rozlišení může vést k poskytnutí nadbytečné informace a delší výpočetní časy.
- `cfg.t_ftimwin` je délka posuvného časového okna v sekundách. Při výběru tohoto parametru je důležité, aby se do časového okna pro danou frekvenci vešel plný počet cyklů.

Tabulka 4.2: Nastavené parametry pro testované varianty STFT.

Nastavení č.	Parametr	<code>cfg.foi</code>	<code>cfg.toi</code>	<code>cfg.t_ftimwin</code>
	Argument	Frekvenční krok	Časový krok (s)	Krok (s)
1		0,1	0,2	0,6
2		0,1	0,2	0,2
3		0,001	3	3


4.3.2 Vlnková transformace

Vlnková transformace, podobně jako Fourierova transformace předpokládá, že signál lze reprezentovat součtem sinusů a kosinusů o příslušné amplitudě a frekvenci [14]. Pomocí Vlnkové transformace lze získat informaci o tom, které frekvence se v signálu vyskytují a jaké je jejich umístění v čase. Vlnková transformace je definována následujícím vztahem: [26]

$$WT(s, \tau) = \frac{1}{\sqrt{s}} \int_{-\infty}^{\infty} x(t) \bar{\psi} \left(\frac{t-\tau}{s} \right) dt, \quad (4.5)$$

kde ψ je vlnka, s je měřítko vlnky, τ je aktuální čas, ve kterém se vlnka vyskytuje.

Základem této transformace je vlnka. Volba vhodné vlnky a nastavení její parametrů, podobně jako u STFT, má vliv na časové a frekvenční rozlišení [8]. Vlnka se pohybuje po celé délce signálu a pomocí integrace skalárního součinu s vlnkou určuje koeficient podobnosti mezi signálem a vlnkou (viz Obrázek 4.4). Poté, co vlnka dorazí na konec signálu, změní se její měřítko a celý proces se opakuje [8].



Obrázek 4.4: Reprezentace principu Vlnkové transformace. Na ose y je frekvence (Frequency) a na ose x je čas (Time). Červeně je označen EEG signál, modře je označena vlnka. Na obrázku je vidět posouvání vlnky (Shift) po celé délce signálu. Převzato a upraveno z [27].

Existuje několik typů vlnek, používaných pro časově-frekvenční analýzu, například vlnky Haar, Daubechies, Symlet, Morlet, Mexický klobouk. Jeden z klíčových parametrů, který je třeba nastavit u Vlnkové transformace je šířka vlnky. Tento parametr určuje šířku vlnek v počtu cyklů. Zmenšení hodnoty šířky vlnky zvyšuje časové rozlišení na úkor frekvenčního a naopak [12]. V této práci byla zvolena Morletova vlnka, která je definována vztahem: [28]

$$\psi(x) = \frac{\cos(x\pi\sqrt{\frac{2}{\ln 2}})e^{-\frac{x^2}{2}}}{\sqrt[4]{\pi}}, \quad (4.6)$$

kde π je Ludolfovo číslo, x je počet vzorků vlnky.

Časově-frekvenční analýza byla provedena pomocí funkce `ft_freqanalysis` z toolboxu `FieldTrip`. Pro volbu vhodných parametrů nastavení Vlnkové transformace jsem vycházela z několika studií [19, 20]. Dle empirického testování (viz Tabulka 4.3) jsem zvolila parametry následovně:

- `cfg.foilim`, sledované frekvence, v této práci byly nastaveny pro simulovaný signál v rozmezí 1–40 Hz, v krocích nastavených dle tabulky 4.3.
- `cfg.toi`, časový interval zájmu. Tento vektor určuje střed vlnky, pro kterou by se měly vypočítat hodnoty výkonu. Nastavení `cfg.toi = 2.5: 7: 77.5` vede k hodnotám výkonu od 2.5 do 77.5 s v krocích po 7 s.
- `cfg.width`, šířka vlnky byla nastavena na 5 podle tabulky 4.3.

Tabulka 4.3: Nastavené parametry pro testované varianty Vlnkové transformace.

Nastavení	Parametr	cfg.toi	cfg.width
č.	Argument	Časový krok (s)	Šířka vlnky
1		5	3
2		7	5
3		9	8

4.3.3 Vizualizace časově-frekvenční analýzy

Pro vizualizaci časově-frekvenční analýzy se používá spektrogram, který poskytuje informace o výkonu jednotlivých komponent signálu a informace o rozložení frekvence v čase. Výkon byl získán pomocí absolutní hodnoty komplexních koeficientů na druhou. Spektrogram je definován následujícím vztahem: [10]

$$SPECT(t, \omega) = |STFT(t, \omega)|^2, \quad (4.4)$$

kde $STFT(t, \omega)$ je signál po aplikování Krátkodobé Fourierové transformace.

Pomocí tří různých nastavení parametrů STFT, byly získány tři spektrogramy. U Vlnkové transformace, podobně jako u STFT, použitím tří různých nastavení parametrů, byly také získány tři spektrogramy. Porovnáním frekvenčních složek (zobrazených spektrogramem) se skutečně obsaženými frekvenčními složkami v simulovaném EEG signálu, bylo nalezeno optimální nastavení parametrů pro STFT a Vlnkovou transformaci. Víme, že simulovaný signál obsahuje jak nižší, tak vyšší frekvence, proto délka posuvného okna u metody STFT byla nastavena na menší a větší hodnotu (viz kapitola 2.2.1). Při větším časovém kroku a delším posuvném okně bylo dosaženo lepšího frekvenčního rozlišení a naopak. U Vlnkové transformace, podobně jako u STFT, šířka vlnky byla nastavena na menší a větší hodnotu (viz kapitola 2.2.2). Při větším časovém kroku a větší šířce vlnky bylo dosaženo lepšího frekvenčního rozlišení a naopak.

V kapitole 5 jsou znázorněny spektrogramy simulovaného signálu po aplikování STFT a Vlnkové transformace pro všechna nastavení parametrů.

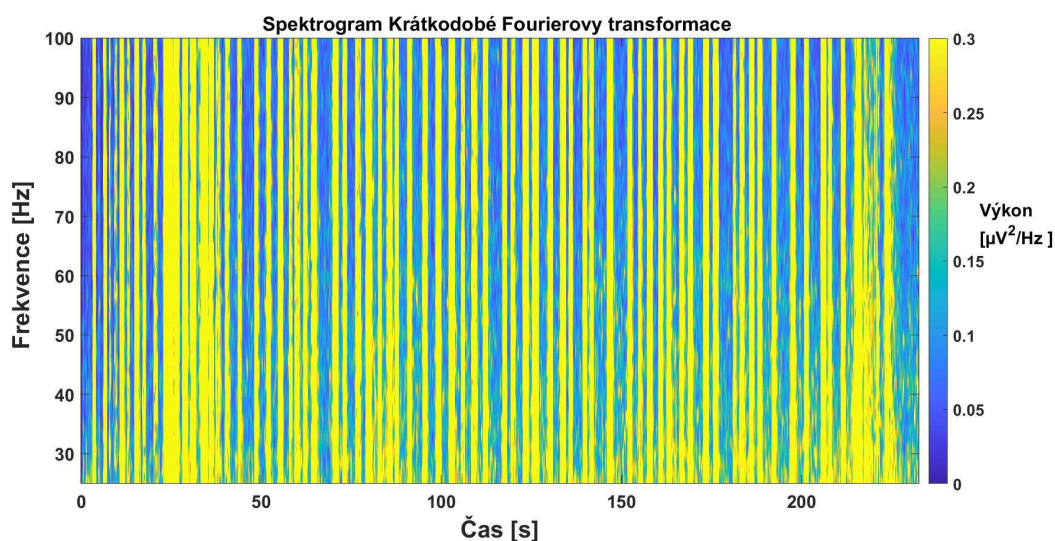
4.4 Detekce svalového artefaktu

Tato kapitola popisuje vytvořenou metodu detekce svalového artefaktu za pomoci časově-frekvenční analýzy vybrané na simulovaném signálu. Metoda byla vytvářena za pomoci reálného testovacího EEG záznamu, kde se vyskytovaly výrazné svalové artefakty ve velkém množství. K detekci svalových artefaktů jsem zvolila metodu STFT s nastavením parametrů číslo 1 (viz kapitola 4.3.1). Metoda funguje na principu nastavení prahové hodnoty průměrného spektrálního výkonu, který byl získán pomocí absolutní hodnoty komplexních koeficientů na druhou a následně zprůměrován. Výkonové spektrum bylo spočteno za pomoci STFT pro frekvence od 25 do 100 Hz. Výpočet

probíhal pro EEG kanály v oblasti 1–50 a 225–256. Zvolené kanály obsahují záznamy z elektrod umístěných nejbližší ke zdroji artefaktu. Analyzované frekvenční pásmo je 25–100 Hz, které odpovídá šířce pásma svalové aktivity. Je důležité správně zvolit prahovou hodnotu výkonu, aby navržená metodika byla efektivní. Při nízké hodnotě prahu by metoda vykazovala falešně pozitivní výsledky, a naopak při vysoké hodnotě prahu by metoda vykazovala falešně negativní výsledky.

Metoda STFT ovlivňuje časové rozlišení výstupních dat, to je dané metodou a parametry nastavení posuvného okna. To má za následek menší velikost výstupních dat. Pro následující statistické vyhodnocení je zapotřebí, aby se shodovala velikost záznamu zpracovaného mnou navrženou metodou s velikostí záznamu zpracovaným expertem. Řešením bylo adekvátně rozšířit binární matici o chybějící data, pomocí funkce `repelem`, která dodá chybějící počet kladných detekcí za každou kladnou detekci a chybějící počet záporných detekcí za každou zápornou detekci. Výsledkem je detekce svalového artefaktu u všech vzorků, které patří pod daný úsek identifikovaný pomocí STFT.


Výkonové spektrum bylo spočítáno pomocí metody STFT s vhodně zvolenými parametry nastavení. Na obrázku 4.5 je vidět grafická reprezentace časově-frekvenční analýzy metodou STFT s vybranými parametry u testovacího EEG záznamu.



Obrázek 4.5: Grafická reprezentace STFT využívané v metodě detekce svalového artefaktu. STFT je zde aplikována na testovací EEG záznam, žlutá část reprezentuje segmenty, které by následně měly být detekovány jako svalový artefakt. Spektrogram byl vytvořen z prvního kanálu.

Aby bylo možné určit prahovou hodnotu spektrálního výkonu je třeba výkonové spektrum zprůměrovat přes vybrané frekvenční složky, ve kterých by se měl vyskytovat svalový artefakt. Na obrázku 4.6 lze pozorovat příklad zprůměrovaného výkonového spektra reálného testovacího EEG signálu z prvního kanálu, zpracovaného pomocí

Krátkodobé Fourierovy transformace. Zelené špičky jsou úseky, které by měly být označeny mnou navrženou metodikou jako svalový artefakt.



Obrázek 4.6: Příklad zprůměrovaného výkonového spektra EEG signálu z prvního kanálu, zpracovaného pomocí Krátkodobé Fourierovy transformace.

Následně jsem musela určit prahovou hodnotu průměrného výkonu k detekci úseku, obsahující svalový artefakt. Svalový artefakt má vyšší amplitudu než fyziologická složka EEG signálu, proto v úsecích, kde se vyskytuje svalový artefakt je větší hodnota výkonu. Pomocí ROC křivky (viz kapitola 4.5) jsem zvolila prahovou hodnotu výkonu, která nejlépe identifikuje svalový artefakt. Prahová hodnota výkonu byla hledána v rozmezí $0,1-0,8 \mu V^2/Hz$ s krokem $0,01$. Vypočítané hodnoty jsem použila pro následnou ROC křivku. Prahovou hodnotu jsem na základě statistické analýzy zvolila $0,35 \mu V^2/Hz$ (viz kapitola 4.5). Segmenty EEG záznamu, kde hodnota průměrného výkonu překročila nastavenou prahovou hodnotu, byly vyhodnoceny jako segmenty obsahující svalové artefakty. Výsledky detekcí byly uloženy do binárních matic pro následné statistické vyhodnocení.

4.5 Statistické vyhodnocení

Pro statistické hodnocení výkonu se často používá výpočet senzitivity a specifity, viz [11]. K použití senzitivity a specifity jako měřítka výkonu je zapotřebí klasifikace do dvou tříd, jak tomu bylo i v tomto případě. Statistická analýza byla v této práci rozdělena na dvě části. V první části jsem pomocí ROC křivky určila ideální prahovou hodnotu na testovacích EEG datech. V druhé části jsem na validačních datech ověřila úspěšnost mnou vytvořené metody detekce svalového artefaktu. Obě části statistické analýzy využívají právě výpočtu senzitivity a specifity.

Pro výpočet senzitivity a specifity je nejprve nutné vypočítat následující parametry:

- TP – true positive (správně pozitivní): expertem označený artefakt je správně detekován mnou navrženou metodikou.
- FP – false positive (falešně pozitivní): artefakt je falešně detekován mnou navrženou metodikou.
- FN – false negative (falešně negativní): expertem označený artefakt nebyl detekován mnou navrženou metodikou.
- TN – true negative (správně negativní): správná detekce úseků bez artefaktů.

Vytvořením binárních matic byla mezi sebou porovnaná data ze dvou záznamů, čímž byl získán počet TP, FP, FN, TN výsledků. Následně jsem tyto parametry využila pro výpočet senzitivity a specifity navržené metody (viz rovnice 4.8, 4.9). Senzitivita popisuje citlivost testu a vyjadřuje úspěšnost, s níž test zachytí přítomnost sledovaného stavu (artefaktu) v záznamu, viz rovnice (4.8).

$$SE = \frac{TP}{TP+FN}, \quad (4.8)$$

kde TP znamená, že expertem označený artefakt je správně detekován mnou navrženou metodikou, FN znamená, že expertem označený artefakt nebyl detekován mnou navrženou metodikou.

Specifita vyjadřuje schopnost testu správně vybrat případy, u nichž se zkoumaný stav (artefakt) nevyskytuje, viz rovnice (4.9).

$$SP = \frac{TN}{TN+FP}, \quad (4.9)$$

kde TN znamená správnou detekci úseků bez artefaktů, FP znamená, že artefakt je falešně detekován mnou navrženou metodikou.

Pro statistické stanovení optimální prahové hodnoty výkonu byla využita ROC analýza, která vyjadřuje vztah mezi specifitou a senzitivitou navržené metody. Pro ROC analýzu bylo spočítáno 70 hodnot specifity a senzitivity s různě nastavenou prahovou hodnotou výkonu v rozmezí 0,1–0,8 $\mu V^2/Hz$ pro reálná testovací EEG data. Z hodnot senzitivity a specifity získaných pro testovací EEG signál byla vytvořena ROC křivka, kde na ose x je 1-specifita a na ose y je senzitivita spočtené pro testované úrovně prahové hodnoty. Z ROC křivky lze stanovit optimální prahovou hodnotu výkonu, v místě, kde dochází ke změně strmosti křivky (viz Obrázek 5.8). Tento bod reprezentuje ideální poměr mezi senzitivitou a specifitou.

Následně bylo provedeno statistické hodnocení mnou navržené metodiky pomocí reálných EEG záznamu pro validaci. Data pro validaci obsahují EEG záznam s úseky, které všichni experti označili jako segment s artefakty a záznam s úseky, které označil


alespoň jeden expert. Pro EEG záznam, kde svalový artefakt detekovali všichni experti, jsou charakteristické výraznější artefakty a menší chybovost experta. Vyhodnocením mnou navržené metodiky pomocí tohoto záznamu lze určit efektivitu metodiky. Pro EEG záznam, kde svalový artefakt detekoval aspoň jeden expert, jsou charakteristické méně výrazné artefakty a větší chybovost experta. Vyhodnocením mnou navržené metodiky pomocí tohoto záznamu lze zjistit schopnost metodiky detekovat i méně výrazné artefakty, stejně jako schopnost metodiky zbytečně nedetekovat neexistující artefakty.

5 Výsledky

V celé práci jsem používala 3 druhy dat: simulovaná data, reálná testovací data a reálná data pro validaci. Simulovaná EEG data jsem používala k výběru funkční metody časově-frekvenční analýzy (STFT, vlnková transformace) s vhodným nastavením parametrů pro následnou detekci svalového artefaktu. Reálná testovací data jsem používala pro vytvoření metodiky detekující svalový artefakt a nastavení prahové hodnoty metodiky. Reálná validační data jsem používala pro testování a vyhodnocení mnou navržené metodiky detekce svalového artefaktu.


5.1 Výběr metody časově-frekvenční analýzy

Pro volbu vhodné metody časově-frekvenční analýzy s optimálním nastavením parametrů k odstranění svalového artefaktu v reálných záznamech jsem vytvořila simulovaný EEG signál pro otestování různých nastavení časově-frekvenční analýzy. Pro každou z metod (STFT a Vlnková transformace) jsem otestovala tři různá nastavení (viz kapitola 4.3), které jsem aplikovala na simulovaný EEG signál, kde jsem přesně věděla charakteristiky analyzovaného signálu (viz Tabulka 4.1). Na obrázku 5.1 je uveden simulovaný EEG signál délkou 80 s.




Obrázek 5.1: Celý simulovaný EEG signál.

Aplikováním Krátkodobé Fourierové transformace s různým nastavením parametrů, byla získána časově-frekvenční analýza simulovaného EEG signálu. Na obrázku 5.2 je uveden spektrogram v definovaném frekvenčním pásmu 1–40 Hz s frekvenčním krokem 0,1 Hz ze záznamu, získaného analýzou simulovaného EEG záznamu, s časovým krokem po 0,2 s. Jednalo se tedy o nastavení číslo 1 (viz kapitola 4.3.1). Použito bylo Hanningovo časové okno s nastaveným parametrem délky 0,6 s.



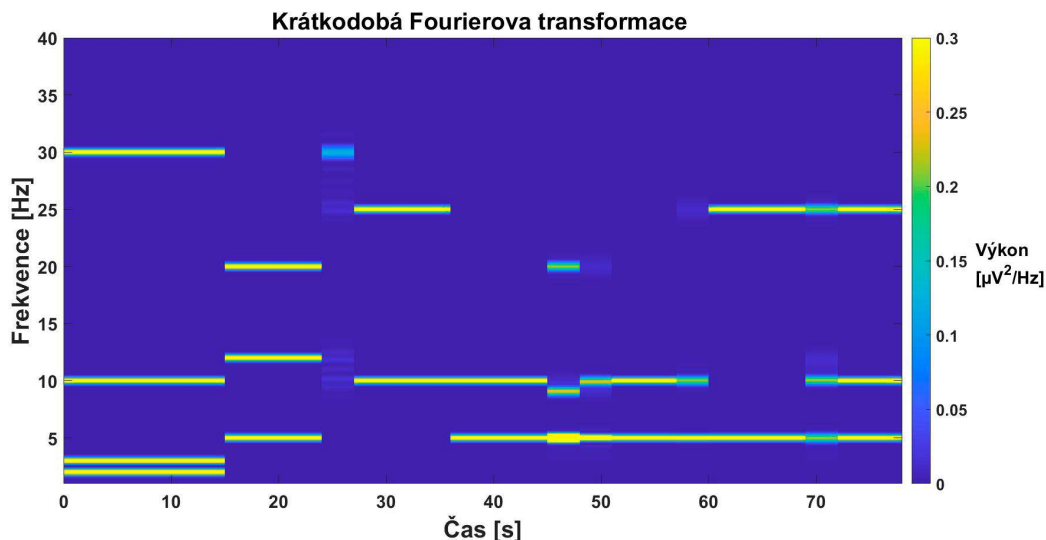
Obrázek 5.2: Časově-frekvenční analýza simulovaného EEG signálu po **STFT s použitým nastavením č. 1**, s frekvenčním krokem 0,1 Hz, časovým krokem po 0,2 s a nastaveným parametrem délky okna 0,6 s.

Na obrázku 5.3 je uveden spektrogram v definovaném frekvenčním pásmu 1–40 Hz s frekvenčním krokem 0,1 Hz ze záznamu, získaného analýzou simulovaného EEG záznamu, s časovým krokem po 0,2 s. Jednalo se tedy o nastavení číslo 2 (viz kapitola 4.3.1). Použito bylo Hanningovo časové okno s nastaveným parametrem délky 0,2 s.



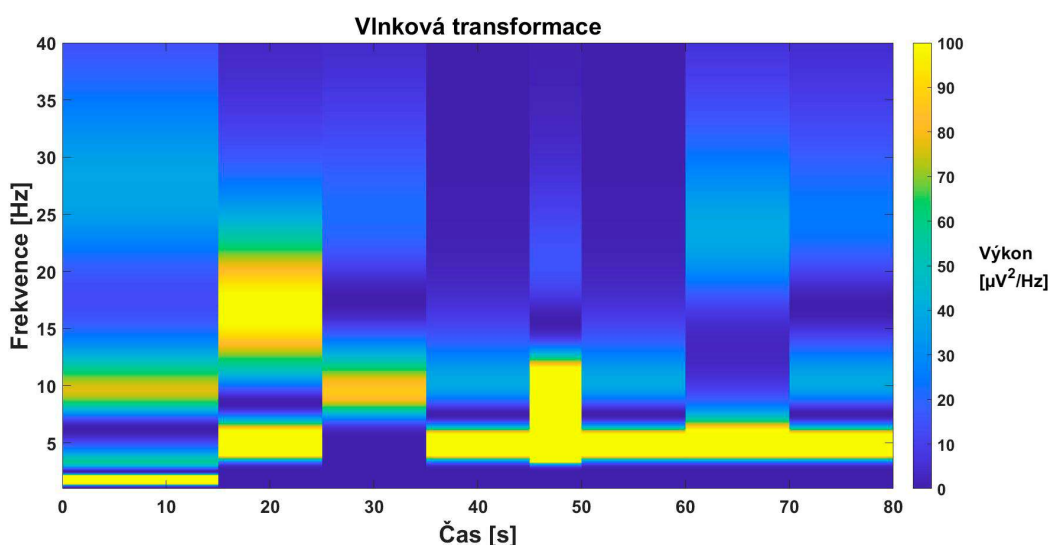
Obrázek 5.3: Časově-frekvenční analýza simulovaného EEG signálu po **STFT s použitým nastavením č. 2**, s frekvenčním krokem 0,1 Hz, časovým krokem po 0,2 s a nastaveným parametrem délky okna 0,2 s.

Na obrázku 5.4 je uveden spektrogram v definovaném frekvenčním pásmu 1–40 Hz s frekvenčním krokem 0,001 Hz ze záznamu, získaného analýzou simulovaného EEG záznamu, s časovým krokem po 3 s. Jednalo se tedy o nastavení číslo 3 (viz 4.3.1). Použito bylo Hanningovo časové okno s nastaveným parametrem délky 3 s.




Obrázek 5.4: Časově-frekvenční analýza simulovaného EEG signálu po **STFT s použitým nastavením č. 3**, s frekvenčním krokem 0,001 Hz, časovým krokem po 3 s a nastaveným parametrem délky okna 3 s.

Druhou metodou pro získání časově-frekvenční analýzy byla zvolena Vlnková transformace. Na obrázku 5.5 je uveden spektrogram po aplikování na simulovaný EEG signál s použitím vlnky Morlet o šířce 3. Definované frekvenční pásmo je v rozmezí 1–40 Hz. Časový interval je v rozmezí 1,5–78,5 s krokem o velikosti 5 s. Jednalo se tedy o nastavení Vlnkové transformace číslo 1 (viz kapitola 4.3.2).




Obrázek 5.5: Časově-frekvenční analýza simulovaného EEG signálu po **Vlnkové transformaci s použitým nastavením č. 1**, s časovým krokem po 5 s a nastaveným parametrem šířky vlnky 3.

Na obrázku 5.6 je uveden spektrogram po aplikování na simulovaný EEG signál s použitím vlnky Morlet o šířce 5. Definované frekvenční pásmo je v rozmezí 1–40 Hz. Časový interval je v rozmezí 2.5–77.5 s krokem o velikosti 7 s. Jednalo se tedy o nastavení Vlnkové transformace číslo 2 (viz 4.3.2).



Obrázek 5.6: Časově-frekvenční analýza simulovaného EEG signálu po **Vlnkové transformaci s použitým nastavením č. 2**, s časovým krokem po 7 s a nastaveným parametrem šířky vlnky 5.

Na obrázku 5.7 je uveden spektrogram po aplikování na simulovaný EEG signál s použitím vlnky Morlet o šířce 8. Definované frekvenční pásmo je v rozmezí 1–40 Hz. Časový interval je v rozmezí 4–76 s krokem o velikosti 9 s. Jednalo se tedy o nastavení Vlnkové transformace číslo 3 (viz 4.3.2).



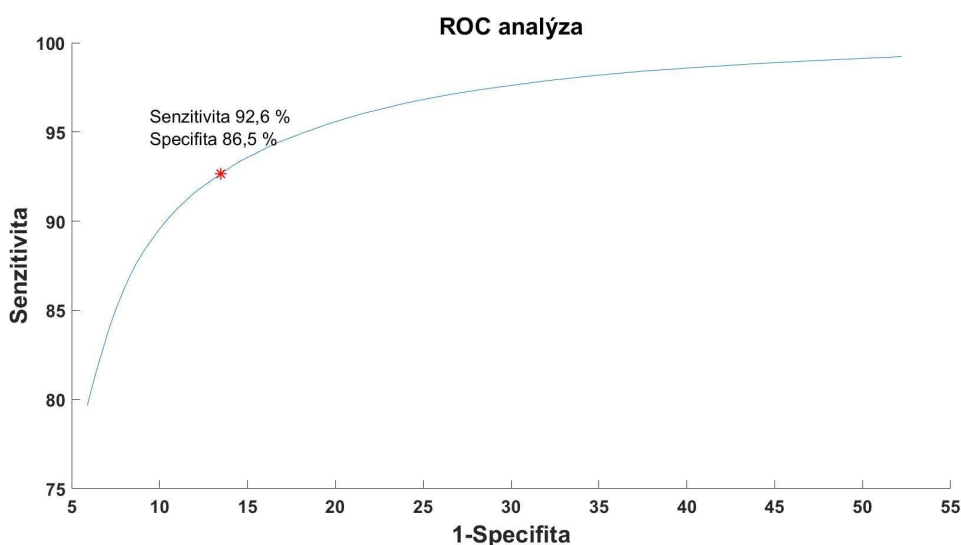
Obrázek 5.7: Časově-frekvenční analýza simulovaného EEG signálu po **Vlnkové transformaci s použitým nastavením č. 3**, s časovým krokem po 9 s a nastaveným parametrem šířky vlnky 8.

Metoda STFT ukázala lepší výsledky než metoda Vlnkové transformace. Metoda STFT byla méně časově náročná a umožňovala spočítat výkonové spektrum na delším úseku EEG záznamu se zachováním jemnějšího kroku posuvného okna na rozdíl od Vlnkové transformace.

5.2 Nastavení hranice pro detekci svalového artefaktu

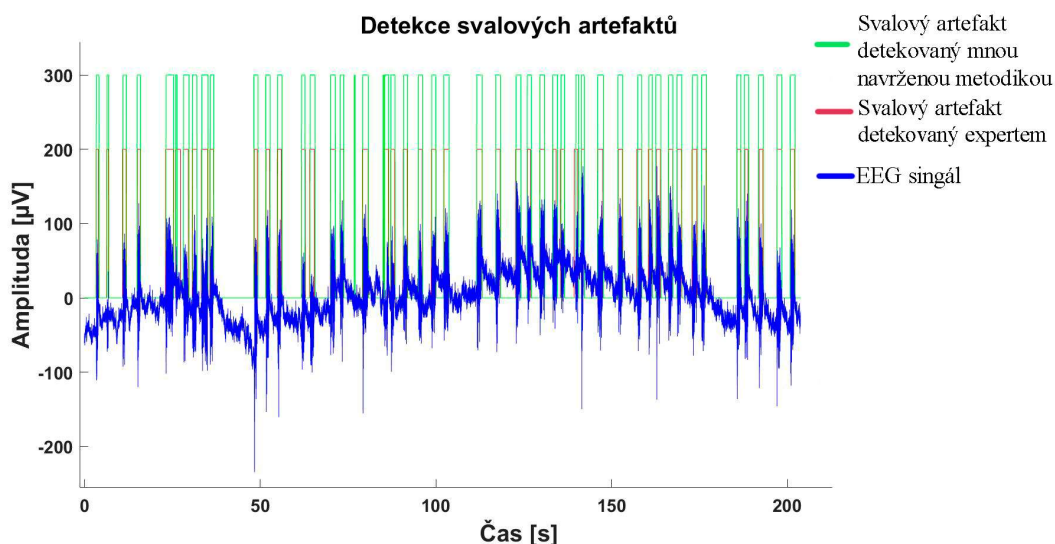
Ke zpracování reálných testovacích EEG dat jsem zvolila nastavení číslo 1 (viz Tabulka 4.2) ze studie EMG signálu viz [17]. Krátkodobá Fourierova transformace s nastavením č. 1 (viz Obrázek 5.2) zároveň vykazovala nejlepší výsledky.

Následně STFT s nastavením číslo 1 (viz 4.3.1) byla použita na reálná testovací data pro nastavení prahové hodnoty výkonu, která byla využita k detekci svalových artefaktů. V místech, kde zprůměrovaná hodnota výkonu překročila nastavený práh, byly detekovány svalové artefakty. Hodnota prahu byla hledaná v rozmezí $0,1 - 0,8 \mu V^2/Hz$ s krokem 0,01. Poté byla hodnota prahu určena z ROC křivky a nastavena na $0,35 \mu V^2/Hz$, kde hodnota senzitivity byla 92,6 % a hodnota specifity byla 86,5 %. Na obrázku 5.8 je vidět ROC křivka, kde červený bod reprezentuje ideální poměr mezi senzitivitou a specifitou.



Obrázek 5.8: ROC křivka, spočítaná pro různé hodnoty prahu. Červený bod reprezentuje optimální nastavení hodnoty prahu $0,35 \mu V^2/Hz$, kde senzitivita má hodnotu 92,6 % a specifita má hodnotu 86,5 %. Na ose x je 1-Specifita, na ose y je Senzitivita.

Na obrázku 5.9 je vidět záznam testovacího EEG z 200. kanálu, kde mnou navržená metodika detekovala úseky, obsahující svalový artefakt. Červeně jsou označené detekce svalových artefaktů od experta a zeleně jsou označené detekce mnou navrženou metodikou.



Obrázek 5.9: Detekce svalových artefaktů v záznamu z 200. kanálu mnou navrženou metodikou na reálných testovacích EEG datech.

5.3 Vyhodnocení metodiky detekce svalového artefaktu

Pro statistickou analýzu byly použity 2 druhy hodnocení – jeden, kde se shodlo všech 5 expertů na výskytu svalového artefaktu, a druhý, kde se za svalový artefakt považoval jakýkoli úsek, který identifikoval alespoň jeden expert. Pro statistické vyhodnocení mnou navržené metodiky jsem používala validační reálná EEG data. V tabulce 5.1 je vidět statistické vyhodnocení EEG záznamu, hodnoceného 5 experty. Za svalový artefakt je zde brán pouze úsek, kde se shodlo všech 5 expertů. Průměrná specifita a senzitivita byla vypočtena z 10 záznamu, kde se všichni experti shodli o výskytu artefaktů v jednotlivých úsecích.

Tabulka 5.1: Statistické hodnocení reálného EEG záznamu s označenými úseky svalových artefaktů, na kterých se shodlo všech 5 expertů. Tabulka obsahuje senzitivitu a specifitu jednotlivých úseků a jejich průměrné hodnoty.

Subjekt	Senzitivita [%]	Specifita [%]
Číslo 1	56	87
Číslo 2	71	84
Číslo 3	59	66
Číslo 4	88	88
Číslo 5	59	78
Číslo 6	61	86
Číslo 7	69	87
Číslo 8	93	89
Číslo 9	91	93
Číslo 10	83	94
Průměrná senzitivita	72 %	
Průměrná specifita	84 %	

V tabulce 5.2 je vidět statistické vyhodnocení EEG záznamu, hodnoceného 5 experty. Za svalový artefakt byl zde považován jakýkoli segment, který identifikoval alespoň jeden expert. Průměrná specifita a senzitivita byla vypočtena z 10 záznamu, kde úsek s artefaktem označil aspoň jeden expert.

Tabulka 5.2: Statistické hodnocení reálného EEG záznamu s označenými úseky svalových artefaktů, které identifikoval alespoň jeden expert z 5. Tabulka obsahuje senzitivitu a specificitu jednotlivých úseků a jejich průměrné hodnoty.

Subjekt	Senzitivita [%]	Specifita [%]
Číslo 1	19	93
Číslo 2	21	85
Číslo 3	42	72
Číslo 4	30	98
Číslo 5	36	89
Číslo 6	40	89
Číslo 7	20	87
Číslo 8	51	92
Číslo 9	26	95
Číslo 10	14	96
Průměrná senzitivita	31 %	
Průměrná specifita	88 %	

6 Diskuse

6.1 Výběr metody časově-frekvenční analýzy

V této práci byly analyzovány dvě metody časově-frekvenční analýzy. Metoda Krátkodobé Fourierovy transformace s použitím Hanningova časového okna a metoda vlnkové transformace s použitím Morletovy vlnky. Při analýze optimálních parametrů délky okna byly získány spektrogramy.

Navrhla jsem simulovaný EEG signál pro frekvenční analýzu, pomocí metod STFT a Vlnkové transformace. Bylo vytvořeno několik časových úseků různé délky, obsahujících různé frekvenční složky. Tato kombinace proměnné délky časových úseků frekvenčních složek přibližuje simulaci k reálnému kvazistacionárnímu EEG signálu. Protože jsem přesně věděla charakteristiky analyzovaného signálu, mohla jsem zjistit vhodnou metodu a nastavení časově-frekvenční analýzy.

Použití STFT s nastavením č. 1 (viz Tabulka 4.2), je vidět na obrázku 5.2. Nastavení STFT č. 1 v této práci bylo považováno za optimální nastavení, kde bylo docíleno kompromisu mezi rozlišením v časové a frekvenční oblasti. Na úseku 20–60 s lze určit, které frekvenční složky se vyskytují v signálu, za použití delšího časového okna 0,6 s, na rozdíl od nastavení č. 2. Při použití nastavení č. 2 (viz Tabulka 4.2), je vidět na obrázku 5.3 lepší časové rozlišení, ale horší frekvenční rozlišení, za použití kratšího časového okna 0,2 s. Na úseku 25–30 s lze určit u nastavení č. 1 přesný čas, vyskytujících se frekvenčních složek, za použití kratšího časového okna 0,6 s, na rozdíl od nastavení č. 3. Na celé délce záznamu není možné přesně určit, které frekvence se vyskytují v signálu. Při použití nastavení č. 3 (viz Tabulka 4.2), je vidět na obrázku 5.4 výrazně lepší frekvenční rozlišení na úkor časového rozlišení. Na úseku 0–15 s lze rozlišit vyskytující se frekvenční složky 2 Hz a 3 Hz. Nevýhodou toho nastavení je ztráta informace v časové oblasti, za použití delšího časového okna 3 s. Na úseku 25–30 s nelze přesně určit okamžitou frekvenci.

Použití nastavení č. 1 Vlnkové transformace (viz Tabulka 4.3) je vidět na obrázku 5.5. Při použití vlnky s šířkou 3 dochází k lepšímu časovému rozlišení na úkor frekvenčnímu rozlišení. Na úsecích 0–10 s, 25–35 s a 60–70 s vyšší frekvenční složky 30 Hz a 25 Hz nejsou téměř detekovatelné. Použití nastavení č. 2 (viz Tabulka 4.3), je vidět na obrázku 5.6. Při použití vlnky s šířkou 5 dochází k zlepšení ve frekvenčním rozlišení. Na úseku 0–10 s lze rozlišit jak nižší frekvenční složky (2 Hz a 3 Hz), tak vyšší frekvenční složku (30 Hz). Frekvenční rozlišení nicméně není stále dostatečné. Použití nastavení č. 3 (viz Tabulka 4.3), je vidět na obrázku 5.7. Při použití delší vlnky s šířkou 8 dochází k výraznému zlepšení ve frekvenčním rozlišení na úkor časovému rozlišení. Ze záznamu lze přesně určit vyšší frekvenční složky (30 Hz a 25 Hz). Nevýhodou tohoto nastavení je zhoršení časového rozlišení. Na úseku 40–50 s nelze přesně určit frekvenci EEG signálu.

Při použití vlnkové transformace bylo dosaženo lepších výsledků s nastavením č. 2, kde šířka Morletovy vlnky byla nastavena na hodnotu 5. Metoda STFT dosahovala nejlepších výsledků s nastavením č. 1, kde bylo použito Hanningovo okno 0,6 s, s časovým krokem 0,2 s a frekvenčním krokem 0,1 Hz. Pro zpracování reálných testovacích EEG záznamů byla zvolena metoda STFT s nastavením č. 1, u které bylo docíleno kompromisu mezi rozlišením v časové a frekvenční oblasti. Spektrogram Vlnkové transformace se od spektrogramu STFT liší nehomogenním časově-frekvenčním rozlišením. To je dáno frekvencí vlnky a mohlo zapříčinit horší výsledky Vlnkové transformace.

6.2 Detekce svalových artefaktů

V dalším kroku byla aplikována metoda STFT s nastavením č. 1 v metodice pro odstranění svalových artefaktů. Pomocí STFT bylo spočítáno výkonové spektrum v definovaném frekvenčním pásmu 25–100 Hz, které odpovídá šířce pásma svalové aktivity. Následně bylo výkonové spektrum zprůměrováno, čímž jsem získala úseky s výrazně vyšší hodnotou výkonu než má mozková aktivita. V těchto úsecích by měl být detekován svalový artefakt. K detekci svalového artefaktu jsem použila nastavení prahové hodnoty výkonu. V místech, kde hodnota výkonu překročila nastavený práh, byly detekovány svalové artefakty. Metodika detekce svalového artefaktu byla nejprve testována na reálném EEG záznamu. Testovací záznam obsahoval velké množství výrazných svalových artefaktů, které subjekt vytvářel záměrně. Testovací EEG data byla použita k nastavení prahové hodnoty výkonu a testování detekčního algoritmu. Výkonové spektrum bylo vztaženo k určitému frekvenčnímu pásmu, které bylo zvoleno od 25 Hz do 100 Hz. Dolní a horní mezní hodnoty frekvenčního pásma byly zvoleny v souladu s mezními frekvencemi aktivit svalových artefaktů. Výpočet probíhal pro EEG kanály 1–50 a 225–256, umístěné na tváři a ve frontální oblasti. Zvolené EEG kanály obsahují záznamy z elektrod umístěných nejbliž ke zdroji artefaktů, proto zde byla větší pravděpodobnost výskytu svalových artefaktů. Hodnota prahu spektrálního výkonu pro detekci artefaktů byla hledána v rozmezí $0,1\text{--}0,8 \mu\text{V}^2/\text{Hz}$ s krokem 0,01. Následně byla z ROC analýzy (viz Obrázek 5.8) určena její optimální hodnota, kde hodnota senzitivity byla 92,6 % a hodnota specifity byla 86,5 %. Ve výkonovém spektru byla tedy nastavena prahová hodnota výkonu $0,35 \mu\text{V}^2/\text{Hz}$, V časových okamžicích, kde výkon překračoval nastavenou prahovou hodnotu, byly detekovány svalové artefakty.

6.3 Metodika detekce svalových artefaktů

Pro statistické vyhodnocení úspěšnosti mnou navržené metodiky byla použita validační EEG data, hodnocena pěti experty. Statistická analýza využívala výpočtu senzitivity a specifity.

Pro hodnocení úspěšnosti mnou navržené metodiky byla použita reálná validační EEG data. Data pro validaci obsahovala EEG záznam s úseky, které všichni experti označili jako segment s artefakty. V tomto záznamu svalové artefakty jsou jisté a výrazné, a chybovost experta je při takové shodě v podstatě vyloučena. Vyhodnocením mnou navržené metodiky pomocí tohoto záznamu bylo docíleno průměrné senzitivity 72 % a průměrné specifity 84 %. Dosažené hodnoty ukazují, že časově-frekvenční analýza na základě STFT dokázala úspěšně detekovat většinu svalových artefaktů.

Data pro validaci také obsahovala záznam s úseky, které označil jako segment s artefaktem alespoň jeden expert. V tomto záznamu artefakty jsou i málo výrazné a chybovost experta je větší, neboť ne vždy se experti shodli a tak alespoň jeden expert musel udělat chybu. Vyhodnocením mnou navržené metodiky pomocí tohoto záznamu bylo docíleno průměrné senzitivity 31 % a průměrné specifity 88 %. Nízká hodnota senzitivity může být způsobena málo výraznými artefakty (které navržená metodika nedokázala detekovat) nebo chybou jednoho či několika expertů. Důvodem nízké hodnoty senzitivity může být také chyba samotného detekčního algoritmu nebo algoritmu a experta zároveň. Hodnota průměrné specifity se u obou typů validačních dat byla prakticky totožná. Dosažené hodnoty specifity ukazují, že navržená metodika je schopna nedetekovat neexistující artefakty v záznamech obsahujících méně výrazné svalové artefakty, stejně jako v záznamech obsahujících pouze výraznější svalové artefakty.

Navržená metodika detekce svalových artefaktů, za pomoci časově-frekvenční analýzy na základě STFT detekovala pozice svalových artefaktů. Počet správně detekovaných svalových artefaktů v navržené metodice by mohl být vylepšen pomocí optimalizace pro různé parametry, například frekvenční pásmo, optimalizace výběru EEG kanálů.

7 Závěr

V této práci byly analyzovány metody transformace EEG signálu do komplexního prostoru v programovém prostředí MATLAB s použitím toolboxu FieldTrip. Jako dvě běžně používané metody pro získání časově-frekvenční analýzy byla zvolena Krátkodobá Fourierova transformace a Vlnková transformace. Jednotlivé metody byly testovány na mnou navrženém a implementovaném simulovaném EEG signálu. Simulovaný EEG signál obsahoval frekvenční složky, které odpovídaly rozmezí skutečných frekvenčních pásem EEG záznamu. Vytvořením několika časových úseků různé délky s různými frekvenčními složkami bylo dosaženo kvazistacionarity signálu, jež se přibližuje reálnému EEG záznamu.

U implementovaných metod byly nalezeny vhodné parametry pro přesnější rozlišení jak v časové, tak ve frekvenční oblasti. U Krátkodobé Fourierové transformace bylo zvoleno Hanningovo časové okno s nastavením parametru délky na 0,6 s, časovým krokem 0,2 s a frekvenčním krokem 0,01 Hz. V případě Vlnkové transformace byla zvolena vlnka typu Morlet se šířkou 5. Ze dvou výše analyzovaných metod dosahovala lepších výsledků metoda STFT s tímto nastavením. Taková šířka Hanningova okna zajišťovala nejlepší rozlišení jak v časové, tak ve frekvenční oblasti na použitém simulovaném signálu.

Na základě Krátkodobé Fourierovy transformace s nastavením č. 1 byla vytvořena metodika vhodná pro identifikaci svalových artefaktů pomocí reálných testovacích EEG dat. Pro statistické vyhodnocení mnou navržené metodiky byla navržena a realizována statistická analýza správnosti detekce svalových artefaktů na reálných EEG datech pro validaci. Statistickým hodnocením mnou navržené metodiky, pomocí reálného EEG záznamu s úseky, které všichni experti ohodnotili jako segmenty s artefakty, bylo docíleno průměrné senzitivity 72 % a průměrné specifity 84 %. Statistickým hodnocením mnou navržené metodiky, pomocí reálného EEG záznamu s úseky, které označil alespoň jeden expert jako segmenty s artefakty, bylo docíleno průměrné senzitivity 31 % a průměrné specifity 88 %. Nízká senzitivita metody mohla být ovlivněna následujícími faktory: málo výraznými artefakty (které nebyly expertem detekovány), chybně označené expertem artefakty, chyba metodiky nebo chyba metodiky a experta zároveň.

Navržena metodika detekce svalových artefaktů, za pomoci časově-frekvenční analýzy na základě STFT detekovala pozice většiny výrazných svalových artefaktů.

Seznam použité literatury

- [1] MIKE X COHEN, 1979. Analyzing Neural Time Series Data: Theory and Practice. London, England : Cambridge, Massachusetts, The MIT Press. ISBN 978-0-262-01987-3
- [2] URIGÜEN, Jose Antonio a Begoña GARCIA-ZAPIRAIN. EEG artifact removal—state-of-the-art and guidelines. Journal of Neural Engineering. IOP Publishing, 2 April 2015n. 1., 2015(3), 1-23. Dostupné z: doi:031001
- [3] KOZUMPLÍK, Jiří. Elektroencefalogram (EEG) 2. část. [přednáška předmětu Analýza biologických sgnálů]. Brno: FEKT VUT, [2013]
- [4] PURANIK, Parag, R. V KSHIRSAGAR a Sagar MOTDHARE. Elementary Time Frequency Analysis of EEG Signal Processing. EAI Endorsed Transactions on Pervasive Health and Technology [online]. 2018, 2018, 2018(4), 1-6 [cit. 2021-04-06]. ISSN 24117145. Dostupné z: doi:10.4108/eai.13-7-2018.155081
- [5] MUTHUKUMARASWAMY, Suresh. High-frequency brain activity and muscle artifacts in MEG/EEG. Frontiers in Human Neuroscience. 2013(7), 138. ISSN 1662-5161. Dostupné z: doi:10.3389/fnhum.2013.00138
- [6] CHEN, Xun, Chen HE a Hu PENG. Removal of Muscle Artifacts from Single-Channel EEG Based on Ensemble Empirical Mode Decomposition and Multiset Canonical Correlation Analysis. Journal of Applied Mathematics [online]. 2014, 12.06.2014, 2014(2014), 10 [cit. 2021-04-02]. ISSN 16870042. Dostupné z: doi:10.1155/2014/261347
- [7] NEVŘIVA, Pavel. Úvod do analýzy signálů a soustav pro integrovanou výuku VUT a VŠB-TUO. Ostrava: VŠB-Technická univerzita Ostrava, 2014. ISBN 978-80-248-3560-0.
- [8] TRNKA, Jan. Časově frekvenční analýza biomedicínských signálů. Ostrava, 2019. Diplomová práce. VŠB – Technická univerzita Ostrava
- [9] PHINYOMARK, Angkoon, Pornchai PHUKPATTARANONT a Chusak LIMSAKUL. Feature reduction and selection for EMG signal classification. Expert Systems with Applications [online]. 2012, 2012(8), 7420-7431 [cit. 2021-5-12]. ISSN 0957-4174. Dostupné z: doi:https://doi.org/10.1016/j.eswa.2012.01.102.
- [10] STANKOVIĆ, Ljubiša, Miloš DAKOVIĆ a Thayannathan THAYAPARAN. Timefrequency signal analysis with applications. Norwood, MA: Artech House, c2013. Artech House radar library. ISBN 978-1-60807-651-2.

- [11] SUBASI, A., KIYMIK, M.K. Muscle Fatigue Detection in EMG Using Time–Frequency Methods, ICA and Neural Networks. *J Med Syst* 34, 777–785 (2010). <https://doi.org/10.1007/s10916-009-9292-7>
- [12] OOSTENVELD, R., Pascal FRIES, Eric MARIS, and Jan-Mathijs SCHOFFELEN. FieldTrip: Open Source Software for Advanced Analysis of MEG, EEG, and Invasive Electrophysiological Data. *Computational Intelligence and Neuroscience*, vol. 2011, Article ID 156869, 9 pages, 2011. doi:10.1155/2011/156869.
- [13] CERUTTI, S. On Time-frequency Techniques in Biomedical Signal Analysis. *Methods Inf Med*. 2013.
- [14] NETOPIIL, O. Frekvenční analýza stabilometrických signálů. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2016
- [15] BECK, TW, HOUSH, TJ, JOHNSON, GO, WEIR, JP, CRAMER, JT, COBURN, JW a MALEK, MH, Porovnání Fourierových a waveletových transformačních postupů pro zkoumání mechanomyografických a elektromyografických frekvenčních doménových odpovědí během únavných isokinetických svalových akcí biceps brachii .. *J. Electromyogr. Kinesiol* . 15: 190–199, 2005. doi: 10.1016 / j.jelekin.2004.08.007 .
- [16] MAJKOWSKI, Andrzej, Marcin KOŁODZIEJ a Remigiusz RAK. Joint time frequency and wavelet analysis – an introduction. *Metrology and measurement systems*. 2014, (4).
- [17] RYAN, Eric D., Joel T. CRAMER, Alison D. EGAN, Michael J. HARTMAN a Trent J. HERDA. Time and frequency domain responses of the mechanomyogram and electromyogram during isometric ramp contractions: A comparison of the short-time Fourier and continuous wavelet transforms. *Journal of Electromyography and Kinesiology* [online]. 2008, 2008(18), 55-67 [cit. 2021-04-06]. Dostupné z: doi:10.1016/j.jelekin.2006.09.003
- [18] TUNCEL, D., A DIZIBUYUK a KIYMIK. Time Frequency Based Coherence Analysis Between EEG and EMG Activities in Fatigue Duration. *Journal of Medical Systems* [online]. 2010, 2010(34), 131–138 [cit. 2021-04-06]. Dostupné z: doi:https://doi.org/10.1007/s10916-008-9224-y
- [19] KUMAR, D. K., N. D. PAH a A. BRADLEY. Wavelet analysis of surface electromyography. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* [online]. 2003, 11(4), 400-406 [cit. 2021-04-09]. Dostupné z: doi:10.1109/TNSRE.2003.819901
- [20] WANG, Y., K.C. VELUVOLU a M. LEE. Time-frequency analysis of band-limited EEG with BMFLC and Kalman filter for BCI applications. *Journal of NeuroEngineering and Rehabilitation* [online]. 2013, 10(109) [cit. 2021-04-09]. Dostupné z: doi:10.1186/1743-0003-10-109

- [21] MATLAB R . The MathWorks, Inc., 2020. Release: 2020b.
- [22] ONDRYÁŠ, O. Aplikace krátkodobé Fourierovy transformace pro biomedicínské signály – laboratorní úloha. Ostrava, 2019. Bakalářská práce. VŠB – Technická univerzita Ostrava.
- [23] MATLAB R . The MathWorks, The Wavelet Toolbox, Inc., 1994-2005.
- [24] LUO, Yu, WANG Yulin. A statistical Time-Frequency Model for Non-stationary Time Series Analysis. *IEEE Transaction on Signal Processing* [online]. 2020, **68**(4757) [cit. 10.1.2021]. ISSN 1053-587X. Dostupné prostřednictvím Mendelej: DOI: 10.1109/TSP.2020.3014607
- [25] OPPENHEIM, Alan V., Ronald W. SCHAFER a John R. BUCK. Discrete-Time Signal Processing. 07458. New Jersey: Upper Saddle River, 1999. ISBN 0137549202.
- [26] TRÁGE, David. *Časově-frekvenční analýza*. Brno, 2009. Bakalářská práce. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ. Vedoucí práce Ing. Radek Kubásek, Ph.D
- [27] SOUISSI, Youssef, M ABDELAZIZ, El AABID, Nicolas DEBANDE, Sylvain GUILLEY a Jean-Luc DANGER. *Novel Applications of Wavelet Transforms based Side-Channel Analysis*. [online]. **2021** [cit. 2021-04-21].
- [28] VALTER, Boris. *Vlnková transformace*. Praha, 2015. Bakalářská práce. Univerzita Karlova v Praze. Vedoucí práce Doc. RNDr. Zdeněk Hlávka, Ph.D.

Příloha A: Obsah přiložených souborů

Zadání_bakalářské_práce.pdf	Zadání bakalářské práce v PDF
Abstrakt.pdf	Abstrakt česky
Abstract.pdf	Abstrakt anglicky
Klíčová_slova.pdf	Klíčová slova v ČJ
Keywords.pdf	Klíčová slova v AJ
Zdrojový kód	Složka se zdrojovým kódem
EEG_simulovany.mat	Funkce vytvoří simulovaný signál
Vyber_metody.mat	Testování parametrů STFT a Vlnkové transformace
STFT_detekce_test_data.mat	Detekce svalových artefaktů
Vyhodnoceni_validacni_data.mat	Statistické vyhodnocení metodiky detekce svalových artefaktů
17PBBBBP_482916_Veranika_Tuzankina.pdf	Bakalářská práce v PDF